



A Sentiment Classification Model Based on Deep Learning and Two Level Stacking SVM

Fei He, Baozhong He, Can Wu and Maobao Yang

EasyChair preprints are intended for rapid dissemination of research results and are integrated with the rest of EasyChair.

June 28, 2023

结合深度学习与双阶段 SVM 的情感分类方法

摘要: 由于短文本包含有限、稀疏的上下文信息,采用机器学习算法无法有效提取特性且短文本并不总是遵守书面语言的语法,因此如何有效提取短文本特征并设计分类效果更好的分类器以提高情感分类的准确率具有重要研究意义。本文针对上述问题,提出结合深度学习与双阶段 SVM 的情感分类方法,在该方法中,首先采用基于注意力机制的卷积神经网络提取文本向量的局部特征,采用基于注意力机制的双向长短期记忆神经网络提取与文本上下文相关的全局特征,其次,将得到的两类特征进行融合,并将融合特征作为分类器的输入;最后,为进一步提高分类准确率,在情感分类阶段不再采用传统的 softmax 算法,而是采用双阶段 stacking 支持向量机分类算法。实验结果表明,本文提出的结合深度学习与双阶段 SVM 的情感分类方法相对于传统的卷积神经网络模型在中、英文数据集上的准确率分别提高了 13.19%和 7.9%,相对于传统的双向长短期记忆神经网络模型在中、英文数据集上的准确率分别提高了 12.55%和 7.68%,其中引入注意力机制的融合模型对中、英文数据集情感分类的准确率平均有 5.05%和 2.83%的提高,引入双阶段 stacking SVM 的模型对中、英文数据集情感分类的准确率有 7.82%和 4.96%的提高,并且召回率和 F 值也优于其他模型。

关键词: 情感分类;卷积神经网络;双向长短期记忆神经网络;注意力机制;集成学习;SVM

中图分类号: TP391

A sentiment classification model based on deep learning and two level stacking SVM

Abstract: Short text contains limited context information, which is too sparse to extract useful features using machine learning algorithm, and short text does not always follow the grammar of written language. Therefore, how to extract short text features effectively and design a better classifier to improve the accuracy of sentiment classification is of great significance. In order to solve above problems, in this paper we proposed sentiment classification method based on deep Learning and two-level stacking SVM (two-level stacking support vector machine, TS-SVM). In this method, first, CNN (convolutional neural network) based on attention mechanism (CNN-ATT) is used to extract the local features, the Bi-LSTM (Bi-directional Long Short-Term Memory model) based on attention mechanism (Bi-LSTM-ATT) is used to extract the global features, and the fusion features are used as input of the classifier; secondly, in order to further improve the classification accuracy, softmax algorithm is no longer used in this paper, but the TS-SVM classification algorithm is used. The results show that the accuracy of CNN/Bi-LSTM-ATT-TS-SVM is 13.19% and 7.9% higher than that of traditional CNN model on Chinese and English datasets, and 12.55% and 7.68% higher than that of traditional Bi-LSTM model on Chinese and English datasets, respectively. By introducing attention mechanism model the average accuracy of sentiment classification of Chinese and English datasets is improved by 5.05% and 2.83%, and the accuracy of sentiment classification of Chinese and English datasets by introducing two-stage stacking SVM is improved by 7.82% and 4.96%, and the recall rate and F value are also better than other models.

Keywords: sentiment classification; CNN; Bi-LSTM; attention mechanism; ensemble learning; SVM

收稿日期

情感分类是在文档、句子和短语级别对给定文本极性进行识别和分类^[1]。目前这项技术已广泛应用,例如制造商可根据评论对商品进行改进,消费者可根据评论做出采买决策。因此,作为自然语言处理(NLP)许多领域的一项重要任务,情感分类技术近年来得到了越来越多的关注。目前造成短文情感分类错误的主要原因有^[2]:(1)短文本包含有限的上下文信

息,对于机器学习算法来说,由于信息稀疏,无法有效提取特性;(2)短文本并不严格遵守书面语言的语法。目前文本情感分类中最常用的仍是监督学习方法,其关键是特征提取与分类器设计。因此,如何从短文本中有效提取特征,并设计分类效果更好的分类器具有重要研究意义。本研究采用基于注意力机制的卷积神经网络(Convolutional Neural Network Based

on Attention Mechanism, CNN-ATT) 与基于注意力机制的双向长短期记忆神经网络 (Bi-directional LSTM Based on Attention Mechanism, Bi-LSTM-ATT) 提取文本特征, 并采用改进的支持向量机 (Support Vector Machine, SVM) 算法进行情感分类。在该算法中, 首先对数据集进行预处理, 并采用 word2vec 模型构造嵌入词; 其次, 在特征提取层面上, 本文利用 CNN-ATT 提取文本向量的局部特征, 利用 Bi-LSTM-ATT 提取与文本上下文相关的全局特征, 并将两种网络提取的特征进行融合作为分类器的输入; 然后, 使用双阶段 stacking SVM (two level stacking SVM, TS-SVM) 分类算法作为情感分类器; 最后, 为了验证所提出算法的性能, 在实验仿真阶段, 采用带深度学习技术任务的 NLPCC2014 情感分类数据集 (NLPCC-SCDL) 对所提出的情感分类模型进行了评价。结果表明, 本文提出的 CNN/Bi-LSTM-ATT-TS-SVM 模型在中、英文数据集情感分类方面均优于传统的模型。

1 相关工作

1.1 情感分类

传统文本情感分类可以分为基于句法分析、基于词典分析与基于机器学习分析三大类。基于机器学习的情感分类方法主要基于 PANG Bo 等^[3]的工作, 将文本情感分类看作文本分类问题, 利用从情感词选取的大量嘈杂的标签文本作为训练集直接构建分类器 (朴素贝叶斯、支持向量机等)。近年来, 随着深度学习技术的发展, 人们提出了各种神经网络模型, 并在短文本情感分类方面取得了显著的效果。Kim^[4]首次将神经网络用于情感分类, 该方法是 CNN 的直接应用, 具有预先训练好的词嵌入功能。Kalchbrenner 等^[5]提出了一个动态 CNN 方法用于句子语义建模, 来处理长度不同的输入句子, 并在句子上生成一个特征图。这种模型能够明确地捕捉短期和长期的关系; Dos Santos 等^[6]提出了一个字符对句子 CNN (CharSCnn) 模型, 该模型使用两个卷积层从任意大小的单词和句子中提取相关特征, 对短文本进行情感分类; Xu 等^[7]提出了一个缓存的 LSTM 模型来捕获长文本中的整体语义信息; Zhou 等^[8]设计了由两个基于注意力的 LSTM 模型用于跨语言情感分类; Wang 等^[9]提出利用 CNN-LSTM

组合模型预测文本情感极性。以上方法是深度神经网络在情感分类领域的重要应用成果。

分类器设计对短文本情感分类准确率也有着重要影响。BP 神经网络、K 最近邻、随机森林和 SVM 等机器学习算法在情感分类任务中得到了广泛的应用。Tan 等^[10]采用四种特征选择方法和五种分类算法对中文文档进行情感分类; Cao 等^[11]提出采用 SVM 代替 CNN 中的完全连接层进行情感分类。为了进一步提高文本情感分类的准确性, 一些研究者引入了集成学习方法。Polikar^[12]证明大多数集成学习模型明显优于单一模型, 常用的集成学习方法有 bagging 和 boosting 算法, bagging 算法具有防止数据过拟合的优点, 包括随机森林和 stacking 算法。Yassine 等^[13]提出采用基于随机森林和 SVM 的集成方法进行情感分类; 金等^[14]利用 OOB 数据的 F 值为每个基分类器的不同类别赋予权值, 构造改进的 bagging 算法, 提出了一种新的基于深度学习与集成学习的情感分类模型。传统的 stacking 算法主要由初级训练器和次级训练器构成, 并由初级训练器的输出作为次级训练器的输入, 本文选用泛化能力强, 准确率高的 SVM 作为初级与次级训练器, 并构造双阶段 stacking SVM 分类算法。

1.2 注意力机制

注意力机制 (attention mechanism) 最早用在图像处理领域, Mnih 等^[15]在 2014 年提出将注意力机制用在图像分类任务中, 使得结合注意力机制的神经网络成为研究热点。由于注意力机制能很好解决同一句子中不同目标的情感极性判别问题, Bahdanau 等^[16]将注意力机制引入自然语言处理领域的编码器-解码器框架中, 该模型也是目前常用注意力模型的基础。随后, 基于注意力机制的编码器-解码器模型在机器翻译、文本分类、摘要生成等很多领域得到了应用^[17-18]。Yang 等^[19]提出采用注意力机制捕捉不同语义层次上的关键成分并用于文档分类; CHEN 等^[20]提出了一种分层神经网络, 通过词句级注意情感分类将用户和产品信息结合起来。随着研究的推进, Yin 等^[18]在 2015 年提出一种基于注意力机制的卷积神经网络, 并将该网络用在句子对建模任务中; Wang 等^[21]利用基于多层注意力机制的卷积神经网络进行句子关系分类, 这些方法的提出证明了注意力机制和神经网络结合的有效性。

2 结合深度学习与双阶段 SVM 的情感分类方法

本文提出的结合深度学习与双阶段 SVM 的情感分类方法系统框架如图 1 所示,该系统由三个模块组成:(1)数据预处理模块;(2)基于双注意力机制的特征表示模块;(3)双阶段 stacking SVM 情感分类模块。首先,利用 word2vec 模型从大量的原始文本集合中学习嵌入单词;其次,运用基于注意力机制的 CNN 和 Bi-LSTM 模型构建文本特征表示;最后,将融合特征作为分类器的输入,利用双阶段 stacking SVM 算法实现情感分类。

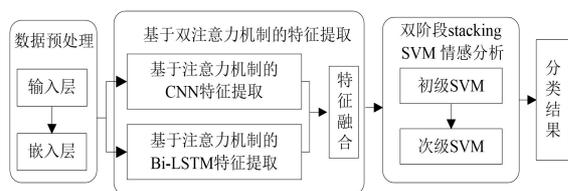


图 1 结合深度学习与双阶段 SVM 的情感分类方法

Fig.1 A sentiment classification model based on deep learning and two level stacking SVM

2.1 数据预处理

本文采用 NLPCC2014 情感分类数据集 (NLPCC-SCDL) 进行情感分类任务,此数据集包括中、英文产品评论(简称中、英文版,分别来自多个领域,包括书籍, DVD 和电子产品),在该系统中使用 word2vec 模型与训练得到中、英文词向量。中、英文数据集的例子分别如下(1)和(2)所示:

(1) 我看了介绍,可惜没有乐团和指挥的信息,而这恰恰是非常重要的。此外,这个版本并不完全,至少在第三幕里它没有“俄罗斯舞曲”。

(2) This blood pressure monitor worked well for 6 months until the cuff lost its elasticity making it impossible to tighten it securely enough. Now all I get is an error message when it tries to inflate

对于中文数据集来说,首先使用 jieba 分词对数据集进行处理,去除不规范的文本格式;对于英文数据集来说,直接通过空格进行分词处理并进行格式转换等,最终保留较多语义信息的中、英文文本,对上述文本进行预处理后得到的文本如下(3)和(4)所示:

(3) 我看了介绍,可惜没有乐团和指挥的信息,而这恰恰是非常重要的。

此外,这个版本并不完全,至少在第三幕里它没有俄罗斯舞曲。

(4) this blood pressure monitor worked well for 6 months until the cuff lost its elasticity making it impossible to tighten it securely enough. now all I get is an error message when it tries to inflate.

2.2 基于注意力机制的特征提取

2.2.1 基于注意力机制的 CNN 特征提取

图 2 为基于注意力机制的 CNN 特征提取框架。其中第一层是词向量表示层,输入句子矩阵的列和行分别是词向量的维度和序列长度;第二层是卷积层,主要通过卷积操作来提取句子的局部特征;第三层进行最大池化操作,提取关键特征,舍弃冗余特征,生成固定维度的特征向量,最后将池化层学习到的特征与注意力文本连接并作为全连接层输入特征的一部分,经过全连接层后得到特征表示结果。CNN 特征提取具体过程如下:将词 $W(i)$ 利用 word2vec 转化为对应的词向量 $E(W(i))$,其中 $E(W(i)) \in R^k$ 代表句子中第 i 个词,词向量为 K 维,文本矩阵表示为

$$\{E(W(1)), E(W(2)), \dots, E(W(m))\}, \quad (1)$$

用 $h \times k$ 的滤波器对文本矩阵执行卷积操作,得到局部特征为

$$c_i = f(F \cdot E(W(i:i+r-1)) + b), \quad (2)$$

式中: F 代表 $h \times k$ 滤波器, b 代表偏置量, f 代表通过 RELU 进行非线性操作的函数, $E(W(i:i+h-1))$ 为从 i 到 $i+h-1$ 共 h 行向量, c_i 为通过卷积操作得到的局部特征。随着滤波器依靠为 1 的步长从上往下进行滑动,走过整个句子,得到局部特征向量集合 $C_i \in R^t$ 。采用 n 个不同的滤波器对短文本中连续单词的 h 个窗口重复卷积运算,得到 $C_{1:m-h+1} \in R^{(m-h+1) \times n}$,采用 VALID 方式进行 padding 操作,获得与原输入相同长度的特征向量 $C_{1:m} \in R^{m \times n}$ 。

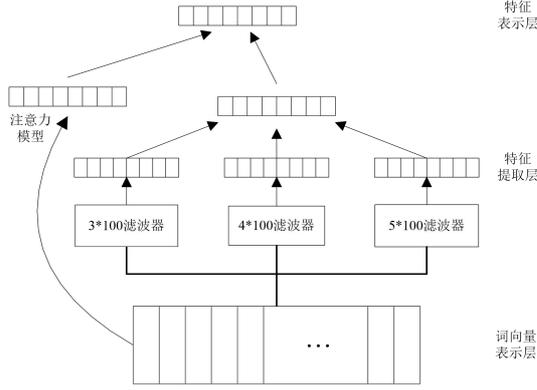


图2 基于注意力机制的 CNN 特征提取

Fig.2 CNN feature extraction based on attention mechanism

2.2.2 基于注意力机制的 Bi-LSTM 特征提取

Bi-LSTM 模型在传统 LSTM 模型上扩展而来，基于注意力机制的 Bi-LSTM 特征提取结构如图 3 所示，第一层是词向量表示层，将嵌入层的句子矩阵作为输入，第二层为基于注意力机制的 Bi-LSTM 特征提取层，其中隐藏层大小设为 128，当前输入与前后序列都相关，将输入序列分别从两个方向输入模型，经过隐含层保存两个方向的信息，最后将两个隐层输出部分拼接，得到最后的特征表示，其中正向 LSTM 在 t 时刻更新过程如下：

$$i_t = \sigma(\bar{W}_{xi}\bar{x}_t + \bar{W}_{hi}\bar{h}_{t-1} + \bar{W}_{ci}\bar{c}_{t-1} + b_i), \quad (3)$$

$$f_t = \sigma(\bar{W}_{xf}\bar{x}_t + \bar{W}_{hf}\bar{h}_{t-1} + \bar{W}_{cf}\bar{c}_{t-1} + b_f), \quad (4)$$

$$o_t = \sigma(\bar{W}_{xo}\bar{x}_t + \bar{W}_{ho}\bar{h}_{t-1} + \bar{W}_{co}\bar{c}_{t-1} + b_o), \quad (5)$$

$$g_t = \tanh(\bar{W}_{xc}\bar{x}_t + \bar{W}_{hc}\bar{h}_{t-1} + \bar{W}_{cc}\bar{c}_{t-1} + b_c), \quad (6)$$

$$\bar{c}_t = f_t\bar{c}_{t-1} + i_t \cdot g_t, \quad (7)$$

$$\bar{h}_t = o_t \cdot \tanh(\bar{c}_t). \quad (8)$$

式中： i_t, f_t, o_t, g_t 分别代表输入门、遗忘门、输出门和当前输入单元， \bar{c}_t 为细胞更新表达， \bar{h}_{t-1} 表示 $t-1$ 时刻的隐层状态， $\bar{W}_{xi}, \bar{W}_{xf}, \bar{W}_{xo}, \bar{W}_{xc}$ 分别为输入门相关权重， $\bar{W}_{hi}, \bar{W}_{hf}, \bar{W}_{ho}, \bar{W}_{hc}$ 为连接激活单元的权重， $\bar{W}_{ci}, \bar{W}_{cf}, \bar{W}_{co}, \bar{W}_{cc}$ 为连接激活单元与门的相关权重， b_i, b_f, b_o, b_c 为偏置项， σ 取 Sigmoid 函数，得到正向 LSTM 输出为 $\bar{h}_{forward}$ ，同理得到反向 LSTM 输出为 $\bar{h}_{backward}$ ，并将 2 个输出向量进行拼接，提取最终的特征

$$H = [\bar{h}_{forward}, \bar{h}_{backward}].$$

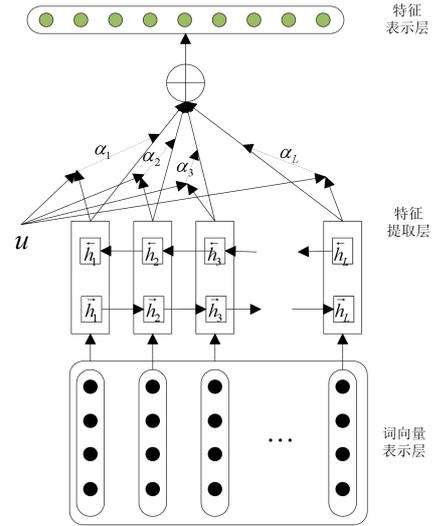


图3 基于注意力机制的 Bi-LSTM 特征提取

Fig.3 Bi-LSTM feature extraction based on attention mechanism

2.2.3 特征融合

在特征提取中，并不是每个 CNN-ATT 特征和 Bi-LSTM-ATT 特征都对分类做出了同等重要的贡献，注意力机制的理念是学会将注意力集中在特定的显著特征上，通过注意力机制达到自动识别与情感分类相关的输入文本的目的。采用 CNN 与 Bi-LSTM 得到的特征构建注意力机制的输入，注意力机制将会产生注意力权重矩阵 α 和特征表示 v ，如下式所示：

$$u_i = \tanh(W_s h_i + b_s), \quad (9)$$

$$\alpha_i = \frac{\exp(u_i u)}{\sum_i \exp(u_i u)}, \sum_i \alpha_i = 1, \quad (10)$$

$$v = \sum \alpha_i h_i. \quad (11)$$

式中： h_i 为 C_i 或 H ，注意力模型中的 α_i 与每一时刻的输入状态和一个随机初始化的上下文向量 u 有关，通过注意力机制得到基于注意力机制的 CNN 特征和 Bi-LSTM 特征分别为 a^L 和 a^S ，然后将基于注意力的特征融合，得到融合特征为

$$A = \left[[a_1^L, a_1^S]^T, [a_2^L, a_2^S]^T, \dots, [a_N^L, a_N^S]^T \right], \quad (12)$$

融合后的特征保存在 output 中，将其作为第一个全连接层的输入，再连接第二个全连接层，之后采用 dropout 机制，防止过拟合，最后输入到分类器输出分类结果，本文采用的分类算法将在下部分中介绍。

2.3 双阶段 Stacking SVM 情感分类

Stacking 算法是集成学习中的基学习器一种智能化结合算法, 该算法使用一个学习器来结合基学习器预测输出得到最终预测值。本文采用双阶段 Stacking SVM 分类策略如图 4 所示, 其中选取 100 个 SVM 学习器作为初级学习器, 并选用 SVM 作为次级学习器将基学习器融合在一起, 构建新的集成短文本情感分类模型。具体过程如下:

(1) 采用基于注意力机制的特征提取阶段得到的融合特征作为模型输入变量, 采用实际类别属性二值变量代表积极与消极情感, 用初级 SVM 分类器产生初级分类模型, 并得到属性预测概率。初级分类模型中, 每个模型有两个属性预测概率, 共能得到 200 个预测概率值。

(2) 以初级分类模型的预测属性概率值作为次级分类器 SVM 的模型输入, 仍然使用实际类别属性进行学习, 并获得最终情感类别预测结果。

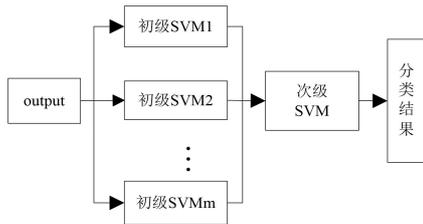


图 4 双阶段 Stacking-SVM 情感分类

Fig.4 Sentiment classification based on two level stacking SVM

3 实验与分析

3.1 数据集与评价指标

为了验证本文提出模型的有效性, 本文选用带深度学习技术任务的 NLPCC2014 情绪分类数据集 (NLPCC-SCDL) 对所提出的组合情绪分类模型进行了评价。选取中文数据集积极、消极评论各 6000 条, 并采用十折交叉验证, 采用同样的方法选取英文数据集。使用正确率 (Precision)、召回率 (Recall) 和 F1 值 (F1-measure) 作为评价标准, 如下所示:

$$Precision = \frac{TP}{TP + FP}, \quad (13)$$

$$Recall = \frac{TP}{TP + FN}, \quad (14)$$

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall}. \quad (15)$$

式中: TP (True Pos Sentiment) 表示正确分类为积极的数目; FN (False Neg Sentiment) 表示错误分类为消极的数目; FP (False Pos Sentiment) 表示错误分类为积极的数目; TN (True Neg Sentiment) 表示正确分类为消极的数目。

3.2 实验设计

实验代码语言为 python, 处理器为 Intel Xeon Gold 5118, 主频 2.3GHz, 操作系统为 Windows10, 64bit, 内存 64GB, 深度学习框架选用 TensorFlow, 词向量维度设置为 100 维, 注意力权重的维度和文本中的长度是一致的, 通过每个 batch 中 50 个样本的方式进行模型的训练, Dropout 设置为 0.5。本文对数据集进行了两组实验, 第一组是基于不同的特征提取表示方法对文本进行了分类, 确定训练网络的最佳方案; 第二组是采用不同的分类方法对文本进行分类, 验证本文提出的情感分类模型的有效性。将本文提出的方法和表 1 中的方法在数据集上进行实验, 模型设置见表 1。

3.3 实验结果与分析

本文将 5 组实验在 NLPCC-SCDL 数据集上进行实验, 分析特定目标的情感极性。表 2 给出中、英文数据集在 5 组模型上的情感分类结果。

由表 2 可知, 本文提出的 CNN/Bi-LSTM-ATT-TS-SVM 算法相对于传统的 CNN 模型在中、英文数据集上的准确率分别提高了 13.19% 和 7.9%; 相对于传统的 Bi-LSTM 模型在中、英文数据集上的准确率分别提高了 12.55% 和 7.68%, 其中引入注意力机制与融合特征的模型对中、英文数据集情感分类的平均准确率有 5.05% 和 2.83% 的提高, 引入双阶段 stacking SVM 模型对中、英文数据集情感分类的准确率有 7.82% 和 4.96% 的提高, 并且召回率和 F 值也优于其他模型, 充分证明本文提出方法有助于提升情感分类的准确率。

表 1 模型类别设置

Tab.1 Model type setting

| 编号 | 模型 | 特征类 | 分类器 |
|----|----|-----|-----|
|----|----|-----|-----|

| | | 型 | |
|---|----------------------------|----------|------------|
| 1 | CNN | 单特征 | Softmax |
| 2 | Bi-LSTM | 单特征 | Softmax |
| 3 | CNN/ Bi-LSTM-ATT | 融合特 征 | Softmax |
| 4 | CNN/ Bi-LSTM-ATT-SVM | 融合特 征 | SVM |
| 5 | CNN/ Bi-LSTM-ATT-TS-SVM | 融合特 征 | TS-SV M |

表 2 模型分类结果对比

Tab.2 Accuracy for models in optimal parameter (%)

| 编号 | 模型 | 中文数据集 | | | 英文数据集 | | |
|----|----------------------------|-------|------|------|-------|------|------|
| | | Pre | Rec | F1 | Pre | Rec | F1 |
| 1 | CNN | 75.3 | 78.4 | 76.8 | 84.9 | 86.5 | 85.7 |
| | | 4 | 6 | 7 | 2 | 3 | 1 |
| 2 | Bi-LSTM | 75.9 | 79.6 | 77.7 | 85.1 | 84.0 | 85.5 |
| | | 8 | 3 | 6 | 4 | 2 | 7 |
| 3 | CNN/ Bi-LSTM-ATT | 80.7 | 81.3 | 81.0 | 87.8 | 86.9 | 87.3 |
| | | 1 | 7 | 4 | 6 | 1 | 8 |
| 4 | CNN/ Bi-LSTM-ATT-SVM | 83.1 | 87.2 | 85.1 | 89.1 | 87.5 | 88.3 |
| | | 5 | 6 | 6 | 3 | 5 | 3 |
| 5 | CNN/ Bi-LSTM-ATT-TS-SVM | 88.5 | 92.5 | 90.5 | 92.8 | 93.3 | 93.0 |
| | | 3 | 7 | 0 | 2 | 5 | 8 |

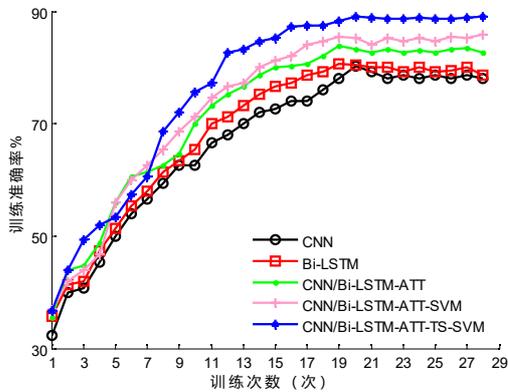


图 5 五种模式在中文数据集上封闭测试结果图

Fig.5 Test results on Chinese datasets

图 5 和图 6 分别展示了本文所提出方法与对比方法在中、英文数据集上测试的实验结果。图 5 和图 6 表明，随着训练次数的增加，各模型的分类型准确率逐渐提升，最基本的 CNN 单特征模型与 Bi-LSTM 单特征模型在迭代次数达到 20 次以后，中、英文训练集的准确率分别停留在 75% 和 85% 左右，均低于其他模型；在传统的 CNN 和 Bi-LSTM 模型上引入注意力

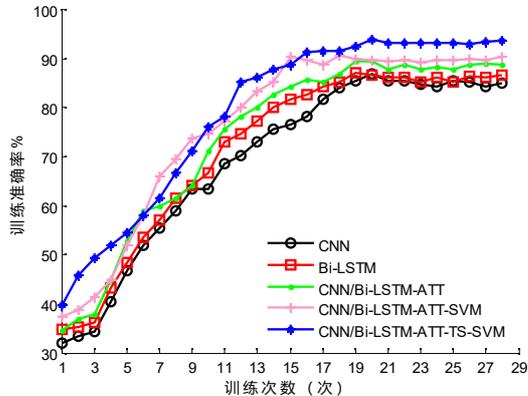


图 6 五种模式在英文数据集上封闭测试结果

Fig.6 Test results on English datasets

机制与融合模型后准确率停留在 80% 和 87%

左右，相比单特征模型提高了约 5% 和 2%，这表明引入注意力机制的融合特征在模型训练过程中有着重要作用。在采用融合特征的模型并采用 SVM 分类时，在迭代次数达到 20 次以后，其准确率停留在 83% 和 89% 左右，而采用双阶段 stacking SVM 模型时，其准确率停留在 88% 和 92% 左右，由此验证了本文提出算法在

中、英文数据集上可达到较好的分类效果。

4 结论

本文针对短文本情感分类任务中,传统机器学习算法无法有效提取特征,且采用不同的分类器对情感分类结果影响也不同这两方面的问题,提出了结合深度学习与双阶段 SVM 的情感分类方法,首先采用了基于注意力机制的 CNN/Bi-LSTM 的特征融合方法,该方法能够获取到文本中的不同信息,且在分类器设计上采用改进的 SVM 方法。在实验分析中,将本文所提出的方法与其他深度学习方法进行两方面的对比,通过在中、英文评测集上的对比表明, CNN/Bi-LSTM-ATT-TS-SVM 算法相对于传统的 CNN 和 Bi-LSTM 模型在中、英文数据集上的准确率均有提高,其中引入注意力机制与融合特征的模型对中、英文数据集情感分类的平均准确率有 5.05%和 2.83%的提高,引入双阶段 stacking SVM 对中、英文数据集情感分类的平均准确率有 7.82%和 4.96%的提高。因此,该方法比本文提到的其他方法在准确率上有了进一步的提升,并且召回率和 F 值也优于其他模型,从而能够更好地解决短文本情感分类任务。

参考文献

[1] COLETTAO L F S, DA SILVA N F F, HRUSCHKA E R, et al. Combining classification and clustering for tweet sentiment analysis [C]//Brazilian Conference on Intelligent Systems, Sao Paulo: IEEE, 2014: 210. DOI: 10.1109/BRACIS.2014.46

[2] WANG Haixun. Understanding short texts [C]. 15th Asia-Pacific Web Conference, Australia: Springer Verlag, 2016: DOI: 10.1007/978-3-642-37401-2_1

[3] PANG Bo, LILLIAN L. Thumbs up? Sentiment classification using machine learning techniques [C]//Proceedings of the ACL-02 conference on Empirical methods in natural language processing-Volume 10, Association for Computational Linguistics, Philadelphia: ACM, 2002: 79. DOI: 10.3115/1118693.1118704

[4] KIM Y. Convolutional neural networks for sentence classification [C]//In Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing, Doha: ACL, 2014: 1746

[5] KALCHBRENNER N, GREFFENSTETTE E, BLUNSOM P. A convolutional neural network for modelling sentences [C]//In Proceedings of the Annual Meeting of the Association for Computational Linguistics, Baltimore: ACL, 2014

[6] DOS SANTOS C N, GATTI M. Deep convolutional neural networks for sentiment analysis for short texts [C]//In Proceedings of the International Conference on Computational Linguistics, Dublin: ACL, 2014: 69

[7] XU Jiacheng, CHEN Danlu, QIU Xipeng, et al. Cached long short-term memory neural networks for document-level sentiment classification [C]//In Proceedings of the Conference on Empirical Methods in Natural Language Processing, 2016: 1660

[8] ZHOU Xinjie, WAN Xiaojun, XIAO Jianguo. Attention-based LSTM network for cross-lingual sentiment classification [C]//In Proceedings of the Conference on Empirical Methods in Natural Language Processing, Austin: ACL, 2016: 247

[9] WANG Jin, YU L C, LAI K R, et al. Dimensional sentiment analysis using a regional CNN-LSTM model [C]//In Proceedings of the Annual Meeting of the Association for Computational Linguistics, Berlin: ACL, 2016: 225

[10] TAN Songbo, ZHANG Jin. An empirical study of sentiment analysis for chinese documents [J]. Expert systems with applications, 2008, 34 (4): 2622. DOI: 10.1016/j.eswa.2007.05.028

[11] CAO Yuhui, XU Ruifeng, CHEN Tao. Combining convolutional neural network and support vector machine for sentiment classification [C]//Chinese national conference on social media processing, Singapore: Springer, 2015: 144. DOI: 10.1007/978-981-10-0080-5_13

[12] Polikar R. Ensemble based systems in decision making [J]. IEEE Circuits and systems magazine, 2006, 6(3): 21. DOI: 10.1109/MCAS.2006.1688199

[13] AMRANI A Y, LAZAAR M, KADIRI K E E. Random forest and support vector machine based hybrid approach to sentiment analysis [J]. Procedia Computer Science, 2018, 127: 511. DOI: 10.1016/j.procs.2018.01.150

[14] 金志刚, 韩玥, 朱琦. 一种结合深度学习和集成学习的情感分析模型, 哈尔滨工业大学学报[J], 2018, 50(11): 32. DOI: 10.11918/j.issn.0367-6234.201709078

JIN Zhigang, HAN Yue, ZHU Qi. A sentiment analysis model with the combination of deep learning and ensemble learning [J]. Journal of Harbin Institute of Technology, 2018, 50 (11): 32. DOI: 10.11918/j.issn.0367-6234.201709078

[15] MNIH V, HEES N, GRAVES A, et al. Recurrent models of visual attention [J]. Advances in Neural Information Processing Systems, 2014: 2204

[16] BAHDANAU D, CHO K, BENGIO Y. Neural machine translation by jointly learning to align and translate [J]. arXiv preprint arXiv, 2014:1

[17] XU K, LEI BA J, KIROUS R, et al. Show, attend and tell: Neural image caption generation with visual attention [C]//International conference on machine learning, Lille: IMLS, 2015: 2048

[18] YIN Wenpeng, SCHUTZE H, XIANG B, et al. Abcnn: Attention-based convolutional neural network for modeling sentence pairs [J]//Transactions of the Association for Computational Linguistics, 2016, 4: 259. DOI: 10.1162/tacl_a_00097

[19] YANG Zichao, YANG Diyi, DYER C, et al. Hierarchical attention networks for document classification [C]//Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, San Diego: ACL, 2016: 1480

[20] CHEN Huimin, SUN Maosong, TU Cunchao, et al. Neural sentiment classification with user and product attention [C]//Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing, Austin: ACL, 2016: 1650

[21] WANG Linlin, CAO Zhu, DE MELO G, et al. Relation classification via multi-level attention CNNs [C]//Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics, Association for Computational Linguistics, Berlin: ACL, 2016: 1298