

引文格式:宋红阳,朱小飞,郭嘉丰.基于强化依赖图的方面情感分类[J].太原理工大学学报,2022,53(2):248-256.

SONG Hongyang,ZHU Xiaofei,GUO Jiafeng. Aspect-based Sentiment Classification with Reinforced Dependency Graph[J]. Journal of Taiyuan University of Technology,2022,53(2):248-256.

基于强化依赖图的方面情感分类

宋红阳¹,朱小飞¹,郭嘉丰²

(1.重庆理工大学 计算机科学与工程学院,重庆 400054;2.中国科学院 计算技术研究所,北京 100190)

摘 要:提出基于强化依赖图的方面情感分类(reinforced dependency graph for aspect-based sentiment classification, RDGSC)模型。在模型中,使用深度强化学习训练了一个策略网络,参与生成与方面情感分类任务相适应的强化依赖图,在强化依赖图上使用图注意力网络学习文本中与方面相关的信息;通过基于检索的注意力机制,为每个上下文信息设置与方面相关的注意力权重,得到精简的最终表示用于分类,并计算延迟奖励指导策略网络的更新。在 5 个公开数据集上进行大量实验,实验结果表明,本文方法在两个评价指标 Accuracy 和上优于所有的基线方法。

关键词:自然语言处理;方面情感分类;深度强化学习;图注意力网络;依赖树

中图分类号:TP391 文献标识码:A

DOI:10.16355/j.cnki.issn1007-9432tyut.2022.02.008 文章编号:1007-9432(2022)02-0248-09

Aspect-based Sentiment Classification with Reinforced Dependency Graph

SONG Hongyang¹, ZHU Xiaofei¹, GUO Jiafeng²

(1. College of Computer Science and Engineering, Chongqing University of Technology, Chongqing 400054, China;

2. Institute of Computing Technology, Chinese Academy of Sciences, Beijing 100190, China)

Abstract: We proposed Reinforced Dependency Graph for Aspect-based Sentiment Classification (RDGSC), a reinforced dependency graph model for aspect-based sentiment classification. In this framework, we train a policy network using deep reinforcement learning and construct a reinforced dependency graph for aspect-based sentiment classification. The graph attention network is used to fuse the aspect-related information in the text over the reinforced dependency graph. Each contextual representation is given an aspect-related attention weight through a retrieve-based attention mechanism. A refined final representation is obtained for classification and calculating delayed reward to guide the policy network to updates. Extensive experiments were conducted on five publicly available datasets, the results show that our method is superior to all the baseline methods in two evaluation indicators Accuracy and F_1 .

Keywords: natural language processing; aspect-based sentiment classification; deep reinforcement learning; graph attention network; dependency tree

随着社交媒体和大数据的快速发展,情感分类 任务已经从计算机科学研究延伸到生产生活的方方

收稿日期:2021-08-21

基金项目:国家自然科学基金资助项目(62141201);重庆市技术创新与应用发展专项(cstc2020jcsx-dxwtBX0014);重庆市教委语言文字科研项目重点项目(yyk20103)

第一作者:宋红阳(1995-),硕士研究生,(E-mail)sunsong1995@2019.cqut.edu.cn

通信作者:朱小飞(1979-),教授,主要从事自然语言处理、数据挖掘及信息检索研究,(E-mail)zxf@cqut.edu.cn

面面,其巨大的发展前景和商业价值引起整个社会的共同关注。特别是商品评论,可以为买家购买商品提供参考信息,也是卖家挖掘商品不足从而进行改进的重要依据,而简单的分析用户对整个商品的情感倾向已无法满足商品改进的需求,针对不同方面挖掘用户更细腻的情感倾向,已经成为研究人员关注的热点。

方面情感分类(aspect-based sentiment classification, ABSC)作为情感分类的子任务,旨在挖掘文本在不同方面表达的更细腻的情感倾向,例如积极(positive)、中性(neutral)和消极(negative)^[1]。如图 1 所示,句子“Great place to relax and enjoy your dinner.”的方面词为“place”和“dinner”,根据语义分析,“place”的情感为积极的,认为这个地点是让人放松的好地方;而“dinner”则是中性的,即语句中没有对晚餐做出评价。

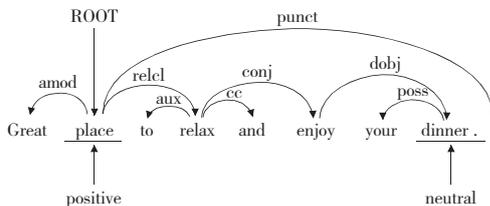


图 1 句法依赖树

Fig. 1 Syntactic dependency tree

方面情感分类的核心任务是在文本中找到与方面相匹配的情感表达。TANG et al^[1]提出使用注意力机制(Attention)和循环神经网络(recurrent neural network, RNN)建立上下文信息与方面词之间的关系,通过学习与方面相关的文本特征表示来实现情感分类;ZHANG et al^[2]使用句法依赖树(dependency tree)构造简单的句法依赖关系,并使用图卷积神经网络(graph convolutional network, GCN)^[3]融合句法信息和远距离单词之间的依赖关系,通过基于检索的注意力机制计算每个上下文信息的重要性;CHEN et al^[4]将句法依赖树和自诱导的方面特定图联系起来,通过自注意力机制结合句法依赖图和潜在图的相关信息,随后提取方面特征,计算明确方面的注意力用于方面情感分类。HOU et al^[5]认为句法依赖树生成的结果对情感分类具有显著的影响,而不同的句法解析器生成的句法依赖树不同,提出图的整体学习策略,将多个依赖树进行融合得到更有效的依赖关系图。

现有的方面情感分类模型对句法依赖树的准确率要求较高,但是句法依赖树不可避免包含与方面情感分类无关的噪音信息,这些噪音信息具体可分

为两种:一是与方面无关的噪音信息,当方面词为“place”时,“great”与“place”之间的关系类型“amod”(adjectival modifier, 即形容词的修饰符),对判断“place”的情感倾向至关重要,而当方面词为“dinner”时,这个关系为噪音信息,对判断“dinner”的情感倾向造成干扰;二是与任务无关的噪音信息,如“your”和“dinner”之间的关系类型“poss”(possession modifier, 即所有格),对判断“place”和“dinner”这两个方面词的情感倾向都没有积极的作用。这些噪音信息会干扰方面特征的提取,导致模型的注意力分散。而深度强化学习在提取相关信息时表现突出,ZHANG et al^[6]对句子的结构化信息进行建模,提取对分类有用的句子结构,用于文本分类。CHEN et al^[7]将文本摘要分为抽取和重写两个步骤,在抽取步骤使用深度强化学习在原始语料中筛选出信息丰富的句子,将抽取的句子进行重写得到摘要文本。因此,使用强化学习对句法依赖树的噪音信息进行删除,得到更适应方面情感分类的强化依赖图用于方面情感分类。

本文提出基于强化依赖图的方面情感分类(reinforced dependency graph for aspect-based sentiment classification, RDGSC)模型。首先,融合依赖词、依赖关系类型、被依赖词和方面词等信息作为状态表示。策略网络可以根据状态得到依赖关系的动作,从而生成一个强化依赖图。该依赖图学习了句子的方面信息和句法依赖关系,更适应方面情感分类任务。随后,在强化依赖图上使用图注意力网络(graph attention network, GAT)^[8],使方面词充分融合句法信息和远距离单词之间的依赖关系。最后,通过基于检索的注意力机制计算上下文信息的重要性,得到最终的文本表示进行分类,并计算延迟奖励指导策略网络的更新。

1 相关工作

1.1 方面情感分类

基于方面的情感分类任务是预测文本中一个或者多个方面的情感极性,方面主要是指句子中实体,包括具体事物(即食物、计算机等)或抽象事物(即环境、氛围等),情感极性表示句子表达的对方面的情感倾向,包括积极、中性和消极 3 种情感。TANG et al^[1]使用长短期记忆(long short-term memory, LSTM),通过捕获方面词与上下文之间的相关性生成文本表示用于分类。LI et al^[9]认为每个词对不同方面的重要性有所差异,将注意力机制引入模型

中,在提取上下文信息时对单词设置权重,根据权重与提取的上下文信息生成文本的表示,显著地提高了分类效果。但是在顺序模型中,依旧存在方面词与其对应的关键情感信息相对距离较远的问题。

1.2 图卷积分类应用

句法依赖树可以准确地表示输入文本中词与词之间的句法依赖关系,解决了顺序模型中无法有效提取相对距离较远的多个单词之间特征的问题。YAO et al^[10]根据句法依赖关系,将文档和单词作为节点,文档与文档、文档与单词之间的关系作为边,构建了一个大型图结构,将文档分类任务转化为文档节点分类任务,通过图卷积操作,使文档节点充分融合了与之相邻节点的特征,显著提高文档分类的效果。GHOSAL et al^[11]在对话情感分类任务、WANG et al^[12]在文档级情感分类任务中均使用句法依赖关系和相关任务的关系构造图结构,提取相对距离较远的单词或上下文之间的特征,生成更为丰富且准确的文本表示,完成相应的任务。在方面情感分类领域也应用了图结构,ZHANG et al^[2]使用句法依赖树构造句法依赖关系,并使用图卷积神经网络融合句法信息和远距离单词之间的依赖关系。CHEN et al^[4]将句法依赖树和自诱导的方面特定图联系起来,通过自注意力机制结合句法依赖图和潜在图的相关信息,提取方面的特征进行分类。LI et al^[13]同时考虑了语法结构和语义关系,构造两个不同的基于句法依赖树的图结构,融合不同的方面特征进行分类。然而由于自然语言的复杂性,句法结构中不可避免地存在与任务不相关的文本信息,对最终表示的生成造成负面影响,导致相关任务的精度下降。

1.3 深度强化学习

强化学习(reinforcement learning, RL)是通过智能体与环境相互作用,通过试错来学习最优策略,广泛用于自然、社会科学和工程等领域的顺序决策问题。深度强化学习则是将深度学习与强化学习结合,在自然语言处理任务中有着突出的贡献。FENG et al^[14]认为在关系提取任务中,远程监督标记的关系混杂着过多的噪音,他们使用深度强化学习筛选对关系提取任务有积极作用的样本,忽略无效样本,使用筛选后的样本对模型进行训练,有效提高相关任务的精度。CHEN et al^[7]将文本摘要分为抽取和重写两个步骤,在抽取步骤使用深度强化学习在原始语料中筛选出信息丰富的句子,随后通过 encoder-aligner-decoder 模型,将抽取的句子进

行重写,拼接得到摘要文本。ZHANG et al^[6]通过训练一个策略网络,对句子的结构化信息进行建模,充分利用句子的结构信息,生成更为精炼的文本表示进行文本分类。CHAI et al^[15]发现文本标签对文本分类有着积极的作用,通过深度强化学习对原始文本进行摘取,生成标签的描述,得到特征更为丰富的文本表示进行分类。深度强化学习在自然语言处理任务的信息提取方面有着杰出的表现,因此我们使用深度强化学习对句法依赖树进行信息筛选,旨在生成与方面相关的强化依赖图,提高方面情感分类的精度。

2 方法

本文提出的基于强化依赖图的方面情感分类模型 RDGSC 如图 2 所示。模型主要包含了两个部分:强化依赖图(reinforced dependency graph, RDG)和图注意力网络(graph attention network, GAT),首先提出强化依赖图方法,即使用深度强化学习对依赖树的句法依赖关系进行学习,然后在强化依赖图上通过图注意力网络进行方面情感分类。

2.1 强化依赖图

给定长度为 n 的句子,即 $X = \{x_1, \dots, x_{\tau+1}, \dots, x_{\tau+m}, \dots, x_n\}$,其中包含了从 $\tau+1$ 开始的 m 个方面词。对输入的句子 X ,通过词向量矩阵 $E \in R^{|V| \times d_e}$,其中 $|V|$ 为词汇表的大小, d_e 表示词嵌入的维度,映射到低维的向量空间 $H^w = \{h_1^w, \dots, h_{\tau+1}^w, \dots, h_{\tau+m}^w, \dots, h_n^w\}$, $h_i^w \in R^{d_e}$,同样的方法得到关系向量矩阵 $E^r \in R^{|V^r| \times d_r}$ 和词性向量矩阵 $E^p \in R^{|V^p| \times d_p}$ 。 $|V^r|$ 和 $|V^p|$ 分别表示关系和词性的个数, d_r 和 d_p 分别表示关系和词性的维度。

对于输入的句子 X ,使用句法解析器(spacy toolkit: <https://spacy.io/>)构造句法依赖树,得到邻接矩阵 $A \in R^{n \times n}$ 、每个单词的词性 $p, p \in R^{d_p}$ 以及词与词之间的关系类型 $r, r \in R^{d_r}$,将词嵌入表示 H^w 与词性 p 拼接,生成新的表示 $H^p = \{h_1^p, \dots, h_{\tau+1}^p, \dots, h_{\tau+m}^p, \dots, h_n^p\}$, $h_i^p \in R^{d_e+d_p}$ 。对邻接矩阵 A ,可以将存在关系的词与词用三元组 (h_i^p, r, h_m^p) 表示, h_i^p 表示依赖词,即图 2 中强化依赖图中箭头指出的词, h_m^p 表示被依赖词,即图 2 中强化依赖图中箭头指向的词,且 h_i^p 有且仅有一个 h_m^p 。由此可认为依赖和被依赖是两种不同的关系类型,所以对反向的关系构建为 (h_m^p, r', h_i^p) ,其中 r' 也由关系向量矩阵 E^r 得到,

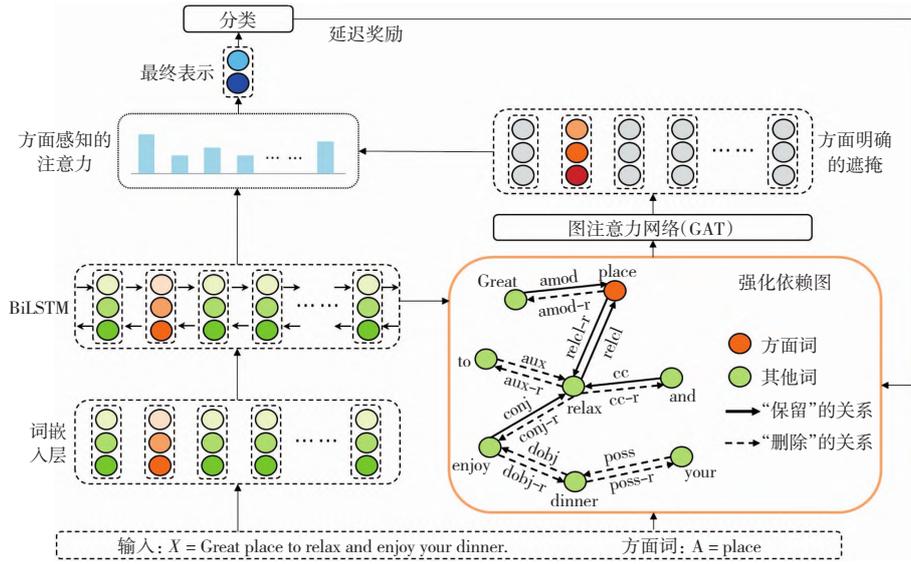


图 2 RDGSC 的整体模型
Fig. 2 Model of RDGSC

如强化依赖图所示,依赖关系类型为“amod”时,反向的依赖关系类型为“amod-r”.随后使用深度强化学习,把依赖词 h_i^p 、依赖关系 r 、被依赖词 h_{in}^p 和方面词的表示 h_{aspect}^p 拼接作为状态 $s_t, s_t \in R^d$,通过策略网络得到强化依赖图,用于图注意力网络计算。

2.1.1 状态

状态 s_t 由依赖词 h_i^p 、依赖关系 r 、被依赖词 h_{in}^p 和方面词的表示 h_{aspect}^p 拼接得到,公式如下:

$$s_t = h_i^p \oplus r \oplus h_{in}^p \oplus h_{aspect}^p \quad (1)$$

式中: \oplus 表示拼接操作,当方面词是短语时,使用最大池化得到 h_{aspect}^p .最终得到的状态 $S = \{s_1, \dots, s_{\tau+1}, \dots, s_{\tau+m}, \dots, s_n, \dots, s_{2n}\}, s_t \in R^d$.

2.1.2 动作和策略

动作由状态唯一决定,动作包含“保留”(Retain)和“删除”(Delete),表示该关系对方面情感分类是否有贡献。“保留”表示在强化依赖图中保留该关系,用于后续的方面情感分类,“删除”则是在强化依赖图中删除该关系。动作是生成强化依赖图的唯一指标,策略网络则是学习对动作进行选择。

与 ZHANG et al^[6]的工作相同,采用随机策略 $\pi(a^p_t | s_t; \theta)$ 对动作进行学习,用 a_i^p 表示状态 s_t 的动作,其策略的定义如下:

$$\pi(a_i^p | s_t; \theta) = \sigma(w^T s_t + b) \quad (2)$$

式中: $\pi(a_i^p | s_t; \theta)$ 表示策略网络中状态 s_t 选择 a_i^p 的概率, $\theta = \{w, b\}$ 为可学习的参数, $w \in R^d, b \in R$.在训练的时候,为了丰富深度强化学习的样本,动作通过随机采样得到;测试时希望能得到最好的分

类效果,所以选择概率最大的动作。

2.1.3 生成强化依赖图

通过策略网络得到单词关系对应的动作,生成强化依赖图。强化依赖图的邻接矩阵定义如下:

$$A_{i,m}^r = \begin{cases} 1, & a_i^p = \text{Retain}; \\ 0, & a_i^p = \text{Delete}. \end{cases} \quad (3)$$

式中: $A^r \in R^{n \times n}$.最终通过深度强化学习得到了强化依赖图的邻接矩阵 A^r ,后续的基于图注意力网络的方面情感分类则在强化依赖图进行。

2.1.4 延迟奖励

得到了强化依赖图后,通过图注意力网络对相应的方面情感进行分类,得到分类结果并计算延迟奖励;使用损失函数的输出 L 作为延迟奖励。此外,为了尽可能多地删除关系,保留更为精炼的图结构,添加了一个附加项。最终,奖励具体公式如下:

$$R = -L + \gamma \left(\frac{n'}{2n} \right)^2 \quad (4)$$

其中, n 为句子的单词个数,每个单词具有正向与反向的关系, n' 表示 a_i^p 为“删除”的关系的个数, γ 为一个超参数。

2.1.5 目标函数

策略网络的参数优化算法采用 REINFORCE 算法^[16]和梯度下降算法^[17],使期望奖励最大化。算法展示如下:

$$J(\theta) = E_{(s_t, a_t^p) \sim P_\theta(s_t, a_t^p)} r(s_1 a_1^p, \dots, s_{2n} a_{2n}^p) = \sum_{s_1 a_1^p, \dots, s_{2n} a_{2n}^p} P_\theta(s_1 a_1^p, \dots, s_{2n} a_{2n}^p) R =$$

$$\sum_{s_1^{a_1^p}, \dots, s_{2n}^{a_{2n}^p}} \prod_t p(s_t) \pi_\theta(a_t^p | s_t) R = \sum_{s_1^{a_1^p}, \dots, s_{2n}^{a_{2n}^p}} \prod_t \pi_\theta(a_t^p | s_t) R. \quad (5)$$

其中, 动作 a_t^p 由状态 s_t 唯一决定, 且 $p(s_t) = 1$. 最终策略网络的梯度可以表示为:

$$\nabla_{\theta} J(\theta) = \sum_{t=1}^{2n} R \nabla_{\theta} \log_2 \pi_\theta(a_t | s_t). \quad (6)$$

2.2 图注意力网络

对于输入文本 $X = \{x_1, \dots, x_{\tau+1}, \dots, x_{\tau+m}, \dots, x_n\}$, 通过深度强化学习, 得到强化依赖图及其邻接矩阵 A' . 随后通过图注意力网络, 在强化依赖图学习融合了句法信息的节点表示, 并通过明确方面的遮掩得到方面词的特征, 使用基于检索的注意力机制, 为每个上下文信息设置注意力权重, 生成最终的表示。

2.2.1 BiLSTM

输入句子通过词嵌入层, 得到句子的词嵌入表示 $H^w = \{h_1^w, \dots, h_{\tau+1}^w, \dots, h_{\tau+m}^w, \dots, h_n^w\}$, 与词性表示拼接得到新的文本表示 $H^p = \{h_1^p, \dots, h_{\tau+1}^p, \dots, h_{\tau+m}^p, \dots, h_n^p\}$. 通过 BiLSTM 层, 得到融合了上下文信息的隐藏层表示 $H^c = \{h_1^c, \dots, h_{\tau+1}^c, \dots, h_{\tau+m}^c, \dots, h_n^c\}$, $h_i^c \in R^{d_h}$.

2.2.2 图注意力网络

与 VELICKOVIC et al^[18] 的工作相同, 在图注意力网络(GAT)层, 将 H^0 作为输入, 令 $H^0 = H^c$, 将强化依赖图作为图结构, 图注意力网络使用多头注意力机制融合邻居节点的信息, 增强当前节点的信息。其公式如下:

$$h_i^{l+1} = \parallel_{k=1}^K \sigma \left(\sum_{j \in N_i} \alpha_{ij}^{lk} \mathbf{W}^{lk} h_j^l \right). \quad (7)$$

$$\alpha_{ij}^{lk} = \frac{\exp(e_{ij})}{\sum_{j' \in N_i} \exp(e_{ij'})}. \quad (8)$$

其中, h_i^{l+1} 表示节点 i 在 $l+1$ 层的表示, \parallel 表示拼接操作, σ 表示非线性激活函数, N_i 表示节点 i 的邻居节点集合, α_{ij}^{lk} 表示第 l 层第 k 个注意力的归一化注意力系数, \mathbf{W}^{lk} 表示第 l 层第 k 个头的转换矩阵, $\mathbf{W}^{lk} \in R^{d_h \times d_h}$, h_j^l 表示第 l 层第 j 个节点的表示。 e_{ij} 表示节点 i 与节点 j 之间的注意力, 公式如下:

$$e_{ij} = \text{LeakyReLU}(a^T [\mathbf{W}^{lk} h_i^l \parallel \mathbf{W}^{lk} h_j^l]). \quad (9)$$

式中, a 是可学习的向量, $a \in R^{2d_h}$. 为了充分融合邻居节点的信息, 采用了多层的图注意力网络, 最终输出第 L 层的隐藏层表示 $H^L = \{h_1^L, \dots, h_{\tau+1}^L, \dots, h_{\tau+m}^L, \dots, h_{n-1}^L\}$, $h_i^L \in R^{d_h}$.

2.2.3 明确方面的遮掩

通过 L 层图注意力网络, 得到了融合句法依赖关系的隐藏状态表示 H^L , 参考 ZHANG et al^[6] 的工作, 对非方面词的向量遮掩, 方面词的向量保持不变, 得到方面的特征 $H_{\text{mask}}^L = \{0, \dots, h_{\tau+1}^L, \dots, h_{\tau+m}^L, \dots, 0\}$, H_{mask}^L 则融合了文本中所有与方面相关的信息。

2.2.4 方面感知的注意力

得到基于方面的特征后, 使用注意力机制计算得到最终表示。与 ZHANG et al^[6] 的工作相同, 使用基于方面的特征 H_{mask}^L 匹配上下文表示 H^c 中与方面词语义相关的重要特征, 对每个上下文信息设置与方面相关的注意力权重, 计算公式如下:

$$\beta_i = \sum_{i=1}^n h_i^{L^T} h_i^c = \sum_{i=\tau+1}^{\tau+m} h_i^{L^T} h_i^c. \quad (10)$$

$$\alpha_i = \frac{\exp(\beta_i)}{\sum_{i=1}^n \exp(\beta_i)}. \quad (11)$$

通过点积, 可以计算方面特征与句子中上下文信息的相关性, 加权求和得到最终的精确表示 $z \in R^{d_h}$:

$$z = \sum_{i=1}^n \alpha_i h_i^c. \quad (12)$$

2.2.5 分类

得到最终的精确表示 z 后, 将其输入一个全连接层, 再通过一个 softmax 层进行归一化, 得到预测的概率分布 $P(\hat{y} | X) \in R^{d_z}$:

$$P(\hat{y} | X) = \text{softmax}(W_z z + b_z). \quad (13)$$

其中, \hat{y} 表示预测的标签, d_z 为方面情感分类的类别数, $W_z \in R^{d_z \times d_h}$ 为可学习参数, $b_z \in R^{d_z}$ 为偏差。

2.2.6 训练

图注意力网络训练时使用标准的梯度下降算法优化模型, 交叉熵损失函数为:

$$L = - \sum_{y=1}^C y \log_2 P(\hat{y} | X). \quad (14)$$

式中: y 表示真实的标签, C 表示方面情感分类的类别数。

为了使强化依赖图部分的深度强化学习快速收敛, 采用了热启动, 即使用原始的依赖树对图注意力网络的参数进行预训练。且同时训练强化依赖图的参数和图注意力网络十分困难, 容易陷入局部最优, 导致模型效果不佳, 因此在热启动后, 使用交替训练对两个网络分别训练。经过热启动后, 固定图注意力网络的参数, 对强化依赖图部分的参数训练, 以期得到对分类更有效的图结构; 接着固定强化依赖图部分的参数, 对图注意力网络进行训练, 提升

在强化依赖图下的分类效果,依次交替,最终得到两者都最优的结果。

3 实验

3.1 数据集与实验设置

对 5 个公开的数据集进行分析,表 1 列举了数据集的统计情况, # Pos.、# Neu. 和 # Neg. 分别表示积极、中性和消极的情感倾向样本个数。其中 Twitter 表示社交平台 Twitter^[19] 用户的评论,包含了用户提及的人名、公司等方面;Lap14 与 Rest14、Rest15 和 Rest16 分别来自 SemEval 2014 task 4^[20]、SemEval 2015 task 12^[21] 和 SemEval 2016 task 5^[22],包含了用户对笔记本电脑和餐厅的评价。

表 1 数据集统计
Table 1 Statistic of datasets

Dataset		# Pos.	# Neu.	# Neg.
Twitter	Train	1 561	3 127	1 560
	Test	173	346	173
Lap14	Train	994	464	870
	Test	341	169	128
Rest14	Train	2 164	637	807
	Test	728	196	196
Rest15	Train	912	36	256
	Test	326	34	182
Rest16	Train	1 240	69	439
	Test	469	30	117

在实验中,采用 300 维的 GLOVE 预训练向量作为词嵌入的初始化,模型的参数使用均匀分布进行初始化。其中 d_e 为 300, d_p 和 d_r 为 100, d_s 为 800, d_h 为 600, d_z 为 3, γ 为 0.7, 图注意力网络中,多头注意力头的个数为 1, GAT 的层数 L 为 1 或 2, LeakyReLU 小于 0 的斜率为 0.2, 最终分类的类别数 C 为 3, 表示 3 种情感极性,批处理的大小为 16, 优化器 Adam 的学习率为 0.001, 交替训练轮次为 5。

3.2 基线模型

本文提出的 RDGSC 与 9 种基线方法在 5 个不同的数据集上进行实验。

1) SVM^[23]: 传统的机器学习方法,使用传统的特征提取方法,通过内部序列标记方面词。

2) LSTM^[1]: 对传统的 LSTM 模型进行扩展,输入文本为有序的单词序列,设置两个与方面相关的长短期记忆模型,充分融合上下文信息。

3) MemNet^[24]: 使用多跳结构和外部记忆学习单词在文本中的重要性,最终生成文本的表示。

4) AOA^[8]: 将机器翻译领域的注意-过度注意方法引入到方面情感分类任务,以联合的方式对各个方面与句子进行建模,准确地捕捉了各方面和上

下文之间的相互作用。

5) IAN: 输入文本建模为有序的单词序列,使用注意力网络学习方面的上下文表示。

6) TD-GAT^[8]: 使用图注意力网络,利用单词的依赖关系进行学习,使用多头注意力融合相互依赖的单词之间的信息。

7) ASCNN^[2]: 使用卷积操作学习句子的上下文信息,通过对非方面词进行遮掩,得到方面的特征,使用基于检索的注意力机制,为每一个上下文信息学习注意力权重。

8) ASGCN^[2]: 使用句法依赖图融合句法依赖信息,对非方面词遮掩得到方面的特征,利用注意力机制来学习文本的表示。

9) kumaGCN^[4]: 将句法依赖树和自动诱导的方面相关的特定图相关联,使用自注意力机制动态结合依赖树与潜在图的信息,再使用注意力机制学习文本中上下文信息的注意力权重。

重复运行 3 次,取平均值作为实验的结果,使用准确率(Acc)和宏观 F_1 作为评价指标。

3.3 实验结果

如表 2 所示,从整体上看,5 个数据集中,本文方法在 4 个数据集的结果都优于现有的模型。对单个的数据集而言,与最好的方法相比,本文的方法在 Twitter 上, Acc 和 F_1 分别提升了 0.9% 和 1.3%; 在 Lap14 上提升了 0.6% 和 0.1%; 在 Rest14 数据集上, Acc 基本保持不变,而 F_1 提升 0.3%; Rest15 数据集, Acc 与 F_1 下降了 0.8% 和 0.3%; 而在 Rest16, Acc 下降 0.3% 的同时, F_1 提升了 1.3%。各项数据都表明了本文方法的有效性,证明了本文的强化依赖图是更适应方面情感分类的图结构。

3.4 消融实验

我们设计了消融实验,研究深度强化学习中状态的组成成分实验结果的影响,状态是决定动作的唯一指示器,而动作决定了强化依赖图的生成,强化依赖图对方面情感分类有决定性作用,因此状态的组成成分是本文关注的重点。如表 3 所示, RDGSC w/o RL 表示不使用深度强化学习,仅使用图注意力网络的结果; RDGSC w/o Rel 表示在深度强化学习,状态不包含词与词之间句法依赖关系类型; RDGSC w/o Aspect 表示状态中不包含句子中的方面词,即动作的学习与方面无关。在 5 个数据集上, RDGSC 的结果与前两项相比,除了在 Rest16 的 Acc 上比 RDGSC w/o RL 均下降了 0.1%, 其余的均为最高值。与 RDGSC w/o RL (即不使用强化依

表 2 与不同模型的对比
Table 2 Comparison of our RDGSC model with different baselines %

Methods	Twitter		Lap14		Rest14		Rest15		Rest16	
	Acc	F_1	Acc	F_1	Acc	F_1	Acc	F_1	Acc	F_1
SVM ^[23]	63.40	63.30	70.49	N/A	80.16	N/A	N/A	N/A	N/A	N/A
LSTM ^[1]	69.56	67.70	69.28	63.09	78.13	67.47	77.31	55.17	86.80	63.88
MemNet ^[24]	71.48	69.90	70.64	65.17	79.61	69.64	77.31	58.28	85.44	65.99
AOA ^[8]	72.30	70.20	72.62	67.52	79.97	70.42	78.17	57.02	87.50	66.21
IAN ^[15]	72.50	70.81	72.05	67.38	79.26	70.09	78.54	52.65	84.74	55.21
TD-GAT ^[8]	72.20	70.45	75.63	70.74	81.32	71.72	80.38	60.50	87.71	67.87
ASGCN ^[2]	71.05	69.45	72.62	66.72	81.73	73.10	78.47	58.90	87.39	64.56
ASGCN ^[2]	72.15	70.40	75.55	71.05	80.77	72.02	79.89	61.89	88.99	67.48
KumaGCN ^[4]	72.45	70.77	76.12	72.42	81.43	73.64	80.69	65.99	89.39	73.19
RDGSC(ours)	73.31	71.99	76.72	72.57	81.45	73.99	79.82	65.72	88.96	74.42

表 3 消融实验
Table 3 Ablation study %

Methods	Twitter		Lap14		Rest14		Rest15		Rest16	
	Acc	F_1	Acc	F_1	Acc	F_1	Acc	F_1	Acc	F_1
RDGSC w/o RL	72.25	70.45	74.76	70.65	80.95	72.64	79.95	63.37	88.25	70.31
RDGSC w/o Rel	71.67	70.28	73.04	68.94	80.89	72.43	79.39	63.51	87.66	68.03
RDGSC	73.31	71.99	76.72	72.57	81.45	73.99	79.82	65.72	88.96	74.42

赖图)相比, Acc 和 F_1 最高分别提升了 2% 和 4%, 表明了强化依赖图对方面情感分类的积极的作用; 与 RDGSC w/o Rel(即强化依赖图的状态不包含依赖关系类型)相比, 最高可提升 3.2% 和 6.3%, 表明依赖关系类型在模型中也是不可或缺的。而 RDGSC w/o RL 与 RDGSC w/o Rel 相比, 除 Rest15 数据集, 其余数据集的指标都有所下降, 原因为词与词之间的关系更为复杂, 导致策略网络训练不充分, 即仅使用单词之间的信息和方面词的信息无法准确地判断方面情感分类是否需要这个依赖关系。

3.5 交替训练实验

在实验细节上, 策略网络生成的强化依赖图决定图注意力网络的结果, 而图注意力网络的结果又会对策略网络进行更新, 两者相互依赖、相互制约, 导致同时训练策略网络和图注意力网络十分困难, 极易陷入局部最优解。因此采用交替训练的方式, 分别对策略网络和图注意力网络进行学习。如图 3 所示, 横坐标表示交替学习的轮次, 纵坐标表示实验的结果。对 Twitter 和 Lap14 数据集, 在第二轮时 Acc 下降, 可认为是因为强化依赖图的变化较大, 图注意力网络训练不充分导致结果下降。对 F_1 而言, 可以看出随着交替轮次的增加, 实验效果逐步提高。但是随着交替轮次的增加, 训练时间也呈倍增加, 因此为了平衡时间与效果, 选择交替 5 次进行实验。

3.6 注意力可视化

通过将公式(11)的 α 进行注意力可视化, 展示本文模型的有效性。如表 4 所示, 方面词表示对该词进行情感分类; 注意力可视化中, 颜色越深, 表示模型越关注该单词的信息; 预测标签表示模型预测方面的情感倾向; 真实标签表示人为判断的结果。第一个例子中, “Space is limited, but the food made up for it.”, 方面词为“food”, 但是 ASGCN 将注意力集中在情感表达明显的“limited”上, 认为“food”是消极的情感倾向, 而 RDGSC 则正确地将注意力放在“but”和“made up”上, 表明“made up”具有与“limited”相反的情感倾向。在“The fish is fresh, though it was cut very thin.”句子中, ASGCN 考虑整个句子的情感倾向, 前半部分为积极的情感, 后半部分具有转折的含义, 认为“fish”也是中性的情感; 而本文的方法则重点关注“fresh”这个词, 得出“fish”的情感倾向为积极的。第三个句子中, ASGCN 虽然也关注了“never recommend”这个表达了消极情感的词, 但是也关注了“casual”, 最终认为这个句子为积极的情感; 而 RDGSC 关注了“never recommend”和“anybody”, 这些具有否定意义的单词, 加强了消极的情感倾向。从注意力可视化看出, 强化依赖图可以更有效地融合与方面相关的信息, 使模型更加关注与方面相关的特征。

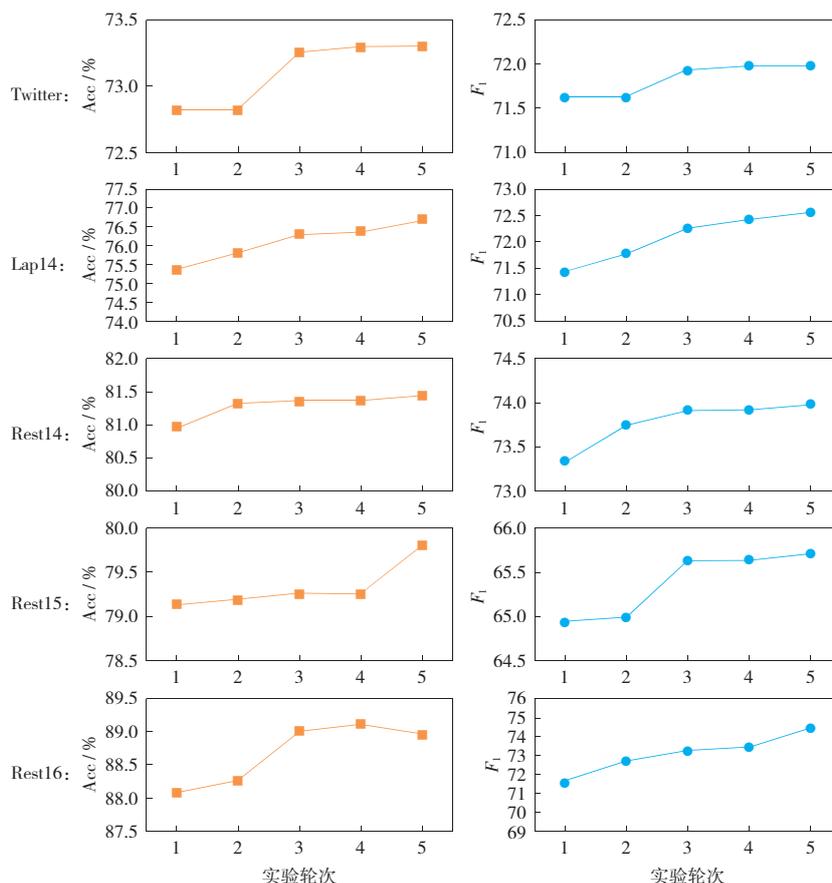


图 3 交替实验

Fig. 3 Experience of alternation

表 4 案例分析

Table 4 Case study

模型	方面词	注意力可视化	预测标签	真实标签
ASGCN	food	Space was limited, but the food made up for it.	negative	positive
	fish	The fish was fresh, though it was cut very thin.	neutral	positive
	place	I would never recommend this place to anybody even for a casual dinner.	positive	negative
RDGSC	food	Space was limited, but the food made up for it.	positive	positive
	fish	The fish was fresh, though it was cut very thin.	positive	positive
	place	I would never recommend this place to anybody even for a casual dinner.	negative	negative

4 总结

本文使用深度强化学习对句法依赖树进行学习,考虑了句法依赖树的关系类型与方面之间的关系,生成基于句法依赖关系的增强依赖图,再通过图注意力网络融合文本中与方面相关的特征,使用基

于检索的注意力机制,为上下文信息设置与方面相关的注意力权重,获得精简的最终文本表示用于分类;最终的分类结果也通过计算得到延迟奖励指导策略网络的更新,且通过大量实验证明了本文的方法的有效性和健壮性。

参考文献:

- [1] TANG D Y, QIN B, FENG X C, et al. Effective lstms for target-dependent sentiment classification[C]//Proceedings of COLING 2016, the 26th International Conference on Computational Linguistics; Technical Papers, osaka, Japan, 2016:3298-3307.
- [2] ZHANG C, LI Q C, SONG D W. Aspect-based sentiment classification with aspect-specific graph convolutional networks[C] //Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP), Hongkong, China, 2019:4568-4578.
- [3] THOMAS N, KIPF, MAX WELLING. Semisupervised classification with graph convolutional networks[C]//Proceedings of

- the 2017 Conference on International Conference on Learning Representations (ICLR), Toulon, France, 2017.
- [4] CHEN C H, TENG Z Y, ZHANG Y. Inducing target-specific latent structures for aspect sentiment classification[C]// Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP), Online, 2020: 5596-5607.
- [5] HOU X C, QI P, WANG G T, et al. Graph ensemble learning over multiple dependency trees for aspect-level sentiment classification[C]// Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Online, 2021: 2884-2894.
- [6] ZHANG T Y, HUANG M L, ZHAO L. Learning structured representation for text classification via reinforcement learning [C]// Proceedings of the AAAI Conference on Artificial Intelligence, Online, 2018.
- [7] CHEN Y C, BANSAL MOHIT. Fast abstractive summarization with reinforce-selected sentence rewriting[C]// Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (ACL), 2018: 675-686.
- [8] HUANG B X, OU Y L, KATHLEEN M. CARLEY. 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, Cham, 2018: 197-206.
- [9] LI X, BING L D, LAM W, et al. Transformation networks for target-oriented sentiment classification[C]// Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (ACL), Melbourne, Australia, 2018: 946-956.
- [10] YAO L, MAO C S, LUO Y. Graph convolutional networks for text classification[C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2019, 33(1): 7370-7377.
- [11] GHOSAL D, MAJUMDER N, PORIA S, et al. DialogueGCN: a graph convolutional neural network for emotion recognition in conversation[C]// EMNLP-IJCNLP 2019-2019 Conference on Empirical Methods in Natural Language Processing and 9th International Joint Conference on Natural Language Processing, Hongkong, China, 2020.
- [12] WANG J J, SUN C L, LI S S, et al. Human-like decision making: document-level aspect sentiment classification via hierarchical reinforcement learning[C]// Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP), Hongkong, China, 2019: 5581-5590.
- [13] LI R F, CHEN H, FENG F X, et al. Dual graph convolutional networks 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 (Volume 1: Long Papers), Tokyo, Japan, 2021.
- [14] FENG J, HUANG M L, ZHAO L, et al. Reinforcement learning for relation classification from noisy data[C]// Proceedings of the AAAI Conference on Artificial Intelligence, Louisiana, USA, 2018.
- [15] CHAI D, WU W, HAN Q H, et al. Description based text classification with reinforcement learning[C]// Proceedings of International Conference on Machine Learning, Online, 2020: 1371-1382.
- [16] RONALD J W. Simple statistical gradient-following algorithms for connectionist reinforcement learning[J]. Machine learning, 1992, 8(3/4): 229-256.
- [17] SUTTON R S, MCALLESTER D, SINGH S, et al. Policy gradient methods for reinforcement learning with function approximation[C]// Advances in Neural Information Processing Systems, 2000: 1057-1063.
- [18] VELICKOVIC P, CUCURULL G, CASANOVA A, et al. Graph Attention Networks[C]// Proceedings of International Conference on Learning Representations, BC, Canada, 2018.
- [19] DONG L, WEI F R, TAN C Q, 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 (volume 2: Short papers), 2014: 49-54.
- [20] PONTIKI M, GALANIS D, PAVLOPOULOS J, et al. SemEval-2014 task 4: Aspect based sentiment analysis[C]// Proceedings of the ACL International Workshop on Semantic Evaluation, 2014: 27-35.
- [21] 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 (SemEval 2015), 2015: 486-495.
- [22] PONTIKI M, GALANIS D, PAPAGEORGIOU H, et al. Semeval-2016 task 5: Aspect based sentiment analysis[C]// International Workshop on Semantic Evaluation, 2016: 19-30.
- [23] KIRITCHENKO S, ZHU X D, CHERRY C, et al. Nrc-canada-2014: detecting aspects and sentiment in customer reviews[C]// Proceedings of the 8th international workshop on semantic evaluation (SemEval 2014), 2014: 437-442.
- [24] TANG D Y, 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 (EMNLP), 2016: 214-224.

(编辑: 贾丽红)