

文章编号: 2095-2163(2023)04-0008-06

中图分类号: TP391.1

文献标志码: A

基于 XLNet 的医学文本实体关系识别模型

郑增亮, 沈宙锋, 苏前敏

(上海工程技术大学 电子电气工程学院, 上海 201620)

摘要: 目前在处理医学文本实体间关系提取任务中,使用传统的词向量表示方法无法解决医学文本中的词多义性问题,加上基于长短时记忆网络对文本语义局部特征抽取不够充分,不能充分捕捉医疗文本隐藏的内部关联信息。因此,提出一种基于 XLNet-BiGRU-Attention-TextCNN 的医疗文本实体关系抽取模型。利用 XLNet 模型将输入的医疗文本转化为向量形式,接着连接双向门控循环神经网络(BiGRU)提取文本语句的长距离依赖关系,然后使用注意力机制(Attention)为特征序列分配权重,降低噪声影响,最后利用文本卷积神经网络(TextCNN)对序列进行局部特征提取并通过 softmax 层输出关系抽取结果。实验结果表明,本文所提模型在精确率、召回率和 F 值上均优于基准模型。

关键词: 医疗文本; 医疗实体关系抽取; XLNet; 双向门控循环单元; 注意力机制; TextCNN

Medical text entity relationship recognition model based on XLNet

ZHENG Zengliang, SHEN Zhoufeng, SU Qianmin

(School of Electronic and Electrical Engineering, Shanghai University of Engineering Science, Shanghai 201620, China)

[Abstract] At present, in the task of extracting the entity relationship of medical texts, the traditional word vector representation method cannot solve the problem of polysemous words in medical texts. In addition, the extraction of semantic local features of texts based on long and short-term memory networks is not sufficient, which could not capture the internal related information hidden in medical texts. To address the problem, a medical text entity relationship extraction model based on XLNet-BiGRU-Attention-TextCNN is proposed. Use the pre-trained language model XLNet to convert the input medical text into vectors, and connect the bidirectional gated recurrent neural network (BiGRU) to extract the long-distance dependence of the text sentence, then use the attention mechanism (Attention) to assign weights to the feature sequence, thereafter reduce the impact of noise, finally use the Text Convolutional Neural Network (TextCNN) to extract local features of the sequence and output the relationship extraction results through the softmax layer. Experimental results show that the model proposed in this paper is better than the benchmark model in terms of accuracy, recall and F value.

[Key words] medical text; medical entity relationship extraction; XLNet; two-way gated recurrent unit; attention mechanism; TextCNN

0 引言

电子病历(Electronic Medical Records, EMR)是患者在医院就诊的记录,主要包含文本、图表以及影像等多种信息^[1]。随着 EMR 的渐趋普及,人们对其了解得更加详细。总地来说,EMR 不仅包含了患者的检查结果、临床用药治疗、不良反应等信息,还涵盖了许多的医疗相关实体^[2]。如何将一个非结构化的临床 EHR 转化为结构化的数据,挖掘其中有价值的诊疗信息,已然成为当前自然语言处理

(NLP)任务的研究热点之一。关系抽取任务是在消息理解会议(MUC)^[3]上首次提出的,自2010年以来,国外对于电子病历相关实体关系抽取研究已经取得许多成果。国内 EMR 相关的研究发展起步时间较晚,公开的数据集和研究结果为数不多,已有的关系抽取模型主要依赖机器学习有关算法,这类方法大多依赖大量的特征工程建设,费时费力。近年来在关系提取任务中,基于神经网络方法取得了良好的效果,但是常见的关系抽取并不能解决文本语句中一词多义的现象,同时也没有充分捕捉到电子

基金项目:“十三五”国家科技重大专项(2018ZX09711001-009-011);科技创新2030-“新一代人工智能”重大项目(2020AAA0109300)。

作者简介:郑增亮(1996-),男,硕士研究生,主要研究方向:知识图谱、大数据。

通讯作者:苏前敏 Email:suqm@sues.edu.cn

收稿日期:2022-05-27

病历中实体关系之间的特征信息,使得分类效果欠佳。

本文提出一种基于 XLNet-BiGRU-Attention-TextCNN 的医疗文本实体关系抽取方法。该方法首先使用 XLNet 预训练语言模型将输入文本语句转换为向量表示,然后将向量化的文本特征序列输入至一个双向门控循环单元 (GRU) 进行长距离依赖关系特征提取,接着使用注意力机制 (Attention) 为特征序列分配权重,降低噪声影响,为了提高 Softmax 分类器的识别效果,最后利用卷积神经网络提取文本语句的局部特征。

1 相关研究

目前,实体关系抽取模型的训练、验证使用的数据集主要来源于开放数据源,例如新闻、微博、百科等^[4]。实体关系提取的早期方法主要是监督式学习,如 CHEN 等学者^[5]在关系抽取任务中,通过对原始数据集进行统计和特征提取的方法取得了较高的 F_1 值 (正确率 * 召回率 * 2 / (正确率 + 召回率))。ZHANG^[6]在关系抽取任务中引入支持向量机的方法来提高抽取的效果。这些方法大都需要手工构建大量特征,不仅费时费力,而且泛化性能也不强。

随着神经网络的快速发展,神经网络模型已逐渐应用到实体关系抽取任务中。Richard 等学者^[7]使用循环神经网络 (RNN) 获取文本序列信息,进行实体关系抽取,虽改进了模型抽取效果,但没有考虑到实体在训练语句中的语义和位置信息。Zeng 等学者^[8]采用词向量和词位置向量相结合方法获取模型输入向量,通过卷积神经网络层与层之间运算得到句子特征表示,充分利用句子中的实体信息,从而提升关系抽取的准确率。Huang 等学者^[9]采用两阶段方法,在长短时记忆 (LSTM) 网络模型中引入支持向量机 (SVM) 模型,以此抽取药物间的关系。

2 基于 XLNet-BiGRU-Attention-TextCNN 的关系抽取模型

关系抽取模型框架主要由 3 个部分组成,分别是:词表示层、编码层、输出层。其中,词表示层包含文本语句的输入,序列化表示模块;编码层包含 BiGRU 模块、Attention 模块和 TextCNN 模块;输出层使用 Softmax 模型,模型结构如图 1 所示。将句子输入到模型中,首先通过词嵌入层构建向量矩阵,将每个词映射成低维向量,随后将句子矩阵送入 BiGRU,进一步提取字向量中上下文特征,接下来将

处理后的矩阵通过自注意力层对重要信息进行加权,计算出权重系数,然后使用 TextCNN 模型提取句子的局部特征,最后由 Softmax 模型确定关系类型,完成关系抽取。

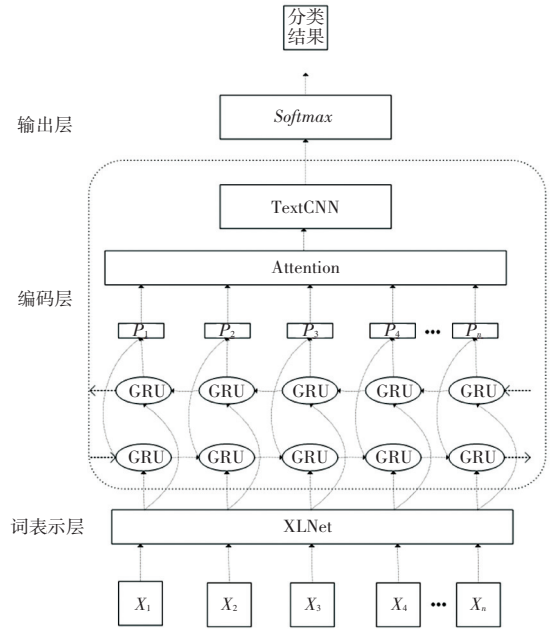


图 1 XLNet-BiGRU-Attention-TextCNN 模型结构

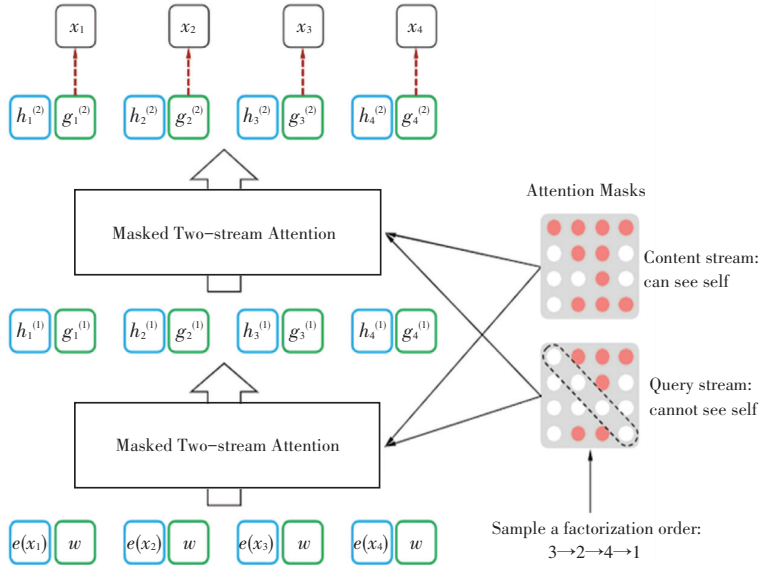
Fig. 1 XLNet-BiGRU-Attention-TextCNN model structure

2.1 词表示层

该模型的词表示层使用 XLNet 预训练语言模型对输入语句进行向量表示。针对 Bert 模型^[10]微调和预训练过程不一致的缺陷,Brain 提出了一种新的广义自回归模型 XLNet^[11]。XLNet 利用排列语言模型 (PLM) 随机排列句子,使用自回归的方式预测句子末尾的单词,通过这种方式,可获取到单词间相互依赖的关系,而且可以充分利用单词或者字符的前后文信息^[12]。与 Bert 相比,XLNet 没有采取在输入端隐藏掉部分单词的模式,而是通过注意力机制^[13]在 Transformer 内部遮掩部分单词。XLNet 的原理如图 2 所示,XLNet 的输入包括词向量和位置信息,图 2 中最下面的 $e(x)$ 就是词向量, w 就是位置信息。经输入层输入后,XLNet 会将句子重新排列,根据排列后顺序使用自回归方式进行预测。

2.2 双向门控循环单元

门控循环单元 (GRU) 使用门控机制来控制输入、记忆和其他信息,并在当前时间步长内进行预测^[14]。GRU 可以视为 LSTM 的变体,与 LSTM 相比,GRU 具有参数少、训练时间短的优点。GRU 门函数保留了重要的特性,可以捕捉时态数据中的长依赖关系。图 3 说明了 GRU 的内部控制结构。GRU

图2 XLNet 原理^[11]Fig. 2 XLNet principle^[11]

内部结构中只有 2 个门单元:更新门和重置门。GRU 结构中的参数具体如下。

(1)重置门: r_t 计算公式见如下:

$$r_t = \sigma(\mathbf{W}_r \cdot [h_{t-1}, x_t]) \quad (1)$$

(2)更新门: z_t 计算公式见如下:

$$z_t = \sigma(\mathbf{W}_z \cdot [h_{t-1}, x_t]) \quad (2)$$

(3)隐藏层:状态更新计算公式见如下:

$$\tilde{h}_t = \tanh(\mathbf{W} \cdot [r_t * h_{t-1}, x_t]) \quad (3)$$

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t \quad (4)$$

其中, σ 表示 sigmoid 激活; \mathbf{W} 为权值矩阵; x_t 表示 t 时刻的输入; h_{t-1} 表示 t 时刻的隐藏状态。本文采用 BiGRU 结构,充分利用时间语境。BiGRU 使用前向和后向计算,每个时间序列数据获得 2 个不同的隐藏层状态。隐藏层的最终输出是两者的连接隐藏状态^[15]。

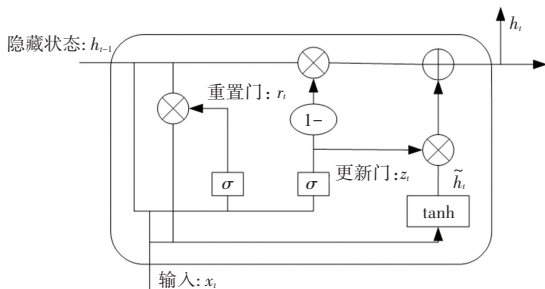


图3 GRU 模型结构图

Fig. 3 Structure diagram of GRU model

2.3 注意力机制

针对 BiGRU 的输出 h_t 学习相应的注意力权重

α , 然后对权重归一化,将得到的向量 α 作为注意力权重概率分布,最后将 α 与输出进行点积相加,从而得到经过注意力运算的特征向量^[16]。

2.4 TextCNN

卷积层意在捕获局部语义信息,并将这些有价值的语义成分压缩为特征图^[17]。当卷积层输入特征矩阵后,卷积运算中需用到的公式为:

$$y_j = f(\mathbf{W}_j^{d * k} * \mathbf{X}_j + b) \quad (5)$$

其中, $b \in R$ 表示偏置; f 表示非线性激活函数; \mathbf{X}_j 为落入滑动窗口的第 j 个特征矩阵; 池化是选择从每个卷积核中提取的特征^[18]。这里,最大池(max pooling)用来获得每个特征的最大值,该方式往往漏掉了其他关键信息。另一种是平均池,即求出特征向量的平均值,能够表示整个文本的语义信息。为了在句子中获取更多的语义信息,以提高关系识别的准确性,故将 2 种池化后的特征进行拼接作为此层输出,可由式(6)~式(8)进行描述:

$$m_{j_{ave}} = ave(y_j) \quad (6)$$

$$m_{j_{max}} = \max(y_j) \quad (7)$$

$$m_j = m_{j_{ave}} \oplus m_{j_{max}} \quad (8)$$

其中, y_j 为每个卷积核卷积出的特征向量, m_j 为池化后的输出。最后通过 Softmax 层输出。

3 实验结果与分析

3.1 数据集

中文 EMR 关系抽取数据集的构建不仅要求对原始数据进行预处理,同时要求标注人员需要具备一定的医学知识。EMR 的诊疗信息中的实体关系

主要存在于疾病、症状、检查等之间,故在本研究中,以 I2B2 (informatics forintegrating biology and the bedside)的医学实体间关系标注规范作为参考标准^[19],在专业医务人员的指导下,制定了本实验的中文 EMR 关系标注类型,见表 1。由表 1 可知,共包含 7 种医疗关系。

表 1 关系类型及描述
Tab. 1 Relationship type and description

关系名称	关系标注
因为症状而采取了检查	Te AS
检查证实了某种疾病	Te RD
为了证实疾病而采取检查	Te CD
检查发现了某种症状	Te RS
治疗方式施加于某种疾病	Tr AD
治疗方式施加于某种症状	Tr AS
疾病导致了某种症状	DCS

本实验的原始数据来自于上海市某二级甲等医院,包括内分泌科、呼吸内科、消化内科等不同科室的 EMR,共 1 500 份。为了保护患者的隐私,对 EMR 文本进行去隐预处理,接着根据事先制定好的标注规则对文本数据进行标注。最后,将标注好的数据集按照 7:2:1 的方式进行划分,其中 1 050 份 EMR 作为训练数据集,300 份 EMR 作为验证数据集,150 份 EMR 作为测试数据集。

3.2 评价指标

实体识别和关系抽取实验通常采用如下指标来评价模型的优劣,分述如下。

(1) 准确率。可由如下公式计算求得:

$$P = \frac{T_p}{T_p + F_p} \times 100\% \quad (9)$$

(2) 召回率。可由如下公式计算求得:

$$R = \frac{T_p}{T_p + F_n} \times 100\% \quad (10)$$

(3) F_1 值。可由如下公式计算求得:

$$F_1 = \frac{2 \times P \times R}{P + R} \times 100\% \quad (11)$$

其中, T_p 表示测试集中正例被正确预测为正例的个数; F_p 表示测试集中正例被误分类为负例的个数; F_n 表示测试集中负例被误分类为正例的个数。

3.3 实验设置

本实验主要分为参数优化实验和不同模型对比实验。参数优化实验主要是验证使用标签平滑交叉熵损失函数 (Label Smoothing Cross Entropy, LSCE) 是否可以提高识别效果。与不同模型的对比实验可

以验证基于 XLNet 模型在实体间关系提取的有效性。本实验均在 Ubuntu 环境中搭建和运行,基于 Python 和 TensorFlow 搭建模型,并使用 GPU 进行深度学习的计算,选用的计算机显卡配置为 NVIDIA RTX 2060,显存为 8 GB。实验中主要的超参数配置包括:XLNet 预训练语言模型选取 XLNet_base 版本,在编码层运行后,再输入到此后的网络结构中进行学习训练。LSTM 的大小设置为 64 维,网络层宽为 64 维,网络学习率为 $2e-5$, Dropout 的比例设置为 0.1,每一批量的样本数量为 32,卷积核的尺寸分别是设置为 5×5 、 9×9 、 13×13 ,卷积核个数设置为 256,隐藏层的维度固定为 768,使用 relu 激活函数,为了使模型收敛速度加快选用 Adam 算法优化器。

3.4 实验结果

(1) 参数优化实验。为验证 LSCE 是否可以提高关系抽取效果,本实验设置 Cross Entropy Loss 和 Focal Loss 函数作为对比。表 2 是 XLNet-BiGRU-Attention-TextCNN 与不同损失函数在糖尿病数据集上达到的实验效果。

表 2 不同损失函数实验结果

损失函数类型	P	R	F_1
Cross Entropy Loss	73.37	76.50	74.90
Focal Loss	72.83	75.42	74.10
Label Smoothing Cross Entropy	75.61	78.54	77.05

(2) 不同模型对比试验。为验证本研究提出的模型在中文糖尿病数据集的效果,本研究选择如下几种方法进行比较:

① CNN 模型^[20]:CNN 用于关系提取,卷积深度神经网络 (CDNN) 用于提取词和句子的特征,并将所有的词标记都用作输入。

② BiLSTM-TextCNN 模型:该模型采用双向 LSTM 网络模型提取语义依赖信息,并利用 TextCNN 网络提取局部特征,解决了传统关系抽取任务中复杂特征构建问题,在这项任务中取得了较好的效果。

③ BiGRU-TextCNN 模型:采用双向 GRU 网络模型获取文本前后向语义信息,然后连接 TextCNN 进行特征提取,利用更新门和重置门机制过滤噪声影响,提高模型识别效果。

④ BiGRU-Attention-TextCNN 模型:在局部特征提取前加入 Attention 机制,与 BiGRU-TextCNN 模型进行对比。

研究中得到的不同模型的实验结果见表 3。

表3 不同模型实验结果

Tab. 3 Experimental results of different models %

Model	Precision	Recall	F_1
CNN	64.22	61.21	62.68
BiLSTM-TextCNN	68.47	66.65	67.55
BiGRU-TextCNN	68.79	66.90	67.83
BiGRU-Attention-TextCNN	72.08	71.84	71.96
XLNet-BiGRU-Attention-TextCNN	75.61	78.54	77.05

4 讨论

从表2可以看出,当采用标签平滑交叉熵函数作为XLNet-BiGRU-Attention-TextCNN模型训练的损失函数时,关系抽取的效果最优,其 F_1 值较Cross Entropy函数和Focal Loss函数分别提高了2.14%和2.94%。由于EMR数据集中关系类型数量分布不均匀,最多为647,最少为115,对模型的关系预测带来一定程度上的干扰。通过使用标签平滑交叉熵函数,缓解了医学文本中关系类型的数量不平衡问题,一定程度上提升了模型的性能。

通过表3的实验研究结果可以看出,XLNet-BiGRU-Attention-TextCNN模型与其他模型相比,总体上看,其精确率、召回率和 F_1 值三方面均有提高:

第一,与传统CNN模型对比,BiLSTM-TextCNN模型和BiGRU-TextCNN模型在准确率分别提高了4.25%和4.57%,召回率分别提高了5.44%和5.69%, F_1 值分别提高了4.87%和5.15%。说明了CNN网络的语义提取范围有限,在处理较长语句的关系识别时效果较差,利用含有门控机制的前后向长短时记忆网络和前后向门控循环网络可以更好地提取文本语句的长期依赖关系,并与TextCNN网络结合可以更加充分地表示文本的语义信息。

第二,对比BiGRU-Attention-TextCNN模型和BiGRU-TextCNN模型,引入Attention机制后关系抽取的精确率提高了3.29%,召回率提高了4.94%, F_1 值提高了4.13%,说明了Attention机制可以聚焦文本序列的关键信息,并为这些关键信息设置较大权重,降低噪声的干扰,通过动态调整权重矩阵,学习到关系抽取在长序列文本中隐藏的关键信息,提升模型识别抽取能力。

第三,对比XLNet-BiGRU-Attention-TextCNN模型和BiGRU-Attention-TextCNN模型,采用预训练语言模型将精确率提高了3.53%,召回率提高了6.70%, F_1 值提高了5.09%,说明了采用双向自回归训练的语言模型XLNet可以对文本上下文的语义

信息进行更全面的表示,提高模型的关系抽取效果。

5 结束语

针对现有的实体关系抽取模型无法解决多义现象和文本语义信息捕获不足的问题,本文提出基于XLNet-BiGRU-Attention-TextCNN的实体关系抽取方法。利用预训练语言模型XLNet对句子进行向量化表示,然后输入BiGRU层充分表示捕捉字的上下文信息,通过注意机制提高在关系分类中起决定性作用的字符权重,最后加入TextCNN提取局部特征,获得更细粒度的特征序列,有效解决一词多义的问题,提升了该模型在关系抽取任务中性能。

参考文献

- [1] 卫生部. 电子病历基本规范(试行)[J]. 中国药房, 2010, 21(12):1063-1064.
- [2] 沈伟. 电子病历给医疗行为带来的变革[J]. 医学信息杂志, 2007,28(04):346-347.
- [3] GRISHMAN R, SUNDHEIM B. Message understanding conference-6: a brief history [C]//Proceedings of the 16th Conference on Computational Linguistics. New York, USA: ACM Press, 1996: 466-471.
- [4] SARAWAGI S. Information extraction [J]. Foundations and Trends in Databases, 2008, 1(3): 261-377.
- [5] CHEN H H, DING Y W, TSAI S C, et al. Description of the NTU system used for MET-2 [C]//Proceedings of the 7th Message Understanding Conference. San Diego, USA: Internet Society, 1998: 1-9.
- [6] ZHANG Zhu. Weakly-supervised relation classification for information extraction [C]//Proceedings of the 13th ACM Conference on Information and Knowledge Management. New York, USA: ACM Press, 2004: 581-588.
- [7] RICHARD S, BRODY H, CHRISTOPHER D, et al. Semantic compositionality through recursive matrix-vector space [C]//Proceedings of the 2012 Joint Conference on Empirical Methods in Natural Language Processing and Computational Natural Language Learning. New York, USA: ACM Press, 2012: 1201-1211.
- [8] ZENG Daojian, LIU Kang, LAI Siwei, et al. Relation classification via convolutional deep neural network [C]//Proceedings of the 25th International Conference on Computational Linguistics. Dublin, Ireland: [s.n.], 2014: 2335-2344.
- [9] HUANG Degen, JIANG Zhenchao, ZOU Li, et al. Drugdrug interaction extraction from biomedical literature using support vector machine and long short term memory networks [J]. Information Sciences, 2017(415/416): 100-109.
- [10] DEVLIN J, CHANG M W, LEE K, et al. BERT: Pre-training of deep bidirectional transformers for language understanding [J]. arXiv preprint arXiv:1810.04805, 2019.
- [11] 李舟军, 范宇, 吴贤杰. 面向自然语言处理的预训练技术研究综述[J]. 计算机科学, 2020, 47(03): 162-173.
- [12] YANG Zhilin, DAI Zihang, YANG Yiming, et al. XLNet: Generalized autoregressive pretraining for language understanding [C]//Advances in Neural Information Processing Systems.

- Vancouver, Canada: NIPS Foundation, 2019, 32:5753–5763.
- [13] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C]//Advances in Neural Information Processing Systems. Long Beach: NIPS Foundation, 2017: 5998–6008.
- [14] 张志昌, 周侗, 张瑞芳, 等. 融合双向 GRU 与注意力机制的医疗实体关系识别[J]. 计算机工程, 2020, 46(06): 296–302.
- [15] ZHENG Jin, ZHENG Limin. A hybrid bidirectional recurrent convolutional neural network attention-based model for text classification[J]. IEEE Access, 2019, 7: 106673–106685.
- [16] 何玉洁, 杜方, 史英杰, 等. 基于深度学习的命名实体识别研究综述[J]. 计算机工程与应用, 2021, 57(11): 21–36.
- [17] 王庆棒, 汪颖懿, 左敏, 等. 基于 CNN-BLSTM 的食品舆情实体关系抽取模型研究[J]. 食品科学技术学报, 2021, 39(02): 152–158.
- [18] DENG L N, XUE C Q, LIN X Q, et al. Application progress of imaging in COVID-19[J]. Chinese Journal of Medical Physics, 2020, 37(6): 727–729.
- [19] KALCHBRENNER N, GREFFENSTETTE E, BLUNSON P. A convolutional neural network for modelling sentences[C]//Annual meeting of the Association for Computational Linguistics. Baltimore, MA: ACL, 2014: 655–665.
- [20] ZLEM U, SOUTH B R, SHEN S, et al. 2010 i2b2/VA challenge on concepts, assertions, and relations in clinical text[J]. Journal of the American Medical Informatics Association, 2011(5): 552.
- [21] ZHENG Suncong, XU Jiaming, BAO Hongyun, et al. Joint learning of entity semantics and relation pattern for relation extraction [C]// Proc. of the Joint European Conference on Machine Learning and Knowledge Discovery in Databases. Cham: Springer-Verlag, 2016: 443–458.

(上接第7页)

服务提供商的效用。然后,通过证明效用函数的超模性,论证该博弈定价纳什均衡的存在性。最后,设计一种梯度迭代更新算法,求解超模博弈的纳什均衡找到最优边缘服务定价。结果表明所提算法在收敛速度和提升边缘服务提供商收益的有效性。在未来工作中,将考虑更复杂、更繁琐的边缘服务交易场景,探索更多针对不同类型边缘服务的定价方法。

参考文献

- [1] ABBAS N, ZHANG Yan, TAHERKORDI A, et al. Mobile edge computing: A survey[J]. IEEE Internet of Things Journal, 2018, 5(1): 450–465.
- [2] LI Q, MA X, ZHOU A, et al. User-oriented edge node grouping in mobile edge computing [EB/OL]. [2022-04-12]. <https://ieeexplore.ieee.org/document/9667295>.
- [3] ZHANG Xiaojie, DEBROY S. Energy efficient task offloading for compute-intensive mobile edge applications[C]//ICC 2020-2020 IEEE International Conference on Communications (ICC). Dublin, Ireland: IEEE, 2020: 1–6.
- [4] 程鹏, 张文柱, 谢书翰, 等. 车联网边缘计算的多目标均衡任务卸载方法研究[J]. 小型微型计算机系统, 2022, 43(09): 1992–1998.
- [5] 屠友鹏, 陈海明, 严林杰. 物联网系统中边缘计算卸载决策问题: 建模、求解与分类[J]. 小型微型计算机系统, 2021, 42(10): 2145–2152.
- [6] WANG Tian, LU Yucheng, WANG Jianhua, et al. EIHPD: Edge-intelligent hierarchical dynamic pricing based on cloud-edge-client collaboration for IoT systems[J]. IEEE Transactions on Computers, 2021, 70(8): 1285–1298.
- [7] HAN Di, CHEN Wei, FANG Yuguang. A dynamic pricing strategy for vehicle assisted mobile edge computing systems[J]. IEEE Wireless Communications Letters, 2018, 8(2): 420–423.
- [8] HOANG D T, NIYATO D, NGUYEN D N, et al. A dynamic edge caching framework for mobile 5G networks [J]. IEEE Wireless Communications Letters, 2018, 25(5): 95–103.
- [9] LIAO Yangzhe, QIAO Xinhui, YU Quan, et al. Intelligent dynamic service pricing strategy for multi-user vehicle-aided MEC networks[J]. Future Generation Computer Systems, 2021, 114: 15–22.
- [10] YASSINE A, HOSSAIN M S. COVID-19 Networking Demand: An Auction-Based Mechanism for Automated Selection of Edge Computing Services[J]. IEEE Transactions on Network Science and Engineering, 2022, 9(1): 308–318.
- [11] 陶小旂, 陈胜, 齐恒, 等. 边缘计算环境中的网络服务拍卖方法研究[J]. 计算机工程, 2019, 45(08): 60–65.
- [12] YASSINE A, HOSSAIN M S, MUHAMMAD G, et al. Cloudlet based intelligent auctioning agents for truthful autonomous electric vehicles energy crowdsourcing [J]. IEEE Transactions on Vehicular Technology, 2020, 69(5): 5457–5466.
- [13] MA Kai, WANG Congshan, YANG Jie, et al. Pricing mechanism with noncooperative game and revenue sharing contract in electricity market[J]. IEEE Transactions on Cybernetics, 2019, 49(1): 97–106.
- [14] PAN X Y, MA J Z, WU C X. Product pricing considering the consumer preference based on Internet of Things [J]. Cluster Computing, 2019, 22: 15379–15385.
- [15] HAGHIGHATDOOST V, KHORSANDI S, AHMADI H. Fair pricing in heterogeneous Internet of Things wireless access networks using crowdsourcing [J]. IEEE Internet of Things Journal, 2021, 8(7): 5710–5721.
- [16] HUANG Mingfeng, LIU Wei, WANG Tian, et al. A game-based economic model for price decision making in cyber-physical-social systems[J]. IEEE Access, 2019, 7: 111559–111576.
- [17] ALSHEIKH M A, HOANG D T, NIYATO D, et al. Optimal pricing of Internet of Things: A machine learning approach[J]. IEEE Journal on Selected Areas in Communications, 2020, 38(4): 669–684.
- [18] LIU Kang, QIU Xiaoyu, CHEN Wuhui, et al. Optimal pricing mechanism for data market in blockchain-enhanced Internet of Things[J]. IEEE Internet of Things Journal, 2019, 6(6): 9748–9761.
- [19] 刘桂东. 超模博弈 Nash 均衡的稳定性[J]. 武汉科技学院学报, 2007, 20(01): 55–57.
- [20] 侯琳琳, 邱莞华. 基于超模博弈的多零售商价格竞争的均衡分析[J]. 计算机集成制造系统, 2008, 14(02): 379–385.
- [21] 郝子霖. 基于竞争对手定价的应对策略研究[J]. 上海管理科学, 2021, 43(06): 18–23.