

文章编号: 2095-2163(2020)07-0141-06

中图分类号: TP39

文献标志码: A

基于 Seq2Seq 模型的命名实体识别方法

王卫红, 冯倩, 吕红燕, 曹玉辉

(河北经贸大学 信息技术学院, 石家庄 050061)

摘要: 本文针对传统命名实体识别方法中存在严重依赖大量人工特征导致文本特征表示不充分的问题, 提出一种基于 Seq2Seq 模型的命名实体识别方法。利用 BERT 预训练模型动态生成字的语义向量, 通过 Seq2Seq 模型中的编码器对字向量进行编码, 并引入注意力机制为词语分配权重, 从而获取文本局部特征和全局特征。最后, 将得到的特征输入到解码器中, 通过 softmax 层预测序列标签。实验结果表明, 该方法在准确率、召回率与 F1 值上均有所提升, 具有良好的适用性。

关键词: 命名实体识别; BERT; Seq2Seq 模型; 注意力机制

Named entity recognition method based on Seq2Seq model

WANG Weihong, FENG Qian, LV Hongyan, CAO Yuhui

(School of Information Technology, Hebei University of Economics and Business, Shijiazhuang 050061, China)

[Abstract] In order to solve the problem that traditional named entity recognition heavily depend on a large number of artificial features and cause insufficient text feature representation, this paper proposes a named entity recognition method based on Seq2Seq model. Firstly, the method first uses the BERT pre-training model to dynamically generate semantic vectors for words. Secondly, the word vector is encoded through the encoder in the Seq2Seq model, and the attention mechanism is introduced to assign weights of the words to obtain local and global features of the text. Finally, the obtained features are input into the decoder, and through the softmax layer to predict the sequence labels. The experimental results show that the method has improved in accuracy, recall and F1, and has better applicability.

[Key words] Named entity recognition; BERT; Seq2Seq model; Attention mechanism

0 引言

命名实体识别(NER)是知识图谱构建中最为关键的一部分^[1], 广泛应用于智能问答、知识管理、语义搜索等领域中的人名、地名、组织名、时间、货币等信息的识别。近年来研究者将命名实体识别任务视为序列标注问题, 对序列中的每一个字标注一个标签, 并根据最终的标签判定命名实体的边界和类型^[2]。命名实体识别任务中文本特征提取的好坏直接影响命名实体识别的准确率, 进而间接影响知识图谱构建的质量。

随着技术的不断发展, 采用端到端的神经网络模型成为命名实体识别最主流的方法, 与传统的方法相比, 该模型不依赖于人工特征和领域知识, 在处理命名实体识别任务时表现出更好的效果。Seq2Seq 模型是 Google 在 2014 年提出的, 成功应用

于机器翻译、自动摘要、问答系统等领域^[3]。Seq2Seq 模型主要用来处理序列到序列的映射问题, 结构采用编码器和解码器的形式, 根据具体应用场景选择编码器端和解码器端使用的神经网络, 来获得问题的最优解。

本文提出一种基于 Seq2Seq 模型的命名实体识别方法, 该方法利用 BERT 预训练模型来生成字的语义向量, 并在 Seq2Seq 模型中加入注意力机制进一步获得文本的特征, 从而准确的获得文本特征, 提高命名实体识别的性能。

1 相关工作

目前, 国内外学者针对命名实体识别中大量依赖人工特征导致文本特征表示不充分的问题进行了大量研究, 包括基于机器学习的命名实体识别、基于神经网络的命名实体识别。例如: 俞鸿魁等人提出

基金项目: 留学回国人员择优资助项目(C2015003042); 河北省自然科学基金青年项目(F2015207009)。

作者简介: 王卫红(1970-), 女, 博士, 教授, 主要研究方向: 知识图谱、推荐系统、协同计算; 冯倩(1994-), 女, 硕士研究生, 主要研究方向: 知识图谱、推荐系统; 吕红燕(1994-), 女, 硕士研究生, 主要研究方向: 知识图谱、用户画像; 曹玉辉(1969-), 男, 博士, 教授, 主要研究方向: 协同计算。

通讯作者: 冯倩 Email: 15733100624@163.com

收稿日期: 2020-05-12

一种基于层叠隐马尔可夫模型的中文命名实体方法,取得了较好的效果;张明杰等人采用最大熵模型融合局部和全局特征,并加入启发式规则进行优化,得到了较好的性能;周俊生等人针对中文机构名特点,提出一个基于层叠条件随机场模型的自动识别算法;Zhou 提出使用四种不同的特征去提高 HMM 在 NER 上的性能。这些研究大都基于统计机器学习方法,仍然存在依赖大量人工特征,适用性差等问题,未能充分表达文本的隐含特征。

神经网络作为一种深度学习技术具有强大的计算能力、学习能力、特征提取能力,弱化了对人工特征和领域知识的依赖,在序列标注任务中有强大的优势。如:采用条件生成式对抗网络(CGAN)中图像概率分布的思想,设计了生成式对抗网络模型,用于实体识别^[4];利用文本的语言结构来改进 BRNN-CNN 的命名实体识别,并采用卷积双向递归网络^[5];一种更快的 Bi-LSTM NER 替代方案:迭代扩张卷积神经网络(ID-CNN),具有比传统 CNN 更好的性能^[6];基于 CharWNN 的深层神经网络,使用词级和字符级表示^[7];针对中文词语边界问题,提出基于深度学习框架的字词联合方法,将字特征和词特征相结合,有效地提高了实体识别的准确率^[8];引入基于实例的迁移学习方法,弥补了深度学习在小数据集上的不足,取得了较好的效果^[9];Lattice LSTM 网络结构,该方法将传统的 LSTM 单元改进为网格 LSTM,在字模型的基础上显性利用词与词序信息,避免了分词错误传递的问题^[10];采用 CRF 对句子进行分词,在此基础上使用 Bi-LSTM 模型进行实体识别^[11];一种使用混合双向 LSTM 和 CNN 架构自动检测词和字符级特征的方法,提高了实体识别性能^[12];基于 BERT-IDCNN-CRF 的中文命名实体识别方法,具有较强的语义表达能力^[13];基于 BERT-BiLSTM-CRF 的命名实体识别方法,增强了字符间的推理能力^[14];BGRU-CRF 体系结构,实现了实体消歧,提高了实体识别的性能^[15]。

上述研究从基于机器学习和神经网络两方面进行了研究,并取得了一定的效果,但大多是都是基于 BiLSTM-CRF 架构上的改进,具有一定的局限性。本文提出一种基于 Seq2Seq 模型的命名实体识别方法,该方法通过使用具有强大表义能力的 BERT 预训练模型获取文本中字的语义表示,利用 Seq2Seq 模型对文本进行特征提取,引入注意力机制来得到文本局部特征,充分的考虑文本上下文信息,提高命名实体识别的准确性。

2 BERT-Seq2Seq-Attention

2.1 模型思想

命名实体包含重要的信息,是关系抽取和事件抽取的基础,其语义信息的表达将直接影响知识表示的性能和知识图谱构建的质量。传统的基于规则和字典的方法,过度依赖于领域知识和规则的制定,可使用性较差。基于统计的命名实体识别模型对数据进行概率化建模,具有良好的序列标注能力,但依赖于特征模板,灵活性较差。因此,针对传统的命名实体识别方法中存在严重依赖大量人工特征导致文本特征表示不充分的问题,采用 BERT 模型训练得到字的语义向量,将字向量输入到 Seq2Seq 模型进行编码和解码,最后在 softmax 层进行序列标签预测。

2.2 模型架构

BERT-Seq2Seq-Attention 模型旨在解决传统的命名实体识别方法中严重依赖大量人工特征导致文本特征表示不充分的问题,其中采用 BERT 预训练模型获取字的语义信息量,采用 Seq2Seq 模型和注意力机制获取文本全局特征和局部特征。

BERT 模型考虑了字的局部信息与局部窗口外字的联系,充分考虑了上下文信息,在不同语境下表示的字向量是不一样的,具有强大的语义表达能力。Seq2Seq 模型采用编码器和解码器的方式,其中编码器和解码器采用 BiLSTM 网络结构,具有强大的特征提取能力。在编码阶段将输入序列信息压缩为固定大小的状态向量 S,压缩过程中会有信息损失,序列越长,对信息造成的损失就越大,因此加入注意力机制减少信息的损失。注意力机制是一种用来分配有限信息处理能力的选择机制,其特点为选择性地关注某些重要的信息,相应的忽略同一时刻接收到的其他信息^[16],从而可以得到文本的局部特征,减少 Seq2Seq 模型对信息的损失。

本文提出 BERT-Seq2Seq-Attention 模型框架如图 1 所示。模型框架分为三层,BERT 层、编码层和解码层。

2.2.1 BERT 层

BERT 预训练语言模型采用了双向 Transformer 进行编码,预训练任务包括 Masked 语言模型和 Next Sentence Prediction,模型的输入是位置信息、词、句子三种向量的叠加,充分利用了字左右两侧的文本信息,能够动态生成字级别和词级别的语义向量。BERT 模型输入表示如图 2 所示。

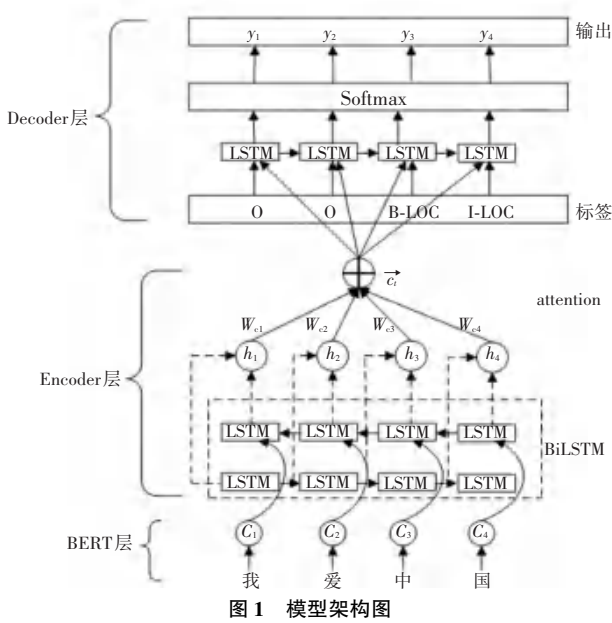


图 1 模型架构图

Fig. 1 Model architecture diagram

BERT 输入模型采用 [CLS] 作为句子开始标记, 采用 [SEP] 作为句子结束标记, 可用于分类任务。本文采用 BERT 模型将文本中的字信息表示成向量, 其中字向量通过查询向量表得到。首先定义一个字典 D_c , 将字向量存储在矩阵 $R^{a \times |D_c|}$, 给定一个句子 P 由 n 个字组成, 每个字向量表示为 $c_i (1 \leq i \leq n)$, 句子向量表示为 $p = [c_1; c_2; \dots; c_n]$ 。采用 BERT 预训练模型训练文本, 得到句子向量作为 Encoder 层的输入。

2.2.2 Encoder 层

从图 1 可以看出 Encoder 层使用的是双向 LSTM 网络, LSTM 网络是为了解决传统 RNN 中存在的梯度消失和梯度爆炸问题而提出的一种特殊的循环神经网络, 广泛应用于自然语言理解中序列建模问题。LSTM 网络包含三个门结构, 分别是遗忘门、输入门和输出门, 具体计算过程, 式(1)~式(5):

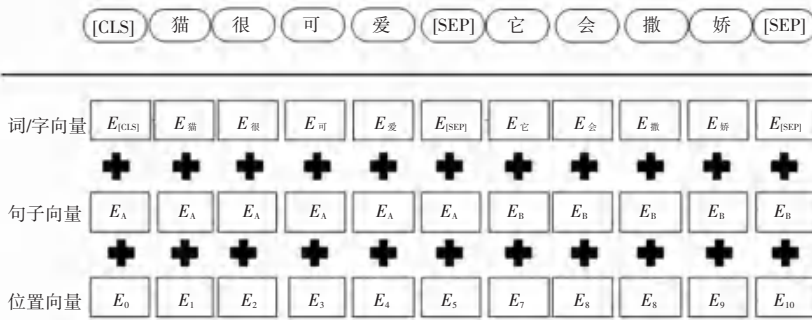


图 2 BERT 输入模型

Fig. 2 BERT input model

$$f_t = \sigma(W_f \cdot [h_{t-1}, c_t] + b_f), \quad (1)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, c_t] + b_i). \quad (2)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t. \quad (3)$$

$$o_t = \sigma(W_o [h_{t-1}, c_t] + b_o). \quad (4)$$

$$h_t = o_t * \tanh(C_t). \quad (5)$$

其中, f_t, i_t, o_t 分别为遗忘门、输入门和输出门; W_f, W_i, W_o 为权重矩阵; b_f, b_i, b_o 为偏置向量; c_t 为 t 时刻的输入; h_{t-1} 表示 $t-1$ 时刻隐藏层输出的向量; C_{t-1} 表示 $t-1$ 时刻的状态向量; σ 和 \tanh 为不同的神经元激活函数。

单向的 LSTM 网络只能获得一个方向的信息, 但在序列建模问题中需要充分利用上下文信息, 因此, 本文采用了双向 LSTM 网络结构, 进行命名实体识别研究。在前向网络结构中得到的隐藏节点表示为 $\vec{h}_t = g(\vec{h}_{t-1}, c_t)$, 在反向网络结构中得到的隐藏

节点表示为 $\overleftarrow{h}_t = g(\overleftarrow{h}_{t-1}, c_t)$, 将前向表示和反向表示进行拼接作为最终的隐藏节点, 将其表示为 $h_t = [\vec{h}_t; \overleftarrow{h}_t]$ 。由于在编码阶段将输入序列信息压缩为一个固定大小的状态向量 S , 会产生信息损失, 在解码阶段可能出现信息丢失的现象。因此, 本文使用了注意力机制来提高解码阶段的准确性。

注意力机制模拟人类视觉注意力机制, 为不同的特征赋予不同的权重, 从而凸显出上下文中的关键信息。计算公式(6)~公式(8):

$$c_t = \sum_{i=1}^n a_{it} h_i, \quad (6)$$

$$a_{it} = \frac{\exp(e_{it})}{\sum_{k=1}^n \exp(e_{ik})}, \quad (7)$$

$$e_{it} = \text{score}(s_{i-1}, h_i), \quad (8)$$

其中, c_t 为注意力机制输出的加权求和特征向

量; h_t 为编码器网络隐藏层向量; a_{it} 为权重值, s_{i-1} 为解码器网络的隐层状态向量。

2.2.3 Decoder 层

Decoder 层采用的是 LSTM 网络结构, 输入包含 c_i 、隐含层的状态向量 s_i 和 $t-1$ 时刻的真实标签。经过 LSTM 处理输入到 softmax 层, 得到 y_i , t 时刻第 i 个样本的概率分布, 计算公式 (9) 和 (10):

$$p(y_i | y_1, \dots, y_{i-1}) = f(y_{i-1}, s_i, c_i), \quad (9)$$

$$s_i = f(s_{i-1}, y_{i-1}, c_i), \quad (10)$$

softmax 层实现对概率归一化, 并输出类别, 计算公式 (11):

$$y_i = \text{softmax}(f(y_{i-1}, s_i, c_i) \cdot W + b), \quad (11)$$

2.3 方法步骤

本文提出的 BERT-Seq2Seq-Attention 模型主要包括 3 个步骤:

(1) 使用 BERT 预训练模型将字转成向量形式。

(2) 采用 Seq2Seq 模型中的编码端对文本进行特征提取, 并引入注意力机制减少信息损失。

(3) 采用 Seq2Seq 模型中的解码端对序列进行解码, 通过 softmax 层进行分类, 得到最优序列。

BERT-Seq2Seq-Attention 算法步骤如下:

输入: 训练集 train, 测试集 test, 字向量维度 h , 隐藏层节点数 hidden_size, 批次大小 batch_size

输出: 准确率 P 、召回率 R 和 $F1$ 值

(1) 采用 BERT 预训练模型得到字向量, 存储到字典 D_c 中;

(2) 根据公式 (1) ~ 公式 (5) 计算隐藏状态向量;

(3) 将前向和反向 LSTM 网络结构得到的隐藏状态向量进行拼接, 得到最终的向量表示 $h_i = [\vec{h}_i; \overleftarrow{h}_i]$;

(4) 根据公式 (6) ~ 公式 (8) 计算加权求和和特征向量 c_i ;

(5) 根据公式 (9)、公式 (10) 计算序列概率分布, 使序列概率最大化;

(6) 根据公式 (11) 对概率归一化, 并根据得到的概率分类, 得到最优序列标签;

(7) 使用训练好的模型对测试集进行标签预测。

3 实验与结果分析

3.1 实验设计

实验采用 1998 年 1 月份《人民日报》语料数据集和 MSRA 语料数据集, 对其中的人名 (PER)、地名 (LOC) 和机构名 (ORG) 进行识别, 其中 80% 作为

训练集, 20% 作为测试集。数据集信息统计表见表 1。

表 1 数据集信息统计

Tab. 1 Data set information statistics

数据集	训练集	测试集
《人民日报》	15 850	3 962
MSRA	23 700	4 400

模型参数设置: BERT 预训练模型采用 BERT-Base, 字向量和词向量长度为 128, BiLSTM 隐藏层为 1 层, 前向和后向神经元个数为 128, 学习率为 0.001。

3.2 标注模型与评价指标

标注模型选用 BIEO, B 代表实体的开始, I 代表实体中间的字符, E 代表实体中的最后一个字符, O 代表另一个非实体字符。

评价指标选用准确率 P 、召回率 R 和 $F1$ 值, 计算公式 (12) ~ 公式 (14):

$$P = \frac{\text{正确识别的实体数}}{\text{实际抽取的实体数}} \times 100\%, \quad (12)$$

$$R = \frac{\text{正确识别的实体数}}{\text{实体总数}} \times 100\%, \quad (13)$$

$$F1 = \frac{2 \times P \times R}{P + R}. \quad (14)$$

3.3 结果分析

(1) 输入字向量的语义准确度对命名实体识别的效果存在一定的影响, 本文在《人民日报》语料数据集上采取了三种向量表示方式, 第一种是 Word2vec, 第二种是 ELMO, 第三种是 BERT。实验结果见表 2。

表 2 表示模型对比

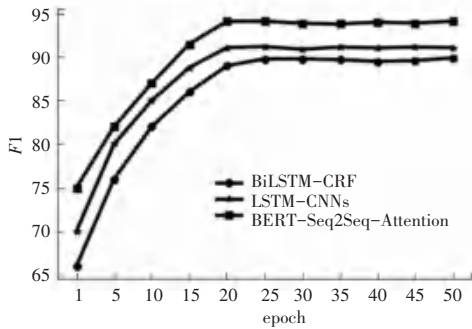
Tab. 2 Model comparison

模型	实体类别	$P/\%$	$R/\%$	$F1/\%$
Word2vec	人名	90.18	87.92	89.04
	地名	87.37	89.65	88.49
	机构名	84.71	80.24	82.41
ELMO	人名	92.96	89.54	92.21
	地名	93.15	88.62	90.84
	机构名	86.91	89.07	88.01
BERT	人名	95.24	93.79	94.50
	地名	94.07	92.80	93.43
	机构名	90.56	92.28	91.41

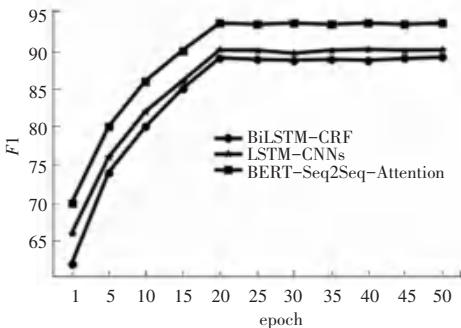
从表 2 可以看出使用 BERT 模型得出的人名、地名、机构名的准确率、召回率、 $F1$ 值优于 Word2vec、ELMO 模型, 其中人名识别率最高, 机构

名识别率最低,主要原因在于人名结构组成相对简单,机构名存在嵌套、缩写等信息。BERT 模型相比于 Word2vec 在人名、地名、机构名上 F1 值分别提升了 5.46%、4.94%、9%,相比于 ELMO 在人名、地名、机构名上 F1 值分别提升了 2.24%、2.59%、3.4%,说明 BERT 模型可以更好地表示字或词的语义信息,提高了命名实体识别的性能。

(2) 采用三种方法在《人民日报》数据集和 MSRA 数据集上进行了 50 轮迭代, F1 值与迭代次数的关系如图 3 所示,横坐标迭代次数,纵坐标为 F1 值。从图 3(a)可以看出在《人民日报》数据集上三种模型在迭代 25 次后达到最高的 F1 值;从图 3(b)在可以看出 MSRA 数据集上三种模型在迭代 20 次后达到最高的 F1 值。综合图 3(a)和图 3(b)可以看出 BERT-Seq2Seq-Attention 模型在两个数据上的 F1 值均高于其他两个模型,具有较好的性能。



(a) 《人民日报》语料数据集
(a) Corpus data set of People's Daily



(b) NSDRA 语料数据集
(b) NSDRA Corpus data set
图 3 F1 与迭代次数关系图

Fig. 3 Diagram of the relationship between F1 and the number of iterations

(3) 为了验证模型的有效性,将本文提出的算法与 CRF 模型、BiLSTM-CRF 模型、LSTM-CNNs 模型在两个数据集上进行对比实验,实验结果见表 3、表 4。

表 3 《人民日报》语料数据集
Tab. 3 《People's Daily》corpus data set

模型	P/%	R/%	F1/%
CRF	86.21	83.48	84.82
BiLSTM-CRF	91.57	88.31	89.91
LSTM-CNNs	92.03	90.16	91.08
BERT-Seq2Seq-Attention	94.65	93.58	94.11

表 4 MSRA 语料数据集
Tab. 4 MSRA corpus data set

模型	P/%	R/%	F1/%
CRF	83.10	82.09	82.59
BiLSTM-CRF	90.72	87.50	89.08
LSTM-CNNs	91.82	90.09	90.94
BERT-Seq2Seq-Attention	94.26	92.87	93.55

从表 3 和表 4 可以看出,本文提出的 BERT-Seq2Seq-Attention 模型在准确率、召回率和 F1 值上均优于其他模型。在《人民日报》语料数据集上 BiLSTM-CRF 模型与 CRF 模型相比 F1 值提高了 5.09%,说明基于神经网络的混合模型比单一模型识别效果好,BERT-Seq2Seq-Attention 模型与 BiLSTM-CRF 模型相比 F1 值提高了 4.2%,与 LSTM-CNNs 模型相比 F1 值提高了 3.03%。在 MSRA 语料数据集上 BiLSTM-CRF 模型与 CRF 模型相比 F1 值提高了 6.49%,BERT-Seq2Seq-Attention 模型与 BiLSTM-CRF 模型相比 F1 值提高了 4.47%,与 LSTM-CNNs 模型相比 F1 值提高了 2.61%。

由此表明,本文提出的模型可以高效的提取文本全局特征和局部特征,并得到更为精准的语义理解,减少了对人工特征的依赖,达到了较好的命名实体识别效果。

4 结束语

针对传统的命名实体识别方法中存在严重依赖大量人工特征导致文本特征表示不充分的问题,提出一种基于 Seq2Seq 模型的命名实体识别方法。利用 BERT 预训练模型得到字的上下文语义向量,并在 Seq2Seq 模型的编码阶段加入注意力机制,改善信息压缩导致无法准确提取文本特征的问题。通过实验验证,该模型在一定程度上提高了命名实体识别的效果,具有良好的适用性。本文下一步考虑将位置信息、词性信息融入到向量表示中,并优化神经网络模型,提高训练效率。其次尝试将迁移学习、对抗神经网络等技术运用到命名实体识别任务中,提高 NER 的性能。

参考文献

- [1] 翟社平,郭琳,高山,等.一种采用贝叶斯推理的知识图谱补全方法[J].小型微型计算机系统,2018,39(5):995-999.
- [2] 石春丹,秦岭.基于BGRU-CRF的中文命名实体识别方法[J].计算机科学,2019,46(9):237-242.
- [3] 郭洪杰.基于深度学习的生成式自动摘要技术研究[D].哈尔滨工业大学,2018.
- [4] 冯建周,马祥聪,刘亚坤,等.关于命名实体识别的生成式对抗网络的研究[J].小型微型计算机系统,2019,40(6):1191-1196.
- [5] LI P H, DONG R P, WANG Y S, et al. Leveraging linguistic structures for named entity recognition with bidirectional recursive neural networks [C]//Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing. 2017,10(2):2664-2669.
- [6] STRUBELL E, VERGA P, BELANGER D, et al. Fast and Accurate Entity Recognition with Iterated Dilated Convolutions [J]. arXiv: Computation and Language, 2017, 12(4):2670-2680.
- [7] SANTOS C N, GUIMARAES V. Boosting Named Entity Recognition with Neural Character Embeddings [J]. arXiv: Computation and Language, 2015,6(2):25-33.

- [8] 张海楠,伍大勇,刘悦,等.基于深度神经网络的中文命名实体识别[J].中文信息学报,2017,31(4):28-35.
- [9] 武惠,吕立,于碧辉.基于迁移学习和BiLSTM-CRF的中文命名实体识别[J].小型微型计算机系统,2019,40(6):1142-1147.
- [10] ZHANG Y, YANG J. Chinese ner using lattice lstm [J]. arXiv preprint arXiv:1805.02023, 2018.
- [11] 柏兵,侯霞,石松.基于CRF和BI-LSTM的命名实体识别方法[J].北京信息科技大学学报(自然科学版),2018(6):27-33.
- [12] CHIU J P C, NICHOLS E. Named Entity Recognition with Bidirectional LSTM-CNNs [J]. Computer Science, 2015,26(8):1-7.
- [13] 李妮,关焕梅,杨飘,等.基于BERT-IDCNN-CRF的中文命名实体识别方法[J/OL].山东大学学报(理学版):1-8[2020-01-10].
- [14] 王子牛,姜猛,高建瓴,等.基于BERT的中文命名实体识别方法[J].计算机科学,2019,46(S2):138-142.
- [15] 石春丹,秦岭.基于BGRU-CRF的中文命名实体识别方法[J].计算机科学,2019,46(9):237-242.
- [16] 冯辉.视觉注意力机制及其应用研究[D].华北电力大学(北京),2011.

(上拉第140页)

本文算法在COCO数据集上的部分检测结果,如图4所示。从图4可以看出,本文设计的基于回归和分类的关节检测算法能够有效准确确定关节点,有效的识别出小尺度的关节点;同时,当关节点密集,易出现错误关联的情况下,也取得较好的关联效果。



图4 COCO数据集检测效果图

Fig. 4 COCO dataset detection effect map

4 结束语

本文介绍了一种基于回归关节点偏移量与分类热力图的多人姿态估计算法,用以解决大多Bottom-up的关节检测识别精度低下,容易造成关

节点误判及精度受限这一问题。首先,对于人体关节检测,大多数算法采用回归关节点坐标或分类关节热力图的方式,具有一定的偏差,识别率低。本文在此基础上,同时分类预测关节点热力图和回归关节点坐标的2-D偏移向量,以精确定位关节点位置。此外,使用部件关联字段对关节点进行关联,以达到在低分辨率热力图上存储细粒度信息的能力;最后利用Hopcroft-Carp算法对进行人体姿态解析,将一个K分图匹配问题转变为二分图匹配,极大提高准确率并减少了时间复杂度。

参考文献

- [1] WEI S E, RAMAKRISHNA V, KANADE T, et al. Convolutional Pose Machines [J]. 2016:4724-4732.
- [2] GÜLER, RZA ALP, NEVEROVA N, KOKKINOS I. DensePose: Dense Human Pose Estimation In The Wild [J]. 2018.
- [3] P PAPANDEOU G, ZHU T, CHEN L C, et al. Personlab: Person pose estimation and instance segmentation with a bottom-up, part-based, geometric embedding model [C]//Proceedings of the European Conference on Computer Vision (ECCV). 2018:269-286.
- [4] WEST D B. Introduction to graph theory [M]. Upper Saddle River, NJ: Prentice hall, 1996.
- [5] CAO Z, SIMON T, WEI S E, et al. Realtime multi-person 2d pose estimation using part affinity fields [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2017:7291-7299.