

# 基于语义共现与注意力网络的问题分类方法

楼 姣,马伟锋,季曹婷,马来宾

(浙江科技学院 信息与工程学院,杭州 310023)

**摘 要:** 针对汽车故障问答文本特征稀疏、语义信息不全、深层次语义特征较难提取等问题,提出基于问题-答案语义共现的多层次注意力卷积长短时记忆网络模型(co-occurrence word attention convolution LSTM neural network, CACL)的问题分类方法。通过向量空间模型计算问题与答案文本中语义相似的共现词,使用注意力机制聚焦问题文本中的共现词特征,输入卷积神经网络(convolutional neural network, CNN)提取问题局部特征,通过长短时记忆网络(long short-term memory network, LSTM)及词级别注意力机制提取长距离依赖特征及其更高层次的文本特征,采用 Softmax 进行问题分类。结果表明,相比较于主流的问题分类方法,该方法有效提高了问题分类的精度,最高提升了10.04%的准确率。同时,试验发现当选用11个有效共现词且共现词来自问题文本时,模型的处理精度最佳。合理利用问题-答案文本语义相似的共现词,能有效提升汽车故障问题的分类性能,且共现词的个数、来源对问题的分类精度有一定的影响。

**关键词:** 问答社区;语义共现;问题分类;共现词注意力机制;长短时记忆网络

**中图分类号:** TP391.1      **文献标志码:** A      **文章编号:** 1671-8798(2020)04-0264-08

## Question classification method based on semantic co-occurrence and attention network

LOU Jiao, MA Weifeng, JI Caoting, MA Laibin

(School of Information and Electronic Engineering, Zhejiang University of Science and Technology, Hangzhou310023, Zhejiang, China)

**Abstract:** In response to the problems of question and answer text of automobile fault such as sparse text features, incomplete semantic information and difficulty in extracting deep-level semantic features, a multi-layer attention convolution long short-term memory network model (CACL) was proposed on the basis of the semantic co-occurrence of question and answer for question classification. Firstly, the vector space model was employed to calculate the co-occurrence words with semantic similarity in the question and answer text. Secondly, the

**收稿日期:** 2020-05-21

**基金项目:** 浙江省公益技术应用研究项目(LGF18F020011)

**通信作者:** 马伟锋(1979—),男,浙江省绍兴人,副教授,硕士,主要从事大数据与人工智能应用研究。E-mail: mawf@zust.edu.cn。

features of co-occurrence words in the question text were focused through the attention mechanism. Then, the convolutional neural network (CNN) was input to extract partial features of the questions and long short-term memory network (LSTM) and word-level attention mechanism were used to capture both long-distance features as well as the higher-level features of text. Finally, Softmax was capitalized on to classify questions. The results show that compared with the mainstream question classification methods, this method can effectively improve the accuracy of question classification by up to 10.04%. At the same time, it is found that the model has the best processing accuracy when 11 valid co-occurrence words from the question text are selected. The reasonable use of co-occurrence words with semantic similarity in the question and answer text can effectively enhance the classification performance of automobile fault problems, and the number and source of co-occurrence words have a certain influence on the classification accuracy.

**Keywords:** community question answering; semantic co-occurrence; question classification; attention mechanism of co-occurrence words; long short-term memory network

随着互联网技术的发展,各类网络问答社区(community question answering, CQA)相继出现并蓬勃发展,而问题分类作为问答社区的核心技术,受到了研究者的高度关注。早期问题分类主要使用基于规则的方法、基于统计的方法及两者相结合的方法,通过提取问题中的中心词<sup>[1]</sup>、词性<sup>[2-3]</sup>、依存关系<sup>[3]</sup>等特征或对特征进行组合<sup>[2]</sup>的方式对问题进行分类,并取得了良好的分类效果<sup>[4]</sup>。然而上述方法忽略了问题本身的词序和语义信息。随着深度学习的发展,深层神经网络凭借能够自动提取特征的优势,在文本分类任务中得到了广泛的应用。Kim等<sup>[5-6]</sup>通过使用卷积网络(convolutional neural network, CNN)探究了深度学习网络模型在句子分类中的应用。Zhou等<sup>[7-8]</sup>将长短时记忆神经网络(long short-term memory network, LSTM)与卷积神经网络、注意力机制相结合,捕获文本的深层语义特征。Yao等<sup>[9]</sup>利用共现词与文档词之间的关系,构建文本图卷积神经网络用于文本分类。近年来,除了对文本分类模型结构进行改进外,许多研究者开始探索如何对文本扩展语义并进行特征融合。徐健等<sup>[10]</sup>提出了一种融合双语信息的问题分类方法。张栋等<sup>[11]</sup>利用问题及其答案联合学习词向量表示,增强问题文本词向量的语义信息。Yu等<sup>[12]</sup>使用疑问词注意力机制关注问句中的疑问词特征,扩展了问句的语义信息。江伟等<sup>[13]</sup>在词嵌入层后加入卷积层提取 N-gram 短语的向量表示,通过学习短语的权重加强文本语义表示。谢雨飞等<sup>[14]</sup>通过依存句法树提取问题文本的语义单元,扩展了问题文本的语义信息。肖琳等<sup>[15]</sup>提出基于标签语义注意力的文本分类方法,提升了模型的预测精度。

上述研究在问题分类任务中取得了较好的结果,但对垂直领域问答社区的问题分类仍有待进一步研究。目前,面向汽车故障领域的问答社区问题分类主要存在以下难点:一是现有的问题分类方法主要基于含有疑问词的问句<sup>[16]</sup>,而多数用户提出的汽车故障问题并不涵盖疑问词;二是问答社区中用户表述汽车故障有其灵活性,难以区分整体特征相似但局部差异较大的问题类别,并且常出现问题文本较短导致语义信息不足等现象。针对上述问题,本研究在现有的深度学习模型基础上结合注意力机制,借助汽车故障问答社区丰富的用户交互文本,提取共现词作为问题文本的扩展语义信息,提出基于问题-答案语义共现的多层次注意力卷积长短时记忆网络(co-occurrence word attention convolution LSTM neural network, CAACL)模型的问题分类方法。

## 1 问题分类模型结构与方法

基于问题-答案语义共现的多层次注意力卷积长短时记忆网络模型结构如图1所示。图1中, $\mathbf{W}$ 为权重参数矩阵, $u_w$ 为注意力权重, $\alpha_i$ 为语义重要程度归一化后的结果, $\mathbf{S}$ 为文本表示。



$$\mathbf{F}_a = \mathbf{A} \times \mathbf{W}_0. \quad (3)$$

式(3)中: $\mathbf{W}_0 \in \mathbf{R}^{m \times d}$ 为权重参数矩阵,需在模型训练中不断学习以更新。

## 1.2 卷积神经网络的运用

使用单通道卷积层对基于共现词的注意力特征图  $\mathbf{F}_a$  进行卷积,得到新的特征  $\mathbf{c}_i$ 。在对  $\mathbf{F}_a$  进行卷积操作时,一般选取  $h \times d$  维大小的卷积核,其中  $d$  为词向量的维度, $h$  为卷积计算中滑动窗口的大小。 $\mathbf{c}_i$  的计算方式如下:

$$\mathbf{c}_i = f_r(\mathbf{W}_0 \cdot \mathbf{S}_{a,i:i+h-1} + \mathbf{b}). \quad (4)$$

式(4)中: $\mathbf{c}_i$  为由卷积操作得到的第  $i$  个特征; $f_r$  为非线性激活函数,本文使用 ReLu 函数作为激活函数; $\mathbf{W}_0$  为卷积核的权重参数矩阵, $\mathbf{W}_0 \in \mathbf{R}^{h \times d}$ ; $\mathbf{S}_{a,i:i+h-1}$  为  $\mathbf{F}_a$  中第  $i$  行到第  $i+h-1$  行的局部特征, $\mathbf{b}$  为偏置项。对每个窗口中的局部特征进行卷积操作,最终得到特征图

$$\mathbf{C} = (\mathbf{c}_1, \mathbf{c}_2, \dots, \mathbf{c}_{n-h+1}). \quad (5)$$

## 1.3 长短时记忆网络的运用

卷积神经网络虽然能够提取问题文本的局部特征,但它在捕获长距离依赖特征时有局限性。而长短时记忆网络恰好能弥补这一缺陷。因此,本文将卷积神经网络提取的特征输入长短时记忆网络,用于获取问题文本的长距离依赖特征。参照 Hochreiter 等<sup>[18]</sup>最早提出的长短时记忆网络结构,最终得到长短时记忆网络的输出结果  $\mathbf{H}$ ,  $\mathbf{H} = (\mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_{t-1}, \mathbf{h}_t, \mathbf{h}_{t+1})$ 。长短时记忆网络的结构如图2所示,其中  $\mathbf{h}_t$  为长短时记忆单元在  $t$  时刻的输出结果, $\mathbf{x}_t$  为经过卷积后时序  $t$  的输入信息。

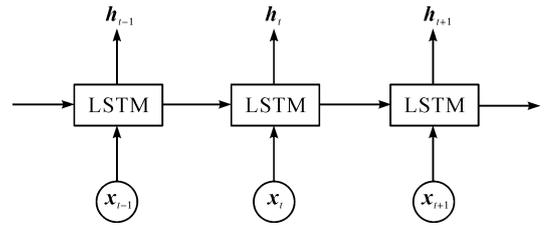


图2 长短时记忆网络结构图

Fig. 2 Long short-term memory network structure

## 1.4 词级别注意力机制的运用

参考 Yang 等<sup>[19]</sup>提出的层次注意力模型(hierarchical attention network, HAN),在长短时记忆网络完成长距离信息提取后,将其输出作为词级别注意力层的输入,并构造加权注意力参数矩阵。通过不断的训练,该参数矩阵将会根据问题文本中语义的重要程度分配权重,聚焦文本中的重要部分,最终得到文本表示  $\mathbf{S}$ 。注意力参数矩阵的计算方式如下:

$$\begin{cases} \mathbf{u}_t = f_t(\mathbf{W}_w \mathbf{h}_t + \mathbf{b}_w); \\ \alpha_t = \frac{e^{(\mathbf{u}_t^\top \mathbf{u}_w)}}{\sum_t e^{(\mathbf{u}_t^\top \mathbf{u}_w)}}; \\ \mathbf{S} = \sum_t \alpha_t \mathbf{h}_t. \end{cases} \quad (6)$$

式(6)中: $f_t$  为激活函数  $\tanh$ ; $\mathbf{W}_w$  为加权注意力参数矩阵; $\mathbf{h}_t$  为长短时记忆网络的输出; $\mathbf{b}_w$  为偏置项; $\mathbf{u}_t$  为语义向量; $\mathbf{u}_w$  为注意力权重; $\alpha_t$  为语义重要程度归一化后的结果。

## 1.5 问题分类

对长短时记忆网络的输出特征使用 Softmax 分类器分类,得到问题文本  $q_i$  到类别  $j$  的概率

$$\mathbf{p} = f_s(\mathbf{W}_c \mathbf{S} + \mathbf{b}_c). \quad (7)$$

式(7)中: $f_s$  为 Softmax 分类器; $\mathbf{W}_c$  为权重参数矩阵; $\mathbf{b}_c$  为偏置项。

在模型训练过程中,将交叉熵作为损失函数衡量模型损失,并加入正则项防止过拟合。模型训练的最终目标是最小化交叉熵损失。损失函数的计算方式如下:

$$J(\theta) = \sum_i \sum_j y_{ij} \lg \hat{y}_{ij} + \lambda \|\theta\|^2. \quad (8)$$

式(8)中: $i$  为样本数; $j$  为问题类别; $y_{ij}$  为问题文本的正确类别; $\hat{y}_{ij}$  为问题类别预测的类别; $\lambda$  为 L2 正则项系数; $\theta$  为模型参数。

## 2 试验结果与分析

### 2.1 数据集的标注与划分

本文使用的数据集为自定义基准数据集,来源于一些专业汽车网站的汽车故障问答社区。目前,绝大部分汽车类问答社区尚未建立完整的汽车故障问题分类体系,一般的中文问题分类多采用文献[20]的分类体系,它将问题归纳为人物、地点、数字、时间、实体、描述 6 大类,而大多数汽车故障问题都属于描述类,因此该分类体系并不适用于汽车故障问题领域。本文根据汽车的故障现象<sup>[21]</sup>,将其归纳为工况异常、渗漏异常、气味异常、声响异常、烟气异常、温度异常、消耗异常、外观异常、仪表异常 9 大类,分类情况及其实例见表 1。

本文的基准数据集共包含汽车故障问题 8 000 条,依据表 1 的汽车故障问题分类对其进行人工标注,并对部分存疑的数据最终通过我们这个项目组探讨处理。为验证本文所提算法模型的有效性,将随机抽取总样本的 20% 作为测试数据集,从剩余 80% 的数据中再抽取 10% 作为验证数据集,其余的作为训练数据集。汽车故障问题数据集的分布统计见表 2。

表 2 汽车故障问题数据集的分布统计

Table 2 Data set distribution statistics of automobile fault problems

类别	训练集	验证集	测试集	样本数
工况异常	712	79	198	989
渗漏异常	569	63	158	790
气味异常	884	98	245	1 227
声响异常	567	63	157	787
烟气异常	444	50	124	618
温度异常	319	35	88	442
消耗异常	471	53	131	655
外观异常	867	96	241	1 204
仪表异常	927	103	258	1 288

### 2.2 评估指标的选择

选用精确率  $P$ 、召回率  $R$ 、 $F1$  值、宏平均精确率  $\bar{P}$ 、宏平均召回率  $\bar{R}$ 、宏平均  $\bar{F1}$  值、准确率  $T_A$  作为评估指标,计算公式如下:

$$\left\{ \begin{array}{l} P = \frac{T_P}{T_P + F_P}; \\ R = \frac{T_P}{T_P + F_N}; \\ F1 = \frac{2 \times P \times R}{P + R}; \\ \bar{P} = \frac{1}{n} \sum_{i=1}^n P_i; \\ \bar{R} = \frac{1}{n} \sum_{i=1}^n R_i; \\ \bar{F1} = \frac{2 \times \bar{P} \times \bar{R}}{\bar{P} + \bar{R}}; \\ T_A = \frac{T_P + T_N}{T_P + F_P + T_N + F_N}. \end{array} \right. \quad (9)$$

表 1 汽车故障问题分类及其实例

Table 1 Classification system of automobile fault problems and its examples

类别	实例
工况异常	踩刹车挂 D 挡车抖是怎么回事?
渗漏异常	气门室盖漏油怎么办?
气味异常	打火有烧焦皮子味,问题出现在哪里?
声响异常	过坑洼路面,后排减震器有异响怎么回事?
烟气异常	排气管冒蓝烟了,是什么原因?
温度异常	车子一直高温,是什么问题?
消耗异常	油耗高怎么解决?
外观异常	刮痕露白怎么办?
仪表异常	出现“请检修电子稳定性控制”的故障报警,该怎么处理?

式(9)中: $T_P$ 为实际为正且预测为正的样本数; $F_P$ 为实际为负但预测为正的样本数; $F_N$ 为实际为正但预测为负的样本数; $T_N$ 为实际为负预测为负的样本数; $i$ 为测试集中的样本数。

### 2.3 对比试验的模型选择

为验证本文提出模型的有效性,我们使用同一数据集对不同模型进行对比试验。在进行对比试验之前,为获取更优质的词向量,我们使用汽车故障语料库中的问题文本和答案文本,采用与文献[7]一致的参数设置,联合训练词向量。具体而言,使用 Word2vec 的 Skip-gram 模式,上下文窗口设为 5,词向量维度设为 100,最终得到问题文本在 Word2vec 中的向量表示。对比试验选取的模型分别为 SVM<sup>[22]</sup>、CNN、LSTM、Bi-LSTM<sup>[8]</sup>、C-LSTM<sup>[7]</sup>及我们提出的 CAEL。

### 2.4 结果分析

表 3 是当前问题分类的主流模型与 CAEL 模型对比试验后所得出的各项指标评估值。由表 3 可知,传统的机器学习模型 SVM 并不能有效学习问题文本语义,在问题分类任务中不具备优势,而主流的深度学习模型 CNN、LSTM、Bi-LSTM、C-LSTM 在学习文本语义方面具有显著优势;相比较于其他 5 种模型,本文提出的 CAEL 模型在汽车故障问题分类中有较好的表现。这表明利用共现词注意力矩阵有助于扩展问题的文本语义,能有效提升汽车故障问题的分类精度。

表 3 对比试验各项指标评估值

Table 3 Index evaluation values of comparative experiment

%

模型	各项指标评估值			
	$\bar{P}$	$\bar{R}$	$\bar{F1}$	$T_A$
SVM	84.41	83.66	83.98	84.90
CNN	90.43	89.72	90.02	90.75
LSTM	91.59	90.92	91.12	91.94
Bi-LSTM	92.63	91.94	92.25	92.81
C-LSTM	92.50	91.61	91.98	92.63
CAEL	94.59	94.92	94.74	94.94

表 4 是 Bi-LSTM、C-LSTM 及 CAEL 模型在不同汽车故障问题类别间的 F1 值对比。F1 值是精确率和召回率的调和平均数,能够有效评估模型精确度。从表 4 中可以看出相比较于 Bi-LSTM 和 C-LSTM 模型,CAEL 模型整体性能都有所提升,尤其对工况异常、声响异常及温度异常等故障问题的分类效果最为显著。这说明利用共现词注意力矩阵能够更好地聚焦问题文本中与答案文本语义相似的内容,答案文本能够在一定程度上对问题文本进行语义限定,从而在面对整体特征相似,但局部特征差异较大的汽车故障问题时有较强的区分能力。

除了探讨 CAEL 模型对问题分类精度的影响外,

我们还探究了共现词个数对问题分类精度的影响。由于从数据集中可提取到的共现词个数最多为 25,因此在对每个共现词按余弦相似度排序后,我们将共现词个数  $K$  设置为 1~25。宏平均精确率  $\bar{P}$ 、宏平均召回率  $\bar{R}$ 、宏平均  $\bar{F1}$  值及准确率  $T_A$  等指标估值随共现词个数变化的情况如图 3 所示。随着共现词个数的不断增加,各项指标评估值不断上升,当共现词个数  $K$  达到 11 时,各项指标评估值整体达到最优值;继续增加共现词个数,各项指标评估值却开始下降。产生上述现象的原因可能是共现词个数的取值范围在 1~11 时,样本间共现词分布较为均衡,且共现词的质量较为优良,即此时的共现词与问题文本语义相关性较高,但当继续增加共现词个数时,可能会引入有干扰的共现词,并且样本间共现词分布逐渐失

表 4 3 种模型在不同汽车故障问题类别上的 F1 值对比

Table 4 Comparison of F1 score of three models in different types of automobile fault problems

%

类别	F1		
	Bi-LSTM	C-LSTM	CAEL
工况异常	86.50	84.60	88.83
渗漏异常	94.23	91.74	95.57
气味异常	98.17	99.18	99.39
声响异常	92.90	91.86	96.49
烟气异常	95.90	97.14	97.99
温度异常	85.71	82.93	91.71
消耗异常	89.63	93.13	93.18
外观异常	95.00	94.80	95.60
仪表异常	92.16	92.43	93.87

衡,导致各项指标评估值整体呈下降趋势。因此,选取有效共现词个数  $K=11$ 。

为了更好地选取优质共现词,我们对共现词的来源进行试验对比。选取汽车故障问题文本中与答案文本语义相似的词作为共现词 I 型,选取答案文本中与问题文本语义相似的词作为共现词 II 型,共现词 I 型与共现词 II 型去重之和作为共现词 III 型。分别对上述 3 种共现词的来源通过各项指标评估值进行试验对比,同时,为了最大限度地保留所有的共现词,设置共现词个数  $K=25$ ,试验结果见表 5。由表 5 可知,共现词 I 型的指标评估值都要优于其余两类共现词。这是由于共现词 I 型中的词都来自问题文本本身,能够最大限度地减少关注问题文本中的非共现词,使共现词注意力矩阵更加聚焦出现共现词的这部分文本特征。因此,最终选取共现词 I 型作为汽车故障问题文本的共现词来源。试验结果表明,共现词的来源也是影响汽车故障问题分类精度的因素之一。

表 5 不同来源共现词的各项指标评估值试验对比的结果

Table 5 Experimental comparison results of index evaluation values for co-occurrence words from different sources %

共现词来源	各项指标评估值			
	$\bar{P}$	$\bar{R}$	$\bar{F1}$	$T_A$
I 型	94.18	93.93	94.02	94.19
II 型	93.66	93.04	93.30	93.50
III 型	93.96	93.55	93.70	93.81

### 3 结 语

本文针对汽车问答社区中汽车故障问题文本复杂,局部语义特征较难提取的问题,提出一种基于问题-答案联合构建共现词注意力矩阵的问题分类方法。依托汽车问答社区中丰富的用户交互文本识别出问题文本中与之语义相似的共现词,作为问题文本的扩展语义信息,捕捉两者的内在相关性,并在这基础上构建共现词注意力矩阵,使其聚焦问题文本中与答案文本语义共现的部分。同时,利用卷积神经网络与长短时记忆网络提取问题文本的局部特征及长距离依赖特征。最后,通过词级别注意力机制,再次重点关注问题文本中贡献度较大的部分内容,去除冗余文本特征。试验结果表明,CACL 模型能够有效提高汽车故障问题分类的精度。但是,本研究仍存在一些不足之处,如模型仅适用于已有答案的问题,此外模型未涉及其他领域的问答社区,未来我们将对上述不足做进一步研究。

#### 参考文献:

- [1] SILVA J, COHEUR L, MENDES A C, et al. From symbolic to sub-symbolic information in question classification [J]. Artificial Intelligence Review, 2011, 35(2): 137.
- [2] 杨思春,高超,戴新宇,等. 基于差异性和重要性的问句特征组合[J]. 电子学报, 2014, 42(5): 918.
- [3] LIU L, YU Z T, GUO J Y, et al. Chinese question classification based on question property kernel[J]. International Journal of Machine Learning and Cybernetics, 2014, 5(5): 713.
- [4] 张宁,朱礼军. 中文问答系统问句分析研究综述[J]. 情报工程, 2016, 2(1): 32.
- [5] KIM Y. Convolutional neural networks for sentence classification [C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing. Doha, EMNLP, 2014: 1746.
- [6] JOHNSON R, ZHANG T. Deep pyramid convolutional neural networks for text categorization [C]//Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics. Vancouver, ACL, 2017: 562.

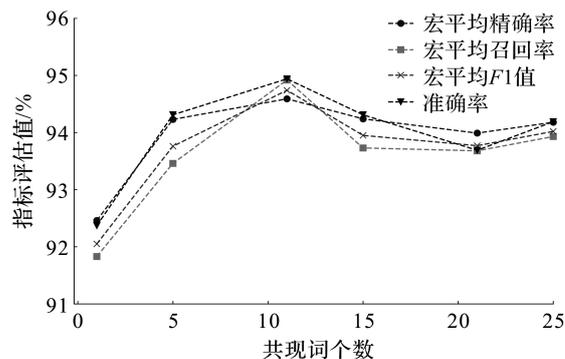


图 3 各项指标评估值随共现词个数变化的情况

Fig. 3 Change of index evaluation values with numbers of co-occurrence words

- [7] ZHOU C T, SUN C L, LIU Z Y, et al. A C-LSTM neural network for text classification[J]. Computer Science, 2015,1(4):39.
- [8] 陶志勇,李小兵,刘影,等. 基于双向长短时记忆网络的改进注意力短文本分类方法[J]. 数据分析与知识发现,2019,3(12):21.
- [9] YAO L, MAO C S, LUO Y. Graph convolutional networks for text classification[C]//Proceedings of the 33th AAAI Conference on Artificial Intelligence. Hawaii: AAAI,2019:7370.
- [10] 徐健,张栋,李寿山,等. 基于双语信息的问题分类方法研究[J]. 中文信息学报,2017,31(5):171.
- [11] 张栋,李寿山,王晶晶. 基于问题与答案联合表示学习的半监督问题分类方法[J]. 中文信息学报,2017,31(1):1.
- [12] YU B G, XU Q T, ZHANG P H. Question classification based on MAC-LSTM [C]//2018 IEEE Third International Conference on Data Science in Cyberspace. Guangzhou: IEEE,2018:69.
- [13] 江伟,金忠. 基于短语注意机制的文本分类[J]. 中文信息学报,2018,32(2):102.
- [14] 谢雨飞,吕钊. 基于语义扩展与注意力网络的问题细粒度分类[J]. 计算机工程,2019,45(1):165.
- [15] 肖琳,陈博理,黄鑫,等. 基于标签语义注意力的多标签文本分类[J]. 软件学报,2020,31(4):1079.
- [16] 董才正,刘柏嵩. 面向问答社区的中文问题分类[J]. 计算机应用,2016,36(4):1060.
- [17] MIKOLOV T, CHEN K, CORRADO G, et al. Efficient estimation of word representations in vector space[C]//International Conference on Learning Representations. Scottsdale: ICLR,2013:1.
- [18] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation,1997,9(8):1735.
- [19] YANG Z C, YANG D Y, DYER C, et al. Hierarchical attention networks for document classification [C]//Proceedings of the 15th Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. San Diego: NAACL,2016:1480.
- [20] 文勳,张宇,刘挺,等. 基于句法结构分析的中文问题分类[J]. 中文信息学报,2006,20(2):33.
- [21] 李春明,刘艳丽,张军. 汽车故障诊断方法与维修技术[M]. 北京:北京理工大学出版社,2004.
- [22] ZHANG D, LEE W S. Question classification using support vector machines [C]//Proceedings of the 26th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval. Toronto: ACM,2003:26.

~~~~~

(上接第256页)

- [15] 中国互联网络信息中心. 2011年浙江省互联网络发展状况统计报告[R/OL]. (2012-05-09)[2019-10-21]. <http://www.cnnic.cn/hlwfzyj/hlwzbg/qybg/201206/P020120612509317499258.pdf>.
- [16] 浙江省商务厅. 浙江省网络零售业发展报告(2011-2019)[ER/OL]. [2019-11-10]. <http://www.zcom.gov.cn/col/coll384591/index.html>.
- [17] MA S, GUO JW, ZHANG HS. Policy analysis and development evaluation of digital trade: an international comparison[J]. China & World Economy,2019,27(3):55.
- [18] 王富喜,毛爱华,李赫龙,等. 基于熵值法的山东省城镇化质量测度及空间差异分析[J]. 地理科学,2013,33(11):1325.
- [19] 胡永宏. 对 TOPSIS 法用于综合评价的改进[J]. 数学的实践与认识,2002,32(4):574.
- [20] 黄山,张学军. 基于相对熵的公路建设项目可行性综合评价分析研究[J]. 工程管理学报,2017,31(3):97.
- [21] 徐书彬. 基于 TOE 框架的跨境电子商务企业绩效影响因素研究[D]. 南昌:江西财经大学,2017.
- [22] 谭军. 基于 TOE 理论架构的开放政府数据阻碍因素分析[J]. 情报杂志,2016,35(8):175.
- [23] 纪玉俊,丁科华,张鹏. 我国沿海地区城市服务业集聚的影响因素分析[J]. 经济与管理,2014,28(5):84.
- [24] 王聪,柴时军,田存志,等. 家庭社会网络与股市参与[J]. 世界经济,2015,38(5):105.
- [25] 邓聚龙. 灰色系统理论教程[M]. 武汉:华中理工大学出版社,1990:53.
- [26] 浙江省统计局. 2016年浙江省国民经济和社会发展统计公报[EB/OL]. (2017-02-24)[2019-12-11]. [http://tjj.zj.gov.cn/art/2017/2/24/art\\_1525568\\_20972734.html](http://tjj.zj.gov.cn/art/2017/2/24/art_1525568_20972734.html).
- [27] 国家互联网信息办公室. 数字中国建设发展报告(2018年)[EB/OL]. (2019-05-07)[2019-12-12]. <http://m.people.cn/n4/2019/0507/c205198-12669445.html>.