

文章编号: 1003-0077(2021)07-0126-08

## 基于特征双重蒸馏网络的方面级情感分析

宋 威<sup>1,2</sup>, 温子健<sup>1</sup>

(1. 江南大学 人工智能与计算机学院, 江苏 无锡 214122;

2. 江南大学 江苏省模式识别与计算智能工程实验室, 江苏 无锡 214122)

**摘 要:** 目前方面级情感分析方法主要利用注意力机制来实现句子与方面词的交互, 然而该机制容易导致方面词与句子中各词的错误搭配, 引入额外噪声。针对此问题, 该文提出了一种基于特征双重蒸馏网络的方面级情感分析方法。首先利用 BiLSTM 提取句子中各词的上下文语义特征, 并结合基于上下文的方面词嵌入方法, 获取方面词的语义特征。进一步地, 利用门控机制构建双重蒸馏门, 通过初步蒸馏与精细蒸馏两个过程实现句子与方面词的语义特征交互, 获取与方面词相关的句子情感语义特征。最终利用 Softmax 对获取的情感语义特征进行情感分类。在通用的 Laptop、Restaurant 和 Twitter 数据集上进行实验, 结果表明, 该方法的准确率分别达到 79.26%、84.53% 和 75.30%, 宏平均  $F_1$  值分别达到 75.77%、75.63% 和 73.21%, 优于目前主流方法。

**关键词:** 方面级情感分析; 门控机制; 双重蒸馏; 神经网络

**中图分类号:** TP391

**文献标识码:** A

## Feature Dual Distillation Network for Aspect-Based Sentiment Analysis

SONG Wei<sup>1,2</sup>, WEN Zijian<sup>1</sup>

(1. School of Artificial Intelligence and Computer Science, Jiangnan University, Wuxi, Jiangsu 214122, China;

2. Jiangsu Provincial Engineering Laboratory of Pattern Recognition and Computational Intelligence,  
Jiangnan University, Wuxi, Jiangsu 214122, China)

**Abstract:** Current methods of aspect-based sentiment analysis usually utilize the attention mechanism to fulfill the interaction between sentence and aspect. However, the attention mechanism often results in the mismatches between words of sentence and aspect, which will introduce extraneous noise. To address this issue, this paper proposes a feature dual distillation network for aspect-based sentiment analysis. Firstly, BiLSTM is utilized to extract context semantic features, and a context-based aspect embedding is utilized to obtain the semantic feature of aspect. Moreover, a gate mechanism is employed to construct a dual distillation gate where preliminary distillation and fine distillation processes are utilized to fulfill the interaction between the semantic features of sentence and aspect. Finally, Softmax is utilized to predict the sentiment polarities. On commonly used Laptop, Restaurant and Twitter datasets, the proposed method performs better than the state-of-the-art methods with 79.26%, 84.53% and 75.30% accuracy, and 75.77%, 75.63% and 73.21% Macro- $F_1$ , respectively.

**Keywords:** aspect-based sentiment analysis; gate mechanism; dual distillation; neural network

## 0 引言

方面级情感分析 (aspect-based sentiment analysis, ABSA) 作为情感分析领域中的细粒度分

析任务, 其目的是识别句子中给定方面词的情感极性, 即积极、消极和中性。例如, “Great food but the service was dreadful”, 当给定的方面词为 “food” 时, 其情感极性为积极。而当给定的方面词为 “service” 时, 其情感极性则为消极。由于 ABSA 能够预测不

收稿日期: 2020-08-27 定稿日期: 2020-10-09

基金项目: 国家自然科学基金 (61673193, 62076110); 江苏省自然科学基金 (BK20181341); 中国博士后科学基金 (2017M621625)

同方面词的情感<sup>[1]</sup>,具有较高的灵活性,目前已被广泛应用于金融<sup>[2]</sup>和政治<sup>[3]</sup>预测、电子健康<sup>[4]</sup>,以及用户画像<sup>[5]</sup>等领域。

ABSA 是自然语言处理(natural language processing, NLP)领域中的一项基本任务<sup>[6-8]</sup>,近十年来得到众多研究人员的广泛关注。早期 ABSA 方法利用情感词典、文本语义等人工特征,并结合传统的机器学习来实现方面词级别的情感分类<sup>[9-10]</sup>。由于获取这些人工特征需要耗费大量的人力和时间,且人工特征的主观性会影响特征的质量,限制了 ABSA 的应用<sup>[11]</sup>。近年来,随着神经网络的快速发展,双向长短时记忆网络(bidirectional long short-term memory, BiLSTM)被广泛应用于 NLP 中的特征提取<sup>[12-13]</sup>。Chen 等人<sup>[14]</sup>利用正反两个方向的 LSTM 分别对句子进行编码,并对编码进行拼接,从而获得句子中每个词的上下文语义特征。此外,由于方面词的实际含义往往会随其上下文的不同而各异,基于上下文的方面词嵌入(context-based aspect embedding, CAE)方法被广泛用于方面词的特征提取。Song 等人<sup>[15]</sup>基于上下文,利用输入的方面词向量,生成基于上下文的方面词语义特征。然而,单独利用各词的上下文或方面词语义特征,缺乏句子中各词与方面词的交互,无法获取句子中给定方面词的情感特征<sup>[16]</sup>。为此, Wang 等人<sup>[17]</sup>引入注意力机制来计算句子中每个词对方面词的重要性,进而获取给定方面词的上下文特征,以实现情感分析。然而,注意力机制在进行句子与方面词的交互时,容易导致方面词与句子中各词的错误搭配,引入与给定方面词情感无关的噪声,影响方面级情感分类的精度。针对此问题,本文提出一种基于特征双重蒸馏网络(feature dual distillation network, FDDN)的方面级情感分析方法,首先利用 BiLSTM 提取句子中每个词的上下文语义特征,并结合 CAE 获取给定方面词的语义特征,进而通过提出的双重蒸馏门(dual distillation gate, DDG)实现句子中每个词与方面词的语义特征交互,并控制信息流,去除与给定方面词不相关的冗余特征,以获取与给定方面词对应的情感特征。最后利用最大值池化(max pooling)与 Softmax 对获取的情感特征进行分类。所提的基于 FDDN 的方面级情感分析方法主要包含语义特征提取层(semantics feature extract layer, SFEL)、特征蒸馏层(feature distillation layer, FDL)和情感输出层(sentiment output layer, SOL)三个部分。

(1) **语义特征提取层**: 利用 BiLSTM 提取句子中每个词的上下文语义特征。同时,结合 CAE 获取方面词的语义特征。

(2) **特征蒸馏层**: 利用门控机制设计 DDG,其情感特征提取包括初步蒸馏和精细蒸馏两个过程。前者计算句子中每个词与方面词的语义特征相关性,提取方面词在句子中的情感特征,并控制信息流,实现句子与方面词的初步交互与冗余过滤。后者对方面词语义特征进行自适应微调,获取精炼的方面词语义特征,进而用于增强情感特征对方面词的关注度,并增强控制信息流,实现句子与方面词的精细交互与冗余去除。

(3) **情感输出层**: 对情感特征进行最大值池化,并利用多层感知机(multi-layer perceptron, MLP)将池化后的特征映射到分类空间,最终结合 Softmax 对情感进行极性分类。

本文的主要贡献如下:

(1) 情感特征初步蒸馏: 本文将情感特征提取细化为初步蒸馏和精细蒸馏两个过程。其中初步蒸馏直接利用方面词语义特征实现句子与方面词的初步交互,并控制信息流,初步过滤冗余特征。

(2) 情感特征精细蒸馏: 利用精炼的方面词语义特征增强情感特征对方面词的关注度,并增强控制信息流,实现句子与方面词的精细交互与冗余去除。

(3) 在通用的 Laptop<sup>①</sup>、Restaurant<sup>①</sup> 和 Twitter<sup>②</sup> 数据集上,所提方法的准确率分别达到 79.26%、84.53%和 75.30%,宏平均  $F_1$  值(Macro- $F_1$ )分别达到 75.77%、75.63%和 73.21%,优于目前主流的方面级情感分析方法。

## 1 相关工作

方面级情感分析旨在识别句子中所给方面词的情感极性,其早期方法主要结合人工特征与传统机器学习来进行情感分类。Vo 等人<sup>[18]</sup>利用情感词嵌入和情感词典来获取丰富的人工特征,在特定的数据集上取得了较好的情感分类效果,但该方法过于依赖人工特征,当迁移到其他数据集时,受其影响较大,且人工特征的获取耗费了较高的时间和人力成

① <http://alt.qcri.org/semeval2014/task4/index.php?id=data-and-tools>

② <https://github.com/songyouwei/ABSA-PyTorch/tree/master/datasets/acl-14-short-data>

本。近年来,方面级情感分析方法主要集中于利用神经网络对句子中的每个词进行编码,以获取其抽象的语义特征。Dong 等人<sup>[19]</sup>提出了一种自适应循环神经网络,通过句法分析来获取句子与方面词的特征。但是句法分析需要依存树、句法关系等外部知识,网络的结构过于复杂,Tang 等人<sup>[20]</sup>利用 LSTM 分别对方面词左侧和右侧的句子进行编码,并将两部分编码进行叠加,以获取整个句子的语义特征。为了获取更全面的句子语义特征,Liu 等人<sup>[21]</sup>利用 BiLSTM 分别从正反两个方向对句子进行编码,以反映双向语义,并拼接编码,提升了语义特征的表达能力。为了获取句子中每个词与方面词相关的情感特征,Ma 等人<sup>[22]</sup>引入了注意力机制,滤除句子中与给定方面词不相关的信息。然而,注意力机制难免会将更大注意力权重分配给句子中不相关的单词,导致方面词的情感特征包含噪声,即典型的注意力机制噪声问题。针对此问题,Liu 等人<sup>[23]</sup>利用门控机制,分别将方面词左侧、右侧及整个句子与方面词进行交互,从而获取与给定方面词相关的句子语义特征。Xue 等人<sup>[24]</sup>首先利用卷积神经网络分别提取句子与方面词的语义特征,并设计门控机制对其进行交互,从而生成句子中与给定方面词相关的情感特征。总而言之,以上方法的门控机制结构相对简单,难以从句子中准确提取与方面词相关的情感特征。为此,本文提出一种基于 FDDN 的方面级情感分析方法,在提取各词的上下文及方面词的语义特征基础上,进一步利用门控机制构建 DDG,实现句子中每个词与方面词的语义特征交互,并控制信息流,去除与给定方面词不相关的冗余特征,获取与给定方面词相关的情感特征,以实现情感分析。

## 2 基于特征双重蒸馏网络的方面级情感分析方法

本节具体介绍基于 FDDN 的方面级情感分析方法。如图 1 所示,FDDN 框架包含 SFEL、FDL 和 SOL 三个部分。在 SFEL 中,FDDN 首先利用 BiLSTM 提取句子中各词的上下文语义特征,并结合 CAE 获取方面词语义特征;在 FDL 中,构建 DDG,实现句子中各词的上下文与方面词语义特征的交互,去除与给定方面词不相关的冗余特征,以获取与给定方面词相关的情感特征;在 SOL 中,对情感特征进行最大值池化,并利用 MLP 将池化后的

特征映射到分类空间,最终利用 Softmax 对情感进行极性预测。

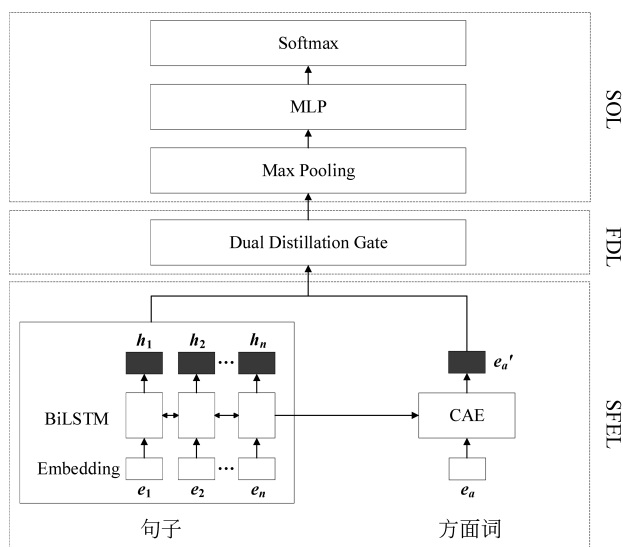


图 1 FDDN 框架

### 2.1 语义特征提取层(SFEL)

假设输入的句子有  $n$  个单词,由词嵌入方法表示句子  $s$  的词嵌入向量  $\mathbf{E}_s = \{e_1, e_2, \dots, e_j, \dots, e_n\}$ ,以及方面词  $a$  的词嵌入向量  $e_a$ ,其中  $e_j$  表示句子中第  $j$  个词的词嵌入向量。在 SFEL 中,BiLSTM 使用正反两个方向的 LSTM 将  $e_j$  转换为对应各词的上下文语义特征  $h_j$ 。正向 LSTM 从句首开始编码,获取  $e_j$  的正向语义特征  $\vec{h}_j$ ,其计算如式(1)所示。

$$\text{BiLSTM}(e_j) = \vec{h} \quad (1)$$

反向 LSTM 从句尾开始编码,获取  $e_j$  的反向语义特征  $\bar{h}_j$ ,接着将  $\vec{h}_j$  与  $\bar{h}_j$  进行拼接,进而获取  $e_j$  的上下文语义特征  $h_j = [\vec{h}_j; \bar{h}_j]$ ,因此,句子词嵌入向量  $\mathbf{E}_s$  的上下文语义特征表示为  $\mathbf{H}_s = [h_1, h_2, \dots, h_j, \dots, h_n]$ 。

另外,由于给定方面词的实际含义往往会随其上下文的变化而各异,需结合句子的上下文语义来表示方面词。本文利用 CAE 方法,首先计算  $h_j$  与  $e_a$  的相关性,其计算如式(2)所示。

$$\text{sim}(e_a, h_j) = \sigma(\tanh[e_a; h_j] \cdot \mathbf{W}_c) \quad (2)$$

其中,  $\mathbf{W}_c$  表示权重,  $\sigma$  表示 sigmoid 函数,“;”代表拼接操作。基于  $\text{sim}(e_a, h_j)$ ,进而获取  $e_a$  基于  $h_j$  的语义特征  $e_a^j$ ,其计算如式(3)所示。

$$e_a^j = \text{sim}(e_a, h_j) e_a \quad (3)$$

因此,  $e_a$  基于整个句子词嵌入向量  $E_s$  的语义特征表示为  $e'_a = [e_a^1, e_a^2, \dots, e_a^n]$ 。

## 2.2 特征蒸馏层(FDL)

在 FDL 中,利用门控机制设计 DDG,实现句子中各词上下文与方面词语义特征的交互,去除与给定方面词不相关的冗余特征,进而获取句子中与给定方面词相关的情感特征。如图 2 所示,DDG 的结构包含初步蒸馏与精细蒸馏两个部分。

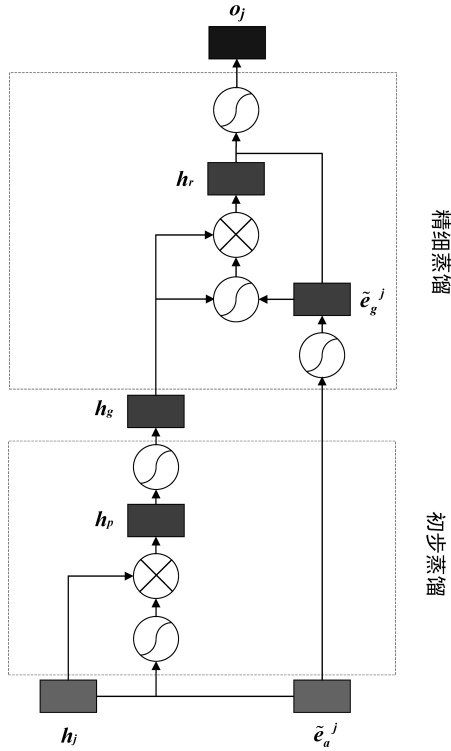


图 2 DDG 结构

DDG 首先利用初步蒸馏计算句子与方面词的语义相关性,提取句子中该方面词的情感特征  $h_p \in \mathbb{R}^d$ ,实现句子与方面词的初步交互,其算法如式(4)所示。

$$h_p = \sigma(W_p \cdot [h_j; \tilde{e}_a^j] + b_p) \odot h_j \quad (4)$$

其中,  $W_p \in \mathbb{R}^{d \times 2d}$  和  $b_p \in \mathbb{R}^d$  分别表示权重和偏置参数,  $h_j \in \mathbb{R}^d$  代表句子中第  $j$  个词嵌入向量  $e_j$  的上下文语义特征。  $\tilde{e}_a^j \in \mathbb{R}^d$  表示方面词基于  $h_j$  的语义特征,  $\sigma$  代表 sigmoid 函数。由于 sigmoid 函数能将变量映射到  $(0, 1)$  范围,故本文利用 sigmoid 函数来计算句子与方面词的语义相关性。接着,利用 ReLU 函数控制信息流,初步过滤句子中与方面词情感无关的特征,其算法如式(5)所示。

$$h_g = \text{ReLU}(W_g h_p + b_g) \quad (5)$$

其中,  $W_g \in \mathbb{R}^{d \times d}$  与  $b_g \in \mathbb{R}^d$  分别表示权重和偏

置参数,  $h_g \in \mathbb{R}^d$  为初步蒸馏的输出。由于 ReLU 函数能将负值映射为 0,本文利用 ReLU 函数过滤句子中与方面词无关的情感特征。通过句子与方面词的初步交互与冗余过滤,实现情感特征的初步蒸馏。

进一步地,DDG 利用精细蒸馏对方面词语义特征进行自适应微调,获取精炼的方面词语义特征,其算法如式(6)所示。

$$\tilde{e}_g^j = \text{ReLU}(W'_g \tilde{e}_j a + b'_g) \quad (6)$$

进而,利用  $\tilde{e}_g^j \in \mathbb{R}^d$  增强句子中情感特征对方面词的关注度,提取增强的情感特征  $h_r \in \mathbb{R}^d$ ,其算法如式(7)所示。

$$h_r = \sigma(W_r \cdot [h_g; \tilde{e}_g^j] + b_r) \odot h_g \quad (7)$$

同时,利用精炼的方面词语义特征增强控制信息流,去除句子中与方面词无关的情感特征,最终获取句子中与方面词相关的精细情感特征  $o_j \in \mathbb{R}^d$ ,其算法如式(8)所示。

$$o_j = \text{ReLU}(W_o(h_r + W_k \tilde{e}_g^j) + b_o) \quad (8)$$

在式(6)~式(8)中,  $W'_g \in \mathbb{R}^{d \times d}$ 、 $W_r \in \mathbb{R}^{d \times d}$ 、 $W_k \in \mathbb{R}^{d \times d}$  与  $W_o \in \mathbb{R}^{d \times d}$  表示可学习权重,  $b'_g \in \mathbb{R}^d$ 、 $b_r \in \mathbb{R}^d$  与  $b_o \in \mathbb{R}^d$  为可学习偏置。与初步蒸馏的区别是直接利用方面词的语义特征实现句子与方面词的初步交互,精细蒸馏首先利用式(6)对方面词语义特征进行自适应微调,以获取精炼的方面词语义特征  $\tilde{e}_g^j$ ,并通过式(7)和式(8)分别实现句子与方面词的精细交互与冗余去除。尤其是式(8),在情感语义特征  $h_r$  中再次引入方面词的语义信息  $\tilde{e}_g^j$ ,加强对给定方面词的关注程度,增强控制信息流,并利用 ReLU 函数去除冗余特征,从而实现情感特征的精细蒸馏。例如,输入句子“Great food, but the service was dreadful”,给定的方面词为“food”,通过初步蒸馏,过滤句子中与方面词情感无关的特征,即过滤掉非情感特征,如“but”“the”和“was”。但由于初步蒸馏相对较简单,无法有效过滤掉“dreadful”。因此,本文在初步蒸馏的基础上,进一步利用精细蒸馏,加强对给定方面词的关注程度,增强控制信息流,并利用 ReLU 函数去除“dreadful”,从而获取与给定方面词“food”相关的情感特征“great”。

## 2.3 情感输出层(SOL)

针对单个词的上下文语义特征  $h_j$ ,FDL 利用初步蒸馏和精细蒸馏获取其与方面词相关的精细情感特征  $o_j$ 。因此,句子中所有单词上下文语义特征与方面词相关的精细情感特征表示为  $O = (o_1; o_2; \dots; o_j; \dots; o_n)$ ,其中,  $n$  代表句子中单词的个数。接着,



SOL 利用最大值池化,获取  $\mathbf{O}$  中最具鉴别性的情感特征,易于实现情感预测。最大值池化计算方法如式(9)所示。

$$\mathbf{Z} = [\max(o_1; o_2; \dots; o_j; \dots; o_n)] \quad (9)$$

接着,利用 MLP 将情感特征  $\mathbf{Z}$  映射到  $C$  个分类标签空间,再通过 Softmax 来预测给定方面词的情感极性  $\hat{y}_i$ ,计算方法如式(10)所示。

$$\hat{y}_i = \text{softmax}(\mathbf{W}_z \cdot \mathbf{Z} + \mathbf{b}_z) \quad (10)$$

其中,  $\mathbf{W}_z$  与  $\mathbf{b}_z$  分别代表权重与偏置。FDDN 的训练过程采用交叉熵作为损失函数,并利用 L2 正则化减少网络对训练样本的过拟合,提高其泛化性。FDDN 的损失函数计算方法如式(11)所示。

$$\mathbf{L} = - \sum_i^D \sum_j^C \mathbf{y}_i^j \cdot \log \hat{\mathbf{y}}_i^j + \lambda \|\theta\|_F^2 \quad (11)$$

其中,  $D$  表示训练集中样本的个数,  $C$  表示情感极性的种类,在本文中为 3,即积极、消极和中性。 $\mathbf{y}_i^j$  代表样本的真实标签,  $\lambda \|\theta\|_F^2$  代表正则项。

### 3 实验

#### 3.1 数据集介绍及评价指标

本文实验分别利用 300 维的 GloVe 词向量<sup>[25]</sup>与 768 维的 BERT 词向量<sup>[26]</sup>来表示输入的句子与方面词,并采用通用的 Laptop、Restaurant 和 Twitter 数据集来验证所提方法的有效性。其中, Laptop 和 Restaurant 数据集来自 SemEval 2014 Task4<sup>[27]</sup>,包含对 Laptop 和 Restaurant 两个领域的用户评论。Twitter 来自于 ACL14<sup>[19]</sup>,收集了 Twitter 网站上的推文。每个样本都由句子、方面词及其对应的情感极性构成,三个数据集的统计信息如表 1 所示。同时,本文采用准确率(accuracy)和宏平均  $F_1$  值(macro- $F_1$ )作为情感极性预测的评价指标。

表 1 三个数据集的统计信息

		积极	消极	中性
Laptop	Train	994	870	464
	Test	341	128	196
Restaurant	Train	2 164	807	637
	Test	728	196	196
Twitter	Train	1 561	1 560	3 127
	Test	173	173	346

#### 3.2 对比方法

本文采用以下方法和所提的 FDDN 进行比较。

**Feature-based SVM<sup>[28]</sup>**: 基于人工特征的支持向量机方法。

**LSTM<sup>[20]</sup>**: 利用 LSTM 直接对句子进行编码,从而获取句子特征。

**ATAE-LSTM<sup>[17]</sup>**: 利用 LSTM 获取句子中每个词的上下文特征,并与方面词向量拼接,获取更关注方面词的句子特征。

**IAN<sup>[22]</sup>**: 以句子与方面词交互的方式,分别生成含有相互关系的句子与方面词特征。

**MemNet<sup>[29]</sup>**: 多次采用注意力机制获取句子中每个词针对方面词的重要性,进而获取句子中与方面词相关的特征。

**RAM<sup>[14]</sup>**: 利用多个注意力机制将 BiLSTM 的输出结合,形成句子的特征。

**CNN<sup>[30]</sup>**: 利用卷积神经网络来编码句子和方面词的拼接向量,获取情感特征。

**GCAE<sup>[24]</sup>**: 利用卷积神经网络分别对句子和方面词进行编码,再采用门控机制获取句子中与方面词情感相关的特征。

**SK-GCN<sup>[31]</sup>**: 利用句法依赖树及常识信息,通过图卷积网络进行情感分析。

**BERT-SPC<sup>[26]</sup>**: 将句子与方面词分别输入到 BERT 分类网络中,对情感进行预测。

**ReMemNN<sup>[32]</sup>**: 利用多元素注意力机制对句子与方面词特征进行交互,并通过 MemNet<sup>[29]</sup>进行情感分析。

#### 3.3 实验结果与分析

在实验部分,本文首先对 FDDN 进行消融实验。其中,FDDN-DDG 表示在 FDDN 中缺省整个 DDG,直接对句子和方面词特征进行加和来实现情感分类。FDDN-RD 表示在 FDDN 中缺省了 DDG 的精细蒸馏(refined distillation, RD)过程,直接利用初步蒸馏提取的特征进行情感分类。实验采用 GloVe 与 BERT 词向量分别测试以上方法的准确率。在三个数据集上的对比实验结果如图 3~图 5 所示。

从图 3~图 5 可以看出,从整体趋势上看,在 Laptop、Restaurant 和 Twitter 数据集上,FDDN、FDDN-DDG 和 FDDN-RD 的准确率在训练开始阶段随着迭代次数的增加而快速上升,然后逐渐趋于稳定。不论是利用 GloVe 词向量,还是利用 BERT




图3 Laptop数据集上 FDDN、FDDN-DDG 和 FDDN-RD 的训练过程




图5 Twitter数据集上 FDDN、FDDN-DDG 和 FDDN-RD 的训练过程




图4 Restaurant数据集上 FDDN、FDDN-DDG 和 FDDN-RD 的训练过程

词向量,在同一词向量的前提下,FDDN 的准确率比 FDDN-DDG 和 FDDN-RD 要高得多。这是由于相对于 FDDN-DDG,FDDN 包含了 FDL;而相对于 FDDN-RD,FDDN 包含了 FDL 中的 RD。具体而言,

FDL 利用 DDG 对情感特征进行了初步蒸馏和精细蒸馏,前者首先对句子与方面词进行初步交互与冗余过滤,后者则实现了句子与方面词的精细交互与冗余去除。

另外,由图中还可以看出,相对基于 GloVe 词向量的方法,基于 BERT 词向量的方法表现较好,这是由于 BERT 的词向量维度为 768 维,而 GloVe 词向量的维度仅为 300 维,BERT 词向量提供了更丰富的语义与语法信息。同时,与 GloVe 采用静态词向量来表示单词不同,BERT 是一种动态的词向量表示方法。因而,对于同一单词,GloVe 会生成固定的词向量,但没有考虑单词上下文的变化。而 BERT 会根据单词的上下文动态地生成更为准确的词向量来表示目标单词。

为了进一步验证 FDDN 的有效性,本文将其与 10 种基于 GloVe 词向量的主流方法及两种基于 BERT 词向量的主流方法进行比较。各方法的准确率及 Macro- $F_1$  如表 2 所示。其中,下划线和加粗字

表 2 FDDN 及主流方面级情感分析方法在三个数据集上的比较

方法		Laptop		Restaurant		Twitter	
		Accuracy/%	Macro- $F_1$ /%	Accuracy/%	Macro- $F_1$ /%	Accuracy/%	Macro- $F_1$ /%
GloVe 词向量	Feature-SVM	70.49	—	80.16	—	63.40	63.30
	LSTM	66.45	63.90	74.28	70.90	66.50	64.70
	ATAE-LSTM	68.70	63.93	77.20	67.02	68.64	66.60
	IAN	72.19	65.92	78.60	66.31	69.80	66.31
	MemNet	70.33	64.09	78.16	65.83	68.50	66.91
	RAM	72.08	68.43	78.48	68.54	69.36	67.30

续表

方法		Laptop		Restaurant		Twitter	
		Accuracy/%	Macro- $F_1$ /%	Accuracy/%	Macro- $F_1$ /%	Accuracy/%	Macro- $F_1$ /%
GloVe 词向量	CNN	70.46	65.31	77.82	65.11	69.27	66.77
	GCAE	72.78	67.10	79.35	70.52	70.80	67.66
	SK-GCN	73.04	68.41	80.36	70.14	71.82	69.56
	ReMemNN	73.04	68.49	80.38	70.86	71.83	69.11
	FDDN	<u>73.09</u>	<u>68.56</u>	<u>80.47</u>	<u>71.08</u>	<u>71.96</u>	<u>69.58</u>
BERT 词向量	SK-GCN(BERT)	79.00	75.57	83.48	75.19	75.00	73.01
	BERT-SPC	78.99	75.03	84.48	70.06	73.55	70.53
	FDDN(BERT)	<b>79.26</b>	<b>75.77</b>	<b>84.53</b>	<b>75.63</b>	<b>75.30</b>	<b>73.21</b>

体分别代表基于 GloVe 和 BERT 词向量方法在三个数据集上的最高准确率和宏平均  $F_1$  值。“—”代表原始论文没有提供该方法在对应数据集上的实验结果。

由表 2 所示,在三个数据集上,FDDN 和 FDDN(BERT)的准确率及 Macro- $F_1$  都高于基于相同词向量的其他方法。具体地,在 Laptop、Restaurant 和 Twitter 数据集上,在利用 GloVe 词向量时,FDDN 的准确率相较于总体表现次好的 ReMemNN 提高了 0.05%、0.09% 和 0.13%,Macro- $F_1$  提高了 0.07%、0.22% 和 0.47%;在利用 BERT 词向量时,FDDN(BERT)的准确率相较于总体表现次好的 SK-GCN(BERT)提高了 0.26%、1.05% 和 0.3%,Macro- $F_1$  提高了 0.2%、0.44% 和 0.2%。

#### 4 总结与展望

本文提出一种基于 FDDN 的方面级情感分析方法。该方法首先利用 BiLSTM 提取上下文语义特征,并结合 CAE,获取方面词语义特征。进一步地,利用门控机制构建 DDG,通过初步蒸馏与精细蒸馏两个过程实现上下文与方面词两种语义特征的交互,去除与给定方面词不相关的冗余特征,获取句子中与方面词相关的情感语义特征,最终利用 Soft-max 实现方面级情感分类。为了验证所提方法的有效性,本文采用 Laptop、Restaurant 和 Twitter 数据集进行了广泛实验。基于 BERT 词向量的 FDDN(BERT)在这三个数据集上的准确率分别达到 79.26%、84.53% 及 75.30%,Macro- $F_1$  分别达到 75.77%、75.63% 及 73.21%,优于目前主流的方面级情感分析方法。

未来工作中,我们将研究如何把本文所提方法

应用于舆情分析、弹幕情感分析等实际问题。同时,为了更好地将所提方法进行实际应用,我们将开发便捷的用户界面,提供更好的用户体验。

#### 参考文献

- [1] 贾川,方睿,浦东,等.基于循环实体网络的细粒度情感分析[J].中文信息学报,2019,33(9):123-128.
- [2] Khaidem L, Saha S, Dey S R. Predicting the direction of stock market prices using random forest[J]. arXiv preprint arXiv:160500003, 2016.
- [3] Tumasjan A, Sprenger T O, Sandner P G, et al. Predicting elections with twitter: What 140 characters reveal about political sentiment[C]//Proceedings of the 4th International AAAI Conference on Weblogs and Social Media, 2010: 1279-1282.
- [4] Cambria E, Hussain A, Durrani T, et al. Sentic computing for patient centered applications[C]//Proceedings of the 10th IEEE International Conference on Signal Processing Proceedings, 2010: 1279-1282.
- [5] Zhang Z, Liu Y, Xu G, et al. A weighted adaptation method on learning user preference profile[J]. Knowledge-Based Systems, 2016, 112: 114-126.
- [6] Yang C, Zhang H, Jiang B, et al. Aspect-based sentiment analysis with alternating coattention networks[J]. Information Processing and Management, 2019, 56(3): 463-478.
- [7] 曾锋,曾碧卿,韩旭丽,等.基于双层注意力循环神经网络的方面级情感分析[J].中文信息学报,2019,33(6):108-15.
- [8] 刘全,梁斌,徐进,等.一种用于基于方面情感分析的深度分层网络模型[J].计算机学报,2018,12:2637-2652.
- [9] Shuang K, Zhang Z, Guo H, et al. A sentiment information collector-extractor architecture based neural network for sentiment analysis[J]. Information Sci-

- ences, 2018, 467: 549-558.
- [10] Wang L, Niu J, Yu S. SentiDiff: Combining textual information and sentiment diffusion patterns for Twitter sentiment analysis[C]//Proceedings of IEEE Transactions on Knowledge and Data Engineering, 2019.
- [11] Serrano-Guerrero J, Olivas J A, Romero F P, et al. Sentiment analysis: A review and comparative analysis of web services[J]. Information Sciences, 2015, 311: 18-38.
- [12] Bahdanau D, Cho K, Bengio Y. Neural machine translation by jointly learning to align and translate[J]. arXiv preprint arXiv:1409.0473, 2014.
- [13] Song M, Park H, Shin K -s. Attention-based long short-term memory network using sentiment lexicon embedding for aspect-level sentiment analysis in Korean[J]. Information Processing and Management, 2019, 56(3): 637-653.
- [14] Chen P, Sun Z, Bing L, et al. Recurrent attention network on memory for aspect sentiment analysis[C]//Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing, 2017: 452-461.
- [15] Song Y, Wang J, Jiang T, et al. Attentional encoder network for targeted sentiment classification[J]. arXiv preprint arXiv:1902.09314, 2019.
- [16] 王盛玉, 曾碧卿, 商齐, 等. 基于词注意力卷积神经网络模型的情感分析研究[J]. 中文信息学报, 2018, 32(9): 123-31.
- [17] Wang Y, Huang M, Zhu X, et al. Attention-based LSTM for aspect-level sentiment classification[C]//Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing, 2016: 606-615.
- [18] Vo D T, Zhang Y. Target-dependent twitter sentiment classification with rich automatic features[C]//Proceedings of the 24th International Conference on Artificial Intelligence, 2015: 1347-1353.
- [19] Dong L, Wei F, Tan C, et al. Adaptive recursive neural network for target-dependent twitter sentiment classification[C]//Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics, 2014: 49-54.
- [20] Tang D, Qin B, Feng X, et al. Effective LSTMs for target-dependent sentiment classification[C]//Proceedings of the 26th International Conference on Computational Linguistics: Technical Papers, 2016: 3298-3307.
- [21] Liu N, Shen B. Aspect-based sentiment analysis with gated alternate neural network[J]. Knowledge-Based Systems, 2020, 188: 105010.
- [22] Ma D, Li S, Zhang X, et al. Interactive attention networks for aspect-level sentiment classification[C]//Proceedings of the 26th International Joint Conference on Artificial Intelligence, 2017: 4068-4074.
- [23] Liu J, Zhang Y. Attention modeling for targeted sentiment[C]//Proceedings of the 15th Conference of the European Chapter of the Association for Computational Linguistics, 2017: 572-577.
- [24] Xue W, Li T. Aspect based sentiment analysis with gated convolutional networks[C]//Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics, 2018: 2514-2523.
- [25] Pennington J, Socher R, Manning C D. Glove: Global vectors for word representation[C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP), 2014: 1532-1543.
- [26] Devlin J, Chang M W, Lee K, et al. Bert: Pre-training of deep bidirectional transformers for language understanding[J]. arXiv preprint arXiv:1810.04805, 2018.
- [27] Pontiki M, Papageorgiou H, Galanis D, et al. SemEval-2014 Task 4: Aspect based sentiment analysis[C]//Proceedings of the SemEval 2014, 2014: 27.
- [28] Kiritchenko S, Zhu X, Cherry C, et al. NRC-Canada-2014: Detecting aspects and sentiment in customer reviews[C]//Proceedings of the 8th International Workshop on Semantic Evaluation, 2014: 437-442.
- [29] Tang D, Qin B, Liu T. Aspect level sentiment classification with deep memory network[C]//Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing, 2016: 214-224.
- [30] Kim Y. Convolutional neural networks for sentence classification[C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing, 2014: 1746-1751.
- [31] Zhou J, Huang J X, Hu Q V, et al. SK-GCN: Modeling syntax and knowledge via graph convolutional network for aspect-level sentiment classification[J]. Knowledge-Based Systems, 2020, 205: 106292:1-10.
- [32] Liu N, Shen B. ReMemNN: A novel memory neural network for powerful interaction in aspect-based sentiment analysis[J]. Neurocomputing, 2020, 395: 66-77.



宋威(1981—),通信作者,博士,教授,主要研究领域为机器学习、自然语言处理、数据挖掘、模式识别等。

E-mail: songwei@jiangnan.edu.cn



温子健(1996—),硕士研究生,主要研究领域为自然语言处理、情感分析等。

E-mail: zjwen@stu.jiangnan.edu.cn