



# 提示符可以用于探测预训练语言模型吗? 从因果角度理解其潜在的风险

曹博希, 林鸿宇, 韩先培, 刘方超, 孙乐

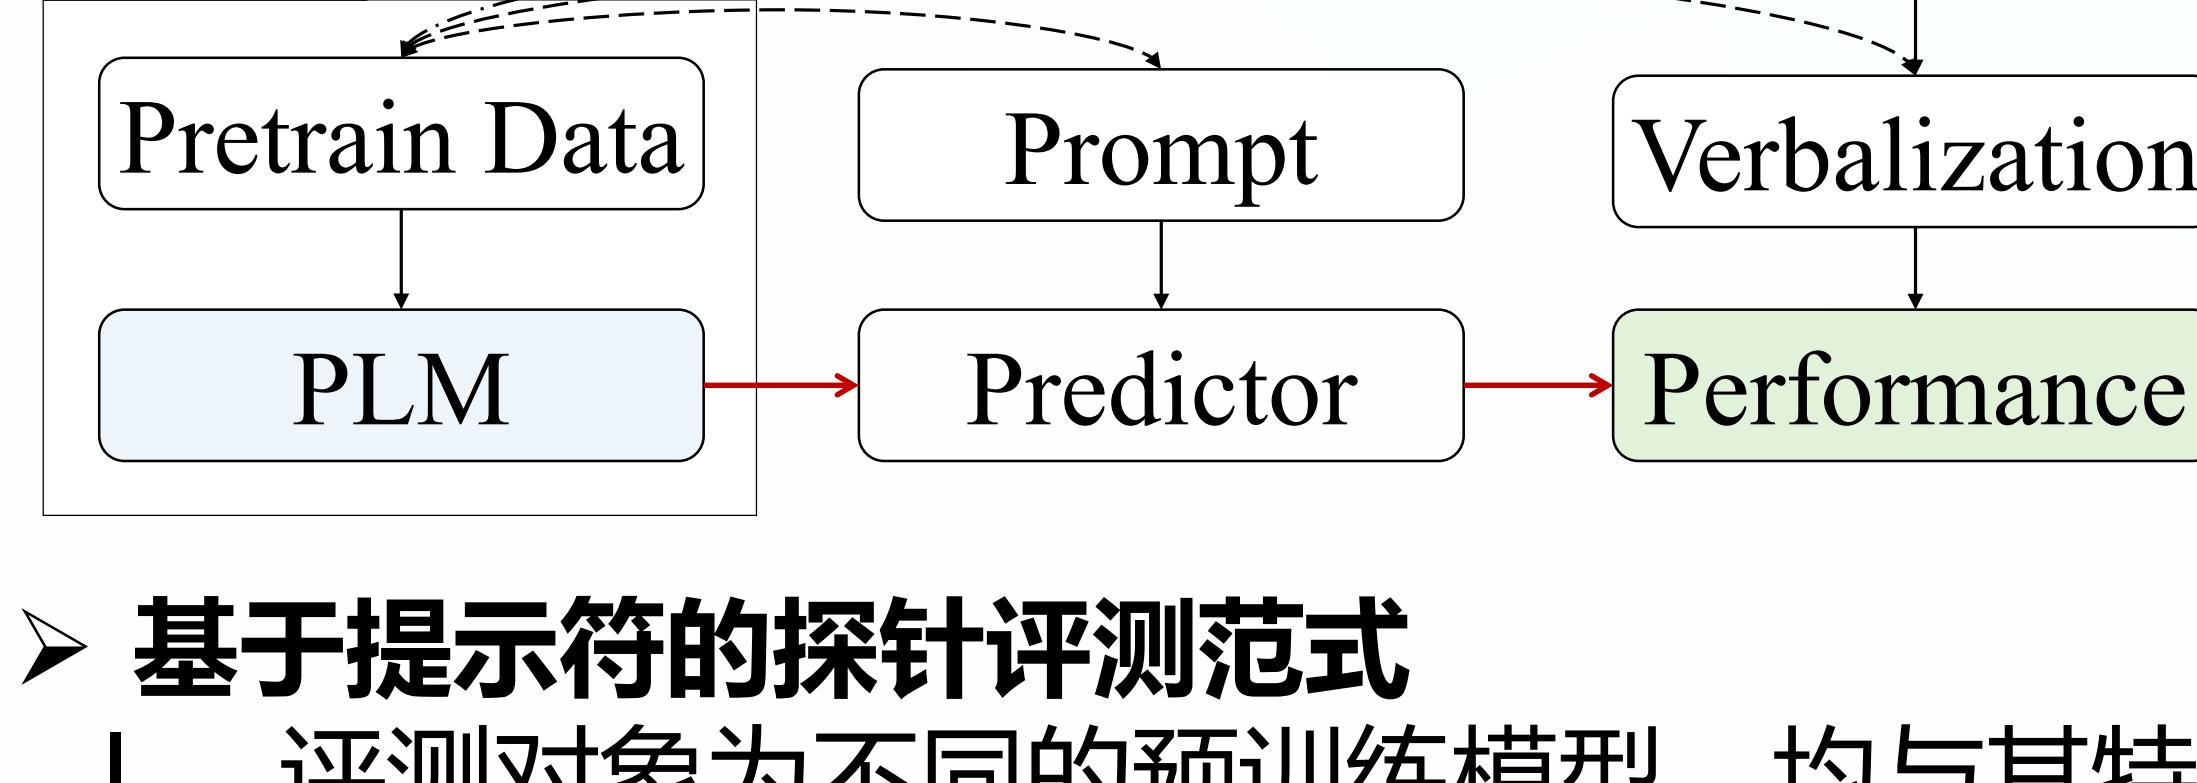
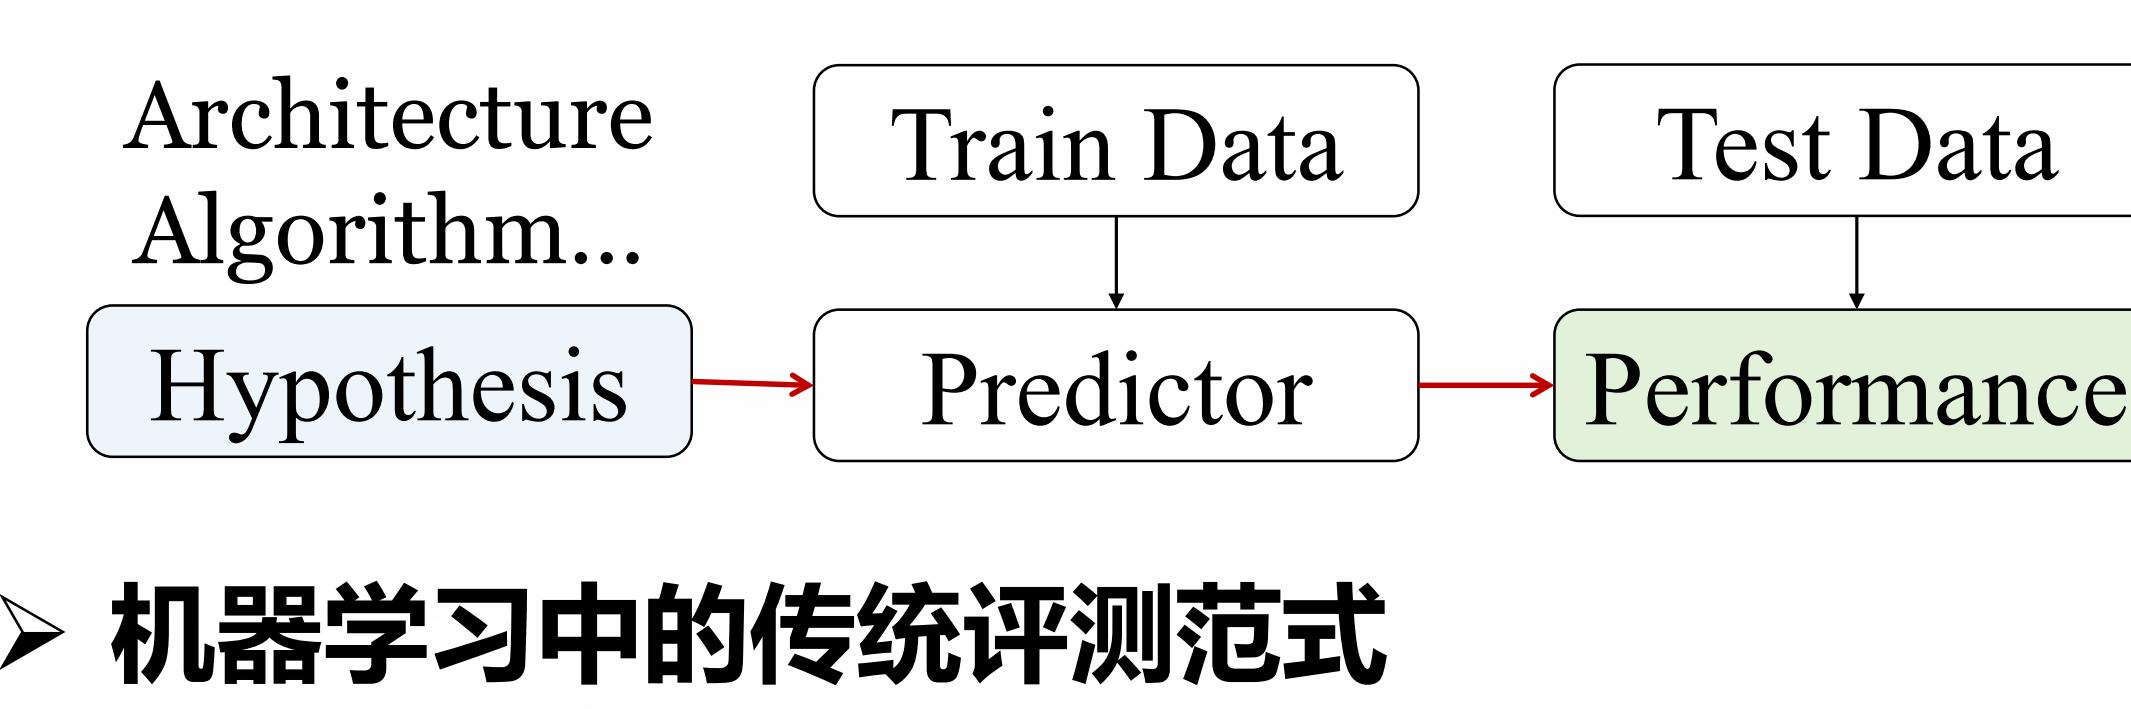
中国科学院软件研究所

Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics  
(Volume 1: Long Papers), pages 5796–5808, Dublin, Ireland.

联系人: 曹博希 邮箱: boxi2020@iscas.ac.cn 电话: 13051882626

## 介绍

- 基于提示符的探针已经被广泛用于评估预训练模型中的知识和能力。
- 现有工作对评测过程中所存在的风险的忽视会误导对模型的理解,甚至产生错误的结论。



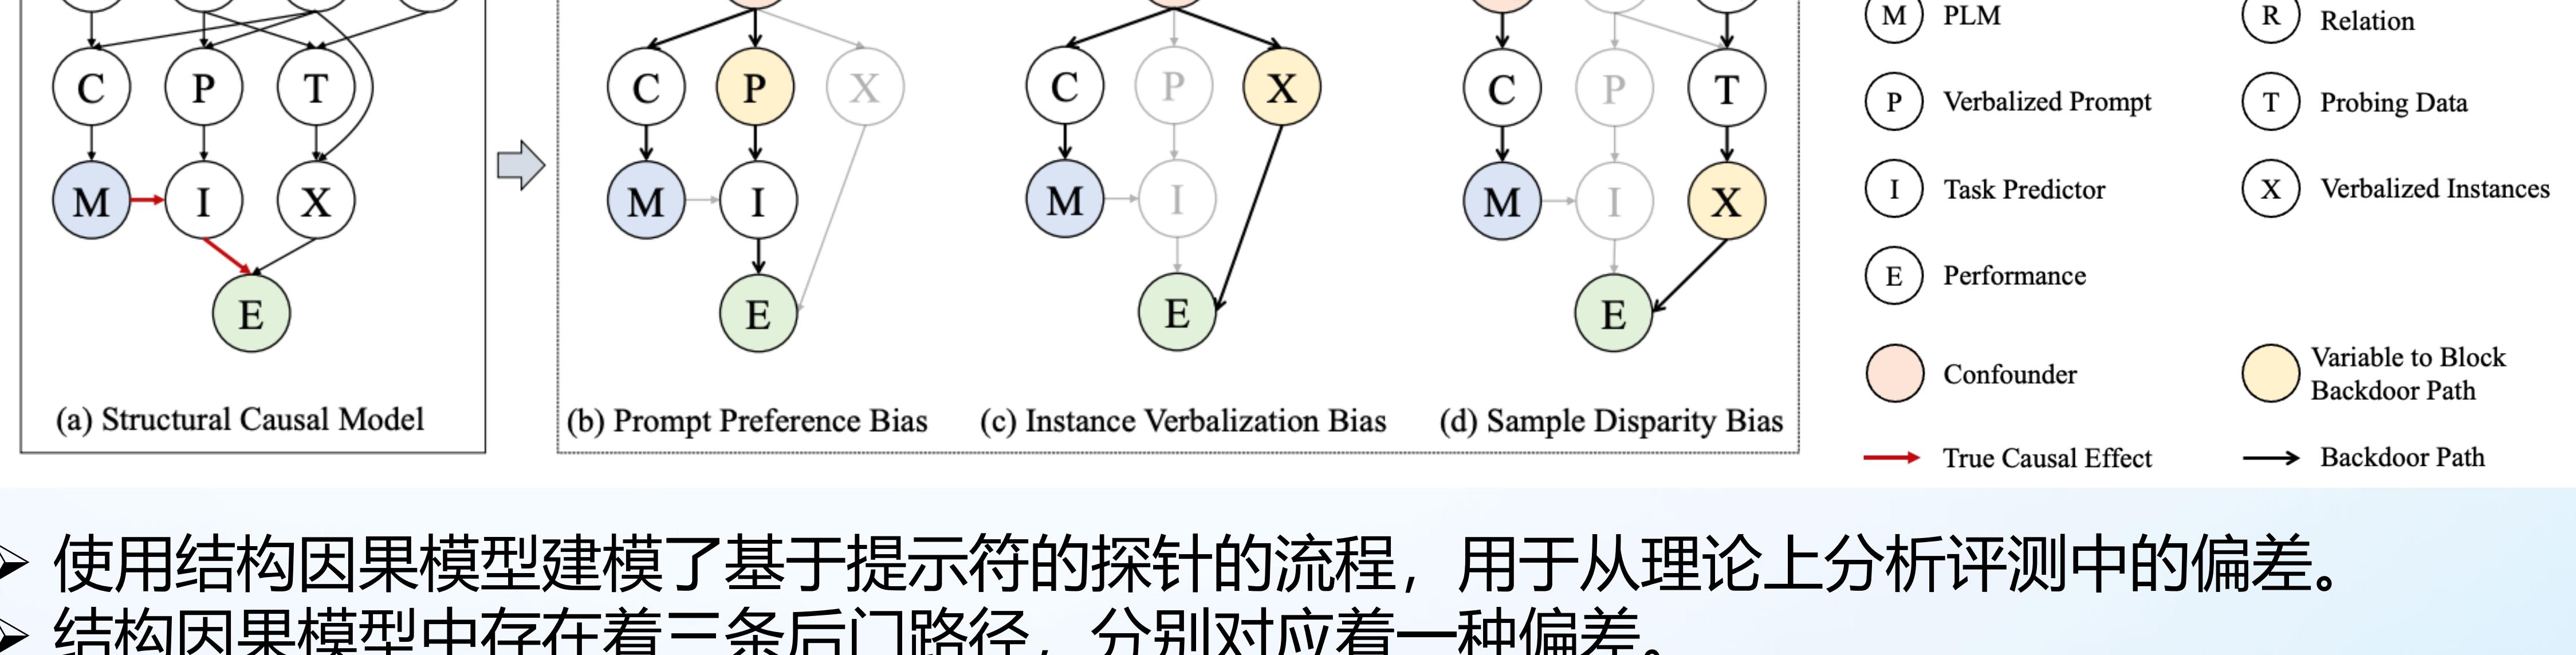
### 机器学习中的传统评测范式

- 评测对象为不同的假设(算法/模型架构),独立于训练测试数据的生成。
- 数据间关联的影响是透明的、可控的,并且对所有假设均平等。

### 基于提示符的探针评测范式

- 评测对象为不同的预训练模型,均与其特定的预训练数据绑定。
- 预训练数据、提示符、探针数据间存在的伪相关会给评测结果带来偏差。

## 结构因果模型



- 使用结构因果模型建模了基于提示符的探针的流程,用于从理论上分析评测中的偏差。
- 结构因果模型中存在着三条后门路径,分别对应着一种偏差。

## 提示符偏好偏差

- 模型性能会同时受到模型能力和其对特定提示符偏好的影响。



## 提示符偏好偏差

- 不同的预训练模型可能会偏好同一个概念的不同自然语言化表达。

Relation	Mention	Prediction
Capital of	America	Chicago
	the U.S.	Washington
Birthplace	China	Beijing
	Cathay	Bangkok
Einstein	Albert Einstein	Berlin
	Isaac Newton	Vienna
Sir Isaac Newton	Sir Isaac Newton	London
	town	town



## 采样差异偏差

- 不同模型性能差异可能来源于其预训练语料的采样差异,而非仅仅模型能力的差别。

$\gamma\%$	BERT-base	BERT-large	GPT2-base	GPT2-medium
0%	30.54	33.08	15.22	22.11
20%	35.77	39.56	22.02	28.21
40%	38.68	39.75	24.32	30.29
60%	38.72	40.68	25.42	31.16
80%	39.79	41.48	25.65	31.88
100%	40.15	42.51	26.82	33.12
None	37.13	39.08	16.88	22.60

- 因果干预能够显著提升评测结果的稳定性。

- 通过后门准则来减小评测偏差。

$$\mathcal{P}(E|do(M=m), R=r) = \sum_{p \in P} \sum_{x \in X} \mathcal{P}(p, x) \mathcal{P}(E|m, r, p, x).$$

Model	Original	Random	+Intervention
BERT-base	56.4	45.4	86.5
BERT-large	100.0	78.1	100.0
RoBERTa-base	75.7	44.0	77.8
RoBERTa-large	56.1	42.2	86.5
GPT2-medium	63.5	40.7	98.2
GPT2-xl	74.2	35.7	77.8
BART-base	63.4	61.6	98.2
BART-large	97.7	61.3	100.0
Overall Rank	25.5	5.5	68.5

## 结论

- 提出了一个因果分析框架,能够从理论层面识别、解释和减小基于提示符的探针中的偏差。
- 基于结构因果模型的分析框架能够原则性地扩展到其他的评测场景中。
- 本文为设计更好的探针框架,可靠的评估范式,以及推动偏差分析从经验化到理论到发展提供宝贵的参考价值。同时提醒研究者们应该重新思考如何更好地评测语言模型。