

Beijing Forest Studio
北京理工大学信息系统及安全对抗实验中心



基于大语言模型的事件根因分析

硕士研究生 刘栋涵

2024年11月24日



- 相关内容
 - 2024.03.31 杨宗源 《LLM的强化学习》
 - 2023.02.12 邵思源 《自动化漏洞挖掘初探》



- 预期收获
- 内涵解析与研究目标
- 研究背景与意义
- 研究历史与现状
- 知识基础
- 算法原理
 - RCA Copilot
 - RCAgent
- 特点总结与未来展望
- 参考文献



- **预期收获**
 - 了解事件根因分析的研究历史与现状
 - 掌握事件根因分析基本概念和内涵
 - 理解事件根因分析的过程及其原理
 - 了解事件根因分析的未来发展方向



- 内涵解析

- 根因分析(RCA): 系统性地收集和分析与**事件**相关的数据, 识别导致系统或服务器事件的**根本原因**

- **日志、指标、追踪信息和警报等**
- **中断或性能下降**


- **事件**: 任何导致**服务中断**或**质量下降**的情况

- **服务无法响应、性能严重下降、用户体验受影响等**

- 研究目标

- 实现数据收集的**自动化**以及输出根因类别

- 提供清晰的**分析过程**, 让分析结果易于**理解**, 并能被相关工程师或管理者直接使用



- 研究背景
 - 服务器系统的**复杂性**和**动态性**
 - 系统容易受到多种故障的影响，传统RCA方法**过程繁琐、容易出错**，且难以应对系统的动态变化
 - 快速而准确的根因分析对于及时**恢复服务并防止问题**复发至关重要
 - 现有基于大规模语言模型的RCA方法普遍存在**隐私风险**
 - 调用外部LLM接口需要将系统数据上传到外部服务器，这增加了**数据泄露**的可能性
 - 云计算环境的复杂性和动态性使得数据分布变化频繁，这进一步加剧了**敏感信息暴露**的风险



- 研究意义

- **精准识别**问题的根本原因，使得模型作出解释性输出，帮助工程师迅速采取有效措施恢复系统的正常运行，从而**减少服务中断时间**
- 现代云服务系统**复杂性高**、**数据多样**且动态变化，传统手动方法难以满足需求，根因分析的研究为解决**多源数据整合**、**海量信息筛选**以及**动态事件适应**提供了理论和技术支持
- 对复杂系统中的问题进行**深层次剖析**，找到系统中薄弱环节，从而增强系统的**稳定性和鲁棒性**



研究历史与现状



Lou等人提出了“基于机器学习的根因分析”方法。这标志着根因分析从**传统规则方法**向**智能化方向**发展的重要一步

Aguilera等人提出了基于“时间相关性”的根因分析方法，利用**分布式跟踪系统**收集的时间戳信息，通过事件的**因果关系**来定位故障来源

Foxreb团队提出了利用大模型的方法，通过观察系统输入和输出的变化应用**GPT**进行根因分析

张伟教授团队结合日志文本、系统指标和网络流量等多种数据源，开发**多模态深度学习模型**，实现对复杂系统的全面监控和异常检测

Chandy等人提出了**CausalRCA**方法。该方法通过**因果结构学习**，并结合**根因推断技术**，能够精确定位故障和相关指标




2015
Dapper提出以“**追踪请求路径**”为核心的根因分析方法。这种方法通过对**跨节点调用**的全面追踪和统计分析，能够**快速定位**服务器中故障的根因

2020
Zhang进一步发展了“因果推理”技术，用于分布式服务器中的根因分析，他们结合基于图模型的**因果推理方法**和**现代深度学习技术**，实现了复杂场景下的高效**根因定位**

2023
Liang等人提出了PSqueeze方法，该方法引入了广义涟漪效应（GRE）的概念，通过**概率聚类**和**启发式搜索技术**实现了高效的故障定位

2024
Zhang等人提出了**CloudRCA**框架，该框架结合了多个数据源，并使用**分层贝叶斯网络模型**进行根因定位，能够实现高效准确的故障分析





定义

- 大规模自然语言处理模型，具有强大的语言理解、生成和推理能力，特点是参数**规模大**、**训练数据广泛**、**架构复杂**，能够在各种语言任务上表现出卓越的性能


工作原理

- 预训练：在大量**非结构化文本**数据上进行无监督学习
- 微调：使预训练模型适应下游应用

分类

- **自回归模型**（GPT）
- **自编码模型**（BERT）

OpenAI GPT





KEY POINT

- 定义
 - 结合推理(Reasoning)和行动(Acting)的人工智能方法
- 核心理念
 - 模型生成一个思考过程描述对问题当前状态的理解
 - 模型基于思考，生成一个行动指令，例如查询外部信息、调用API或访问外部网址
 - 获取行动结果后，模型生成新的思考过程，再进行下一步
- 优点
 - 使得模型在执行动作时可以考虑到之前的推理结果





- 定义
 - 通过生成一系列**中间推理步骤**，引导模型逐步解决复杂任务的技术
- 核心思想
 - 分步推理
 - 将问题分解为多个**子问题**
 - 每一步基于前一步的结果进行推导
 - 显式过程
 - 输出中包含**中间推理步骤**，而不是黑盒式预测
- 优点
 - 更清晰地捕捉输入数据中的逻辑关系
 - 避免复杂任务中的**错误累积**或**遗漏关键信息**
 - 提供更高的可解释性，通过显式展示中间推理路径






• 定义

- 一种基于大语言模型的，具有**规划思考能力**、**记忆能力**、**使用工具能力**，能自主完成给定任务的实体

• 关键部分

- 规划：智能体将**大型任务**分解为**子任务**，并规划执行任务的流程
- 记忆：分为**长期记忆**和**短期记忆**
- 工具使用：网页搜索工具、代码执行器





Automatic Root Cause Analysis via Large Language Models for Cloud Incidents



TIPO

T	目标	实现数据的自动化收集，提高效率和准确率
I	输入	与事件相关的多源数据，653个真实事件
P	处理	<ol style="list-style-type: none"> 1. 根据警报类型，自动化收集多源数据，完成特定数据的提取和整合 2. 利用嵌入模型将事件信息转换为向量，选择最相关事件作为示例输入 3. 通过思维链和诊断信息，以及历史事件进行相似匹配
O	输出	输出事件的 根因类别 并作出 解释性说明

P	问题	<ol style="list-style-type: none"> 1. 单一数据源不足支持高效诊断 2. 新类型事件是诊断过程中的最大挑战
C	条件	需要ChatGPT（版本：GPT-4）
D	难点	<ol style="list-style-type: none"> 1. 多源数据可能存在噪声、缺失或不一致，增加了数据预处理的复杂性。 2. 对于没有历史参考的事件，模型的预测准确性和适应能力存在挑战
L	水平	2024 SCI 1区

现存难题

- 现有方法存在问题
 - 工程师需要**手动**筛选和分析海量数据，**效率低下**和容易**出现错误**，更难以快速的定位复杂系统的根因
 - 静态的故障排查指南(TSGs)难以覆盖动态的系统，对于**未见过的**事件类型，工程师缺乏参考案例，诊断效果低下
 - 云服务系统产生的日志、追踪信息和性能指标等多源数据**体量庞大**，且**格式不一致**，**单一数据源**难以全面反映问题。



• 解决方法

– 多源数据整合

- 针对**不同报警类型**自动化收集日志、追踪信息和性能指标
- 使用动态决策树操作，保证数据收集的全面性和高效性

– 思维链

- 将任务**分解成明确的中间步骤**，并在提示中逐步列出这些步骤
- **要求模型一步步给出答案**，例如，在异常检测任务中，可以引导模型先判断变量是否符合特定条件，再决定日志是否异常



• 算法原理


首屏消插

– 诊断信息收集阶段

- 输入：事件，包括**基础信息**，例如**报警类型**和**事件类型**
- 输出：一个包含多源数据的**诊断信息文件**，包括日志片段、追踪路径等

– 根因预测阶段

- 输入：系统收集到的诊断信息文件
- 输出：当前事件的**根本原因**和**详细解释**



• 根因分析评价指标

– Micro-F1

- 定义：计算每个样本的正确预测数量与总预测数量的比值
- 计算公式：
$$Micro - F1 = \frac{2 \times Micro - Precision \times Micro - Recall}{Micro - Precision + Micro - Recall}$$
- 特点：衡量系统的总体性能

– Macro-F1

- 定义：对每个类别分别计算F1分数，然后求平均
- 计算公式：
$$Macro - F1 = \frac{1}{N} \sum_{i=1}^N F1_i$$
- 特点：反映模型在各类别上的均衡性





实验设置

- 模型设置
 - 实验使用**ChatGPT4**的API（8K token版本）作为主要推理模型
- 对比方法
 - 基线模型：XGBoost, FastText, Fine-tune GPT
 - 变体模型：GPT-4 Prompt, GPT-4 Embed
- 评价指标
 - Micro-F1和Macro-F1, 模型的**性能指标**
 - 训练时间和推理时间, 模型的**效率指标**
- 数据集
 - 653个真实事件, 由经验丰富的工程师标注根因类别



– 根因分析

• 性能对比

– RCACopilot (GPT-4)

在 **Micro-F1** 和 **Macro-F1** 上均表现最佳，远远高于其他基线模型和变体模型

• 效率对比

– RCACopilot (GPT-4)

的效率表现良好，**远远高于基线模型**，和变体模型相差无几，可以满足生产环境的实时需求

Method	F1-score		Avg. Time (s)	
	Micro	Macro	Train.	Infer.
FastText [61]	0.076	0.004	10.592	0.524
XGBoost [3]	0.022	0.009	11.581	1.211
Fine-tune GPT [1]	0.103	0.144	3192	4.262
GPT-4 Prompt	0.026	0.004	–	3.251
GPT-4 Embed.	0.257	0.122	1925	3.522
RCACopilot (GPT-3.5)	0.761	0.505	10.562	4.221
RCACopilot (GPT-4)	0.766	0.533	10.562	4.205



- 算法贡献

- 多源数据整合

- 解决了传统方法中**单一数据源**难以提供全面信息的问题，提高了诊断信息的覆盖率

- 自动化与实时性

- 提供**端到端**的自动化流程，从诊断信息收集到根因预测实现**全链路自动化**

- 算法不足

- 尽管使用思维链可以增强对新事件的处理能力，但

- 对**完全无先例**的事件，模型仍然**缺乏足够**参考信息

- RCA Copilot的推理时间优化到4.2秒，但GPT-4的**高**

- 开销**仍可能成功大规模部署中的瓶颈，尤其是在**事**

- 件频发**的环境下





RCAgent: Cloud Root Cause Analysis by Autonomous Agents with Tool-Augmented Large Language Models



TIPO

T	目标	在数据庞大时候，保证根因分析的准确率和可解性
I	输入	阿里云平台的5000个异常事件，选取其中的161个
P	处理	<ol style="list-style-type: none"> 1.使用快照键机制，将输入压缩为可处理得短片段，同时保存完整信息 2.在思维-行动的同时，使用JSON修改机制解决工具调用因格式导致的错误 3.利用轨迹自治性聚合，选择语义一致性最高的结果
O	输出	事件发生的主要原因以及针对异常问题的修复建议

P	问题	<ol style="list-style-type: none"> 1.现有方法通常涉及多种类型的大量数据，无法有效的整合利用 2.模型在工具调用的时候，可能会出现配置错误、格式错误等问题
C	条件	强大的计算资源和存储数据的数据库
D	难点	<ol style="list-style-type: none"> 1.如何对长文本进行处理，使得不超过LLM的输入限制，而且不遗漏信息 2.如何保证在复杂的情况下，保证调用的工具不会失效
L	水平	2024 ICSE

- 现有方法存在问题

- 上下文长度问题

- 根因分析任务通常涉及多种类型的**大量数据**，包括日志、代码片段、数据库查询结果等，这些数据往往非常冗长

- 行动无效性

- 模型在推理过程中调用工具或采取的操作，可能因为工具调用的输入错误、**格式问题**或**参数无效**，从而使得模型可能进行**无关**或**重复**的行动，浪费资源，并影响任务效率





- 解决方法

- 观测快照键 (OBSK)

- 目标

- 减少上下文占用:将长观测结果压缩为短摘要,降低输入长度
 - 保留信息完整性:通过键值存储关联完整观测内容

- 基本构成

- 摘要: 提取观察内容的**关键信息**, 作为LLM的**直接输入**, 例如错误类型, 时间戳等
 - 快照键: 为观测内容生成**完整唯一的标识** (如哈希值),快照键与完整数据存储在键值系统中, 可以随时检索, 如果模型需要更详细的信息, 可以根据快照键从键值存储总检索完整内容




- 解决方法

- JSON修复机制 (JsonRegen)

- 格式检测: 在每次工具调用前, 检测生成的JSON数据是否符合标注
 - 自动修复: 若发现错误, 系统会通过清理非法字符或重新生成JSON数据进行修复

- 轨迹级自一致性 (TSC)

- 轨迹多样性: 在任务终止阶段, 采用**多条完整**的行动轨迹
 - 轨迹语义投票: 使用语义嵌入计算各轨迹之间的一致性, 并选择最优的轨迹





• 解决方法

– 分析工具

• 代码分析工具


– 输入：输入数据中的**代码部分**

– 输出：通过LLM对复杂的代码文件内容进行**自动化提取和汇总**，减少人工干预

• 日志分析工具

– 输入：输入数据中的**日志部分**


– 输出：使用LLM对每个分块进行详细分析，生成**日志分析**和异常诊断结果





算法原理图

- **控制器代理**: 通过思维将任务进行拆分, 然后确定下一步行动
- **专家代理**: 负责处理复杂的任务, 利用针对性大语言模型生成高级的解决方案
- **环境交互**: 从日志系统、数据库和代码仓库中获取信息
- **错误处理**: 检测并修复执行过程中的错误, 若无法处理, 就调用专家代理





数据资源

- 数据集
 - 包含 5000个异常任务，经过筛选和标注，最终生成 161 个多样性样本，覆盖多种异常类型
- 对比模型
 - 非基于智能体的模型: XGBoost, Finetune T5, LLM Summary
 - 基于智能体的模型: ReAct
- 评价指标
 - **METEOR、BLEURT、BASTScore**: 衡量文本生成的质量
 - **H-Helpfulness**: 通过人工评估，衡量生成结果对实际任务的帮助度
 - **G-Correctness**: 由 LLM 判断根因预测的语义正确性



评价指标

- 评价指标

- METEOR

- 定义：它通过匹配单词和短语来评估生成文本与参考文本的相似性，考虑了词形变化和语义信息
 - 公式： $METEOR = F(1 - Penalty)$

- NUBIA

- 定义：用于评估生成文本和参考文本之间的语义一致性和信息完整性
 - 公式： $NUBIA = \frac{E_{candidate} \times E_{reference}}{\|E_{candidate}\| \times \|E_{reference}\|}$

- BLEURT

- 定义：基于BERT的生成文本质量评估指标，通过训练一个模型来预测生成文本和参考文本之间的评分



实验结论

- RCAgent在云环境中处理事件异常时，相较于其他模型具有**显著优势**，尤其是在**根因预测**、**责任归属**、**人工帮助度**等方面，RCAgent均表现出色
- **TSC**的引入进一步优化了RCAgent的性能，使其在复杂任务中的表现更为出色

Model	Root Cause					Responsibility	Human
	METEOR	NUBIA	BLEURT	BARTScore	G-Correctness	Precision	H-Helpfulness
XGBoost	-	-	-	-	-	77.65	-
Finetune T5	4.18	8.20	19.32	-6.61	2.62	77.85	-
LLM Summary	7.88	14.57	25.40	-6.00	3.58	77.21	-
ReAct	5.21	10.38	20.33	-6.25	2.24	73.53	1.36 \pm 0.03
RCAgent	13.77	19.48	31.52	-5.59	3.82	80.74	2.47 \pm 0.17
w/ TSC (LLM)	15.72\pm0.61	26.79\pm2.54	35.72\pm0.58	-5.29\pm0.03	4.36\pm0.01	82.06\pm0.42	2.92\pm0.21



- 评估RCAgent各功能的有效性

- w/o LLM Experts: 移除**专家代理**后, 性能大幅下降, 表明专家代理在复杂任务分析中的重要性
- w/o OBSK: 去掉**快照键机制**后, 长上下文的处理能力下降, 导致 BLEURT 降低至 29.67
- w/o Json: 移除 JSON 修复功能后, 任务稳定性受影响, G-Correctness 从 5.22 降至 4.19

模型设置	Root Cause (根因分析)	Responsibility (责任归属)	Human (人工评估)
	METEOR	NUBIA	BLEURT
完整 RCAgent	15.15	19.48	31.57
w/o LLM Experts	9.60	14.20	27.77
w/o OBSK	12.37	16.55	29.67
w/o JsonRegen	13.89	17.72	27.72

• 算法贡献

- 提出了**首个**基于 LLM 的工具增强型智能体框架，用于解决云系统中的根因分析任务
- 引入了一系列**增强方法**，包括自洽性聚合、稳定性增强和快照键机制
- 在本地部署，对**隐私和信息安全**起到保护作用

• 算法不足

- 轨迹级自一致性（TSC）虽然有效，但增加**计算开销**，特别是在复杂任务中，生成多个路径可能导致资源浪费
- 现有工具可能难以处理**新的数据类型**或不同的云环境





特点总结与未来展望

- 特点总结

- RCA Copilot

- 在针对**不同事件类型**，利用事件处理器，从多种数据源中收集相关诊断数据，弥补单一数据源信息不足
 - 实现了云事件管理的**端到端**自动化，从数据收集到根因预测均由系统自主完成
 - 对于**未见过**的新型事件，系统能够自动生成新的根因类别，并提供相应解释，帮助OCES理解根因

- RCA Agent

- 本地部署，避免依赖外部API，保障**云平台数据的隐私和安全**
 - 通过OBSK**压缩上下文长度**，提高效率
 - 使用**JSON修复机制**，提高模型在复杂任务的稳定性





- [1] Sun Y, Huang Y, Yu Y, et al. DivLog: Log Parsing with Prompt Enhanced In-Context Learning[C]. Proceedings of the 46th International Conference on Software Engineering (ICSE 2024). ACM, 2024: 1-12
- [2] Liu, Y., Tao, S., Meng, W., Wang, J., Ma, W., Zhao, Y., Chen, Y., Yang, H., Jiang, Y., & Chen, X. (2023). LogPrompt: Prompt Engineering Towards Zero-Shot and Interpretable Log Analysis :2308.07610.
- [3] Meng W, Zhao Y, Chen Y, et al. Automatic Root Cause Analysis via Large Language Models for Cloud Incidents[J]. IEEE Transactions on Cloud Computing, 2023, 11(4): 1123-1135.
- [4] Ma, L., Yang, W., Xu, B., Jiang, S., Fei, B., Liang, J., Zhou, M., & Xiao, Y. (2024). KnowLog: Knowledge Enhanced Pre-trained Language Model for Log Understanding. Proceedings of the 46th International Conference on Software Engineering (ICSE 2024), 1-12.

知人者智，自知者明。胜人者有力，自胜者强。知足者富。强行者有志。不失其所者久。死而不亡者，寿。

谢谢!

