软件筑基智能新时代 | 2026 CCF ChinaSoft 中国软件大会
NASAC 第25届全国软件与应用学术会议 The 25th National Software and Application Conference
FMAC 第11届全国形式化方法与应用会议 The 11th National Conference on Formal Methods and Applications

从数据中挖掘符号规则

大模型驱动的符号智能蒸馏

汇报人：熊英飞（北京大学）

汇报时间：2026年11月7日

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。

软件技术的未来是什么样的?

（去年中国软件大会神经符号融合论坛提出的问题）

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
- 在多数有判定过程的形式化验证问题上，大模型不如传统方法

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?

- 科学研究的一般规律：从特殊到一般，从一般到特殊。
- 从大量数据中分析出合适的自动化策略，并形式化为符号算法

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。
- 核心是设计合适的流程驱动大模型工作

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。

关键挑战和贡献

- 如何找到方法，可以从大量数据中提取符号规则，并能稳定地应用？
  - 大模型无法直接处理大量数据
  - 大模型抽象总结能力仍然不足，难以从多个数据中直接得到稳定符号算法
- 本报告：基于大模型的规则挖掘算法
  - 模型每次只针对一条数据输出符号规则
  - 通过合适的引擎来选择和应用规则
- 目前应用：软工专委首批重大难题（seresearchchallenges.github.io）
  - 自动程序定理证明
  - 大规模代码遗产系统的优化与重构

软件筑基智能新时代 | 2026 CCF ChinaSoft 中国软件大会
NASAC 第25届全国软件与应用学术会议 The 25th National Software and Application Conference
FMAC 第11届全国形式化方法与应用会议 The 11th National Conference on Formal Methods and Applications

从证明数据挖掘符号证明算法

ASE26

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

分析证明过程

LLM 逐步解释证明过程

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

Ltac 生成

将自然语言策略用 Rocq 的 Ltac 语言编写为可执行策略

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

```
### 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**
...
```

```
## 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 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

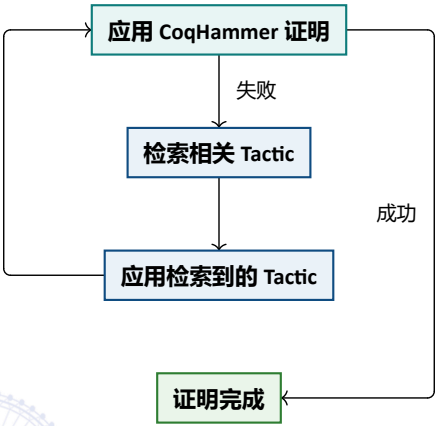

在线阶段：检索

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

软件筑基智能新时代 | 2026 CCF ChinaSoft 中国软件大会
NASAC 第25届全国软件与应用学术会议 The 25th National Software and Application Conference
FMAC 第11届全国形式化方法与应用会议 The 11th National Conference on Formal Methods and Applications

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

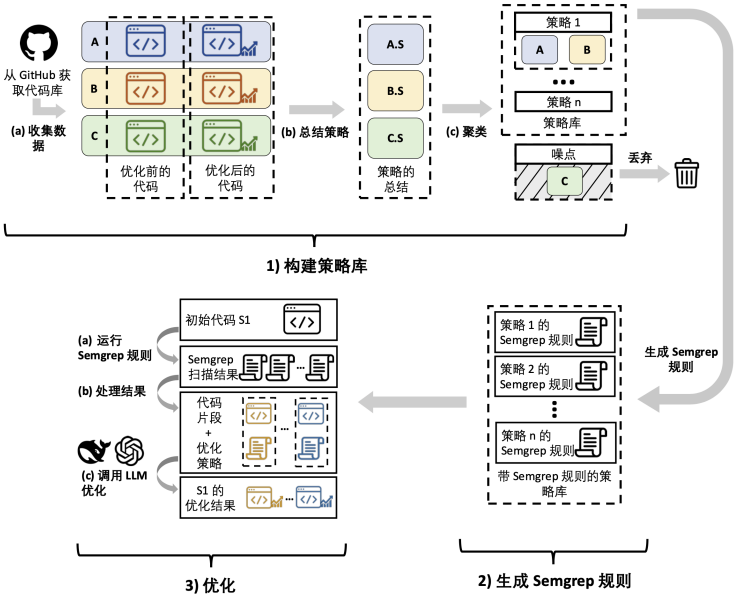
从 GitHub 获取代码库
(a) 收集数据
A
B
C
优化前的代码
优化后的代码
(b) 总结策略
A.S
B.S
C.S
策略的总结
(c) 聚类
策略 1
A
B
策略 n
策略库
噪点
C
丢弃
1) 构建策略库
生成 Semgrep 规则
策略 1 的 Semgrep 规则
策略 2 的 Semgrep 规则
策略 n 的 Semgrep 规则
带 Semgrep 规则的策略库
2) 生成 Semgrep 规则
(a) 运行 Semgrep 规则
(b) 处理结果
(c) 调用 LLM 优化
初始代码 S1
Semgrep 扫描结果
代码片段 + 优化策略
S1 的优化结果
3)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

软件筑基智能新时代 | 2026 CCF ChinaSoft 中国软件大会
NASAC 第25届全国软件与应用学术会议 The 25th National Software and Application Conference
FMAC 第11届全国形式化方法与应用会议 The 11th National Conference on Formal Methods and Applications

规则策略挖掘统一框架

未来展望

规则策略挖掘问题

- 给定训练集，如何从训练集中得到高效的符号规则集合，并集成到系统中完成任务？
  - LLM2LTAC：从训练集中挖掘证明规则，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规则，生成 Semgrep 规则，指导大模型进行优化

规则策略挖掘步骤

数据
收集任务与解决方案，形成训练集

→

生成
LLM 抽取策略，形成符号规则

→

优化
合并相似规则，剔除无效规则

→

检索
根据当前场景，检索合适的规则

→

集成
将规则集成到更大的系统中，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

生成过程

如何降低 LLM 生成规则的幻觉、过拟合和漏报?

规则检索

在线阶段如何检索、排序和组合大量候选规则?

规则质量

如何检查生成的规则的质量?

演化机制

能否保证系统随训练集数据增多能力单向增强?

研究方向的战略选择

- AI 时代学术界应该做什么？
  - 技术变革出现的时候，往往企业会投入大量资源，形成学术界难以直接竞争的产品
    - Unix, MapReduce, VMWare, C/C++
  - 学术界经过多年的研究，通过更深入的理解和持续的技术发展，最终工业界会基于学术界的研究成果继续发展
    - Linux, Hadoop/Spark, Zen, ML/Haskell
- 神经符号融合的大模型智能体
  - 极度拥挤：计算机各个方向的人都转过来做智能体了，工业界也在做。
  - 费用较高：做一轮实验需要多个模型和大量任务，开销以万计。论文被拒了就要再来一次。
  - 不可持续：模型两个月更新一轮，为上一代模型设计的 Harness，在下一代上可能就不适用了。
- 构建符号系统
  - 仍然是可以持续增进理解，持续技术积累的方向
  - 没有那么拥挤、费用也可控
  - 在大模型时代仍然有用

总结

总结

- 在大量问题上，符号算法仍然是最终追求的目标
  - 包括形式化验证问题
- 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！