

基于概念图卷积的方面级情感检测方法

高庆吉, 田学进, 黄 淼, 邢志伟

(中国民航大学 机器人研究所, 天津 300300)

摘要: 针对方面级情感分析方法准确率难以达到实用效果的问题, 设计一种融合注意力机制并同时考虑句子句法结构和语料库共现信息的 A-LSGCN 模型, 以便提高预测句子中特定属性情感极性的准确率; 首先, 联合多头注意力机制和词汇-句法图卷积, 对属性的记忆向量和历史上下文内存向量进行叠加与更新, 从而获得目标属性词及其上下文之间的关系; 其次, 为减少冗余对分类干扰, 并充分学习通用语法知识, 采用句法依存图神经网络提取句法结构信息, 直接匹配属性及其情感表达, 经网络分类计算最终得到特定属性对应的情感极性; 最后在多个 SemEval 数据集上进行对比试验, 其中 Laptop14 数据集的 MF1 分数和准确率分别提升了 1.1%、5.5%。

关键词: 方面级情感分析; 图卷积神经网络; 句法词汇概念图卷积; 注意力机制; 句法依存树

Convolution over Syntactic Vocabulary Hierarchical Graph Used in Aspect-Based Sentiment Analysis

GAO Qingji, TIAN Xuejin, HUANG Miao, XING Zhiwei

(Robotics Institute, Civil Aviation University of China, Tianjin 300300, China)

Abstract: In order to solve the problem that the accuracy of aspect-based sentiment analytic method is difficult to achieve practical application, an A-LSGCN model that integrates the attention mechanism and simultaneously considers the sentence syntactic structure and corpus co-occurrence information is designed, so the accuracy of predicting the sentiment polarity of each specific attribute in a given sentence is improved. Firstly, combined with the multi-head attention mechanism and the lexical-syntactic graph convolution for the superimposing of the attribute memory vector and the historical context memory vector, the relationship between the target attribute word and its contextual content is obtained. Secondly, in order to reduce the redundancy of the classification interference, and learn the general grammar knowledge enough, the syntactic dependency graph neural network is used to extract the syntactic structure information, directly match the attributes and their emotional expressions, and the emotional polarity corresponding is obtained to the specific attributes through the network classification calculation. Finally, compared with the experiment on multiple SemEval datasets, the MF1 score and accuracy of the Laptop14 dataset are improved by 1.1% and 5.5%, respectively.

Keywords: Keywords aspect-based sentiment analysis; graph convolutional networks; syntactic vocabulary diagram convolution; adaptive attention; syntactic dependency trees

0 引言

方面级情感分析 (ABSA, aspect-based sentiment analysis) 是用户情感分析中的一项细粒度任务^[1], 包括属性类别情绪分析和属性术语情绪分析, 其目标是识别和检测给定句子中的实体词、方面词和观点词, 并对给定句子中的每个特定属性对应的情绪极性 (例如, 积极、中性或消极) 进行预测。

目前方面级情感分析领域的研究主要集中于用户消费评价, 自动驾驶模式为所有利益相关者带来了一个全新的场景。而人机对话形成服务确认, 是一种必然趋势, 人机达成供需是自主载人车实施服务是必要环节, 人机之间存

在形成认可和法律责任问题, 结合无人车接受模型与方面级情感分析进行信任度评判, 可准确有效地检测旅客意图, 为将来航站楼服务机器人自主实现引导、调节旅客航站楼内活动提供依据。因此, 方面级情感分析对于用户挖掘、新兴自主载人车投入服务以及产品服务重建方面有广泛应用前景。

对于方面级情感分析, 方面示例包括产品、服务、主题、组织、事件、及其属性。示例 “The sandwiches and sushi is delicious but the waiter is very rude”, 如图 1 所示, “sandwiches” 和 “sushi” 描述属性类别 “food”, “waiter” 则描述 “service”, 以此分析用户对 “食品” 和 “服务” 的态度。

收稿日期: 2022-03-03; 修回日期: 2022-03-23。

基金项目: 国家自然科学基金 (U1533203); 天津市教委科研项目 (2019KJ117)。

作者简介: 高庆吉 (1966-), 男, 黑龙江桦川人, 博士, 教授, 主要从事人工智能与智能控制方向的研究。

邢志伟 (1970-), 男, 辽宁新民人, 博士, 教授, 主要从事民航装备与系统、机场交通信息与控制方向的研究。

通讯作者: 田学进 (1997-), 女, 贵州遵义人, 硕士研究生, 主要从事机场智能与自动化方向的研究。

引用格式: 高庆吉, 田学进, 黄 淼, 等. 基于概念图卷积的方面级情感检测方法[J]. 计算机测量与控制, 2022, 30(6): 45-52.

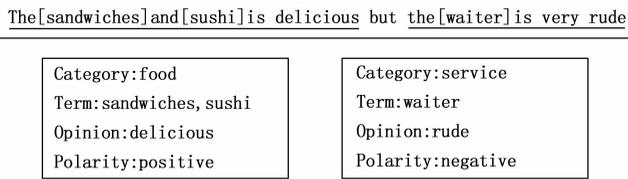


图 1 包含两个基于方面的情绪分析实例

目前, ABSA 技术主要以情感词典、机器学习和深度学习为基础的方法。基于情感词典的方法实现过程中不存在繁杂步骤, 但其局限在于此方法对于方面级别的情感的检测和分类效果严重依赖于情感词典质量。基于机器学习方法^[2]需人工提取特征, 而基于深度学习的 ABSA 模型^[3], 可以自动获得语料的文本特征信息并提取信息中所含的复杂非线性关系, 从而引起了该领域内学者的广泛重视。随着词嵌入技术的发展, 卷积神经网络 (CNN, convolutional neural networks)^[4]可兼顾句子映射到低维的语义表示和单词序列信息以及本地文本表示的保持, 由此发展出具有选通机制的 CNN^[5]应用于 ABSA。但 CNN 模型只卷积连续单词的信息, 从而忽略非相邻词的影响。而后因递归神经网络 (RecNN, recursive neural network)^[6]模型能够灵活地捕捉属性与其上下文词之间的语义关系而被引入 ABSA, RNN 及其变体被广泛应用至 ABSA 任务, 如长短期记忆网络 (LSTM, long short-term memory) 及其变体 BiLSTM^[7]。Tang 等人^[8]提出了目标导向性的长短期记忆网络 (TD-LSTM, target-dependent LSTM) 和与目标连接的长短期记忆网络 (TC-LSTM), 前者通过二个单向 LSTM 对目标单词的左部上下文与右部上下文分别进行建模, 后者在 TD-LSTM 的基础上, 将目标单词引入至输入端。为了更好地关注语料的属性等关键信息, Gu 等人^[9-12]在 ABSA 中融入了注意力机制以便聚焦关键信息。

相较于 CNN 和 RNN, GCN 能够有效地处理具有图结构的数据, THOMAS 等人首次将 GCN^[13]应用于 ABSA, 利用句法依赖结构解决了长期多次依赖的问题。Zhang 等人^[14]设计了包含属性门控机制的 ASGCN 模型, 使用与属性相关的编码器改善了缺乏属性信息而导致的错误预测。近来, 利用 GCN 与依存句法树相结合的 ABSA 模型取得了很好的效果^[14-17], ZHANG 等人^[14]设计了包含属性门控机制的 ASGCN 模型, 从而通过句法依存树建立融合属性词和语义信息的表达形式, 并联合注意力机制进行语料的属性词和语料语义信息的交互, 通过采用与属性相关的编码器改善了缺乏属性信息而导致的错误预测。进一步地, Sun 等人^[15]考虑到句法结构对 ABSA 的重要影响, 通过依赖树卷积模型 (CDT, convolution over a dependency tree) 融合句法、词性、位置和语义特征信息, 由此诠释了语法距离及其权重的定义和计算方式, 从而设计了结合图卷积和 BiLSTM 的轻量级 ABSA 模型。为获取更加准确的上下文信息, Zheng 等人^[16]以随机遍历搜寻句法依存树的方式来确定与情感极性相关的特定子树。研究表明与属性词距离越

近的情感词对属性词影响会越大, 巫浩盛等人^[17]结合词语的语法距离和句法结构, 进一步提出了基于距离与图卷积网络的 DGCN 模型 (DGCN, distance and graph convolutional network)。在特征提取过程中, 情感分类常用基于词典的向量空间模型 (VSM)、潜在的语义分析 (LSA)、基于无监督算法的词嵌入 (Word 2 word) 和随机词向量法来进行特征信息的提取。这些方法都是对单个词语进行处理, 陈等人^[18]使用改进的隐马尔科夫模型 (MHMM) 构建词对向量特征并取得了很好的效果。

前文所述模型重点考虑属性词、位置信息和上下文之间的语义关系, 主要从词的层面提取文本的语义特征, 未充分考虑属性词和邻近词组的局部信息的重要性, 从而导致模型很难充分利用语料库中文本信息。在模型训练的过程中结合词性特征信息, 能有效避免模型训练过程中的文本语义特征信息的缺失问题。所以, 方面属性词的局部信息与全局信息、方面属性词与观点词和实体的交互信息、相对位置信息与词性信息都是影响 ABSA 效果的关键因素。

因此, 结合 3 大关键影响因素, 提出一种融合注意力机制和词汇一句法分级图卷积的神经网络模型 (A-LSGCN, lexical syntactic graph convolution based on adaptive attention mechanism), 联合多头注意力机制及词汇一句法图卷积, 模型同时考虑句法结构和语料库共现信息, 联合多头注意力机制及词汇一句法图卷积并使用局部聚合机制检测、提取从而生成方面词的局部属性信息, 通过以方面词为导向的方式叠加更新属性记忆向量和句子的历史上下文内存向量, 从而学习获得目标及其上下文之间的关系特征表示方法, 最终得到特定方面属性对应的情感极性分类作为输出。

1 A-LSGCN 分类模型设计

综合考虑方面属性词的局部信息和全局信息、方面属性词与观点词和实体之间的交互信息、相对位置信息和词性信息这三大关键因素对 ABSA 的影响, 设计 A-LSGCN 模型。模型框架如图 2 所示。

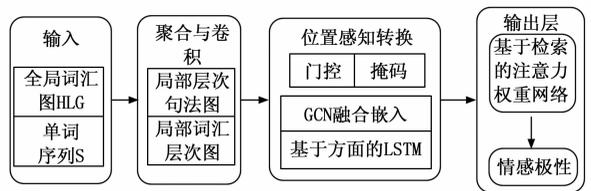


图 2 A-LSGCN 模型框架

- 1) 首先把由语料库构建的全局词汇概念图和语料库单词序列作为输入来获得初始句子表示。
- 2) 其次, 设计一个多层聚合模块 (AggIn, aggregate & interaction), 即 AggIn 聚合卷积模块。在 AggIn 聚合卷积模块对局部分级词汇概念图和分级句法图进行浅层聚合和深层卷积交互, 输出精化语义特征后的句子表示。
- 3) 再次, 采用基于方面属性为导向的掩码和门控机制

得到特定方面属性的表示, 从而提升模型对句子中特定方面属性对应的情感极性的预测精度。

4) 最后通过基于检索的注意力权重网络层最终输出特定方面属性对应的情感极性。

1.1 A-LSGCN 文本预处理

任务描述: 语料库给定句子 S , 由 n 个单词组成, 其中包括从第 $(a+1)$ 个位置开始、长度为 τ 的方面属性词, 任务目标是识别 S 中特定方面属性的情感极性, 即积极、中性和消极 3 种极性。

$$S = [\omega_1, \dots, \omega_{a+1}, \dots, \omega_{a+\tau}, \dots, \omega_n] \quad (1)$$

其中需考虑:

1) 共同出现频率高的词组代表语言学中的固定组合; 例如, 词组 “nothing great” 表示负极性, 需要全局信息抵消 “great” 对句子 S 总体的正面影响, 以便做出综合全局信息的判断;

2) 每种不同类型的句法依存关系描述某种特定的语法关系;

3) 构建全局词汇概念图用于属性类别情绪分析任务。对语料库级别的单词共现信息进行编码, 其中节点是单词, 边表示训练语料库中两个单词节点之间的频率;

4) 建立概念分级, 对不同类型的依存关系或词对共现关系进行分级。

因此, 为了更好地区分句子 S 中的谓语的主语和宾语, 在融合词对共现信息和句法依存信息时使用双向 GCN 网络, 由此建立用于训练语料库的全局词汇概念图, 和语料库中句子的局部分级句法图。

1) 句法分级概念图构造。每个依存关系都代表一个词在句子中的特定语法功能, 直接使用依赖关系作为图的边可能会导致与解析错误类似的噪音^[11]。因此为句法图附加概念分级类型的标签, 可构建了分级概念的句子图 HSG 。

$$HSG = \{V_s, E_s, R_s\} \quad (2)$$

其中: V_s, E_s, R_s 分别是节点集、边集和句法关系类型集, E_s 中的每条边都附加了对应的 R_s 中的依赖关系类型标签。

2) 词法分级图构造。全局词汇概念图: 对语料库里级别的词汇共现信息进行编码, 其中单词作为节点, 训练语料库中两个单词节点之间的频率作为边。

词法分级图: A-LSGCN 模型通过在全局词汇概念图的基础上, 融入分级概念来区分不同类型的句法依存关系或词对共现关系在句子 S 中的重要程度。词的共现频率是高度偏斜的, 根据对数正态分布对词的共现频度进行分组, 从而形成词对概念分级, 由此构建全局分级词法图, 同理可构建局部分级词法图。

$$HLG^o = \{V_d^o, E_d^o, R_d^o\}, HLG^l = \{V_d^l, E_d^l, R_d^l\} \quad (3)$$

其中: V_d^o, E_d^o, R_d^o 和 V_d^l, E_d^l, R_d^l 分别是全局分级词法图、局部分级词法图的节点集、边集和词法关系类型集, V_d^o 与 V_s 相同。

1.2 A-LSGCN 分类模型

提出的 A-LSGCN 模型架构包含 4 个模块, 如图 3 所示。

1.2.1 句子初始表达 (词嵌入层)

使用 300 维 GloVe 向量^[13]初始化单词预训练词典, 对语料库中的句子 S 进行文本嵌入, 对于预训练词典外的词汇则通过均匀分布实现词汇的随机初始化。将语料库数据中的每一个词汇由高维向低维映射, 从而得到低纬度的向量空间表示形式, 其数值矩阵的数学表述为: $E_w \in R^{v \times d}$ 。

其中: v 代表预训练词典中的词汇量, d 为使用单词预训练词典对句子 S 进行词嵌入的维度。 E_w 用于将具有 n 个单词的序列映射到词向量, 嵌入后文本表示为 $[e_1, \dots, e_{a+1}, \dots, e_{a+\tau}, \dots, e_n] \in R^{v \times d}$ 。

1.2.2 语义提取层

采用基于全局词汇概念图的 GCN 形式特征嵌入和基于双向 LSTM 的 Bi-LSTM embedding 表示优化句子编码方

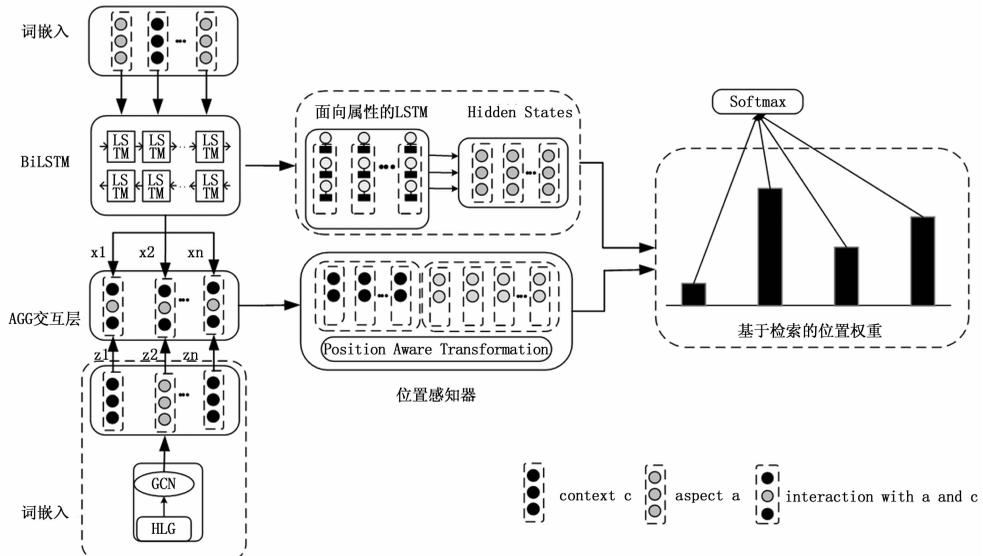


图 3 A-LSGCN 模型结构图

式。构建嵌入矩阵 $E_{wcf} \in R^{N \times d}$ 作为训练语料的特征矩阵，用于在句子 S 的特征表示形式中编码语料库中特有的词汇信息，其中 N 为语料库训练集的词汇量， d 为词嵌入向量的维度；并对 HLG^o 执行 GCN 层，从而获得整个训练集的词汇嵌入矩阵 $E_{gcn} \in R^{N \times dx}$ 。由 E_{gcn} 可通过查找表获到 S 的 GCN embedding, $[x_1, \dots, x_{a+1}, \dots, x_{a+\tau}, \dots, x_n] \in R^{v \times dx}$, 在图 3 中用 x 表示。

通过研究顺序信息编码到评论表示，考虑与方面属性词的词汇间距，间距越小可能会对其情感极性的检测和分类作出更大的贡献^[10,12]。计算从每个上下文词到相应方面属性词的绝对距离，从而得到 S 的位置序列 $E_p \in R^{v \times dp}$ 作为随机初始化的位置嵌入查找表，位置查找层将位置序列映射到位置嵌入列表 $[P_1, \dots, P_{a+1}, \dots, P_{a+\tau}, \dots, P_n]$ 。则 S 中的每个单词 w_i 可计算为 $e_i^p = e_i \odot p_i \in R^{d+dp}$ ，其中 \odot 表示拼接，都含有预训练词嵌入和位置信息嵌入。

然后经 Bi-LSTM 层处理获得 Bi-LSTM embedding，记作 $Z_i \in R^{N+dx}$, $[z_1, \dots, z_{a+1}, \dots, z_{a+\tau}, \dots, z_n] \in R^{v \times dx}$ 在图 3 中用 z 表示。

1.2.3 AggIn 聚合卷积层

将初始句子表示形式，即 x, z 作为模型输入，A-LS-GCN 模型进一步通过局部分级概念词汇图和分级句法图在聚合交互模块 AggIn 深层交互，通过卷积交互精炼含局部分级概念词汇图和分级句法图相互影响信息的特征表示形式，即 S 的精炼表示。AggIn 包含多层结构，交叉网络用以融合 x 和 z 的特征信息，并通过双层 GCN 以在分级句法图和局部分级概念词汇图上进行卷积，最终获得句子 S 的精炼表达。AggIn 通过多层结构的设计，使得在不同层级执行的不同类型信息能够交互和协作。可用逻辑描述如下。

$$y^0 = x \odot z, y^0 \in R^{dx} \quad (4)$$

$$y^l = y^0 y^{l-1} \omega^l + b^l + y^{l-1} \quad (5)$$

其中： l, ω^l 和 b^l 分别为层数、权重和偏置，且 $\omega^l, b^l \in R^{dx}$ 。 y^l 为 x^l 和 z^l 输入双向 GCN 前的节点。

浅层聚合按照关系类型划分节点，并将同一类关系类型的节点聚合成为一个虚拟节点，表示为 $\tilde{h}_i^{l,r}$ 。

深层聚合用于把浅层聚合中得到的虚拟节点及其对应的特定依存关系类型信息融合在一起，并通过使用不同关系类型对应的虚拟节点上设置的平均聚合函数，从而能够更新目标单词 w_i 的信息表示形式，如下所示：

$$h_i^l = \text{ReLU}(W_l \cdot (\oplus_r \tilde{h}_i^{l,r})) \quad (6)$$

\oplus_r 为不同关系类型表示的连接， W_l 为第 l 层中的权重矩阵。

经此层后， x 和 z 的精炼表示分别为 x^l 和 z^l 。

$$x^l = [h_1^{l,d}, \dots, h_{a+1}^{l,d}, \dots, h_{a+\tau}^{l,d}, \dots, h_n^{l,d}] \quad (7)$$

$$z^l = [h_1^{l,s}, \dots, h_{a+1}^{l,s}, \dots, h_{a+\tau}^{l,s}, \dots, h_n^{l,s}] \quad (8)$$

在聚合模块的最后一层，形成最终的聚合嵌入。

$$h^l = x^l \odot z^l$$

1.2.4 融合双头注意力机制的情感极性分类层

为了更好地检测和预测句子 S 中特定方面属性的情感极性并进行分类，A-LSGCN 模型在情感极性分类层中采用门控机制对流向给定方面属性 aspect 的情感信息进行筛选和控制。

$$\alpha_i = \tanh(h^L + h_i^L W_{ga} + b_{ga}), h^L = h^L * \alpha_i \quad (9)$$

其中： h_i^L 是 h^L 中的方面属性， W_{ga} 和 b_{ga} 分别是权重和偏差。

然后，在门控嵌入中屏蔽非方面属性内容并保持方面属性字不变，由此得到零掩码嵌入。零掩码嵌入 h_i^l 与 h_i^l 之间为全连接层，以保持与 Z 相同的维数。

$$[0, \dots, h_{a+1}^l, \dots, h_{a+\tau}^l, \dots, 0] \in R^{dx} \quad (10)$$

经过门控和掩码处理后，全局检索语义与方面属性词相关的特征作为重要显著特征，并为方面属性词与其每个上下文词间的相互影响设置基于检索的注意权重因子。 S 最终表示为 P 。

$$\theta_i = \sum_{i=1}^{i=1} z_i^T h_i^l, \gamma_i = \frac{\exp(\theta_i)}{\sum_n \exp(Q_i)} \quad (11)$$

$$P = \sum_{i=1}^{i=1} \gamma_i z_i \quad (12)$$

其中： z_i 是双 LSTM 嵌入 $Z_i \in R^{N+dx}$ 。

1.3 损失函数选择

模型使用 BCE With Logits Loss 函数：

$$\text{loss} = \frac{1}{N} \sum_N l_n \quad (13)$$

其中： l_n 为第 n 个样本对应的 loss。

$$l_n = \frac{1}{M} \sum_M l_n^i$$

$$l_n^i = -w_i [y_n^i \cdot \log x_n^i + (1 - y_n^i) \cdot \log(1 - x_n^i)] \quad (14)$$

w_i 是超参数，用于处理标签间的样本不平衡问题。对于一批训练集，若其中某个标签的出现次数较少，计算 loss 时应该给予更高的权重。

1.4 A-LSGCN 评价指标

对于语料库中给定的评论句和一组方面属性，A-LS-GCN 模型在预测所有“实体#方面属性”组的情感极性前，需要先识别评论中的目标实体及其相应的方面属性。例如，针对句子“The sandwiches and sushi is delicious but the waiter is very rude”，模型对方面属性进行检测和处理后输出“RESTAURANT#SERVICES”为消极，输出“FOOD#QUALITY”为积极。

由于样本存在不平衡性，句子 S 中包含的多个方面属性存在精确度和召回率产生无法忽视的偏差，因此 A-LS-GCN 模型采用准确率 (Acc) 和 F1 分数的宏平均值 (Macro average F1, 即 MF1) 作为评价指标。其中，Acc 评价 A-LSGCN 模型的分类的准确率，定义为正确分类的样本数在样本总数量的比例；MF1 是评估模型性能的综合指标。并且，为了更加准确地刻画模型的有效性，实验过程中严

格控制评测方式。

根据以上语料库样本分类的可能情况, 准确率计算公式如下:

$$Accuracy = \frac{\sum_{i=1}^m TP_i}{\sum_{i=1}^m (TP_i + FP_i + FN_i)} \quad (15)$$

$$\begin{cases} Precision = \frac{TP}{TP + FP} \\ Recall = \frac{TP}{TP + FN} \\ F1 = \frac{2 * Precision * Recall}{Precision + Recall} \\ MF1 = \frac{1}{m} \sum_{i=1}^m F1_i \end{cases} \quad (16)$$

对于单个类别, 式中 TP 表示被正确预测的语料样本数量; FN 是当前的类别被预测成其他类别语料样本的数量; FP 是其他类别的语料样本被预测为当前语料样本的数量。

2 实验与结果分析

2.1 A-LSGCN 实验环境与数据集配置

实验环境配置如表 1 所示。

表 1 实验环境配置

实验环境	环境配置
操作系统	Ubuntu 20.04
CPU	Intel Core i7-10875H
GPU	GEFORCE GTX1065Ti
内存	4 GB
编程语言	Python3.6.2
深度学习框架	PyTorch1.4.1

实验数据来自 SemEval 数据集 (即 Laptop14、Restaurant14、Restaurant15 和 Restaurant16)。评论中包含目标单词和目标单词的情感极性, 数据集统计信息如表 2 所示。

表 2 实验数据集配置

数据集 ^①	积极		中性		消极	
	训练	测试	训练	测试	训练	测试
Laptop14	997	341	464	169	870	128
Restaurant14	2 164	728	637	196	807	196
Restaurant15	912	326	36	34	256	182
Restaurant16	1240	469	69	30	439	117

注: ①实验数据来自 SemEval 数据集包括 Laptop14、Restaurant14、Restaurant15 和 Restaurant16。

为了更好地学习语料库数据的文本结构的特征信息, 在使用预训练词典时附加维度为 300 的位置嵌入。实验数据样例如表 3 所示。

2.2 实验流程及实验参数设置

实验分为数据预处理、图结构的生成和模型训练及调整 3 个步骤, 实验流程如表 4 所示。

表 3 实验数据样例

数据库语料样例
The sandwiches and sushi is delicious but the waiter is very rude
<AspectTerms>
<AspectTerm="food"polarity="positive">
<AspectTerm="service"polarity="negative">
/<AspectTerms>

表 4 实验流程

实验流程	细节说明
数据预处理	1)格式处理;2)附加 30 维的词性编码和相对位置编码;3) 数据库语料多为短文本,故在词嵌入后把文本向量的长度补全至当前所在 batch 最大值。
图结构生成	使用 SpaCy 工具包进行句法依存树的获取及权重增强。
模型训练与调整	预先设置最大训练轮次为 100,并引入早停机制(倘若连续 5 个轮次训练损失函数值,即 loss 值未改变时进行早停)。

其中, 数据库中评价文本包含口语和部分缩略词, 其表示内容很难与书面表达完全符合。因此, 实验前首先需要实验数据进行清洗和规范化, 包括改写缩略词、去除不规则标点符号等操作, 使文本更规则和严谨。

以 Restaurant16 数据集为例对比不同优化器 (包括 Adagrad、Adam、Ada-max、ASGD 和 RMSprop 优化器) 对 A-LSGCN 模型的性能影响, 使用不同优化器训练损失值散点图、训练时长对比、准确率及 MF1 分数对比如图 4 所示。

由图 4 可见 Adam 优化器损失函数值方差较小, 且仅需 56 轮便可训练完成, 可兼顾训练速度和精确率, 因此为加快模型收敛使用 Adam 优化器。

使用 GloVe 预训练好的词向量进行 A-LSGCN 模型的语料上下文和方面属性词的初始化。BiLSTM 的隐藏层大小为 300。使用 Dropout 和 L2 正则项减少过拟合, 使用均匀分布进行 A-LSGCN 模型的权重初始化, 实验参数如表 5 所示。

表 5 参数设置

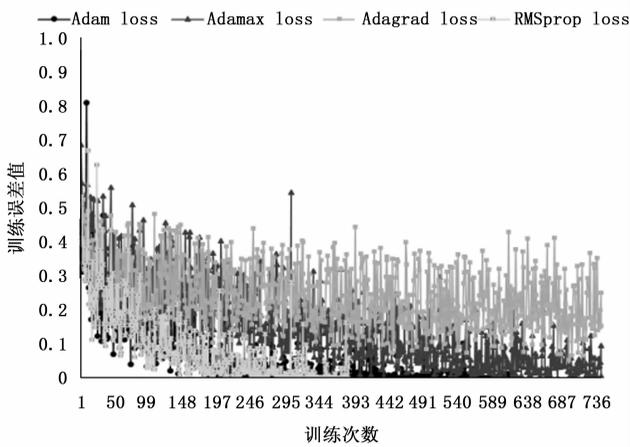
参数	值	参数	值
词向量维度	300	Dropout	0.3
隐藏层大小	300	L2 正则项	10^{-5}
Batch Size	32	优化器	Adam
GCN 层数	2	学习率	10^{-3}

2.3 基线模型选择与实验结果分析

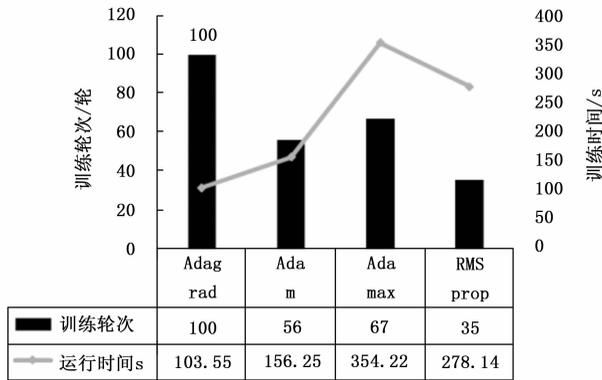
选用的对比基准模型包括基于注意力机制的 ABSA 方法和基于图和语法的 ABSA 分析模型, 将 A-LSGCN 模型与以下 7 个基线进行对比。

2.3.1 基于基于注意力机制的方法

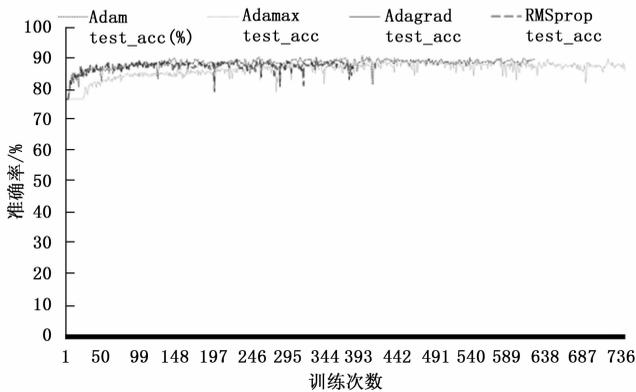
MemNet^[8]通过注意力机制融合句子的位置特征信息设



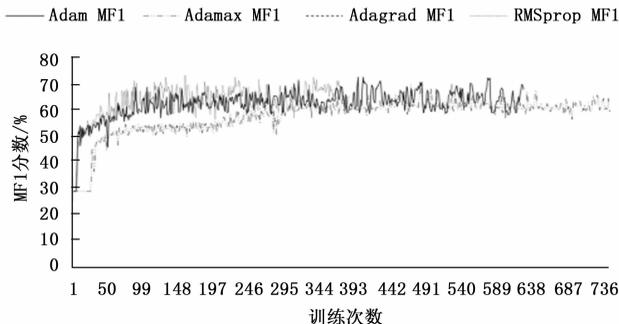
(a) 不同优化器训练损失图



(b) 不同优化器训练时长对比图



(c) 不同优化器准确率对比



(d) 不同优化器MF1分数对比

图 4 使用不同优化器时 A-LSGCN 性能对比改图

计深度注意网络，从而对属性级情感极性进行检测分类，最终在多个公开数据集上的分类效果表明该模型在传统 LSTM 模型的基础上，其检测和分类效果有一定提升。

IAN^[10]考虑方面属性词和语料观点词之间的相互影响和交互性，以此为解决思路融合方面属性词和整句语义并使二者进行交互，从而实现了方面级情感的检测。

AOA^[12]借鉴机器翻译领域的 AOA (attention-over-attention) 机制并将其融入方面级情感分析。通过引入 AOA 模块，方面级情感检测和分析模型可以同时学习方面属性和句子的表示形式，并自动关注句子中的重要部分，从而取得很好的分类效果。

2.3.2 基于图和语法的方法

RepWalk^[9]建立的神经网络模型通过在句法依存树上随机遍历搜寻与方面级情感极性相关的特定子树，从而模型得到了更加准确的上下文信息。

TD-GAT^[10]提出了一种图注意网络来明确利用词之间的依赖关系。

ASGCN^[14]使用 GCN 与句法依存树融合建立属性词和语义信息的表达形式，并考虑二者间的相互影响，使用注意力机制对二者进行交互。但不够充分的词性信息是模型检测和分类效果提升不显著的主要原因。

CDT^[15]是一组结合了图卷积和 Bi-LSTM 模型的轻量级情感分析模型，其中融合了句法信息、词性信息、相对位置信息及语义的特征信息，最终在缩短模型训练代价的同时提升了方面级情感分析的分类效果。

ASGCN 由于词性信息的缺失使得效果并没有很好的提升，CDT 在缩短模型训练代价的同时取得了良好的分类效果。A-LSGCN 与其它模型方法的对比如图 5 所示。

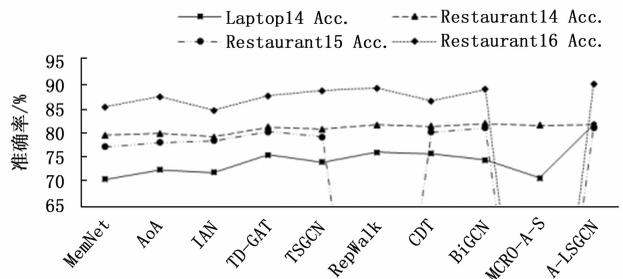


图 5 A-LSGCN 与其它模型准确率对比

在所选公开数据集上的实验结果对比如表 6 所示。

由表 6 可见，A-LSGCN 模型在 Laptop14、Restaurant14、Restaurant15、Restaurant16 数据集上 MF1 值分别提升了 1.1%、1.14%、1.77 和 0.84%，准确率分别提升了 5.5%、0.3%、0.21 和 0.90%，实验结果验证了 A-LSGCN 模型的有效性，且精确度和 MF1 分数均超过基线模型。

3 结束语

目前方法大多使用注意力机制隐性建模属性-情感表达关系，而忽略了语法信息和句法依存信息的问题。因此，

表 6 准确性和 MF1 (%) 对比

模型	Laptop14		Restaurant14		Restaurant15		Restaurant16	
	Acc.	MF1	Acc.	MF1	Acc.	MF1	Acc.	MF1
AOA	72.62	67.52	79.97	70.42	78.17	57.02	87.5	66.21
IAN	72.05	67.38	79.26	70.09	78.54	52.65	84.74	55.21
TD-GAT	75.63	70.74	81.32	71.72	80.38	60.50	87.71	67.87
ASGCN	74.14	69.24	80.86	72.19	79.34	60.78	88.69	66.64
Rep Walk	<u>76.2</u>	<u>72.32</u>	81.72	<u>73.86</u>	N/A	N/A	89.2	<u>71.2</u>
CDT	75.89	71.84	81.46	73.59	80.25	61.92	86.65	70.18
BiGCN	74.59	71.84	81.97	73.48	<u>81.16</u>	<u>64.79</u>	<u>88.96</u>	70.84
MCRO-A-S	70.92	68.14	81.69	72.66	N/A	N/A	N/A	N/A
A-LSGCN	81.7 (+5.5)	73.33 (+1.01)	<u>81.87</u> (-0.1)	74.63 (+0.77)	81.18 (+0.02)	65.93 (+1.14)	90.10 (+0.90)	72.04 (+0.84)

注:表中每个数据集上的最佳结果以粗体显示,效果次之的使用双下划线标出。

为了提高方面级别的情感检测方法准确率,设计了融合词汇-句法图卷积的神经网络分类模型(A-LSGCN)。首先,该模型同时考虑句子句法结构和语料库共现信息,充分学习通用语法知识,减少了隐性建模导致的误差。其次,模型通过句法依存图神经网络提取句法结构信息,直接匹配方面属性及其情感表达,有效缓解了冗余信息对分类的干扰。A-LSGCN分类模型相较于8种主流模型,在保持相同分类速度的前提下,准确率和MF1分数均有所提升。A-LSGCN能够更好地解决细粒度情感分类问题,效果更贴近于实用性。

方面级情感分析可推广应用至新兴的自动驾驶行业,例如封闭场景内的自主载人车。自主载人车实施服务需要机器人与人达成一致共识,从而保证服务的合法性及责任的追溯。方面级情感分析可结合无人车接受模型与方面级情感分析进行承载合约的达成度计算,实现基于方面级情感分析模型承载合约自动形成方法。

参考文献:

- [1] ZHANG T, TAO D, QU X, et al. Automated vehicle acceptance in China: social influence and initial trust are key determinants [J]. *Transportation Research Part C: Emerging Technologies*, 2020, 112: 220-233.
- [2] MANEK A S, SHENOY P D, MOHAN M C, et al. Aspect term extraction for sentiment analysis in large movie reviews using Gini index feature selection method and SVM classifier [J]. *World Wide Web-internet & Web Information Systems*, 2017, 20 (2): 135-154.
- [3] DONG L, W F, TAN CH, et al. Adaptive recursive neural network for target-dependent twitter sentiment classification [C] // *Proc. of the 52nd Annual Meeting of the Association for Computational Linguistics (volume 2: Short papers)*. Baltimore, Maryland: Association for Computational Linguistics Press, 2014: 49-54.
- [4] KUMAR R, PANNU H S, MALHI A K. Aspect-based sentiment analysis using deep networks and stochastic optimization [J]. *Neural Comput. & Applic.*, 2020, 32: 3221-3235.
- [5] XUE W, LI T. Aspect based sentiment analysis with gated convolutional networks [C] // *Annual Meeting of the Association for Computational Linguistics (ACL)*, 2018: 2514-2523.
- [6] 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.
- [7] YAO L, RONG H, CHU C, et al. Mining aspects in online comments with attention and Bi-LSTM [C] // *2019 5th International Conference on Big Data Computing and Communications (BIGCOM)*, 2019: 288-292.
- [8] TANG D, QIN B, FENG X, et al. Effective LSTMs for target-dependent sentiment classification [C] // *International Conference on Computational Linguistics*, 2016: 3298-3307.
- [9] ZHENG Y, ZHANG R, MENSAH S, et al. Replicate, walk, and stop on syntax: an effective neural network model for aspect-level sentiment classification [J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020, 34 (5): 9685-9692.
- [10] MA D, LI S, WANG X, et al. Interactive attention networks for aspect-level sentiment classification [C] // *26th International Joint Conference on Artificial Intelligence*, 2017.
- [11] GU S, ZHANG L, HOU Y, et al. A position-aware bidirectional attention network for aspect-level sentiment analysis [C] // *Proceedings of the 27th International Conference on Computational Linguistics*, 2018: 774-784.
- [12] Huang B, YANG L, 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*, Springer, 2018: 197-206.
- [13] THOMAS N K, MAX W. Semi-supervised classification with graph convolutional networks [C] // *International Conference on Learning Representations (ICLR)*, 2017: 24-26.
- [14] ZHANG C, LI Q, SONG D. Aspect-based sentiment classification

cation with aspect-specific graph convolutional networks [C] //Conference on Empirical Methods in Natural Language Processing (EMNLP), 2019; 4560 - 4570.

[15] SUN K, ZHANG R, MENSAH S, et al. Aspect-level sentiment analysis via convolution over dependency tree [C] // Proceedings of the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP), 2019; 5678 - 5687.

[16] ZHANG M, QIAN T. Convolution over hierarchical syntactic

and lexical graphs for aspect level sentiment analysis [C] // Proceedings of the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP), 2020; 3540 - 3549.

[17] 巫浩盛, 缪裕青, 张万桢, 等. 基于距离与图卷积网络的方面级情感分析 [J]. 计算机应用研究, 2021, 38 (11): 3274 - 3278, 3321.

[18] 陈昌浩, 范太华. 改进的 HMM 模型在特征抽取上的应用 [J]. 计算机测量与控制, 2018, 26 (4): 217 - 220.

(上接第 16 页)

由、灵活、便携移动的突出优势, 极其方便地对处于包装箱内的装备进行测试。其典型功能包括: 测试激励加载、响应信息获取与显示, 故障隔离和修理指导。此外, 小型测试设备具有无线联网功能, 借助无线技术可以利用厂房内的无线局域网将测试数据通过设在技术阵地的中心服务器进行发布, 或对武器装备历次测试数据进行查询与分析, 或与位于远方的中央数据库和技术专家相连接, 为维修人员根据需要随时随地获取必要的数据和专家的远程技术支持提供了便利条件;

2) 组合化测试设备的组合化是指一套测试设备通过增加或减少相应的软硬件模块实现不同的测试功能。包含两个方面的含义: (1) 横向组合, 即通过改变软硬件结构实现对不同型号装备的测试, 主要是增加或减少与特定装备密切相关的专用设备; (2) 纵向组合, 即通过改变软硬件结构实现同一种武器装备在不同维修级别的场所的测试。就目前常见的三级维护模式而言, 装备在基层级、中继级和基地级所使用的设备在核心部分不变的情况下, 设备的数量会逐渐增多, 功能会逐渐增强, 故障定位深度则逐渐加深。组合化的测试设备对确保测试的连续性、减少测试设备的种类和数量, 减少备件数量和人力资源方面都有着非常重要的意义;

3) 测试设备的综合化发展包括技术综合化和应用综合化。技术综合化指未来的测试设备开发所采用的技术可能包括故障诊断、专家系统、神经网络、模糊逻辑, 还可能融合了计算机网络、仿真、虚拟现实等各项技术, 技术应用是综合化的。应用综合化指测试设备不仅局限于武器装备在技术阵地的测试功能, 还可用于装备健康管理与预测、维修计划与保障策略制定等环节活动。

测试设备作为一种集软硬件、声光机电、微波技术、模拟技术、数字技术等多种技术于一身的复杂产品, 要真正满足用户的“好用、管用、顶用”要求, 今后还需做大量深入的技术研究和开发工作。

参考文献:

[1] 卢宁波, 齐亮, 姜泽伟. 一种便携式低成本通用并行测试设备研制 [J]. 计算机测量与控制, 2020, 28 (10): 60 - 65.

[2] 苏群星, 解璞, 贾长治. 基于自动测试系统的故障诊断专家

系统 [J]. 计算机测量与控制, 2003, 11 (1): 11 - 13.

[3] 于劲松, 李行善. 下一代自动测试系统体系结构与关键技术 [J]. 计算机测量与控制, 2005, 13 (1): 1 - 3.

[4] 陈永奇, 马迎建, 石多. 1553B 总线应用 [J]. 电子测量技术, 2006 (5): 211 - 212.

[5] 董文岳, 蒋晓华, 颜军. 便携式 1553B 总线测试系统的设计与实现 [J]. 军民两用技术与产品, 2011 (10): 54 - 56.

[6] 孙志军, 纪晓辉. 基于 PXI 总线通用测试系统的设计 [J]. 电子测试, 2016 (16): 20 - 21.

[7] 娄宇, 欧阳晓峰. 基于 PXI 总线的导弹测试系统设计 [J]. 计算机测量与控制, 2015, 23 (3): 828 - 830, 846.

[8] 罗锦, 孟晨, 杨锁昌. 基于 VXI 总线的导弹自动测试系统设计 [J]. 国外电子测量技术, 2002 (2): 6 - 8.

[9] 刘阳, 李玺. 某型导弹测试系统模块化设计 [J]. 火力与指挥控制, 2015 (7): 168 - 169.

[10] 梅寒剑, 某发射装置便携测试设备的设计与实现 [J]. 计量与测试技术, 2018, 45 (2): 42 - 44.

[11] 李宝安, 李行善. 自动测试系统 (ATS) 软件的发展及关键技术 [J]. 宇航总体技术, 2018, 2 (3): 38 - 45.

[12] 孟文龙, 陈明. 基于数据库的自动测试系统 (ATS) 软件 [J]. 测控技术, 2004, 23 (9): 55 - 56.

[13] 张军清, 金旗. 基于 PXI 模块化仪器系统的某导弹控制箱自动测试系统 [J]. 通信与电子测试, 2001 (3): 48 - 49.

[14] 曹威. VXI 总线在导弹综合测试系统的应用 [J]. 现代防御技术, 2002 (2): 49 - 56.

[15] 安宏勇, 范祥辉, 武坚. 一种 1553B 总线接口模块测试设备的设计与实现 [J]. 电脑知识与技术, 2016, 12 (25): 168 - 170, 174.

[16] 刘福军, 蔡德咏, 孟晨, 等. 下一代自动测试系统体系结构研究进展 [J]. 计算机测量与控制, 2015, 23 (2): 339 - 341.

[17] 于雅丽, 陈锦莉. 1553B 通信研究及其在导弹测试系统中的应用 [J]. 计算机测量与控制, 2009 (2): 360 - 362.

[18] 潘安君, 奚全生, 孟汉城, 等. 综合测试与故障诊断技术发展及对策 [J]. 计算机测量与控制, 2011, 19 (1): 1 - 6.

[19] 张科, 陈之光, 田海宝. 综合测试与故障诊断一体化平台研究与设计 [J]. 计算机测量与控制, 2013, 21 (10): 2634 - 2637.

[20] 张建东, 李志浩. 基于 1553B 总线的通用测试系统设计 [J]. 测控技术, 2013, (11): 115 - 118.