·人工智能与模式识别·　　文章编号：1000-3428(2023)04-0061-07　　文献标志码：A　　中图分类号：TP391

结合依存图卷积与文本片段搜索的方面情感三元组抽取

徐　康，李　霏，姬东鸿

（武汉大学 国家网络安全学院 空天信息安全与可信计算教育部重点实验室，武汉 430040）

摘　要：现有基于序列标注或文本生成的三元组抽取模型通常未考虑完整文本片段级别的交互，且忽略了句法知识的应用。为解决上述问题，提出一种基于依存图卷积与文本片段搜索的深度学习模型来联合抽取方面情感三元组。通过预训练语言模型BERT编码层学习句子中每个单词的上下文表达，同时利用图卷积神经网络学习句子单词之间的依存关系和句法标签信息，以捕获远距离的方面词与观点词之间的语义关联关系，并采用文本片段搜索构造候选方面词与观点词及其特征表示，最终使用多个分类器同时进行方面词与观点词抽取及情感极性判断。在ASTE-Data-V2数据集上的实验结果表明，该模型在14res、14lap、15res和16res子集上的F1值相比于JET模型提升了10.61、10.54、4.91和8.48个百分点，具有较高的方面情感三元组抽取效率。

关键词：方面情感三元组抽取；图卷积神经网络；深度学习；依存句法分析；文本片段搜索

开放科学（资源服务）标志码（OSID）：

中文引用格式：徐康，李霏，姬东鸿．结合依存图卷积与文本片段搜索的方面情感三元组抽取[J]．计算机工程，2023，49(4)：61-67.

英文引用格式：XU K，LI F，JI D H.Aspect sentiment triple extraction by combining dependency graph convolution and text span search[J].Computer Engineering，2023，49(4)：61-67.

Aspect Sentiment Triple Extraction by Combining Dependency Graph Convolution and Text Span Search

XU Kang，LI Fei，JI Donghong

（Key Laboratory of Aerospace Information Security and Trusted Computing，Ministry of Education，School of Cyber Science and Engineering，Wuhan University，Wuhan 430040，China）

【Abstract】Existing studies on the extraction of aspect sentiment triples mostly employ methods based on sequence tagging or text generation. These methods consider neither the interactions at the span pair level nor the application of syntactic knowledge. To address these problems，this study proposes a deep learning model based on dependency graph convolution and text span search to jointly extract aspect sentiment triples. The model first learns the contextual representation of each word in a sentence through the Bidirectional Encoder Representations from Transformers（BERT）coding layer. It then utilizes a graph convolutional neural network to learn the dependencies and syntactic label information in words to capture the semantic associations between distant aspect terms and opinion terms. It also uses text span search to construct candidate aspect and opinion terms and their feature representations. Finally，the model extracts aspect and opinion terms and sentiment polarity simultaneously using multiple classifiers. Experiments on the Aspect Sentiment Triple Extraction（ASTE）-Data-V2 dataset show that the model improves F1 scores by 10.61，10.54，4.91，and 8.48 percentage points on the 14res，14lap，15res，and 16res subsets，respectively，as compared with the JET model，thus demonstrating its effectiveness.

【Key words】Aspect Sentiment Triple Extraction（ASTE）；graph convolution neural network；deep learning；dependency syntactic parsing；text span search

DOI：10. 19678/j. issn. 1000-3428. 0064558

0　概述

方面级情感分析（Aspect-Based Sentiment Analysis，ABSA）是一种细粒度的情感分析技术[1]，目的是识别方面术语、对应的情感极性和意见术语[2]，广泛应用于商品评论、公众观点分析等任务。国际语义评

基金项目：国家自然科学基金（62176187）；国家重点研发计划（2017YFC1200500）；教育部哲学社会科学研究重大课题攻关项目（18JZD015）；教育部人文社科青年基金（22YJCZH064）；湖北省自然科学基金（2021CFB385）。

作者简介：徐　康（1996—），男，硕士研究生，主研方向为自然语言处理；李　霏，副研究员、博士；姬东鸿，教授、博士。

收稿日期：2022-04-26　　**修回日期：**2022-06-08　　**E-mail：**xukang0531@whu.edu.cn

计算机工程 www.ecice06.com

测大会SemEval从2014年起连续3年将ABSA任务作为其子任务并提供了一系列人工标注的基准数据集[3-5]。但由于现有方面级情感分析研究主要关注方面词抽取[6-8]、基于方面词的情感极性分类[9-11]、观点词抽取[12-13]、方面词和观点词的共同抽取等子任务[14-16]，然而针对这些子任务均仅解决了细粒度情感分析任务的某一方面，并没有为其提供完整的解决方案，因此文献[1]提出方面情感三元组抽取(Aspect Sentiment Triplet Extraction，ASTE)任务。该任务的目标是从用户评论中抽取形如(What，How，Why)这样的三元组集合，其中：What代表评论的目标，即方面词；How代表用户对于评论目标表达的情感极性；Why代表体现相应情感极性的原因，即观点词。例如，从用户评论“the food is not comforting，not appetizing and uncooked.”中，可以抽取(food，negative，not comforting)、(food，negative，not appetizing)、(food，negative，uncooked)三元组集合来刻画用户对于“food”品质的综合评价。此外，文献[1]建立两阶段框架来处理该任务：在第一阶段中，通过序列标注的方法从输入句子中分别抽取带有情感极性的方面词和观点词；在第二阶段中，通过分类器来选择合适的方面词和观点词进行组合。然而，该方法存在两方面的问题：一方面，在第一阶段中将方面词与情感极性相结合的标注方法会导致模型训练和优化过程过于复杂；另一方面，这种基于流水线方式的两阶段方法容易受到错误传播的影响。

近年来，学者们陆续提出了基于序列标注[17]、基于文本生成[18-19]、基于阅读理解[20-21]、基于文本片段[22]等端到端ASTE方法，然而在这些方法中：基于序列标注的方法仅考虑了单个单词的信息而忽略了情感词整体的信息，因此不能很好地处理由多个单词组成的情感词；基于文本生成和阅读理解的方法需要对原始任务进行一定程度的改造，并为其设计相应的问题模板，增加了任务的复杂性；基于文本片段的方法[22]虽然在预测情感极性时考虑了情感词的完整文本片段的信息，但忽略了依存句法分析在ASTE任务中的重要作用。文献[9-11]利用图神经网络来学习与特定方面词相关的上下文，进而判断特定方面词的情感极性。然而，这些方法并没有考虑到依存句法标签的类别信息，同时也无法以端到端的方式从用户评论中抽取情感三元组。

为解决上述问题，本文提出一种基于依存句法知识与文本片段搜索的端到端方面情感三元组抽取模型ESYNM。该模型利用图卷积神经网络来学习单词之间的依存句法关系，建立方面词与观点词之间的远距离联系，基于依存句法标签的类别信息来判断观点词所表达的情感极性，同时利用文本片段搜索联合进行方面词、观点词预测和情感极性判断以提高计算效率，并在ASTE-Data-V2数据集上与多种基线模型进行实验对比。

1 相关工作

在方面级的情感分析任务中，现有研究多数仅关注细粒度情感分析任务的某一个子任务。文献[9-11]通过图卷积神经网络来学习依存句法树，然后利用单词之间的依存关系找到与特定方面词相关的句法上下文，进而判断情感极性。文献[23]设计一个双层交互式图卷积网络来融合层次句法图和词汇图。文献[24]提出双图卷积网络DualGCN来同时学习句法结构与语义相关性。文献[25]通过图注意力网络来融合句法知识，从而加强方面词之间的交互。

然而，单独处理细粒度情感分析任务的某一个子任务面无法进行整体的情感分析。因此，学者们开始考虑多个子任务的联合学习，包括方面词与观点词的共同抽取、方面词及其情感极性抽取[26-27]等。文献[14]使用基于依存树的递归神经网络来捕获方面词与观点词之间的双向传播关系。文献[16]建立一个融入规则的方面词和观点词共同抽取模型。文献[26]采用多目的的标注机制来同时抽取方面词和判定情感极性。

文献[1]提出方面情感三元组抽取任务，该任务旨在同时从句子中抽取方面词、观点词，以及与每个方面词相关的情感极性，基于SemEval 2014、2015和2016相关测评任务的数据集构造基准数据集ASTE-Data-V1。然而，文献[17]发现ASTE-Data-V1数据集遗漏了一个观点词对应多个方面词的情况，在ASTE-Data-V1数据集的基础上进行修正，发布了ASTE-Data-V2数据集。在ASTE任务中，早期工作主要采用流水线方式，例如CMLA+[1]、RINANTE+[1]和TwoStage[1]。这类方法的基本思想是使用统一的标签来抽取方面词和情感极性，同时基于BIO标注机制抽取观点词，然后通过分类器将带有情感极性的方面词与观点词配对。然而，这种将情感极性与方面词统一起来的多目的标注方案可能会导致模型特征学习和训练过程过于复杂，同时还存在错误传播问题。近年来，学者们提出了一些端到端方式的ASTE方法。文献[17]提出一个端到端的模型JET，该模型设计了一种基于位置感知的标注机制来考虑情感三元组各元素之间的交互信息，以端到端的方式直接输出情感三元组。然而，对于包含多个单词的方面词和观点词，JET模型并没有将其视为整体，而是逐个处理其中的每个单词，因此忽视了方面词和观点词的整体信息。为解决JET模型存在的问题，文献[22]提出基于文本片段的ASTE方法来考虑方面词与观点词在完整文本片段之间的交互。

除了上述方法之外，部分学者也开始尝试重新定义方面级情感分析任务，然后利用其他领域的方法来解决该问题。文献[18-19]将方面级情感分析的多个子问题重新定义为文本生成问题，然后使用预训练的文本生成模型来统一处理。文献[20]将方面情感三元组抽取任务转换为多轮机器阅读理解任务，通过3个轮次的问答从输入句子中得到相应的情感三元组。文献[21]将方面情感三元组任务转换为两个阅读理解问题，其中，一个负责完成方面词抽取，另一个负责完成情感分类和观点词抽取。然而，这些方法需要对原始任务进行重新定义，并依赖人工设计相应模板。

在上述工作中，基于文本片段搜索的ASTE方

计算机工程 www.ecicao.com

法[22]在基准数据集上表现最为优越，但忽略了句法知识在ASTE任务中的贡献。方面情感三元组抽取示例如图1所示。在依存句法树中，通过单词“comforting”与“food”之间的“nsubj”依存弧可以找到方面词“food”与观点词“not comforting”。同时，基于单词“not comforting”与“appetizing”之间的“dep”依存弧以及“appetizing”与“uncooked”的“conj”依存弧，可以进一步建立“food”与距离较远的观点词“appetizing”、“uncooked”之间的联系，从而生成正确的三元组集合。此外，在依存句法树中，还可以观察到“not”与“comforting”、“not”与“appetizing”之间均存在“neg”依存弧，这一信息有助于帮助模型判断观点词“not comforting”和“not appetizing”所表达出来的负面情感极性。

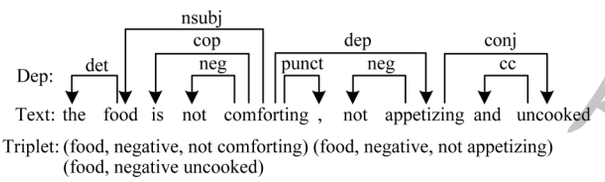


图1　方面情感三元组抽取示例

Fig.1　Example of aspect sentiment triplet extraction

基于上述研究，本文通过图卷积神经网络来学习单词之间的依存句法知识，进而帮助发现远距离的方面词、观点词及其情感极性。

2　基于依存图卷积与文本片段搜索的方面情感三元组抽取模型

本文提出的基于依存图卷积和文本片段搜索的ESYNM模型主要包含预训练语言模型BERT编码层、依存图卷积层、文本片段搜索层、方面词和观点词抽取模块和情感极性分类模块5个部分，如图2所示，其中$\boldsymbol{s}_k$代表第k个文本片段。

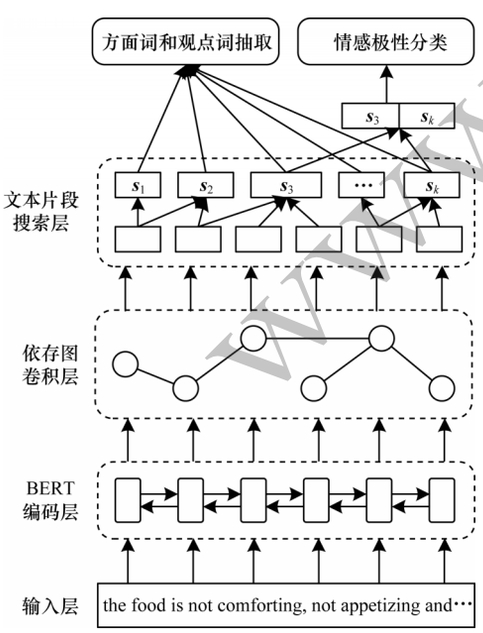


图2　ESYNM模型框架

Fig.2　Framework of the ESYNM model

2.1　BERT编码层

使用BERT对输入的句子进行编码。假设输入句子$\boldsymbol{X}$中包含N个单词，首先在句子$\boldsymbol{X}$前后分别添加特殊符号[CLS]和[SEP]，以满足BERT模型的输入要求，然后将其送入BERT模型学习输入句子中每个单词的上下文表达，最后将BERT模型最后一层的输出作为句子$\boldsymbol{X}$的深度向量表达，得到句子编码$\boldsymbol{H}$：

$$\boldsymbol{H}=\mathrm{BERT}\left([\mathrm{CLS}]\boldsymbol{X}[\mathrm{SEP}]\right) \tag{1}$$

其中：$\boldsymbol{H}=\{\boldsymbol{h}_0,\boldsymbol{h}_1,\cdots,\boldsymbol{h}_{N+1}\}$，$\boldsymbol{h}_0$代表特殊符号[CLS]的编码，可将其作为输入句子的全局上下文表达，用于后续任务。

2.2　依存图卷积层

经过BERT模型编码得到输入句子中每个单词的上下文向量表达后，基于单词之间的依存句法关系来构建依存句法图网络，然后使用图卷积神经网络来学习单词之间的依存句法知识。

对于依存句法树，将其建模为边带有标签的有向图$G=(V,E)$，其中，V代表图中节点的集合，E代表图中边的集合。$e_{i,j}=1(0)$代表节点i与j之间存在（不存在）依存关系。图卷积神经网络允许信息随着图中的边不断向远处传播，通过增加图卷积的层数可以帮助模型解决方面词和观点词距离较远的问题。依存图卷积层中第l层节点的更新方式如式(2)所示：

$$\boldsymbol{h}_i^{l+1}=\mathrm{ReLU}\left(\sum_{j=1}^{N}\boldsymbol{\alpha}_{i,j}\left(\boldsymbol{W}^l\cdot\boldsymbol{h}_j^l+\boldsymbol{b}^l\right)\right) \tag{2}$$

其中：$\boldsymbol{h}_j^l$代表句子中的第i个单词在第l层图卷积网络中的表达；$\boldsymbol{W}^l$和$\boldsymbol{b}^l$分别代表第l层图卷积网络的权重矩阵和偏置向量；$\boldsymbol{\alpha}_{i,j}$代表邻接强度分布。$\boldsymbol{\alpha}_{i,j}$计算如式(3)所示：

$$\boldsymbol{\alpha}_{i,j}=\frac{e_{i,j}^l\cdot\exp\left\{\left(\boldsymbol{h}_i^l\right)^{\mathrm{T}}\cdot\boldsymbol{h}_j\right\}}{\sum_{t=1}^{N}e_{i,t}^l\cdot\exp\left\{\left(\boldsymbol{h}_i^l\right)^{\mathrm{T}}\cdot\boldsymbol{h}_t\right\}} \tag{3}$$

2.3　文本片段搜索层

经过依存图卷积层学习句子中单词之间的依存句法关联之后，通过枚举所有可能的文本片段来生成候选方面词和观点词集合。

对于文本片段$\boldsymbol{s}_i=\{x_{\mathrm{start}(i)},\cdots,x_{\mathrm{end}(i)}\}$，它既可以是单个单词，又可以是由多个单词组成的短语，其中$\mathrm{start}(i)$和$\mathrm{end}(i)$分别代表文本片段$\boldsymbol{s}_i$在输入句子中的起始和终止索引。假设文本片段的最大长度为l_s，那么起止索引需满足条件：$1\leqslant\mathrm{start}(i)\leqslant\mathrm{end}(i)$和$\mathrm{end}(i)-\mathrm{start}(i)<l_s$。例如，当$l_s$设置为3时，给定句子“the food was delicious”，通过枚举可以得到“food”、“delicious”、“the food”、“food was”，以及“food was delicious”等候选文本片段。

在枚举候选文本片段过程中，会得到各种不同长度的文本片段。在用户评论中，方面词、观点词通常以较短的文本片段长度出现。因此，通过考虑文本片段的长度信息可以帮助模型排除错误的文本片段，进而提高抽取准确率。因此，在拼接文本片段的首尾单词向量表达和最大池化操作之后，额外添加一个文本长度特征向量$\boldsymbol{l}_i$，最终文本片段$\boldsymbol{s}_i$的向量表达$\boldsymbol{p}_i$如式(4)

计算机工程 www.ecice06.com

所示：

$$\boldsymbol{p}_i=\left[\text{maxpooling}\left(\boldsymbol{h}_{\text{start}(i)};\ \boldsymbol{h}_{\text{end}(i)}\right);\ \boldsymbol{l}_i\right] \tag{4}$$

2.4 方面词和观点词抽取模块

在得到候选文本片段的向量表达之后，通过方面词和观点词抽取模块来帮助模型正确识别方面词和观点词边界。该模块可以通过对所有文本片段进行并行预测来提高模型的计算效率。

在对候选文本片段进行预测时，为了利用输入句子的完整上下文信息，首先将文本片段向量$\boldsymbol{p}_i$与句子特征向量$\boldsymbol{h}_0$拼接起来得到向量$\boldsymbol{t}_i$，接着将$\boldsymbol{t}_i$送入前馈神经网络，最后由Softmax函数输出预测的文本片段类别概率$\boldsymbol{y}_{i,\text{AO}}$，计算过程如式(5)、式(6)所示：

$$\boldsymbol{t}_i=\left[\boldsymbol{p}_i;\ \boldsymbol{h}_0\right] \tag{5}$$

$$\boldsymbol{y}_{i,\text{AO}}=\text{Softmax}\left(\boldsymbol{W}_{\text{AO}}\cdot\boldsymbol{t}_i+\boldsymbol{b}_{\text{AO}}\right) \tag{6}$$

其中：$\boldsymbol{W}_{\text{AO}}$和$\boldsymbol{b}_{\text{AO}}$分别代表权重矩阵和偏置向量。

对于文本片段$\boldsymbol{s}_i$，其预测类别为最高概率所对应的类别。

2.5 情感极性分类模块

对于给定的候选文本片段对$\left(\boldsymbol{s}_i,\boldsymbol{s}_j\right)$，首先通过最大池化操作得到两者之间的局部上下文特征$\boldsymbol{c}_{i,j}$，然后将文本片段$\boldsymbol{s}_i$、$\boldsymbol{s}_j$的向量表达与$\boldsymbol{c}_{i,j}$进行拼接得到$P\left(\boldsymbol{s}_i,\boldsymbol{s}_j\right)$，最后由Softmax函数来输出预测的情感极性类别概率分布$\boldsymbol{y}_{(s_i,s_j),\text{SP}}$，具体计算过程如式(7)~式(9)所示：

$$\boldsymbol{c}_{i,j}=\text{maxpooling}\left(\boldsymbol{h}_{\text{start}(i)+1};\ \boldsymbol{h}_{\text{end}(j)-1}\right) \tag{7}$$

$$\boldsymbol{P}_{(s_i,s_j)}=\left[\boldsymbol{p}_i;\ \boldsymbol{p}_j;\ \boldsymbol{c}_{i,j}\right] \tag{8}$$

$$\boldsymbol{y}_{(s_i,s_j),\text{SP}}=\text{Softmax}\left(\boldsymbol{W}_{\text{SP}}\cdot\boldsymbol{P}_{(s_i,s_j)}+\boldsymbol{b}_{\text{SP}}\right) \tag{9}$$

其中：$\boldsymbol{W}_{\text{SP}}$和$\boldsymbol{b}_{\text{SP}}$分别代表权重矩阵和偏置向量。

对于候选文本片段对$\left(\boldsymbol{s}_i,\boldsymbol{s}_j\right)$，其预测的情感极性为最高概率所对应的类别。

2.6 损失函数

方面词与观点词抽取及情感极性判断两个子任务共享底层的BERT编码层、依存图卷积层、文本片段搜索层。在最顶层，两个任务分别通过各自独立的分类器，独立进行方面词和观点词的抽取，以及情感极性的判断。

对于方面词和观点词抽取，采用多分类交叉熵作为损失函数，如式(10)所示：

$$L_{\text{AO}}=-\sum_{i=1}^{k_1}\hat{\boldsymbol{y}}_{i,\text{AO}}\ln\boldsymbol{y}_{i,\text{AO}} \tag{10}$$

其中：k_1代表文本片段的类别数量；$\hat{\boldsymbol{y}}_{i,\text{AO}}$和$\boldsymbol{y}_{i,\text{AO}}$分别代表当前文本片段在类别$i$上的标准概率分布与预测概率分布。

对于情感极性分类，同样采用多分类交叉熵作为损失函数，如式(11)所示：

$$L_{\text{SP}}=-\sum_{i=1}^{k_2}\hat{\boldsymbol{y}}_{(s_i,s_j),\text{SP}}\ln\boldsymbol{y}_{(s_i,s_j),\text{SP}} \tag{11}$$

其中：k_2代表情感极性的类别数量；$\hat{\boldsymbol{y}}_{(s_i,s_j),\text{SP}}$和$\boldsymbol{y}_{(s_i,s_j),\text{SP}}$分别代表文本片段对$\left(\boldsymbol{s}_i,\boldsymbol{s}_j\right)$在情感极性类别$i$上的标准概率分布与预测概率分布。

最终损失函数为上述两部分损失函数的加权之和，如式(12)所示：

$$L=L_{\text{SP}}+\lambda L_{\text{AO}} \tag{12}$$

其中：λ代表超参数，用于控制方面词和观点词抽取模块的损失函数L_{AO}对最终损失函数L的影响。

3 实验设置

3.1 数据集

使用ASTE-Data-V2数据集[24]作为评测数据集，其标注语料来源于SemEval-2014 task 4[3]、SemEval-2015 task 12[4]和SemEval-2016 task 5[5]发布的相关数据集。该数据集包含了两个领域的用户评论，其中，14res、15res和16res子集来自Restaurant领域，14lap子集来自Laptop领域。

沿用文献[17]的数据集划分方式，将其分为训练集、验证集和测试集。数据集统计信息如表1所示，其中，S代表用户评论句子数量，POS、NEU、NEG分别代表情感极性为积极、中性以及消极的三元组数量。

表1 ASTE-Data-V2数据集统计信息

Table 1 Statistics of the ASTE-Data-V2 datasets 单位：个

数据集划分类型	14res				14lap				15res				16res			
	S	POS	NEU	NEG	S	POS	NEU	NEG	S	POS	NEU	NEG	S	POS	NEU	NEG
训练集	1 266	1 692	166	480	906	817	126	517	605	783	25	205	857	1 015	50	329
验证集	310	404	54	119	219	169	36	141	148	185	11	53	210	252	11	76
测试集	492	773	66	155	328	364	63	116	322	317	25	143	326	407	29	78

3.2 基线模型

CMLA+[1]：首先使用基于多层注意力机制的CMLA模型[20]来抽取带有情感极性的方面词和观点词；然后使用分类器来选择合适的方面词和观点词对。

RINANTE+[1]：首先使用基于依存关系挖掘方面词和观点词提取规则的联合模型RINANTE[22]来抽取带有情感极性的方面词和观点词；然后通过分类器来选择合适的方面词和观点词对。

TwoStage[1]：抽取情感三元组的过程可以分为两个阶段。第一阶段，采用序列标注的方法从用户评论中分别抽取带有情感极性的方面词和观点词；第二阶段，使用分类器为方面词选择合适的观点词。

JET[17]：基于一种新颖的位置感知的标注机制来考虑情感三元组中各个元素之间的交互信息，最终以端到端的方式从用户评论中抽取三元组。

BARTABSA[18]：首先对方面级情感分析的7个子任务进行重新定义，将其转化为文本生成问题；然后基

www.ecr.com 计算机工程

于预训练文本生成模型BART来统一处理所有的子任务。

SpanASTE[22]：利用基于文本片段的ASTE模型来进行文本片段级别的交互，并通过一种双通道剪枝策略来降低时间复杂度。

3.3　评价指标

采用精确率、召回率和F1值作为模型性能评价指标。在评测时，只有当抽取的三元组中方面词、观点词以及对应的情感极性都预测正确时，才将其视为正确的三元组。为了保证实验结果的可靠性，在实验过程中，在每个数据集上均采用不同的随机种子运行10次实验，然后取其平均值作为最终结果。

4　实验结果与分析

4.1　主要实验结果

表2给出了不同基线模型和本文提出的ESYNM模型在ASTE-Data-V2数据集上的实验结果。对于最优和次优结果，分别通过加粗和下划线标识。由表2可以得到以下结论：

1）JET、BARTABSA、SpanASTE、ESYNM等端到端模型在4个数据集的各项评测指标上的表现都远超CMLA+、RINANTE+、TwoStage等流水线模型。这说明相比于流水线方式，端到端方式既可以处理同一方面词存在不同情感极性的问题，又避免了流水线方式存在的错误传播问题，因此可以更好地处理ASTE任务。

2）尽管同为端到端模型，但基于文本片段的SpanASTE和ESYNM模型性能显著优于基于序列标注的JET和基于文本生成的BARTABSA模型。具体而言：ESYNM模型的F1值相比于JET模型在14res、14lap、15res、16res数据集上分别提升了10.61、10.54、4.91、8.48个百分点；相比于BARTABSA模型分别提升了7.76、2.89、3.18、4.69个百分点。这一结果证明了完整的文本片段级别的交互信息对于ASTE任务具有促进作用。

3）ESYNM和SpanASTE模型虽然都采用基于文本片段的方法，但ESYNM模型在14res、14lap、16res等3个数据集上的性能表现均优于SpanASTE模型，仅在15res数据集上略劣于SpanASTE模型。具体而言，ESYNM模型在14res、14lap、16res等3个数据集上的F1值相比于SpanASTE模型分别提升了1.16、2.20和2.05个百分点。这一结果证明了本文提出的使用图卷积神经网络来编码单词之间的依存句法知识的ESYNM模型在ASTE任务上的有效性。

表2　不同模型实验结果对比

Table 2　Comparison of experimental results of different models　%

模型	14res			14lap			15res			16res		
	精确率	召回率	F1值	精确率	召回率	F1值	精确率	召回率	F1值	精确率	召回率	F1值
CMLA+	39.18	47.13	42.79	30.09	36.92	33.16	34.56	39.84	37.01	41.34	42.10	41.72
RINANTE+	31.42	38.38	34.95	21.71	18.66	20.07	29.88	30.06	29.97	25.68	22.30	23.87
TwoStage	43.24	63.66	51.46	37.38	50.38	42.87	48.07	57.71	52.32	46.96	64.24	54.21
JET	70.56	55.94	62.40	55.39	47.33	51.04	**64.45**	51.96	57.53	70.42	58.37	63.83
BARTABSA	65.52	64.99	65.25	61.41	56.19	58.69	59.14	59.38	59.26	66.60	68.68	67.62
SpanASTE	**72.89**	70.89	71.85	**63.44**	55.84	59.38	62.18	64.45	**63.27**	69.45	71.17	70.26
ESYNM	71.47	**74.63**	**73.01**	62.25	**60.92**	**61.58**	60.06	**65.12**	62.44	**71.18**	**73.51**	**72.31**

4.2　消融实验

为了验证ESYNM模型中特征向量、文本片段长度特征向量和依存图卷积层对模型性能的影响，设计消融实验。在ASTE-Data-V2数据集上的实验结果如表3所示，其中，最优结果通过加粗标识。

表3　消融实验结果

Table 3　Results of ablation experiment　%

模型	F1值			
	14res	14lap	15res	16res
ESYNM	**73.01**	**61.58**	**62.44**	**72.31**
w/o [CLS]	72.24	60.79	61.82	71.68
w/o LenEmb	71.86	60.47	61.51	71.24
w/o Dep	70.26	60.18	60.25	70.13

由表3可以看出，3个模块都有助于提高模型的最终性能。具体而言：不使用句子特征向量（w/o［CLS］）后，模型在14res、14lap、15res以及16res数据集上的F1值分别下降了0.77、0.79、0.62、0.63个百分点；不使用文本长度特征向量（w/o LenEmb）后，模型在14res、14lap、15res、16res数据集上的F1值分别下降了1.15、1.11、0.93、1.07个百分点；删除了依存图卷积层（w/o Dep）后，模型性能下降最为明显，在4个数据集上的F1值分别下降了2.75、1.40、2.19、2.18个百分点。这一结果表明：句子特征向量和文本长度特征向量可以在一定程度上提高模型性能，但提升作用有限；依存句法知识的引入可以显著提升方面情感三元组的抽取效果。

4.3　图卷积层数对模型性能的影响

由于从消融实验结果可以看出依存图卷积层可以明显提高模型的抽取效果，因此进一步研究依存图卷积层中图卷积层数对模型性能的影响，实验结果如图3所示。在一般情况下，图卷积层数越多，模型捕获远距离的方面词与观点词之间的依存句法关系能力越强，方面情感三元组抽取效果也越好。由图3可以看出：当图卷积层数为2时，ESYNM模型可以取得最好的结果；当图卷积层数增加时，ESYNM模型在4个数据集上的指标却有所下降。这说明当

计算机工程 www.ecice06.com

信息传播的层数过多时,反而会导致模型学习到错误的句法知识,进而出现过拟合现象。

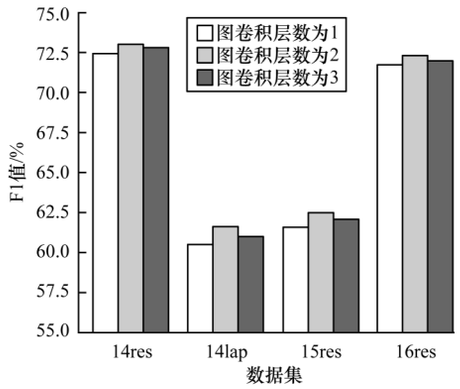


图3 图卷积层数对比

Fig.3 Comparison of the number of graph convolution layers

4.4 文本片段最大搜索长度对模型性能的影响

在基于文本片段的ASTE方法中,文本片段最大搜索长度对模型最终效果具有一定的影响。使用ASTE-Data-V2数据集中的4个测试集作为基准数据集,将文本片段最大搜索长度由1逐步增加到10分别进行实验,实验结果如图4所示。由图4可知,当最大搜索长度为2时,模型在4个测试集上均取得了最优结果。随着最大搜索长度的进一步增加,情感三元组抽取的F1值虽然偶有波动,但是整体均呈现下降的趋势。这一结果说明:较短的最大搜索长度足以帮助模型找到正确的方面词和观点词;过长最大搜索长度会生成过多的错误候选方面词和观点词,使得模型在方面词和观点词配对过程中生成较多的错误配对结果,最终导致模型性能下降。

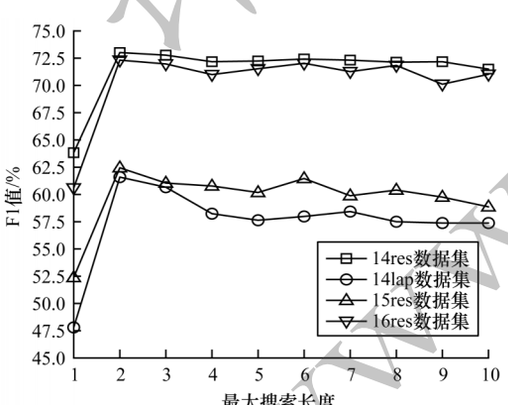


图4 最大搜索长度对比

Fig.4 Comparison of maximum search length

4.5 案例分析

通过以下案例来说明依存句法知识在ASTE任务中所起的作用,其中,Ground Truth代表标注的正确情感三元组,×用于标记错误情感三元组:

Example:Rice is too dry, tuna was n't so fresh either.

Ground Truth:(Rice, negative, too dry),(tuna, negative, was n't so fresh)

TwoStage:(Rice, negative, too dry),(tuna, negative, was n't so fresh),(Rice, negative, was n't so fresh)×,(tuna, negative, too dry)×

ESYNM w/o Dep:(Rice, negative, too dry),(tuna, negative, was n't so fresh),(Rice, negative, dry)×

ESYNM:(Rice, negative, too dry),(tuna, negative, was n't so fresh)

对于案例"Rice is too dry, tuna was n't so fresh either.":TwoStage模型除了生成正确的结果之外,还额外生成了两个错误的结果"(Rice, negative, was n't so fresh)"和"(tuna, negative, too dry)";删除了依存图卷积层的ESYNM模型(ESYNM w/o Dep),则由于生成了错误的观点词"dry",导致额外生成了一个错误的三元组;ESYNM模型由于学习了单词之间的依存关系,因此可以在方面词与观点词之间建立正确的联系,避免了TwoStage模型存在的错误配对情况,同时ESYNM模型还能利用句法标签类别信息来找到合适的观点词边界,以避免生成错误的情感三元组。

5 结束语

本文提出一种端到端的方面情感三元组抽取模型ESYNM,首先使用BERT模型对输入句子进行编码,然后基于对输入句子的依存句法分析结果构建依存句法图网络,同时通过图卷积神经网络来学习句子单词之间的依存关系和依存句法标签类别信息,最后从句子中抽取方面词和观点词并判断其情感极性。在ASTE-Data-V2数据集上的实验结果证明了ESYNM模型的有效性。但由于现有研究主要关注显式方面词和观点词,然而现实场景中包含了大量的隐式方面词和观点词,因此在后续工作中将研究包含隐式方面词和观点词的方面情感多元组抽取,进一步完善细粒度情感分析研究。

参考文献

[1] PENG H Y, XU L, BING L D, et al. Knowing What, How and Why: a near complete solution for aspect-based sentiment analysis[C]//Proceedings of AAAI Conference on Artificial Intelligence. Palo Alto, USA: AAAI Press, 2020: 8600-8607.

[2] 张佳慧. 融合位置信息与注意力机制的方面级情感分析研究[D]. 长春:吉林大学,2021.
ZHANG J H. Research on aspective-level sentiment analysis that merge position information and attention mechanism[D]. Changchun: Jilin University, 2021. (in Chinese)

[3] PONTIKI M, GALANIS D, PAVLOPOULOS J, et al. SemEval-2014 task 4: aspect based sentiment analysis[C]// Proceedings of the 8th International Workshop on Semantic Evaluation. Stroudsburg, USA: Association for Computational Linguistics, 2014: 27-35.

[4] PONTIKI M, GALANIS D, PAPAGEORGIOU H, et al. SemEval-2015 task 12: aspect based sentiment analysis[C]// Proceedings of the 9th International Workshop on Semantic Evaluation. Stroudsburg, USA: Association for Computational Linguistics, 2015: 486-495.

[5] PONTIKI M, GALANIS D, PAPAGEORGIOU H, et al. SemEval-2016 task 5: aspect based sentiment analysis[C]// Proceedings of the 10th International Workshop on Semantic Evaluation. Stroudsburg, USA: Association for Computational

Linguistics,2016:19-30.
[6] LI K,CHEN C B,QUAN X J,et al. Conditional augmentation for aspect term extraction via masked sequence-to-sequence generation[C]//Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. Stroudsburg, USA: Association for Computational Linguistics, 2020: 7056-7066.
[7] CHEN Z,QIAN T Y. Enhancing aspect term extraction with soft prototypes[C]//Proceedings of 2020 Conference on Empirical Methods in Natural Language Processing. Stroudsburg,USA:Association for Computational Linguistics, 2020:2107-2117.
[8] CHEN Z,QIAN T Y. Bridge-based active domain adaptation for aspect term extraction[C]//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. Stroudsburg, USA: Association for Computational Linguistics,2021:317-327.
[9] SUN K,ZHANG R C,MENSAH S,et al. Aspect-level sentiment analysis via convolution over dependency tree[C]// Proceedings of 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing. Stroudsburg, USA: Association for Computational Linguistics, 2019: 5679-5688.
[10] ZHANG C,LI Q C,SONG D W. Aspect-based sentiment classification with aspect-specific graph convolutional networks[C]//Proceedings of 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing. Stroudsburg,USA:Association for Computational Linguistics, 2019:4568-4578.
[11] TANG H,JI D H,LI C L,et al. Dependency graph enhanced dual-transformer structure for aspect-based sentiment classification[C]//Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. Stroudsburg, USA: Association for Computational Linguistics, 2020: 6578-6588.
[12] FAN Z F,WU Z,DAI X Y,et al. Target-oriented opinion words extraction with target-fused neural sequence labeling[C]// Proceedings of 2019 Conference of the North American Chapter of the Association for Computational Linguistics. Stroudsburg, USA: Association for Computational Linguistics,2019:2509-2518.
[13] BEN VEYSEH A P,NOURI N,DERNONCOURT F,et al. Introducing syntactic structures into target opinion word extraction with deep learning[C]//Proceedings of 2020 Conference on Empirical Methods in Natural Language Processing. Stroudsburg,USA:Association for Computational Linguistics,2020:8947-8956.
[14] WANG W Y,PAN S J,DAHLMEIER D,et al. Coupled multi-layer attentions for co-extraction of aspect and opinion terms[C]//Proceedings of AAAI Conference on Artificial Intelligence. Palo Alto, USA: AAAI Press, 2017: 3316-3322.
[15] YU J F,JIANG J,XIA R. Global inference for aspect and opinion terms co-extraction based on multi-task neural networks[J]. IEEE/ACM Transactions on Audio,Speech, and Language Processing,2019,27(1):168-177.
[16] DAI H L,SONG Y Q. Neural aspect and opinion term extraction with mined rules as weak supervision[C]// Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. Stroudsburg,USA:Association for Computational Linguistics,2019:5268-5277.
[17] XU L,LI H,LU W,et al. Position-aware tagging for aspect sentiment triplet extraction[C]//Proceedings of 2020 Conference on Empirical Methods in Natural Language Processing. Stroudsburg, USA: Association for Computational Linguistics,2020:2339-2349.
[18] YAN H,DAI J Q,JI T,et al. A unified generative framework for aspect-based sentiment analysis[C]//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. Stroudsburg, USA: Association for Computational Linguistics, 2021: 2416-2429.
[19] ZHANG W X,LI X,DENG Y,et al. Towards generative aspect-based sentiment analysis[C]//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. Stroudsburg,USA:Association for Computational Linguistics,2021:504-510.
[20] CHEN S W,WANG Y,LIU J,et al. Bidirectional machine reading comprehension for aspect sentiment triplet extraction[C]// Proceedings of AAAI Conference on Artificial Intelligence. Palo Alto,USA:AAAI Press,2021:12666-12674.
[21] MAO Y,SHEN Y,YU C,et al. A joint training dual-MRC framework for aspect based sentiment analysis[C]// Proceedings of AAAI Conference on Artificial Intelligence. Palo Alto,USA:AAAI Press,2021:13543-13551.
[22] XU L,CHIA Y K,BING L D. Learning span-level interactions for aspect sentiment triplet extraction[C]//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. Stroudsburg,USA:Association for Computational Linguistics,2021:4755-4766.
[23] ZHANG M,QIAN T. Convolution over hierarchical syntactic and lexical graphs for aspect level sentiment analysis[C]// Proceedings of 2020 Conference on Empirical Methods in Natural Language Processing. Stroudsburg,USA:Association for Computational Linguistics,2020:3540-3549.
[24] LI R,CHEN H,FENG F,et al. Dual graph convolutional networks for aspect-based sentiment analysis[C]//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics. Stroudsburg,USA:Association for Computational Linguistics,2021:6319-6329.
[25] 施荣华,金鑫,胡超. 基于图注意力网络的方面级别文本情感分析[J]. 计算机工程,2022,48(2):34-39.
SHI R H,JIN X,HU C. Aspect-level text emotion analysis based on graph attention network[J]. Computer Engineering, 2022,48(2):34-39. (in Chinese)
[26] LI X,BING L D,LI P J,et al. A unified model for opinion target extraction and target sentiment prediction[C]// Proceedings of AAAI Conference on Artificial Intelligence. Palo Alto,USA:AAAI Press,2019:6714-6721.
[27] LUO H S,LI T R,LIU B,et al. DOER:dual cross-shared RNN for aspect term-polarity co-extraction[C]//Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. Stroudsburg,USA:Association for Computational Linguistics,2019:591-601.

编辑 陆燕菲

计算机工程 www.ecice.com