

医学图像配准的多策略优化方法库及LLM动态调度研究

钟泽伟

广东工业大学数学与统计学院, 广东 广州

收稿日期: 2026年4月1日; 录用日期: 2026年5月2日; 发布日期: 2026年5月11日

摘要

医学图像配准中, 不同优化方法在不同样本和优化阶段的表现并不一致, 单一固定算法往往难以兼顾精度与稳定性。针对CT-MRI多模态配准中的9参数受限仿射变换问题, 文章构建了包含8种方法的候选库, 并在三组等预算配置下比较其整体精度、阶段收敛特征和跨样本稳定性。结果表明, 各方法之间存在明显互补性: CRO-ZZ-QLS整体表现最好, Powell收敛较快但容易停留在局部最优, CRO-ZZ-QLS与CRO-SL在跨样本上更稳定。在此基础上, 进一步提出基于LLM的动态调度方法, 使其在等评估预算下从候选算法与种群配置中进行离散选择。实验结果显示, LLM调度的平均NMI为0.2388, 较最佳静态方法提高0.72%, 且14个样本中有9个取得最优结果。说明将全局探索与后期局部精修结合起来, 有助于进一步提升配准性能。

关键词

医学图像配准, 多策略方法库, 动态算法选择, 大语言模型, 进化计算

Research on Multi-Strategy Optimization Method Library and LLM Dynamic Scheduling for Medical Image Registration

Zewei Zhong

School of Mathematics and Statistics, Guangdong University of Technology, Guangzhou Guangdong

Received: April 1, 2026; accepted: May 2, 2026; published: May 11, 2026

Abstract

In multimodal medical image registration, different optimization methods often behave differently

across samples and optimization stages, so a single fixed algorithm is usually insufficient. For the 9-parameter constrained affine transformation problem in CT-MRI registration, this paper builds a candidate library of eight methods and compares their overall accuracy, stage-wise convergence, and cross-sample stability under three equal-budget settings. The results show clear complementarity among the methods: CRO-ZZ-QLS achieves the best overall performance, Powell converges quickly but is more likely to get trapped in local optima, and CRO-ZZ-QLS, together with CRO-SL, shows better stability across samples. Based on these observations, an LLM-based dynamic scheduling method is further introduced to select algorithms and population settings under the same evaluation budget. Experimental results show that the proposed scheduler reaches a mean NMI of 0.2388, improving the best static method by 0.72% and obtaining the best result on 9 of 14 samples. These results suggest that combining global exploration with later local refinement is beneficial for improving registration performance.

Keywords

Medical Image Registration, Multi-Strategy Method Library, Dynamic Algorithm Selection, Large Language Model, Evolutionary Computation

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

1.1. 研究背景与问题

CT、MRI 等医学成像模态在成像机理、空间分辨率和组织对比度等方面存在明显差异,因此多模态医学图像配准一直是影像融合、手术导航和放射治疗规划中的基础问题[1]-[3]。近年来,深度学习方法逐渐被用于医学图像配准,但在参数化配准场景下,传统优化方法仍然占据主导地位[2] [4]。其核心任务是估计固定图像与浮动图像之间的空间变换参数,使二者在统一坐标系下实现对齐[5]。除基于图像强度的配准外,点集配准和非刚性建模方法也在相关研究中得到广泛关注[6]。

在参数化配准中,配准过程通常可表述为围绕相似性度量展开的迭代优化问题。对于多模态图像,归一化互信息(NMI)是常用的目标函数[3] [7]。但这类目标函数通常具有非线性、非凸和多峰等特点,优化过程中容易陷入局部极小值[3] [12]。

针对这一问题,已有研究尝试了多种优化方法,包括珊瑚礁优化算法(CRO)及其扩展[8] [9]、CMA-ES [10]以及 Powell 法[11]等。相关比较研究表明,不同方法在搜索能力、收敛速度和适用场景上各有特点[12]。群体智能算法依靠较强的全局搜索能力,在复杂优化问题中表现出一定优势[13] [14];而 Powell 法等局部搜索方法虽然收敛较快,但在 NMI 形成的复杂搜索空间中更容易陷入局部最优,最终精度往往受限[11] [12]。与此同时,不同进化算法在搜索偏向和收敛行为上也存在差异,单一固定算法往往难以适应不同样本和不同优化阶段[15] [16]。基于此,本文关注的核心问题是:如何对多种优化方法进行系统比较与有效整合,以提高多模态医学图像配准的鲁棒性和精度。

1.2. 现有方法的局限及本文工作

现有静态优化方法主要面临两方面问题:其一,不同样本对应的目标函数形态存在差异,同一算法在不同病例上的表现并不稳定;其二,在同一样本的优化过程中,前期全局探索与后期局部精修对算法

的要求并不相同[15][16]。根据“没有免费的午餐”定理，不存在对所有问题都占优的通用算法[17]。已有研究表明，超启发式、自适应算法选择和参数调优方法可以通过高层策略改善鲁棒性[15][18][19]。近年来，LLM 也开始被用于优化任务，并显示出一定的算法调度潜力[20]-[23]，但其在连续数值优化中的局限也已有讨论[24][25]。对于本文关注的 CT-MRI 配准任务，直接让 LLM 生成连续变换参数并不是最自然也最稳妥的路径；相比之下，将其限定为高层离散策略选择器，使其仅在候选算法与配置集合内进行受约束决策，而底层连续参数优化仍由 CRO 变体与 Powell 等数值方法完成，更符合该问题“低维连续黑盒优化”的结构特点，也有助于保持调度过程的数值稳定性和可解释性。

基于上述背景，本文先构建包含 8 种方法的候选库，在统一预算下比较其精度、稳定性和阶段特征；随后在此基础上引入 LLM 进行动态调度，使其在固定决策边界上对候选算法与种群配置进行离散选择。本文的主要贡献包括：1) 构建并分析多策略配准方法库；2) 提出等预算约束下的 LLM 动态调度机制，并将 LLM 限定为高层离散调度器而非连续参数生成器；3) 设计跨算法的种群转移策略，以保证切换过程中的搜索连续性；4) 通过静态实验、规则调度对比与 LLM 动态实验验证该框架的有效性。

2. 配准优化方法与候选库

2.1. 问题定义

给定固定图像 $I_F: \Omega \rightarrow \mathbb{R}$ 和浮动图像 $I_M: \Omega \rightarrow \mathbb{R}$ ，其中 $\Omega \subset \mathbb{R}^3$ 为图像定义域。本文采用 9 参数受限仿射变换：

$$\theta = [r_x, r_y, r_z, s_x, s_y, s_z, t_x, t_y, t_z]^T \in \mathbb{R}^9$$

变换表达式为：

$$T_\theta(\mathbf{x}) = \mathbf{R}_z(r_z) \mathbf{R}_y(r_y) \mathbf{R}_x(r_x) \cdot \text{diag}(s_x, s_y, s_z) \cdot \mathbf{x} + [t_x, t_y, t_z]^T$$

各参数的约束范围为：旋转角 $[-0.5, 0.5]$ rad，缩放因子 $[0.8, 1.2]$ ，平移量 $[-50, 50]$ mm。

配准目标为最大化归一化互信息：

$$\theta^* = \arg \max_{\theta \in \Theta} \text{NMI}(I_F, I_M \circ T_\theta)$$

其中 $\text{NMI} = \frac{H(I_F) + H(I_M \circ T_\theta)}{H(I_F, I_M \circ T_\theta)}$ 。Dice 相似系数作为辅助评价指标(不参与优化)。

图 1 展示了 RIRE 数据集 Patient 001 的 CT-MRI 配准示例。配准前 CT 与 MRI 在空间上存在明显偏移(叠加图中红绿不重合)，经 CRO-ZZ-QLS 优化后($\text{NMI} = 0.261$)，两模态在解剖结构上基本对齐。

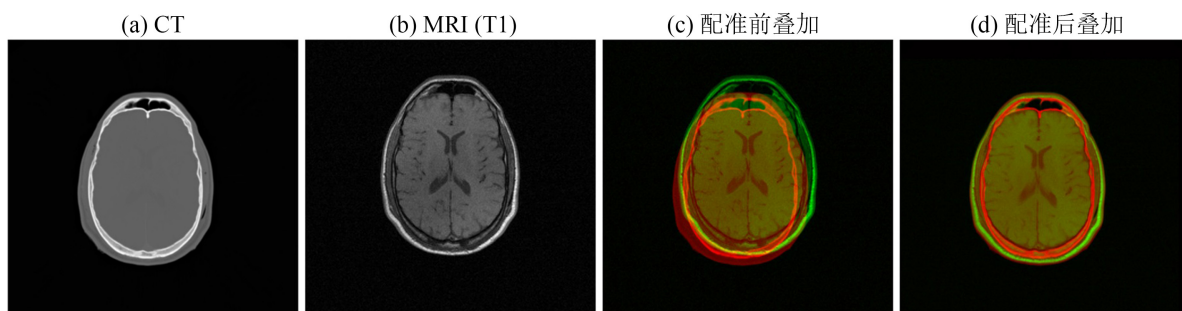


Figure 1. Before and after CT-MRI registration

图 1. RIRE 数据集 CT-MRI 配准前后对比

2.2. 候选方法库

本文构建的算法库包含 8 种方法，涵盖群体型进化算法、局部搜索和混合策略。表 1 列出了各方法的范式、搜索偏向和在动态调度框架中的角色。

Table 1. Candidate method library and role assignment
表 1. 候选方法库及其角色定位

方法名	对应范式	搜索偏向	本文角色	LLM 候选
CRO	标准 CRO	全局探索	基线候选	是
CRO-ZZ	本文提出	全局探索	主候选	是
CRO-ZZ-MSP	本文提出	探索 - 开发平衡	主候选	是
CRO-ZZ-QLS	本文提出	局部开发	主候选	是
CRO-ZZ-DES	本文提出	多样性维持	条件候选	是
Powell	方向集法	局部精修	快收敛候选	是
Gradient	梯度下降法	局部下降	参考基线	否
CRO-SL	自适应 CRO	自适应	自适应基线	否

上述方法中，CRO-ZZ、CRO-ZZ-MSP、CRO-ZZ-QLS 和 CRO-ZZ-DES 为本文在 CRO 基础上的改进变体，分别对应增强变异、平衡搜索、混合精修和双环境并行搜索等设计思路。表 1 中的角色划分并非预设，而是依据后续静态实验中各方法在阶段表现、稳定性和配置偏好上的差异进行归纳。

为评估方法库的实用价值，本文在 RIRE 数据集 14 个 CT-MRI 样本上进行了系统对比实验。静态实验采用三组等预算配置：Group A (种群 $100 \times$ 代数 50)、Group B (50×100)、Group C (25×200)，总评估次数均为 5000 次。

2.3. 静态性能分享

表 2 给出三组配置下各方法的 NMI 均值对比。

Table 2. Comparison of mean NMI across three configurations
表 2. 三组配置下各方法 NMI 均值对比

方法	Group A (100×50)	Group B (50×100)	Group C (25×200)	极差
CRO-ZZ-QLS	0.2414	0.2377	0.2322	0.0092
CRO-SL	0.2361	0.2323	0.2074	0.0287
Powell	0.2257	0.2257	0.2257	0.0000
CRO-ZZ-DES	0.2230	0.2232	0.2249	0.0019
CRO-ZZ-MSP	0.2234	0.2187	0.2181	0.0053
CRO-ZZ	0.2146	0.2171	0.2116	0.0055
CRO	0.1790	0.1740	0.1788	0.0050
Gradient	0.1408	0.1408	0.1408	0.0000

关键发现：1) CRO-ZZ-QLS 在三组配置中均排名第一；2) 不同方法跨配置表现差异明显，CRO-SL 在 C 组下降较多；3) Powell 和 Gradient 作为非种群算法，其结果不受种群配置影响(极差 = 0)，但精度

天花板低于最优进化算法——这体现了局部搜索方法在多峰搜索空间中的固有局限性：收敛快速但容易陷入局部最优。

这里我们采用变异系数(CV)衡量跨样本一致性：

$$CV = \frac{\sigma}{\bar{x}}$$

其中， σ 为方法在 14 个样本上 NMI 值的标准差， \bar{x} 为均值。表 3 给出稳定性分析结果。

Table 3. Cross-sample stability analysis (Group A configuration)

表 3. 跨样本稳定性分析(Group A 配置)

方法	NMI 均值	标准差	CV	稳定性等级
CRO-ZZ-QLS	0.2414	0.0228	0.094	优秀
CRO-SL	0.2361	0.0227	0.096	优秀
Powell	0.2257	0.0222	0.098	优秀
CRO	0.1790	0.0187	0.104	良好
CRO-ZZ-MSP	0.2234	0.0270	0.121	良好
CRO-ZZ	0.2146	0.0266	0.124	一般
CRO-ZZ-DES	0.2230	0.0307	0.138	一般
Gradient	0.1408	0.0288	0.205	一般

CRO-ZZ-QLS、CRO-SL、Powell 的 CV 均低于 0.10，属于优秀稳定性级别；Gradient 的 CV 高达 0.205，跨样本波动剧烈。

图 2 给出了不同方法在进化过程中的平均收敛趋势。可以看到，Powell 和梯度下降在初期改进较快，但很快进入停滞；CRO-ZZ-QLS 前期起步较慢，中后期仍能持续提升，最终达到最高 NMI；CRO-SL 后期表现较稳，CRO-ZZ-DES 和基础 CRO 则收敛相对较慢。由此可见，局部搜索方法在早期具有速度优势，而进化方法在中后期更容易获得更高精度，这种阶段互补性正是后续动态调度的依据。

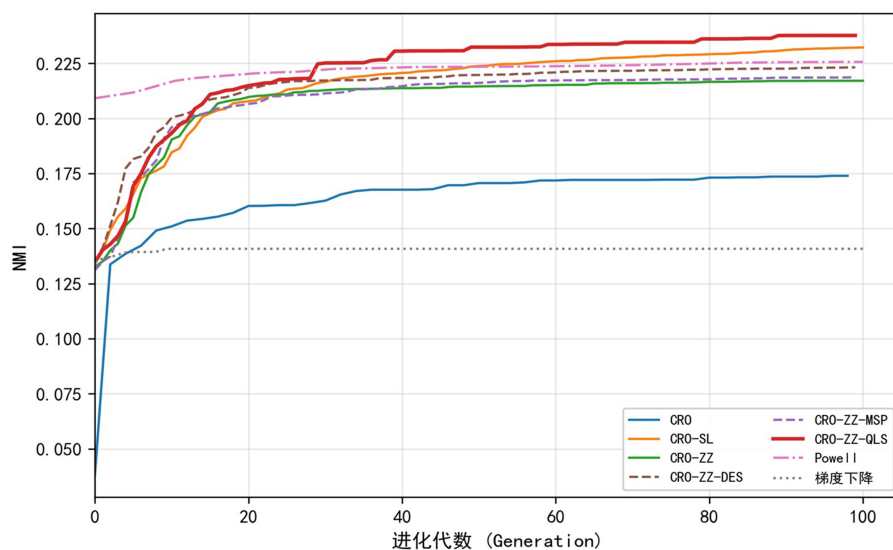


Figure 2. Comparison of NMI convergence curves for each algorithm under Group B configuration

图 2. B 组配置下各算法 NMI 收敛曲线对比

3. 基于 LLM 的动态选择机制

第 2 章的静态实验表明，不同方法在阶段表现、跨样本稳定性和配置偏好上存在明显差异，因此动态调度的目标不是寻找单一最优算法，而是在不同阶段选择更合适的策略。基于这一思路，本文将配准过程表述为等预算约束下的周期性动态策略选择问题：在固定总预算内，系统按周期提取当前优化状态，并从候选算法及其配置集合中选择下一周期的执行策略。LLM 在该框架中被限定为高层调度器，仅负责离散动作选择，而不直接生成连续变换参数；具体搜索仍由底层优化算法完成。流程可以参考图 3 所示。若记第 k 个决策周期开始时的搜索状态为 ϕ_k ，则动态选择过程可写为

$$a_k = \pi(\phi_k, \mathcal{K}, \mathcal{H}_k), a_k \in \mathcal{A},$$

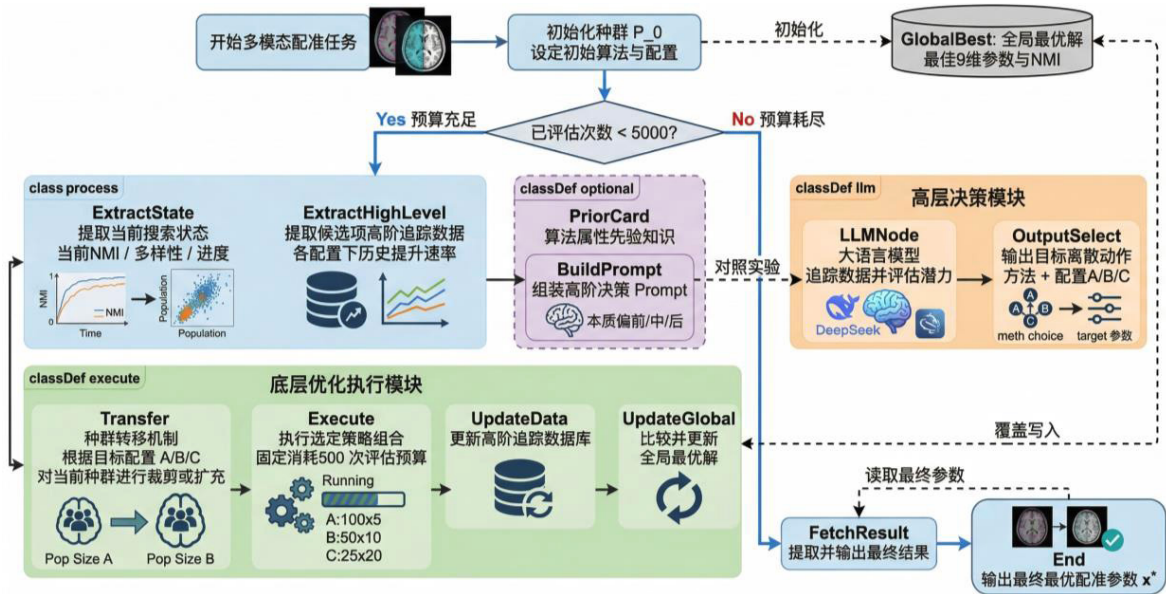


Figure 3. LLM dynamic selection flowchart
图 3. LLM 动态选择流程图

其中， \mathcal{K} 表示由第 2 章静态实验提炼得到的算法知识， \mathcal{H}_k 表示截至第 k 个决策点的历史信息， $\pi(\cdot)$ 表示高层调度策略。对规则调度器而言， $\pi(\cdot)$ 由人工设定的阶段性规则给出；对 LLM 调度器而言， $\pi(\cdot)$ 由 Prompt 驱动的大语言模型完成。从整体结构上看，本文的方法可以概括为三层：底层是第 2 章形成的静态策略池，中间是状态提取与历史记录模块，顶层是高层决策模块。整个框架并不试图替代已有优化器，而是在原有策略池之上增加一层调度，使系统能够根据当前状态在不同策略之间进行切换。

3.1. 动态调度框架

本文采用周期性决策框架。总评估预算为 5000，每个周期固定消耗 500 次评估，因此共进行 10 次决策。每次决策时，系统从候选动作集合中选择下一周期的策略

$$\mathcal{A} = \mathcal{M} \times \mathcal{C},$$

其中， \mathcal{M} 为方法名， \mathcal{C} 为三种等预算配置集合。为提高决策的结构化程度，本文将 LLM 输入划分为三部分：实时状态特征、近期历史反馈和静态知识卡片。实时状态可表示为

$$\phi_k = [f_k^{best}, R_k, \Delta_k^{elite}, D_k, P_k],$$

其中, f_k^{best} 为当前周期最优 NMI, R_k 为近期收敛速率, Δ_k^{elite} 为精英个体改进幅度, D_k 为种群多样性, P_k 为当前优化进度; 历史信息 \mathcal{H}_k 记录最近若干周期所选方法、配置及其 NMI 变化; 静态知识 \mathcal{K} 则由第 2 章实验结果归纳得到, 用于描述各方法的搜索角色、阶段偏好和典型适用情形。

为避免状态特征仅停留在定性描述, 本文进一步将收敛速率定义为最近一个周期内最优目标值的平均提升速度:

$$R_k = \frac{f_k^{best} - f_{k-1}^{best}}{\lambda},$$

其中 $\lambda = 500$ 为单周期评估预算。优化进度可记为

$$P_k = \frac{k}{K},$$

用于区分前期、中期和后期决策。对于群体型方法, D_k 则用于刻画当前种群在参数空间中的离散程度, Δ_k^{elite} 用于反映精英个体在相邻周期之间的改进幅度。这样处理后, LLM 的输入不再只是若干孤立指标, 而是能够同时反映“当前效果 - 近期变化 - 搜索阶段”的结构化状态描述。为进行比较, 本文还设置了一个不依赖 LLM 的规则策略: 前期采用 Powell, 中期采用 CRO-ZZ-MSP, 后期采用 CRO-ZZ-QLS。

需要指出的是, 表 4 并非简单的静态性能排名, 而是由第 2 章实验结果提炼得到的“算法知识卡片”。这些知识卡片与实时状态特征 ϕ_k 及历史信息 \mathcal{H}_k 共同组成每个决策时刻的结构化输入, 用于帮助调度器判断当前搜索阶段与候选策略之间的匹配关系。

Table 4. Algorithm card summary (embedded in LLM system prompt)

表 4. 算法知识卡片摘要(嵌入 LLM system prompt)

方法	适合阶段	NMI	CV	搜索偏向
CRO-ZZ-QLS	中后期	0.2414	0.094	局部开发
CRO-SL [†]	中后期	0.2361	0.096	平衡
Powell	快收敛(易局部最优)	0.2257	0.098	局部搜索
CRO-ZZ-MSP	中期	0.2234	0.121	平衡
CRO-ZZ-DES	后期	0.2230	0.138	多样性
CRO-ZZ	全程	0.2146	0.124	全局探索
CRO	全程	0.1790	0.104	全局探索

3.2. 等预算配置与切换机制

LLM 在选择算法的同时选择种群配置。本文定义三种等预算配置:

$$c_i = (N_i, G_i), N_i \times G_i = \lambda = 500, i \in \{1, 2, 3\}$$

具体为 $c_1 = (100, 5)$ 、 $c_2 = (50, 10)$ 、 $c_3 = (25, 20)$ 。三种配置在单周期评估次数上等价, 但搜索特征不同: 大种群(100)侧重宽度探索, 小种群(25)侧重深度精修。总预算 $B = 5000$ 下, 决策周期数恒定为 $K = B/\lambda = 10$ 。

每个决策点 $k \in \{1, \dots, K\}$, LLM 从 $\mathcal{M} \times \mathcal{C}$ 中选择组合 (m_k, c_k) 。

当相邻周期的种群配置不同时, 需要在算法切换时转移种群。本文利用两个关键事实设计转移策略:

- 1) 所有 CRO 变体共享同一种群数据结构(珊瑚礁三元组), 算法间差异仅在变异策略, 因此 CRO 系列内部可零成本迁移;
- 2) Powell 为单点搜索, 通过最优解 x_{best} 桥接。

设 \mathcal{P}_{k-1} 为上周期结束时的种群(按适应度降序排列), 转移映射定义为:

$$T(\mathcal{P}, N_{\text{old}}, N_{\text{new}}) = \begin{cases} \mathcal{E}_{N_{\text{old}}}(\mathcal{P}) \cup \mathcal{G}_{N_{\text{new}} - N_{\text{old}}}(x_{\text{best}}, \sigma_g), & N_{\text{new}} > N_{\text{old}} \\ \mathcal{E}_{N_{\text{new}}}(\mathcal{P}), & N_{\text{new}} < N_{\text{old}} \\ \mathcal{P}, & N_{\text{new}} = N_{\text{old}} \end{cases}$$

其中, $\mathcal{E}_n(\mathcal{P})$ 为精英选择算子(取适应度前 n 的个体), $\mathcal{G}_m(x_{\text{best}}, \sigma_g)$ 为围绕最优解的高斯采样, $\sigma_g = 0.05 \times w_{\text{domain}}$ (w_{domain} 为搜索域宽度)。

对于 Powell 的特殊迁移: CRO 系列 \rightarrow Powell 时提取 x_{best} 作为初始点; Powell \rightarrow CRO 系列时以 x_{best} 为中心, 通过 $\mathcal{G}_{N_{\text{new}}}(x_{\text{best}}, \sigma_g)$ 生成种群。这样设计的目的并不是简单“重启”下一种算法, 而是使策略切换建立在前一周搜索结果之上的连续演化, 从而保证高层调度与底层优化之间的信息继承与搜索连续性。

3.3. 综合评分与决策流程

在实际实现中, 系统并不是仅向 LLM 提供单个状态向量, 而是将实时状态特征、近期历史反馈、表 4 中的候选方法知识摘要以及 A/B/C 三种配置的统计信息共同组装为结构化 Prompt, 细致情况可以参考图 4。LLM 的任务是在受约束的候选动作集合 $\mathcal{M} \times \mathcal{C}$ 内, 选择下一周期最合适的方法与配置, 并以结构化 JSON 形式返回结果, 例如: {“method”: “CRO-ZZ-QLS”, “config”: “c2”, “reason”: “当前已进入中后期, 近期改进放缓, 适合采用更强局部开发能力的方法”}。

其中, method 表示所选方法, config 表示对应配置编号, reason 用于记录选择依据。这样设计的目的, 是将 LLM 限定为高层离散调度器, 而不允许其直接生成连续配准参数, 从而提高调度过程的可解释性、可记录性与数值稳定性。

LLM 接收状态向量 $\text{state}_k = (\tau_k, \Delta f_k, v_k, \sigma_k, s_k)$, 由当前最优 NMI、收敛速率、停滞情况、种群多样性和历史记录组成, 结合嵌入 system prompt 中的静态性能规律, 输出最优组合。从外部可解释角度看, LLM 的决策偏好可概括为:

$$S(m, c | \text{state}_k) = \alpha \cdot S_{\text{stage}}(\tau_k) + \beta \cdot S_{\text{conv}}(\Delta f_k) + \gamma \cdot S_{\text{div}}(\sigma_k) + \delta \cdot S_{\text{algo}}(h_k)$$

其中, 四个分量分别反映阶段适配(前期偏好大种群, 后期偏好小种群)、收敛响应(停滞时偏好大种群打破僵局)、多样性需求(多样性低时偏好大种群)和算法历史(基于指数衰减加权的历史成功率), 权重 $\alpha + \beta + \gamma + \delta = 1$ 。各分量的详细数学表达见附录。

上式用于概括 LLM 在不同状态下的偏好方向, 而非替代实际的 Prompt 决策过程; 实际执行时, 系统仍以 LLM 返回的算法 - 配置组合结果为准。为避免无意义的频繁切换, 引入惰性约束: 若候选策略之间差异较小, 则保持当前配置。为避免无意义的频繁切换, 引入惰性约束: 若评分差异小于阈值 Δ_{min} , 则保持当前配置。

LLM 动态调度的完整流程概述如下: 每个决策点 k , 系统构造包含当前优化状态的 user prompt 发送给 LLM, LLM 输出下一周期的算法 - 配置组合 (m_{k+1}, c_{k+1}) , 随后通过公式[eq:transfer]执行种群转移。若评分差异小于阈值 Δ_{min} , 则保持当前配置以避免无意义的频繁切换。

系统解析输出后执行相应的种群转移与下一周期搜索。该流程的关键设计特征在于: 1) 等预算约束确保每个周期的评估开销完全相同, 决策纯粹基于策略需求; 2) LLM 仅做离散选择, 不直接生成连续参数; 3) 静态知识、实时状态和历史反馈被统一组织到结构化 Prompt 中, 从而提高决策的可解释性与可复现性。

```

系统角色: 你是一位进化算法优化专家, 负责为 CT-MRI 配准任务选择下一周期的优化策略。
当前优化状态:
决策周期: 第 5/10 周期 (中期), 当前进度: 50.0%
当前最优 NMI: 0.2387; 同周期平均 NMI: 0.2315; 相对同周期平均水平: +3.11%; 同周期分位: 71.4%
当前收敛速率: 0.000012; 同周期平均收敛速率: 0.000085; 相对同周期平均水平: 14.1%
当前种群多样性: 0.0231; 同周期平均多样性: 0.0318; 相对同周期平均水平: 72.6%
最近 1000 次函数评估累计 NMI 提升: +0.0005
最近连续无显著改进评估次数: 1000 (对应 2 个决策周期)
最近历史:
第 3 周期: CRO-EP (配置 A) → NMI 提升 +0.0089
第 4 周期: CRO-EP (配置 A) → NMI 提升 +0.0003
近两周期变化: NMI 增量由 +0.0089 降至 +0.0003; 多样性持续收缩
候选方法知识摘要:
CRO-EP: 搜索角色 = 探索型; 典型阶段 = 前期; 主要机制 = 固定大扰动搜索
CMA-ES-Smart: 搜索角色 = 稳定型; 典型阶段 = 中期; 主要机制 = 协方差自适应搜索
CRO-EP-DES: 搜索角色 = 平衡型; 典型阶段 = 中期; 主要机制 = 双环境协同演化
CRO-EP-QLS: 搜索角色 = 精修型; 典型阶段 = 中后期; 主要机制 = Powell 局部精修
Powell: 搜索角色 = 单点局部搜索; 典型阶段 = 后期; 主要机制 = 无种群局部优化
方法 × 配置历史观测统计:
当前匹配条件: 中期阶段; 收敛速率低于同周期平均水平; 多样性低于同周期平均水平。
统计口径: 以下统计来自第三章静态实验中满足上述条件的历史样本, 用于描述各候选动作 (方法 × 配置) 在后续第 10~20 代的
逐代平均 NMI 水平。

CRO-EP-A (样本数 = 12): [0.1468, 0.1449, 0.1427, 0.1406, 0.1388, 0.1369, 0.1348, 0.1329, 0.1312, 0.1297, 0.1283]
CRO-EP-B (样本数 = 12): [0.1451, 0.1430, 0.1408, 0.1389, 0.1370, 0.1351, 0.1333, 0.1316, 0.1300, 0.1285, 0.1271]
CRO-EP-C (样本数 = 12): [0.1436, 0.1412, 0.1390, 0.1371, 0.1352, 0.1335, 0.1318, 0.1302, 0.1287, 0.1272, 0.1259]
CMA-ES-Smart-A (样本数 = 12): [0.1482, 0.1463, 0.1446, 0.1429, 0.1411, 0.1395, 0.1379, 0.1364, 0.1350, 0.1337, 0.1324]
CMA-ES-Smart-B (样本数 = 12): [0.1494, 0.1478, 0.1460, 0.1444, 0.1428, 0.1412, 0.1397, 0.1383, 0.1369, 0.1356, 0.1344]
CMA-ES-Smart-C (样本数 = 12): [0.1470, 0.1451, 0.1434, 0.1417, 0.1400, 0.1384, 0.1369, 0.1355, 0.1341, 0.1328, 0.1316]
CRO-EP-DES-A (样本数 = 12): [0.1475, 0.1458, 0.1440, 0.1423, 0.1407, 0.1391, 0.1376, 0.1361, 0.1347, 0.1334, 0.1321]
CRO-EP-DES-B (样本数 = 12): [0.1487, 0.1470, 0.1453, 0.1436, 0.1420, 0.1404, 0.1389, 0.1374, 0.1360, 0.1347, 0.1335]
CRO-EP-DES-C (样本数 = 12): [0.1463, 0.1445, 0.1428, 0.1411, 0.1395, 0.1379, 0.1364, 0.1350, 0.1336, 0.1323, 0.1311]
CRO-EP-QLS-A (样本数 = 12): [0.1498, 0.1481, 0.1465, 0.1449, 0.1434, 0.1419, 0.1404, 0.1390, 0.1376, 0.1363, 0.1351]
CRO-EP-QLS-B (样本数 = 12): [0.1510, 0.1494, 0.1479, 0.1464, 0.1449, 0.1434, 0.1420, 0.1406, 0.1393, 0.1380, 0.1368]
CRO-EP-QLS-C (样本数 = 12): [0.1484, 0.1468, 0.1452, 0.1436, 0.1421, 0.1406, 0.1392, 0.1378, 0.1365, 0.1352, 0.1340]
Powell-A (样本数 = 12): [0.1479, 0.1460, 0.1441, 0.1423, 0.1405, 0.1388, 0.1372, 0.1357, 0.1343, 0.1330, 0.1318]
Powell-B (样本数 = 12): [0.1488, 0.1470, 0.1452, 0.1434, 0.1417, 0.1401, 0.1386, 0.1371, 0.1357, 0.1344, 0.1332]
Powell-C (样本数 = 12): [0.1465, 0.1447, 0.1429, 0.1412, 0.1395, 0.1379, 0.1364, 0.1350, 0.1337, 0.1324, 0.1312]
任务: 请结合当前状态、最近历史、候选方法知识摘要和 A/B/C 配置统计, 从候选方法及其配置中选择下一周期最合适的策略, 并以 JSON 格式返回结果。
JSON 字段要求: {"method": "...", "config": "...", "reason": "..."}

```

Figure 4. LLM prompt display
图 4. LLM 提示词展示

4. 实验设计与结果分析

实验分为两个阶段。第一阶段在 RIRE 数据集 14 个 CT-MRI 样本上, 对 8 种方法在三组等预算配置下进行静态比较, 用于总结其精度、稳定性和阶段特征。第二阶段在相同总预算下比较 LLM 调度、规则策略和最佳静态方法 CRO-ZZ-QLS, 其中 LLM 每 500 次评估进行一次调度, 总计 10 个周期。为避免信息泄漏, 动态实验采用 leave-one-case-out 策略。需要说明的是, 本文在动态实验中重点比较“固定静态策略 - 人工规则调度-LLM 调度”三类方案, 其目的在于验证 LLM 作为高层离散调度器相对于静态与简单规则策略的有效性; 更强的非 LLM 自适应选择基线仍有待后续研究进一步补充。

表 5 表明, LLM 动态调度取得了最好的综合结果: 其平均 NMI 为 0.2388, 较最佳静态方法 CRO-ZZ-QLS 提高 0.72%, 并在 14 个样本中有 9 个取得最优, 同时标准差最低。需要说明的是, 表 5 中的静态基线结果低于表 2, 这是因为动态实验采用周期性决策框架, 与连续进化的静态实验设置并不完全相同。

Table 5. Performance comparison of dynamic scheduling strategies (mean over 14 samples)**表 5.** 动态调度策略性能对比(14 个样本均值)

策略	NMI 均值	标准差	Win 数	相比最佳静态
最佳静态(CRO-ZZ-QLS)	0.2371	0.0262	–	–
规则调度策略	0.2365	0.0258	2	-0.25%
LLM 动态调度	0.2388	0.0234	9	+0.72%

表 6 进一步显示, LLM 在前期更常选择 CRO-ZZ 等偏探索的方法, 而在后期更频繁地调用 Powell 进行局部精修, 说明其调度行为与第 2 章总结出的阶段互补规律基本一致。统计 LLM 在各阶段的方法选择频率, 结果如表 6 所示。

Table 6. LLM method selection frequency at each phase**表 6.** LLM 各阶段方法选择频率

方法	前期(1~15 代)	中期(16~35 代)	后期(36~50 代)
Powell	5%	15%	60%
CRO-ZZ-QLS	15%	50%	15%
CRO-ZZ-MSP	20%	20%	5%
CRO-ZZ-DES	10%	10%	15%
CRO-ZZ	50%	5%	5%
CRO	0%	0%	0%

5. 讨论与结论

本文围绕医学图像配准中的算法选择问题, 先构建了包含 8 种方法的候选库, 并在统一预算下比较其整体精度、稳定性和阶段特征; 随后在此基础上提出了基于 LLM 的动态调度方法。实验结果表明, 不同方法之间确实存在明显互补性: CRO-ZZ-QLS 整体精度较高, Powell 初期收敛较快但容易停留在局部最优, 而动态调度能够利用这种差异, 在 14 个样本中有 9 个超过最佳静态方法, 平均 NMI 提升 0.72%。这说明, 在固定预算下, 通过高层策略对候选方法进行阶段性组合, 能够进一步改善配准的鲁棒性和最终性能。

本文仍存在三点限制: 其一, 当前调度主要依赖 NMI、收敛速率、种群多样性等数值反馈, 尚未直接利用图像空间中的结构信息; 其二, 实验样本量较小, 统计结论仍需在更大规模数据集上进一步验证; 其三, 本文当前的比较对象主要是固定静态策略与人工规则调度, 尚未纳入 Q-Learning、多臂老虎机等更强的非 LLM 自适应选择基线, 因此现阶段结论主要支持 LLM 高层调度机制在该任务中的可行性与有效性, 而不能直接推广为其对所有自适应策略均具有优势。后续工作可考虑从三个方向进一步展开: 一是引入视觉信息更强的多模态模型或图像结构特征, 增强状态表征能力; 二是补充更强的非 LLM 动态选择基线, 以进一步检验 LLM 调度的独特价值; 三是将该框架扩展到非刚性配准及更复杂的医学图像配准场景。

参考文献

- [1] Nie, Q., Zhang, X., Hu, Y., Gong, M. and Liu, J. (2024) Medical Image Registration and Its Application in Retinal Images: A Review. *Visual Computing for Industry, Biomedicine, and Art*, 7, Article No. 21. <https://doi.org/10.1186/s42492-024-00173-8>

- [2] Chen, J., Liu, Y., Wei, S., Bian, Z., Subramanian, S., Carass, A., *et al.* (2025) A Survey on Deep Learning in Medical Image Registration: New Technologies, Uncertainty, Evaluation Metrics, and Beyond. *Medical Image Analysis*, **100**, Article ID: 103385. <https://doi.org/10.1016/j.media.2024.103385>
- [3] Sengupta, D., Gupta, P. and Biswas, A. (2022) A Survey on Mutual Information Based Medical Image Registration Algorithms. *Neurocomputing*, **486**, 174-188. <https://doi.org/10.1016/j.neucom.2021.11.023>
- [4] 郑子涵, 谢颖华, 蒋学芹, 等. 基于深度学习的无监督单模态医学图像配准算法[J]. 计算机科学与应用, 2023, 13(1): 57-64.
- [5] Klein, S., Staring, M., Murphy, K., Viergever, M.A. and Pluim, J. (2010) Elastix: A Toolbox for Intensity-Based Medical Image Registration. *IEEE Transactions on Medical Imaging*, **29**, 196-205. <https://doi.org/10.1109/tmi.2009.2035616>
- [6] 石先英, 杨奋林. 基于高斯混合模型的非刚性点集配准[J]. 应用数学进展, 2024, 13(8): 3826-3836.
- [7] Maes, F., Collignon, A., Vandermeulen, D., Marchal, G. and Suetens, P. (1997) Multimodality Image Registration by Maximization of Mutual Information. *IEEE Transactions on Medical Imaging*, **16**, 187-198. <https://doi.org/10.1109/42.563664>
- [8] Salcedo-Sanz, S., Del Ser, J., Landa-Torres, I., Gil-López, S. and Portilla-Figueras, J.A. (2014) The Coral Reefs Optimization Algorithm: A Novel Metaheuristic for Efficiently Solving Optimization Problems. *The Scientific World Journal*, **2014**, Article ID: 739768. <https://doi.org/10.1155/2014/739768>
- [9] Bermejo, E., Chica, M., Damas, S., Salcedo-Sanz, S. and Cerdón, O. (2018) Coral Reef Optimization with Substrate Layers for Medical Image Registration. *Swarm and Evolutionary Computation*, **42**, 138-159. <https://doi.org/10.1016/j.swevo.2018.03.003>
- [10] Hansen, N. and Ostermeier, A. (2001) Completely Derandomized Self-Adaptation in Evolution Strategies. *Evolutionary Computation*, **9**, 159-195. <https://doi.org/10.1162/106365601750190398>
- [11] Powell, M.J.D. (1964) An Efficient Method for Finding the Minimum of a Function of Several Variables without Calculating Derivatives. *The Computer Journal*, **7**, 155-162. <https://doi.org/10.1093/comjnl/7.2.155>
- [12] Leskovar, M., Heyland, M., Trepczynski, A. and Zachow, S. (2025) Comparison of Global and Local Optimization Methods for Intensity-Based 2D–3D Registration. *Computers in Biology and Medicine*, **186**, Article ID: 109574. <https://doi.org/10.1016/j.compbiomed.2024.109574>
- [13] 王艳辉, 王冠洲, 何才壮. 群体智能算法在无人机路径规划中的应用[J]. 计算机科学与应用, 2025, 15(1): 21-27.
- [14] 刘义庆, 屠义强, 卢厚清. 遗传算法协同优化改进理论与应用研究[J]. 软件工程与应用, 2025, 14(4): 765-771.
- [15] Durgut, R., Aydin, M.E. and Atli, I. (2021) Adaptive Operator Selection with Reinforcement Learning. *Information Sciences*, **581**, 773-790. <https://doi.org/10.1016/j.ins.2021.10.025>
- [16] Yin, S. and Xiang, Z. (2024) Adaptive Operator Selection with Dueling Deep Q-Network for Evolutionary Multi-Objective Optimization. *Neurocomputing*, **581**, Article ID: 127491. <https://doi.org/10.1016/j.neucom.2024.127491>
- [17] Wolpert, D.H. and Macready, W.G. (1997) No Free Lunch Theorems for Optimization. *IEEE Transactions on Evolutionary Computation*, **1**, 67-82. <https://doi.org/10.1109/4235.585893>
- [18] Dokeroglu, T., Kucukyilmaz, T. and Talbi, E. (2024) Hyper-Heuristics: A Survey and Taxonomy. *Computers & Industrial Engineering*, **187**, Article ID: 109815. <https://doi.org/10.1016/j.cie.2023.109815>
- [19] Huang, C., Li, Y. and Yao, X. (2020) A Survey of Automatic Parameter Tuning Methods for Metaheuristics. *IEEE Transactions on Evolutionary Computation*, **24**, 201-216. <https://doi.org/10.1109/tevc.2019.2921598>
- [20] Wu, X., Wu, S., Wu, J., Feng, L. and Tan, K.C. (2025) Evolutionary Computation in the Era of Large Language Model: Survey and Roadmap. *IEEE Transactions on Evolutionary Computation*, **29**, 534-554. <https://doi.org/10.1109/tevc.2024.3506731>
- [21] Yang, C., Wang, X., Lu, Y., *et al.* (2024) Large Language Models as Optimizers. arXiv: 2309.03409.
- [22] 卢焯, 陈磊. LLM-NAS: 一种基于大型语言模型的神经架构搜索进化框架[J]. 计算机科学与应用, 2026, 16(2): 405-413.
- [23] Zhong, R., Hussien, A.G., Yu, J. and Munetomo, M. (2025) LLMOA: A Novel Large Language Model Assisted Hyper-Heuristic Optimization Algorithm. *Advanced Engineering Informatics*, **64**, Article ID: 103042. <https://doi.org/10.1016/j.aei.2024.103042>
- [24] Guo, P.F., Chen, Y.H., Tsai, Y.D., *et al.* (2024) Towards Optimizing with Large Language Models. arXiv: 2310.05204.
- [25] Zhang, T., Yuan, J. and Avestimehr, S. (2024) Revisiting OPRO: The Limitations of Small-Scale LLMs as Optimizers. *Findings of the Association for Computational Linguistics ACL 2024*, Bangkok, 11-16 August 2024, 1727-1735. <https://doi.org/10.18653/v1/2024.findings-acl.100>