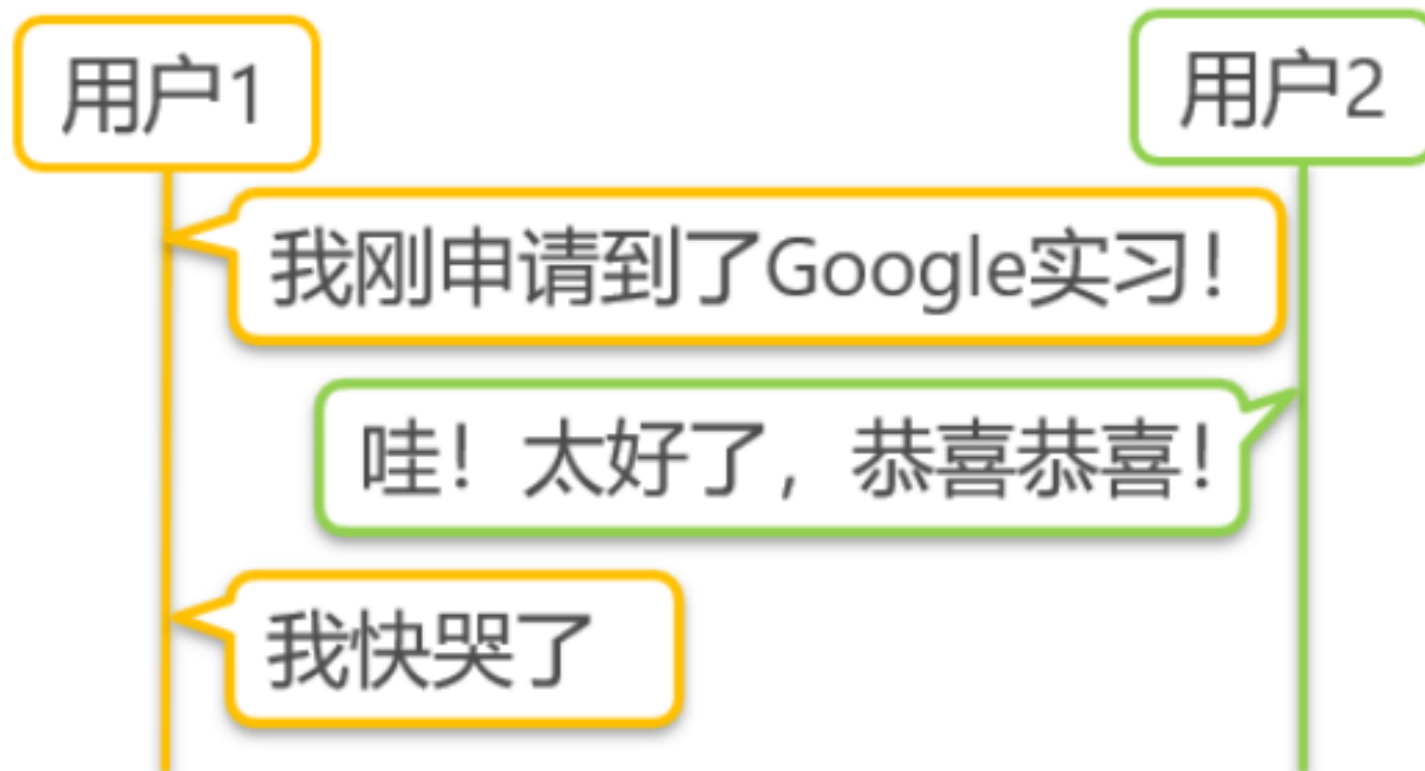


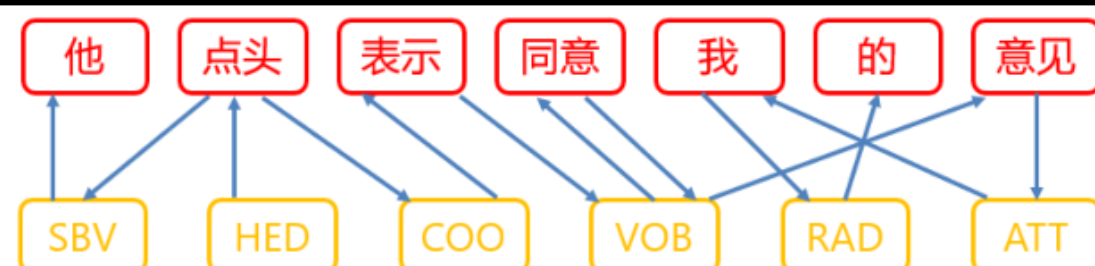
论文摘要

对话情感分析旨在分析识别一段对话中用户在发言终止时的情绪状态。与传统的文本情感分析不同，对话过程中的上下文语境和用户之间的交互会对用户的情绪产生重要影响，且对话文本的语法结构复杂，多存在较远距离的语法成分的依赖关系，因而是一项十分具有挑战性的任务。

为解决上述问题，本文将文本的句法依存关系引入模型中，通过图卷积网络提取句法结构信息，并与文本情感分析模型相结合，提出了两种同时建模语义和句法结构的模型。在构建的中文对话情感分析数据集上的实验表明，与不采用依存关系的基线模型相比，本文所提出的模型取得了更好的实验性能。



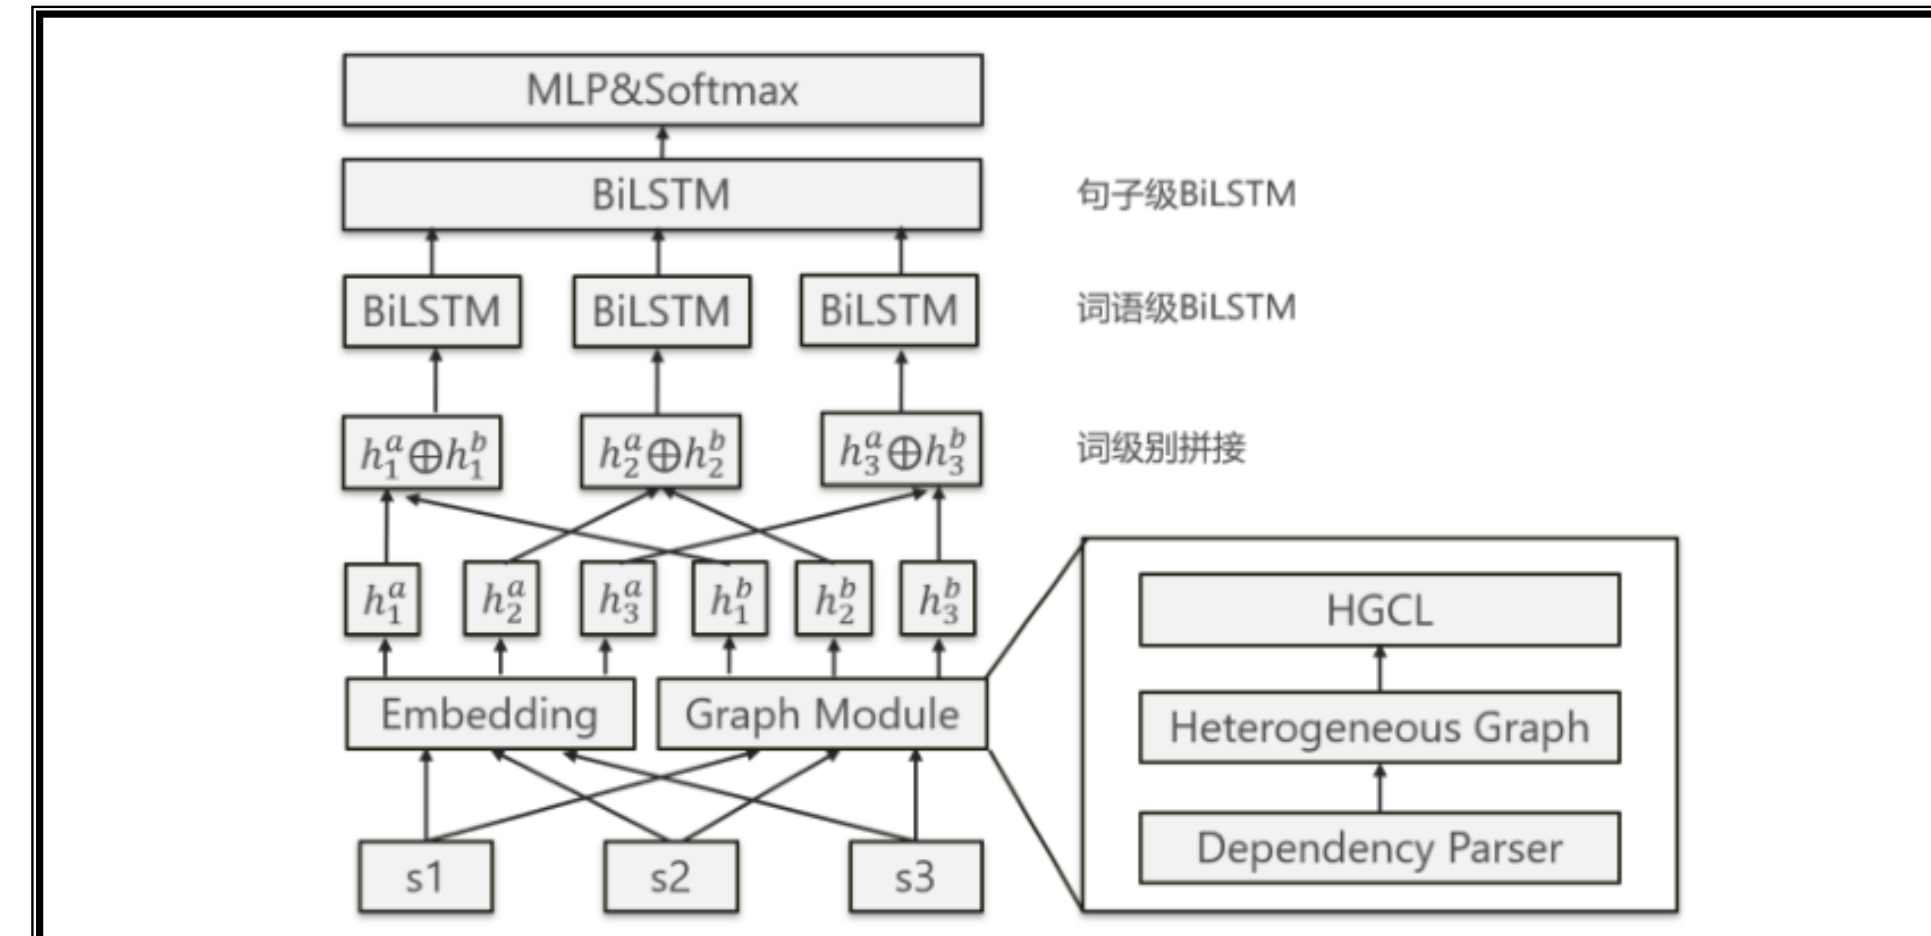
异构二部图实例



论文简介

本文提出了一种基于依存关系的图卷积网络辅助解决对话情感分析任务的方法。该方法将依存关系图转化为异构二部图，然后通过图卷积网络提取文本的句法结构信息，与层次双向 LSTM 或 BERT 的语义信息结合后，都能使模型在对话情感分析任务的性能提升。

算法原理



实验仿真

表 2 中文对话情感分析数据分布

情感标签	训练集	开发集	测试集
Happy	2068	121	244
Sad	445	26	53
Angry	476	28	57
Others	4681	276	551

$$P_{\mu} = \frac{\sum TP_i}{\sum (TP_i + FP_i)} \quad \forall i \in \{Happy, Sad, Angry\}$$

$$R_{\mu} = \frac{\sum TP_i}{\sum (TP_i + FN_i)} \quad \forall i \in \{Happy, Sad, Angry\}$$

$$F1_{\mu} = 2 \cdot \frac{P_{\mu} \cdot R_{\mu}}{P_{\mu} + R_{\mu}}$$

表 3 与基线模型比较

模型	$F1_{\mu}/\%$
GNB	36.1
MLP	52.8
SVM	58.9
RFC	55.4
GBDT	61.5
Text-CNN	66.7
BiLSTM	66.2
H-BiLSTM	69.5
BERT	73.4
H-BiLSTM+HGCL	70.2
BERT+HGCL	74.3

论文结论

- 在机器学习模型中，集成学习算法 RFC 和 GBDT 的整体表现优于其他单模型算法，深度学习的模型超越机器学习的方法
- BERT 优于其他未使用预训练的模型，将依存关系引入 BERT 后，相较于 BERT 提升了 0.9%，H-BiLSTM+HGCL 相较于 H-BiLSTM 提升了 0.7%，表明句法结构有利于对话情感分析任务
- 异构图模型性能大幅领先于同构图模型，表明异构图对不同类型的依存关系的建模是必要且有效的
- 异构图模型性能优于自注意力模型，证明了相比于注意力机制这种隐式的“软连接”，依存关系这种显式的“硬连接”是更加准确有效的