

基于融合模型的名词隐喻识别

苏魁麟¹, 张凯², 吕学强¹, 张乐¹

(1. 北京信息科技大学 网络文化与数字传播重点实验室, 北京 100101;
2. 首都师范大学文学院 中国语言智能研究中心, 北京 100048)

摘要: 隐喻识别是自然语言处理各前沿领域中所面临的难题。为了解决名词性隐喻中忽视的潜在特征和语义的信息利用不足从而导致隐喻识别效果不高的问题, 利用深度学习的优势, 该文提出一种特征融合神经网络模型—CB, 针对名词性隐喻进行识别。使用卷积神经网络模型—CNN 挖掘名词性隐喻句中的潜在特征, 预训练表征模型—BERT 对词语之间的关系和词的位置信息进行向量化表征, 以此有效地学习名词性隐喻句中的语义信息。在隐藏层特征维度上融合两者提取到的信息, 最后通过线性分类器进行识别。由于模型本身具有局限性, 名词性隐喻句中还蕴含少量抽象的特性, 因此无法只依靠模型挖掘所有的特征信息, 但针对大部分非抽象名词性隐喻句能够在不耗费人力资源的条件下有较好的识别效果。经过实验对比发现 CB 模型在准确率上达到 0.904 7、召回率 0.936 2、F1 值 0.926 2, 其综合指标均高于现有的最优深度学习模型。

关键词: 隐喻识别; 名词隐喻; 特征融合; 语义信息; CNN; BERT

中图分类号: TP391

文献标识码: A

文章编号: 1673-629X(2022)06-0192-06

doi:10.3969/j.issn.1673-629X.2022.06.032

Noun Metaphor Recognition Based on Fusion Model

SU Kui-lin¹, ZHANG Kai², LYU Xue-qiang¹, ZHANG Le¹

(1. Beijing Key Laboratory of Internet Culture & Digital Dissemination Research, Beijing Information Science & Technology University, Beijing 100101, China;
2. Research Center for Language Intelligence of China, School of Literature Capital Normal University, Beijing 100048, China)

Abstract: Metaphor recognition is a difficult problem in various fields of natural language processing. To solve the problem of poor metaphor recognition caused by hidden features overlooked in metaphors and insufficient use of semantic information, taking advantage of deep learning, we introduce the feature fusion neural network model (CB) to recognize nominal metaphors. First, convolutional neural network (CNN) is used to excavate the potential features in metaphorical sentences. Then, BERT, a pre-training model, is used to represent words and positions to excavate the semantic information in metaphorical sentences. It can effectively learn the semantic information in nominal metaphorical. Finally, the information extracted from CNN and BERT is recognized by the linear classifier. Due to the limitations of the model itself, nominal metaphorical sentences contain a small amount of abstract features, so it is impossible to mine all the feature information only by relying on the model. However, for most non-abstract nominal metaphorical sentences, it can achieve a better recognition effect without consuming human resources. Through experimental comparison, it is found that the accuracy rate of CB model is 0.904 7, the recall rate is 0.936 2, and the F1 value is 0.926 2, all of which are higher than the existing optimal deep learning model.

Key words: metaphor recognition; noun metaphor; feature fusion; semantic information; CNN; BERT

0 引言

隐喻是用来描述和理解抽象概念的主要手段, 它

不但是一种语言现象, 也是一种认知方式^[1]。认知是指人们获得知识或应用知识的过程, 是人类信息加工

收稿日期: 2021-07-06

修回日期: 2021-11-11

基金项目: 国家自然科学基金项目(61671070); 北京市自然科学基金(4212020); 国家语委科研项目面向基础教育的语言文字运用能力提升(YB135-163)

作者简介: 苏魁麟(1996-), 男, 硕士, 研究方向为自然语言处理; 吕学强, 博士, 教授, 研究方向为中文信息处理; 张乐, 博士, 副教授, 研究方向为自然语言处理。

的基本过程^[2],隐喻对人们的交流和认知有莫大的帮助,在人们日常用语或行为中都存在隐喻的特性,因此隐喻研究近年来越来越受关注。

隐喻的理解是隐喻理论的一个重要部分,因为隐喻的工作机制和认知功能是在理解过程中达成和体现出来的。隐喻的理解过程包括:隐喻识别和隐喻意义的推断。其作用是在人们用语言思考所感知的物质世界和精神时,能从原先互不相干的不同事物、概念和语言表达中发现如同互联网中的链接点,建立想象丰富的联系。这不是一个量的变化,而是认识上质的飞跃,难以用规则描述^[3]。因此如何有效地识别隐喻是当下面临的问题,而这个问题对自然语言的下游任务如机器翻译、问答系统、情感分析、阅读理解、人机对话、文本摘要等有着制约的影响。根据句法结构,隐喻一般分为:名词性隐喻、动词性隐喻、形容词性隐喻、副词性隐喻等。名词性隐喻在自然语言中占的比重较大,因此该文围绕名词性隐喻识别开展研究。

名词隐喻指自然语言表达中通过连接词表征的隐喻类型,其源域与目标域词汇通常以名词的形式出现在句子中也称本体和喻体,如“爱情就像棉花糖,柔软而又甜蜜”为名词隐喻,本体是爱情,喻体是棉花糖,是不同领域之间的映射。如何定位源域和目标域以及实体间的映射关系是隐喻识别的一项重要因素。

名词隐喻识别研究常用的方法是基于规则,利用语法特征,传统的机器学习,再到神经网络,但是目前对名词隐喻的语义表示不够充分,特征的抽取不精确,信息丢失造成识别的准确率不高。因此如何充分地上下文识别学习语义信息和潜在特征的抽取是隐喻识别的问题关键。

该文提出一种融合表征模型,抽取隐喻句中的潜在特征,结合上下文的语义信息和位置信息进行编码,构建针对名词隐喻识别的模型。具体而言使用 BERT 进行字嵌入表示,其 Transformer 结构中的注意力机制能够有效获得上下文的语义信息,同时对位置信息也进行向量化表征,提高喻体和本体的定位准确率,利用 CNN 进行局部特征的提取,融合两者特征再通过线性层得到隐喻结果。经实验表明该模型优于现有的深度学习模型。

1 相关研究

隐喻的识别起于 Wilks^[4]提出的语义中断理论和优先选择模型,是基于符号规则的识别方法。Fass^[5]提出基于语义优先理论,由于语料库有限,不能很好地获取语义信息,因此效果不好。许雅缘^[6]基于 WordNet 根据语义知识和语义关系识别隐喻,其原理是基于词语间的相似度计算,通过与 WordNet 词典中

的词语计算相似度再使用加权算法得出隐喻值,但在中文方面暂时没有成熟的知识库。上述方法均需要构建大量规则和特征,耗费人力。

随着深度学习技术在自然语言处理中的广泛应用, Kim. Y 等^[7]提出 CNN 用于文本分类,它只需要很少的超参数调整和静态向量,就可以在多个基准上获得很好的结果。Luo. L 等^[8]应用 LSTM+Attention 在实体识别上的效果有了大幅提升,利用通过 Attention 获得的文档级全局信息在文档中实施同一 Token 的多个实例之间标记一致性。王子牛等^[9]提出一种语言强化融合模型 CNN+LSTM 证明在文本分类上的提升。Yang 等^[10]提出将 BERT 与 Anserini 相结合,构建了一个通过外部知识库从而辅助阅读理解的方法,在问答领域有了较大提升。Peng^[11]提出变体 BERT 模型,其主要是在解码器 Transformer 上进行微调改造,在多种生物医学和临床自然语言处理任务都有大幅提升。Zhang 等^[12]提出 CMedBERT,是一种异构特征的动态融合机制和多任务学习策略,将医学知识融合到预先训练的语言模型,在基线实验上表现最优。但将深度学习应用于隐喻研究领域还是较少,Do Dinh 等^[13]提出基于词向量的神经网络模型识别隐喻,在效果上相较于传统机器学习等方法有了较大的提升,但网络本身比较简单且相较于现有的 LSTM 略逊色。王治敏^[14]提出基于机器学习算法的隐喻识别,主要针对上下文和词性两种特征进行建模,但忽视了语义层的重要信息。李晗雨^[15]提出基于深度学习的隐喻识别与解释方法研究,采用卷积神经网络和 SVM 作为模型架构,表明卷积神经网络在提取隐喻特征的表现很好。朱嘉莹等^[16]提出基于 Bi-LSTM 的多层面隐喻识别方法,结合卷积神经网络进行建模。通过分析隐喻的多层面特征在 Bi-LSTM 上进行识别取得了 88.8% 的准确率。张冬瑜等^[17]提出使用 BERT+Transformer 模型进行隐喻识别,能够很好地获取语义信息,但局限性是对文本的冷僻词判断较困难,无法有效提取句子的局部特征。

上述研究采用了基于规则、机器学习、深度学习的方法识别,对语义信息的挖掘不足,无法有效分辨隐喻中的动词、名词、形容词等知识。语义是隐喻中的一个重要因素,需要根据不同的上下文从不同维度去挖掘语义信息获取相应的知识,因此要满足建模的适用性和稳定性,同时如何把隐喻中隐含的潜在特征挖掘出来是提高隐喻识别的关键,二者缺一不可。

2 研究方法

2.1 基于 CNN 特征提取

Moriya S 等^[18]提出使用 CNN 模型进行文本特征

提取。其优点在于只需要很少的超参数调整和静态向量就可以提取文本中的有效特征,通过词向量编码,进行一维卷积得到特征图,计算公式见式(1),其中假定每个 k 维词向量用 x_i 表示, $b \in R$, f 为非线性函数, h 为卷积核的高度,卷积核 $w \in R^{hk}$,卷积后结果 $c = [c_1, c_2, \dots, c_{n-h+1}]$ 。每个特征图再通过 Pooling 层得到一个特征值,计算公式见式(2),池化后的汇总结果 $h_c = [c'_1, c'_2, \dots, c'_m]$,通过卷积层和最大池化层得到隐藏层特征,CNN 提取特征的模型如图 1 所示。

$$c_i = f(w \bullet x_{i:i+h-1}) \tag{1}$$

$$c'_i = \max\{c\} \tag{2}$$

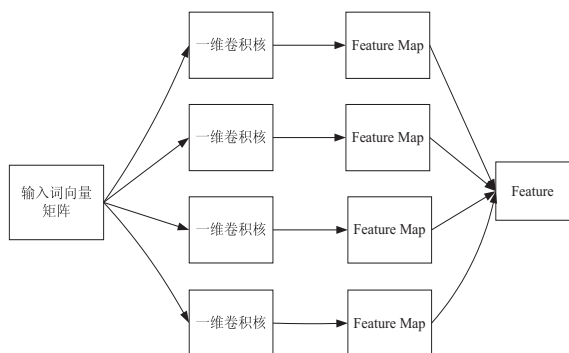


图 1 CNN 模型结构

2.2 BERT 预训练模型

Devlin J 等^[19]提出的基于 Transformer 结构的全新预训练模型瞬间刷新在各项自然语言处理任务 GLUE 的得分。从模型特点来说其输入表征不仅是词向量(token embedding),还有段表征(segment embed-

ding)和位置表征(position embedding)相加产生,一定程度上丰富了特征信息。为了能够更好地学习到语言的本质增加 Masked LM 和 Next Sentence Prediction 机制,首先 Masked LM 随机选取少量词汇进行遮掩训练,这就迫使模型更依赖于上下文信息去预测词汇,并赋予了模型一定的纠错能力。其次 Next Sentence Prediction 在段落结构上进行了训练学习,与 Masked LM 相结合让模型能够更准确地刻画语句乃至篇章层面的语义信息。

从模型结构上 Transformer 是组成 BERT 的核心模块,而 Attention 机制又是 Transformer 中最关键的部分。其中主要涉及三个概念:Query、Key 和 Value,目标字及其上下文的字都有各自的原始 Value,Attention 机制将目标字作为 Query、其上下文的各个字作为 Key,并将 Query 与各个 Key 的相似性作为权重,把上下文各个字的 Value 融入目标字的原始 Value 中。Attention 计算公式如式(3):

$$\text{Attention}(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \tag{3}$$

其中, Q, K, V 分别表示矩阵, d_k 表示 k 维序列。通过 Attention 构成多头机制作为编码器的一个分支,另一个分支是一个前向传播网络,在两个分支外加一个残差连接,这样就组成了一个编码器。BERT 是由 6 个编码器组成编码层,解码层也是由 6 个解码器组成,每个解码器的组成原理和编码器一致。BERT 的模型结构如图 2 所示。

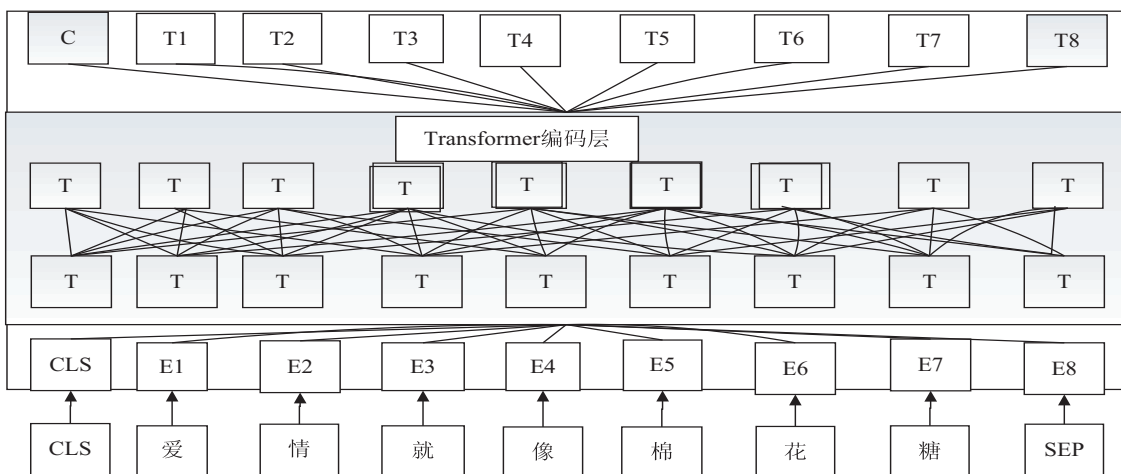


图 2 BERT 模型结构

实际操作中,Attention 是在序列上并行,将所有序列连在一起构成 Q, K, V 矩阵在矩阵上进行计算,多头 Attention 计算公式如式(4):

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_n) \tag{4}$$

Concat 用于连接多个头,把多个不同的注意力体连接在一起,每个 head 的表示如式(5):

$$\text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V) \tag{5}$$

BERT 的前馈神经网络公式如式(6):

$$\text{FFN}(x) = \max(0, xW_1 + b_1)W_2 + b_2 \tag{6}$$

其中, W_1, W_2, b_1, b_2 分别代表权重,根据反向传播自动优化。

2.3 CB 模型

CNN 有效提取局部特征,有效识别句子中冷僻词

汇、成语古语以及干扰词汇,BERT 对语义信息的理解和词与词之间位置信息的特征提取,通过融合两个模型提取到的特征,最后通过线性分类器,从而提升隐喻的识别效果。特征融合计算公式如式(7),线性层计算公式如式(8):

$$H = \text{concat}(h_c, h_b) \quad (7)$$

$$Y = HA^T + b \quad (8)$$

其中, h_c 代表 CNN 隐藏层输出, h_b 代表 BERT 隐藏层输出, H 代表融合隐藏层矩阵, A^T 代表权重矩阵, b 代表偏置矩阵, Y 代表预测值。

特征融合模型 CB 结构如图 3 所示。

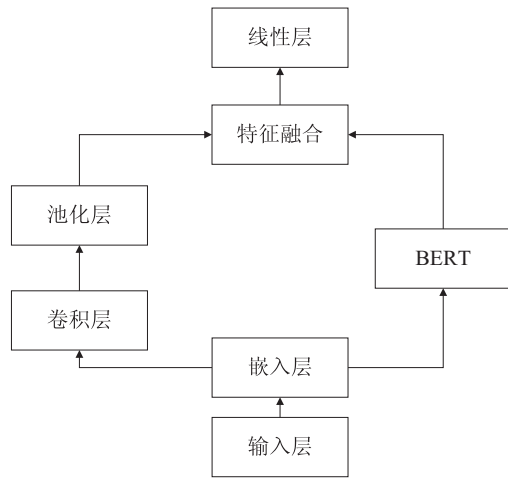


图 3 CB 模型结构

2.4 思路框架

整体的隐喻识别思路是首先对语料进行清洗,由于语料本身为结构化,只需要去掉标点符号,然后对句子进行编码,在每个句子开头和结尾分别添加 CLS 和 SEP 标识符分别代表开始和中断,其作用是处理成 BERT 的输入格式;其次是对网络层的编码组合包括对 BERT 预训练模型的选取和 CNN 卷积层和池化层的维度定义,通过两者输出进行隐藏层维度的融合,再

通过线性分类器,这样网络层就定义好了;最后经过多次训练得出最优结果。整体的识别流程如图 4 所示。




图 4 隐喻识别流程

3 实验

3.1 数据集

(1)数据来源。

采用 CCL2018 评测的中文动词隐喻识别任务中的数据集,由 2 040 条动词隐喻、2 035 条名词隐喻、319 条非隐喻句组成,共计 4 394 个中文句子。同时针对数据集进行了进一步归并,把名词性隐喻句归为一类,动词隐喻和非隐喻句子归为一类。

(2)数据标注情况。

数据分为正文部分和类别部分,而类别标注情况主要有三种,如表 1 所示。

表 1 数据标注情况

正文	类别
爱情就像棉花糖,柔软而又甜蜜	名词隐喻
改革开放推动了中国经济的发展	动词隐喻
灾民们在挖掘、整理废墟下的物品	非隐喻

“爱情就像棉花糖,柔软而又甜蜜”是名词隐喻,将“爱情”(本体)比喻为“棉花糖”(喻体),“爱情”本身是一个抽象的名词,但“棉花糖”是人们熟知的东西,说到“棉花糖”不禁想到“甜美”,“纯洁”等词汇,这是一种意识聚集。将抽象事物“爱情”比喻为具体事物“棉花糖”能够更好地去理解爱情的本质。

3.2 对比实验

将该文提出的模型与基线模型和同数据集实验下的最优模型进行对比实验,如表 2 所示。

表 2 对比实验分析

序号	模型	方法描述
1	CNN	通过多个一维卷积层,在对每一个卷积层进行最大池化后在通道维度上连接通过全连接层输出。在文本特征提取上效果很好
2	LSTM	通过其独特的门控制设计来控制传输状态,相比于传统的 RNN 能更好的在长序列中识别语义信息和解决梯度消失和梯度爆炸问题
3	LA(LSTM+Attention)	在 LSTM 的模型加上 Attention 机制计算各个隐藏层的权重,加权平均后替换原始 LSTM 最后一层隐藏层作为输出
4	CLA(CNN+LSTM+Attention)	CNN 提取局部特征,LSMT+Attention 获取上下文语义信息特征,最后融合两者的特征通过全连接层作为输出
5	BT(BERT+Transformer)	张冬瑜 ^[17] 使用 BERT+Transform 方法能够很好地识别语义信息,但对于中文文本中的冷僻词汇、成语古语以及干扰词汇等特征判断较困难

3.3 评价指标

实验结果评价指标采用准确率 (A)、精确率 (P)、召回率 (R) 和 F1 值, 分别见公式 (9) ~ 公式 (12)。

$$A = \frac{TP + TN}{TP + FP + TN + FN} \quad (9)$$

$$P = \frac{TP}{TP + FP} \quad (10)$$

$$R = \frac{TP}{TP + FN} \quad (11)$$

$$F1 = \frac{2PR}{P + R} \quad (12)$$

其中, TP: 样本为正, 预测结果为正; FP: 样本为负, 预测结果为正; TN: 样本为负, 预测结果为负; FN: 样本为正, 预测结果为负。

3.4 实验过程和参数设置

经过多次实验, 实验结果较好的参数情况如下: 优化器采用 AdamW, 其中学习率 2×10^{-5} , $\text{eps} = 1 \times 10^{-8}$, 损失函数采用 CrossEntropyLoss, Epoch 初始化为 100, 通过设置判断条件即连续 10 个 Epoch 下验证集的准确率没有提升结束训练, 并保存最优的 Epoch 值为 4, Batch 设置为 32, 采用 BERT 生成的字向量, 维度 100。卷积核长度设置为 [3, 4, 5], 通道设置为 [100, 100, 100], 输出维度为 300。防止过拟合采用 dropout, $\text{dropout} = 0.5$, 融合后的隐藏特征通过线性层进行分类。

数据集按照 7 : 2 : 1 比例分为训练集、验证集、测试集, 使用 pytorch 框架进行预处理和模型训练等编码, 使用由谷歌提供的中文预训练模型 BERT, 结构为 12 层, 隐藏层大小 768。

4 结果分析

根据 4 个评价指标在所提出的模型上的实验结果如表 3 所示。

表 3 名词隐喻识别结果

模型	A	P	R	F1
CNN	0.678 9	0.683 2	0.667 9	0.675 4
LSTM	0.743 3	0.742 6	0.771 3	0.756 6
LA	0.785 0	0.801 2	0.814 8	0.807 5
CLA	0.853 6	0.861 8	0.842 4	0.851 9
BT	0.900 0	0.896 4	0.885 8	0.891 0
CB	0.904 7	0.916 7	0.936 2	0.926 2

从结果可以看出, 提出的 CB 模型方法在各项指标上表现最优, 说明能够有效地提取语义信息和潜在特征。CNN 和 LSTM 的指标结果说明语义理解对隐喻的识别会有大幅度提高, 但是也不能忽视其中的潜

在的特征。CB 模型的精确率和召回率较于 BT 模型的提升可以说明在加入 CNN 提取局部特征确实能够提高对于中文文本中的冷僻词汇、成语古语以及干扰词汇等特征信息的判断, 从而提高名词隐喻的识别率, 而 CLA 也是基于特征融合的思想, 尽管 LSTM 能够获得上下文信息, 但其门控制相较于 BERT 中 MLM 和 NSP 学习机制对语义信息的提取还是略显不足, 且对长依赖问题处理效果不好。

从预测结果来说 CB 模型学习到名词隐喻中具有代表性的词如“像”, “好像”, “似乎”等句子预测结果都正确, 同时对于没有代表性的词特征的句子如“太阳是我们心中的明灯, 引领我们前行”预测正确说明对本体“太阳”和喻体“明灯”正确定位, 说明对语义信息的理解很好。“广告路牌是地面上的肉疣”中“肉疣”是生僻词, 但预测结果正确, 说明 CNN 对局部潜在特征的提取能够提高识别效果。

5 结束语

隐喻是自然语言认知上的一个重要因素, 因此如何有效地识别隐喻是当前需要攻克的难题。该文针对目前隐喻识别上对语义信息的理解不足和隐喻中蕴含的特征提取不够等问题, 提出了一种特征融合神经网络模型, 利用 BERT 提取文本中语义信息和表征位置信息, CNN 提取隐喻中潜在的局部特征, 最后在隐藏特征维度上对两者进行融合。从局部和全局两个方向上识别隐喻, 从提出的评价指标来看优于现有的主流深度学习和方法。名词隐喻中不仅只有本体和喻体的映射关系。还有其他如隐喻触发词、隐喻链等特征无法针对性的去挖掘, 模型还存在局限。

针对这些局限性可以联想到两种解决办法:

(1) 对数据集进行知识性的扩充标注和扩大数据集的量, 从本质上丰富数据集的特征信息。

(2) 挖掘隐喻中更重要的特性并针对性地进行建模识别, 理论上来说可以通过模型挖掘隐喻中所有的特性, 根据每个特性在隐喻中的重要性去分散研究最后通过加权算法识别隐喻, 而这其中涉及到各个特性在隐喻中比重是需要通过大量研究得出结论, 隐喻识别仍是当今自然语言研究上所面临的难题。

参考文献:

- [1] LAKOFF G, JOHNSON M. Metaphors we live by[M]. Chicago: University of Chicago Press, 2008.
- [2] AUSUBEL D P. The acquisition and retention of knowledge: a cognitive view[M]. [s. l.]: Springer Science & Business Media, 2012.
- [3] 胡壮麟. 语言·认知·隐喻[J]. 现代外语, 1997(4): 52+51+53-59.

- [4] WILKS Y, DALTON A, ALLEN J, et al. Automatic metaphor detection using large-scale lexical resources and conventional metaphor extraction [C]//Proceedings of the 1st workshop on metaphor in NLP. Atlanta, Georgia, USA; [s. n.], 2013:36-44.
- [5] FASS D. Met*: a method for discriminating metonymy and metaphor by computer [J]. Computational Linguistics, 1991, 17(1):49-90.
- [6] 许雅缘. 基于 WordNet 的隐喻自动处理研究 [J]. 外语电化教学, 2010(6):39-43.
- [7] KIM Y. Convolutional neural networks for sentence classification [J]. arXiv:1408.5882, 2014.
- [8] LUO L, YANG Z, YANG P, et al. An attention-based BiLSTM-CRF approach to document-level chemical named entity recognition [J]. Bioinformatics, 2018, 34(8):1381-1388.
- [9] 王子牛, 王宏杰, 高建瓴. 基于语义强化和特征融合的文本分类 [J]. 软件, 2020, 41(1):211-215.
- [10] YANG W, XIE Y, LIN A, et al. End-to-end open-domain question answering with bertserini [J]. arXiv:1902.01718, 2019.
- [11] PENG Y, CHEN Q, LU Z. An empirical study of multi-task learning on BERT for biomedical text mining [J]. arXiv: 2005.02799, 2020.
- [12] ZHANG T, WANG C, QIU M, et al. Knowledge-empowered representation learning for chinese medical reading comprehension: task, model and resources [J]. arXiv: 2008.10327, 2020.
- [13] DO DINH E L, GUREVYCH I. Token-level metaphor detection using neural networks [C]//Proceedings of the 4th workshop on metaphor in NLP. San Diego, California, USA; [s. n.], 2016:28-33.
- [14] 王治敏, 王厚峰, 俞士汶. 基于机器学习方法的汉语名词隐喻识别 [J]. 高技术通讯, 2007, 17(6):575-580.
- [15] 李晗雨. 基于深度学习的隐喻识别与解释方法研究 [D]. 杭州: 杭州电子科技大学, 2019.
- [16] 朱嘉莹, 王荣波, 黄孝喜, 等. 基于 Bi-LSTM 的多层面隐喻识别方法 [J]. 大连理工大学学报, 2020, 60(2):209-215.
- [17] 张冬瑜, 崔紫娟, 李映夏, 等. 基于 Transformer 和 BERT 的名词隐喻识别 [J]. 数据分析与知识发现, 2020, 4(4):100-108.
- [18] MORIYA S, SHIBATA C. Transfer learning method for very deep CNN for text classification and methods for its evaluation [C]//Proceedings of the IEEE 42nd annual computer software & applications conference. Tokyo, Japan; IEEE, 2018:153-158.
-
- (上接第 191 页)
- [2] 王玉善, 王金荣, 周春香, 等. 大港滩海区古近系储层类型及次生孔隙成因分析 [J]. 科技视界, 2012(6):25-26.
- [3] 田彦德. 基于孔隙度变化规律的石灰岩单轴压缩损伤度表征方法 [J]. 山西焦煤科技, 2019, 43(10):32-34.
- [4] 曹鹏. 注水开发砂岩油藏优势渗流通道模拟分析 [D]. 成都: 西南石油大学, 2017.
- [5] LI T, TAN Y, CAI Z, et al. Mathematical model of spontaneous potential well-logging and its numerical solutions [M]. Berlin: Springer, 2014.
- [6] 宋子齐, 李伟峰, 唐长久, 等. 利用自然电位与自然伽马测井曲线划分沉积相带及储层分布 [J]. 地球物理学进展, 2009, 24(2):650-656.
- [7] LI C, SIMA L Q, SHEN A J, et al. The application of the reservoir heterogeneity evaluate method with microresistivity image log in FC formation of G region in northeastern Sichuan [J]. Progress in Geophysics, 2015, 30(2):725-732.
- [8] 赵丹. 陈沱口地区盐间非砂岩地层地球物理响应特征研究 [D]. 武汉: 长江大学, 2015.
- [9] 徐春梅. 川中古隆起磨溪地区碳酸盐岩储层预测研究 [D]. 大庆: 东北石油大学, 2011.
- [10] 冯智慧. 高分辨率复数道分析方法在油藏描述中的应用 [D]. 长春: 吉林大学, 2008.
- [11] 李斌斌, 郭大立, 毛新军, 等. 基于 BP 神经网络的储集层物性参数预测与评价——以准噶尔盆地东部北三台地区为例 [J]. 重庆科技学院学报: 自然科学版, 2014, 16(2):39-42.
- [12] SEZER A. Prediction of shear development in clean sands by use of particle shape information and artificial neural networks [J]. Expert Systems with Applications, 2011, 38(5):5603-5613.
- [13] GROSSBERG S. Classical and instrumental learning by neural networks [J]. Progress in Theoretical Biology, 1982, 3:51-141.
- [14] 李映涛, 袁晓宇, 刘迪, 等. BP 神经网络在测井解释中的应用研究 [J]. 西部探矿工程, 2013, 25(3):45-48.
- [15] 杨建, 杨程博, 张岩, 等. 基于改进神经网络的渗透率预测方法 [J]. 岩性油气藏, 2011, 23(1):98-102.