从数据中挖掘符号规则

大模型驱动的新型机器学习框架

2026-06-14

熊英飞 北京大学

1 概论

大模型正在替代自动化算法

大模型生成代码 直接生成成千上万行代码，完成软件项目。	→	**传统程序合成** 仅能合成单行小表达式或局部代码片段。
大模型生成证明 直接完成公开数学问题的证明。	→	**传统求解器** 只能在已知决策过程的小范围内证明。
大模型查找漏洞 Mythos 已经对世界网络安全构成威胁	→	**传统程序分析** 因为误报高居不下在实践中应用有限。
大模型生成优化 对程序进行全面改写并大幅提升性能	→	**传统编译优化** 只能进行局部小改动，很少影响复杂度。

软件自动化的未来是什么样的?

① 只有大模型

② 大模型和符号算法混合

③ 只有符号算法

为什么是符号算法?

经过充分研究的问题上，理论最优算法远优于大模型

- 大模型进行四则运算远不如计算器
- 很多约束求解场景，大模型未超越传统工具

为什么现在大模型解得更好?

因为很多场景的自动化策略和算法**还没有被研究出来**。

如何能得到这些算法?

参考大模型训练，**从大量样例中学习**：对所有样例分析出合适的自动化策略，并形式化为符号系统中的规则。

为什么之前没有这样做?

- 面临场景过多，**人力不够**
- 大模型时代，这一切都能交给大模型来做。

另一个证据

Why Expert Systems Fail.
Michael Z. Bell, *The Journal of the Operational Research Society*, 1985.
DOI: 10.2307/2582480

专家系统失败的常见原因

- 专家没空
- 专家无法表述规则
- 专家不想表述规则
- 没有专家
- 缺乏常识
- 知识表示语言不够强
- 难以测试
- 用户不信任

符号智能失败的核心原因:
没有足够多的专家来写规则。

2 从证明数据挖掘符号证明算法 [arxiv:2605.08694]

动机

大模型证明智能体

- 混合大模型和符号求解器
- 展现出强大的证明能力
- 大模型带来昂贵的证明成本
- 在中小安全攸关软件企业难以使用

如何增强证明智能体?

- 大量已有研究关注增强大模型
- 但符号求解器（如：CoqHammer）同样值得增强
  - 如果增强能力落在大模型之外，则提升智能体整体能力
  - 如果增强能力落在大模型之内，则降低智能体整体开销
- 中小安全攸关软件企业往往只能使用符号求解器

LLM2LTAC 方法概览

离线阶段

给定一个证明训练集，大模型分析每个证明，提取其中用到的证明策略

→

证明策略

大模型将证明策略编码成 Rocq Tactics

→

在线阶段

提取出的符号策略和 CoqHammer 交替运用，完成证明

离线阶段：提取

证明准备

提取定理、证明脚本、相关定义和引理

```
Lemma append_neutral_r :
forall (i : positive),
  append i xH = i.
Proof.
  induction i; simpl; congruence.
Qed.
```

分析证明过程

LLM 逐步解释证明过程

```
### Step-by-step explanation
1. ** induction i**
- ** Effect :** Performs induction on the binary positive integer i. So the induction generates three subgoals:
- Base case: i = xH
- Inductive case for xO p with IH for p
  ...
2. **simpl**
...
```

识别通用策略

要求 LLM 从中证明过程中识别出通用的证明策略

```
## General Proof Strategies
### 1. **Structural Induction with Recursive Data Types**
This pattern is widely applicable to theorems about recursive data structures like lists, trees, and natural numbers, where properties can be proven by following the structure's definition.
...
```

Ltac 生成

将自然语言策略用 Rocq 的 Ltac 语言编写为可执行策略

```
Ltac
structural_induction_recursive :=
  match goal with
  | [ |- forall p : positive, _ ] ⇒
    induction p; simpl; try
congruence
  | [ |- forall n : nat, _ ] ⇒
  ...
```

离线阶段：质量检查

有效性测试

- 编译器检查策略有效性
- 如果没有通过编译则请 LLM 修复

泛化性测试

- 在一个验证集上检测策略泛化性
- 只保留让 a%-b% 的证明状态发生改变的策略
  - 低于 a% 说明泛化性不足
  - 高于 b% 往往是没有实际意义的策略，比如重命名变量

在线阶段：整体流程

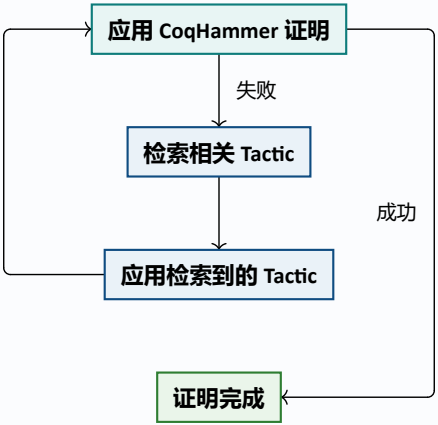

在线阶段：检索

问题

- 直接检索：从证明状态检索 Ltac 策略
- **失败**：检索算法基于文本相似性，但 Ltac 程序文本密度低。

解决方案

- 首先将目标证明目标匹配到源定理
- 再从定理找到所关联的 Ltac 策略

实验验证

实验设置

- 训练集：Rocq 标准库
- 测试集：来自四个真实项目的定理：CompCert、Coq-Art、Ext-Lib、Vfa
- 提取模型：DeepSeek V3.2，GPT 5.2

实验结果

- 显著提升符号求解器的能力
- 集成到大模型智能体之后，智能体的求解能力和词元效率均得到提升

+23.87%

CoqHammer 求解数提升

+9.90%

集成到 Claude Code 后求解数提升

−10.51%

集成到 Claude Code 后词元消耗降低

3 融合符号规则和大模型的自动代码优化 [TOSEM26]

研究动机：一个优化示例

```
R_API const char* r_reg_32_to_64(RReg* reg,
    const char* rreg32) {
  // ...
  for (i = 0; i < R_REG_TYPE_LAST; ++i) {
    r_list_foreach(reg->regset[i].regs, iter, item) {
      if (!r_str_casecmp(rreg32, item->name)
          && item->size == 32) {
        j = item->offset;
        break;
      }
    }
  }
}
```

```
R_API const char* r_reg_32_to_64(RReg* reg,
    const char* rreg32) {
  // ...
  for (i = 0; i < R_REG_TYPE_LAST; ++i) {
    r_list_foreach(reg->regset[i].regs, iter, item) {
      if (item->size == 32 //交换了顺序
          && !r_str_casecmp(rreg32, item->name)) {
        j = item->offset;
        break;
      }
    }
  }
}
```

通过交换子条件的顺序，避免开销较大的运算

2.2 现有方法局限性与本研究的思路

基于规则的方法

难以对所有场景都精确覆盖

- Clang-tidy 不支持“交换条件顺序”
- CLion 会对所有条件都建议交换

纯 LLM 端到端优化

- 策略空间和代码空间都很庞大
- LLM 难以定位优化位置和对应策略，往往只能给出通用建议

检索增强方法

- 指定位置和样例后模型优化效果提升
- 但基于文本相似度检索样例往往返回无关结果

本研究核心思路

静态分析匹配优化位置和对应策略： 由 LLM 生成的 Semgrep 规则在代码中匹配可优化位置和对应优化策略，再由 LLM 在策略提示下生成具体优化代码。

SemOpt 框架概述

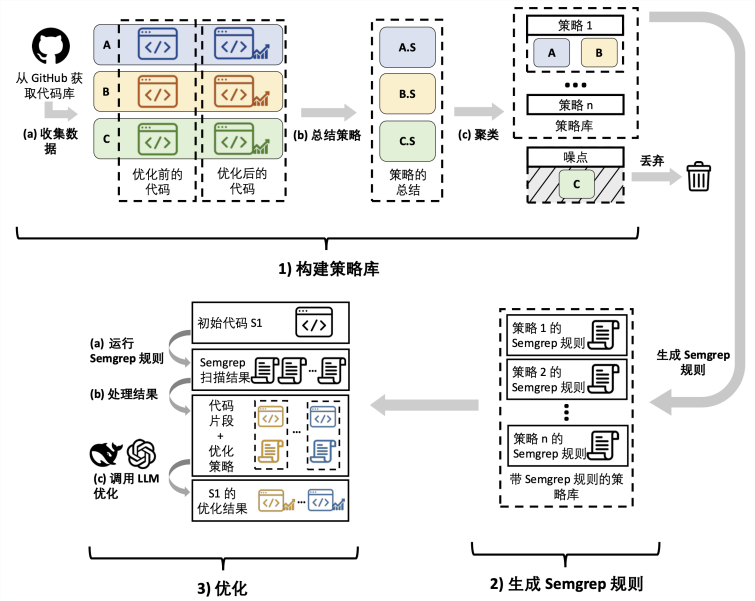
从 GitHub 获取代码库
(a) 收集数据
A
B
C
优化前的代码
优化后的代码
(b) 总结策略
A.S
B.S
C.S
策略的总结
(c) 聚类
策略 1
A
B
策略 n
策略库
噪点
C
丢弃
1) 构建策略库
生成 Semgrep 规则
策略 1 的 Semgrep 规则
策略 2 的 Semgrep 规则
策略 n 的 Semgrep 规则
带 Semgrep 规则的策略库
2) 生成 Semgrep 规则
初始代码 S1
(a) 运行 Semgrep 规则
Semgrep 扫描结果
(b) 处理结果
代码片段 + 优化策略
(c) 调用 LLM 优化
S1 的优化结果
3) 优化

策略库构建

数据来源

- GitHub 活跃开源仓库（100+ stars，近 5 年活跃）
- C/C++：30,342 个代码库，35,668 个优化提交
- Python：9,316 个代码库，10,084 个优化提交

策略提炼流程

1. LLM 为每个提交生成 3 条策略描述
2. 选择与其他描述平均相似度最高的描述
3. 使用 DBSCAN 算法对策略做聚类

指标	C/C++	Python
代码库	30,342	9,316
优化提交	35,668	10,084
聚类数	155	55
平均簇大小	13.4	19.9

实验结果：复现程序员的历史优化

C/C++ 代码优化（151 个任务）

方法	精确匹配	语义等价
直接提示	1.32%	5.96%
RAG	16.56%	23.84%
RAPGen	0.00%	1.99%
SemOpt	**27.81%**	**42.38%**
Clang-tidy	2.65%	2.65%

Python 代码优化（150 个任务）

方法	精确匹配	语义等价
直接提示	4.00%	9.33%
RAG	16.00%	28.67%
RAPGen	4.00%	10.00%
SemOpt	**25.33%**	**46.00%**

实验结果

- 相比 RAPGen，SemOpt 实现 **14 至 21 倍**的相对提升
- 相比直接提示，精确匹配提升 **4 至 21 倍**，语义等价提升 **3 至 7 倍**
- **89.86%** 的优化建议经验证可保持语义且产生性能收益

2.8 实验验证：跨代码库泛化能力

评测设计

评估方法在面对**从未见过的代码库中的优化任务**时的性能表现

- **标准模式**：排除与目标代码完全相同的提交
- **降级模式**：排除同一代码库的所有历史知识

方法	模式	DeepSeek 语义等价	变化
RAG	标准	36 (23.84%)	
RAG	降级	10 (6.62%)	**下降 72%**
SemOpt	标准	64 (42.38%)	
SemOpt	降级	63 (41.72%)	**仅下降 1.7%**

核心洞察

通过抽取结构化策略并转化为规则化检测，SemOpt 实现了从特定项目知识到通用优化模式的有效迁移。

2.9 真实场景验证

C/C++ 项目优化结果

项目	最大提升	平均提升	≥5% 用例数	状态
RocksDB	5.04%	2.41%	1/2	PR 审查中
Redis	6.14%	1.68%	3/21	✓ 已接受
gRPC	35.48%	3.10%	2/16	PR 审查中
LevelDB	218.07%	10.40%	2/22	社区认可
spdlog	20.00%	3.27%	6/45	✓ 已接受

Python 项目优化结果

项目	最大提升	平均提升	≥10% 用例数
click	479.90%	143.25%	11/11
flask	66.07%	56.67%	8/8
jinja2	71.43%	48.60%	7/8
requests	85.45%	40.19%	8/9
scrapy	61.77%	50.26%	4/4

所产生的部分优化效果用 Cursor+GPT5.4 High 长时间多轮尝试也无法达到

4 符号策略挖掘统一框架 [进行中工作]

符号策略挖掘问题

- 给定训练集，如何从训练集中得到高效的符号策略集合，并集成到系统中完成任务？
  - LLM2LTAC：从训练集中挖掘证明策略，生成 Ltac 规则，提升 CoqHammer 的证明能力
  - SemOpt：从训练集中挖掘代码优化机会匹配策略，生成 Semgrep 规则，指导大模型进行优化

符号策略挖掘步骤

训练集

任务实例与人类经验

→

NL 描述

LLM 抽取规则意图

→

筛选

合并相似策略，剔除无效策略

→

符号规则

生成可执行规则

→

系统集成

利用策略完成任务

LLM2Ltac

历史证明 → 证明策略描述 → 筛选 → Ltac 策略 → 和 CoqHammer 集成

SemOpt

历史优化 → 优化策略描述 → 聚类 → Semgrep 规则 → 指导大模型优化

开放问题

规则质量

如何降低 LLM 生成规则的幻觉、过拟合和漏报?

规则选择

在线阶段如何检索、排序和组合大量候选规则?

验证闭环

如何检查生成的策略的质量?

演化机制

能否保证系统随训练集数据增多能力单向增强?

5 总结

总结

- 在大量问题上，符号算法仍然是最终追求的目标
  - 包括约束求解问题
- 在完全替代大模型之前，符号算法的发展也能提升混合系统的效果和降低资源消耗
- 现有符号算法的主要问题是缺乏足够多的人力来覆盖所有场景
- 用大模型挖掘策略是一条可行之路
- 很多开放问题有待解决

欢迎大家一起来研究！