

基于DPCNN和多学习模式损失的富上下文反讽识别

刘畅, 朱焱

引用本文

刘畅, 朱焱. 基于DPCNN和多学习模式损失的富上下文反讽识别[J]. 计算机科学, 2023, 50(11A): 230200067-5.

LIU Chang, ZHU Yan. [Context-rich Sarcasm Recognition Based on DPCNN and Multiple Learning Modes Loss](#) [J]. Computer Science, 2023, 50(11A): 230200067-5.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于话题注意力和依存句法信息的文本立场分析](#)

Text Stance Detection Based on Topic Attention and Syntactic Information

计算机科学, 2023, 50(11A): 230200068-5. <https://doi.org/10.11896/jsjcx.230200068>

[基于图OLAP的学术网络分析](#)

Analysis of Academic Network Based on Graph OLAP

计算机科学, 2023, 50(6A): 220100237-5. <https://doi.org/10.11896/jsjcx.220100237>

[基于多目标粒子群优化的属性网络局部社区检测算法](#)

Local Community Detection Algorithm for Attribute Networks Based on Multi-objective Particle Swarm Optimization

计算机科学, 2023, 50(6A): 220200015-6. <https://doi.org/10.11896/jsjcx.220200015>

[融合多类时空轨迹特征的跨网络用户身份识别](#)

Cross-network User Identification Based on Multiple Spatio-Temporal Trajectory Features

计算机科学, 2023, 50(3): 114-120. <https://doi.org/10.11896/jsjcx.211200287>

[基于异构网络表征学习的作者学术行为预测](#)

Author's Academic Behavior Prediction Based on Heterogeneous Network Representation Learning

计算机科学, 2022, 49(9): 76-82. <https://doi.org/10.11896/jsjcx.210900078>

基于 DPCNN 和多学习模式损失的富上下文反讽识别

刘畅 朱焱

西南交通大学计算机与人工智能学院 成都 611756

(hunter_lc@qq.com)

摘要 反讽作为一种层次丰富且复杂的语言表达方式,广泛存在于人们的日常表达和社交平台中。在电子商务、事件话题分析等方面,准确检测评论文本是否具有反讽意图对判断评论者情感倾向、对评论主体的好恶至关重要。研究针对会话上下文、用户上下文、主题上下文这3类反讽上下文语境,构建上下文语境丰富的反讽检测模型。针对传统浅层 CNN 难以捕获句子远距离依赖的问题,所提模型引入 DPCNN 架构捕获语句远程关联信息,并融合双向注意力机制学习会话上下文中的不协调信息。考虑到现实的数据样本中反讽类型数量少、反讽表达层次不均衡,还提出一种多学习模式的非对称损失函数,来解决样本类别不平衡、难样本优先学习的问题。通过在3个公开反讽数据集上进行验证实验,结果表明所提模型在 ACC、F1 和 AUC 指标上均优于基准模型,最高超出 2.5%。消融实验证明所提模型各个模块以及多学习模式损失函数均能提升反讽检测的性能。

关键词:反讽检测;富上下文;双向注意力;不协调;非对称损失

中图法分类号 TP391

Context-rich Sarcasm Recognition Based on DPCNN and Multiple Learning Modes Loss

LIU Chang and ZHU Yan

School of Computing and Artificial Intelligence, Southwest Jiaotong University, Chengdu 611756, China

Abstract As a richly layered and complex linguistic expression, sarcasm is widely observed in people's daily expressions and social platforms, and correctly detecting whether a comment has ironic intent in e-commerce, event topic analysis, etc., is crucial to determine a commenter's emotional tendency, attitude to the comment subject. Three types of contexts, namely, conversation context, user context and topic context, have been covered to build a context-rich sarcasm detection model. To address the problem that traditional shallow CNNs are difficult to capture sentence long-term dependencies, the proposed model introduces the DPCNN architecture to capture utterance remote association information and incorporates the bidirectional attention mechanism to learn incongruity information in conversation context. Considering the small number of sarcasm types and unbalanced levels of sarcasm expressions in realistic data samples, an asymmetric loss function with multiple learning modes is also proposed. Experiments are conducted on three public and real sarcasm datasets, and the results demonstrate that the method in this paper outperforms the benchmark model in ACC, F1 and AUC metrics by up to 2.5%, and the effectiveness of each module of the proposed model and the loss function of the multiple learning modes is demonstrated by ablation experiments, which can improve the performance of sarcasm detection.

Keywords Sarcasm detection, Context-rich, Bidirectional attention, Incongruity, Asymmetric loss

1 引言

反语 (Irony) 和讽刺 (Sarcasm) 作为高级的情感表述形式,为基于社交平台的情感分析任务带来了新的挑战。从隐式表达中分析用户的真实情感,有助于在情绪分析、意见挖掘等任务中精确识别用户意图,在电子商务、事件话题分析、舆论监管等应用场景中都具有重大意义。例如电商平台分析用户对商品、服务、物流评价中的真实含义可以降低用户投诉率,提升平台的获客率与服务质量。因大量研究不区分反语和讽刺的细微差别^[1],本文的研究使用反讽 (Sarcasm) 来表示反语和讽刺。

反讽采用矛盾的、不协调的语言要素^[2]表达现实与期望之间的差别,相比传统的二元情感分析更具有挑战性。一方面,反讽作为一种复杂的语言现象,在多数情况下需要特定的上下文才能理解反讽表达。会话式上下文信息使得文本句子较长,正确理解语义需要捕获长句内部的远程关联依赖和长句之间的不协调信息。另一方面,现实数据中反讽类型样本数量较少,且反讽表达的层次不均衡,加大了正确理解反讽语义的难度。有较多研究忽略此类问题影响,削弱了模型的实际应用价值。

针对以上问题,本文提出了一种面向社交平台评论的富上下文反讽检测机制。针对富上下文中会话长句内部远程

基金项目:四川省科技计划(2019YFSY0032)

This work was supported by the Sichuan Science and Technology Project(2019YFSY0032).

通信作者:朱焱(yzhu@swjtu.edu.cn)

依赖、会话之间不协调挖掘问题,本文使用 Doc2Vec 和个性 CNN 网络对用户、主题上下文进行建模,结合 DPCNN 架构^[3]抽取会话上下文的特征,使用双向注意力捕获不协调信息;针对真实环境中反讽正负样本数量不均衡、反讽表达难易层次不均衡的问题,提出了多学习模式的非对称损失函数来调节学习样本信息的比重和优先级。本文的主要贡献有以下两点:

(1) 提出了一个富上下文类型输入的反讽检测模型,引入 DPCNN 架构捕获长句远程关联信息,结合双向注意力机制来捕获会话上下文之间的不协调信息;

(2) 提出了一种多学习策略的非对称损失函数,可适应数据正负样本数量不均衡,并模拟简单样本优先(Easy-first)、困难样本优先(Hard-first)这两种样本优先学习策略。

2 相关工作

众多学者在早期研究中主要针对目标语句进行反讽检测。Tay 等^[2]使用句内注意力来提取前后情感矛盾式的反讽特征,并使用 LSTM 网络提取反讽的句级特征。Xiong 等^[4]使用自匹配网络捕获反讽语句中的不协调信息,结合 Bi-LSTM 网络获取句子中单词的时序信息进行反讽检测。Li 等^[5]将反讽检测作为迁移学习的目标任务,将其余相关且具有较大规模数据的任务视为源任务,通过学习并转移源领域知识来改进并优化神经网络模型,提升反讽检测的性能。Wen 等^[6]在词级表示学习使用语素知识增强汉语特征,引入辅助信息获取反讽表达的

背景。以上研究由于仅使用独立语句进行反讽识别,只考虑独立语句中的不协调因素,缺乏对上下文信息的建模,使得算法模型并不适用于社交平台的对话式评论。

考虑上下文信息是近年来反讽检测领域较新的研究点。Khodak 等^[7]构建了一个包含用户、主题和会话上下文的大型 Reddit 语料数据集 SARC。Ghosh 等^[8]发起了一项反讽检测共享任务,旨在探索反讽检测中会话上下文的作用。Hazari-ka 等^[9]从用户的历史发言中提取用户的写作风格和个性风格,结合 Text-CNN 提取的语句特征完成反讽识别。然而浅层 CNN 在处理较长评论语句时无法捕获句子中的远程关联,影响检测效果。Han 等^[10]基于前者的研究简化用户嵌入以获取更佳的时间性能。Zhang 等^[11]认为反讽言论发起者的立场信息有助于检测反讽,他们发布了一个立场级别反讽检测子任务,并提出一种以立场为中心的图注意力网络(Stance-centered Graph Attention Networks)来检测反讽。本文提出的模型覆盖 3 类反讽上下文,引入等长卷积和 1/2 最大池化实现较长句内特征关联,使用双向注意力捕获会话间不协调信息,配合本文提出的多学习模式损失函数,具有更好的检测性能。

3 模型

本文提出的富上下文反讽检测模型由会话上下文建模网络、用户上下文建模网络、主题上下文建模网络和分类输出层这 4 部分组成,模型的整体结构如图 1 所示。

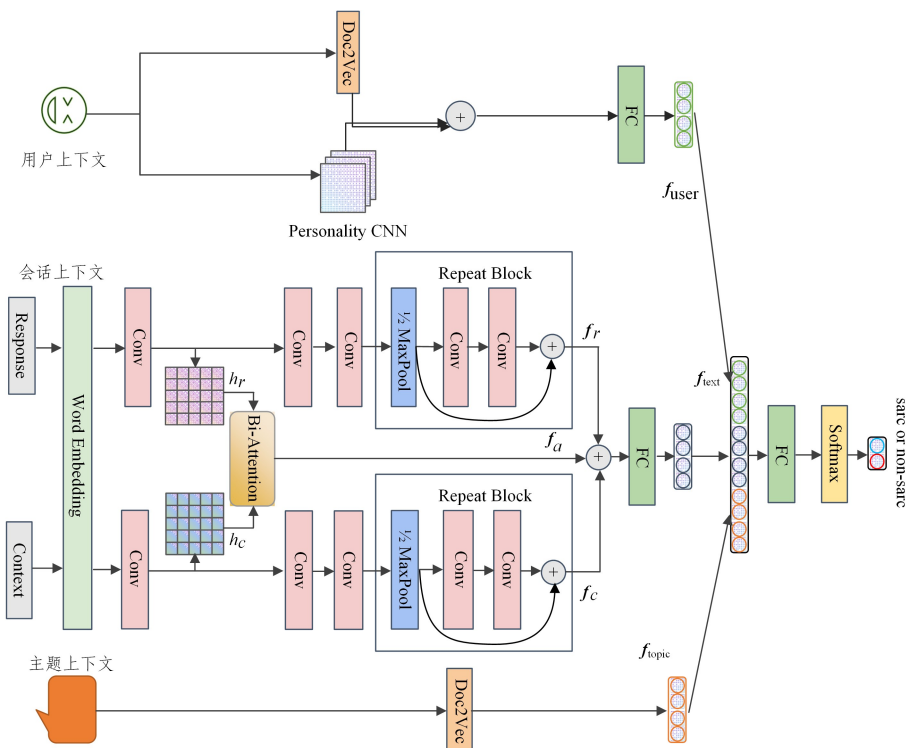


图 1 富上下文反讽检测模型总体框架

Fig. 1 Overall framework of context-rich sarcasm detection model

3.1 任务定义

本研究旨在检测社交平台中包含富上下文信息的目标语句文本的反讽倾向。每个目标文本(Response)关联唯一的用户和主题,有若干直接关联的会话前文(Context)。给定用户集合 $U = \{u_1, u_2, \dots, u_{N_u}\}$ (N_u 为用户总数), 主题集合 $T = \{t_1, t_2, \dots, t_{N_t}\}$ (N_t 为主题总数)。对于用户 u_i 在 t_j 主题下发

布的目标文本 r_{ij} , 其包含若干条会话前文 $con_{ij} = \{con_1, con_2, \dots\}$, 本文的研究目标是判断 r_{ij} 是否具有反讽倾向。

3.2 会话上下文嵌入

3.2.1 会话词嵌入

为解决不同样本的输入序列长度不一致的问题,将会话前文与目标语句的输入序列长度分别截断或补足为 N_c, N_r ,

获得最终输入序列 $X_c \in R^{N_c \times 1}$, $X_r \in R^{N_r \times 1}$ 。本文使用 Fast-Text 训练的 d 维词嵌入空间来建立特征映射,获得会话前文词嵌入 $E_c \in R^{N_c \times d}$ 和目标语句词嵌入 $E_r \in R^{N_r \times d}$ 。

3.2.2 会话特征提取与远距离依赖

在 NLP 任务中,句子内部的远距离依赖(Long-term Dependencies)指句子中相距较远的两个语言单元之间的语义联系。文献[9]使用 Text-CNN 模型对目标反讽语句建模,该类浅层 CNN 模型采用 N_k 个高度为 k 的卷积核 $W_i \in R^{k \times d}$, $i \in \{c, r\}$,卷积过程如式(1)所示:

$$h_i = \text{ReLU}(W_i \cdot E_{i(1:N_i-k+1)} + b_i) \quad (1)$$

其中, $E_{i(1:N_i-k+1)}$ 表示 k 个相邻单词的词嵌入为一组。然而处于卷积窗口以外的单词之间无法进行运算交互,在此基础上采用池化策略会忽略句子远程特征的关联信息。为解决浅层 CNN 模型无法捕获较长语句中的远程依赖问题,本文引入 DPCNN 模型,即在浅层 CNN 的基础上加入等长卷积和 1/2 最大池化(Max Pooling)操作来扩大卷积核感知距离,实现长距离特征关联,更适用于会话式场景。

如图 2 所示,为进一步丰富每一个句子片段(Sentence Snippets)的语义,在浅层 CNN 的卷积基础上增加 padding,使用等长卷积将每个片段周围的词语片段信息纳入自身的表示中。通过两层等长卷积的作用,卷积核能够感知的文本会成倍增加,使用 1/2 最大池化层将输入序列压缩为原来的一半,达到捕获句子中远距离依赖的效果。该过程可用式(2)表示。

$$f_i^j = \text{Pooling}(\text{ReLU}(\text{Conv}(\text{ReLU}(\text{Conv}(h_i)))))) \quad (2)$$




图 2 池化双等长卷积捕获句子远程依赖

Fig. 2 Capture sentence remote dependencies by pooling and double equal-width convolution

将双等长卷积操作简写为 $\text{Conv}_2(\cdot)$,压缩每一个卷积核的特征长度来提取语句最具代表性的特征,引入残差连接来缓解随着网络层数加深而出现的梯度消失问题,该过程如式(3)所示:

$$f_i^{j+1} = \text{Pooling}(\text{Conv}_2(f_i^j) + f_i^j) \quad (3)$$

其中, f_i^j 代表第 j 轮池化双等长卷积结果, $1 \leq j < \log_2(N_i - k + 1)$ 。最终获得会话前文的特征向量 $f_c \in R^{N_c}$ 、目标语句的特征向量 $f_r \in R^{N_r}$ 。

3.2.3 会话不协调匹配

由于反讽与对话上下文息息相关,单向考虑会话前文与目标语句的影响显得不够全面。为了更好地捕获会话前文和目标语句之间的关系,受 AOA 注意力模型[12]启发,本文引入双向的注意力实现句子片段不协调挖掘。

卷积结果 h_c, h_r 作为会话前文和目标语句的语句片段特征,未受等长卷积补足语义的影响,语义纯净,适用于不协调匹配。首先使用式(4)获得两者的交互信息匹配矩阵 I 。

$$I = h_r^T \cdot h_c \quad (4)$$

为获取双向关联,分别对交互矩阵 I 按列、按行进行归一化。列归一化可获得 context-to-response 层次的注意力分数矩阵 $\text{Col} \in R^{(N_r-k+1) \times (N_c-k+1)}$,其代表着对于会话前文的每一个语句片段而言,目标语句的句子片段各自可以从中获得多少重要性。行归一化可获得 response-to-context 层次的注意力分数矩阵 $\text{Row} \in R^{(N_r-k+1) \times (N_c-k+1)}$,其代表着对于目标语句的每一个语句片段而言,会话前文的句子片段各自可以从中获得多少重要性。使用式(5)所示的点乘运算得到融合会话上下文双向的注意力分数 $\text{Att} \in R^{N_r-k+1}$,获得更好的识别目标文本中的矛盾冲突语义表示 $f_a \in R^{N_k}$ 。

$$f_a = h_r \cdot \text{Att}^T \quad (5)$$

3.2.4 会话特征输出

将会话前文特征向量 f_c 、目标语句特征向量 f_r 、双向注意力特征向量 f_a 拼接起来,经过一层全连接网络获得最终会话上下文模块的嵌入结果 f_{text} 。

3.3 用户上下文嵌入

同一用户的历史发言信息被视为用户上下文,从中捕获用户的特征对识别反讽具有重要意义。针对用户集合 U 中的任一用户 u_i ,将其历史发言拼接为一个文档并作为用户 u_i 的训练语料,使用 Doc2Vec 模型构建用户历史文本的特征 $E_U^H \in R^{N_u \times d_U}$, d_U 为每个用户历史文本向量的维数。为提取用户文档中隐藏的用户个性信息,本文使用预训练个性 CNN 捕获用户潜在的个性特征 $E_U^P \in R^{N_u \times d_U}$ 。将用户的历史文本嵌入矩阵和个性嵌入矩阵通过一层全连接网络获得最终的用户嵌入表示结果 $E_U \in R^{N_u \times d_U}$ 。用户集合 U 中的任一用户 u_i 均会指定唯一向量 $f_{\text{user}} \in R^{d_U}$ 作为用户上下文嵌入向量。

3.4 主题上下文嵌入

目标语句所属的主题作为一种背景知识,会揭示目标语句是否具有反讽意味。文献[10]指出,相较于自然灾害主题,在政治、体育类主题下出现反讽评论的概率更大。类似于用户上下文的嵌入方式,本文使用 Doc2Vec 获取主题特征 $E_T \in R^{N_t \times d_T}$, d_T 为每个主题向量的维数。主题集合 T 中的任一主题 t_i 均会指定唯一向量 $f_{\text{topic}} \in R^{d_T}$ 作为主题上下文嵌入向量。

3.5 多学习模式损失函数

真实数据中的反讽存在两类不均衡现象:

(1) 样本数量不均衡。虽然反讽作为一种常用的表达方式,被广泛应用于各种社交平台上,但是实际中反讽样本的数量少于非反讽样本。

(2) 表达层次不均衡。反讽作为一种高级且复杂的情感表述方式,能否被正确理解取决于倾听人的理解能力和说话人在表达反讽时语言组织的难易,造成不同样本具有不同的学习难度。

定义 1(简单样本/易样本, Easy Sample) 预测值与真值标签之间存在较小误差的样本。Lin 等[13]将样本类别正确分类概率 $p \gg 0.5$ 的样本称为简单样本。

定义 2(困难样本/难样本, Hard Sample) 预测值与真值标签之间存在较大误差的样本。

为了解决真实环境中反讽正负样本数量不均衡、难易样本优先学习的问题,提升反讽识别模型在现实世界中的应用价值,受 FocalLoss[13]启发,本文提出了一种多学习模式的非对称损失函数,如式(6)~式(8)所示。该损失函数在没有先验知识或理论线索的情况下,可根据参数设定来切换难易样本优先学习模式,便于寻找当前较优的学习模式。

$$Loss = -\frac{1}{N} \sum_{i=1}^N (y_i L_+ + (1 - y_i) L_-) \quad (6)$$

$$L_+ = (1 - \alpha)(1 - p_i + \beta)^{\gamma^+} \log p_i \quad (7)$$

$$L_- = \alpha(p_i + \beta)^{\gamma^-} \log(1 - p_i) \quad (8)$$

其中, N 为训练集中的样本数, y_i 为第 i 条样本的真实标签, p_i 为模型预测为反讽的概率, α 为样本平衡因子, β 为权重平滑因子, γ^+ , γ^- 用于调节权重函数的单调性, 即正、负样本难易优先的学习模式。

如图 3 所示, 以正样本调节 γ^+ 为例, 权重函数 $w_i = (1 - p_i + \beta)^{\gamma^+}$, $1 - p_i$ 代表将该样本分类正确的难度: 当 $\gamma^+ < 0$ 时, 权重函数单调递减, 简单样本具有更高的权重, 损失函数更倾向于简单样本, 即图 3(a) 的 Easy-first 模式; 当 $\gamma^+ > 0$ 时, 权重函数单调递增, 困难样本具有更高的权重, 损失函数更倾向于困难样本, 即图 3(b) 的 Hard-first 模式。需要说明的是, β 值的作用在于防止在权重函数为单调递减的情况下, 当 $1 - p_i$ 趋于 0 时, 权重趋于无穷大。在实验中 β 值固定为常量, 不影响权重函数的曲线走势。

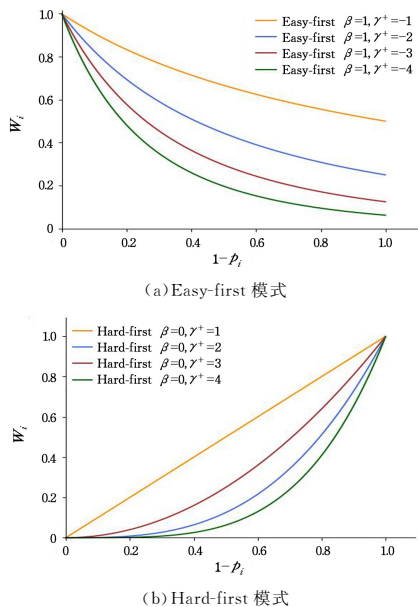


图 3 两种优先学习模式的权重函数示例

Fig. 3 Weight curves example of two learning priority modes

4 实验设计与结果分析

4.1 实验数据与环境设置

(1) 本文使用来自 Reddit 平台的 SARC 2.0 中 Main Balanced, Main Imbalanced, Politics 数据集, 表 1 列出了数据集的样本数量, Sarc, Non-sarc 分别为反讽、非反讽, 数据集进行

了无关符删除、表情转义、缩写词还原、连缀词拆分等数据预处理工作。

表 1 数据集信息
Table 1 Dataset statistics

Dataset	Train set		Test set	
	Sarc	Non-sarc	Sarc	Non-sarc
Main Balanced	128 541	128 541	32 333	32 333
Main Imbalanced	25 784	77 351	10 778	32 333
Politics	6 834	6 834	1 703	1 703

(2) 本文的对比模型如下:

CASCADE^[9]: 首次将主题上下文引入反讽任务中, 使用段落向量提取主题和用户上下文历史发言特征, 并采用 CCA 融合用户特征, 结合浅层 CNN 完成反讽检测。

UT-BIGRU^[10]: 提取主题特征和用户特征, 并采用 Bi-GRU 建模文本。

MHSA^[14]: 采用多层多头注意力机制捕捉目标语句的单词对中的不协调信息, 并使用 Bi-GRU 建模匹配结果。

(3) 实验环境与参数设置如下:

实验代码基于 PyTorch 深度学习框架, 环境基于 Windows 和 RTX 2060。会话前文序列长度 N_c 、目标语句序列长度 N_t 根据数据样本的平均语句长度均设置为 55, 词向量维数 d 为 300, 卷积核高度 k 为 3, 学习率为 1×10^{-4} , batchsize 为 256。训练结合早停机机制 (Early Stopping) 并设置 Hit Patience 为 7, 避免模型过拟合, 节省训练时间。实验采用相关研究普遍使用的 ACC, F1 和 AUC 作为评价指标。

4.2 实验结果与分析

实验结果如表 2 所列。本文提出的方法在 3 个数据集上均有较优的性能表现, 且在非平衡数据样本上也能保持较好的性能, 这表明模型具有较好的泛化能力。CASCADE 使用浅层 CNN 模型, 不能捕获长句子中的远距离依赖, 有效性更多的是来自词嵌入技术解决了传统 One-Hot 编码所带来的向量稀疏性问题。UT-BIGRU 使用 Bi-GRU 时序模型, 在数据量大的平衡数据集上能较充分学习语义信息, 其结果优于 CASCADE。然而 UT-BIGRU 仅针对目标语句建模, 无法捕获会话上下文之间的关联信息, 在非平衡数据样本下性能下降幅度更大。本文提出的模型针对以上方法存在的问题有进一步的优化: 一方面, 采用 DPCNN 架构能够弥补浅层 CNN 的缺点, 充分学习句子整体的语义信息。引入会话上下文环境并使用句子片段作为基本单元来匹配上下文之间的不协调信息, 能充分挖掘上下文语境信息。另一方面, 针对非平衡数据, 使用多学习模式损失使得模型能够适应不同数据样本分布, 检测性能提升较为明显。

表 2 实验结果

Table 2 Experiment results

Algorithm	Main Balanced			Main Imbalanced			Politics		
	ACC	F1	AUC	ACC	F1	AUC	ACC	F1	AUC
CASCADE	78.99	78.81	85.35	81.43	73.90	86.89	75.51	74.97	83.50
UT-BIGRU	79.57	79.51	87.08	81.28	73.59	85.81	74.40	74.16	82.95
MHSA	80.33	80.32	87.98	80.42	74.40	86.28	77.83	77.98	85.92
Our Method	81.63	81.57	89.10	81.65	76.91	88.12	79.77	79.75	86.52

MHSA 仅考虑目标语句的单词对之间的不协调信息, 多层多头自注意力结构不仅需要更多计算资源, 还可能会放大潜在的噪声。该模型后续使用 Bi-GRU 处理注意力加权后的

句子特征不具有可解释性。本文使用句子片段作为不协调匹配的基本单元, 相比单词粒度更加符合一般情况。双向注意力和会话前文的引入使得模型能更充分地学习语境信息,

削弱潜在噪声的影响。

4.3 消融实验

本文设计了在 Main Balanced 数据集上的消融实验,检验本文模型中各部分在检测反讽中发挥的作用大小,结果如表 3 所列。引入双向注意力 Bi-Att 模块后,模型能够学习到会话上下文表达的更泛化的语境信息,而加入用户上下文 U 模块后,检测模式进一步理解用户的表达与个性风格,有助于准确发现目标文本表达是否协调。使用本文提出的完整模型可提取出融合会话、用户和主题上下文的反讽特征,平衡了反讽样本数量、反讽表达层次不均衡,更好地识别目标文本中的矛盾冲突语义,大幅提升了反讽检测性能。

表 3 MainBalanced 数据集上模型消融实验结果

Table 3 Experiment results of model ablation on Main Balanced dataset

Model	ACC	F1	AUC
Response	69.06	69.01	76.08
Response+Context	69.25	69.15	76.11
Response+Context+Bi-Att	69.54	69.41	76.47
Response+Context+Bi-Att+U	81.06	81.05	88.85
Response+Context+Bi-Att+U+T	81.63	81.57	89.10

此外,本文设计了实验研究不同学习模式中损失函数对性能的作用,结果如表 4 所列。标准模式中设置传统 CE 损失函数,即不区别对待正、负样本所造成的损失。Easy-first, Hard-first 已在 3.5 节解释。实验结果表明,在 Main Imbalanced 数据集上,简单样本优先的学习策略取得了最佳效果,而标准模式的检测性能最低,原因是其受反讽数量少的影响,致使整体损失由负样本主导,模型无法较好地学习到正样本所携带的信息。

表 4 Main Imbalanced 数据集上不同学习模式的结果

Table 4 Results of different learning modes on Main Imbalanced dataset

Learning mode	ACC	F1	AUC
CE	81.47	75.32	87.61
Hard-first	81.60	76.70	88.03
Easy-first	81.65	76.91	88.12

结束语 本文面向社交平台评论,提出一种基于上下语境的反讽检测机制。该机制使用 DPCNN 提取会话上下文的句子表征,解决传统浅层 CNN 模型无法捕获长句远程依赖的问题;运用双向注意力挖掘会话上下文中的不协调信息,更好地识别目标文本中的矛盾冲突语义。本文还提出一种多学习模式的非对称损失函数,可适用于反讽数据样本、反讽表达层次不平衡的场景,且在无先验知识或理论线索的情况下可切换优先模式,具有通用性与有效性。实验表明,本文提出的模型具有较优的反讽检测性能。由于在线社交用户常在文本中附加图片以表达反讽情感,跨图文模态的不协调挖掘对于反讽检测任务问题而言至关重要。下一步工作将从多模态角度进行考虑,丰富反讽检测的应用场景。

参 考 文 献

[1] KOLCHINSKI Y A, POTTS C. Representing social media users for sarcasm detection[C]// Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. 2018: 1115-1121.

[2] TAY Y, TUAN L A, HUI S C, et al. Reasoning with sarcasm by reading in-between[C]// Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics. 2018: 1010-1020.

ring of the Association for Computational Linguistics. 2018: 1010-1020.

[3] JOHNSON R, ZHANG T. Deep pyramid convolutional neural networks for text categorization[C]// Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics. 2017: 562-570.

[4] XIONG T, ZHANG P, ZHU H, et al. Sarcasm detection with self-matching networks and low-rank bilinear pooling[C]// The World Wide Web Conference. 2019: 2115-2124.

[5] LI L A, MA H C, ZHOU Q L. Sarcasm detection based on transfer learning[J]. Application Research of Computers, 2021, 38(12): 3646-3650.

[6] WEN Z, GUI L, WANG Q, et al. Sememe knowledge and auxiliary information enhanced approach for sarcasm detection[J]. Information Processing & Management, 2022, 59(3): 102883.

[7] KHODAK M, SAUNSHI N, VODRAHALI K. A large self-annotated corpus for sarcasm[C]// Proceedings of the 8th International Conference on Language Resources and Evaluation. 2018: 641-646.

[8] GHOSH D, VAJPAYEE A, MURESAN S. A report on the 2020 sarcasm detection shared task[C]// Proceedings of the Second Workshop on Figurative Language Processing. 2020: 1-11.

[9] HAZARIKA D, PORIA S, GORANTLA S, et al. Cascade: Contextual sarcasm detection in online discussion forums[C]// Proceedings of the 27th International Conference on Computational Linguistics. 2018: 1837-1848.

[10] HAN H, ZHAO Q T, SUN T Y, et al. Contextual sarcasm detection model for social mediacomment[C]. Computer Engineering, 2021, 47(1): 66-71.

[11] ZHANG Y, MA D, TIWARI P, et al. Stance level sarcasm detection with BERT and stance-centered graph attention networks[J]. ACM Transactions on Internet Technology, 2023, 23(2): 1-21.

[12] HUANG B, OU Y, CARLEY K M. Aspect level sentiment classification with attention-over-attention neural networks[C]// International Conference on Social Computing, Behavioral-cultural Modeling and Prediction and Behavior Representation in Modeling and Simulation. Cham; Springer, 2018: 197-206.

[13] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]// Proceedings of the IEEE International Conference on Computer Vision. 2017: 2980-2988.

[14] AKULA R, GARIBAY I. Interpretable multi-head self-attention architecture for sarcasm detection in social media[J]. Entropy, 2021, 23(4): 1-14.



LIU Chang, born in 1998, postgraduate. His main research interests include sarcasm detection and natural language processing.



ZHU Yan, born in 1965, Ph.D, professor, Ph.D supervisor, is a member of China Computer Federation. Her main research interests include data mining, computational network analysis, and big data.