

文章编号: 2096-1618(2020)02-0139-07

基于 LSTM 前融合中文情感倾向分类模型的研究

王 铃, 陶宏才

(西南交通大学信息科学与技术学院, 四川 成都 611756)

摘要:在互联网平台上,用户可以针对电影、新闻等发表自己的观点、表达自己的情感,为其他用户提供消费该商品的参考意见,也帮助产品经理制定有效的产品消费策略。目前,针对中文情感倾向分类、深度学习的方法取得了一定的成就,尤其是长短期记忆神经网络(LSTM)。该网络是一个时序模型,可以很好地理解评论语义抓住评论中蕴含的情感倾向,但是它存在词向量构建阶段无法突出情感词的情感信息,以及无法针对不同场景进行文本情感倾向分析的问题。为此,提出 LSTM 前融合情感倾向分类模型。新模型利用情感词的情感标签修正情感词向量,解决了情感词向量无法突出情感信息的问题,并且将电影的简介作为一个输入特征融合到最终句子的特征向量中,实现针对具体的电影新闻场景评论情感倾向分类。实验结果表明,新模型相对于基本的 LSTM 模型取得了更好的效果,亦表明该模型能更加精确地抓取评论的情感信息。

关键词:情感倾向分类;LSTM;情感词向量;前融合模型

中图分类号:TP391.1

文献标志码:A

doi:10.16836/j.cnki.jcuit.2020.02.003

0 引言

在Web 2.0时代,科技飞速发展、计算机技术突飞猛进以及电子产品的全民化普及都为用户提供了一个在线陈述观点、发布评论、表达情感的便捷平台,让用户可以随时随地在各种电商平台、社会化媒体平台以及社交软件上表达自己的观点和评论。这些评论中蕴含着大量的有用信息,可以为其他用户提供消费该产品的参考意见,也有助于产品经理制定高效的评论智能灌入策略和排序策略,提高用户交互行为,引导流量,增加产品收益。因此,为了分析和了解互联网用户的短文本评论信息,中文情感倾向分析技术应运而生。

情感倾向分析^[1-3],又称观点挖掘,是对带有情感色彩的主观性中文文本进行分析、处理、归纳和推理的过程^[4]。其分析方法通常采用基于词典、基于机器学习分类算法和基于深度学习三大类。到目前为止,深度学习方法在自然语言处理中应用最为广泛。其中,Socher等^[5]先后使用递归神经网络(recursive neural network, RNN)和递归神经张量网络(recursive neural tensor network, RNTN)处理文本情感分析,所提出的模型在预测单句的情感极性以及对句子细粒度情感分析上都有比较突出的表现。而循环神经网络中的长短期神经网络能够捕获评论上下文信息,在解决中文评论情感倾向分类^[6-10]中有很大的进步。为了更加突出评论中的情感信息,提出了一种 LSTM^[11]前融合情感倾向分类模型,通过情感词标签修正情感词向量,添加一

个输入特征(评论场景)实现特定场景下中文评论情感倾向信息的增强,取得更好的分类效果。

1 相关工作

1.1 word2vec 工具

通过对 word2vec^[12-13]的两个模型 CBOW (continuous bag-of-words model) 和 Skip-gram 进行实验对比,得出基于负采样的 CBOW 模型效果最佳,故采用基于负采样的 CBOW 模型训练评论原始词向量。该模型主要是通过词 w_i 的上下文 $context(w_i)$ 预测词 w_i ,该词 w_i 就是一个正样本,除 w_i 以外的词就是负样本。通过负采样可构成一个关于 w_i 的负采样集合 $NEG(w_i) \neq \Phi$,其词标签组成为

$$L^{w_i}(w_j) = \begin{cases} 1 & w_j = w_i \\ 0 & w_j \neq w_i \end{cases} \quad (1)$$

对于给定的正样本,该模型需要优化的目标函数为

$$g(w_i) = \prod_{w_j \in \{w_i\} \cup NEG(w_i)} p(w_j | context(w_i)) \quad (2)$$

其中,

$$p(w_j | context(w_i)) = \begin{cases} \sigma(X_{w_i}^T \theta^{w_j}) & L^{w_i}(w_j) = 1 \\ 1 - \sigma(X_{w_i}^T \theta^{w_j}) & L^{w_i}(w_j) = 0 \end{cases} \quad (3)$$

综上,CBOW 模型的目标函数为

$$g(w_i) = \sigma(X_{w_i}^T \theta^{w_i}) \cdot \prod_{w_j \in NEG(w_i)} [1 - \sigma(X_{w_i}^T \theta^{w_j})] \quad (4)$$

1.2 LSTM 模型

长短期神经网络(LSTM)是一种时序模型,该模

型能够记忆评论句子上下文信息,不仅解决了长期依赖问题,还解决了传统循环神经网络(RNN)^[14]存在的梯度消失和梯度爆炸问题。图1是LSTM模型的单元网络结构,该模型包含了3个门逻辑:输入门、遗忘门和输出门。




图1 LSTM单元网络结构

图1中的 f_t 、 i_t 、 o_t 和 C_t 分别代表遗忘门、输入门、输出门和网络内部记忆单元。 W_i 、 W_f 、 W_o 、 W_c 、 b_i 、 b_f 、 b_o 、 b_c 表示 t 时刻输入变量在各个部分的权重矩阵和偏置矩阵, U_i 、 U_f 、 U_o 、 U_c 表示上一层输出 H_{t-1} 在这一层各个部分的权重矩阵, C'_t 表示本层细胞单元中信息的保留程度。

遗忘门主要控制 t_{t-1} 时刻记忆单元信息的遗忘程度;输入门主要决定 t 时刻计算新的状态更新到记忆单元中的程度;输出门主要决定 t 时刻记忆单元对 t 时刻输出的影响程度。该模型的 t 时刻更新计算公式为输入门计算公式是

$$i_t = \text{sigmoid}(W_i x_t + U_i H_{t-1} + b_i) \quad (5)$$

遗忘门计算公式是

$$f_t = \text{sigmoid}(W_f x_t + U_f H_{t-1} + b_f) \quad (6)$$

输出门计算公式是

$$o_t = \text{sigmoid}(W_o x_t + U_o H_{t-1} + b_o) \quad (7)$$

记忆单元更新公式是

$$C'_t = \tanh(W_c x_t + U_c H_{t-1} + b_c) \quad (8)$$

$$C_t = f_t \otimes C_{t-1} + i_t \otimes C'_t \quad (9)$$

每层输出的信息计算公式是

$$H_t = o_t \otimes \tanh(C_t) \quad (10)$$

2 一种新的中文情感倾向分类模型

2.1 问题的提出

基于长短期神经网络^[15-16]的中文评论文本情感倾向分析^[17]模型,仅能分析中文文本本身的情感倾向,即把同样的一条评论放到不同的场景下,该模型针对这条评论的情感倾向分析结果是一样的。文中将通过添加评论场景特征,对不同场景下的评论进行情感

倾向分类的研究分析,并且结合情感词的情感标签修正情感词向量,以此增强评论句子的情感倾向信息,达到更加准确的分类目的。

2.2 新的LSTM前融合模型

2.2.1 新模型概述

基于LSTM的前融合中文情感倾向分类模型和基于LSTM中文情感倾向分类模型的区别主要有两点:

(1)评论句子向量中的情感词向量是通过情感词倾向标签修正之后的情感词向量,以此实现突出句子情感倾向信息的效果;

(2)前融合模型是在LSTM模型的输入层和隐藏层之间添加了一个数据融合处理逻辑,即将评论场景作为一个输入特征添加到原始评论的输入特征中,以此增强评论句子的情感倾向,实现针对场景的评论情感倾向分类。

基于LSTM的前融合中文情感倾向分类模型的单元网络结构如图2所示,它与图1的区别在于输入层和隐藏层之间对输入向量 x 和场景特征向量 a 进行了一个拼接转换处理,以此得到评论短文本最终的句子特征向量,实现针对具体评论场景的特征提取。该模型的实现框架如图3所示。




图2 LSTM前融合单元网络结构

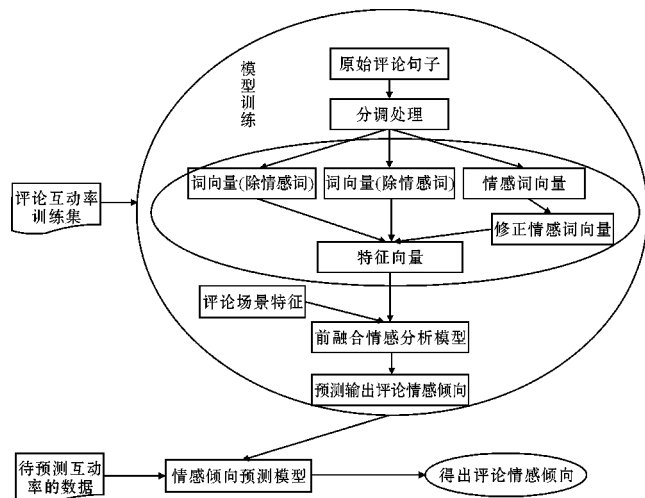


图3 前融合情感倾向分类模型框架

2.2.2 词嵌入

情感倾向分类的前提是如何将评论句子转换成计算机理解的形式,即将文本向量化。传统的 one-hot 编码方式存在维数庞大、矩阵稀疏以及无法在语义上正确表示两个词关系的问题。相反,词嵌入是将一个词语映射到一个低维的稠密空间,解决了 one-hot 编码方式存在的高维、稀疏问题;同时,这种方式能够让语义上相似的两个词语距离比较近,不相似的两个词语距离比较远,这就在语义上很好地表示了两个词语之间的关系,解决了 one-hot 存在的在语义上无法正确表达的问题。

利用 word2vec 工具的 CBOW 模型构建词典(PAD 表示填充词,UNK 表示未知词)和对应的词向量集合,实现词嵌入。文本向量化具体步骤为:首先将经过预处理的评论句子根据词典构建索引向量,如公式(11)所示;其次通过索引向量从词向量集合中获取对应词语的词向量;最后根据顺序组合获取的词语向量,得到评论句子的句子向量,如公式(12)所示,实现评论文本向量化。

$$\begin{bmatrix} word_1 \\ word_2 \\ \dots \\ word_{n-1} \\ word_n \end{bmatrix}^T + \begin{bmatrix} 0:PAD \\ 1:UNK \\ 2:word_1 \\ 3:word_2 \\ \dots \\ m-1:word_{n-1} \\ m:word_n \end{bmatrix} \Rightarrow \begin{bmatrix} 2 \\ 3 \\ \dots \\ m-1 \\ m \end{bmatrix}^T \quad (11)$$

$$\begin{bmatrix} 2 \\ 3 \\ \dots \\ m-1 \\ m \end{bmatrix}_{n \times 1} + \begin{bmatrix} x_{0,0} & x_{0,1} & \dots & x_{0,198} & x_{0,199} \\ x_{1,0} & x_{1,1} & \dots & x_{1,198} & x_{1,199} \\ x_{2,0} & x_{2,1} & \dots & x_{2,198} & x_{2,199} \\ x_{3,0} & x_{3,1} & \dots & x_{3,198} & x_{3,199} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{m-1,0} & x_{m-1,1} & \dots & x_{m-1,198} & x_{m-1,199} \\ x_{m,0} & x_{m,1} & \dots & x_{m,198} & x_{m,199} \end{bmatrix}_{m \times 200} \Rightarrow \begin{bmatrix} x_{2,0} & x_{2,1} & \dots & x_{2,198} & x_{2,199} \\ x_{3,0} & x_{3,1} & \dots & x_{3,198} & x_{3,199} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{m-1,0} & x_{m-1,1} & \dots & x_{m-1,198} & x_{m-1,199} \\ x_{m,0} & x_{m,1} & \dots & x_{m,198} & x_{m,199} \end{bmatrix}_{n \times 200} \quad (12)$$

2.2.3 情感词向量修正

通过修正情感词的词向量强化评论句子的情感倾向,增加情感倾向预测分类的准确性。情感词向量修正,即是根据已经标注的情感词倾向标签对情感词的原始向量进行不断训练,直到其情感分类准确率达到 99%,得到相应的参数矩阵和偏移矩阵;再利用参数矩阵和偏移矩阵对情感词语原始向量进行修正,如公式

(13),最终得到一个修正后的情感词向量集合,用于后面评论句子特征向量的构建。此处用于训练的的是一个 3 层的神经网络,其网络结构如图 4 所示。情感词向量修正的具体步骤如下:

(1)根据知网情感相关词语文件进行去重、整理和筛选,构建适合研究的情感词典;

(2)根据构建的情感词典从 CBOW 模型构建的原始词向量集合中,获取相应的情感词原始向量;

(3)创建一个 3 层的神经网络,其隐藏层的大小是原始词向量的维度;

(4)将已经标注好情感倾向标签的情感词向量集合按照 5:1 划分训练集和验证集;

(5)对已经划分好的训练集和验证集,采用六折交叉验证的方式进行训练。即将实验数据集划分为 6 个子样本,选取其中 1 个样本作为验证集,其他 5 个作为训练集对该情感词向量修正模型进行训练,交叉验证重复 6 次,保证每个子样本都要验证 1 次,然后平均 6 次的验证结果数据,得到最终的模型评估数据;

(6)直到分类精确度达到 99%,才输出相应的参数矩阵和偏移矩阵;

(7)利用参数矩阵和偏移矩阵,修正情感词原始向量。




图4 3层神经网络结构图

$$\begin{aligned} V_{\text{修正}} &= X_{\text{原始}} W_1 + b_1 \\ &= \begin{bmatrix} x_{0,0} & x_{0,1} & \dots & x_{0,k-1} \\ x_{1,0} & x_{1,1} & \dots & x_{1,k-1} \\ \vdots & \vdots & \vdots & \vdots \\ x_{5740,0} & x_{5740,1} & \dots & x_{5740,k-1} \end{bmatrix} \cdot \begin{bmatrix} w_{0,0} & w_{0,1} & \dots & w_{0,k-1} \\ w_{1,0} & w_{1,1} & \dots & w_{1,k-1} \\ \vdots & \vdots & \vdots & \vdots \\ w_{k-1,0} & w_{k-1,1} & \dots & w_{k-1,k-1} \end{bmatrix} + [b_{0,0} \quad b_{0,1} \quad \dots \quad b_{0,k-1}] \end{aligned} \quad (13)$$

2.2.4 特征向量构建

根据对数据集评论句子长度(评论句子分词,去掉停用词之后的词语个数)的统计分析,如图5所示,得到95%的评论数据的句子长度都 ≤ 60 ,故文中提取评论句子的特征数目确定为60,可以尽量多地包含评

论句子的特征信息。当评论句子样本长度小于 60 时,在所有特征词前用 0 (即填充词) 补齐;当评论句子样本长度大于 60 时,截断大于 60 之后的词语,只保留前 60 个词语作为评论句子的特征。

中 45 部电影的评论数据,共计 27000 条原始数据,经过数据清洗、整理之后得到有效数据为 25758 条。其中,正面评论 8601 条;中性评论 8554 条;负面评论 8603 条,该数据集分布如表 1 所示。

表 1 实验数据集

极性	数目
正面评论	8601
中性评论	8554
负面评论	8603




图 5 评论句子长度分布柱状图

在构建评论句子特征向量的过程中,传统的方式是从 word2vec 模型构建的词向量集合中,获取句子包含词语对应的词向量进行组合,得到最终的句子特征向量 X ,如图 6 所示;文中特征向量不仅在传统的特征向量上进行情感词向量 Q 的修正,如图 7 所示,而且还在修正之后的句子特征向量之前拼接了评论场景特征向量 V (取评论场景特征数目为 5),如公式 (14)。经过以上处理,得到最终的模型输入特征向量,其特征数目为 65。




图 6 传统方式构建特征向量




图 7 情感词修正的特征向量

对于不同的学习任务,会有不同的评价标准。针对分类任务,其合适的评价指标就是精确率 (precision)、召回率 (recall) 和 $F1$ 值^[9]。

精确率:查准,表示在预测为正面样本的结果中,有多少个样本是正确被分类的。

$$precision = \frac{num_{correct}}{num_{predict_total}} \tag{15}$$

召回率:表示在真正的正面样本中,有多少个样本数据是被正确分类的。

$$recall = \frac{num_{correct}}{num_{real_total}} \tag{16}$$

$F1$ 值:由于直接根据精确率高或者召回率高不一定能说明该模型就是好,因此利用 $F1$ 值评估模型的效果。 $F1$ 值即精确率和召回率的调和平均值,能够全面衡量精确率和召回率两个评价指标,综合地反映模型的整体分类效果。

$$F1 = \frac{2 \times recall \times precision}{recall + precision} \tag{17}$$

3 实验及分析

3.1 数据集

3.3 实验过程和参数

3.3.1 CBOW 和 Skip-gram 模型对比实验

使用 3.1 中的 25758 条电影评论作为实验数据集。

利用 python 的 scrapy 框架爬取豆瓣电影 top250

在此数据集上通过对 word2vec 工具的 CBOW 和 Skip-gram 模型进行实验对比分析,得出在基于负采样的 CBOW 模型中词向量维度为 200 维、滑动窗口 window(即当前词与预测词在一个句子中的最大距离)为 2 的情况下构建词向量效果最佳,实验结果如表 3 所示。

表 3 CBOW 和 Skip-gram 模型对比实验结果数据

模型组合	滑动窗口				
	1	2	3	4	5
CBOW +Hierarchical Softmax	0.71	0.64	0.67	0.61	0.60
Skip-gram+Hierarchical Softmax	0.68	0.64	0.58	0.47	0.50
CBOW +Negative Sampling	0.92	0.93	0.92	0.91	0.92
Skip-gram+Negative Sampling	0.89	0.85	0.84	0.82	0.76

3.3.2 情感词向量修正实验

本文情感词向量修正实验中,情感词典是对知网的正面评价词语、正面情感词语、负面评价词语和负面情感词语进行筛选和整理得到,共计 5741 个词语。

情感词向量的修正过程中,分别对学习率、批处理大小以及迭代次数等参数进行了调整,其实验数据如表 4 所示,得出最优结果是学习率 lr 为 0.001、批处理大小 batch 为 8、epochs 迭代次数为 70 的条件下其准确率最高为 99.73%,该条件下的训练集和验证集的 accuracy 值和 loss 值如图 8、图 9 所示。

表 4 情感词向量修正实验结果

batch, epochs, lr	accuracy	loss
8, 30, 0.005	0.9904	0.0338
8, 30, 0.001	0.9943	0.0218
8, 50, 0.005	0.9960	0.0137
8, 50, 0.001	0.9959	0.0201
8, 70, 0.005	0.9951	0.0262
8, 70, 0.001	0.9973	0.0109
12, 50, 0.005	0.9948	0.0198
12, 50, 0.001	0.9949	0.0216
12, 70, 0.005	0.9971	0.0106
12, 70, 0.001	0.9964	0.0160




图 8 训练集和验证集 accuracy 图




图 9 训练集和验证集 loss 图

3.3.3 情感倾向分类实验

情感倾向分类实验进行训练的过程中,分别对参数学习率 lr、批处理大小 batch 和迭代次数 epochs 进行了调整,实验结果如表 5 所示。根据实验结果得出最优方案是学习率为 0.005、批处理大小为 128、迭代次数为 70。该方案计算出模型的准确率 accuracy 为 99.72%,该条件下的训练集和验证集的 accuracy 值和 loss 值如图 10 所示。

表 5 情感倾向分类实验结果

batch, epochs, lr	accuracy	loss
64, 50, 0.001	0.9271	0.1243
64, 50, 0.005	0.9408	0.1009
64, 70, 0.005	0.9362	0.1154
128, 50, 0.005	0.9824	0.0501
128, 70, 0.005	0.9972	0.0067
128, 70, 0.001	0.9881	0.0330




图 10 前融合模型训练集和验证集实验数据

3.4 对比实验

提出的前融合情感倾向分类模型是在 LSTM 模型的基础上进行改进的,根据两个模型的预测数据,计算模型的 3 个评价指标,得出该模型与基本的 LSTM 情感倾向分类模型的对比实验结果,如表 6 所示。

表 6 模型对比评价指标结果

模型	精确率	召回率	F1 值
前融合模型	0.9944	0.9822	0.9882
基本 LSTM 模型	0.9726	0.9820	0.9773

实验结果表明前融合情感倾向分类模型的效果相对于基本的 LSTM 情感倾向分类模型要好,分类的准确率大约提高了 1%。

4 结束语

中文文本情感倾向分类研究一直是自然语言处理领域一个非常重要的任务。基于 LSTM 模型提出了利用情感词倾向标签修正情感词向量,并融合评论场景向量的前融合情感倾向分类模型,来解决不同场景下电影中文评论数据的情感倾向分析问题。首先,通过 word2vec 中的 CBOW 模型创建词典和原词词向量集合;其次,根据构建的情感词词典从原词词向量集合中提取出对应情感词向量,通过 3 层神经网络根据情感词倾向标签修正情感词向量,构建情感词向量结合;然后,结合评论场景向量、情感词向量集合、以及原始词向量集合构建评论样本数据的特征向量对前融合模型进行训练;最后,通过与基本的 LSTM 模型进行对比实验证明了提出的前融合情感倾向分类模型能够突出评论句子的情感信息,在电影中文评论分类任务中效果更加好,准确率更高。

参考文献:

[1] Liu B. Sentiment analysis: mining opinions, sentiments, and emotions[C]. The Cambridge University Press, 2015.

[2] Liu B. Sentiment analysis and opinion mining(introduction and survey), Morgan & Claypool, May 2012.

[3] Pang B. , Lee L. A sentimental education: Sentiment analysis using subjectivity summ-arization based on minimum cuts [C]. Proc-eedings of the 42nd Annual Meeting on Ass-ociation for Computational Linguistics. Stro-udsburg, PA, USA: ACL, 2004:271-278.

[4] 百度百科. 文本情感分析 [DB/OL]. <https://baike.baidu.com/item/%E6%96%87%E6%9C%AC%E6%83%85%E6%84%9F%E5%88%86%E6%9E%90/19431243?fr=aladdin>, 2019-01-12.

[5] Socher R, Perelygin A, Wu J Y, et al. Re-cursive deep models for semantic compositionality over a sentiment treebank [C]. Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing, EMNLP. 2013:1631-1642.

[6] Ma X L, Jin B Y, Fan B S. An Analysis of Chinese Text Emotional Tendency [J]. Information and Documentation Service, 2013(1):52-56.

[7] 黄莹菁, 张奇, 吴苑斌. 文本情感倾向分析 [J]. 中文信息学报, 2011, 25(6):118-126.

[8] 赵妍妍, 秦兵, 刘挺. 文本情感分析 [J]. 软件学报, 2010, 21(8):1834-1848.

[9] 李艺红, 蒋秀凤. 中文句子倾向性分析 [J]. 福州大学学报(自然科学版), 2010, 38(4):504-508.

[10] 夏玉芹, 单雪微. 基于 Python 的简单文本情感分析 [J]. 阴三学刊, 2018, 32(4):58-62.

[11] 周虎, 于跃, 贾媛媛, 等. 基于深度 LTSM 神经网络的在线消费评论情感分类研究 [J]. 中华医学图书情报杂志, 2018, 27(5):23-29.

[12] 黄东晋, 纪浩, 耿晓云, 等. 基于文本矢量特征的电影评分预测模型 [J]. 现代电影技术, 2019(3):44-50.

[13] 王名扬, 吴欢, 贾晓婷. 结合 word2vec 与扩充情感词典的微博多元情感分类研究 [J]. 东北师大学报(自然科学版), 2019, 51(1):55-62.

[14] 胡荣磊, 芮璐, 齐筱, 等. 基于循环神经网络和注意力模型的文本情感分析 [J]. 计算机应用研究, 2019, 36(11):3282-3285.

[15] 金宸, 李维华, 姬晨, 等. 基于双向 LSTM 神经网络模型的中文分词 [J]. 中文信息学报, 2018, 32(2):29-37.

[16] 张玉环. 基于多种 LSTM 结构的文本情感分析 [D]. 北京:北京邮电大学, 2018.

[17] Wang J. , Cao Z. W. Chinese Text Sentiment Analysis Using LSTM Network Based on L2 and Nadam [C]. Proceedings of 2017 17th IEEE International Conference on Communication Technology (ICCT 2017), 2017:1891-1895.

Research on the Classification Model of Pre-fusion Chinese Emotion Tendency based on LSTM

WANG Ling, TAO Hongcai

(School of Information Science & Technology, Southwest Jiaotong University, Chengdu 611756, China)

Abstract: Users can express their own opinions and emotions on the Internet platform for movies, news, etc., provide other users with reference opinions on consumption of the product, and help product strategists to formulate effective product consumption strategies. At present, although for the classification of Chinese affective tendencies, deep learning method has made achievements, especially Long Short-Term Memory Model (LSTM). The network is a time series model, which can well understand the comment semantics and grasp the emotional tendency contained in the comment. However, it has the problems that the emotional information of emotional words cannot be highlighted in the construction stage of word vector and the emotional tendency analysis of text cannot be carried out for different scenes. For this, a LSTM pre-fusion emotional tendency classification model is proposed in this paper, which uses emotional labels of emotional words to modify the emotional words vector, solves the problem that emotional words vector can not highlight emotional information, and integrates the brief introduction of the movie as an input feature into the final sentence feature vector to achieve the emotional tendency classification of specific movie news scene comments. The experimental results show that the novel model is better than the basic LSTM model, and can capture the emotion information of comments more accurately.

Keywords: classification of emotional tendency; LSTM; emotional words vector; pre-fusion model