

知识增强的语义通信接收端设计

李荣鹏¹, 汪丙炎¹, 张宏纲^{1,2}, 赵志峰^{1,2}

(1. 浙江大学信息与电子工程学院, 浙江 杭州 310027; 2. 之江实验室, 浙江 杭州 311121)

摘要: 针对现有的语义通信系统对先验知识利用不够充分、接收端解码能力有限的问题, 提出了一个知识增强的语义通信框架。在这个框架中, 接收端可以利用知识库中的先验知识进行语义推理和解码, 同时不需要对发送端的神经网络结构进行额外的修改。具体而言, 在语义接收端的基础上, 设计了一个基于 Transformer 的知识提取器来为接收到的含噪信号寻找语义相关的知识三元组, 以用于语义解码。在 WebNLG 数据集上的仿真结果表明, 所提框架在知识图谱增强解码的基础上产生了明显的性能提升。

关键词: 语义通信; 知识图谱; 深度学习; 知识提取; 语义解码

中图分类号: TN92

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2023106

Design of knowledge enhanced semantic communication receiver

LI Rongpeng¹, WANG Bingyan¹, ZHANG Honggang^{1,2}, ZHAO Zhifeng^{1,2}

1. College of Information Science and Electronic Engineering, Zhejiang University, Hangzhou 310027, China

2. Zhejiang Lab, Hangzhou 311121, China

Abstract: To address the problem that existing semantic communication do not make sufficient use of prior knowledge and have limited decoding capability at the receiver side, a knowledge enhanced semantic communication framework was proposed, in which the receiver could more actively utilize the prior knowledge in the knowledge base for semantic reasoning and decoding, without extra modifications to the neural network structure of the transmitter. Specifically, a transformer-based knowledge extractor was designed to find relevant factual triples for the received noisy signal. Extensive simulation results on the WebNLG dataset demonstrate that the proposed framework has significantly improved performance on the basis of knowledge graph enhanced decoding.

Keywords: semantic communication, knowledge graph, deep learning, knowledge extraction, semantic decoding

0 引言

随着深度学习 (DL, deep learning) 和自然语言处理 (NLP, natural language processing) 的快速发展, 一种新的通信形式——语义通信成为通信领域的研究热点。与传统通信不同, 语义通信强调收发双方对语义的准确传递, 而非符号层面的准确率。目前, 已经有一些关于语义通信的研究, 例如,

文献[1]提出了一个基于 Transformer 的语义通信系统, 用于文本传输。文献[2]介绍了一个基于 UT (universal transformer) 的语义通信系统, 采用自适应循环机制以提升系统对不同信道条件的适应性。文献[3]利用混合自动重传请求 (HARQ, hybrid automatic repeat request) 来减少语义传输错误和通信开销。文献[4]为语义通信系统引入了自适应比特率控制机制, 能够根据信噪比情况自动调整传输

收稿日期: 2023-02-06; 修回日期: 2023-05-04

基金项目: 国家自然科学基金资助项目 (No.62071425); 浙江省“领雁”基金资助项目 (No.2022C01093); 华为公司合作基金资助项目; 浙江省杰出青年基金资助项目 (No.LR23F010005)

Foundation Items: The National Natural Science Foundation of China (No.62071425), “Leading Goose” Research and Development Program of Zhejiang Province (No.2022C01093), Huawei Cooperation Project, Zhejiang Provincial Distinguished Young Scholars Foundation (No.LR23F010005)

比特率。文献[5]提出了一个基于掩蔽自编码器 (MAE, masked autoencoder) 的语义通信系统用于图片传输, 并通过对抗训练提高系统抵抗语义噪声的能力。此外, 还有针对语音^[6]和视频^[7]数据传输的语义通信研究。值得注意的是, 这些研究的一个关键假设在于发送端和接收端具有共同的先验知识。在此假设的基础上, 现有的语义通信方法大多通过联合训练基于深度神经网络 (DNN, deep neural network) 的发送端和接收端来实现语义的传递。然而, 这种语言模型的接收端仍然缺乏对知识的理解和推理能力, 难以充分挖掘复杂句子中隐含的先验知识。

为了提高系统对知识的理解和推理能力, 一些研究提出将知识图谱 (KG, knowledge graph) 引入语义通信中。知识图谱能够为模型引入各类世界常识, 也就是句子中不能通过语法直接判断, 必须对现实世界有所了解才能理解的内容。知识图谱将人类的知识表示成实体和关系组成的图状结构^[8], 以便机器学习模型理解和处理常识。在知识图谱中, 每条知识被抽象为 (实体-关系-实体) 的三元组。当前已经有一些将知识图谱与语义通信结合的工作。例如, 文献[9]利用知识三元组来表示语义信息, 并提出了一种算法来评估每个三元组的重要性; 文献[10]提出了一个将文本编码为知识图谱的语义通信框架; 文献[11]设计了一个基于知识推理的语义通信系统; 文献[12]提出了一个基于知识图谱的可靠语义通信系统, 能够根据信道情况选择性地传输语义重要性较高的知识。

以上所述研究主要集中在发送端的设计上, 而没有特别关注接收端。同时, 这些研究有一个共同的特点, 即将知识三元组作为语义载体, 传输的句子首先在发送端被表示成三元组的形式。然而, 知识图谱的表达能力是有限的, 且知识库中的知识往往不足以表示句子中所有的语义信息。事实上, 知识图谱只能描述简单陈述句中的语义, 而语义通信场景的传输内容可能复杂得多。如果只发送这些三元组, 则不可避免地会产生额外的语义损失。

因此, 为了解决这些问题, 本文提出在接收端应用知识图谱, 从而使知识库中的先验知识可以直接被用于语义解码, 而不需要对发送端的结构进行任何额外改动。同时, 它也避免了给系统引入人为的语义损失。与发送端方案的不同之处在于, 由于

接收到的内容不可避免地会受到噪声的影响, 因此如何准确地从噪声内容中提取知识三元组成为至关重要的问题。通常的知识提取方法, 如文献[4]中基于命名实体识别 (NER, named entity recognition) 的方法, 可能并不适用于此类场景。此外, 接收到的句子内容是以向量形式表示的, 导致其中的命名实体难以被直接识别。因此, 与其关注一个句子中的每个词, 不如考虑提取整个句子的语义表示, 将知识三元组与所接收到的内容的语义相关联。为此, 本文利用 Transformer 编码器来获得句子的隐含语义表示。通过将知识图谱和知识提取器集成到传统的语义解码器中, 接收端可以从含噪的信息中提取知识并增强解码能力。本文使用的主要参数及其含义如表 1 所示。

表 1 本文使用的主要参数及其含义

参数	含义
$S_\beta(\cdot)$ 和 $S_\gamma^{-1}(\cdot)$	语义编码器和解码器
$C_\alpha(\cdot)$ 和 $C_\delta^{-1}(\cdot)$	信道编码器和解码器
$K_\theta(\cdot)$	知识提取器
s 和 \hat{s}	发送和接收到的句子
h	语义编码向量
\hat{h}	接收端信道解码向量
x	发送的信号
y	接收的信号
k	知识向量
t	知识库索引向量
n_i	知识库中三元组的数量
N	句子长度
w	知识提取过程的权重参数
$f_k(\cdot)$	知识嵌入过程

1 系统模型

语义通信系统通常包含一个语义编码器和一个语义解码器, 如图 1 所示。不失一般性地, 长度为 N 的输入句子可以表示为 $\mathbf{s} = [s_1, \dots, s_N] \in \mathbb{N}^N$, 其中, s_i 代表句子中第 i 个词 (token)。发送端由 2 个模块组成, 即语义编码器和信道编码器。语义编码器 $S_\beta(\cdot)$ 提取内容中的语义信息, 并将其表示为一个向量 $\mathbf{h} \in \mathbb{R}^{N \times d_s}$, 其中, d_s 是每个语义编码符号的维度, 整个过程可以表示为

$$\mathbf{h} = S_\beta(\mathbf{s}) \quad (1)$$

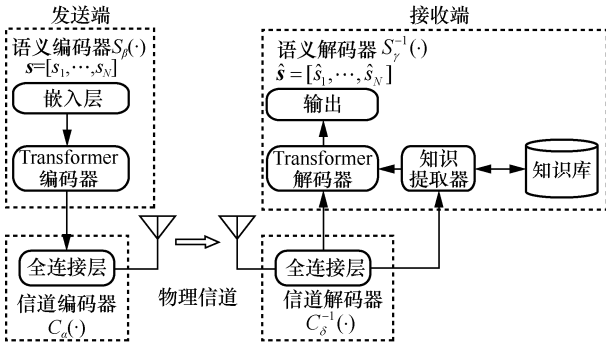


图 1 知识增强的语义通信系统架构

然后，信道编码器 $C_\alpha(\cdot)$ 将 \mathbf{h} 编码为在物理信道上传输的信号，即

$$\mathbf{x} = C_\alpha(\mathbf{h}) \quad (2)$$

其中， $\mathbf{x} \in \mathbb{C}^{N \times c}$ 是信道编码向量， c 是每个词对应的符号数。

将 \mathbf{x} 通过物理信道传输，得到接收信号 $\mathbf{y} \in \mathbb{C}^{N \times c}$ 。 \mathbf{y} 可以写作

$$\mathbf{y} = \mathbf{H}\mathbf{x} + \mathbf{n} \quad (3)$$

其中， \mathbf{H} 为信道矩阵， $\mathbf{n} \sim \mathcal{N}(0, \sigma^2 \mathbf{I})$ 为加性白高斯噪声 (AWGN, additive white Gaussian noise)。

接收到 \mathbf{y} 后，接收端首先用信道解码器 $C_\alpha^{-1}(\cdot)$ 对接收信号进行解码，解码后的向量 $\hat{\mathbf{h}} \in \mathbb{R}^{N \times d_s}$ 为

$$\hat{\mathbf{h}} = C_\alpha^{-1}(\mathbf{y}) \quad (4)$$

在本文提出的系统架构中，接收端拥有一个知识库，知识库中的每个事实被组织为一个知识三元组。接收端的知识提取器 $K_\theta(\cdot)$ 从知识库中寻找与 $\hat{\mathbf{h}}$ 在语义上相关联的三元组，并将其嵌入为知识向量 \mathbf{k} 。整个知识提取和聚合过程可以表示为

$$\mathbf{k} = K_\theta(\hat{\mathbf{h}}) \quad (5)$$

然后，知识增强的语义解码器 $S_\gamma^{-1}(\cdot)$ 利用信道解码向量 $\hat{\mathbf{h}}$ 和提取的知识向量 \mathbf{k} 来获得收到的信息 $\hat{\mathbf{s}} = [\hat{s}_1, \dots, \hat{s}_N]$ ，相当于

$$\hat{\mathbf{s}} = S_\gamma^{-1}(\hat{\mathbf{h}} \parallel \mathbf{k}) \quad (6)$$

其中， $S_\gamma^{-1}(\cdot)$ 表示知识增强的语义解码器， \parallel 表示拼接运算符。

语义通信的准确率由发送和接收的内容之间的语义相似度决定。为了使 \mathbf{s} 和 $\hat{\mathbf{s}}$ 之间的语义误差最小，定义 2 个向量的交叉熵 (CE, cross entropy) 为损失函数

$$\mathcal{L}_{\text{model}} = -\sum_{i=1}^N (q(s_i) \log p(\hat{s}_i)) \quad (7)$$

其中， $\mathcal{L}_{\text{model}}$ 是损失函数， $q(s_i)$ 是 s_i 的 one-hot 表示， $p(\hat{s}_i)$ 是第 i 个词的预测概率分布。

现有的研究大多选择利用端到端的深度神经网络来完成整个通信过程，而非使用传统通信模块进行物理层传输，如图 1 所示。具体而言，本文使用的语义编码器和解码器通常是基于 Transformer^[13] 的，同时，信道编码和解码部分可以看作由全连接层实现的自编码器。整个语义通信过程可以建模成一个序列到序列的问题。本文目标是找到合适的知识提取器 $K_\theta(\cdot)$ 和语义解码器 $S_\gamma^{-1}(\cdot)$ ，以最小化整个模型的损失函数。

2 结合知识提取器模型的语义解码器

2.1 知识提取器的设计

本节主要讨论知识提取器结合语义解码任务的具体实现，整个知识提取过程如图 2 所示，具体可以分为 2 个阶段。第一阶段是一个嵌入任务，利用 Transformer 编码器获得解码向量的语义表示；第二阶段是通过多标签分类找到向量相应的三元组，并将提取的三元组嵌入为知识向量形式。

为了得到内容的语义表示，本文采用由 L 个 Transformer 编码器堆叠组成的模型，每个编码器都由一个多头自注意力机制层、一个前馈层和 2 个相加&标准化层组成^[13]。假设 $\mathbf{z}^{(l-1)}$ 是第 $(l-1)$ 个编码器的输出，其中， $\mathbf{z}^{(0)}$ 相当于 $\hat{\mathbf{h}}$ ，则第 l 层的自注意力机制可以表示为

$$\text{Attention}(\mathbf{z}^{(l-1)}) = \text{softmax} \left(\frac{\mathbf{Q}^{(l)} \mathbf{K}^{(l)\top}}{\sqrt{d_k}} \right) \mathbf{V}^{(l)} \quad (8)$$

其中， $\mathbf{Q}^{(l)} = \mathbf{z}^{(l-1)} \mathbf{W}_Q^{(l)}$ ， $\mathbf{K}^{(l)} = \mathbf{z}^{(l-1)} \mathbf{W}_K^{(l)}$ ， $\mathbf{V}^{(l)} = \mathbf{z}^{(l-1)} \mathbf{W}_V^{(l)}$ ， $\mathbf{W}_Q^{(l)}$ 、 $\mathbf{W}_K^{(l)}$ 和 $\mathbf{W}_V^{(l)}$ 是第 l 层的投影矩阵， d_k 是模型的维度。 $\mathbf{z}^{(l-1)}$ 通过残差连接与计算结果 $\text{Attention}(\mathbf{z}^{(l-1)})$ 相加，然后进行层标准化，即

$$\mathbf{a}^{(l)} = \text{LayerNorm}(\text{Attention}(\mathbf{z}^{(l-1)}) + \mathbf{z}^{(l-1)}) \quad (9)$$

其中， $\mathbf{a}^{(l)}$ 表示输出， $\text{LayerNorm}(\cdot)$ 表示层标准化操作。将计算输出 $\mathbf{a}^{(l)}$ 通过一个前馈神经网络，则有 $\text{FFN}(\mathbf{a}^{(l)}) = \max(0, \mathbf{a}^{(l)} \mathbf{W}_{F1}^{(l)} + \mathbf{b}_{F1}^{(l)}) \mathbf{W}_{F2}^{(l)} + \mathbf{b}_{F2}^{(l)}$ ，其中， $\mathbf{W}_{F1}^{(l)}$ 、 $\mathbf{W}_{F2}^{(l)}$ 、 $\mathbf{b}_{F1}^{(l)}$ 和 $\mathbf{b}_{F2}^{(l)}$ 是第 l 个编码器中前馈层的

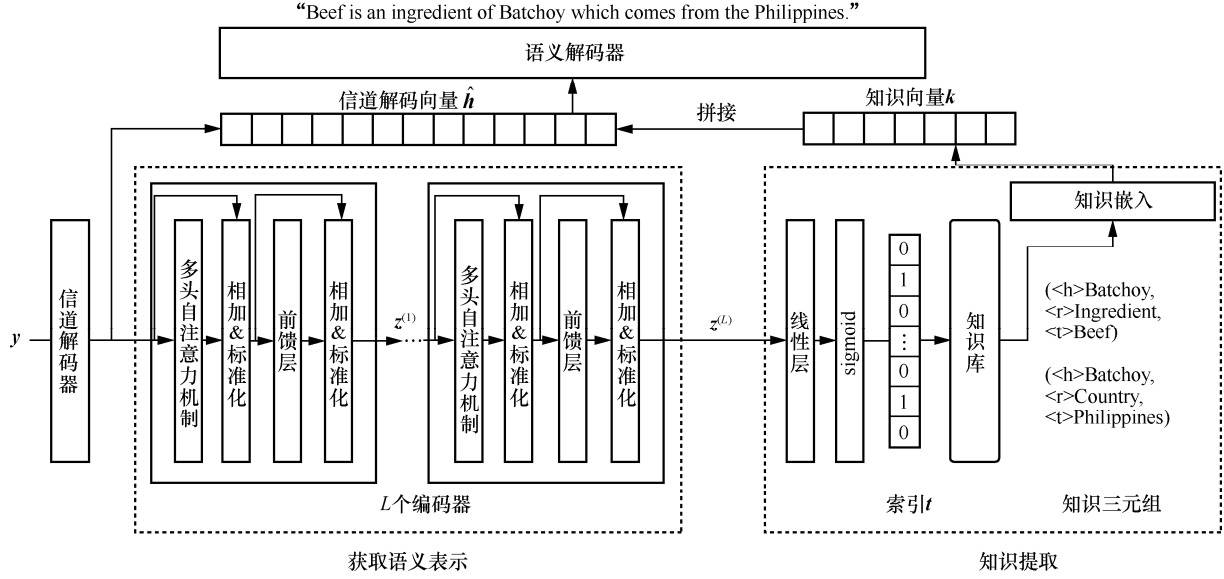


图2 整个知识提取过程

参数。接下来同样是残差连接和标准化运算

$$\mathbf{z}^{(l)} = \text{LayerNorm}(\text{FFN}(\mathbf{a}^{(l)}) + \mathbf{a}^{(l)}) \quad (10)$$

经过 L 层编码，可以得到信道解码向量的嵌入表示 $\mathbf{z}^{(L)}$ 。然后采用一个多标签分类模型来计算与向量语义相关的知识三元组的索引向量 \mathbf{t}

$$\mathbf{t} = \text{sigmoid}(\mathbf{z}^{(L)}\mathbf{W}_t + \mathbf{b}_t) \quad (11)$$

其中， $\mathbf{t} = [\hat{t}_1, \dots, \hat{t}_{n_t}]$ ， $\hat{t}_i \in [0, 1]$ ， $i = 1, \dots, n_t$ ， n_t 是知识库中的三元组数量； \mathbf{W}_t 和 \mathbf{b}_t 是分类器模型参数。对于 $\hat{t}_i \geq 0.5$ ，下标 i 对应的三元组 m_i 被预测为相关。

由模型预测得到的相关知识三元组 $\{m_i\}$ 被嵌入一个向量 $\mathbf{k} = f_k(\{m_i\})$ 中，其中， $f_k(\cdot)$ 表示嵌入过程。随后根据式(6)将知识向量与解码向量拼接，并送入语义解码器。整个知识增强的语义通信系统过程如算法1所示。

算法1 知识增强的语义通信系统过程

给定模型 $S_\beta(\cdot)$ 、 $C_\alpha(\cdot)$ 、 $S_\gamma^{-1}(\cdot)$ 、 $C_\delta^{-1}(\cdot)$ 和 $K_\theta(\cdot)$ ，

发送句子 \mathbf{s} ，接收句子 $\hat{\mathbf{s}}$

发送端：

- 1) 语义编码： $\mathbf{h} = S_\beta(\mathbf{s})$ ；
- 2) 信道编码： $\mathbf{x} = C_\alpha(\mathbf{h})$ ；
- 3) 将 \mathbf{x} 通过信道得到接收信号 $\mathbf{y} = \mathbf{H}\mathbf{x} + \mathbf{n}$ ；

接收端：

- 4) 信道解码： $\hat{\mathbf{h}} = C_\delta^{-1}(\mathbf{y})$ ；

知识提取：

- 5) 计算嵌入表示 $\mathbf{z}^{(L)}$ ；

- 6) $\mathbf{t} \leftarrow \text{sigmoid}(\mathbf{z}^{(L)}\mathbf{W}_t + \mathbf{b}_t)$ ；

- 7) 对所有 $t_i \geq 0.5$ ，找到下标对应 i 的三元组 $\{m_i\}$ ；

- 8) 知识嵌入： $\mathbf{k} \leftarrow f_k(\{m_i\})$ ；

- 9) 语义解码： $\hat{\mathbf{s}} \leftarrow S_\gamma^{-1}(\hat{\mathbf{h}} \parallel \mathbf{k})$ 。

2.2 训练方法

为了训练知识提取器 $K_\theta(\cdot)$ ，首先需要完整的语义通信模型。在训练过程中，句子首先经发送端编码，然后通过信道传输，将收到的解码向量输入知识提取器。之后冻结发送端的参数，通过梯度下降法训练知识提取器模型。由于在分类过程中负样本的数量远多于正样本的数量，因此采用加权的二元交叉熵（BCE, binary cross entropy）作为损失函数。该函数可以表示为

$$\mathcal{L}_{\text{knowledge}} = \sum_{i=1}^{n_t} -w_i [t_i \log \hat{t}_i + (1-t_i) \log(1-\hat{t}_i)] \quad (12)$$

其中， $t_i \in \{0, 1\}$ 是训练标签， \hat{t}_i 是式(11)的预测输出； w_i 是第 i 个位置的权重，与超参数 w 有关，当 $t_i = 0$ 时， $w_i = w$ ；否则， $w_i = 1-w$ 。 w 的大小控制了提取器的敏感程度， w 的值越大，提取器越倾向于忽略不太有把握的内容。

值得注意的是，该知识提取器适用的解码器并不局限于传统的 Transformer 结构，还可以应用于不同的 Transformer 变体，如 UT^[2]。通过自注意力机制，提取的知识三元组可以为语义解码器提供额

外的先验知识，从而提高解码器的性能。

接收端采用的知识库取决于通信场景，当知识库规模较大时，能够覆盖更多的内容范围，但同时也会增加接收端处理信息的难度和计算量，因此需要根据实际情况，在信息量和效率之间做出合理选择。

3 仿真分析

3.1 数据集与参数设定

仿真实验中使用的数据集基于 WebNLG v3.0^[14]，它由数据-文本对组成，其中，数据是一组从 DBpedia 中提取的三元组，文本是这些三元组的字面描述。基于 WebNLG 数据集，本文可以方便地得到标记化的句子及其相关的三元组。在仿真实验中，权重参数 w 设定为 0.02，学习率设定为 10^{-4} ，参数的取值是根据经验和实验结果确定的。系统的仿真参数设置如表 2 所示。仿真所对比的基准是不含知识提取器的 Transformer 解码器，性能指标是 1-gram BLEU (bilingual evaluation understudy) 分数^[15]。本文分别在传统 Transformer 和 UT^[2]上进行了仿真。

表 2 系统的仿真参数设置

参数	值
训练集数量/个	24 467
测试集数量/个	2 734
权重参数 w	0.02
优化器	Adam
Batch 大小	32
模型维度	128
学习率	10^{-4}

3.2 仿真结果

图 3 和图 4 显示了 1-gram BLEU 在 AWGN 和瑞利衰落信道上的模型性能。可以看出，知识提取器有助于提高接收端的性能。对于 2 种不同的信道，在低信噪比的情况下，知识提取器的引入能够带来超过 5% 的性能提升。这一结论对传统 Transformer 和 UT 均成立。而在信噪比较高的情况下，由于误码较少，传统 Transformer 解码器已经足以将接收内容还原，因此性能提升相对较小。

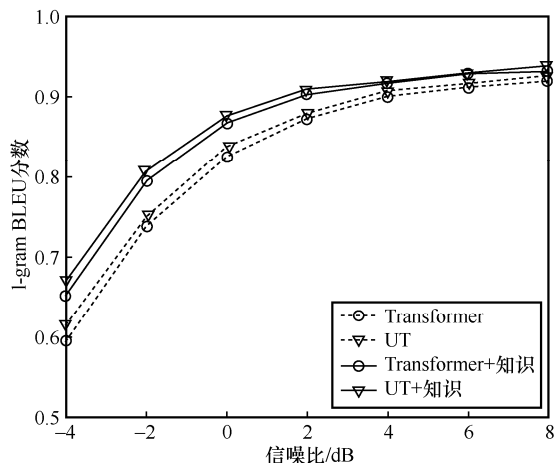


图 3 AWGN 信道下模型 1-gram BLEU 分数与信噪比的关系

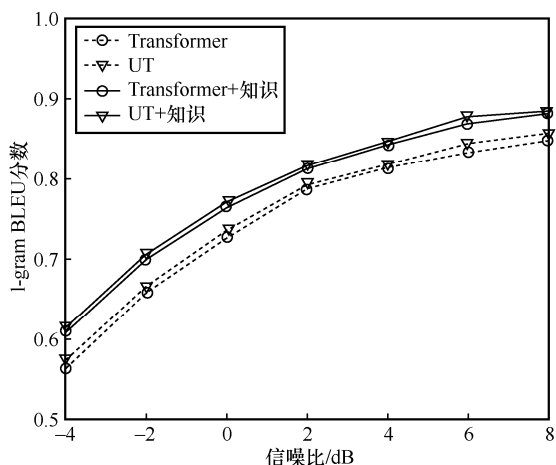


图 4 瑞利衰落信道下模型 1-gram BLEU 分数与信噪比的关系

为了进一步验证知识提取器的有效性，本文单独测试了知识提取器在不同信噪比下的性能，如图 5 所示。在高信噪比条件下，知识提取器可以获得超过 90% 的召回率。同时，知识提取器的精确率约为 50%，这是因为其会受到信道噪声的影响。




图 5 知识提取器在不同信噪比下的性能

此外，除了在固定信噪比下训练模型之外，还可以对每个特定的信噪比分别训练模型。表3展示了单一模型和特定信噪比模型之间的性能对比。从表3可以看出，与固定模型相比，特定信噪比模型在1-gram BLEU分数上可以产生1%~2%的性能改进。

表3 单一模型和特定信噪比模型之间的性能对比

信噪比/dB	单一模型	特定信噪比模型
-4	0.651 4	0.671 8
-2	0.793 6	0.812 6
0	0.866 1	0.866 1
2	0.902 5	0.913 4
4	0.916 4	0.920 1

知识提取器中 Transformer 编码器层数也会影响模型的性能。因此，本文尝试使用不同的 Transformer 编码器层数来实现知识提取。图6展示了 AWGN 信道下不同编码器层数的性能。从图6可以看出，当模型从3层增加到6层时，性能约有2%的提升。然而当模型进一步增加到9层时，性能几乎没有变化，这可能是梯度消失或爆炸、过拟合等问题所导致的。




图6 AWGN 信道下不同编码器层数的性能

4 结束语

本文提出了一个知识增强的语义通信框架，其中，接收端可以利用知识图谱中的先验知识进行语

义解码，同时不需要对发送端架构进行额外的修改。具体而言，在语义接收端基础上，本文设计了一个知识提取器，以找到与接收到的含噪句子语义相关的知识三元组。WebNLG 数据集上的仿真结果表明，本文提出的架构能够深入利用知识图谱中的先验知识，并提升接收端的性能。

参考文献：

- [1] XIE H Q, QIN Z J, LI G Y, et al. Deep learning enabled semantic communication systems[J]. IEEE Transactions on Signal Processing, 2021, 69: 2663-2675.
- [2] ZHOU Q Y, LI R P, ZHAO Z F, et al. Semantic communication with adaptive universal transformer[J]. IEEE Wireless Communications Letters, 2022, 11(3): 453-457.
- [3] JIANG P W, WEN C K, JIN S, et al. Deep source-channel coding for sentence semantic transmission with HARQ[J]. IEEE Transactions on Communications, 2022, 70(8): 5225-5240.
- [4] ZHOU Q Y, LI R P, ZHAO Z F, et al. Adaptive bit rate control in semantic communication with incremental knowledge-based HARQ[J]. IEEE Open Journal of the Communications Society, 2022, 3: 1076-1089.
- [5] HU Q Y, ZHANG G Y, QIN Z J, et al. Robust semantic communications against semantic noise[C]//Proceedings of 2022 IEEE 96th Vehicular Technology Conference (VTC2022-Fall). Piscataway: IEEE Press, 2023: 1-6.
- [6] WENG Z Z, QIN Z J. Semantic communication systems for speech transmission[J]. IEEE Journal on Selected Areas in Communications, 2021, 39(8): 2434-2444.
- [7] JIANG P W, WEN C K, JIN S, et al. Wireless semantic communications for video conferencing[J]. IEEE Journal on Selected Areas in Communications, 2023, 41(1): 230-244.
- [8] JI S X, PAN S R, CAMBRIA E, et al. A survey on knowledge graphs: representation, acquisition, and applications[J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 33(2): 494-514.
- [9] WANG Y N, CHEN M Z, SAAD W, et al. Performance optimization for semantic communications: an attention-based learning approach[C]//Proceedings of 2021 IEEE Global Communications Conference (GLOBECOM). Piscataway: IEEE Press, 2022: 1-6.
- [10] ZHOU F H, LI Y H, ZHANG X Y, et al. Cognitive semantic communication systems driven by knowledge graph[C]//Proceedings of 2022 IEEE International Conference on Communications. Piscataway: IEEE Press, 2022: 4860-4865.
- [11] LIANG J M, XIAO Y, LI Y Y, et al. Life-long learning for reasoning-based semantic communication[C]//Proceedings of 2022 IEEE International Conference on Communications Workshops (ICC Workshops). Piscataway: IEEE Press, 2022: 271-276.
- [12] JIANG S T, LIU Y L, ZHANG Y C, et al. Reliable semantic communication system enabled by knowledge graph[J]. Entropy, 2022,

24(6): 846.

- [13] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. New York: ACM Press, 2017: 6000-6010.
- [14] GARDENT C, SHIMORINA A, et al. Creating training corpora for NLG micro-planning[C]//Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics. Morristown: Association for Computational Linguistics, 2017: 1-9.
- [15] PAPINENI K, ROUKOS S, WARD T, et al. BLEU: a method for automatic evaluation of machine translation[C]//Proceedings of the 40th Annual Meeting on Association for Computational Linguistics. Morristown: Association for Computational Linguistics, 2001: 311-318.

[作者简介]



李荣鹏 (1989-)，男，河北衡水人，博士，浙江大学副教授，主要研究方向为智能通信网络、网络智能、网络切片。



汪丙炎 (1999-)，男，广东深圳人，浙江大学硕士生，主要研究方向为语义通信、深度学习。



张宏纲 (1967-)，男，甘肃兰州人，博士，浙江大学教授，主要研究方向为认知无线电、绿色通信和下一代异构蜂窝网络架构。



赵志峰 (1975-)，男，河南洛阳人，博士，之江实验室总工程师，主要研究方向为认知无线电、无线 mesh 网络和 SDN 在无线通信中的应用。