

# 控制与决策

Control and Decision

## 大模型与智能优化算法集成研究综述

张浩然, 李君, 邢立宁, 杨若涵, 吴健

引用本文:

张浩然, 李君, 邢立宁, 等. 大模型与智能优化算法集成研究综述[J]. *控制与决策*, 2026, 41(4): 871–891.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2025.0121>

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 基于弱关联的自适应高维多目标进化算法

A weak association-based adaptive evolutionary algorithm for manyobjective optimization

*控制与决策*. 2021, 36(8): 1804–1814 <https://doi.org/10.13195/j.kzyjc.2019.1723>

#### 基于地标特征和元学习方法推荐最适用优化算法

Recommending best suitable metaheuristic based on landmarking feature and meta-learning approach

*控制与决策*. 2021, 36(5): 1223–1231 <https://doi.org/10.13195/j.kzyjc.2019.0993>

#### 求解非线性方程组的智能优化算法综述

Overview of intelligent optimization algorithms for solving nonlinear equation systems

*控制与决策*. 2021, 36(4): 769–778 <https://doi.org/10.13195/j.kzyjc.2020.0379>

#### 基于复杂昂贵仿真的体系效能多目标优化

Complex and expensive simulation based multi-objective optimization to system-of-system effectiveness

*控制与决策*. 2021, 36(3): 589–598 <https://doi.org/10.13195/j.kzyjc.2019.0844>

#### 融合能量周期性递减与牛顿局部增强的改进HHO算法

[Improved harris hawks optimization coupling energy cycle decline mechanism and Newton local enhancement strategy](#)

*控制与决策*. 2021, 36(3): 629–636 <https://doi.org/10.13195/j.kzyjc.2019.0810>

# 大模型与智能优化算法集成研究综述

张浩然<sup>1</sup>, 李君<sup>2</sup>, 邢立宁<sup>3†</sup>, 杨若涵<sup>4</sup>, 吴健<sup>5</sup>

(1. 西安电子科技大学 电子工程学院, 西安 710071; 2. 湖南工程学院 商学院, 湖南湘潭 411104;  
3. 江苏理工学院 电气信息工程学院, 江苏常州 213001; 4. 西北工业大学 电子信息学院, 西安 710129;  
5. 西安电子科技大学 杭州研究院, 杭州 311231)

**摘要:** 大模型作为人工智能领域的一项突破性进展, 在新一轮全球科技革命和产业变革中发挥着重要作用. 智能优化算法凭借其在降本增效方面的优势, 极大地推动了社会经济的稳步发展, 两者的有机结合有望为应对复杂交叉的科学研究和工程实践注入新鲜血液. 鉴于此, 提出大模型与智能优化算法间相互赋能的综述. 首先, 从定义和分类两个方面介绍大模型和智能优化算法; 然后, 从大模型赋能智能优化算法和智能优化算法赋能大模型两条路线梳理最新研究进展: 前者围绕代理辅助优化、自动优化建模、自动算法设计与生成、自动算法分析与改进、行业应用开展, 后者基于参数优化、提示优化、联合优化进行, 从通用基础和专用应用两个视角擘画两者的发展方向; 最后, 展望大模型与智能优化算法集成的机遇和挑战.

**关键词:** 大模型; 智能优化算法; 代理辅助优化; 算法自动生成; 模型优化

中图分类号: N945

文献标志码: A

DOI: 10.13195/j.kzyjc.2025.0121

引用格式: 张浩然, 李君, 邢立宁, 等. 大模型与智能优化算法集成研究综述 [J]. 控制与决策, 2026, 41(4): 871-891.

## A research review on integration of large models and intelligent optimization algorithms

ZHANG Hao-ran<sup>1</sup>, LI Jun<sup>2</sup>, XING Li-ning<sup>3†</sup>, YANG Ruo-han<sup>4</sup>, WU Jian<sup>5</sup>

(1. School of Electronic Engineering, Xidian University, Xi'an 710071, China; 2. School of Business, Hunan Institute of Engineering, Xiangtan 411104, China; 3. School of Electrical and Information Engineering, Jiangsu University of Technology, Changzhou 213001, China; 4. School of Electronics and Information, Northwestern Polytechnical University, Xi'an 710129, China; 5. Hangzhou Institute of Technology, Xidian University, Hangzhou 311231, China)

**Abstract:** As a breakthrough in the field of artificial intelligence, large models play a crucial role in the new round of global technological revolution and industrial transformation. Intelligent optimization algorithms have greatly promoted the steady development of social economy by virtue of their advantages in reducing cost and upgrading efficiency. The integration of both is expected to inject fresh blood into handling scientific research and engineering practice with the trait of being complex and multidisciplinary. This article reviews the empowerment between foundational models and intelligent optimization algorithms. First, large models and intelligent optimization algorithms are profiled from two aspects: definition and classification. Then, the latest research progress is combed from two routes: one is empowering large models with intelligent optimization algorithms, the other is empowering intelligent optimization algorithms with large models. Wherein, the former revolves around surrogate-assisted optimization, automatic optimization modeling, automatic algorithm designing and generating, automatic algorithm analyzing and enhancing, and industry practices, while the latter's report is according to parameter optimization, prompt optimization, and joint optimization, the developing trend for both of which is envisioned from the perspectives of general basics and specific applications. The article concludes with prospecting the integration of foundation models and intelligent optimization algorithms.

**Keywords:** large models; intelligent optimization algorithms; surrogate-assisted optimization; automatic algorithm generation; model optimization

收稿日期: 2025-01-24; 录用日期: 2025-04-20.

基金项目: 陕西省科技创新团队项目 (2023-CX-TD-07); 陕西省重点研发计划项目 (2024GH-ZDXM-48); 广东省重点领域研发计划项目 (2021ZDZX1019); 航空科学基金项目 (2023Z034053004); 国家自然科学基金项目 (62203365, 62203461); 中国博士后科学基金项目 (2023M742843); 陕西省科协青年人才托举计划项目 (20220121, 20230125); 智能化航天测运控教育部重点实验室基金项目 (CYK2024-02-04).

责任编辑: 王凌.

†通信作者. E-mail: xinglining@gmail.com.

### 0 引言

随着 2022 年 ChatGPT (chat generative pre-trained transformer) 的爆火,“大模型”逐渐为大众所熟知,并在这些年迅猛发展,成为当今名副其实的颠覆性技术之一.在计算机视觉、自然语言处理等多项领域技术联合加持下,充分利用观测数据和领域知识,大模型开始履行人类专家的职责,为用户提供即时、可信的决策支持服务,成为军用和民用人机混合智能系统中的重要组成部分<sup>[1]</sup>.

大模型 (large models), 又称基础模型 (foundation models)<sup>[2]</sup>, 指的是一类具有海量参数 (通常在 $10^8$ 及以上) 和复杂结构的机器学习模型: 在建模目标方面, 其可以是判别式 (discriminative), 也可以是生成式 (generative); 从信息处理来看, 其可以是单模态 (unimodal), 如文本、图像、视频、音频, 也可以是多模态 (multimodal); 在训练范式方面, 其可以是预训练 (pre-training), 也可以是从头训练 (training from scratch); 从应用范围来看, 其可以是通用型, 也可以是专用型. 当今, 在 OpenAI、DeepSeek、Meta、xAI 等头部企业的引领下, 当提到大模型时, 更多的指的是以基于 Transformer 架构的深度神经网络为主体的生成式大语言模型<sup>[3]</sup>, 但是严格说来, 其只是上述定义的一个特例, 并不等同. 考虑到严谨性, 本文对大模型的表述将遵从上述定义. 大模型分类在上述定义中已有所体现. 实际上, 国内外对于大模型分类尚未形成统一标准. 提供一种合理的分类方案, 如图 1 所示, 涵盖建模目标、参数规模、训练范式、研发机构、信息处理、体系架构、应用范围等维度, 其完备性可在后续发展中逐步加强. 重点对其中两种分类方式进行介绍: 信息处理和应用范围. 对于信息处理: 若一个大模型能够感知、融合、生成或判别不同类型的模态信息, 则称其为多模态大模型; 否则, 称其为单模态大模型. 单模态大模型以大语言模型为主. 鉴于大听觉模型 (如 SALMONN<sup>[4]</sup>)、大视觉模型 (如 Sora<sup>[5]</sup>) 对文本提示的依赖, 可将其理解为大听觉语言模型、大视觉语言模型, 均为多模态大模型<sup>[6]</sup>. 根据应用范围, 可将大模型划分为通用型和专用型 (或垂直型). 更为丰富多样的训练数据来源使得通用大模型适用性更强, 但是在特定应用中的表现往往不及专用大模型. 鉴于专用大模型在大多数情况下是借助与特定应用有关的训练数据从通用大模型中蒸馏而得, 其参数往往更少. 此外, 可按照专用程度将专用大模型进一步细化为行业大模型 (如

金融行业大模型、医疗行业大模型) 和领域大模型 (如科学计算大模型). 值得注意的是, 根据奥卡姆剃刀原理 (Ockham’s razor), 对专用程度的过度细化可能会削弱大模型的使用价值和意义.




图1 大模型分类方案

自从 20 世纪 90 年代“计算智能”概念被提出以来, 智能优化算法一直是其社群中的一个热门研究领域, 旨在以确定性或随机性的方式更快速地制定出更可行的解决方案, 俨然成为应对现代科学探究和工程实践中高成本、低效率等问题的一种重要技术途径.

智能优化算法通常指的是为求解包含决策向量、目标向量和约束条件等要素的静态或动态最优化模型而设计的, 受自然界和人类社会中的演化规律和群集行为启发的迭代式随机性黑箱算法. 相比于确定性传统优化算法, 其摆脱了对最优化模型中诸如可微性等数学假设的依赖, 具备更强的灵活性和可用性, 能够更好地在寻优过程中实现精度和速度的权衡. 目前, 关于智能优化算法的分类尚未形成统一标准. 提供一种合理的分类方案, 如图 2 所示, 其完备性可在未来发展中进一步提升. 对于面向基础的通用型智能优化算法, 根据启发对象, 可将其划分为群体智能、演化计算、自然模拟等基本类型<sup>[7]</sup>, 以及由不同基本类型的有机结合、不同基本类型与确定性传统优化算法的深度融合构成的复合类型, 旨在以更高效率解算更复杂、更模糊的最优化模型,

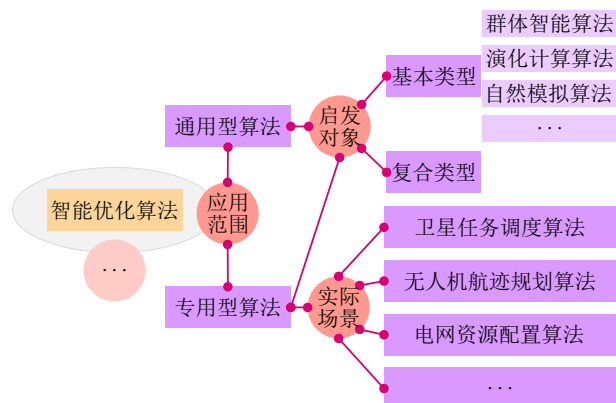


图2 智能优化算法分类方案

获取更优质的决策方案. 以没有免费午餐定理 (no free lunch) 为支撑, 面向应用的专用型智能优化算法通常是针对特定实际场景 (如卫星任务调度、无人机航迹规划、电网资源配置) 的需求和特性 (如算法的透明度和可解释性<sup>[8-9]</sup>) 对面向基础的通用型智能优化算法做出的适应性调整和改进行, 其分类依据可沿用启发对象, 也可以参照实际场景.

大模型的涌现能力有望为智能优化算法的搜索效率和寻优精度的均衡提升提供新思路, 而智能优化算法的普适能力使其为大模型的从头训练和微调提供新策略成为可能, 催生出大模型与智能优化算法集成这一新兴研究方向. 目前, 该研究方向尚处于发展初期, 研究性文献的分散和综述性文献的匮乏是其发展的主要阻力. Huang 等<sup>[10]</sup>首次对大语言模型和优化算法集成进行了综述. 相比之下, 本文是关于大模型和智能优化算法集成的综述, 以提高该研究方向关注度为动机, 基于大模型与智能优化算法相互赋能的视角, 对相关文献进行系统整理, 并对该研究方向的发展前景进行合理展望, 为科技工作者开展探索提供参考.

尽管现有相关文献数量少、内容分散, 但是均在本文中覆盖. 大模型赋能智能优化算法研究现状陈述围绕代理辅助优化、自动优化建模、自动算法设计与生成、自动算法分析与改进、行业应用展开, 其中行业应用涵盖建筑、软件、旅游电商、金融、粮食、物流、医疗保健等多个行业; 智能优化算法赋能大模型研究现状梳理围绕参数优化、提示优化、联合优化 3 个方面进行, 其中联合优化主要涉及对齐、剪枝、蒸馏三大技术. 需要强调的是, 本文作为该研究方向的综述, 将重心放在现有相关文献特点和亮点的合理解读, 而非其优点和缺点的刻意区别 (鉴于该研究方向尚处于发展初期), 并发表相应的思想和见解, 抛砖引玉. 对于所涉及的技术名词, 或给出基本定义, 或提供文献来源.

## 1 大模型赋能智能优化算法研究进展

大模型赋能智能优化算法是指通过将大模型这一新生事物引入最优化模型的智能构建和求解过程中, 助力相关科学研究和工程实践的开展. 大规模参数和高复杂结构决定了大模型能够更好地利用经验知识和观测数据来模拟人类的认知和学习过程, 而大模型固有的涌现能力和幻觉现象也使其智能程度有望逼近人类 (注意到, 幻觉现象亦是对人类情绪的建模, 并非需要杜绝, 也无法实现杜绝), 为智能优化算法在复杂环境下的决策辅助提供了新手段, 也奠

定了大模型赋能智能优化算法的理论基础. 大模型对智能优化算法的赋能思路有二: 一是以大模型为核心设计相应的通用型或专用型智能优化算法; 二是将大模型引入以元启发式为主的智能优化算法, 代替一般的机器学习模型 (代理辅助优化场景) 或人类 (人在环路优化场景), 实现更高效的决策支持. 需要指出的是, 对于任一思路, 大模型的训练细节往往被忽略, 即假设训练好的通用或专用大模型是可获得的. 本节从代理辅助优化、自动优化建模、自动算法设计与生成、自动算法分析与改进、行业应用 5 个方面对该话题的现有相关文献进行汇报, 并以其发展方向收尾.

### 1.1 代理辅助优化

代理辅助优化 (surrogate-assisted optimization) 作为一种应对最优化建模和解模中复杂、昂贵等特性的典型技术<sup>[11-13]</sup>, 旨在通过引入一个或多个机器学习模型作为代理, 减少目标函数评估对硬计算的依赖, 从而降低资源开销.

为改进面向约束多目标优化问题的进化算法对全局最优解的快速发现能力, Wang 等<sup>[14]</sup>将大语言模型引入了 CCMO (coevolutionary framework for constrained multiobjective optimization, 本质上是一种算法框架<sup>[15]</sup>, 实现细节在该工作中并未提及). 将 GPT-3.5 作为搜索算子, 同时保留了原有搜索算子, 两者间不存在交互. GPT-3.5 借助所设计的提示词模板完成了与其他算法流程的对接. 提示词模板作为领域知识的载体, 主要内容涉及问题描述、输入信息、运行步骤、输出格式, 引导 GPT-3.5 完成了自适应解搜索. 在每轮迭代中, 父代解按照比例分配给 GPT-3.5 和原有搜索算子进行分治, 以此缩小最优子代解与最劣子代解间的差距, 为种群收敛提速. 基于 PlatEMO 平台和 DASCMP 测试套件, 针对所提出算法和包含 CCMO 在内的 5 种算法开展了多轮对比实验. 所提出算法在平均超体积和平均反世代距离上的表现最佳, 表明了基于大语言模型的搜索算子的引入对于寻优质量具有积极作用. 遗憾的是, 在实证研究中, 有关寻优效率或收敛速度的讨论并未涉及.

考虑到在对同一通用型代理辅助优化算法根据不同工程项目的实际需求进行定制化时, 数据特性的波动 (如输入的高维性、输出的不确定性以及输入-输出映射的强非线性) 往往导致不同专用型代理辅助优化算法的性能出现不同程度的下降, Rios 等<sup>[16]</sup>提出了一种基于大模型的代理管理原型框架. 该框

架将 GPT-4 作为领域知识库, 通过交互效果而非数据特性为不同工程应用匹配相应的回归代理模型, 实现了初级从业者-业内专家-大模型的协同闭环. 鉴于大模型推理过程不可解释, 幻觉现象频发<sup>[17]</sup>, 该方法离现实应用还有一定差距.

为了在一定程度上规避传统代理模型在从头训练时存在的种种困难, Hao 等<sup>[18]</sup>开展了对大模型辅助演化策略的探索性研究, 基于任务特定的提示设计, 采用多种海外大模型, 或作为分类代理模型评估新解的好坏, 或作为回归代理模型预测新解的大小, 在多套测试集上取得了比传统代理模型更佳的搜索速度和搜索精度, 初步展示了大模型在代理辅助优化中的潜力, 但是, 也指出了大模型对 Token (文本中的最小语义单元) 的支持将成为大模型辅助进化计算性能的重要限制.

Zhong 等<sup>[19]</sup>以 Gemini 为例, 对基于大语言模型的超启发式优化算法设计进行了初步探索: 以 Gemini 为高层组件, 用于优化序列的自动构建; 以基于精英的局部搜索算子组合为低层组件, 用于解的迭代更新. 尽管该方案通过牺牲更多的资源开销获得了更有竞争力的寻优速度和寻优精度, 但是, 却为面向连续优化问题的智能优化算法设计提供了基于大模型的新思路.

诚然, 与众多小模型相比, 使用大模型作为代理分类器或代理回归器会带来更大的时空资源开销, 大模型固有的幻觉现象也会对算法的稳定性造成影响. 根据现有相关文献, 采用大模型代理的智能优化算法能够完成的任务, 小模型代理同样可以完成, 甚至还能够展现出更强的竞争力. 从 OpenAI 的一举成名, 到各大科技公司的百家争鸣, 再到如今 DeepSeek 的异军突起, 大模型技术的发展日趋成熟. 然而, 基于大模型代理的智能优化算法这一研究方向尚处于起步阶段, 目前, 主要针对的是相对简单的优化问题. 大模型在参数规模和体系结构上的显著提升, 赋予了其更强的泛化能力和小模型所不具备的涌现能力, 这无疑为解决更为复杂、更为实际的优化问题提供了新思路, 也为设计更优秀的智能优化一般框架而非特定算法提供了新途径. 尽管大模型在全局可解释性和事前可解释性方面相对较弱, 但是, 诸如思维链推理、因果推理的存在使其在局部可解释性和事后可解释性方面得到了一定程度的保障, 能够逐步向用户展示推理过程, 从而增强用户的信任. 此外, 对于代理辅助的智能优化算法, 大小模型协同推理也具有一定的前景<sup>[20]</sup>, 值得进一步探索.

## 1.2 自动优化建模

优化建模是优化解模的基础. 对于报童问题<sup>[21]</sup>、弧路径问题<sup>[22]</sup>等经典优化问题, 通常将优化算法的设计和改进行为研究焦点. 然而, 对于模糊未知的科学探究和复杂易变的工程实践, 往往无法在初期得到完全正确的最优化模型. 盲目依靠后期试错迭代不仅时间周期长, 且经济成本高, 使得优化问题的自动描述和诊断具有重要现实意义.

Ahmed 等<sup>[23]</sup>开展了关于优化问题的语言描述到数学表达转录过程的前沿探索, 基于增量微调后的 GPT-4、GPT-3.5 Turbo、Llama2 等大模型在特定数据集上进行了一系列的对比研究, 但是缺乏对实验结果合理性的分析; Chen 等<sup>[24]</sup>基于 GPT-4 和开箱即用的优化器, 设计并实现了面向普通用户和专业用户的混合整数线性规划不可行性自动诊断专家系统原型 OptiChat, 该系统将不可约不可行子集 (irreducible infeasible subset, ISS) 作为最优化模型不可行性的定性描述, 并综合运用小样本学习、情感分析、思维链等技术构建了提示策略, 以提升不可行性定位的准确性、鲁棒性和可解释性, 旨在为金融、物流等多个应用场景提供智能决策支持.

## 1.3 自动算法设计与生成

在最优化模型求解方面, 存在一些工作利用大模型提升算法设计和生成的自动化程度<sup>[25-30]</sup>.

为弱化面向组合优化 (特别是非平凡和 NP 难的组合优化) 的演化算法的算子设计对于领域知识和人为干预的依赖, Liu 等<sup>[25]</sup>受大模型预训练特性的启发, 尝试通过 GPT-3.5 Turbo 构建相应的算子用于迭代过程中新解的自适应评估和选择, 同时尽可能避免陷入局部最优. 在旅行商问题案例中, 使用了大模型构建的算子的演化优化器展现出比使用手工构建的启发式算子的演化优化器更强的寻优能力, 但是其效率仍然存在提升空间.

传统优化算法对梯度的依赖给其在实际应用中的落地带来了诸多困难. 为此, Yang 等<sup>[26]</sup>提出了以大模型为核心的基于自然语言描述而非数学语言表达的优化建模和解模的通用范式. 在人为向大模型提供初始提示作为输入信息后, 大模型生成的输出信息将作为其在下一次迭代中的输入信息, 渐近执行自身交互直至满足终止条件. 选用了多种大模型依次在线性回归问题、旅行商问题以及大模型提示优化 (即两个大模型间的博弈) 中对该范式的可用性进行论证. 尽管如此, 对于该范式, 历史信息并未得到有效利用, 生成提示质量评价困难, 最优解质量对

于初始提示敏感,这些不足尚待弥补。

聚焦手工设计启发式搜索优化方法人力成本高、人员水平高的痛点, Liu 等<sup>[27]</sup> 倡议令大模型模仿人类专家,并借助思想 (thoughts) 和代码 (codes) 两大关键要素,提出了基于大模型的启发式算法演化设计范式,实现了启发式搜索优化方法设计的自动化。以在线装箱问题、旅行商问题、流水车间调度问题为例,使用该范式自动设计出的启发式算法展现出了不输于人类专家手工设计出的启发式算法的求解精度和求解速度,并在以查询次数作为计算开销评价指标的情况下,优于使用同类范式 FunSearch 自动设计出的启发式算法。

为借助大模型这一新兴计算技术推动元启发式算法研究社群的发展, Zhong 等<sup>[28]</sup> 基于大模型和经典提示工程框架 CRISPE,设计了一种面向连续优化问题求解的元启发式算法自动生成方案,并以 GPT-3.5 Turbo 为例,半自主地实现了一种称为动物搜索优化 (zoological search optimization, ZSO) 的复合智能优化算法,其在多个测试集上展现出了更有竞争力的收敛精度和收敛速度。

Pluhacek 等<sup>[29]</sup> 使用 GPT-4 对包括粒子群优化 (particle swarm optimization, PSO)、灰狼优化 (grey wolf optimizer, GWO)、鲸鱼优化 (whale optimization algorithm, WOA) 等多种调优后的群智能优化算法进行了分解,提取出最具优势的算子组合,并以此为基础,自动实现合成算法,以简化和加速群智能优化算法的设计和生成过程。但是也指出,大模型黑盒的本质属性可能会成为合成算法稳定性和可信性的最大制约因素。

为缓解真实工业场景中复杂运筹优化建模对于领域专家的高度依赖, Xiao 等<sup>[30]</sup> 提出了基于大模型的多智能体协同框架,令多个大模型扮演具备不同领域知识的人类专家,通过对多个大模型间的交互进行演绎-归纳双轨编排,实现了从文本描述到数学建模再到程序编写的自动推进,同时公开了自建基准数据集,为后续改进奠定了基础。

#### 1.4 自动算法分析与改进

STNWeb<sup>[31]</sup> 作为一款用于智能优化算法行为分析和可视化的工具,其生成的图文信息往往过于专业。为简化操作流程、提升用户体验, Sartori 等<sup>[32]</sup> 将以 GPT-4 为代表的多模态大模型集成至 STNWeb 中,对 STNWeb 产出的报告进行了二次分析,并将解读结果展示给终端用户,为其改进现有智能优化算法提供了更有价值、更易理解的参考。尽管该方法本身

创新性较弱,但是,其验证过程揭示了由大模型生成提示的可解释性与使用该提示作为输入的大模型的输出准确性间具有较强关联。

多数情况下,演化算法的表现对于其超参数的取值敏感。鉴于手工调整并固定超参数的方式效率低、效果差,自适应超参数调整成为演化算法的一个重要研究方向。Custode 等<sup>[33]</sup> 对基于大模型的演化算法超参数调整机制进行了初步探索,利用大模型在线分析历史迭代信息,实时推荐并更新了包括步长在内的最佳超参数。选用两种开源大模型进行了实验论证,该机制下的演化算法的寻优性能更具竞争力。

Tianrunroj 等<sup>[34]</sup> 为一般意义上的分类系统设计了一种基于大模型的自然语言规则优化策略,在交互式环境中完成模仿学习的任务,规避了试错法带来的高成本问题。在 WebShop (一种电商网站仿真平台<sup>[35]</sup>) 上对该策略的性能进行了验证,其在部分实验中的表现优于选用的一些基线策略。

Pluhacek 等<sup>[36]</sup> 以 GPT-4 Turbo 和自组织迁移算法 (self-organizing migrating algorithm, SOMA) 的一个变体为例,初步探索了基于大模型的元启发式算法自动改进。给定的大模型在不依赖反馈机制和专家知识的情况下,以自交互的方式对给定的元启发式算法进行了版本更迭。实验结果表明,所涉及的 SOMA 变体的性能指标分值并非按照预期线性上升,而是随着迭代次数的增加整体呈现先升后降的趋势,引出了迭代次数优选这一后续工作。

Pluhacek 等<sup>[37]</sup> 进一步开展了关于 GPT-4 Turbo 对差分进化算法 (differential evolution, DE) 性能提升的实验性研究,得到了类似的结果,即 DE 算法的性能指标分值并不会随着迭代次数的增加而持续上升,尽管性能指标分值最高的 DE 算法版本在部分测试集上的表现可优于部分 SOTA 算法。该工作并未对智能优化算法性能与大模型提示次数间的关系进行剖析,但是,强调了将 Token 与性能指标分值一并考虑的重要意义,即实现了计算资源、存储资源等经济成本与时间成本间的权衡。

#### 1.5 行业应用

目前,大模型技术在建筑、软件、旅游电商、金融、粮食、物流、医疗保健等多个行业的优化问题求解过程中得到了初步应用。

##### 1.5.1 建筑行业

建筑能源自动优化和剪力墙结构设计优化的研究对于推动建筑行业可持续发展具有重要意义。

为响应“建筑节能”和“绿色发展”的号召, Xiao 等<sup>[38]</sup>提出了基于虚拟专家协同的自动建筑能源优化框架,将多种领域知识注入多个大模型,使其扮演指导者、计划者、研究者等不同角色,以合作的方式分阶段从审计报告的非结构化数据中提取出关键信息,并重组为相应的结构化数据,进一步生成能源最优的施工推荐方案.为验证所提出框架的有效性和优越性,基于大模型开发框架 LangChain 和 CrewAI,对所提出框架进行了软件实现;将 ChatGLM 系列和 ChatGPT 系列的 SOTA 大模型作为基线,记为 #ChatGLM 和 #ChatGPT,并将集成所提出框架的 #ChatGLM 与 #ChatGPT 用于对比;分别选择精确率和召回率、自定义分值<sup>[39]</sup>、覆盖率作为验证对象在建筑信息处理、建筑质量诊断、建筑改造建议 3 个环节的定量评价指标;验证结果表明,所提出框架的引入使得各项定量评价指标均得到了一定程度的提升.

着眼于基于深度学习的剪力墙结构设计优化方案往往质量低、操作难, Qin 等<sup>[40]</sup>探索了一种基于经验规则和大模型的新方案.该方案以大模型为核心控制单元,在考虑机械性能、材料消耗等多项实际要素的情况下,通过与用户的迭代交互,实现了剪力墙结构设计优化的提速和提质.选取了经典的剪力墙结构建筑案例<sup>[41]</sup>用于所提出方案的检验;借助 ChatGPT 系列大模型(并未公开具体型号)和 StructGAN(一种面向剪力墙结构设计优化的生成对抗网络<sup>[41]</sup>),开发了所提出方案相应的软件系统,其通过用户的持续提示实现了剪力墙结构设计优化的目标;检验结果显示,所提出方法在优化质量方面与人类设计师相当,优于传统的试验优化方法(direct optimization),但是其在项目全过程中的总开销比后两者要更低.

如今,智能化已成为建筑行业的主要发展趋势之一,人工智能技术也已渗透到建筑行业涉及的各类优化问题的求解中,包括上述的建筑能源自动优化<sup>[42-43]</sup>和剪力墙结构设计优化<sup>[44-45]</sup>.大模型时代的到来,一方面将沉寂了 10 余年之久的混合专家架构(mixture of experts, MoE)<sup>[46-47]</sup>重新推上风口浪尖,另一方面也将符号神经集成对可信大模型认知推理的意义推向新高度,为面向建筑行业各类优化问题求解的智能化方案设计提供了新思路.同时,与小模型相比,大模型具备更强大的知识发现和数据挖掘能力,使其在领域知识和观测数据联合驱动方面更具竞争力,为进一步实现建筑行业各类优化问题求解周期缩短和质量提升创造了新机遇.

## 1.5.2 软件行业

软件行业是推动社会发展的重要引擎之一,大模型技术势如破竹,软件行业功不可没.与此同时,大模型技术也在潜移默化地影响着软件行业涉及到的众多优化问题,如高层次综合(high-level synthesis, HLS)设计优化<sup>[48-50]</sup>和测试用例设计优化<sup>[51-53]</sup>.在现有的手工或基于计算智能<sup>[54]</sup>求解方法的基础上,大模型凭借其强大的表达、推断、学习能力,将知识数据联合驱动的应用范式发展到了新高度,实现了对软件行业的反哺.

HLS 技术在软件编程语言向硬件描述语言的转换过程中得到了广泛应用.该技术往往依赖人工实施,要求工程师兼具软件设计和硬件设计的职业技能,具有迭代周期长、程序调试难等特点.为此, Xu 等<sup>[55]</sup>将 Top- $k$ 检索增强、小样本学习与大模型相结合,实现了 HLS 工作流的自动化,直接得到调优后的机器码,大大提升了从业者的工作效率.通过复现前人在 FPGA 并行编程方面的成果,辅以向量数据库 Faiss,完成了实验平台的搭建;选取平均延迟和 Pass@ $k$ (一种用于量化大模型在可判断正误的问题集上性能的指标,由 OpenAI 提出<sup>[56]</sup>,其值反映了大模型在  $k$  次尝试中至少一次成功解决问题的可能性)作为优化效率和优化质量的定量度量;基于 Code Llama (Meta 旗下一款专用于编程任务的大模型)和 GPT-3.5 Turbo 分别开展了 10 轮实验;观察结果,相比于零样本学习与大模型结合,所提出 Top- $k$ 检索增强、小样本学习与大模型相结合得到的 Pass@10 更高、平均延迟更低,表明了其在优化质量和优化效率方面均更具优势.

单元测试用例设计对于软件系统的质量保证具有重要作用,但是却面临高耗时和低覆盖等问题,催生出基于搜索的单元测试用例生成这一研究方向.为了兼顾覆盖和效率的提升,借助大模型对单元测试用例的迭代寻优过程进行有效干预的构想已经得到了初步探索,但是,干预时机和干预策略的谋划仍然是一个谜.为此, Xiao 等<sup>[57]</sup>基于不同的 Python 模块进行了大量实验性研究.首先,单元测试用例生成过程被划分为 3 个阶段:种群初始配置、种群迭代更新、测试覆盖停滞.然后,为大模型制定了 3 种干预措施:随机介入、动态监控、长度控制,并以此为基础,构想了 6 种干预场景:在种群初始配置阶段进行随机介入,在种群初始配置阶段进行随机介入和动态监控,在种群迭代更新阶段进行随机介入,在种群迭代更新阶段进行随机介入和动态监控,在测试覆盖停滞阶段进行长度控制,在测试覆盖停滞阶段进

行长度控制和动态监控.接着,借助 Pynguin (一种基于 Python 开发的单元测试用例生成框架,其核心是多目标排序遗传算法<sup>[58]</sup>)完成了基于搜索的单元测试用例生成软件系统的实现,并进一步将 Code Llama 集成进其中,从而完成了实验平台的搭建.最后,采用 CodaMosa 算法验证了所使用的数据集<sup>[59]</sup>,针对以上 6 种干预场景分别执行了 3 轮实验,通过对测试覆盖曲线的分析,得到了两项重要结论:1)对初始解集的生成过程进行重点干预对于干预结果具有积极作用;2)盲目提高干预频率对于干预结果具有消极作用,需要控制在一定范围.

### 1.5.3 旅游电商行业

近年来,旅游路线优化<sup>[60]</sup>和推荐新颖性优化<sup>[61]</sup>的研究持续推动着旅游电商行业的发展.

传统的旅游路线规划服务仅将从始发地到目的地的路途时间作为优化目标,导致推荐结果缺乏个性化,引起用户满意度的降低.为此, Li 等<sup>[62]</sup>提出了基于大模型的图搜索算法,以此为基础,进一步在偏好方面对现有的旅游路线规划服务进行了改进,通过将大模型对用户查询中的多个关键要素(如距离、预算、热度等)的响应与实时交通数据、历史旅游数据进行有效融合,实现了潜在路径的快速优选.选取基于规则的搜索算法、基于大模型的启发式搜索算法等 3 种路径规划算法,以及行程规划查询(trip planning query, TPQ)<sup>[63]</sup>、最优顺序路线(optimal sequenced route, OSR)<sup>[64]</sup>等 4 种路径搜索算法开展对比实验,以检验所提出基于大模型的图搜索算法的有效性和优越性.从准确性、时效性、鲁棒性 3 个方面对由不同算法生成的推荐方案进行综合评价:准确性的定量评价借助用户满意度来实现,该指标通过对基于问卷调查、实时反馈等方式构建的样本库中的各样本在依从感、舒适感、体验感等字段上的取值进行加权求和而得到;时效性的定量评价借助运行时间来实现;鲁棒性的定量评价借助性能分值来实现,该自定义指标通过对不同算法的输入施加不同程度的扰动重复多轮实验而得到,但是文中并未公开其计算方法.最后,分别对旅途总时间与用户满意度、运行时间、性能分值间的关系进行可视化,分析得出所提出算法在准确性、时效性、鲁棒性 3 个方面均实现了最优.

预测结果排序操作的不可微、用户反馈数据的缺失等现实因素的存在,使得新颖性优化成为推荐系统商业化所面临的一个重大挑战.鉴于此, Sharma 等<sup>[65]</sup>提出了一种基于大模型和强化学习的不可知算法,并在 Amazon 电商购物用户行为等数据集上对

该算法的应用进行了示范.在该算法中,大模型被用于模拟用户生成低复杂度样本,从而在迭代过程中以自适应的方式修正策略梯度.具体而言,该工作围绕检索项目 Top- $k$  新颖性(一种用于定量评价推荐系统性能的指标,其取值反映了推荐结果中前  $k$  个项目的新颖程度,越大越好)优化展开:在理论层面,通过将状态建模为(查询,项目)二元组而非(查询)一元组,缩小了强化学习所依赖的动作空间,从而简化了新颖性优化问题的提法;在应用层面,摒弃了从头训练一个基于强化学习的推荐系统的传统思路,探索了将强化学习范式引入一个已借助用户反馈数据训练后的基于监督学习的推荐系统的创新思路,进而提出了面向大规模检索的策略梯度算法(policy gradient for large-scale retrieval, PG-Ret).在 PG-Ret 中,大语言模型凭借其在语义理解和语义生成方面的优势发挥了数据增强的作用,使得无任何用户反馈数据支持(检索项目 Top- $k$  新颖性优化的主要挑战之一)得到了有效应对.分别基于查询广告推荐任务数据集(非公开)、查询网页匹配任务数据集(公开)、基于 Amazon 评论的产品推荐数据集(公开)对所提出 PG-Ret 的有效性和优越性进行了验证,对象涉及如下:某款商用推荐系统(具体信息并未揭露,记为 System#1),基于监督学习的推荐系统(记为 System#2),集成 PG-Ret 的 System#2(记为 System#3).针对每个数据集执行多轮实验,观察每个对象在不同  $k$  值下的 3 项定量评价指标:Top- $k$  新颖性、精确率、召回率.实验结果表明,随着  $k$  值的增加(意味着推荐难度的增加),System#3 的 3 项定量评价指标的取值均高于 System#1 与 System#2,而其 3 项定量评价指标的减少量均低于 System#1 与 System#2,该工作的价值由此体现.

大模型的应运而生为人工智能向人类智能逼近提供了契机,这一点在旅游电商行业优化问题的求解中得到了很好的体现.通过对旅游路线优化和推荐新颖性优化前沿工作的细致解读可以发现,大模型的引入使得该行业优化问题的求解时耗更低,效果更好.过去,该行业优化问题的求解,或不涉及人工智能,或仅涉及判别式人工智能.正是大模型的引入令生成式人工智能以及生成式-判别式混合人工智能在该行业优化问题的求解中得以发展.不可否认,大模型拓宽了专家系统、人在环路、人机协同等术语的内涵和外延,在优化过程中,其充当了领域知识的载体,作为具备认知能力的虚拟人类,践行了真实人类的职能,弱化了真实人类对优化过程的干预(如上述中,智能优化算法所集成的大模型通过用户

扮演实现数据增强的目标,以应对不完美数据的挑战),进一步提升了优化过程的自动化程度。

#### 1.5.4 金融行业

诚然,人工智能在金融行业优化问题中已得到了广泛应用,但是涉及大模型的研究却是凤毛麟角<sup>[66-68]</sup>。目前,大模型在投资组合管理优化这一金融行业经典优化问题中已得到了初步应用,下面是一份前沿工作的详细汇报。

面向经销商的影视作品智能投资组合管理往往依赖于传统专家系统,这些系统在灵活性和可扩展性方面的不足,对优化影视作品智能投资组合管理产生了不利影响。影视作品票房预测是影视作品智能投资组合管理的重要组成部分,名人效应对于影视作品票房具有重要影响,受限于传统专家系统,名人效应鲜有在影视作品票房预测中得到考虑。鉴于此,Alipour-Vaezi等<sup>[69]</sup>利用大模型、数据对齐、多属性决策等技术,搭建了面向影视作品发行商的智能投资组合管理框架,令大模型扮演人类专家,忽略其固有的偏见,对影视作品中涉及的利益相关者进行了声望评估,作为票房预测的基础,并根据其响应以迭代的方式获取厂商偏好-作品收益双目标下的最优投资组合。具体而言,该框架的实施涵盖4个环节:票房预测、数据处理、偏好评估、方案生成。票房预测重点关注影视作品本身利益相关者(导演、编剧、演员等)的声望对于其票房涨跌的影响,考虑名人效应,借助大模型对不同利益相关者的声望进行评估,获取对应的分数,其中大模型被视为人类专家发挥决策支持的作用。数据处理重点解决样本分布不均衡的问题,以削弱其对于预测准确性的影响,依次对样本库进行聚类(具体方法并未提及),对不同类中的部分样本(无标注)进行人工标注,将人工标注的样本作为训练样本构建分类器(具体方法并未指定),将剩余样本作为测试样本,通过分类器完成标注。偏好评估重点考虑影视作品经销商对于每份影视作品的偏好,在贝叶斯最好最坏法(best-worst, BW)和加权聚合求和积评估法(weighted aggregated sum product assessment, WASPAS)的基础上建立了混合多属性决策模型完成其求解。方案生成重点涉及最优投资组合的获取,其被建模为一个双目标优化问题,以在影视作品经销商总利润(税后)最大化与影视作品经销商投资组合总偏好最大化间进行权衡。选用ChatGPT系列大模型和通用代数建模系统软件(general algebraic modeling system, GAMS)中的BARON求解器完成了实验平台的搭建。基于美国1980年~2020年影视作品数据集完成了对所提出

框架可行性和有效性的验证,其中方案生成环节中的双目标优化问题的求解引入了加权和法,其性能定量评价采用了常见的分类器或回归器性能定量评价指标(精确率、召回率、均方误差及其变体、决定系数等),并未开展对比实验以突出所提出框架的优越性。将不同程度的扰动作用于输入,观察输出的扰动,对各环节的敏感性进行了探究,为所提出框架的实际应用提供了一定的指导。不可否认,该工作的发表对于大模型在金融行业优化问题求解的发展具有里程碑式的意义,但是,仍然存在3处值得重视的地方:1)该工作所提出框架面向影视作品投资组合管理优化,声称具有一定的通用性,但是缺乏相应的论证;2)该工作所提出框架通过对聚类后的部分样本进行手工标注,再通过分类完成剩余样本的标注,若将这一数据标注过程基于大模型实现,或许能够在某些方面取得更好的表现;3)该工作所提出框架中的大模型弥补了传统专家系统在可扩展性和灵活性方面的不足,但是其引入动机,如作者所述,涉及避免人类偏见。注意到,即便是在今天,大模型在认知偏见方面仍然存有很大的提升空间<sup>[70]</sup>。因此,该论述的合理性有待商榷。

相比于前述行业,大模型在金融行业优化问题求解中初露锋芒,相关工作罕见。目前,大模型在该话题中更多地是作为一种开箱即用的工具接入已有智能优化过程,替代人类执行相关决策,提高智能优化过程的自动化程度,集成程度较弱,更富有深度和广度的研究有待开展。

#### 1.5.5 粮食行业

粮食行业作为农业行业的核心组成部分,在国家粮食安全保障、农业经济发展推动、人民生活质量提高等方面发挥着关键作用,智能化是其转型升级的一个重要方向。农业行业大模型的技术优势、应用价值、发展前景均已在学界和业界得到了一致认可,一系列重磅成果如雨后春笋般涌现<sup>[71-72]</sup>。然而,对于该行业中的优化问题智能求解,大模型的贡献却是极度缺乏,在粮食行业中亦是如此。幸运的是,对于生物工艺优化和生产过程优化这两类粮食行业中的典型优化问题,大模型在其智能求解中得到了初步的考虑和探索。

虚拟实验平台是实现生物工艺优化降本增效的重要途径。面向基于Kraft木质纤维素废料预处理的葡萄糖提取工艺优化的提速和提质,David等<sup>[73]</sup>设计了一种基于小模型-大模型协同的虚拟实验平台。其中:小模型(蒸汽辅助人工神经网络和微波辅助人工神经网络)作为主要组件实现葡萄糖产量定量评

估环节,大模型(ChatGPT系列)作为次要组件实现葡萄糖产量趋势预测环节。基于Kraft木质纤维素废料的绿液残渣浓度、功率密度、加热时间和固体负载,以及葡萄糖产量的观测值构建了样本库,以此为基础,得到两大环节的决定系数(一种回归评价指标,取值在0~1之间,越高越好)均在95%以上。接着,对两大环节开展敏感性测试,结果显示系统输出(葡萄糖产量)对于系统输入(绿液残渣浓度、功率密度)的变化更为敏感,为后续改进提供了一定的参考依据。该工作首次将大模型引入了生物工艺优化的智能求解,对于进一步提升粮食行业的智能化水平具有重要意义,但是仍然存在以下3方面的不足:1)关于时耗的综合评价以及对比实验的缺失,使得该工作所提出方法的优越性难以体现;2)在智能优化过程中,大模型发挥着决策支持和互补分析的作用,但是其所依赖的迭代提示模板并未在文中得到说明;3)该工作仅将大模型作为黑箱专家系统简单集成进智能优化过程,存在集成动机不明、集成程度不足等问题,有待进一步提升。

如今,动态性和不确定性已成为粮食行业乃至整个农业行业的常态,这对于传统的以经验主义为主导的粮食生产过程管理带来了巨大挑战。为此,Chen等<sup>[74]</sup>提出了一种基于强化学习和大模型的构想,旨在实现粮食生产过程管理在有效性、连续性、可持续性等多个方面的最优控制。该构想忽略了大模型的训练细节,将其作为开箱即用的专家系统,替代人类在优化过程中实现自主决策。该构想相应的软件架构已得到详细描述,其有效性和优越性的论证有待进一步开展。

### 1.5.6 物流行业

在生成式人工智能的浪潮下,京东、顺丰等多家头部企业已着手推进大模型技术的引入以及物流行业大模型的建设。物流配送路径优化是物流行业中的一类重要优化问题,得到了广泛研究<sup>[75-77]</sup>。以下是对基于大语言模型的物流配送路径优化这一话题工作的梳理,该工作将大模型技术引入物流行业优化问题的智能求解。

对于求解配送路径优化问题,一般的优化算法无法对司机历史驾驶行为中所蕴含的隐式知识进行有效分析和利用,导致其无法应对真实世界中的复杂工况。为此,Liu等<sup>[78]</sup>跨越语言学和运筹学,提出了一种集成大语言模型和旅行商模型的算法,用于在配送区域内实现配送路径的实时优化。该算法中:大语言模型负责从司机历史驾驶行为中捕获个性化的隐式知识,并借助定制化的链式法则将其映射为

文本序列,以降低司机偏好表征学习所需的计算资源开销;旅行商模型负责对大语言模型习得的司机偏好表征和实际场景中的路况、基建等多种要素进行综合考虑,在配送区域内动态生成多目标最优意义下的配送路径。基于Amazon配送数据集开展数值仿真,其仿真结果表明,相比于一般的优化算法(细节并未提及),所提出算法的计算时间更短,混合误差(自定义)更小,其有效性以及在准确率和效率方面的优越性得以体现。

在前述诸多行业优化问题的智能求解中,大模型更多地是发挥知识载体和领域专家的作用,以提升智能决策的自动化程度,从而使得智能优化算法在精度、速度等方面得到改进。目前,对于物流行业优化问题的智能求解,大模型的应用仅涉及大语言模型,并未发挥以上作用,而是将自然语言处理中的语义建模思想融入智能优化算法,以降低真实情景中非理想因素的负面影响。

### 1.5.7 医疗保健行业

大模型技术在医疗保健行业的潜力已得到初步发掘<sup>[79-82]</sup>。为进一步推进大模型技术在医疗保健行业的发展,面向外科医疗动态多目标资源分配优化,Wan等<sup>[83]</sup>提出了一种基于大语言模型的算法。在建模方面:从可优化性的角度对资源(手术室、恢复床位、外科医生)进行区分;目标向量由最小化手术室总费用、最小化外科医生总加班时间、最小化日需最大恢复床位数量组成;施加通过医学知识问卷调查而得到的伦理和法律约束。该算法的核心部分基于提示工程和检索增强生成技术实现:提示工程技术涉及的提示词模板多为明确指示,如:“将手术室和恢复床位分配给择期患者,以最大限度地减少资源压力”;检索增强生成技术执行数据存取的功能。同时,该算法也集成了相关软件工具用于数据分析和可视化等任务,使其具有更强的可操作性。基于ChatGPT系列、Qwen系列等7种大语言模型对所提出算法进行编程实现。实验结果表明,使用GPT-4o时,所提出算法在各目标上均实现了最优,且运行耗时最短。选用传统优化算法——列生成算法和智能优化算法——二代非支配排序遗传算法(nondominated sorting genetic algorithm II, NSGA-II),与所提出算法(基于GPT-4o实现)一起开展对比实验。在列生成算法对应的实验中,多目标优化问题经由加权和法转换为单目标优化问题。实验结果显示,3种算法在各目标上的差异较小,但是所提出算法的运行耗时远低于其他两种算法。进一步执行扩展研

究, 扩大病人规模, 提升问题的复杂性, 重复实验, 得到了类似的结果, 所提出算法的有效性和优越性得以验证. 注意到, 在所提出算法中, 检索增强生成技术的实施涉及历史信息和新信息的综合推断, 这意味着所采用的大语言模型必须具备长期记忆机制<sup>[84]</sup>, 其设计对于智能优化算法的效率和效果影响巨大, 尤其是在面向动态环境的情况下, 值得深究. 此外, 考虑到大模型固有的幻觉现象, 尽管所提出算法在优化流程上是可控的, 但是其优化结果并不可控, 如何进一步提升所提出算法的稳定性, 有待探究.

### 1.6 发展方向

以不平衡、不完备、污染、缺失为主要特点的不完美数据问题<sup>[85-86]</sup>广泛存在于真实数据中, 对于智能优化算法的性能提升造成了负面影响, 特别是在涉及代理模型的情况下. 数据增强和数据标注是缓

解真实数据不完美性的可行思路. 大模型的涌现能力使其在充当数据增强和数据标注的技术手段上颇具潜力, 而这种潜力在近期得到了初步发掘<sup>[87-88]</sup>. 大模型赋能智能优化算法的后期发展如图3所示. 从通用基础出发, 以大模型为核心, 人类为辅助, 提升数据增强和数据标注的自动化程度; 通过对标注真实数据、标注合成数据、无标注真实数据、无标注合成数据的充分利用, 以生成式-判别式模型级协同、监督学习-无监督学习-强化学习范式级协同的方式, 助力智能算法和智能模型全量优化、增量优化、在线优化、离线优化理论和方法的多方位发展; 进一步将所得理论和方法推广至军民专用应用, 如故障诊断与容错自愈、性能评估与构型重构、寿命预测与最优维护等在轨星座健康管理实践<sup>[89-90]</sup>以及机场航班实时调度实践<sup>[91]</sup>.

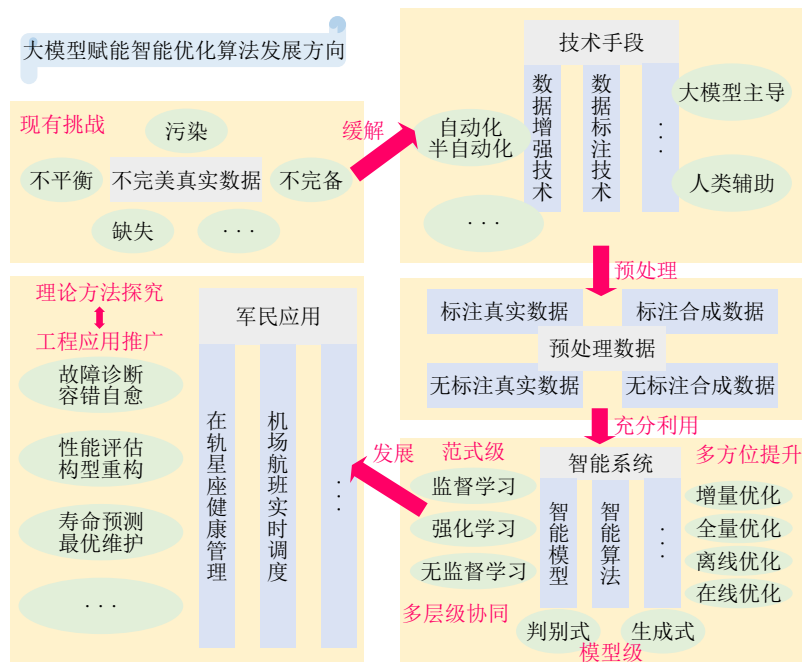


图3 大模型赋能智能优化算法发展方向

## 2 智能优化算法赋能大模型研究进展

鉴于大模型往往涉及监督学习、无监督学习、强化学习等多种机器学习范式的综合运用, 其优化难度较小模型高出不少. 凭借数学理论保障性强、软件工具支持度高等特点, 基于梯度的传统优化算法在大模型优化中占据主导地位. 相对而言, 智能优化算法计算成本更高、理论支持更弱, 但是, 其对于参数不确定性、函数不可导性以及局部最优等情况的应对能力更为出色. 因此, 将不同智能优化算法或各类智能优化算子有效整合进基于梯度的传统优化算法, 进行优势互补、协同增效, 实现大模型优化过程在多指标均衡意义下的提速和提质, 正成为一种趋势. 智

能优化算法赋能大模型旨在将智能优化算法的思想嵌入至大模型的初始化和优化过程中, 使得大模型的推理结果更加符合人类预期.

现阶段, 大模型的性能提升主要基于内部优化和外部优化两种基本策略及其组合 (称为联合优化) 实现: 内部优化通常涉及到大模型的参数优化和结构优化, 其直接对大模型的组成要素进行修改; 外部优化主要体现在大模型的提示优化, 其作为提示工程的一个环节<sup>[92]</sup>, 不对大模型本身进行调整, 而是通过寻求特定意义下的最佳输入信息, 引导大模型朝着更加贴合实际需求的输出信息进行推理.

鉴于大模型的结构优化通常不单独进行, 而是

在联合优化中加以考虑,这部分的文献极为匮乏。智能优化算法赋能大模型现有相关文献均在本节中覆盖,将依次从参数优化、提示优化和联合优化3个方面对其进行汇报,并对其未来发展做出合理展望。鉴于现有相关文献数量较少,并未在各节中进行二次分类,而是将重点放在各项工作创新性的陈述上。

## 2.1 参数优化

低秩自适应 (low-rank adaptation, LoRA) 作为大模型调参的经典方法之一,旨在通过调整部分参数而非全部参数,提升大模型的综合性能。然而,大量的梯度运算和重复的反向传播执行造成了不必要的资源浪费,导致基础 LoRA 在经济性方面有所欠缺。为此, Jin 等<sup>[93]</sup> 将基于群体演化的计算方法整合进基础 LoRA, 以实现大模型在小样本场景下的无梯度优化。实验结果表明,相比于基础 LoRA, 改进方法显存使用更少、收敛速度更快。

Li 等<sup>[94]</sup> 对自动程序修复大模型的轻量级参数微调进行了初步探索,在不降低综合性能的情况下提升了计算资源的利用率,实现了对自动程序修复任务的高效适配。基于多种大模型实例和多种轻量级参数微调方法开展了大量实验论证,为该研究方向的进一步深入奠定了基础。

为了对大模型的参数高效微调 (parameter-efficient fine-tuning, PEFT) 过程进行提速,同时降低时间投资和运营成本, Wang 等<sup>[95]</sup> 定义了影子稀疏性 (shadowy sparsity) 的概念,并在此基础上,进一步设计了一种称作 LONG EXPOSURE 的系统方案,其包含3个核心组件:用于感知增强和细节捕获的稀疏曝光器,用于序列处理和参数更新的序列预测器,用于内存合并和模式构造的动态感知器。通过与多个 SOTA 系统方案的对比, LONG EXPOSURE 的应用潜力得以体现。

Ling 等<sup>[96]</sup> 对大模型在资源受限场景下的参数联邦调优的收敛性进行了理论分析和实验论证,构建了基于两点梯度估计和个性化学习率调整的零阶参数联邦调优方法。相比于传统的一阶参数联邦调优方法,所提出方法收敛速度更快,显存占用更少。

针对大模型在下游医学任务适配过程中面临的数据不完备和不均衡、时间和计算开销大等问题, Liu 等<sup>[97]</sup> 设计了基于 MoE 和 LoRA 的多任务 PEFT 框架,以实现隐式任务知识的高效学习。

值得指出的是,上述中的 PEFT 作为一种大模型优化策略,通过仅调整部分参数,实现了与调整全部参数相近的综合性能,同时显著降低了时间、计

算、存储等成本<sup>[98]</sup>。这种策略在资源受限环境中尤为有效,而 LoRA 正是其典型实例之一。

## 2.2 提示优化

针对面向细粒度情感分析场景的大语言模型, Baumann 等<sup>[99]</sup> 将所设计的提示词变异交叉机制与 NSGA-II、超体积测度选择演化多目标算法 (s-metric selection evolutionary multi-objective algorithm, SMS-EMOA) 相结合,提出了一种基于演化计算的多目标提示优化方法,以实现归纳、总结、问答、编程等能力最优意义下的复合情感响应生成。在该方法中,交叉算子和变异算子分别为引导大语言模型执行交叉和变异的文本提示:前者基于两个现有提示创建了一个新提示(如“将以上两条提示提炼为一条提示,勿删减关键信息”),后者基于一个现有提示创建了一个新提示(如“生成以下提示的变体,勿改动其语义”)。

Saletta 等<sup>[100]</sup> 基于演化采样策略对大模型的提示空间进行了探索,通过对动态结构化语法演变算法 (dynamic structured grammatical evolution, DSGE) 的染色体表示方案在丰富性方面进行改进,促进了演化搜索过程中计算成本与开采速度的平衡,在语义层面上提高了生成的提示模板的质量。

受元提示思想的启发, Levi 等<sup>[101]</sup> 设计了模块化的自动提示优化系统方案,其根据用户的意图生成与边界用例相关的无标注合成样本,结合少量标注真实样本,以迭代的方式实现了大模型的提示校准。基于 OpenAI 旗下的私有大模型家族对该系统方案的有效性和相对于一些 SOTA 方案的优越性进行了实验论证。

Salemi 等<sup>[102]</sup> 提出了基于检索增强的大模型个性化优化方法。该方法利用检索器管道从用户档案中提取用户偏好,将其作为辅助信息引入至提示模板中,进一步借助强化学习、知识蒸馏等技术实现了大模型响应个性化程度的提升。

为提升以大模型为核心的机器学习即服务这一新兴云计算服务模式的使用效率, Liu 等<sup>[103]</sup> 构建了一种基于调度优化和语境学习 (in-context learning, ICL) 的提示模板演化多目标选择策略,旨在实现最大化处理准确率与最小化调用成本间的权衡。鉴于处理准确率适应度的评估需要在选择完成后执行,设计了一种预测机制并将其集成进该策略,以在选择过程中执行处理准确率适应度的评估。以日志解析任务为例,开展该策略的实验论证,实验结果表明,相比于使用单一提示模板,根据不同作业针对性地

选择不同提示模板对于提升大模型的使用效率具有积极作用。

为提升通用大模型在面对不同下游任务时的适应能力, Sabbatella 等<sup>[104]</sup>借助高斯过程辅助的贝叶斯优化方法, 将大模型提示优选这一组合优化问题转换为连续优化问题, 从而实现了搜索空间维数、结果准确性、实际时间等多个指标最优意义下的提示选择。然而, 该方法的设计完全基于黑箱优化的视角, 在可解释性方面存在固有缺陷<sup>[105]</sup>, 有待改进。

### 2.3 联合优化

为简化现代医疗信息的处理和检索流程, 提升医患双方对于智慧医疗模式的满意度, Goswami 等<sup>[106]</sup>提出了一种基于大模型的出院文件自动摘要方法。该方法在考虑提示词调优的同时, 利用量化 LoRA (quantized LoRA, QLoRA) 实现了大模型的 PEFT, 以降低显存开销, 提高了计算效率。该方法旨在令通用大模型结合不同的医学场景, 从特定的医学报告中定位关键的医学问题, 进一步使用准确的医学语料生成凝练的医学总结。以 Llama2 为例, 对该方法进行了实验论证, 实验结果表明, 在双语评估替补 (bilingual evaluation understudy, BLEU)<sup>[107]</sup>、面向召回的摘要评估替补 (recall-oriented understudy for gisting evaluation, ROUGE)<sup>[108]</sup> 等评价指标上, 该方法更具竞争力。此外, 该方法通过了医学专家的质量评估。

大量实验结果表明, 多任务关系建模和多任务协同学习对于提升图像识别系统的准确率具有促进作用, 尤其是在小样本场景中, 但是这一现象并未引起足够的重视。鉴于此, Ding 等<sup>[109]</sup>提出了面向大视觉语言模型的低耦合上下文共享调优策略。该策略借助元网络生成了不同任务的文本描述, 将其转化为可学习的形式并嵌入至原有的提示内容, 以实现多任务和小样本环境下的大视觉语言模型提示参数联合优化。然而, 该策略的效果对于任务的相关程度敏感, 当任务的相关程度较低时, 其在图像识别准确率方面的提升并不显著。

根据现有相关文献, 对齐 (alignment)<sup>[110]</sup>、剪枝 (pruning)<sup>[111]</sup>、蒸馏 (distillation)<sup>[112]</sup> 构成了大模型联合优化的主要技术手段, 三者在内涵和外延上存在一定程度的交叉和重叠。

#### 2.3.1 对齐

对齐指的是调整大模型, 使其输出符合人类的偏好、观念和认同, 并满足各区域的安全和伦理标准的过程<sup>[113]</sup>, 其核心方法包括基于人类反馈的强化学

习 (reinforcement learning from human feedback, RLHF) 和逆向强化学习 (inverse reinforcement learning, IRL)。

Bai 等<sup>[114]</sup>设计了一种直接多偏好优化精简框架, 用于对齐基于大模型的推荐系统。该框架通过兼顾最大化正样本概率和最小化负样本概率, 提高了推荐系统对正负样本的辨识能力, 实现了对推荐系统参数和结构的联合优化。实验结果表明, 相比于传统的基于序贯机制的推荐系统与基于大模型的推荐系统, 引入该框架后的基于大模型的推荐系统在小样本情景中具有更强的推荐能力和泛化能力。

推荐系统固有的黑箱特性导致其在面向使用者和开发者的可解释性方面存在较大缺陷, 阻碍其在现实世界中的应用。鉴于此, Lei 等<sup>[115]</sup>借助对齐优化技术, 对基于大模型的推荐系统的可解释性增强进行了初步探索。将大模型作为推荐系统的代理, 从语言空间和隐空间出发, 为大模型制定了行为对齐、意图对齐、混合对齐 3 种方案。以此为基础, 实现了大模型的参数和结构对于推荐任务的适应性调整, 从而生成了高质量、高保真、高辨识的定制化内容, 用于推荐结果的解释说明。

大视觉语言模型在分析和处理输入中的不同视觉模态实体 (如图像、视频) 时, 往往默认它们相互独立。这导致关键信息在流经分析和处理过程中的各环节时可能会出现不同程度的丢失, 从而对大视觉语言模型输出的质量造成负面影响。为此, Wu 等<sup>[116]</sup>从输入中的不同视觉模态实体的相关性入手, 为大视觉语言模型设计了双向语义引导机制, 引入其 workflow, 实现了不同视觉模态实体的视觉 Token 提取以及视觉 Token 在文本特征空间中的对齐。该机制同时涉及大视觉语言模型的参数优化和提示优化。

#### 2.3.2 剪枝

剪枝指的是剔除大模型中的冗余参数并更新剩余参数, 在保证推理准确率的情况下, 提升推理效率并降低对计算、存储等资源开销的过程, 其实现思路包括全局剪枝和局部剪枝。

大模型的海量参数给其实际部署带来了成本高、难度大等一系列挑战, 催生出模型剪枝这一技术手段。传统的模型剪枝策略往往忽略了大模型深度结构中中层与层之间的重要性差异, 致使模型剪枝效果差强人意。为此, Sun 等<sup>[117]</sup>提出了基于双向评估机制的模型剪枝策略。该策略利用 Kullback-Leibler 散度分别构建了层内局部指标和层间全局指标, 用于模型剪枝影响的综合评估, 并以此为基础, 通过对

层间稀疏分布进行迭代寻优, 实现了大模型响应性能退化量的最小化. 与多种 SOTA 策略的对比实验结果显示, 该策略能够在参数压缩量更大的情况下具备更强的理解能力, 其实施本质上是一种对大模型结构和参数进行联合优化的过程.

Islam 等<sup>[118]</sup> 针对大模型在资源受限环境下的高效部署问题, 设计了基于稀疏正则化和贝叶斯压缩感知的随机剪枝方法, 以实现大模型在部署体积、响应精度、推理速度等方面的均衡提升. 通过情感分析和文本分类案例, 该方法的有效性和优越性得以论证.

### 2.3.3 蒸馏

蒸馏指的是对一个参数更多、结构更复杂的大模型 (教师模型) 的参数和结构进行联合调优, 得到一个参数更少、结构更简单的大模型 (学生模型) 的过程, 其发展瓶颈包括跨模型架构适配和跨模态标签生成.

Cui 等<sup>[119]</sup> 对基于大模型的推荐器向传统的序贯式推荐器的保性能知识蒸馏进行了初步探索, 构建了一种组合式策略, 用于实现推荐系统的推理加速和轻量化部署. 该策略借助基于赋权过滤的重要性排序和基于信号挖掘的协同式嵌入两个环节, 有效克服了知识蒸馏技术在推荐系统工程实践中面临的 3 大挑战——教师模型知识的不可靠性、教师模型与学生模型能力上限的差异、教师模型与学生模型语义空间的差异.

Lu 等<sup>[120]</sup> 开发了一种基于大模型协同的社交媒体发帖意图识别框架. 该框架内置了 3 个大模型, 分别执行重点提取、意图蒸馏、综合评估的功能, 通过

对大模型参数、结构、提示的联合调优, 实现了对含噪跨模态内容的准确理解. 在讽刺识别等情感分析任务中, 该框架取得了多个分类效果评价指标的最优.

### 2.4 发展方向

相比于小模型, 监督学习、无监督学习、强化学习 3 大机器学习范式的综合运用在大模型中体现得更为显著. 这种多范式的综合运用极大地增加了大模型最优化建模的难度, 制约了智能最优化建模方法的发展, 需要引起足够重视.

智能优化算法赋能大模型的未来发展如图 4 所示. 从通用基础出发, 针对最优化建模中的高维、多目标、动态、多峰、昂贵等特性所带来的挑战, 有机结合智能优化算法所含的启发式算子等要素和传统优化算法所含的梯度算子等要素, 探索更为经济、准确、高效的通用求解方法, 实现以生成式预训练语言模型为主的大模型在结构、参数、提示等方面的联合调优. 同时, 通过开展必要的数学分析, 增强通用求解方法的可信性 (这在现有相关工作中严重缺失). 在此基础上, 进一步借助领域自适应 (迁移学习的子集之一, 旨在对训练好的通用大模型进行微调, 使其在特定领域中获得更佳的表现<sup>[121-123]</sup>) 等专用化技术, 尝试将通用求解方法以更具针对性的方式应用于各类专用应用, 包括智慧矿山、智慧气象和智慧医疗.

大模型往往具备深度结构, 即为深度学习模型. 目前, 关于深度学习模型优化的研究以参数优化为主, 经典算法涉及梯度下降 (gradient descent, GD) 和自适应矩估计 (adaptive moment estimation, Adam)<sup>[124]</sup>. 鉴于这两种经典算法的确定性, 它们不属

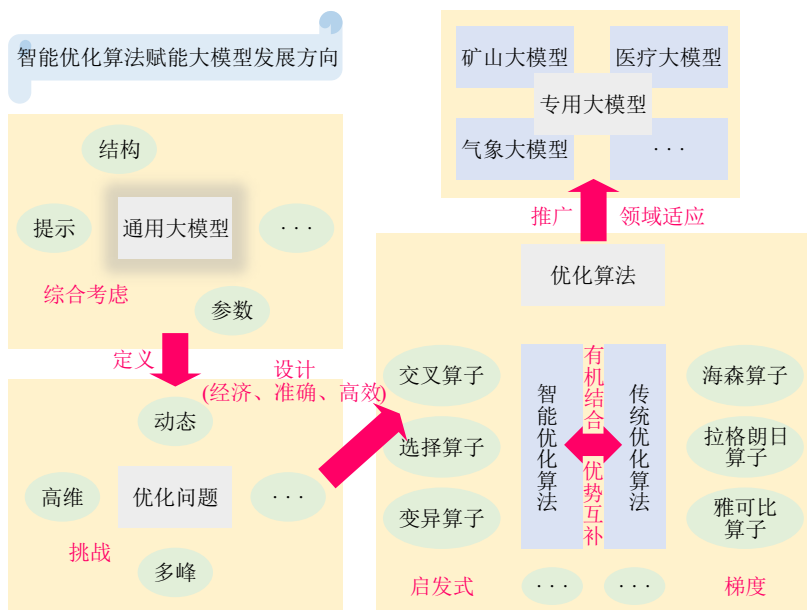


图4 智能优化算法赋能大模型发展方向

于智能优化算法的范畴. 尽管如此, 对于深度学习模型的参数优化, 诸多前沿算法的问世均是基于这两种经典算法和智能优化算法的深度融合. Le-Duc 等<sup>[125]</sup> 向基础 GD 中引入了追逃博弈策略, 提出了一种称为顺序运动优化 (sequential motion optimization, SMO) 的混合智能优化算法, 用于深度神经网络的参数调优; 之后, Le-Duc 等<sup>[126]</sup> 又将短期记忆机制引入至 Adam 的步长确定中, 并进一步将改进后的 Adam 与其所提出的 SMO 相结合, 实现了物理信息深度神经网络参数学习的效率提升; Yang 等<sup>[127]</sup> 对 GD 中的梯度算子和演化计算中的遗传算子进行了集成, 以此为基础, 开发了相应的混合智能优化算法, 用于在多目标意义下更新深度神经网络的海量权值; Akay 等<sup>[128]</sup> 对面向各类具备深度结构的神经网络的元启发式优化算法进行了系统梳理. 值得注意的是, 深度学习模型强调的是具备深度结构和学习能力的人工智能模型, 深度神经网络仅仅是深度学习模型的一个子集. 规则模型 (如置信规则库) 以及符号神经集成模型<sup>[129-130]</sup> 均可成为深度学习模型的实例. 为

了解组合爆炸对于证据推理准确率和效率造成的负面影响, 同时保持证据推理对于用户的透明性, Cao 等<sup>[131]</sup> 提出了可解释分层置信规则库; 以此为基础, 面向复杂工业系统故障诊断工程实践, Zhao 等<sup>[132]</sup> 将分层结构推广为深度结构; Mai 等<sup>[133]</sup> 进一步将属性可靠度引入深度置信规则库, 使其在不完美数据场景中的适用性得到了提升. 深度置信规则库的参数学习通常借助演化计算、群体智能等元启发式算法来实现, 如协方差矩阵自适应进化策略 (covariance matrix adaptation evolution strategy, CMA-ES) 和鲸鱼优化算法 (whale optimization algorithm, WOA), 其前沿性主要体现在基于领域知识和面向具体应用的目标和约束设计上. 实际上, 不论是对于深度学习模型的何种实例, 其在智能参数优化方面的成果均有望为大模型的智能参数优化的发展提供启发和借鉴.

### 3 结论

大模型结合智能优化算法实现优势互补, 具有重要的理论价值和实践意义. 本文从基本概念出发,

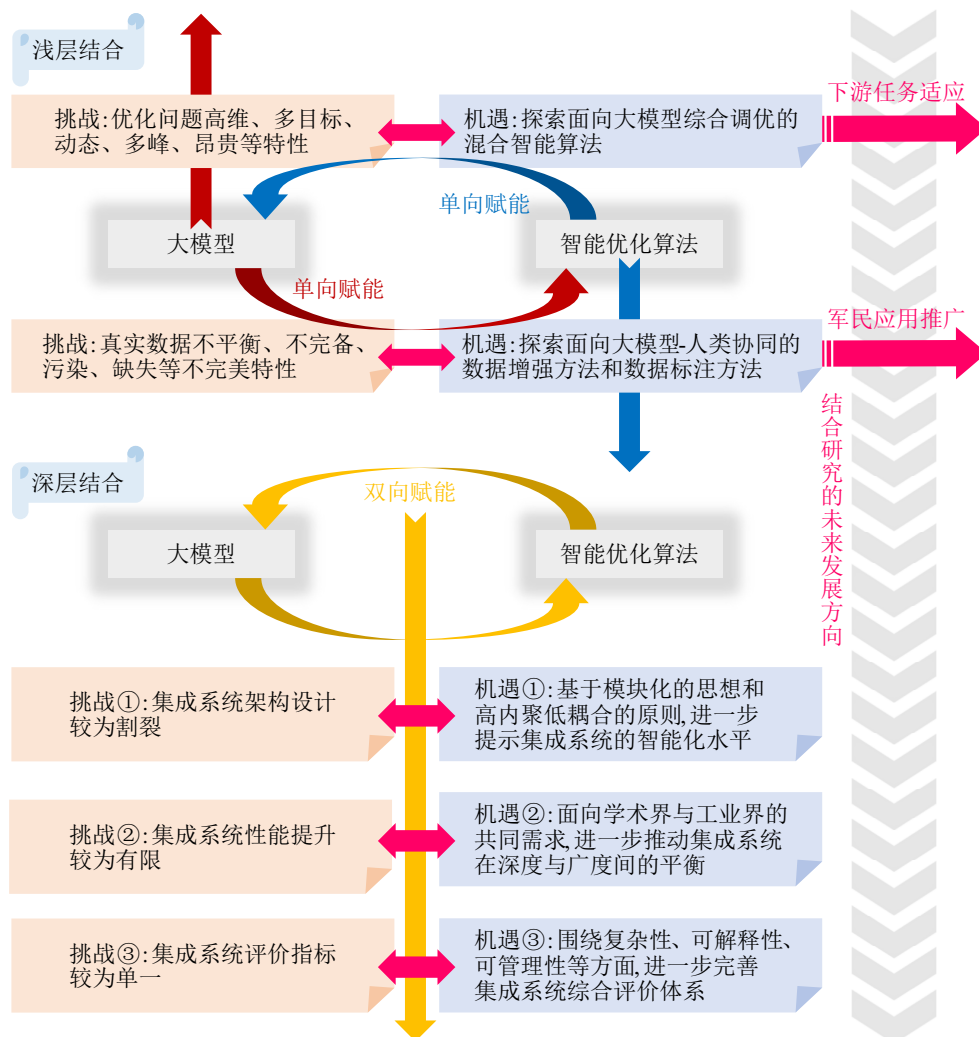


图5 结合研究的未来发展方向

依次对大模型赋能智能优化算法和智能优化算法赋能大模型的现有相关文献进行了系统梳理,并对两者的未来发展进行了合理展望。

在本文中,“可解释性”这一术语被多次提及。事实上,任何人工智能系统的诞生和发展均围绕表示、推理、优化3个方面展开,这3个方面的可解释性对于人工智能系统的成功落地至关重要。可解释性作为人工智能系统可信性的重要组成部分<sup>[134-135]</sup>,其关注度日益增加,对其评价的研究也逐渐从定性阶段迈向定量阶段,形成全局-局部、事前-事后等多种分类方式<sup>[136-137]</sup>。对可解释性评价的研究在不同人工智能流派中并未得到统一。周志杰等<sup>[138]</sup>针对置信规则库这一符号主义代表性方法的解释性进行了深入分析,窦慧等<sup>[139]</sup>针对卷积神经网络这一联结主义标志性技术的解释性进行了详细讨论,曹宏业等<sup>[140]</sup>针对强化学习范式这一行为主义典型实例的解释性进行了系统总结。流派思想的差异使得他们在诸多细节的认知上存在相当程度的分歧和割裂。目前,不同人工智能流派间已形成一种融合互补的发展趋势,体现之一便是符号神经集成,而对于大模型解释性的研究也已起步<sup>[141]</sup>,如思维链技术(chain of thoughts, CoT)。因此,对不同人工智能流派在解释性方面的成果进行整合、规范,打破人工智能系统解释性在学界与业界间的壁垒,有望进一步健全大模型解释性评估体系,为探索大模型解释性智能优化奠定更加坚实的基础。

强化学习作为机器学习三大经典范式之一,涵盖了多种模型、算法和思想。部分工作将强化学习范式涉及的算法简称为强化学习算法<sup>[142]</sup>,易对读者的正确理解造成干扰。在一般情况下,强调强化学习范式很有必要。特别是在强化学习与其他领域结合的情况下<sup>[143]</sup>,强调强化学习范式更有助于多领域协同发展形成合力。

图5以更加全面的视角展示了大模型与智能优化算法结合研究的未来发展方向。总体而言,大模型与智能优化算法结合研究尚处于浅层阶段,现有相关工作已在本文中基于合理框架进行了详尽整理。值得指出的是,不论是对于大模型赋能智能优化算法,还是对于智能优化算法赋能大模型,现有相关工作均仅涉及实证研究,旨在通过实验结果展现所提出方法的可行性、有效性和优越性。大模型与智能优化算法结合的理论基础主要依托于机器学习理论和智能优化理论,目前,鲜有专门针对大模型与智能优化算法结合的理论研究公开。大模型的海量参数和复杂结构使得开展大模型与智能优化算法结合的理论

研究颇具挑战性。这种挑战性不仅体现在大模型辅助的智能优化算法运行稳定性证明上,也反映在智能优化算法驱动的大模型训练泛化性分析上,两者在现有相关工作中均未涉及,有待在未来加以考虑。此外,对于大模型与智能优化算法结合研究,存在诸多不足,阻碍其迈向深层阶段,包括但不限于以下3个方面。

#### 1) 集成系统架构设计较为割裂。

大模型助力智能优化算法的辅助决策,智能优化算法反哺大模型的过程控制。在理想情况下,基于两者的集成系统在架构设计上应呈现一个相辅相成的二元闭环。然而,在现阶段,大模型与智能优化算法结合研究仅面向单向赋能。在未来,可根据模块化的思想,采用高内聚低耦合的原则,进一步提升集成系统的智能化水平。

#### 2) 集成系统性能提升较为有限。

在现有涉及智能优化算法与大模型结合研究的文献中,会议论文居多,期刊论文较少。多数工作将重心放在集成系统的新颖性和可用性上,对其优越性和易用性的重视程度明显不足。这导致集成系统消耗了更多的计算、存储等资源,却未能在目标任务上实现更显著的性能提升,有悖于奥卡姆剃刀原理。在未来,有必要面向学术界和工业界的共同需求,进一步推动智能优化算法与大模型结合研究在深度与广度间的平衡。

#### 3) 集成系统评价指标较为单一。

对于同一大模型,使用不同算子组合下的智能优化算法进行训练,在推理效率、推理准确率等方面有所不同;对于同一智能优化算法,使用不同架构和规模下的大模型作为代理,在寻优速度、寻优精度等方面亦是如此。现有相关工作在集成系统的评价上往往仅考虑“快”和“准”,较为片面,不利于集成系统的综合评价。一方面,可基于不同的信息熵,如邓熵<sup>[144]</sup>,对集成系统的解释性进行量化评价;另一方面,可基于不同的信息准则,如赤池信息准则(akaike information criterion, AIC),对集成系统的复杂性进行量化评价。此外,当集成系统涉及多种智能优化算法与多种大模型间的协同时,算法管理和模型管理成为必要。此时,需要设计更有针对性的评价指标,在考虑模型和算法专用化程度的情况下,对管理效果进行量化评价。这些挑战均值得在未来逐一攻克。

### 参考文献 (References)

- [1] Mustapha K B. A survey of emerging applications of

- large language models for problems in mechanics, product design, and manufacturing[J]. *Advanced Engineering Informatics*, 2025, 64: 103066.
- [2] Li X, Tian Y L, Ye P J, et al. A novel scenarios engineering methodology for foundation models in metaverse[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2023, 53(4): 2148-2159.
- [3] 孙宇祥, 赵俊杰, 解宇轩, 等. 自生成兵棋 AI: 基于大语言模型的双层 Agent 任务规划[J]. *控制与决策*, 2024, 39(12): 3927-3936.  
(Sun Y X, Zhao J J, Xie Y X, et al. Self-generated wargame AI: Double-layer agent task planning based on large language model[J]. *Control and Decision*, 2024, 39(12): 3927-3936.)
- [4] Tang C L, Yu W Y, Sun G Z, et al. SALMONN: Towards generic hearing abilities for large language models[J/OL]. 2023, arXiv: 2310.13289.
- [5] Liu Y X, Zhang K, Li Y, et al. Sora: A review on background, technology, limitations, and opportunities of large vision models[J/OL]. 2024, arXiv: 2402.17177.
- [6] Fei N Y, Lu Z W, Gao Y Z, et al. Towards artificial general intelligence via a multimodal foundation model[J]. *Nature Communications*, 2022, 13(1): 3094.
- [7] Mohammadi A, Sheikholeslam F. Intelligent optimization: Literature review and state-of-the-art algorithms (1965-2022)[J]. *Engineering Applications of Artificial Intelligence*, 2023, 126: 106959.
- [8] Mei Y, Chen Q, Lensen A, et al. Explainable artificial intelligence by genetic programming: A survey[J]. *IEEE Transactions on Evolutionary Computation*, 2023, 27(3): 621-641.
- [9] Wang B, Pei W B, Xue B, et al. A multiobjective genetic algorithm to evolving local interpretable model-agnostic explanations for deep neural networks in image classification[J]. *IEEE Transactions on Evolutionary Computation*, 2024, 28(4): 903-917.
- [10] Huang S, Yang K X, Qi S, et al. When large language model meets optimization[J]. *Swarm and Evolutionary Computation*, 2024, 90: 101663.
- [11] He C L, Zhang Y, Gong D W, et al. A review of surrogate-assisted evolutionary algorithms for expensive optimization problems[J]. *Expert Systems with Applications*, 2023, 217: 119495.
- [12] 张勇, 梁晓珂, 陈志鹏, 等. 基于多代理辅助多目标进化优化的建筑节能智能设计方法[J]. *控制与决策*, 2023, 38(11): 3057-3065.  
(Zhang Y, Liang X K, Chen Z P, et al. Intelligent design of building energy conservation with multi-surrogate assisted MOEA[J]. *Control and Decision*, 2023, 38(11): 3057-3065.)
- [13] Jin Y C. Surrogate-assisted evolutionary computation: Recent advances and future challenges[J]. *Swarm and Evolutionary Computation*, 2011, 1(2): 61-70.
- [14] Wang Z Y, Liu S B, Chen J Y, et al. Large language model-aided evolutionary search for constrained multiobjective optimization[C]. *Advanced Intelligent Computing Technology and Applications*. Singapore, 2024: 218-230.
- [15] Tian Y, Zhang T, Xiao J H, et al. A coevolutionary framework for constrained multiobjective optimization problems[J]. *IEEE Transactions on Evolutionary Computation*, 2021, 25(1): 102-116.
- [16] Rios T, Lanfermann F, Menzel S. Large language model-assisted surrogate modelling for engineering optimization[C]. *IEEE Conference on Artificial Intelligence*. Singapore, 2024: 796-803.
- [17] Farquhar S, Kossen J, Kuhn L, et al. Detecting hallucinations in large language models using semantic entropy[J]. *Nature*, 2024, 630(8017): 625-630.
- [18] Hao H, Zhang X Q, Zhou A M. Large language models as surrogate models in evolutionary algorithms: A preliminary study[J]. *Swarm and Evolutionary Computation*, 2024, 91: 101741.
- [19] Zhong R, Hussien A G, Yu J, et al. LLMOA: A novel large language model assisted hyper-heuristic optimization algorithm[J]. *Advanced Engineering Informatics*, 2025, 64: 103042.
- [20] Ma Y B, Cao Y X, Hong Y, et al. Large language model is not a good few-shot information extractor, but a good reranker for hard samples![C]. *Findings of the Association for Computational Linguistics*. Singapore, 2023: 10572-10601.
- [21] Wang F, Li Y X, Zhou A M, et al. An estimation of distribution algorithm for mixed-variable newsvendor problems[J]. *IEEE Transactions on Evolutionary Computation*, 2020, 24(3): 479-493.
- [22] Xing L N, Rohlfshagen P, Chen Y W, et al. An evolutionary approach to the multidepot capacitated arc routing problem[J]. *IEEE Transactions on Evolutionary Computation*, 2010, 14(3): 356-374.
- [23] Ahmed T, Choudhury S. LM4OPT: Unveiling the potential of large language models in formulating mathematical optimization problems[J]. *INFOR: Information Systems and Operational Research*, 2024, 62(4): 559-572.
- [24] Chen H, Constante-Flores G E, Li C. Diagnosing infeasible optimization problems using large language models[J]. *INFOR: Information Systems and Operational Research*, 2024, 62(4): 573-587.
- [25] Liu S C, Chen C S, Qu X H, et al. Large language models as evolutionary optimizers[C]. *IEEE Congress on Evolutionary Computation*. Yokohama, 2024: 1-8.
- [26] Yang C, Wang X, Lu Y, et al. Large language models as optimizers[C]. *The 12th International Conference on Learning Representations*. Vienna, 2024: 1-41.
- [27] Liu F, Tong X L, Yuan M X, et al. Evolution of heuristics: Towards efficient automatic algorithm design using large language model[C]. *The 41st International Conference on Machine Learning*. Vienna, 2024: 1-23.
- [28] Zhong R, Xu Y F, Zhang C, et al. Leveraging large language model to generate a novel metaheuristic

- algorithm with CRISPE framework[J]. *Cluster Computing*, 2024, 27: 13835-13869.
- [29] Pluhacek M, Kazikova A, Kadavy T, et al. Leveraging large language models for the generation of novel metaheuristic optimization algorithms[C]. Proceedings of the Companion Conference on Genetic and Evolutionary Computation. Lisbon, 2023: 1812-1820.
- [30] Xiao Z, Zhang D, Wu Y, et al. Chain-of-experts: When LLMs meet complex operations research problems[C]. The 12th International Conference on Learning Representations. Vienna, 2024: 1-19.
- [31] Sartori C C, Blum C, Ochoa G. STNWeb: A new visualization tool for analyzing optimization algorithms[J]. *Software Impacts*, 2023, 17: 100558.
- [32] Sartori C C, Blum C, Ochoa G. Large language models for the automated analysis of optimization algorithms[C]. Proceedings of the Genetic and Evolutionary Computation Conference. Melbourne, 2024: 160-168.
- [33] Custode L L, Caraffini F, Yaman A, et al. An investigation on the use of large language models for hyperparameter tuning in evolutionary algorithms[C]. Proceedings of the Genetic and Evolutionary Computation Conference Companion. Melbourne, 2024: 1838-1845.
- [34] Tianrunroj Y, Iba H. ROIL: Rule optimization via large language model for imitation learning[C]. IEEE Congress on Evolutionary Computation. Yokohama, 2024: 1-8.
- [35] Yao S, Chen H, Yang J, et al. WebShop: Towards scalable real-world web interaction with grounded language agents[C]. Advances in Neural Information Processing Systems. New Orleans, 2022: 1-14.
- [36] Pluhacek M, Kovac J, Viktorin A, et al. Using LLM for automatic evolution of metaheuristics from swarm algorithm SOMA[C]. Proceedings of the Genetic and Evolutionary Computation Conference Companion. Melbourne, 2024: 2018-2022.
- [37] Pluhacek M, Kovac J, Janku P, et al. A critical examination of large language model capabilities in iteratively refining differential evolution algorithm[C]. Proceedings of the Genetic and Evolutionary Computation Conference Companion. Melbourne, 2024: 1855-1862.
- [38] Xiao T, Xu P. Exploring automated energy optimization with unstructured building data: A multi-agent based framework leveraging large language models[J]. *Energy and Buildings*, 2024, 322: 114691.
- [39] Bran A M, Cox S, Schilter O, et al. Augmenting large language models with chemistry tools[J]. *Nature Machine Intelligence*, 2024, 6(5): 525-535.
- [40] Qin S Z, Guan H, Liao W J, et al. Intelligent design and optimization system for shear wall structures based on large language models and generative artificial intelligence[J]. *Journal of Building Engineering*, 2024, 95: 109996.
- [41] Liao W J, Lu X Z, Huang Y L, et al. Automated structural design of shear wall residential buildings using generative adversarial networks[J]. *Automation in Construction*, 2021, 132: 103931.
- [42] Genkin M, McArthur J J. A transfer learning approach to minimize reinforcement learning risks in energy optimization for automated and smart buildings[J]. *Energy and Buildings*, 2024, 303: 113760.
- [43] Iijima F, Ikeda S, Nagai T. Automated computational design method for energy systems in buildings using capacity and operation optimization[J]. *Applied Energy*, 2022, 306: 117973.
- [44] Fei Y F, Qin S Z, Liao W J, et al. Graph neural network-assisted evolutionary algorithm for rapid optimization design of shear-wall structures[J]. *Advanced Engineering Informatics*, 2025, 65: 103129.
- [45] Fei Y F, Liao W J, Lu X Z, et al. Semi-supervised learning method incorporating structural optimization for shear-wall structure design using small and long-tailed datasets[J]. *Journal of Building Engineering*, 2023, 79: 107873.
- [46] Yuksel S E, Wilson J N, Gader P D. Twenty years of mixture of experts[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2012, 23(8): 1177-1193.
- [47] Cai W L, Jiang J Y, Wang F, et al. A survey on mixture of experts in large language models[J/OL]. 2024, arXiv: 2407.06204.
- [48] Ferretti L, Ansaloni G, Pozzi L. Cluster-based heuristic for high level synthesis design space exploration[J]. *IEEE Transactions on Emerging Topics in Computing*, 2021, 9(1): 35-43.
- [49] Xydis S, Palermo G, Zaccaria V, et al. SPIRIT: Spectral-aware Pareto iterative refinement optimization for supervised high-level synthesis[J]. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 2015, 34(1): 155-159.
- [50] Siracusa M, Ferrandi F. Tensor optimization for high-level synthesis design flows[J]. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 2020, 39(11): 4217-4228.
- [51] Haas R, Nömmner R, Juergens E, et al. Optimization of automated and manual software tests in industrial practice: A survey and historical analysis[J]. *IEEE Transactions on Software Engineering*, 2024, 50(8): 2005-2020.
- [52] Wang X Y, Ali S, Yue T, et al. Quantum approximate optimization algorithm for test case optimization[J]. *IEEE Transactions on Software Engineering*, 2024, 50(12): 3249-3264.
- [53] Hu Q, Guo Y J, Xie X F, et al. Test optimization in DNN testing: A survey[J]. *ACM Transactions on Software Engineering and Methodology*, 2024, 33(4): 1-42.
- [54] Zhu S Q, Yu T, Xu T, et al. Intelligent computing: The latest advances, challenges, and future[J]. *Intelligent*

- Computing, 2023, 2: 0006.
- [55] Xu H C, Hu H T, Huang S T. Optimizing high-level synthesis designs with retrieval-augmented large language models[C]. IEEE LLM Aided Design Workshop. San Jose, 2024: 1-5.
- [56] Chen M, Tworek J, Jun H, et al. Evaluating large language models trained on code[J/OL]. 2021, arXiv: 2107.03374.
- [57] Xiao D N, Guo Y M, Li Y H, et al. Optimizing search-based unit test generation with large language models: An empirical study[C]. Proceedings of the 15th Asia-Pacific Symposium on Internetware. Macau, 2024: 71-80.
- [58] Lukaszczuk S, Fraser G. Pynguin: Automated unit test generation for Python[C]. IEEE/ACM the 44th International Conference on Software Engineering: Companion Proceedings. Pittsburgh, 2022: 168-172.
- [59] Lemieux C, Inala J P, Lahiri S K, et al. CodaMosa: Escaping coverage plateaus in test generation with pre-trained large language models[C]. IEEE/ACM the 45th International Conference on Software Engineering. Melbourne, 2023: 919-931.
- [60] Heris F S M, Ghannadpour S F, Bagheri M, et al. A new accessibility based team orienteering approach for urban tourism routes optimization (A real life case)[J]. Computers & Operations Research, 2022, 138: 105620.
- [61] Díez J, Martínez-Rego D, Alonso-Betanzos A, et al. Optimizing novelty and diversity in recommendations[J]. Progress in Artificial Intelligence, 2019, 8: 101-109.
- [62] Li B H, Zhang K, Sun Y P, et al. Research on travel route planning optimization based on large language model[C]. Proceedings of the 6th International Conference on Data-Driven Optimization of Complex Systems. Hangzhou, 2024: 352-357.
- [63] Li F F, Cheng D H, Hadjieleftheriou M, et al. On trip planning queries in spatial databases[C]. Advances in Spatial and Temporal Databases. Heidelberg, 2005: 273-290.
- [64] Sharifzadeh M, Kolahdouzan M, Shahabi C. The optimal sequenced route query[J]. The VLDB Journal, 2008, 17: 765-787.
- [65] Sharma A, Li H, Li X, et al. Optimizing novelty of top- $k$  recommendations using large language models and reinforcement learning[C]. Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. Barcelona, 2024: 5669-5679.
- [66] Xu J J, Li B. Uncertain utility portfolio optimization based on two different criteria and improved whale optimization algorithm[J]. Expert Systems with Applications, 2025, 268: 126281.
- [67] Behera J, Kumar P. An approach to portfolio optimization with time series forecasting algorithms and machine learning techniques[J]. Applied Soft Computing, 2025, 170: 112741.
- [68] Kubo K, Nakagawa K. Portfolio optimization using deep learning with risk aversion utility function[J]. Finance Research Letters, 2025, 74: 106761.
- [69] Alipour-Vaezi M, Tsui K L. Data-driven portfolio management for motion pictures industry: A new data-driven optimization methodology using a large language model as the expert[J]. Computers & Industrial Engineering, 2024, 197: 110574.
- [70] Gan K, Wei T. Erasing the bias: Fine-tuning foundation models for semi-supervised learning[C]. Proceedings of the 41st International Conference on Machine Learning. Vienna, 2024: 1-18.
- [71] Li J J, Xu M L, Xiang L R, et al. Foundation models in smart agriculture: Basics, opportunities, and challenges[J]. Computers and Electronics in Agriculture, 2024, 222: 109032.
- [72] Li J J, Lammers K, Yin X Y, et al. MetaFruit meets foundation models: Leveraging a comprehensive multi-fruit dataset for advancing agricultural foundation models[J]. Computers and Electronics in Agriculture, 2025, 231: 109908.
- [73] David A N, Sewsynker-Sukai Y, Meyer E L, et al. Harnessing artificial neural networks and large language models for bioprocess optimization: Predicting sugar output from Kraft waste-based lignocellulosic pretreatments[J]. Industrial Crops and Products, 2023, 206: 117686.
- [74] Chen D, Huang Y B. Integrating reinforcement learning and large language models for crop production process management optimization and control through a new knowledge-based deep learning paradigm[J]. Computers and Electronics in Agriculture, 2025, 232: 110028.
- [75] Zhang X, Chen H Z, Hao Y C, et al. A low-carbon route optimization method for cold chain logistics considering traffic status in China[J]. Computers & Industrial Engineering, 2024, 193: 110304.
- [76] Zheng K N, Huo X X, Jasimuddin S, et al. Logistics distribution optimization: Fuzzy clustering analysis of e-commerce customers' demands[J]. Computers in Industry, 2023, 151: 103960.
- [77] Gan Q. A logistics distribution route optimization model based on hybrid intelligent algorithm and its application[J]. Annals of Operations Research, 2022, 1: 1-13.
- [78] Liu Y, Wu F Y, Liu Z Y, et al. Can language models be used for real-world urban-delivery route optimization?[J]. The Innovation, 2023, 4(6): 100520.
- [79] Zhu Y B, Xu S T, Liu B Y, et al. Optimization of smart healthcare services and development strategies based on large language models[C]. Proceedings of the 4th International Conference on Artificial Intelligence and Computer Engineering. Dalian, 2023: 1004-1011.
- [80] Nerella S, Bandyopadhyay S, Zhang J Q, et al. Transformers and large language models in healthcare: A review[J]. Artificial Intelligence in Medicine, 2024, 154: 102900.

- [81] He K, Mao R, Lin Q K, et al. A survey of large language models for healthcare: From data, technology, and applications to accountability and ethics[J]. *Information Fusion*, 2025, 118: 102963.
- [82] Dong B, Zhang L, Yuan J J, et al. Large language models: Game-changers in the healthcare industry[J]. *Science Bulletin*, 2025, 70(3): 283-286.
- [83] Wan F, Wang K Z, Wang T, et al. Enhancing healthcare resource allocation through large language models[J]. *Swarm and Evolutionary Computation*, 2025, 94: 101859.
- [84] Jiang X, Li F, Zhao H, et al. Long term memory: The foundation of AI self-evolution[J/OL]. 2024, arXiv: 2410.15665.
- [85] Yang J B, Xu D L, Xu X B, et al. Likelihood analysis of imperfect data[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2023, 53(8): 5046-5057.
- [86] 王村松, 陆宁云, 程月华, 等. 基于无标签、不均衡、初值不确定数据的设备健康评估方法[J]. *控制与决策*, 2020, 35(11): 2687-2695.  
(Wang C S, Lu N Y, Cheng Y H, et al. Equipment health risk assessment based on unlabeled, unbalanced data under uncertain initial condition[J]. *Control and Decision*, 2020, 35(11): 2687-2695.)
- [87] Zhou Y, Guo C L, Wang X, et al. A survey on data augmentation in large model era[J/OL]. 2024, arXiv: 2401.15422.
- [88] Tan Z, Li D W, Wang S, et al. Large language models for data annotation and synthesis: A survey[J/OL]. 2024, arXiv: 2402.13446.
- [89] Tao L F, Zhang T, Peng D, et al. Long-term degradation prediction and assessment with heteroscedasticity telemetry data based on GRU-GARCH and MD hybrid method: An application for satellite[J]. *Aerospace Science and Technology*, 2021, 115: 106826.
- [90] Ranasinghe K, Sabatini R, Gardi A, et al. Advances in integrated system health management for mission-essential and safety-critical aerospace applications[J]. *Progress in Aerospace Sciences*, 2022, 128: 100758.
- [91] Li Y T, Ren B, Wen X. An efficient two-stage matheuristic for scheduling airport electric shuttle buses with flight schedule coordination[J]. *Computers & Industrial Engineering*, 2025, 203: 110998.
- [92] Wu Z X, Zhang O, Wang X R, et al. Leveraging language model for advanced multiproperty molecular optimization via prompt engineering[J]. *Nature Machine Intelligence*, 2024, 6: 1359-1369.
- [93] Jin F H, Liu Y F, Tan Y. Derivative-free optimization for low-rank adaptation in large language models[J]. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 2024, 32: 4607-4616.
- [94] Li G C, Zhi C, Chen J L, et al. Exploring parameter-efficient fine-tuning of large language model on automated program repair[C]. Proceedings of the 39th IEEE/ACM International Conference on Automated Software Engineering. Sacramento, 2024: 719-731.
- [95] Wang T W, Li K, Hao Z X, et al. LONG EXPOSURE: Accelerating parameter-efficient fine-tuning for LLMs under shadowy sparsity[C]. SC24: International Conference for High Performance Computing, Networking, Storage and Analysis. Atlanta, 2024: 1-18.
- [96] Ling Z Q, Chen D Y, Yao L Y, et al. On the convergence of zeroth-order federated tuning for large language models[C]. Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. Barcelona, 2024: 1827-1838.
- [97] Liu Q D, Wu X, Zhao X Y, et al. When MOE meets LLMs: Parameter efficient fine-tuning for multi-task medical applications[C]. Proceedings of the 47th International ACM SIGIR Conference on Research and Development in Information Retrieval. Washington DC, 2024: 1104-1114.
- [98] Zhang D, Feng T, Xue L, et al. Parameter-efficient fine-tuning for foundation models[J/OL]. 2025, arXiv: 2501.1378.
- [99] Baumann J, Kramer O. Evolutionary multi-objective optimization of large language model prompts for balancing sentiments[C]. Applications of Evolutionary Computation. Singapore, 2024: 212-224.
- [100] Saletta M, Ferretti C. Exploring the prompt space of large language models through evolutionary sampling[C]. Proceedings of the Genetic and Evolutionary Computation Conference. Melbourne, 2024: 1345-1353.
- [101] Levi E, Brosh E, Friedmann M. Intent-based prompt calibration: Enhancing prompt optimization with synthetic boundary cases[C]. ICLR Workshop on Navigating and Addressing Data Problems for Foundation Models. Vienna, 2024: 1-18.
- [102] Salemi A, Kallumadi S, Zamani H. Optimization methods for personalizing large language models through retrieval augmentation[C]. Proceedings of the 47th International ACM SIGIR Conference on Research and Development in Information Retrieval. Washington DC, 2024: 752-762.
- [103] Liu Y Y, Zhang H Y, Li Z Q, et al. Optimizing the utilization of large language models via schedule optimization: An exploratory study[C]. Proceedings of the 18th ACM/IEEE International Symposium on Empirical Software Engineering and Measurement. Barcelona, 2024: 84-95.
- [104] Sabbatella A, Ponti A, Giordani I, et al. Prompt optimization in large language models[J]. *Mathematics*, 2024, 12(6): 929.
- [105] Du Y, Sun W, Snoek C. IPO: Interpretable prompt optimization for vision-language models[C]. The 38th Annual Conference on Neural Information Processing Systems. Vancouver, 2024: 1-42.
- [106] Goswami J, Prajapati K K, Saha A, et al. Parameter-efficient fine-tuning large language model approach for

- hospital discharge paper summarization[J]. *Applied Soft Computing*, 2024, 157: 111531.
- [107] Papineni K, Roukos S, Ward T, et al. BLEU: A method for automatic evaluation of machine translation[C]. Proceedings of the 40th Annual Meeting on Association for Computational Linguistics. Philadelphia, 2001: 311-318.
- [108] Lin C Y. ROUGE: A package for automatic evaluation of summaries[C]. Text Summarization Branches Out. Barcelona, 2004: 74-81.
- [109] Ding K, Wang Y, Liu P Z, et al. Multi-task prompt tuning with soft context sharing for vision-language models[J]. *Neurocomputing*, 2024, 603: 128290.
- [110] Shen T H, Jin R R, Huang Y F, et al. Large language model alignment: A survey[J/OL]. 2023, arXiv: 2309.15025.
- [111] Cheng H R, Zhang M, Shi J Q. A survey on deep neural network pruning: Taxonomy, comparison, analysis, and recommendations[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2024, 46(12): 10558-10578.
- [112] Yang C P, Zhu Y, Lu W, et al. Survey on knowledge distillation for large language models: Methods, evaluation, and application[J]. *ACM Transactions on Intelligent Systems and Technology*, 2024, 16: 1-27.
- [113] Bai G, Li Y, Ling C, et al. SparseLLM: Towards global pruning of pre-trained language models[C]. Advances in Neural Information Processing Systems 37. New Orleans, 2024: 46203-46225.
- [114] Bai Z X, Wu N, Cai F Y, et al. Aligning large language model with direct multi-preference optimization for recommendation[C]. Proceedings of the 33rd ACM International Conference on Information and Knowledge Management. Boise, 2024: 76-86.
- [115] Lei Y X, Lian J X, Yao J, et al. RecExplainer: Aligning large language models for explaining recommendation models[C]. Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. Barcelona, 2024: 1530-1541.
- [116] Wu T, Li M Z, Chen J Y, et al. Semantic alignment for multimodal large language models[C]. Proceedings of the 32nd ACM International Conference on Multimedia. Melbourne, 2024: 3489-3498.
- [117] Sun Q H, Wang W L, Zhu Y N, et al. Dual-assessment driven pruning: Iterative optimizing layer-wise sparsity for large language model[C]. Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. Barcelona, 2024: 2775-2783.
- [118] Islam M M, Alawad M. Stochastically pruning large language models using sparsity regularization and compressive sensing[C]. Proceedings of the Great Lakes Symposium on VLSI 2023. Knoxville, 2023: 63-68.
- [119] Cui Y, Liu F, Wang P B, et al. Distillation matters: Empowering sequential recommenders to match the performance of large language models[C]. Proceedings of the 18th ACM Conference on Recommender Systems. Bari, 2024: 507-517.
- [120] Lu F H, Wang W Q, Luo Y, et al. Miko: Multimodal intention knowledge distillation from large language models for social-media commonsense discovery[C]. Proceedings of the 32nd ACM International Conference on Multimedia. Melbourne, 2024: 3303-3312.
- [121] Fang Z, Lu J, Liu F, et al. Open set domain adaptation: Theoretical bound and algorithm[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 32(10): 4309-4322.
- [122] Fang Z, Lu J, Liu F, et al. Semi-supervised heterogeneous domain adaptation: Theory and algorithms[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(1): 1087-1105.
- [123] Li K, Lu J, Zuo H, et al. Multidomain adaptation with sample and source distillation[J]. *IEEE Transactions on Cybernetics*, 2024, 54(4): 2193-2205.
- [124] Kingma D, Ba J. Adam: A method for stochastic optimization[C]. Proceedings of the 3rd International Conference on Learning Representations. San Diego, 2015: 1-15.
- [125] Le-Duc T, Nguyen Q H, Lee J, et al. Strengthening gradient descent by sequential motion optimization for deep neural networks[J]. *IEEE Transactions on Evolutionary Computation*, 2023, 27(3): 565-579.
- [126] Le-Duc T, Nguyen-Xuan H, Lee J. Sequential motion optimization with short-term adaptive moment estimation for deep learning problems[J]. *Engineering Applications of Artificial Intelligence*, 2024, 129: 107593.
- [127] Yang S S, Tian Y, He C, et al. A gradient-guided evolutionary approach to training deep neural networks[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 33(9): 4861-4875.
- [128] Akay B, Karaboga D, Akay R. A comprehensive survey on optimizing deep learning models by metaheuristics[J]. *Artificial Intelligence Review*, 2022, 55: 829-894.
- [129] Sheth A, Roy K, Gaur M. Neurosymbolic artificial intelligence (why, what, and how)[J]. *IEEE Intelligent Systems*, 2023, 38(3): 56-62.
- [130] Yu D R, Yang B, Liu D Y, et al. A survey on neural-symbolic learning systems[J]. *Neural Networks*, 2023, 166: 105-126.
- [131] Cao Y, Tang S W, Yao R Q, et al. Interpretable hierarchical belief rule base expert system for complex system modeling[J]. *Measurement*, 2024, 226: 114033.
- [132] Zhao B Y, Zhang Q X, He W, et al. A deep belief rule base-based fault diagnosis method for complex systems[J]. *ISA Transactions*, 2024, 150: 77-91.
- [133] Mai J H, Huang H L, Wei F X, et al. Autonomous underwater vehicle fault diagnosis model based on a deep belief rule with attribute reliability[J]. *Ocean Engineering*, 2025, 321: 120472.

- [134] 刘晗, 李凯旋, 陈仪香. 人工智能系统可信性度量评估研究综述[J]. 软件学报, 2023, 34(8): 3774-3792.  
(Liu H, Li K X, Chen Y X. Survey on trustworthiness measurement for artificial intelligence systems[J]. Journal of Software, 2023, 34(8): 3774-3792.)
- [135] Kaur D, Uslu S, Rittichier K J, et al. Trustworthy artificial intelligence: A review[J]. ACM Computing Surveys, 2022, 55(2): 1-38.
- [136] Ali S, Abuhmed T, El-Sappagh S, et al. Explainable artificial intelligence (XAI): What we know and what is left to attain trustworthy artificial intelligence[J]. Information Fusion, 2023, 99: 101805.
- [137] Longo L, Brcic M, Cabitza F, et al. Explainable artificial intelligence (XAI) 2.0: A manifesto of open challenges and interdisciplinary research directions[J]. Information Fusion, 2024, 106: 102301.
- [138] 周志杰, 曹友, 胡昌华, 等. 基于规则的建模方法的可解释性及其发展[J]. 自动化学报, 2021, 47(6): 1201-1216.  
(Zhou Z J, Cao Y, Hu C H, et al. The interpretability of rule-based modeling approach and its development[J]. Acta Automatica Sinica, 2021, 47(6): 1201-1216.)
- [139] 窦慧, 张凌茗, 韩峰, 等. 卷积神经网络的可解释性研究综述[J]. 软件学报, 2024, 35(1): 159-184.  
(Dou H, Zhang L M, Han F, et al. Survey on convolutional neural network interpretability[J]. Journal of Software, 2024, 35(1): 159-184.)
- [140] 曹宏业, 刘潇, 董绍康, 等. 面向强化学习的可解释性研究综述[J]. 计算机学报, 2024, 47(8): 1853-1882.  
(Cao H Y, Liu X, Dong S K, et al. A survey of interpretability research methods for reinforcement learning[J]. Chinese Journal of Computers, 2024, 47(8): 1853-1882.)
- [141] Zhao H Y, Chen H J, Yang F, et al. Explainability for large language models: A survey[J]. ACM Transactions on Intelligent Systems and Technology, 2024, 15(2): 1-38.
- [142] Silver D, Hubert T, Schrittwieser J, et al. A general reinforcement learning algorithm that Masters chess, shogi, and Go through self-play[J]. Science, 2018, 362(6419): 1140-1144.
- [143] Song Y J, Wu Y T, Guo Y Y, et al. Reinforcement learning-assisted evolutionary algorithm: A survey and research opportunities[J]. Swarm and Evolutionary Computation, 2024, 86: 101517.
- [144] Deng Y. Deng entropy[J]. Chaos, Solitons and Fractals, 2016, 91: 549-553.

### 作者简介

张浩然 (2000-), 男, 博士生, 主要研究方向为智能系统、证据推理, E-mail: zhr@stu.xidian.edu.cn;

李君 (1979-), 女, 讲师, 博士, 主要研究方向为智能优化与调度、信息安全, E-mail: jli@hnie.edu.cn;

邢立宁 (1980-), 男, 教授, 博士, 主要研究方向为智能优化与调度、复杂系统仿真, E-mail: xinglining@gmail.com;

杨若涵 (1992-), 女, 副教授, 博士, 主要研究方向为多智能体协同控制、复杂系统健康管理, E-mail: ruohanyang@nwpu.edu.cn;

吴健 (1994-), 男, 讲师, 博士, 主要研究方向为智能优化与调度、卫星任务规划, E-mail: jianwwwu@126.com.