



















$$bpref = \frac{1}{R} \sum_r 1 - \frac{|n \text{ ranked higher than } r|}{R} \quad (15)$$

公式(12)中, $N^i$ 为查询的数量, $N$ 为总的文档数量.若第*i*个文档为带观点的主题相关文档,则 $r_i=1$ ;否则, $r_i=0$ .

公式(13)中, $Z_n$ 为标准化因子,用理想返回列表的  $NDCG(n)$ 作为因子进行归一化. $r(j)$ 指的是返回文档的评分,若相关,设为2,否则,设为1.

公式(14)中, $R$ 为与查询相关并带有对查询观点的文档数量, $R_j$ 为检索结果中第*j*个文档的评分,若是正确结果集中的文档,则取1,否则,取0.

公式(15)中, $R$ 是与查询相关的文档个数, $r$ 是具体的某一个相关文档, $|n \text{ ranked higher than } r|$ 是排名比*r*靠前的非相关文档的数量.

上述评价指标中,MAP是一个较为重要的指标,在本文的后续实验中,主要针对MAP进行不同方法之间的对比分析,其他3个指标仅作为参考指标.

### 3.2 实验对比

为了验证本文方法的有效性与普适性,本文分别与不需要训练语料的观点检索模型以及需要训练语料的排序学习模型进行对比.

#### • 观点检索模型

- (1) SIGIR08<sup>[5]</sup>:基于词典的统一相关模型,通过二次组合方式将主题相似度得分与观点得分结合.该模型将观点词看成是均匀分布.模型使用传统信息检索方法 BM25 和基于词典的观点得分模型分别计算查询与文档的相关度和文档的观点得分;
- (2) SIGIR08+Lexicon<sup>[6]</sup>:首先,基于异质图计算观点词在不同查询上的观点分布,然后将其融入 SIGIR08<sup>[5]</sup>提出的模型中;
- (3) SIGIR08\_KG+Lexicon<sup>[10]</sup>:在文献[6]的基础上,使用知识图谱 freebase 的文本描述信息为用户查询进行查询扩展;
- (4) BOC+X:本文方法,基于概念模型计算查询与文档的相关度并结合不同观点得分方法.有3种变形:BOC+Lexicon,BOC+NBSVM,BOC+CNN;
- (5) NE+X:本文方法,基于网络表示计算查询与文档的相关度并结合不同观点得分方法.同样有3种变形:NE+Lexicon,NE+NBSVM,NE+CNN;
- (6) BOC\_NE+X:本文方法,基于概念模型和网络表示计算查询与文档的相关度,同情形(3)、情形(4),有3种变形:BOC\_NE+BOC\_Lexicon,BOC\_NE+NBSVM,BOC\_NE+CNN.

#### • 排序学习模型

- (7) AAAI2012<sup>[39]</sup>:排序学习方法,利用推文特征、作者特征和观点特征训练排序模型;
- (8) WWW2015<sup>[35]</sup>:排序学习方法,除了情形(7)提到的特征,加入了不同观点词典得到的观点特征、向量空间模型计算得到的查询相关特征和该推文发布的时长等特征;
- (9) L2R+X:本文方法,除了信息检索的常用特征外,还加入了本文所提出的3种特征表示方法作为额外特征,包括文本概念化特征(BOC)、网络表示特征(NE)、观点得分特征(Lexicon, CNN 和 NBSVM),并在后续实验中分别对本文提出的特征进行组合分析.

基于上述方法,本文进行了以下5个实验.实验1~实验3为统一相关模型的实验:实验1对比了本文方法与基准方法的实验结果.实验2、实验3分析了本文统一相关模型方法中的参数设置.实验4、实验5为排序学习模型的实验:实验4对比了本文特征与基准方法特征的实验结果,实验5分析了本文不同特征组合的实验结果.

实验1:基于统一相关模型的观点检索对比实验.

为了验证本文提出的特征在统一相关模型的观点检索方法上的有效性,对比本文最优方法和基准方法在两个数据集上的实验结果.结果见表3和表4.

**Table 3** Comparison of our best approach and benchmark approaches on Tweet 2014 dataset (I)**表 3** 本文最优方法与基准方法在推特 2014 数据集上的实验结果对比(I)

方法	MAP	NDCG@10	R-Prec	bPref
SIGIR08	0.330 6	0.406 8	0.405 1	0.410 8
SIGIR08+Lexicon	0.342 0	0.474 1	0.434 7	0.413 0
SIGIR08_KG+Lexicon	0.365 5	0.499 6	<b>0.447 7</b>	0.423 5
BOC_NE+NBSVM(本文方法)	<b>0.387 7</b>	0.502 6	0.444 9	<b>0.428 7</b>
BOC_NE+CNN(本文方法)	0.374 7	<b>0.523 6</b>	0.447 1	0.406 5

**Table 4** Comparison of our best approach and benchmark approaches on extended dataset (I)**表 4** 本文最优方法与基准方法在扩展数据集上的实验结果对比(I)

方法	MAP	NDCG@10	R-Prec	bPref
SIGIR08	0.317 7	0.425 8	0.278 5	0.277 1
SIGIR08+Lexicon	0.330 5	0.471 0	0.307 8	0.261 1
SIGIR08_KG+Lexicon	0.331 0	0.490 3	0.391 0	0.303 0
BOC_NE+NBSVM(本文方法)	<b>0.361 7</b>	0.504 1	<b>0.419 5</b>	<b>0.354 0</b>
BOC_NE+CNN(本文方法)	0.315 8	<b>0.524 2</b>	0.390 4	0.317 7

从实验结果可以看出,

- (1) 首先比对两个数据集上的 3 种基准方法,SIGIR08 在 4 个指标上都是最低的,说明 SIGIR08+Lexicon 和 SIGIR08\_KG+Lexicon 方法相比 SIGIR08 效果较优,因此,后续实验主要和这两种方法比对.在推特 2014 数据集(见表 3)和扩展数据集(见表 4)中,SIGIR08\_KG+Lexicon 与 BOC\_NE+NBSVM(本文方法)的实验结果均优于 SIGIR08+Lexicon,说明引入知识图谱分析用户查询和文档集的语义信息可以提高模型的知识泛化能力,进而提高原有观点检索的性能.并且需要注意的是:在不同的观点得分计算方式下,算法的性能存在一定的差异.主要原因在于:本文的观点得分是在其他领域的数据集上进行训练,对于观点检索所在领域的观点得分计算存在一定的误差.尤其是基于卷积神经网络的方法,由于需要大规模的训练样本,因此在小数据集上的性能受限,并不适合处理这一问题.最后,本文采用了基于 NBSVM 的观点得分计算方式;
- (2) 在推特 2014 数据集中(见表 3),对比本文方法 BOC\_NE+NBSVM 与 SIGIR08\_KG+Lexicon,BOC\_NE+NBSVM 优于 SIGIR08\_KG+Lexicon,在 MAP、NDCG@10、bPref 指标上均有一定提升,分别提升了 6.1%、1.0%、1.2%.在扩展数据集中(见表 4),本文方法 BOC\_NE+NBSVM 优于 SIGIR08\_KG+Lexicon,在 MAP、NDCG@10、R-Prec、bPref 这 4 个指标上分别提升了 9.3%、2.8%、7.3%、16.6%.说明本文方法相比基于知识库的扩展,不仅可以有效分析用户查询的信息需求,同时可以准确理解文本集的信息,有效改善了传统的基于词袋模型的词匹配中词汇之间语义鸿沟的问题,提高了计算泛化能力,进而能够提高观点检索的性能.

实验 2:统一相关模型中不同特征组合的性能对比.

实验 2 比对不同观点得分计算方法结合不同相关度得分对检索性能的影响.实验结果见表 5 和表 6.

- 首先观察相同主题相关度得分结合不同观点得分的差异性.

在推特 2014 数据集中(见表 5),SIGIR08+NBSVM、BOC+NBSVM、NE+Lexicon、BOC\_NE+NBSVM 分别取得相应的最高 MAP,在扩展数据集中(见表 6),SIGIR08+Lexicon、BOC+Lexicon、NE+Lexicon、BOC\_NE+Lexicon 分别取得相应的最高 MAP,说明相同的相关度得分结合不同观点得分方法的检索效果具有明显的差异性.在基础数据集中,统计机器学习的观点得分优于基于词典的观点得分,但在扩展数据集中,统计机器学习的观点挖掘得分并未优于基于词典的观点得分.一方面是因为扩展数据集的测试语料远大于训练语料;另一方面是因为训练语料与测试语料的异质性,导致泛化能力不够.

- 然后观察相同观点得分结合不同主题相关度得分的差异性.

在两个数据集上,本文方法均取得相应的最高 MAP 值,说明本文方法能够有效提高模型的知识泛化能力和计算泛化能力,进而提高检索性能.同时还可以发现:在推特 2014 数据集中(见表 5),本文方法的 BOC\_NE+

NBSVM 在 MAP 和 bPref 指标上均达到最好,BOC\_NE+Lexicon 在 R-Prec 指标上获得最优值,BOC\_NE+CNN 在 NDCG@10 指标上获得最优值.在扩展数据集中(见表 6),BOC\_NE+Lexicon、BOC\_NE+CNN、BOC\_NE+Lexicon、BOC\_NE+NBSVM 分别获得了 4 个指标的最优值,再一次验证了本文方法更加有效检索到与查询主题相关观点的文本,说明了本文方法能够有效提高检索模型的知识泛化能力和计算泛化能力,进而提高观点检索的性能.

**Table 5** Comparison of different feature combinations in unified relevance model on Tweet 2014 dataset

**表 5** 统一相关模型中不同特征组合在推特 2014 上的实验结果对比

方法	MAP	NDCG@10	R-Prec	bPref
SIGIR08+Lexicon	0.342 0	0.474 1	0.434 7	0.413 0
SIGIR08+NBSVM	0.369 3	0.481 8	0.426 6	0.404 6
SIGIR08+CNN	0.362 7	0.494 6	0.441 2	0.394 9
BOC+Lexicon	0.380 8	0.501 2	0.424 9	0.425 6
BOC+NBSVM	0.382 2	0.501 2	0.433 5	0.425 6
BOC+CNN	0.361 1	0.493 0	0.442 2	0.397 4
NE+Lexicon	0.381 9	0.503 0	0.447 3	0.426 0
NE+NBSVM	0.378 3	0.503 1	0.437 0	0.425 9
NE+CNN	0.364 8	0.520 7	0.438 1	0.401 8
BOC_NE+Lexicon	0.384 8	0.503 5	<b>0.448 9</b>	0.428 5
BOC_NE+NBSVM	<b>0.387 7</b>	0.502 6	0.444 9	<b>0.428 7</b>
BOC_NE+CNN	0.374 7	<b>0.523 6</b>	0.447 1	0.406 5

**Table 6** Comparison of different feature combinations in unified relevance model on extended dataset

**表 6** 统一相关模型中不同特征组合在扩展数据集上的实验结果对比

方法	MAP	NDCG@10	R-Prec	bPref
SIGIR08+Lexicon	0.330 5	0.471 0	0.307 8	0.261 1
SIGIR08+NBSVM	0.281 2	0.481 4	0.287 2	0.238 7
SIGIR08+CNN	0.259 9	0.411 3	0.261 9	0.218 4
BOC+Lexicon	0.372 8	0.467 4	0.415 0	0.353 4
BOC+NBSVM	0.361 7	0.467 4	0.402 1	0.353 4
BOC+CNN	0.275 5	0.504 0	0.286 9	0.299 2
NE+Lexicon	0.374 1	0.490 8	0.410 6	<b>0.354 0</b>
NE+NBSVM	0.347 9	0.488 6	0.419 5	0.353 2
NE+CNN	0.304 6	0.504 9	0.384 1	0.314 3
BOC_NE+Lexicon	<b>0.374 7</b>	0.504 2	<b>0.421 6</b>	0.353 4
BOC_NE+NBSVM	0.361 7	0.504 1	0.419 5	<b>0.354 0</b>
BOC_NE+CNN	0.315 8	<b>0.524 2</b>	0.390 4	0.317 7

实验 3:统一相关模型中不同特征权重参数的对比实验.

本文模型 BOC\_NE+Lexicon、BOC\_NE+NBSVM、BOC\_NE+CNN 均涉及两个参数:向量维度  $d$  和平滑参数  $\lambda$ .由于在 4 个评估指标中 MAP 较为重要,因此本实验研究不同参数下对这 3 个模型 MAP 的影响.维度  $d$  设置为 50、100、150、200,平滑参数  $\lambda$  的范围为 0~1,步长为 0.1. $\lambda$  为 0 时表示基于网络表示的主题相关度得分, $\lambda$  为 1 时表示基于概念模型的主题相关度得分.实验结果如图 2~图 4 所示.

图 2(a)、图 3(a)和图 4(a)展示的是在推特 2014 数据集中,本文 3 种模型的 MAP 随参数  $d$  和  $\lambda$  的变化情况. BOC\_NE+Lexicon(如图 2(a)所示)模型中,当  $d$  一定时,MAP 随着  $\lambda$  的增长而提升,在  $\lambda$  为 0.4 时达到峰值,随后又开始下降.其中,当  $d$  为 200、 $\lambda$  为 0.4 时取得最大值.类似地,BOC\_NE+NBSVM(如图 3(a)所示)模型当  $d$  为 150、 $\lambda$  为 0.8 时 MAP 取得最大值,BOC\_NE+CNN(如图 4(a)所示)模型在  $d$  为 150、 $\lambda$  为 0.4 时 MAP 取得最大值.整体而言,在  $\lambda$  确定的前提下,网络表示的维度  $d$  对性能影响往往不大,体现为上述图表中维度方向的边际分布往往比较平缓.但是具体的  $\lambda$  则对性能的影响较大,即:文本概念化与网络表示的权重对于性能的影响较大.3 种不同的观点建模方法在两个数据集上的结果显示,这种参数设置对 MAP 的影响在 1%左右.考虑到表 3 与表 4 中本文提出方法相较于基准方法提升的幅度较大,所以这种参数设置并不影响本文方法相较于基准方法的性能优势.




Fig.2 MAP of BOC\_NE+Lexicon with different parameters on two datasets  
 图 2 BOC\_NE+Lexicon 在两个数据集中不同参数对 MAP 的影响




Fig.3 MAP of BOC\_NE+NBSVM with different parameters on two datasets  
 图 3 BOC\_NE+NBSVM 在两个数据集中不同参数对 MAP 的影响




Fig.4 MAP of BOC\_NE+CNN with different parameters on two datasets  
 图 4 BOC\_NE+CNN 在两个数据集中不同参数对 MAP 的影响

实验 4:基于排序学习模型的观点检索对比实验.

为了进一步验证文本概念化特征、网络表示特征和观点得分特征在观点检索任务中的性能,本文进一步构造了基于排序学习模型的观点检索实验,在信息检索的常用特征基础上加上本文提出的特征进行实验,选取其中最优的特征组合进行对比.实验结果见表 7 和表 8.

**Table 7** Comparison of our best approach and benchmark approaches on Tweet 2014 dataset (II)

**表 7** 本文最优方法和基准方法在推特 2014 上的实验结果对比(II)

方法	MAP	NDCG@10	R-Prec	bPref
AAAI2012	0.432 0	0.587 9	0.491 2	0.607 6
WWW2015	0.434 5	0.592 8	0.502 9	0.601 3
L2R+BOC+NE+NBSVM(本文方法)	<b>0.442 0</b>	<b>0.607 9</b>	0.499 1	0.641 2
L2R+BOC+NE+CNN(本文方法)	0.441 7	0.599 1	<b>0.503 4</b>	<b>0.647 9</b>

**Table 8** Comparison of our best approach and benchmark approaches on extended dataset (II)

**表 8** 本文最优方法和基准方法在扩展数据集上的实验结果对比(II)

方法	MAP	NDCG@10	R-Prec	bPref
AAAI2012	0.381 2	0.555 3	0.360 3	0.566 2
WWW2015	0.385 4	0.546 4	0.375 7	0.578 4
L2R+BOC+NE+NBSVM(本文方法)	<b>0.452 9</b>	<b>0.624 3</b>	<b>0.453 0</b>	<b>0.616 4</b>
L2R+BOC+NE+CNN(本文方法)	0.441 7	0.618 3	0.439 0	0.609 8

表 7 和表 8 显示:在推特 2014 数据集和扩展数据集中加入本文提出的 3 类特征后,MAP、NDCG@10、R-Prec 和 bPref 这 4 个指标均有提升.在推特 2014 数据集上(见表 7),4 个指标获得最优值的方法分别为 L2R+BOC+NE+NBSVM、L2R+BOC+NE+NBSVM、L2R+BOC+NE+CNN、L2R+BOC+NE+CNN.在扩展数据集中(见表 8),MAP、NDCG@10、R-Prec 和 bPref 这 4 个指标上达到最优值的方法均为 L2R+BOC+NE+NBSVM.说明 AAAI2012 和 WWW2015 提出的特征不够充分,产生的特征空间比较稀疏.而本文提出的利用知识图谱和网络表示产生的文档概念空间和文档低维向量能够缓解向量空间稀疏的问题.

实验 5:排序学习模型中不同特征组合的性能对比.

在基于排序学习方法观点检索中,不同的特征组合导致的检索性能可能存在差异,实验 5 研究的是在信息检索的常用特征基础上加上本文提出的不同特征组合的观点检索性能.

表 9 和表 10 显示了本文提出的 3 类特征的不同组合在两个数据集上的实验结果.可以看出,单独加入 3 种观点得分特征对排序学习的性能影响不大.这是由观点分类的训练数据和测试数据的异质性导致的.同时可以看出:文本概念化特征和网络表示特征均能有效提升模型的性能,特别是在扩展数据集上,因为扩展数据集数据量大,出现歧义的实体现象较多,说明文本概念化特征和网络表示特征能够有效改善特征稀疏所引起的语义相似度计算困难现象.而在两个数据集上均显示出,同时使用文本概念化特征与网络表示特征可以进一步提升系统性能.这也说明两类方法在具体的使用过程中有一定的互补性.最后,在两个数据集上的所有特征组合中,MAP 值最高的均是 L2R+BOC+NE+NBSVM.这进一步证明了本文提出的方法能够有效解决上文提出的现有观点模型的 3 个局限性问题,从而提高检索模型的性能.

**Table 9** Comparison of different feature combinations in learning to rank model on Tweet 2014 dataset

**表 9** 排序学习模型中不同特征组合在推特 2014 上的实验结果对比

方法	MAP	NDCG@10	R-Prec	bPref
L2R+BOC	0.438 9	0.602 1	0.508 0	0.647 9
L2R+NE	0.441 7	0.592 7	0.504 0	0.611 4
L2R+CNN	0.435 4	0.597 8	0.501 1	0.616 4
L2R+Lexicon	0.434 9	0.590 0	0.494 0	0.607 0
L2R+NBSVM	0.435 6	0.586 2	0.497 1	0.606 7
L2R+NE+CNN	0.440 2	0.596 5	0.507 2	0.620 2
L2R+NE+Lexicon	0.437 8	0.593 2	<b>0.518 2</b>	0.630 8
L2R+NE+NBSVM	0.435 6	0.587 6	0.488 1	0.610 2
L2R+BOC+CNN	0.435 0	0.599 4	0.506 1	0.650 7

**Table 9** Comparison of different feature combinations in learning to rank model on Tweet 2014 dataset (Continued)

表 9 排序学习模型中不同特征组合在推特 2014 上的实验结果对比(续)

方法	MAP	NDCG@10	R-Prec	bPref
L2R+BOC+Lexicon	0.438 2	0.604 8	0.506 8	0.647 2
L2R+BOC+NBSVM	0.436 3	0.597 7	0.478 0	0.640 4
L2R+BOC+NE+CNN	0.436 4	0.599 1	0.503 4	0.647 9
L2R+BOC+NE+Lexicon	0.435 1	0.599 0	0.509 2	<b>0.652 1</b>
L2R+BOC+NE+NBSVM	<b>0.442 0</b>	<b>0.608 0</b>	0.499 1	0.641 2

**Table 10** Comparison of different feature combinations in learning to rank model on extended dataset

表 10 排序学习模型中不同特征组合在扩展数据集上的实验结果对比

方法	MAP	NDCG@10	R-Prec	bPref
L2R+BOC	0.403 3	0.547 7	0.402 0	0.585 4
L2R+NE	0.384 2	0.581 6	0.392 8	0.564 0
L2R+CNN	0.381 0	0.534 8	0.354 1	0.576 2
L2R+Lexicon	0.383 0	0.565 5	0.366 2	0.576 0
L2R+NBSVM	0.384 8	0.534 7	0.356 5	0.562 9
L2R+NE+CNN	0.402 2	0.544 4	0.397 0	0.581 6
L2R+NE+Lexicon	0.403 5	0.546 5	0.396 1	0.583 8
L2R+NE+NBSVM	0.403 4	0.540 8	0.403 5	0.582 8
L2R+BOC+CNN	0.424 8	<b>0.687 2</b>	0.398 8	0.577 2
L2R+BOC+Lexicon	0.423 0	0.672 6	0.397 8	0.578 1
L2R+BOC+NBSVM	0.431 8	0.682 6	0.402 3	0.581 1
L2R+BOC+NE+CNN	0.441 7	0.618 3	0.439 0	0.609 8
L2R+BOC+NE+Lexicon	0.441 1	0.640 9	0.433 6	0.609 4
L2R+BOC+NE+NBSVM	<b>0.452 9</b>	0.624 3	<b>0.453 0</b>	<b>0.616 4</b>

#### 4 总 结

本文提出了一种融合文本概念化与网络表示的观点检索模型.与现有研究工作不同,本文充分利用了知识图谱的结构化信息对用户查询和文本集进行语义分析,利用网络表示学习捕获知识图谱中节点之间的语义信息,利用统计机器学习的方法挖掘文本的倾向性信息.然后构建文本概念化特征、网络表示特征、观点得分特征这 3 类特征应用于统一观点检索模型以及基于排序学习的观点检索模型.实验结果表明:与现有工作对比,本文方法在 MAP 等指标上有明显的提升.在下一步工作中,首先可以进一步标注数据集,扩大训练集的语料,并结合常识性知识图谱,采用端到端(end to end)的模型进行训练,以期提高观点泛化能力.

#### References:

- [1] Ounis I, Macdonald C, Rijke MD, Mishne G, Soboroff I. Overview of the TREC 2006 Blog track. In: Proc. of the 14th Text Retrieval Conf. (Trec 2006). Gaithersburg, 2006. 86–95.
- [2] Pang B, Lee L. Opinion mining and sentiment analysis. In: Proc. of the Foundations and Trends in Information Retrieval. 2008. 1–135.
- [3] Zhang W, Yu C, Meng W. Opinion retrieval from Blogs. In: Proc. of the 6th ACM Conf. on Information and Knowledge Management. ACM Press, 2007. 831–840. [doi: 10.1145/1321440.1321555]
- [4] Wang XL, Wei F, Liu XH, Zhou M, Zhang M. Topic sentiment analysis in Twitter: A graph-based hashtag sentiment classification approach. In: Proc. of the 20th ACM Int'l Conf. on Information and Knowledge Management. ACM Press, 2011. 1031–1040. [doi: 10.1145/2063576.2063726]
- [5] Zhang M, Ye X. A generation model to unify topic relevance and lexicon-based sentiment for opinion retrieval. In: Proc. of the 31st Annual Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. ACM Press, 2008. 411–418.
- [6] Liao XW, Chen H, Wei JJ, Yu ZY, Chen GL. A weighted lexicon-based generative model for opinion retrieval. In: Proc. of the Int'l Conf. on Machine Learning and Cybernetics. 2015. 821–826.
- [7] Huang X, Croft WB. A unified relevance model for opinion retrieval. In: Proc. of the 18th ACM Conf. on Information and Knowledge Management. ACM Press, 2009. 947–956. [doi: 10.1145/1645953.1646075]

- [8] Perozzi B, Al-Rfou, Skiena S. Deepwalk: Online learning of social representations. In: Proc. of the 20th ACM SIGKDD Int'l Conf. on Knowledge Discovery and Data Mining. ACM Press, 2014. 701–710.
- [9] Tang J, Qu M, Wang MZ, Zhang M, Yan J, Mei QZ. LINE: Large-Scale information network embedding. In: Proc. of the 24th Int'l Conf. on World Wide Web, Int'l World Wide Web Conf. on Steering Committee. Florence, 2015. 1067–1077.
- [10] Ma FX, Liao XW, Yu ZY, Wu YB, Chen GL. A text opinion retrieval method based on knowledge graph. Journal of Shandong University (Natural Science), 2016,51(11):33–40 (in Chinese with English abstract).
- [11] Wang S, Manning CD. Baselines and bigrams: Simple, good sentiment and topic classification. In: Proc. of the Meeting of the Association for Computational Linguistics: Short Papers. 2012. 90–94.
- [12] Kim Y. Convolutional neural networks for sentence classification. arXiv Preprint arXiv: 14085882, 2014.
- [13] Robertson SE, Walker S, Jones S, Hancock-Beaulieu MM, Gatford M. Okapi at TREC-3. NIST Special Publication, 1995. 109–125. <http://www.doc88.com/p-9972384819356.html>
- [14] Salton G, Wong A, Yang CS. A vector space model for automatic indexing. Communications of the ACM, 1975,18(11):613–620.
- [15] Li X, Wang SG, Li DY, Kang XP, Zhai YH. Knowledge acquisition in incomplete information system based on formal concept analysis. Computer Science, 2014,41(7):250–253 (in Chinese with English abstract).
- [16] Zhuang Y, Li GL, Feng JH. A survey on entity alignment of knowledge base. Journal of Computer Research and Development, 2016,53(1):165–192 (in Chinese with English abstract).
- [17] Dalton J, Dietz L, Allan J. Entity query feature expansion using knowledge base links. In: Proc. of the 37th Int'l ACM SIGIR Conf. on Research & Development in Information Retrieval. ACM Press, 2014. 365–374. [doi: 10.1145/2600428.2609628]
- [18] Xiong CC, Allan J. Query expansion with freebase. In: Proc. of the 2015 Int'l Conf. on the Theory of Information Retrieval. ACM Press, 2015. 111–120. [doi: 10.1145/2808194.2809446]
- [19] Wang F, Wang ZY, Li ZJ, Wen JR. Concept-Based short text classification and ranking. In: Proc. of the 23rd ACM Int'l Conf. on Information and Knowledge Management. ACM Press, 2014. 1069–1078. [doi: 10.1145/2661829.2662067]
- [20] Wang ZY, Zhao KJ, Wang HX, Wen JR. Query understanding through knowledge-based conceptualization. In: Proc. of the Int'l Conf. on Artificial Intelligence. 2015. 3264–3270.
- [21] Li YH, Li DY, Wang SG, Zhai YH. Incremental entropy-based clustering on categorical data streams with concept drift. Knowledge-Based Systems, 2014,59(2):33–47.
- [22] Zheng WG, Cheng H, Zou L, Jeffrey XY, Zhao KF. Natural language question/answering: Let users talk with the knowledge graph. In: Proc. of the 2017 ACM Conf. on Information and Knowledge Management. Singapore, 2017. 217–226.
- [23] Hao YC, Zhang YZ, Liu K, He SZ, Liu ZY. An end-to-end model for question answering over knowledge base with cross-attention combining global knowledge. In: Proc. of the 55th Annual Meeting of the Association for Computational Linguistics. 2017. 221–231. [doi: 10.18653/v1/P17-1021]
- [24] Liu ZY, Sun MS, Lin YK, Xie RB. Knowledge representation learning: A review. Journal of Computer Research and Development, 2016,53(2):247–261 (in Chinese with English abstract).
- [25] Bordes A, Usunier N, Garcia-Duran A, Weston J, Yakhnenko O. Translating embeddings for modeling multi-relational data. In: Proc. of the NIPS. Cambridge, 2013. 2787–2795.
- [26] Wang Z, Zhang J, Feng J, Chen Z. Knowledge graph embedding by translating on hyperplanes. In: Proc. of the AAAI. Citeseer, 2014. 1112–1119.
- [27] Lin YK, Liu ZY, Sun MS, Liu Y, Zhu X. Learning entity and relation embeddings for knowledge graph completion. In: Proc. of the AAAI. 2015. 2181–2187.
- [28] Ji GL, He SZ, Xu LH, Liu K, Zhao J. Knowledge Graph embedding via dynamic mapping matrix. In: Proc. of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th Int'l Joint Conf. on Natural Language Processing. 2015. 687–696. [doi: 10.3115/v1/P15-1067]
- [29] Shi J, Gao H, Qi GL, Zhou ZQ. Knowledge graph embedding with triple context. In: Proc. of the 2017 ACM on Conf. on Information and Knowledge Management. Singapore, 2017.
- [30] He SZ, Liu K, Ji GL, Zhao J. Learning to represent knowledge graphs with gaussian embedding. In: Proc. of the ACM Int'l Conf. on Information and Knowledge Management. 2015. 623–632.

- [31] Ahmed A, Shervashidze N, Narayanamurthy S, Josifovski A, Smola AJ. Distributed large-scale natural graph factorization. In: Proc. of the 22nd Int'l Conf. on World Wide Web. ACM Press, 2013. 37–48.
- [32] Jacob Y, Denoyer L, Gallinari P. Learning latent representations of nodes for classifying in heterogeneous social networks. In: Proc. of the 7th ACM Int'l Conf. on Web Search and Data Mining. ACM Press, 2014. 373–382.
- [33] Santos RL, He B, Macdonald C, Ounis I. Integrating proximity to subjective sentences for Blog opinion retrieval. In: Proc. of the European Conf. on Information Retrieval. Springer-Verlag, 2009. 325–336. [doi: 10.1007/978-3-642-00958-7\_30]
- [34] Eguchi K, Lavrenko V. Sentiment retrieval using generative models. In: Proc. of the Conf. on Empirical Methods in Natural Language Processing. 2006. 345–354. [doi: 10.3115/1610075.1610124]
- [35] Luo Z, Osborne M, Wang T. An effective approach to tweets opinion retrieval. World Wide Web, 2015,18(3):545–566.
- [36] Kim YS, Song YI, Rim HC. Opinion retrieval systems using Tweet-external factors. In: Proc. of the 26th Int'l Conf. on Computational Linguistics (COLING), Proc. of the Conf. on System Demonstrations. Osaka: ACL, 2016. 126–130.
- [37] Wang ZY, Cheng JP, Wang HX, Wen JR. Short text understanding: A survey. Journal of Computer Research and Development, 2016,53(2):262–269 (in Chinese with English abstract).
- [38] Joachims T. Optimizing search engines using clickthrough data. In: Proc. of the 8th ACM SIGKDD Int'l Conf. on Knowledge Discovery and Data Mining. ACM Press, 2002. 133–142.
- [39] Luo Z, Osborne M, Wang T. Opinion retrieval in Twitter. In: Proc. of the AAAI 2012. 2012. 507–510.
- [40] Gerani S, Carman MJ, Crestani F. Investigating learning approaches for Blog post opinion retrieval. In: Proc. of the European Conf. on Information Retrieval. Springer-Verlag, 2009. 313–324.
- [41] Duan YJ, Jiang L, Qin T, Zhou M, Shum HY. An empirical study on learning to rank of Tweets. In: Proc. of the 23rd Int'l Conf. on Computational Linguistics. Association for Computational Linguistics, 2010. 295–303.

#### 附中文参考文献:

- [10] 马飞翔,廖祥文,於志勇,吴运兵,陈国龙.基于知识图谱的文本观点检索方法.山东大学学报(理学版),2016,51(11):33–40.
- [15] 李想,王素格,李德玉,翟岩慧.形式概念分析在不完备信息系统中的知识获取.计算机科学,2014,41(7):250–253.
- [16] 庄严,李国良,冯建华.知识库实体对齐技术综述.计算机研究与发展,2016,53(1):165–192.
- [24] 刘知远,孙茂松,林衍凯,谢若冰.知识表示学习研究进展.计算机研究与发展,2016,53(2):247–261. [doi: 10.7544/issn1000-1239.2016.20160020]
- [37] 王仲远,程健鹏,王海勋,文继荣.短文本理解研究.计算机研究与发展,2016,53(2):262–269. [doi: 10.7544/issn1000-1239.2016.20150742]



廖祥文(1980—),男,福建安溪人,博士,副教授,CCF 高级会员,主要研究领域为文本倾向性检索与挖掘.



程学旗(1971—),男,博士,教授,博士生导师,CCF 会士,主要研究领域为网络科学与社会计算,互联网搜索与挖掘.



刘德元(1992—),男,硕士生,主要研究领域为知识图谱,观点检索.



陈国龙(1965—),男,博士,教授,博士生导师,CCF 高级会员,主要研究领域为计算智能,计算机网络.



桂林(1987—),男,博士,主要研究领域为自然语言处理.