

基于 LSTM-GCAE 的特定目标情感分析

沈 彬^{1,2}, 严 馨^{1,2*}, 谢 庆^{1,2}, 徐广义³, 张金鹏⁴

(1. 昆明理工大学信息工程与自动化学院, 昆明 650504;

2. 昆明理工大学, 云南省人工智能重点实验室, 昆明 650504;

3. 云南南天电子信息产业股份有限公司, 昆明 650041; 4. 云南财经大学信息学院, 昆明 650221)

摘 要: 针对传统特定目标情感分析在模型输入前未能将上下文和目标词进行良好地融合以及在提取情感特征时未能有效地关注到特定目标等问题, 提出了一种基于 LSTM-GCAE 的特定目标情感分析模型。首先, 将上下文和目标词进行拼接得到融合词向量, 采用 LSTM 对融合词向量进行编码, 以捕获上下文语义信息; 然后, 通过带有目标词向量的门控卷积机制进一步提取关于目标词的情感特征; 最后, 通过 softmax 分类函数对特定目标进行情感极性分类。

关键词: 特定目标; 长短期记忆网络; 门控卷积神经网络

中图分类号: TP391 文献标识码: A 文章编号: 1009-2552(2022)04-0007-06

DOI: 10.13274/j.cnki.hdzj.2022.04.002

Specific-targeted sentiment analysis based on LSTM-GCAE

SHEN Bin^{1,2}, YAN Xin^{1,2}, XIE Qing^{1,2}, XU Guang-yi³, ZHANG Jin-peng⁴

(1. Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650504, China; 2. Yunnan Key Laboratory of Artificial Intelligence, Kunming University of Science and Technology, Kunming 650504, China; 3. Yunnan Nantian Electronic Information Industry Co., Ltd., Kunming 650041, China; 4. Yunnan University of Finance and Economics, School of Information, Kunming 650221, China)

Abstract: In order to overcome the problem of the intergration of context and target words, along with the issue that traditional specific-targeted sentiment analysis fails to integrate the context and target words well before model input and fails to pay attention to the specific target effectively when extracting emotion features, a target-specific sentiment analysis model based on LSTM-GCAE is proposed. Firstly, context and target words are spliced to obtain the fusion word vector, and LSTM is used to code the fusion word vector to capture the context semantic information. Then, the gating convolution mechanism with the target word vector is used to extract the emotional features of the target word. Finally, the emotional polarity of specific targets is classified by softmax classification function.

Key words: specific target; Long Short-Term Memory (LSTM); Gated Convolutional Neural Network

基金项目: 国家自然科学基金(61462055, 61562049)

作者简介: 沈彬(1997-), 男, 硕士研究生, 研究方向为自然语言处理。

* 通讯作者: 严馨(1969-), 女, 硕士, 副教授, 硕士生导师, 研究方向为自然语言处理。

0 引 言

特定目标的情感分析^[1] (Target-Specific Sentiment Analysis, TSSA) 是情感分析任务中一个重要的子任务。与一般的情感分析任务不同, 特定目标的情感分析旨在给定一个句子及其特定目标

的条件下,分析和推断出该句中特定目标的情感极性。传统的基于情感词典的方法^[2-3]依赖于情感词典的构建及其质量,基于机器学习的方法^[4]依赖于人为设计的与目标相关的特征的质量,这些方法不仅需要耗费大量的人工成本,而且也很难对上下文和目标词之间的语义关联进行建模。基于神经网络的深度学习的方法^[5]能够在不需要特征工程的情况下学习到连续、低维的特征表示,同时捕获目标词和上下文之间复杂的语义关联。许多研究者在这方面投入了大量的研究^[6-14]。陈思远等人^[8]提出了一种基于 CNN 和区域 LSTM 的深度网络模型,通过区域 LSTM 对特定目标进行区域划分,并利用 CNN 保留整个句子的情感信息。Wei 等人^[9]提出了一种融合方面词向量的门控卷积神经网络模型,该模型采用 CNN 和门控单元,不仅能够有效地提取特定目标的情感特征,而且模型的并行计算能力能够减少训练的时间。

在对以上方法深入研究后,本文提出了一种基于 LSTM-GCAE 的特定目标情感分析模型。该模型首先将目标词向量与对应文本词向量进行拼接融合,再通过 LSTM 对融合词向量进行编码,以

捕获上下文语义信息。然后,使用 softmax 分类函数对门控卷积神经网络提取到的特定目标情感特征进行情感极性分类。实验结果表明,本文提出的模型与现有的基准模型在三个评价指标上有较明显的提升。

1 LSTM-GCAE 网络模型

1.1 模型定义

本文提出的基于 LSTM-GCAE 网络模型的整体框架图如图 1 所示,其结构主要由输入层、编码层、门控卷积层、最大池化层和输出层组成。

①输入层:对模型输入进行向量嵌入、拼接操作,得到融合目标信息的词向量;

②编码层:使用 LSTM 对输入内容进行编码,捕获句子内部的语义信息;

③门控卷积层:对 LSTM 输出的隐层状态进行门控卷积计算,提取特定目标的情感特征;

④最大池化层:从门控卷积提取的特征中抽取最大值;

⑤输出层:使用 softmax 分类函数对特定目标进行情感分类。




图 1 模型框架图

1.2 输入层

为了将输入序列和目标转化为计算机可以处理的形式,首先需要对单词进行向量化操作,本文使用的词向量来源于 Li^[15]训练好的中文微博开

源词向量。对于给定的长度为 n 的句子序列 $s = \{x_1, x_2, \dots, x_n\}$ 和目标词 x_a ,通过查找词向量矩阵 $W \in \mathbb{R}^{d \times |V|}$,其中 d 表示词向量的维度, $|V|$ 表示词表大小,将每一个词 x_i 映射为其对应的词向量

表示 $w_i \in \mathbf{R}^{d \times 1}$, 分别得到序列 s 的词向量表示 $X_s = \{w_1, w_2, \dots, w_n\} \in \mathbf{R}^{d \times n}$ 和目标词向量表示 $v_a \in \mathbf{R}^{d \times 1}$, 其中 w_i 表示序列 s 中第 i 个词的词向量。并将目标词向量与序列中的每一个词向量进行拼接, 得到融合目标词特征的新的词向量 $z_i \in \mathbf{R}^{2d \times 1}$, 其中 $i = 1, 2, \dots, n$ 。

1.3 编码层

编码层使用的是具有记忆功能的长期记忆网络 LSTM^[16], 它对输入层融合目标信息之后的词向量进行编码, 以获得包含目标信息的隐藏语义信息和情感信息。将序列中的词向量与目标词向量进行拼接是为了加强目标词与上下文的联系, 更好地利用目标词的信息。LSTM 各个时间步的隐藏状态表示为:

$$h_t = \text{LSTM}(z_t, h_{t-1}) \quad (1)$$

其中, h_t 表示第 t 个时间步的隐藏状态, h_0 进行了随机初始化。对于长度为 n 的句子, 将每个时间步的隐藏状态按序列方向拼接之后得到句子表示的隐藏状态输出矩阵 $H = \{h_1, h_2, \dots, h_n\} \in \mathbf{R}^{d_h \times n}$, 其中 d_h 表示网络中隐藏层的节点数量。

1.4 门控卷积层

门控卷积神经网络^[17] (Gated Convolutional Neural Network, GCNN) 与经典的卷积神经网络 CNN 的不同之处在于引入了门控机制, 所以可以通过门控单元和最大池化有效地提取文本的关键特征。由 LSTM 层获得带有依赖关系的隐藏状态, 之后使用每一个卷积滤波器对隐藏状态计算不同粒度的 n 元特征, 卷积层中的各个门控单元是相互独立的。

门控机制在 LSTM 中已经被验证了是行之有效的, 门控单元能控制情感信息流向汇集层的路径。在特定目标的情感分析中, 由于目标词不同, 在一个句子中具有多个不同的情感倾向是很常见的, 所以为了加强特定目标词与句子情感倾向的相关性, 在 ReLU 门中融入目标词向量。在公式 (2) 中, ReLU 门输出的 a_i 相当于控制情感特征 s_i 输出大小的控制系数。当 a_i 为正数时, 表示的是对情感特征 s_i 相应的放大; 当 a_i 为 0 时, 情感特征 s_i 将被阻塞。随着训练时间的累积, 最大池化进一步删除了整个句子中不重要的情感特征^[18]。门控

卷积层中情感特征的计算方式如下:

$$a_i = \text{ReLU}(H_{i:i+k} * W_a + v_a T_a + b_a) \quad (2)$$

$$s_i = \tanh(H_{i:i+k} * W_s + b_s) \quad (3)$$

$$c_i = a_i \times s_i \quad (4)$$

其中, $*$ 表示卷积操作; ReLU 和 tanh 表示非线性激活函数; $W_a \in \mathbf{R}^{d_h \times k}$ 和 $W_s \in \mathbf{R}^{d_h \times k}$ 表示滤波器的权重矩阵; T_a 表示目标词向量 v_a 的权重矩阵; b_a 和 b_s 表示偏置。

1.5 最大池化层

当宽度为 k 的卷积核在窗口中进行滑动时, 每连续 k 个词向量将会获得一个新的特征值 c 。对于一个长度为 n 的句子, 当使用不变卷积滑过整个句子之后, 最终得到 n 个特征, 用向量表示为 $c = \{c_1, c_2, \dots, c_n\} \in \mathbf{R}^n$ 。然后使用最大池化操作抽取最显著的特征 $\hat{c} = \max(c)$ 。当有 d_k 个滤波器时, 最终生成一个固定大小的向量 $e \in \mathbf{R}^{d_k}$ 。

1.6 输出层

为了得到最终特定目标的情感极性, 将最终的特征表示 e 输入到 softmax 分类函数中, 得到目标属于不同情感极性的概率分布, 如式 (5) 所示。

$$\hat{y} = \text{softmax}(W_y e + b_y) \quad (5)$$

其中, $W_y \in \mathbf{R}^{C \times d_k}$ 和 b_y 分别表示权重矩阵和偏置。

1.7 模型训练

本文的损失函数选择的是交叉熵损失函数, 如式 (6) 所示。

$$\text{loss} = - \sum_i \sum_j^C y_i^j \log \hat{y}_i^j \quad (6)$$

其中, i 是数据集的索引; j 是情感极性类别的下标; y 为句子情感极性标签; $\hat{y}$ 为句子情感极性的概率分布; C 为情感极性类别。

2 实验与分析

2.1 数据集

网络上带有特定目标词的数据集比较稀少, 所以实验中采用的是一个混合的带有特定目标词的数据集。数据集来源分为两个部分: 一部分选自 NLPCC2012 的数据集, 其中包含了教育、社会生活、体育等方面的评论; 另一部分来自于在微博上收集的微博评论, 其中包含了国际新闻、社会生活等方面的评论。本文对数据进行清理、筛选和标记, 使得每条数据包括评论、目标词和目标词对

应的情感极性,最后整理得到的数据集共有 5000 个样本。数据集的统计信息如表 1 所示。

表 1 数据集

	积极	消极	共计
训练集	1573	2427	4000
测试集	450	550	1000
共计	2023	2977	5000

2.2 算法描述

模型算法描述如下:

算法 1 LSTM-GCAE 模型算法
输入: 源文本、特定目标词、特定目标对应的情感极性
输出: 测试集上的 loss、precision、recall、f1
1. Select training dataset //分别选取 2.1 节中数据的 4000 条作为训练集,1000 条作为测试集; (x_i, y_i) 表示第 i 个样本及其对应的情感标签,积极情感标为 1,消极情感标为 0.
2. Preprocessing text //数据清洗,使用 jieba 工具进行分词,去除停用词.
3. Get word embedding //使用预训练的词向量初始化源文本中的每个词和特定目标词.
4. Feature fusion //将 1.2 节源文本中每一个词的词向量和特定目标词向量按维度方向进行拼接,得到融合目标词的词向量.
5. Train //将融合词向量输入到 LSTM 中,得到每个时间步含有序列信息的隐层状态,再输入到门控卷积神经网络中;使用带有目标词向量的门控卷积进一步提取情感特征,根据损失函数反向传播,更新网络中的参数.
6. Test //每训练完一个 epoch 使用测试集对模型的性能进行测试,输出 loss、precision、recall 和 f1.

2.3 实验设置和评价指标

本文实验中采用 Li 等人^[15]公布的预训练好的中文微博预训练词向量,使用 gensim 模块加载预训练好的词向量对上下文和目标词进行初始化,词向量维度为 300;设置 LSTM 中隐藏层单元数量为 300;门控卷积层中的卷积核数量设为 100,卷积核大小为 3;采用 Adam 优化器更新模型中的参数,批训练的数量为 64,学习率设为 0.001。使用的编程语言是 python3.6,深度学习框架是 PyTorch。

本文采用三个指标来评价模型的分类效果,分别是精确率 (precision)、召回率 (recall) 和 $F1$ 。分类结果的混淆矩阵^[19]如表 2 所示。

表 2 分类结果的混淆矩阵

真实情况	预测情况	
	正例	反例
正例	TP	FN
反例	FP	TN

分类计算公式如下:

$$precision = \frac{TP}{TP + FP} \times 100\% \tag{7}$$

$$recall = \frac{TP}{TP + FN} \times 100\% \tag{8}$$

$$F1 = \frac{2 \times precision \times recall}{precision + recall} \times 100\% \tag{9}$$

其中, TP 表示实际为正类被预测为正类的样本数; FP 表示实际为负类被预测为正类的样本数; $TP + FP$ 表示被预测为正类的样本数; FN 表示实际为正类被预测为负类的样本数; $TP + FN$ 表示实际为正类的样本数; $F1$ 是对精确率和召回率的平衡。

2.4 实验设计

为了验证本文提出模型的效果,本文针对特定目标的情感分析任务共进行了 4 组实验,实验使用的是 2.1 节中的数据集。本文提出的模型是在 LSTM-CNN 模型的基础上,将该模型中的 CNN 做出改进,替换为门控卷积神经网络。具体的实验如下:

① 对照实验 LSTM-CNN 模型^[18]。LSTM-CNN 模型中的嵌入层需融合特定目标词向量和上下文向量输入到 LSTM 中,之后将 LSTM 的隐藏层状态输入到 CNN 中。设置 LSTM 中隐藏层单元数量为 300,CNN 中的卷积核数量设为 100,卷积核的大小为 3,模型迭代 30 次,批训练的数量为 64,学习率设为 0.01。本实验的目的是为了验证 LSTM-CNN 和 LSTM-GCAE 这两个模型之间的性能差异。

② 对照实验 ATAE-LSTM 模型^[10]。使用 Wang 等人^[10]提出的基于方面级别的情感分析方法 ATAE-LSTM,该方法是将注意力机制和 LSTM 相结合,本实验中具体使用的目标词向量,首先在嵌入层中将目标词向量和文本词向量相融合,得到融合词向量作输入,之后还将目标词向量和隐

藏层状态相连接,来计算注意力权重,通过注意力机制来捕获句子中与目标词相关的重要部分。设置 LSTM 中隐藏层单元数量为 300,模型迭代 100 次,批训练的数量为 64,学习率设为 0.01。

③对照实验 GCAE 模型^[9]。本实验的目的是为了验证 GCAE 和 LSTM-GCAE 这两个模型之间的性能差异。GCAE 使用了 Tanh-ReLU 门控单元,并将目标词向量作为额外的输入和词向量融合。GCAE 中的卷积核数量设为 100,卷积核大小为 3,模型迭代 100 次,批训练的数量为 64,学习率设为 0.01。

④本文方法 LSTM-GCAE。LSTM-GCAE 为本文所提出的模型,具体方法是,首先嵌入预训练好的词向量,然后通过 LSTM 和 GCAE 相结合的方法提取句子的情感语义特征,最后采用 softmax 输出分类结果,参数设置在 2.3 节中。

2.5 实验结果分析

为了验证本文方法的有效性,分别设置了几个深度学习方法进行对比。几个深度学习的方法中使用的嵌入层都是特定目标词向量和上下文向量进行拼接,得到融合的词向量。深度学习方法有 LSTM-CNN 模型^[18]、ATAE-LSTM 模型^[10]和 GCAE 模型^[9],LSTM-CNN 模型的输入为融合词向量,之后使用 LSTM 对微博特定目标句子进行编码,之后使用 CNN 模型进行预测;ATAE-LSTM 模型输入同样为融合词向量,之后基于注意力的 LSTM 对微博特定目标句子进行编码,之后使用 softmax 进行预测。GCAE 模型输入同样为融合词向量,之后基于 GCAE 对微博特定目标句子进行编码,使用 softmax 函数进行预测。

表 3 实验结果

模型	精确率	召回率	F 值
LSTM-CNN	68.56%	68.23%	68.39%
ATAE-LSTM	70.11%	70.20%	70.15%
GCAE	70.53%	70.62%	70.57%
LSTM-GCAE	71.19%	71.78%	71.48%

从表 3 中实验结果可以看出,本文模型与其他三个基准模型相比,在三个评价指标上均较佳,F1 值高说明本文模型在特定目标情感分析中综

合性能更好。本文模型的召回率相对于 LSTM-CNN 提高了 3.55%,说明将 CNN 中加入门控机制之后,模型能够更准确地捕捉到目标和情感特征之间的关联,提取关键的情感特征,从而实现正确的情感极性判别。本文模型的召回率相对于 ATAE-LSTM 提高了 1.58%,说明相比于基于方面嵌入的注意力 LSTM 模型,本文模型的门控卷积更适用于对目标的局部情感特征的提取,效果更好。本文模型的召回率相对于 GCAE 提高了 1.16%,使用 LSTM 模块,可以使用 LSTM 的优势对文本进行处理,LSTM 具有长期记忆功能;再加上门控卷积神经网络,门控卷积神经可以有效地提取关键特征,所以可以对观点句中的情感特征进行有效提取,由此取得较好的效果。通过对比实验,验证了本文提出方法在特定目标情感分析任务上的可行性。

3 结束语

本文提出了一种基于 LSTM-GCAE 的特定目标情感分析模型。该模型将上下文词向量和目标词向量进行融合之后作为 LSTM 的输入,强化了目标词和上下文之间的联系。并采用 LSTM 处理序列化信息的优势对融合词向量进行编码,可以捕捉到句子内部的语义关联。采用门控卷积机制提取与目标相关的重要的情感特征,与三个基准模型的对比实验中达到较好的性能,验证了本文模型的有效性。本文中仅仅将上下文和目标词进行了融合,未考虑句子中情感词的特征,在接下来的工作中尝试将情感词特征融合到模型的输入中,进一步提升模型的性能。

参考文献:

- [1] Wang S, Mazumder S, Liu B, et al. Target-sensitive memory networks for aspect sentiment classification[C]. Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers), 2018: 957–967.
- [2] 赵妍妍, 亲兵, 石秋慧, 等. 大规模情感词典的构建及其在情感分类中的应用[J]. 中文信息学报, 2017, 31(2): 187–193.
- [3] 朱嫣岚, 闵锦, 周雅倩, 等. 基于 HowNet 的词汇语义倾向计算[J]. 中文信息学报, 2006, 20(1): 14–20.
- [4] Agarwal B, Mittal N. Machine learning approach for sen-

- timent analysis [M]. Prominent Feature Extraction for Sentiment Analysis. Springer, Cham 2016: 21 – 45.
- [5] 孔杏, 林庆. 主观性文本情感分类研究综述 [J]. 信息技术 2018, 42(8): 126 – 130, 134.
- [6] Gao Y, Zhang Y, Xiao T. Implicit syntactic features for target-dependent sentiment analysis [C]. Proceedings of the Eighth International Joint Conference on Natural Language Processing (Volume 1: Long Papers) 2017: 516 – 524.
- [7] Pontiki M, Galanis D, Papageorgiou H, et al. Semeval2016 task 5: aspect based sentiment analysis [C]. International Workshop on Semantic Evaluation 2016: 19 – 30.
- [8] 陈思远, 彭超, 蔡林森, 等. 一种用于特定目标情感分析的深度网络模型 [J]. 计算机工程, 2019, 45(3): 286 – 292.
- [9] Wei Xue, Tao Li. Aspect based sentiment analysis with gated convolutional networks [J]. arXiv preprint arXiv: 1805.07043 2018.
- [10] 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.
- [11] Li L, Zhou A, Liu Y, et al. Aspect-based sentiment analysis based on dynamic attention GRU [J]. Scientia Sinica Informationis 2019, 49(8): 1019 – 1030.
- [12] Bin L, Quan L, Jin X, et al. Aspect-based sentiment analysis based on multi-attention CNN [J]. Journal of Computer Research and Development, 2017, 54(8): 1724.
- [13] 曹卫东, 李嘉琪, 王怀超. 采用注意力门控卷积网络模型的目标情感分析 [J]. 西安电子科技大学学报: 自然科学版 2019, 46(6): 30 – 36.
- [14] 孙承爱, 赵瑞, 田刚. 基于 Aspect 带有 CNN 注意力机制的门控卷积网络与情感分析 [J]. 软件, 2019, 40(7): 8 – 15.
- [15] Li S, Zhao Z, Hu R, et al. Analogical reasoning on chinese morphological and semantic relations [J]. arXiv preprint arXiv: 1805.06504 2018.
- [16] Hochreiter S, Schmidhuber J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735 – 1780.
- [17] Dauphin Y N, Fan A, Auli M, et al. Language modeling with gated convolutional networks [C]. International Conference on Machine Learning. PMLR 2017: 933 – 941.
- [18] 马远浩, 曾卫明, 石玉虎, 等. 基于加权词向量和 LSTM-CNN 的微博文本分类研究 [J]. 现代计算机: 专业版 2018(25): 18 – 22.
- [19] Li Y X, Tan C L, Ding X Q, et al. Contextual post-processing based on the confusion matrix in offline handwritten Chinese script recognition [J]. Pattern Recognition 2004, 37(9): 1901 – 1912.

(责任编辑: 杨静)

(上接第 6 页)

- [12] Urbanowicz R J, Melissa M, La C W, et al. Relief-based feature selection: introduction and review [J]. Journal of Biomedical Informatics 2018, 85: 189 – 203.
- [13] Kumar M, Rath N K, Swain A, et al. Feature selection and classification of microarray data using mapreduce based ANOVA and K-nearest neighbor [J]. Procedia Computer Science 2015, 54: 301 – 310.
- [14] Guo Su-xin, Zhong Sheng, Zhang Ai-dong. Privacy-preserving kruskal-wallis test [J]. Computer Methods & Programs in Biomedicine 2013, 112(1): 135 – 145.
- [15] Srivastava A K, Kumar Y, Singh P K. Computer aided diagnostic system based on SVM and K harmonic mean based attribute weighting method [J]. Obesity Medicine 2020, 19: 100270.
- [16] Erick O O, George O O, Michael W K. Feature selection for classification using principal component analysis and information gain [J]. Expert Systems with Applications 2021, 174: 114765.
- [17] Zare M, Eftekhari M, Aghamollaei G. Supervised feature selection via matrix factorization based on singular value decomposition [J]. Chemometrics and Intelligent Laboratory Systems 2019, 185: 105 – 113.
- [18] Song Yang, Zhang Jing, Zhang Yu-dong, et al. Feature explorer (FAE): a tool for developing and comparing radiomics models [J]. PLOS ONE, 2020, 15(8): 0237587.

(责任编辑: 杨静)