

基于 BERT_Stacked LSTM 的农业病虫害问句分类方法

李林刁磊唐詹柏召周晗郭旭超

(中国农业大学信息与电气工程学院,北京 100083)

摘要:为解决农业病虫害问句分类过程中存在公开数据集较少、文本较短、特征稀疏、隐含语义信息较难学习等问题,以火爆农资招商网为数据源,构建了用于农业病虫害问句分类的数据集,提出了一种用于农业病虫害问句分类的深度学习模型 BERT_Stacked LSTM。首先,BERT 部分获取各个问句的字符级语义信息,生成了包含句子级特征信息的隐藏向量。然后,使用堆叠长短期记忆网络(Stacked LSTM)学习到隐藏的复杂语义信息。实验结果表明,与其他对比模型相比,本文模型对农业病虫害问句分类更具优势,F1 值达到了 95.76%,并在公开通用领域数据集上进行了测试,F1 值达到了 98.44%,表明了模型具有较好的泛化性。

关键词:农业病虫害;问句分类;BERT;Stacked LSTM

中图分类号:TP391.1 文献标识码:A 文章编号:1000-1298(2021)S0-0172-06

Question Classification Method of Agricultural Diseases and Pests Based on BERT_Stacked LSTM

LI Lin DIAO Lei TANG Zhan BAI Zhao ZHOU Han GUO Xuchao

(College of Information and Electrical Engineering, China Agricultural University, Beijing 100083, China)

Abstract: In order to solve the thorny problems in the process of classification of agricultural diseases and insect pests questions, such as fewer public data sets, shorter texts and sparse features, and difficult to learn implicit semantic information, using the hot agricultural investment network as the data source, a data set for the classification of agricultural pests and diseases was constructed, and a deep learning model BERT_Stacked LSTM for the classification of agricultural pests and diseases was proposed. Firstly, the BERT obtained the character-level semantic information of each question, and generated a hidden vector containing sentence-level feature information. Then, stacked long short-term memory network (Stacked LSTM) structure was used to learn the hidden complex semantic information. Experimental results showed the effectiveness of the proposed model. Compared with other comparative models, the model proposed had more advantages in classifying agricultural diseases and insect pests questions. The F1 score reached 95.76%, and it was widely used in public. Tested on the domain data set, the F1 score reached 98.44%, indicating that the generalization of the model was also very good.

Key words: agricultural diseases and pests; question classification; BERT; Stacked LSTM

0 引言

随着互联网技术的发展,微信朋友圈、网络问答社区用户提问等短文本数据呈爆发式增长。在农业领域,火爆农业招商网(www.3456.tv)是包括肥料、农药、种子、农机、农膜、农产品等诸多农业信息的大型农业帮助型网站,为农业技术人员以及广大农业生产者提供了技术和商业支持以及在线技术指导。

该网站每天增加的病虫害提问近千条,但大部分用户提问时无法正确选择问题分类,或者是由于操作失误导致部分已经分类的问句也不正确,从而影响了技术指导的精确性。因此,如何对这些农户的提问进行自动分类是当前急需解决的问题。

目前,文本分类方法可分为机器学习^[1]和深度学习^[2]两大类。机器学习方法中,广泛应用于文本分类的有 SVM^[3]、最大熵模型^[4]、隐马尔可夫模

型^[5]、朴素贝叶斯模型^[6]、K最近邻算法^[7]等。这些方法虽然取得较好的效果,但也存在一些问题。如机器学习方法过于依赖人工特征提取,而在庞大的数据规模面前,该方式无法覆盖到所有的数据样本,这使得模型只对特定的数据集有效,泛化性较差。

近年来,深度学习方法在许多领域得到了广泛的探索^[8-13],研究人员也提出了多个用于问句的深层神经网络,这类模型可以进行端到端的特征学习,避免了大量人工特征提取。KIM^[14]将广泛应用于图像领域的卷积神经网络(CNN)应用到问句分类中并取得较好的效果。在RNN^[15]模型提出后,这种可以记忆一段文本的前后信息并用于当前计算的神经网络模型在问句分类领域也得到了广泛的应用。但是,针对RNN模型容易出现梯度弥散的问题,研究人员提出了长短期记忆网络模型(LSTM)^[16]并在各类任务中取得较好的效果。史梦飞等^[17]将双向LSTM与CNN结合的方法用于网络社区问句分类。为了能够更好利用文本中不同词语的重要性程度,Attention机制^[18]被引用到文本分类任务中^[19-20],通过对不同词语分配不同的注意力权重,使得重要词语的权重系数更大,从而提升分类效果。如今,研究人员将预训练语言模型(BERT)应用到问句分类任务中,如黄东晋等^[21]在电影原声问答系统的问句分类中也使用BERT与CNN结合,取得了较好效果。

在农业领域,赵明等^[22]将Bi-GRU用于番茄病虫害问答系统问句分类问题,分类准确率得到明显提升。金宁等^[23]针对网络社区的农业病虫害问句分类任务,提出了Bi-GRU-MulCNN模型,有效提升了分类准确率。杨国峰等^[24]将BERT用于处理常见的农业病虫害问句分类,取得了较好效果。

上述研究为深度学习在农业病虫害领域的应用提供了一些实践参考,但是仍然存在着以下问题:①农业病虫害领域可供使用的公开数据集较少,极大限制了农业病虫害问句的分类工作。②农业病虫害问句都为短文本,存在特征稀疏语义信息较难获取的问题。③传统的方法在文本特征提取方面方法较为单一,或是利用统计方法对文本进行特征扩充,无法有效地运用一个单独的深度学习模型来处理该问题。

针对以上问题,本文构建并标注一个农业病虫害问句数据集,以解决语料稀缺问题。提出BERT_Stacked LSTM模型,该模型BERT部分将学习问句的字符级语义信息,其内部独特的多头自注意力机制能更好地完成特征提取任务,Stacked LSTM(堆叠

LSTM)^[25]层则能更好学习到其隐藏的语义信息,提升模型分类性能。

1 数据集

1.1 文本收集

为解决常见农业病虫害问句分类公开数据集不足的问题,本文以火爆农资招商网为语料来源,爬取其中的农业病虫害问句,共获得4 000条问句作为基础语料库。

1.2 数据集标注和划分

对获得的4 000条农业病虫害问句进行手工标注,将其分为9类,分别为:病害信息、病害发生因素、病害防治、虫害信息、虫害防治、药剂使用、作物的病虫害、病虫害症状及防治、如何施肥。将其中3 200条问句作为训练集,400条问句作为验证集,400条作为测试集。各种类型问句的分布情况如图1所示。

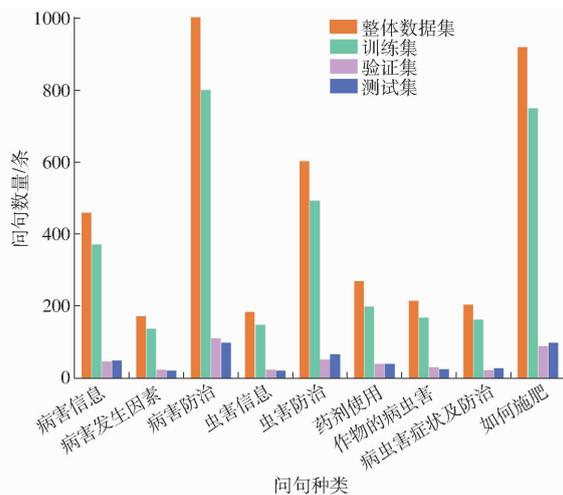


图1 各类型问句的分布情况

Fig. 1 Distribution of each type of question

1.3 数据集特点

本文所构建的农业病虫害问句数据集与通用领域的多分类数据集相比,在句子领域和专业性上有很大的不同。具有以下特点:①句子种类更多。不同于通用领域的多分类数据集如搜狗新闻分类数据集仅将数据分为5种类型的新闻,本文数据集将所有的农业问句分为了9种类型。多种类别的问句识别对模型性能的要求较高。②专业性强。所有问句均是农业病虫害领域的提问,句子类别的边界较为模糊,因此,将通用领域模型迁移到农业病虫害领域进行问句细分类难度较大。③各类型问句分布较为不均匀。如图1所示,各种类型的问句并不是均匀分布的,其中病害防治类和如何施肥类问句最多,而病害发生因素类和虫害信息类问句相对较少。④句

子序列较短。经统计分析发现,农业病虫害问句数据集集中样本的最大长度为 32 个字符,平均长度为 14 个字符,远小于搜狗新闻数据集样本的最大长度(38 872 个字符)和平均长度(1 250 个字符)。这种较短文本在分类过程中所产生的特征难以提取语义信息问题,增加了模型识别的难度。

表 1 为该数据集部分样本实例。

表 1 农业病虫害问句数据集样例

Tab.1 Samples of agricultural diseases and pests questions data set

问句类型	数目/条	问句样本
病害信息	456	菠萝黑腐病的症状是怎样的?
病害发生因素	169	金针菇黑根病发病原因分析?
病害防治	1 000	油麦菜霜霉病如何及早防治?
虫害信息	181	花椰菜甜菜夜蛾有什么特征?
虫害防治	600	菊小长管蚜的处理方法
药剂使用	266	波尔多液怎么使用?
作物的病虫害	211	枸杞常见的病虫害有哪些?
病虫害症状及防治	200	玉米白苗怎么回事? 怎么防治?
如何施肥	917	高产山药如何科学施肥?

2 BERT_Stacked LSTM 模型

针对农业病虫害文本存在的问题,本文以问句中每个字符为基本单元,提出了一种适用于农业病虫害问句多分类的深度学习模型 BERT_Stacked LSTM,该模型的主体结构如图 2 所示,主要包括 BERT 部分和 Stacked LSTM 层。如图 2 所示,模型输入为一个农业病虫害问句“苏铁的施肥方法”,经过字符拆分和填充后得到 n 个初始表达向量 W_i ($1 \leq i \leq n$),经过 BERT 的处理后得到各个字符的表达向量 T_i ,再经过 Stacked LSTM 层计算处理后得到最终分类结果。

2.1 BERT 部分

为了充分利用问句文本字符级序列的语义信息,本文使用了 Google 的中文 BERT 预训练模型进行微调生成每个问句中单个字符的隐藏向量。经过 BERT 词嵌入层处理后的每个问句文本的字符可表示为 $B = (W_1, W_2, \dots, W_i, \dots, W_n)$, $W_i \in \mathbf{R}^{d \times 1}$,其中 W_1 和 W_n 表示特殊字符 [CLS] 和 [SEP],分别表示分类特征符和分句符号,除这两个特殊值外 W_i ($i \in [2, n - 1]$) 则表示问句中第 i 个字符的初始词嵌入向量。

将 B 经过位置编码后获得的包含问句中每个字符位置信息的一组编码向量表示为 $E = (e_1, e_2, \dots, e_i, \dots, e_n)$, $e_i \in \mathbf{R}^{d \times 1}$ 。将 E 输入到多层基于自注意力机制的 Transformer 中,其结构如图 3 所示。

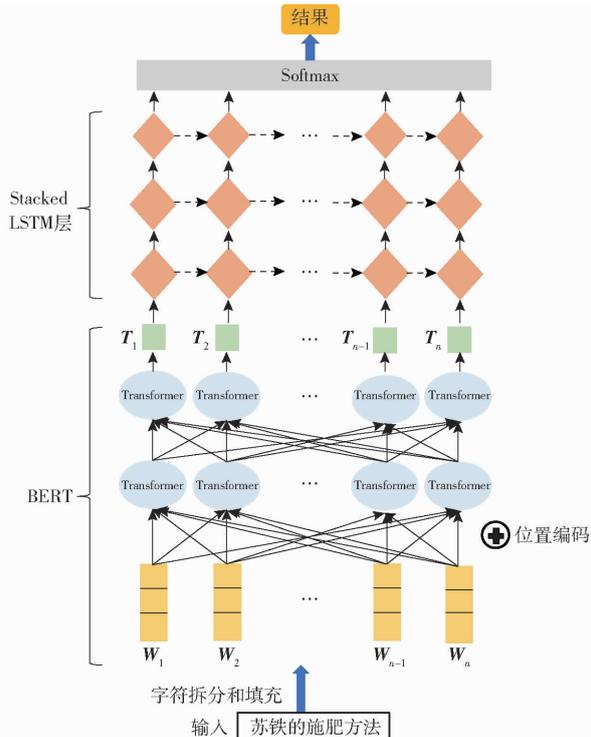


图 2 BERT_Stacked LSTM 模型结构图

Fig.2 BERT_Stacked LSTM model structure diagram

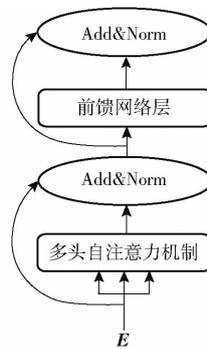


图 3 Transformer 结构图

Fig.3 Transformer structure diagram

Transformer 中最主要的部分是多头自注意力机制,主要通过同一个句子中字符与字符之间的关联程度调整权重系数矩阵来获取特征。

注意力机制的相关计算为

$$Q = \text{Linear}(E) = EW_Q \tag{1}$$

$$K = \text{Linear}(E) = EW_K \tag{2}$$

$$V = \text{Linear}(E) = EW_V \tag{3}$$

式中 Q, K, V —— E 的线性映射矩阵

W_Q, W_K, W_V ——分配的权重矩阵

E 经过多头自注意力机制处理后得到自注意力权重加权^[26],并通过残差链接和归一化得到新的字符表示向量 $E_{attention}$ 。

2.2 Stacked LSTM 层

该层主要用于提取问句的隐藏语义信息,解决短文本特征稀疏、语义信息难以获取的问题。为了

确定每条问句的类型, 本文将由 BERT 生成的字嵌入表达向量 T 输入到堆叠 LSTM^[16] 网络层中。不同于传统的单层 LSTM 只接受当前的字嵌入表达向量和隐藏状态向量, 堆叠 LSTM^[25] 从第 2 层开始其输入就变为第 1 层的 LSTM 输出的隐藏状态向量和同层上一时刻的隐藏状态向量, 这种堆叠结构弥补了单层 LSTM 空间建模能力上的缺陷, 通过更加深层次的学习, 增强了模型对于文本语义信息学习的能力, 解决了短文本中特征稀疏、语义信息难以获取以及单层 LSTM 对空间建模能力不足的问题, 有效提升了模型对文本长度较短的农业病虫害文本分类的性能。

Stacked LSTM 层结构如图 2 所示。设问句中第 i 个字符的表示向量为 T_i , $h_{j,i}$ 表示在 Stacked LSTM 层中第 j 层在 i 时刻的输出隐藏层向量。

第 1 层为

$$h_i = LSTM(W_i, h_{i-1}) \quad (4)$$

式中 h_i —— i 时刻隐藏层向量

第 j 层为

$$h_{j,i} = LSTM(h_{j,i-1}, h_{j-1,i}) \quad (j > 1) \quad (5)$$

经过堆叠 LSTM 层的处理, 该层最后输出的是目标问句的隐藏向量 H , 即

$$H = (h_{3,1}, h_{3,2}, \dots, h_{3,n}) \quad (H \in \mathbf{R}^{n \times d}) \quad (6)$$

式中 d ——词向量维数

将这些最终的字符表达隐藏向量经过 Softmax 函数处理得到最终的分类型概率 p 为

$$p = \text{Softmax}(W \odot H) \quad (7)$$

3 BERT_Stacked LSTM 模型实验

3.1 实验设计

本文采用 Google 的中文 BERT 预训练模型 Chinese_L-12_H-768_A-12 进行微调来生成每个问句中单个字符的隐藏向量。批尺寸 (Batch_Size) 设置为 4, 学习率设置为 2×10^{-5} , 采用交叉熵作为损失函数, 本文模型采用 Keras2.3.1 框架, 运行环境为 GTX1660。为了更好评价模型性能, 本文选择了 CNN、Bi-LSTM、Bi-GRU、Bi-GRU-MulCNN、BERT 模型与本文所提出的新模型进行对比。

3.2 评估指标

采用精确度 (P)、召回率 (R) 和 F1 值来评价模型性能。

3.3 实验结果与分析

3.3.1 农业病虫害问句测试集结果

BERT_Stacked LSTM 模型在农业病虫害问句数据集上的实验结果, 如表 2 所示。

表 2 测试集实验结果

Tab.2 Experimental results on test set		%	
模型	精确度	召回率	F1 值
CNN	93.09	91.91	92.45
Bi-LSTM	92.91	91.75	92.33
Bi-GRU	90.67	88.48	89.50
Bi-GRU-MulCNN	89.41	88.90	88.94
BERT	94.57	94.12	94.26
BERT_Stacked LSTM	96.83	94.84	95.76

由表 2 可知, 相较于按时序建模的 Bi-LSTM, 空间建模能力较强的 CNN 模型的分类效果更好, F1 值比 Bi-LSTM 高 0.12 个百分点, 说明在农业病虫害问句分类中空间建模能力相较于 Bi-LSTM 的按时序建模对问句分类更具有优势。Bi-GRU 模型的 F1 值比 Bi-LSTM 低了 2.83 个百分点, 说明在处理番茄病虫害问句分类取得优秀效果的 Bi-GRU, 在处理综合性农业病虫害问句时并未取得较好效果。Bi-GRU-MulCNN 模型的 F1 值则低于 Bi-GRU 模型 0.56 个百分点, 表明 Bi-GRU 及其优化模型在处理综合农业病虫害问句时性能一般。而 BERT 模型的 F1 值相较于 CNN、Bi-LSTM、Bi-GRU、Bi-GRU-MulCNN 有了较大的提升, 达到了 94.26%, 说明使用字符表达嵌入向量的自训练语言模型进行问句多分类对分类效果有显著提升。

此外, 在 BERT 的基础上加上 Stacked LSTM 层, 对 BERT 生成的问句字嵌入隐藏向量按时序建模, 特有的堆叠结构也增加了模型的空间建模能力, 有效解决了短文本特征不足、语义信息较难学习的问题, 从而获得了最优的 BERT_Stacked LSTM 模型。该模型在测试集上的 F1 值达到了 95.76%, 比 BERT 模型的 F1 值高 1.50 个百分点, 优于其他对比模型。

3.3.2 问句类别

图 4 为各个类别问句在各个最优分类模型中的 F1 值。由图 4 可知, BERT_Stacked LSTM 模型在如何施肥、病虫害症状及防治、虫害信息、病害防治、病害发生因素、病害信息这 6 类问句分类的 F1 值均为最高, 表明该模型的整体分类效果优于其他对比模型。该模型在病虫害症状及防治、虫害信息、病害发生因素 3 类数据集中的 F1 值明显优于其他模型, 说明 BERT_Stacked LSTM 模型在数据量较少的情况下仍能够充分学习到文本的语义信息、提取问句特征有效进行分类。但是, 整体来看, 数据量较少的问句几种模型的 F1 值均低于数据量丰富的问句, 说明深度学习模型的分类型效果一定程度上取决于数据量。

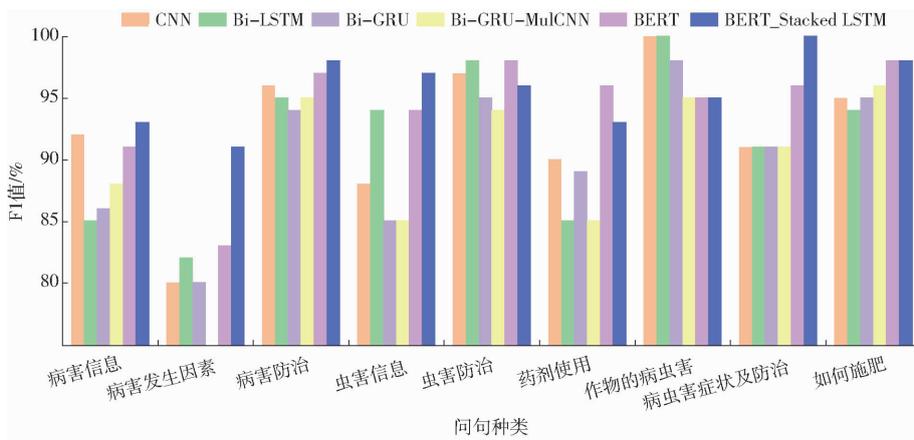


图4 6种模型对不同类别问句分类的F1值对比

Fig.4 Comparison of F1 score of six kinds of models for different types of question classification

3.3.3 LSTM 堆叠层数

如图5所示,当堆叠层数为1~3层时,模型的F1值呈小幅度递增状态,当堆叠层数为3时,获得了最优值。这是因为当多个LSTM叠加时不仅能够获取到经过BERT处理后的文本时序信息,同时能够增加模型的空间建模能力,解决了短文本的特征稀疏问题,学习到了各个问句的隐藏语义信息。而当层数从3层递增至5层时,F1值则出现了较大幅度的减小,是因为当堆叠层数超过一定限度时网络过于复杂,模型容易出现过拟合而导致效果不佳。因此,本文选择最佳堆叠层数为3层。

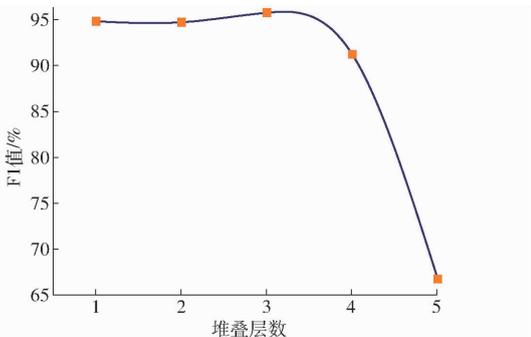


图5 不同堆叠层数对模型性能的影响

Fig.5 Effect of different stacking layers on model performance

3.3.4 泛化性

为验证本文模型的泛化性,将6类模型在搜狗新闻分类数据集上进行测试。测试结果如表3所示。可以看到,BERT的测试结果明显优于其他深度学习模型,F1值达到了97.61%,可以说明BERT在文本分类领域的显著优势。而BERT_Stacked LSTM模型的F1值则达到了98.44%,优于其他模型。可以看出堆叠LSTM结构不仅可以获取特征稀疏的短文本的特征和语义信息,对较长且复杂性较大的新闻文本特征获取和语义信息学习也有一定优势。该测试结果充分说明了BERT_Stacked LSTM

模型的泛化性较优。

表3 搜狗新闻分类数据集测试结果

Tab.3 Sogou news classification data set test results

模型	精确度	召回率	F1值
CNN	97.36	96.50	96.89
Bi-LSTM	95.97	95.11	95.41
Bi-GRU	95.53	95.01	95.08
Bi-GRU-MulCNN	97.18	97.00	97.02
BERT	97.60	97.65	97.61
BERT_Stacked LSTM	98.43	98.47	98.44

3.3.5 模型响应时间

6种模型对400条测试数据的响应时间如表4所示。CNN模型层数较少结构简单,其训练和测试时间优势明显,但其识别效果明显低于BERT_Stacked LSTM模型。LSTM和GRU结构的模型在训练和测试响应时间上稍逊于CNN模型。BERT模型的训练时间和测试响应时间远远大于CNN、Bi-LSTM、Bi-GRU结构模型,这是由于BERT网络层数较多,参与训练的参数增多。BERT_Stacked LSTM模型的训练和响应时间多于所有对比模型,这是由于堆叠LSTM结构在BERT结构基础上再次增加了网络的层数。但在可接受的响应时间范围内BERT_Stacked LSTM模型的识别性能最优。

表4 训练时间和测试响应时间

Tab.4 Training time and test response time

模型	训练时间	测试响应时间
CNN	25	4.2×10^{-2}
Bi-LSTM	52	0.409
Bi-GRU	50.018	1.684×10^{-3}
Bi-GRU-MulCNN	50.019	1.920×10^{-3}
BERT	2928.65	2.83
BERT_Stacked LSTM	4330.40	4.29

4 结束语

构建了一个包含4000条农业病虫害问句的数据集,并进行了自行标注,与通用领域数据集相比,本文构建的数据集句子种类多,专业性较强,句子序列较短。提出了一种深度学习模型BERT_Stacked

LSTM,解决了在处理农业病虫害文本过程中文本较短、特征稀疏、隐含语义信息较难学习等问题,在测试集中本文模型的精确度达到了96.83%,F1值达到了95.76%,大幅提高了分类性能。在搜狗新闻分类数据集上验证了模型的泛化性。

参 考 文 献

- [1] 苏金树,张博锋,徐昕. 基于机器学习的文本分类技术研究进展[J]. 软件学报, 2006(9): 1848 - 1859.
- [2] YANN L, YOSHUA B. Deep learning[J]. Nature, 2015(521):436 - 444.
- [3] OSUNA E, FREUND R, GIROSIT F. Training support vector machines: an application to face detection[C] // Proceedings of the 1997 Conference on Computer Vision and Pattern Recognition, NW Washington, DC, 1997.
- [4] 陈雪天,李荣陆. 使用最大熵模型进行文本分类[J]. 计算机工程与应用, 2004(35): 78 - 79.
- [5] VIEIRA A S, BORRAJO L, IGLESIAS E L. Improving the text classification using clustering and a novel HMM to reduce the dimensionality[J]. Computer Methods & Programs in Biomedicine, 2016,136:119 - 130.
- [6] CHEN Z, SHI G, WANG X. Text classification based on naive Bayes algorithm with feature selection[J]. International Journal on Information, 2012,15(10): 4255 - 4260.
- [7] VRIES A, NES N, KERSTEN M. Efficient k - NN search on vertically decomposed data[C] // Proceedings of the 2002 ACM SIGMOD International Conference on Management of Data, 2002.
- [8] LIU A, LAILI Y. Balance gate controlled deep neural network[J]. Neurocomputing, 2018, 320: 183 - 194.
- [9] LIU T, CUI Y, YIN Q. Generating and exploiting large-scale pseudo training data for zero pronoun resolution[C] // Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics, 2016.
- [10] PRASAD A S, CHANGJU Y, KRZYSZTOF S, et al. Hybrid no-propagation learning for multilayer neural networks[J]. Neurocomputing, 2018, 321(10): 28 - 35.
- [11] HONG C, YU J, CHEN X. Image-based 3D human pose recovery with locality sensitive sparse retrieval [C] // IEEE International Conference on Systems, Man, and Cybernetics, 2013.
- [12] CUI Y, ZHOU F, WANG J, et al. Kernel pooling for convolutional neural networks [C] // IEEE Conference on Computer Vision & Pattern Recognition, 2017.
- [13] HONG C, YU J, WANG J, et al. Multimodal deep autoencoder for human pose recovery[J]. IEEE Transactions on Image Processing, 2015,24(12): 5659 - 5670.
- [14] KIM Y. Convolutional neural networks for sentence classification[J]. Eprint Arxiv: 2014.1408.5582.
- [15] MIKOLOV T, SUTSKEVER I, CHEN K, et al. Distributed representations of words and phrases and their compositionality[J]. ArXiv, 2013: 1310. 454616.
- [16] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997,9(8): 1735 - 1780.
- [17] 史梦飞,杨燕,贺樑,等. 基于Bi-LSTM和CNN并包含注意力机制的社区问答问句分类方法[J]. 计算机系统应用, 2018,27(9):157 - 162.
- [18] VASWANI A, SHAZEER N, PAEMAR N, et al. Attention is all you need [C] // Proceedings of the 31st International Conference on Neural Information Processing Systems, 2017.
- [19] ROZENTAL A, FLEISCHER D. Amobee at SemEval-2018 Task 1: GRU neural network with a CNN attention mechanism for sentiment classification [C] // Proceedings of the 12th International Workshop on Semantic Evaluation, 2018.
- [20] PENG C, SUN Z, BING L, et al. Recurrent attention network on memory for aspect sentiment analysis [C] // Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing, 2017.
- [21] 黄东晋,秦汉,郭昊. 基于BERT-CNN的电影原声智能问答系统[J]. 计算机技术与发展, 2020,30(11): 164 - 168.
- [22] 赵明,董翠琴,董乔雪,等. 基于BIGRU的番茄病虫害问答系统问句分类研究[J]. 农业机械学报, 2018, 49(5): 278 - 283. ZHAO Ming, DONG Cuicui, DONG Qiaoxue, et al. Question classification of tomato pests and diseases question answering system based on BIGRU[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(5):278 - 283. (in Chinese)
- [23] 金宁,赵春江,吴华瑞,等. 基于BiGRU_MulCNN的农业问答问句分类技术研究[J]. 农业机械学报,2020,51(5):199 - 206. JIN Ning, ZHAO Chunjiang, WU Huarui, et al. Classification technology of agricultural questions based on BiGRU_MulCNN [J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(5): 199 - 206. (in Chinese)
- [24] 杨国峰,杨勇. 基于BERT的常见作物病害问答系统问句分类[J]. 计算机应用,2020, 40(6):34 - 40.
- [25] ESPAÑA-BONET C, FONOLLOSA J A R. Automatic speech recognition with deep neural networks for impaired speech [C] // International Conference on Advances in Speech and Language Technologies for Iberian Languages, Lisbon, Portugal, 2016.
- [26] LIN Zhouhan, FENG Minwei, CICERO NOGUEIRA dos S, et al. A self-attentive sentence embedding [C] // 5th International Conference on Learning Representations, Palais des Congrès Neptune, 2017.