DOI:10.20033/j.1003-7241.(2026)07-0144-05

一种多源融合的英语翻译词汇语义自动标注算法

王彦易

(上海城建职业学院国际交流处, 上海 201415)

摘　要:针对现有循环神经网络(recurrent neural networks,RNN)在长序列学习任务中容易遇到梯度消失或爆炸,且对长文本处理能力存在局限的问题,本文提出一种基于多源信息融合的自动标注算法。该算法构建了多目标语义映射器(multi-objective semantic mapper,MOSM)模型,在传统RNN基础上融合了Transformer结构与自注意力机制(Self-Attention),以增强模型对长距离依赖文本的特征捕捉能力。同时,引入贝叶斯理论处理多源数据融合,并利用多目标优化算法调整模型参数,以实现各项标注指标的最佳平衡。为验证所提方法的有效性,研究采用Chinese-English Text和UN translation text双语数据集进行对比实验,从吞吐量、准确度、召回率、F_1分数、系统资源消耗及可用性等多个维度,将MOSM模型与传统的BERT、GAN模型进行综合评估与测试。实验结果表明,本文提出的MOSM模型吞吐量达到1.32word/s,准确度高达93.5%,召回率为92.1%,F_1分数为92.8%;系统仅消耗15%的CPU和300 MB内存,可用性维持在99.95%。各项性能指标均显著优于传统模型,该模型在提升翻译文本隐形词汇语义标注的准确性、效率及资源利用率方面展现出明显优势。

关键词:隐形词汇标注;自动算法;多源信息融合;性能评估;MOSM;Transformer

中图分类号:TP391.2;TP183　　**文献标志码**:A　　**文章编号**:1003-7241(2026)07-0144-05

An automatic semantic annotation algorithm for English translation vocabulary based on multi-source fusion

Wang Yanyi

(International Cooperation Division, Shanghai Urban Construction Vocational College, Shanghai 201415, China)

Abstract: In response to the problems that existing recurrent neural network(RNN) encounter in long sequence learning tasks, such as the issue of gradient vanishing or explosion, and their limitations in processing long texts, this paper proposes an automatic annotation algorithm based on multi-source information fusion. This algorithm constructs a multi-objective semantic mapper (MOSM) model, which integrates the Transformer structure and self-attention mechanism on the basis of the traditional RNN to enhance the model's ability to capture features of long-distance dependent texts. At the same time, Bayesian theory is introduced to handle the fusion of multi-source data, and the multi-objective optimization algorithm is used to adjust the model parameters to achieve the best balance of various annotation indicators. To verify the effectiveness of the proposed method, the study conducts a comparative experiment using the Chinese-English Text and UN translation text bilingual datasets. The MOSM model is comprehensively evaluated and tested against traditional BERT and GAN models from multiple dimensions such as throughput, accuracy, recall rate, F_1 score, system resource consumption, and availability. The experimental results show that the MOSM model achieves a throughput of 1.32 texts per second, an accuracy of 93.5%, a recall rate of 92.1%, and an F_1 score of 92.8%; the system consumes only 15% of CPU and 300MB of memory, and the availability remains at 99.95%. All performance indicators are significantly superior to traditional models, and this model demonstrates clear advantages in improving the accuracy, efficiency, and resource utilization of the semantic annotation of hidden words in translated texts.

Keywords: invisible vocabulary annotation; automatic algorithms; multi-source information fusion; performance evaluation; MOSM; Transformer

随着全球化的不断深入,跨语言交流的需求日益增长,英语作为国际通用语言,在这一过程中扮演着至关重要的角色[1]。翻译工作的准确性和自然性直接影响到信息传递的质量和效率[2]。然而,在英语翻译实践中,隐形词汇的语义自动标注一直是一个挑战。隐形词汇,即那些在文本中可能被忽略但对整体语义理解至关重要的词汇,其准确翻译对于保持原文意义的完整性至关重要[3]。毛达展等[4]使用自训练方法提高无标注数据的利用效率,弥补对抗学习方法的不足。Di等[5]使用语义注释工具,该工具利用领域本体和逻辑规则来消除工作流中的概念歧义,并执行推理引擎以强制执行规则。随着自然语言处理技术的发展,机器翻译在一定程度上缓解了这一问题,但

收稿日期:2025-06-07;**录用日期**:2025-07-10

基金项目:上海市科技创新行动计划国内科技合作项目(22015802400)

作者简介:王彦易(1989—),女,硕士,讲师,研究方向为英语教学研究、自动模型设计等。

引用本文:王彦易. 一种多源融合的英语翻译词汇语义自动标注算法[J]. 自动化技术与应用, 2026,45(7):144-148. (Wang Yanyi. An automatic semantic annotation algorithm for English translation vocabulary based on multi-source fusion[J]. Techniques of Automation and Applications, 2026,45(7):144-148.)

其自动化程度和翻译质量仍有待提高[6]。特别是在处理隐形词汇时,传统方法往往无法准确捕捉其深层语义,导致翻译结果出现偏差[7-8]。因此,研究提出一种融合多源信息的英语翻译文本隐形词汇语义自动标注算法,通过构建 MOSM 模型,整合 Transformer 结构和自注意力机制,显著提升了对长文本的处理能力。研究的创新之处在于,它不仅提升了翻译的自动化水平,更通过先进的算法增强了翻译的语义准确性和自然性,为机器翻译领域带来了新的视角和解决方案。

1 多源融合与标注模型构建

1.1 多源信息融合框架

英语翻译文本隐形词汇语义自动标注是一种先进的技术,它通过计算机算法帮助翻译者识别并标注翻译过程中可能被忽视的词汇的深层语义。在这一领域,RNN 能够处理序列数据,通过分析文本中的词法、句法和语义信息,学习并识别翻译中的模式和规律。RNN 在训练过程中不断优化,能够自动地从大量文本数据中学习语言的内在结构,进而在翻译过程中自动识别和标注关键词汇的语义,无须依赖预先设定的规则[9-10]。这种自动化的语义标注方法,使翻译者可以更加专注于文本的文化内涵和表达的细微差别,从而提升翻译的整体质量。循环神经网络的展开结构如图 1 所示。

图 1 所示为循环神经网络的展开结构。在图 1 中,$\boldsymbol{x}_t$ 表示 t 时刻时间步长的输入,$t=[1,2,\cdots m]$。$\boldsymbol{h}_t$ 表示 t 时刻时间步长输出的隐含状态。循环神经网络的标准表达式如式(1)和式(2)所示。

$$\boldsymbol{h}_t=\varphi_{\mathrm{h}}(W_{\mathrm{h}}\boldsymbol{x}_t+U_{\mathrm{h}}\boldsymbol{h}_{t-1}+b_{\mathrm{h}}) \tag{1}$$

式(1)为 t 时刻时间步长输出隐含状态的表达式。W_{h}、U_{h}、b_{h} 分别表示输出隐含状态的相关参数。φ_{h} 则表示输出隐含状态的非线性激活函数。$\boldsymbol{x}_t$ 表示 t 时刻时间步长输入的序列特征向量,而 $\boldsymbol{h}_{t-1}$ 表示上一时刻传递下来的隐含状态向量。

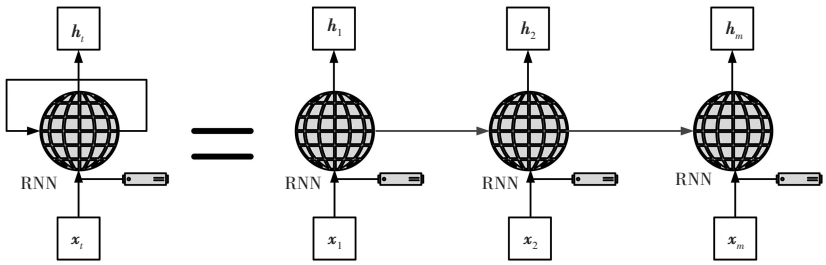


图 1 循环神经网络扩展结构

Fig. 1 Expanded structure of recurrent neural networks

$$\boldsymbol{y}_t=\varphi_{\mathrm{y}}(W_{\mathrm{y}}\boldsymbol{h}_t+b_{\mathrm{y}}) \tag{2}$$

式(2)为 t 时刻网络输出的计算公式。$\boldsymbol{y}_t$ 表示 t 时刻网络的输出。W_{y} 和 b_{y} 分别网络输出状态的相关参数。φ_{y} 表示网络输出的非线性激活函数。原始的 RNN 在进行参数更新时可能会遇到梯度消失或梯度爆炸的问题,这些问题限制了其在长序列学习任务中的性能。

1.2 Transformer 增强的语义标注模型

为了解决这一问题,研究在 RNN 的基础上引入了 Transformer 结构,以改进英语翻译文本隐形词汇语义自动标注模型[11]。自动标注模型如图 2 所示。

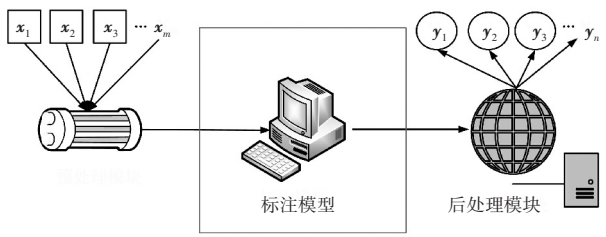


图 2 自动标注器

Fig. 2 Automatic annotator

图 2 所示为常见的自动标注器模型。整个模型由三部分组成,分别为预处理模块、标注模型、后处理模块。注意力模型是一种神经网络模型,它不仅能够识别和捕捉翻译文本中的重要语义信息,同时在识别过程中还能有效避免其他无关信息的干扰[12-13]。在自然语言处理领域,注意力模型被广泛应用于各种任务,如机器翻译、文本摘要、问答系统等。在英语翻译文本隐形词汇语义自动标注中,注意力模型能够帮助模型集中关注文本中的关键词汇及其上下文,识别出那些可能被忽视但对整体语义理解至关重要的词汇。因此,整个模型在标注模型的基础上,额外添加了一个注意力机制模块,用于增加模型处理文本信息的能力。编码-解码的计算流程如式(3)和式(4)所示。

$$e_1,e_2,\cdots,e_m=\mathrm{encoder}(\boldsymbol{x}_1,\boldsymbol{x}_2,\cdots,\boldsymbol{x}_m) \tag{3}$$

式中,$e_1,e_2,\cdots,e_m$ 表示一串输入的文本序列,$\mathrm{encoder}(\boldsymbol{x}_1,\boldsymbol{x}_2,\cdots,\boldsymbol{x}_m)$ 表示编码器进行编码。

$$\boldsymbol{Y}_t=\mathrm{decoder}(e_1,e_2,\cdots,e_m,\boldsymbol{y}_1,\boldsymbol{y}_2,\cdots,\boldsymbol{y}_{t-1}) \tag{4}$$

式中,$\boldsymbol{Y}_t$ 表示解码数据的概率分布向量,通过 Softmax 函数进行计算得到。$\mathrm{decoder}(e_1,e_2,\cdots,e_m,\boldsymbol{y}_1,\boldsymbol{y}_2,\cdots,\boldsymbol{y}_{t-1})$ 表示对概率分布向量进行解码操作。多源融合技术在英语翻译文本隐形词汇语义自动标注中通过整合不同来源的语言数据,以提升标注的准确性。该技术包含源数据预处理、特征提取和数据融合识别三个基本步骤。在特征级融合中,不同数据源的语义特征被合并,以增强标注的可靠性。为解决数据源间可能的冲突,采用贝叶斯方法进行融合,利用概率模型优化标注结果。贝叶斯定理公式如式

(5)所示。

$$P(B\mid A)=\frac{P(A\mid B)P(B)}{P(A)} \tag{5}$$

式中,$P(B\mid A)$ 代表事件 B 在 A 事件发生前提下的发生概率;$P(\cdot)$ 代表事件发生概率。在英语翻译文本隐形词汇语义自动标注中,贝叶斯理论通过先验知识和后验知识来提高标注的准确性。先验知识基于大量文本分析,建立词汇语义的初始模型。对训练样本进行分析获得条件概率矩阵,如式(6)所示。

$$\boldsymbol{M}_P=\begin{bmatrix} P(a_1\mid y_1) & P(a_2\mid y_1) & \cdots & P(a_n\mid y_1)\\ P(a_1\mid y_2) & P(a_2\mid y_2) & \cdots & P(a_n\mid y_2)\\ \cdots & \cdots & \cdots & \cdots\\ P(a_1\mid y_m) & P(a_2\mid y_m) & \cdots & P(a_n\mid y_m) \end{bmatrix} \tag{6}$$

式中,$\boldsymbol{M}_P$ 代表条件概率矩阵;$P(a\mid y)$ 代表特征属性在不同种类的条件概率。通过贝叶斯定理对条件概率进行重构,如式(7)所示。

$$P(y_i\mid x)=\frac{P(x\mid y_i)P(y_i)}{P(x)} \tag{7}$$

式中,y_i 表示第 i 种潜在的语义类别标签。设置分母为常数,则重构公式中的分子计算如式(8)所示。

$$P(x\mid y_i)P(y_i)=P(y_i)\prod_{j=1}^{m}P(a_j\mid y_i) \tag{8}$$

式中,a_j 表示输入数据的第 j 个特征属性。用重构的结果对条件概率进行更新,如式(9)所示。

$$P(y_{\mathrm{k}}\mid x)=\max\{P(y_1\mid x),P(y_2\mid x),\cdots,P(y_n\mid x)\} \tag{9}$$

式中,y_n 表示第 n 种潜在语义标签;y_{k} 则表示经过最大后验概率比较后,得出的最优语义映射标签。通过定量识别,模型能够准确地捕捉源语言中的隐形词汇,并在目标语言中找到最合适的语义对应。建立源语言和目标语言之间的耦合关系模型,可以帮助自动标注系统更好地理解文本的深层含义,从而在翻译过程中实现更准确的语义传递。

1.3 隐形词汇识别与语义标注方法

隐形词汇识别与语义标注通常采用的方法包括自然语言处理技术和机器学习算法。多目标配置方法涉及对模型的不同参数进行系统化的搜索和评估,以找到最佳的组合,这通常通过定义一个或多个目标函数来实现[14-15]。研究构建一个数学表达式来描述不同参数配置下的性能,如式(10)所示。

$$X_{(i+1)}=\sum_{i=1}p(i)\ \pm b\times\mid m'-X_{(i)}\mid\times\ln\left(\frac{1}{u}\right) \tag{10}$$

式(10)为模糊隶属度函数,在式(10)中,X 为相关参数,u、m' 为随机数,其取值在[0,1]以内,设置多目标配置系数为 b。对多目标寻优的个体极值进行设置,将其设置为 $p(i)$。根据式(10),进行多目标学习参数模型 C' 的构建,C' 的数学表达式如式(11)所示。

$$C'=\frac{C_{\mathrm{S}}\boldsymbol{A}^{P-1}}{X_{(i+1)}}+p(i)\cdot m \tag{11}$$

式中,$\boldsymbol{A}$ 为多目标特征分布矩阵,其维数是 $P\times L$。C_{S} 表示多目标特征的基础分配常数;m 表示特征分配的学习权重参量。以多参数融合为基础,引入自适应参量估计法,利用这两个方法,开展多目标学习,并进行自适应参数跟踪。经过多次迭代后,通过概率推理,确定多目标学习的推理模型,具体如式(12)所示。

$$\boldsymbol{X}_{i\mathrm{next}}=C'\prod_{i=1}\boldsymbol{X}_i\boldsymbol{T}+\frac{\boldsymbol{X}_{\mathrm{c}}-\boldsymbol{X}_i}{\boldsymbol{X}_{\mathrm{c}}+\boldsymbol{X}_i} \tag{12}$$

式中,$\boldsymbol{T}$ 代表的意思是所翻译的语义映射向量;$\boldsymbol{X}_{\mathrm{c}}$ 表示目标映射的中心参考向量;$\boldsymbol{X}_i$ 表示当前第 i 步迭代中的语义映射状态向量。完成推理模型的构建后,对语义映射向量进行大量迭代,在自适应寻优控制法的作用下,对多目标优化进行路由控制。在此过程中,更新规则的相关计算式如(13)所示。

$$\begin{cases}\boldsymbol{m}_{\mathrm{best}}(t+1)=\dfrac{1}{n}\displaystyle\sum_{j=1}^{n}\boldsymbol{p}_j^{\mathrm{T}}(t)\\ \boldsymbol{p}_j(t+1)=\dfrac{1}{a_1+a_2}\Big(\displaystyle\sum_{j=1}^{n}(a_1\boldsymbol{p}_j(t))^{\mathrm{T}}\Big)+\\ \qquad\dfrac{1}{a_1+a_2}\Big(\displaystyle\sum_{g=1}^{m}(a_2\boldsymbol{p}_g(t))^{\mathrm{T}}\Big)\end{cases} \tag{13}$$

式中,a 为随机数,其取值在[0,1]以内,在多目标优化过程中,经过多次迭代后,得到最完整关系特征量,对其进行设置为 $X_j(t)$,j 表示编号,设置特征分布集为 $p_g(t)$;上标 T 表示向量的转置;$\boldsymbol{p}_g$ 表示全局最优解特征向量;$\boldsymbol{p}_j$ 则表示优化过程中的随机干扰或自适应权重向量;$\boldsymbol{m}_{\mathrm{best}}$ 表示多目标综合评价的平均最优位置向量。通过上下文对应,开展多目标优化工作,对参数进行调整,从而可以确定翻译软件优化输出结果,其数学表达式如式(14)所示。

$$X_j(t+1)=\boldsymbol{p}_g^{\mathrm{T}}(t+1)+\sum_{t=1}\boldsymbol{m}_{\mathrm{best}}{}^{\mathrm{T}}(t+1)-\boldsymbol{X}_j^{\mathrm{T}}(t)\times\boldsymbol{u}_j^{\mathrm{T}}(t+1) \tag{14}$$

式中,$\boldsymbol{u}_j$ 表示优化过程中的随机干扰或自适应权重向量。通过上述流程,便可使翻译软件优化输出转换控制、组网控制得以实现。整体上,多目标优化的过程如图 3 所示。

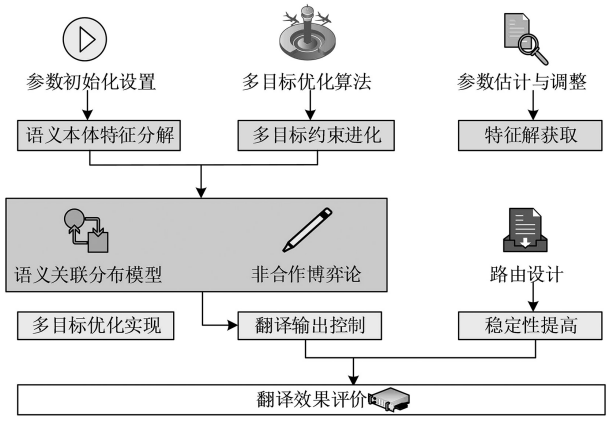


图 3 隐形词汇的语义优化流程图

Fig. 3 Semantic optimization flowchart of hidden vocabulary

首先,在隐形词汇的语义分布特征的基础上,进行模型参数的初始化设置。接着,运用多目标优化算法来调整

和估计模型参数,以实现在多个性能指标(如准确度、召回率和 F_1 分数)之间的最佳平衡。然后,采用语义本体特征分解方法来获取满足多目标约束的进化特征解。进一步地,以语义关联分布模型为基础,结合非合作博弈论的概念,根据特定的路由设计策略,实现多目标优化。最终,为了促进软件输出的稳定性和准确性,对隐形词汇语义自动标注软件的效果进行了评价。评价过程可以采用双语评估替补(bilingual evaluation understudy,BLEU)等指标,以及完整性(Completeness)参数等,来全面衡量标注结果的质量。研究将设计的隐形词汇识别与语义标注模型命名为 MOSM。

2 MOSM 模型性能评估

结合研究构建的 MOSM 模型,配置标注模块,设计架构好隐形词汇语义自动标注系统整体框架之后,用户就能够利用该系统进行文本的语义标注,而该系统需要保证输出的标注符合实际英语文本中隐形词汇的使用场景,这样才能保证提升翻译文本的准确性和自然性。研究利用 UDC 数据库对隐形词汇语义自动标注系统的处理时间进行测试,测试结果如图 4 所示。

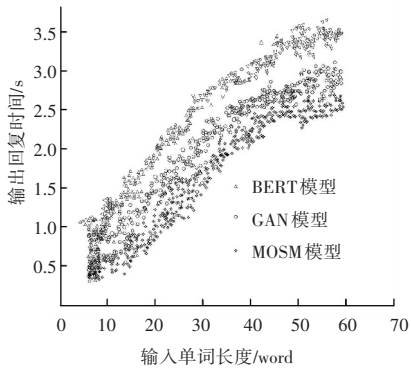
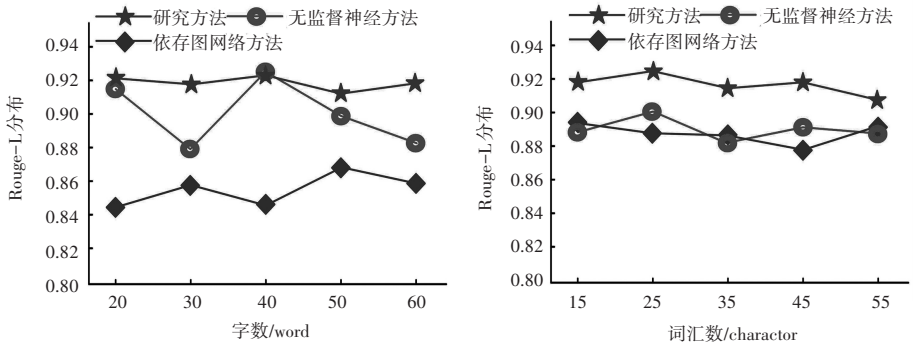


图 4 不同模型响应时间对比分析

Fig. 4 Comparison analysis of response times among different models

如图 4,研究对文献[14]提出的 BERT 模型以及文献[15]提出的 GAN 模型,以及研究设计的改进的 MOSM 模型展开对比,可以看出,MOSM 模型的输出回复的时间多在 2.26 s 左右,而 BERT 模型的响应时间在 3.15 s 左右,GAN 模型的响应时间在 2.66 s。MOSM 响应时间更快,相较于 BERT 模型与 GAN 模型,具有更高的回复效率。为了深入分析英语翻译文本中隐形词汇的语义自动标注的有效性,研究选取了 Chinese-English Text 和 UN translation text 两个数据集作为实验基础。研究设计了五组汉语文本样本,每组样本的字数分别为 20、30、40、50 和 60 字;同时,设计了五组英语文本样本,每组样本的词汇量分别为 15、25、35、45 和 55 个。通过计算标注结果的 Rouge 分数,评估自动标注方法的性能,并将其与基于依存图的网络方法和无监督神经标注方法进行对比,相关结果详见图 5。

如图 5(a)所示,无监督神经方法在处理 42 字的汉语文本时,平均 Rouge-L 分数达到最高点,约为 0.932;而在处理 28 字文本时,分数降至最低,约为 0.883。这表明无监督神经方法在最佳和最差情况下的 Rouge-L 分数相差约 4.9%。依存网络方法在处理 52 字文本时,平均 Rouge-L 分数最高,约为 0.874;在 20 字文本时得分最低,约为 0.845,波动较小,相差约 2.9%。研究提出的自动标注方法在 42 字文本时达到最高分,约为 0.931;在 48 字文本时得分最低,约为 0.910,相差约 2.1%,显示出较高的一致性和稳定性。如图 5(b)所示,无监督神经方法在处理 24 个词汇的法语文本时,平均 Rouge-L 分数最高,约为 0.903;在 34 个词汇时得分最低,约为 0.887,相差约 1.6%,波动性较小。依存网络方法在处理 16 个词汇时得分最高,约为 0.897;在 44 个词汇时得分最低,约为 0.878,相差约 1.9%,整体波动较小。研究方法在 24 个词汇时达到最高分,约为 0.922;在 54 个词汇时得分最低,约为 0.907,相差约 1.5%,同样显示出在不同词汇量文本中的稳定性和一致性。



(a) 汉译英 (b) 英译汉

图 5 跨语言翻译任务中自动标注方法的 Rouge-L 分数性能对比

Fig. 5 Comparison of Rouge-L scores perfrmance for automatic annotation methods in cross-language translation tasks

在隐形词汇语义自动标注系统的评估中,MOSM 模型在多个关键性能指标上表现卓越。该模型以 1.32 word/s 的吞吐量领先于 BERT 模型的 0.98 word/s 和 GAN 模型的 1.19 word/s。准确度达到 93.5%,超越了 GAN 模型的 92.3%和 BERT 模型的 91.2%。在召回率上,MOSM 模型以 92.1%的得分位居第一,BERT 和 GAN 模型分别为 90.4%和 91.6%。F_1 分数为 92.8%,显示了 MOSM 模型在准确性和召回率之间的良好平衡,相比之下,BERT 和 GAN 模型分

别为 90.8%和 91.9%。资源消耗方面,MOSM 模型的 CPU 使用率和内存消耗分别为 15%和 300 MB,低于 BERT 模型的 20%和 450 MB,以及 GAN 模型的 18%和 350 MB。系统可用性方面,MOSM 模型以 99.95%的高可用性超越了 BERT 模型的 99.90%和 GAN 模型的 99.93%。

表 1 隐形词汇语义自动标注系统性能评估对比

Tab. 1 Performance evaluation comparison of automatic semantic annotation system for invisible vocabulary

模型名称	吞吐量/(word · s^{-1})	准确度/%	召回率/%	F_1 分数/%	资源消耗(CPU/%,内存/MB)	系统可用性/%
MOSM	1.32	93.5	92.1	92.8	15, 308	99.95
BERT	0.98	91.2	90.4	90.8	20, 461	99.90
GAN	1.19	92.3	91.6	91.9	18, 352	99.93

3 结论

研究为了解决传统翻译方法在语义精确度和处理效率方面的不足,采用了融合多源信息,整合了 Transformer 结构,以提高英语翻译文本中隐形词汇的语义自动标注性能。研究结果显示,MOSM 模型在响应时间上展现出显著优势,且 Rouge-L 分数表现出较高的一致性和稳定性。MOSM 模型在性能评估中表现突出,其吞吐量高达 1.32 word/s,准确度和召回率分别达到 93.5%和 92.1%,F_1 分数为 92.8%。在资源使用效率上,该模型仅占用 15%的 CPU 和 300MB 内存,同时确保了 99.95%的系统可用性。尽管 MOSM 模型在研究中表现出色,但仍存在改进空间。未来的工作将集中于进一步优化模型参数,以降低在极端情况下的性能波动,并扩展模型在更多语言对和专业领域的应用范围。此外,研究将继续关注模型的可扩展性和实时应用能力,以满足日益增长的翻译质量和效率需求。

参考文献

[1]张冠萍. 基于数学表达式和文档关键词的英文文献检索模型设计[J]. 自动化技术与应用, 2024, 43(12):107-109, 129.

[2]朱平. 基于概念维度拓展的汉语文本全局语义分析方法[J]. 计算机应用, 2022, 42(增刊 2):14-24.

[3]张淑珍, 何镇, 查富生, 等. 基于可调场景语义标注范围的家庭室内语义地图构建[J]. 中国惯性技术学报, 2024, 32(4):371-378.

[4]毛达展, 喻快, 邵艳秋. 基于数据选择和局部伪标注的跨领域语义依存分析研究[J]. 中文信息学报, 2023, 37(6):15-24.

[5]Di Martino B, Colucci Cante L, Esposito A, et al. A tool for the semantic annotation, validation and optimization of business process models[J]. Software: Practice and Experience, 2023, 53(5): 1174-1195.

[6]田培强, 王彬文, 吴敬涛, 等. 基于评定参数的气候试验数据分析与数据库设计[J]. 环境技术, 2023, 41(3):67-73. .

[7]刘洛浩. 基于机器辅助的高校英语专有名词自动翻译研究[J]. 自动化技术与应用, 2024, 43(6):129-132.

[8]崔丹, 李舒淇. 基于 AI 算法的自然语言信息提取-翻译-校对系统设计[J]. 现代电子技术, 2024, 47(10):111-116.

[9]王超, 吕国英, 李茹, 等. 基于 BERT 特征融合与膨胀卷积的汉语副词框架语义角色标注[J]. 中文信息学报, 2024, 38(2):25-35.

[10]肖耀辉, 余俊松, 李为明, 等. 信息物理融合下的特高压换流站状态识别技术[J]. 哈尔滨理工大学学报, 2024, 29(1):69-77.

[11]何憬. 翻转课堂下建筑英语翻译教学实践探究[J]. 建筑结构, 2023, 53(6):174.

[12]李荟, 韩晓飞, 朱万成, 等. 基于多源信息融合的矿山边坡滑坡灾害研究现状与展望[J]. 工矿自动化, 2024, 50(6):6-15.

[13]姚德臣, 王琰亮, 杨建伟, 等. 语义数据标注的轻量化轨道扣件故障检测方法[J]. 振动. 测试与诊断, 2024, 44(1):52-59,196.

[14]Talebi S, Tong E, Li A, et al. Exploring the performance and explainability of fine-tuned BERT models for neuroradiology protocol assignment[J]. BMC Medical Informatics and Decision Making, 2024, 24(1): 40-52.

[15]Guo Z, Shao M, Li S. Image-to-image translation using an offset-based multi-scale codes GAN encoder[J]. The Visual Computer, 2024, 40(2): 699-715.