

## 基于变分自编码器的多隐变量双向推理模型

赵雁斌, 苏锦钿

### 引用本文

赵雁斌, 苏锦钿. 基于变分自编码器的多隐变量双向推理模型[J]. 计算机科学, 2023, 50(10): 176-183.

ZHAO Yanbin, SU Jindian. Bidirectional Inference Model with Multiple Latent Variables Based on Variational Auto-encoders [J]. Computer Science, 2023, 50(10): 176-183.

---

### 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

#### Similar articles recommended (Please use Firefox or IE to view the article)

#### [融合多类时空轨迹特征的跨网络用户身份识别](#)

Cross-network User Identification Based on Multiple Spatio-Temporal Trajectory Features

计算机科学, 2023, 50(3): 114-120. <https://doi.org/10.11896/jsjcx.211200287>

#### [结合情感信息的个性化对话生成](#)

Personalized Dialogue Generation Integrating Sentimental Information

计算机科学, 2022, 49(11A): 211100019-6. <https://doi.org/10.11896/jsjcx.211100019>

#### [基于双向长短时记忆网络的企业弹性能力预测模型](#)

Prediction Model of Enterprise Resilience Based on Bi-directional Long Short-term Memory Network

计算机科学, 2022, 49(11): 197-205. <https://doi.org/10.11896/jsjcx.210900195>

#### [融合RACNN和BiLSTM的金融领域事件隐式因果关系抽取](#)

Implicit Causality Extraction of Financial Events Integrating RACNN and BiLSTM

计算机科学, 2022, 49(7): 179-186. <https://doi.org/10.11896/jsjcx.210500190>

#### [基于CNN-LSTM的卫星云图云分类方法研究](#)

Study on Cloud Classification Method of Satellite Cloud Images Based on CNN-LSTM

计算机科学, 2022, 49(6A): 675-679. <https://doi.org/10.11896/jsjcx.210300177>

# 基于变分自编码器的多隐变量双向推理模型

赵雁斌 苏锦钊

华南理工大学计算机科学与工程学院 广州 541001

(zhaoyanbin98@foxmail.com)

**摘要** 开放域对话系统的关键任务之一是生成丰富多样且连贯的对话回复,但是仅从上文信息进行单向推理无法达到这一目标。针对该问题,提出了基于多隐变量的双向推理模型 MLVBI(Multiple Latent Variables Bidirectional Inference)。首先,在语言模型中结合变分自动编码器并将单向推理扩充到双向推理,将语料分割为上文、查询与回复后,使用正向推理从查询中推理出回复用于学习正常语序信息,同时使用反向推理从回复中推理出查询用于学习额外主题信息,最后融合成双向推理,使得模型生成更连贯的回复。其次,针对双向推理过程中单个隐变量解释能力不足的问题,引入多个隐变量进一步提高生成对话的多样性。实验结果表明,MLVBI 在两个开放域数据集 DailyDialog 和 PersonalChat 上的准确性和多样性都达到了当前最佳的效果,并且消融实验也证明了双向推理和多隐变量的有效性。

**关键词:** 对话生成;变分自动编码器;隐变量;双向推理;长短时记忆网络

中图法分类号 TP391

## Bidirectional Inference Model with Multiple Latent Variables Based on Variational Auto-encoders

ZHAO Yanbin and SU Jindian

School of Computer Science and Engineering, South China University of Technology, Guangzhou 541001, China

**Abstract** One of the key tasks of open-domain dialog system is to generate diverse and coherent dialog responses. However, one-way inference from above information alone cannot achieve this goal. To solve this problem, this paper proposes a bidirectional inference model MLVBI(multiple latent variables bidirectional inference) based on multiple latent variables. First, variational auto-encoder is incorporated into the language model and one-way inference is extended to two-way inference. That is, after the corpus is divided into context, query and response, forward inference is used to infer the response from the query to learn the word order information, and reverse inference is used to infer the query from the response to learn additional topic information at the same time. Finally, the model is integrated into bidirectional inference to generate more coherent responses. Then, in order to solve the problem of insufficient explanation ability of a single latent variable in the two-way inference process, this paper introduces multiple latent variables in the inference process to further improve the diversity of generated conversations. Experimental results show that MLVBI obtains the best accuracy and diversity on two open-domain datasets, DailyDialog and PersonalChat, and ablation experiments also show the effectiveness of two-way inference and multiple latent variables.

**Keywords** Dialogue generation, Variational auto-encoder, Latent variable, Bidirectional inference, Long short-term memory

## 1 引言

开放域对话系统的一项关键任务是能产生类人的回复,即回复不仅要具有多样性和丰富性,而且语义要连贯且相关。通常,在给定对话历史后,传统的方法如 Seq2Seq<sup>[1]</sup>和 Transformer<sup>[2]</sup>会学习如何通过最大似然估计来预测回复<sup>[3]</sup>。但是在传统编码器解码器中,只根据上文信息进行单向推理容易

产生“我不知道”或者“我不确定”之类无意义的和枯燥的回复<sup>[4-5]</sup>。针对该问题,一些学者直接在对话模型中引入基础变分自动编码器(Variational Autoencoders, VAE)和隐变量,取得了明显优于传统编码器解码器的效果<sup>[6-7]</sup>。

随后,许多学者陆续对 VAE 与对话模型的结合提出了一系列的改进,尝试引入更多额外信息。为了更好地重建对话场景,Feng 等<sup>[8]</sup>利用模仿学习框架,使用教师模型指导

到稿日期:2022-09-21 返修日期:2022-12-09

基金项目:广东省 2019 年引进创新团队和产学研合作专项资金项目(2019C002001);广东省基础与应用研究基金(2019B151502057);国家自然科学基金(61936003)

This work was supported by the Guangdong Provincial Special Funding Projects for Introducing Innovation Team and Industry University Research Cooperation, China(2019C002001), Research and Development Program in Key Areas of Guangdong Province, China(2019B151502057) and National Natural Science Foundation of China(61936003).

通信作者:苏锦钊(sujd@scut.edu.cn)

当前模型更好地生成隐变量和回复。为了避免生成单一的问题,Zhou等<sup>[9]</sup>提出了对比学习方法,使得模型在生成相同回复的同时能够进行惩罚并对语料进行扰乱,从而得到更丰富的回复。为了利用上下文中的主题联系,Li等<sup>[10]</sup>提出了倒退推理,将隐变量空间作为桥梁,使得生成的回复更连贯。近年来,随着预训练语言模型的流行,一些学者开始将其与VAE结合,并结合预训练和下游任务微调的方法来提高回复的生成质量,典型的工作有PLATO-2<sup>[11]</sup>,Optimus<sup>[12]</sup>。

在上述工作中,模仿学习的教师模型需要先学习未来句子的信息,并将信息转移给学生模型,对比学习需要构造扰乱的数据集并进行对比,而预训练则需要预先学习大规模文本中的语法和语义信息等。为了避免过多依赖外部信息而造成的过拟合问题,并在有限信息的条件下保证回复的生成效果,本文受Li等<sup>[10]</sup>工作的启发,提出了一种基于多隐变量的双向推理模型MLVBI。MLVBI假定相邻的对话轮次应该具有紧密的主题联系,即相邻对话轮次可以互相推理,并且引入隐变量能存储更多上下文信息。具体来说,本文的主要贡献包括:

1)为了让模型从上文信息中学习连贯的内容并更好地生成高质量的回复,提出了基于多隐变量的双向推理模型。其中正向推理从查询推理出回复,而反向推理从回复推理出查询,最后融合正反方向的推理效果。

2)针对双向推理过程中单个隐变量解释能力不足的问题,提出在每个推理步骤中都引入隐变量的方式用于存储更多的上文信息,从而提升生成回复的多样性和准确性。

3)在两个公开数据集DailyDialog和PersonalChat上证明了本文提出的MLVBI是有效的,并在自动评价上取得了当前最佳的效果。

## 2 相关工作

结合变分自动编码器(VAE)<sup>[13]</sup>的对话模型是最流行的对话建模框架之一,它能够有效地缓解对话生成中的枯燥回复问题。很多学者在对话生成任务中针对VAE与对话模型的结合提出了改进。

例如,Sun等<sup>[14]</sup>提出了SepaCVAE,通过关系增强,在隐变量空间中扩大不同组对话的差异,增强同一组对话的相似性,使得生成的回复在具有高度多样性的同时保持相关性。Zhao等<sup>[15]</sup>提出了DB-VAE,将隐变量空间转化为由共享可学习词本组成的离散空间,并学习选取词本的一个词来表示语义建模,同时还加入了词本切分和预训练。还有第1章所述的Feng等<sup>[8]</sup>提出的模仿学习方法、Zhou等<sup>[9]</sup>提出的对比学习方法,以及Li等<sup>[10]</sup>提出的反向推理,都有效地提高了生成回复的质量。

近年来,一些学者将预训练语言模型与VAE相结合,利用大型预训练语言模型中预先学习的额外信息在对话领域中生成更自然的回复。例如,百度提出的PLATO-2<sup>[11]</sup>采用离散的隐变量来解决回复生成中固有的一对多映射问题。Li等<sup>[12]</sup>提出了Optimus,并证明了在大规模的预训练之后模型可以通过学习更多的信息来减缓后验崩溃<sup>[16]</sup>。虽然这些工作均证明了基于预训练语言模型的对话模型能够取得不错的效果,但是预训练语言模型与VAE的结合方式和LSTM<sup>[17]</sup>

与VAE的结合方式并没有本质的区别。另外,预训练语言模型容易因微调语料不足而出现过拟合问题。

与上述工作不同,本文的主要目标是在不引入额外信息的情况下,通过多隐变量的双向推理模型生成高质量的回复。为了仅探究推理过程和隐变量对结果的影响,本文将工作重点放在了VAE和隐变量上,语言模型仍采用传统的LSTM结构。

## 3 模型架构

### 3.1 任务定义

在许多会话场景中,对话上文相对较长且包含大量信息,而回复较短,这使得仅依靠回复难以反推上文中的信息。所以本文引入双向推理并把语料分为3部分,即上文 $C$ 、查询 $X$ 、回复 $Y$ ,反向推断是从回复推断到查询。本文的最终目标是给定对话上文 $C$ 和查询 $X$ 后,预测回复 $Y$ 。在一段有 $t$ 句话的对话中,假定 $s$ 为开始句, $e$ 为结束句,那么 $C$ 为第 $[s, e-2]$ 句, $X$ 为第 $e-1$ 句, $Y$ 为第 $e$ 句。分割示例如图1所示。




图1 上文、查询、回复的分割示例

Fig. 1 Segmentation example of context, query and response

本文提出的MLVBI采用双向推理和4个隐变量空间,分别用不同的隐变量空间 $Z_1, Z_2, Z_3, Z_4$ 单独优化正向和反向的重构损失和KL散度(Kullback-Leibler Divergence)。语料及其对应的隐变量空间如图2所示。其中, $c, x, y$ 分别代表上文、查询、回复经过编码后的隐藏状态, $Z$ 代表对应的隐变量空间, $c$ 对应 $Z_1, c, x, y$ 联结对应 $Z_4$ ,而 $c$ 和 $x$ 联结对应 $Z_2$ , $c$ 和 $y$ 联结对应 $Z_3$ 。




图2 语料及其对应的隐变量空间

Fig. 2 Corpus and its corresponding latent variable space

### 3.2 模型架构

当以对话作为条件时,VAE可以转变成CVAE,即条件变分自编码器(Conditional Variational Auto-Encoders)。在基础的CVAE中,假设给定上文 $c$ 为条件,可确定一个隐变量的先验分布为 $p(z|c)$ 。先验网络可以从这个先验分布中采样出隐变量 $z$ ,再通过解码器生成回复隐状态 $y$ 。那么训练的目标为:最小化真实回复 $y$ 和生成回复 $y$ 之间的重构损失以及最小化后验分布 $q(z|c, y)$ 和先验分布 $p(z|c)$ 的KL散度,公式如下:

$$\log p(y|c) \geq \mathbb{E} q_\phi(z|c, y) [\log p_\theta(y|z, c)] - D_{\text{KL}}(q_\phi(z|c, y) \| p_\theta(z|c)) \quad (1)$$

MLVBI在式(1)的基础上,将原始上文拆分成上文 $c$ 和

查询  $x$ , 对联合条件进行分解, 分为正向推理和反向推理。公式前半部分是重构损失, 后半部分是 KL 散度, 优化目标公式如下:

$$\begin{aligned} \log p(x, y|c) &= \frac{1}{2} [\log p(x|c) + \log p(y|x, c) + \\ &\quad \log p(y|c) + \log p(x|y, c)] \\ &\geq \frac{1}{2} \{ \mathbb{E}_{q_\phi}(z_1|c, x) [\log p_\theta(x|c, z_1)] - \\ &\quad D_{\text{KL}}(q_\phi(z_1|c, x) \| p_\theta(z_1|c)) \} \end{aligned} \quad (1)$$

$$\begin{aligned} &+ \mathbb{E}_{q_\phi}(z_2|c, x, y) [\log p_\theta(y|c, x, z_2)] - \\ &\quad D_{\text{KL}}(q_\phi(z_2|c, x, y) \| p_\theta(z_2|c, x)) \quad (2) \\ &+ \mathbb{E}_{q_\phi}(z_3|c, y) [\log p_\theta(y|c, z_3)] - \\ &\quad D_{\text{KL}}(q_\phi(z_3|c, y) \| p_\theta(z_3|c)) \quad (3) \\ &+ \mathbb{E}_{q_\phi}(z_4|c, x, y) [\log p_\theta(x|c, y, z_4)] - \\ &\quad D_{\text{KL}}(q_\phi(z_4|c, x, y) \| p_\theta(z_4|c, y)) \quad (4) \end{aligned} \quad (2)$$

根据式(2), MLVBI 模型的总体架构如图 3 所示。

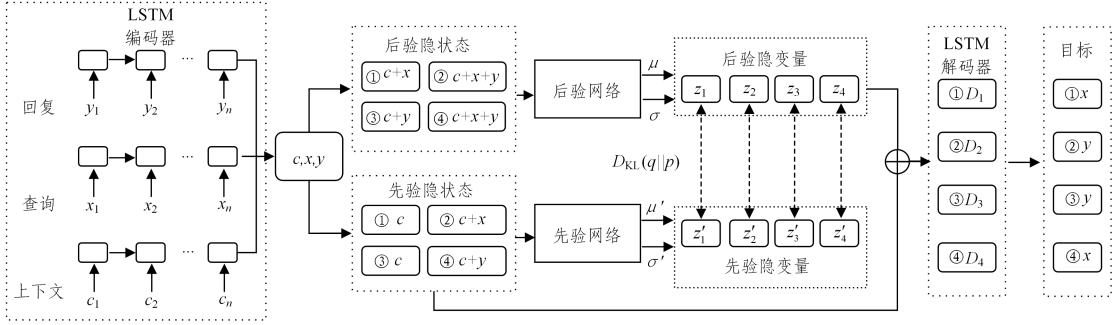


图 3 MLVBI 的总体架构

Fig. 3 Overall framework of MLVBI

图 3 左侧为 LSTM 编码器,  $c, x, y$  分别表示上文、查询和回复分别经过 LSTM 编码器编码之后得到的编码隐状态。图 3 中间为后验和先验网络, 生成方差  $\sigma$  和均值  $\mu$  后, 采样得到隐变量  $z$ 。隐变量之间的虚线箭头表示先验隐变量  $z'$  与后验隐变量  $z$  相对应。图 3 右侧的解码器 Decoder 与编码器类似, 不同的解码器会生成不同的目标。

在图 3 中的后验隐状态和先验隐状态中, ①和②代表正向推理阶段, ③和④代表反向推理阶段。MLVBI 假设  $z$  是从容易理解的遵循正态分布的连续分布中采样, 并且假设后验分布为  $q_\phi \sim N(\mu, \sigma^2 I)$ , 先验分布为  $p_\theta \sim N(\mu', \sigma'^2 I)$ 。在解码过程中, 4 个解码器分别将隐变量  $z$  和各自不同的输入组合后解码得到查询或者回复。

接着, 为了鼓励后验分布逼近先验分布, 即最小化 KL 散度, 需要计算后验和先验之间的 KL 散度。因为各阶段的分布

不同, 所以 MLVBI 将 4 个隐变量之间的 KL 散度加和求平均值。接下来将阐述正向推理和反向推理的流程以及公式。

### 3.3 正向推理

正向推理如图 4 所示, MLVBI 将在①中从上文  $C$  推理出查询  $X$  (见图 4 右侧), 接着在②中推理出回复  $Y$  (见图 4 左侧), 分阶段求条件似然。

在阶段①中, MLVBI 将上文隐状态  $c$  和隐变量  $z_1$  结合, 通过解码器 1 来生成查询  $x$ :

$$\begin{aligned} \log p(x|c) &\geq \mathbb{E}_{q_\phi}(z_1|c, x) [\log p_\theta(x|c, z_1)] - \\ &\quad D_{\text{KL}}(q_\phi(z_1|c, x) \| p_\theta(z_1|c)) \end{aligned} \quad (3)$$

在阶段②中, MLVBI 将上文隐状态  $c$ 、查询隐状态  $x$  和隐变量  $z_2$  结合, 通过解码器 2 来生成回复  $y$ :

$$\begin{aligned} \log p(y|c, x) &\geq \mathbb{E}_{q_\phi}(z_2|c, x, y) [\log p_\theta(y|c, x, z_2)] - \\ &\quad D_{\text{KL}}(q_\phi(z_2|c, x, y) \| p_\theta(z_2|c, x)) \end{aligned} \quad (4)$$

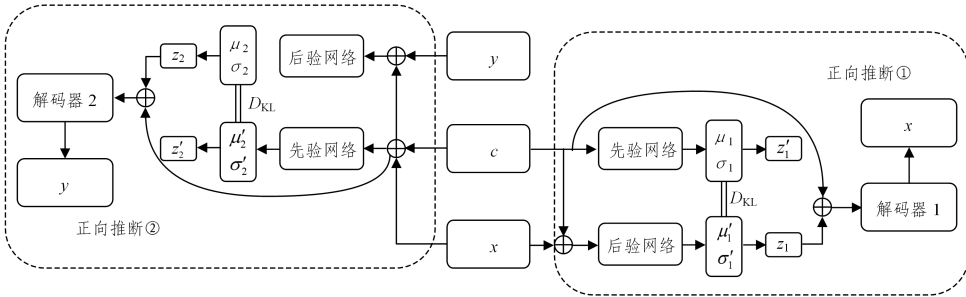


图 4 正向推理两阶段

Fig. 4 Two stages of forward inference

### 3.4 反向推理

本文假设反向推理能帮助模型学到更多的主题信息, 并且训练方法也与正向推理类似。反向推理如图 5 所示, MLVBI 将在③中从上文  $C$  推理出回复  $Y$  (见图 5 右侧), 接着在④中推理出查询  $X$  (见图 5 左侧)。

在阶段③中, MLVBI 将上文隐状态  $c$  和隐变量  $z_3$  结合,

通过解码器 3 来生成回复  $y$ :

$$\begin{aligned} \log p(y|c) &\geq \mathbb{E}_{q_\phi}(z_3|c, y) [\log p_\theta(y|c, z_3)] - \\ &\quad D_{\text{KL}}(q_\phi(z_3|c, y) \| p_\theta(z_3|c)) \end{aligned} \quad (5)$$

在阶段④中, MLVBI 将上文隐状态  $c$ 、回复隐状态  $y$  和隐变量  $z_4$  结合, 通过解码器 4 来生成查询  $x$ :

$$\begin{aligned} \log p(x|c, y) &\geq \mathbb{E}_{q_\phi}(z_4|c, x, y) [\log p_\theta(x|c, y, z_4)] - \\ &\quad D_{\text{KL}}(q_\phi(z_4|c, x, y) \| p_\theta(z_4|c, y)) \end{aligned} \quad (6)$$

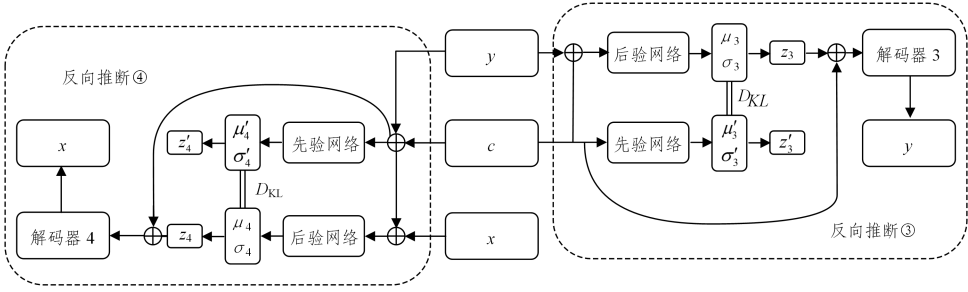


图5 反向推理两阶段

Fig. 5 Two stages of reverse inference

### 3.5 模型训练

在训练中,模型将根据对应阶段序号的输入经过对应的编码器生成对应阶段序号的输出。以正向推理阶段②为例,MLVBI将从上文隐状态  $c$  和查询隐状态  $x$  推理出回复隐状态  $y$ 。MLVBI的训练步骤如下:

1)将上文、查询和回复送入编码器。

$$c = LSTM(c_1, c_2, \dots, c_n)$$

$$x = LSTM(x_1, x_2, \dots, x_n) \quad (7)$$

$$y = LSTM(y_1, y_2, \dots, y_n)$$

2)通过先验和后验网络分别生成方差  $\sigma$  和均值  $\mu$ ,其中后验网络需经过线性网络,先验网络需要经过一层非线性网络 MLP。

$$\begin{bmatrix} \mu \\ \log(\sigma^2) \end{bmatrix} = W \begin{bmatrix} x \\ y \\ c \end{bmatrix} + b \begin{bmatrix} \mu' \\ \log(\sigma'^2) \end{bmatrix} = MLP(c, x) \quad (8)$$

3)采样出隐变量  $z$ : MLVBI 使用重参数技巧<sup>[18]</sup> (Reparameterization Trick)从标准正态分布  $N(0, 1)$  中采样出  $\epsilon$ , 结合方差和均值计算出后验隐变量  $z$ 。

$$z = \mu + \epsilon \times \sigma \quad (9)$$

4)通过编码后的隐状态和后验隐变量解码生成目标隐状态计算损失,从解码器得到回复隐状态  $y$ 。

$$y \sim LSTM(p_\theta(z, c, x)) \quad (10)$$

### 3.6 模型测试

MLVBI 的测试部分如图 6 所示,目的为给定上文  $C$  和查询  $X$  后,生成回复  $Y$ 。




图6 测试部分

Fig. 6 Test section

MLVBI 在测试时遵循传统的方法,直接利用上文隐状态  $c$  和查询隐状态  $x$  生成的先验隐变量  $z'$ 。通过解码器得到隐状态  $y$  后,为使随机性完全来自隐变量,MLVBI 采用贪婪采样从解码器得到回复  $Y$ 。推断步骤与 3.5 节类似,公式如下:

$$c = LSTM(c_1, c_2, \dots, c_n) \quad x = LSTM(x_1, x_2, \dots, x_n) \quad (11)$$

$$\begin{bmatrix} \mu' \\ \log(\sigma'^2) \end{bmatrix} = MLP(c, x) \quad (2)$$

$$z' = \mu' + \epsilon \times \sigma' \quad (3)$$

$$y \sim LSTM(p_\theta(z', c, x)) \quad (4)$$

(11)

## 4 实验

本文的实验将分成 3 个部分进行。为了缓解 VAE 特有的后验崩溃问题,即 KL 值降到 0, MLVBI 引入 beta 退火<sup>[5]</sup> 和 PID<sup>[18]</sup> 比例积分微分 (Proportion Integration Differentiation) 来控制 KL 值的权重。实验一的目的得到各模型 KL 散度的收敛值与收敛过程。该实验使用 beta 退火<sup>[5]</sup> 简单地减少 KL 值的权重,目的是让模型在前期学到更多知识,并且在 KL 值收敛后计算出合适的 KL 值。实验二的目的是避免后验崩溃对各模型的影响,经过训练后得到生成对话的最终结果。该实验从实验一得到合适的 KL 值后,将其作为超参数,引入 PID 对 KL 值权重进行动态控制,使 KL 值稳定在该值。最后,本文对 MLVBI 进行了消融实验,验证了双向推理和多隐变量的有效性。

### 4.1 数据集

本文使用的两个数据集分别是 DailyDialog<sup>[19]</sup> 和 PersonalChat<sup>[20]</sup>。DailyDialog 提供 13118 个英语学习者的日常对话,PersonalChat 数据集是通过亚马逊劳务众包平台“Amazon Mechanical-Turk”收集的,包含 162064 个对话语句,单个语句最多 15 个词,不使用里面的个性部分。将这两个数据集分成训练、验证和测试集,它们的比例与之前的研究相同。数据集的详细信息如表 1 所列。本文将对话窗口设置为 3~10,即一段对话的最少句子数为 3,最多句子数为 10。

表1 两个数据集的详细信息

Table 1 Details of two datasets

数据集	训练集	验证集	测试集	总段落	词数	平均句长
Dailydialog	11118	1000	1000	13118	20000	14.47
PersonalChat	9172	1000	968	2438	22000	12.51

### 4.2 评价方法

为了评价 MLVBI 的有效性,本文选择了 3 个广泛使用的标准度量: BLEU<sup>[21]</sup>, BOW Embedding<sup>[22]</sup> 和 Distinct<sup>[22]</sup>。

1) BLEU (Bilingual evaluation understudy): 所生成回复的  $n$ -gram 重叠程度。本文使用 nltk3.4.5 包<sup>1)</sup> 中的平滑技术

<sup>1)</sup> [https://www.nltk.org/\\_modules/nltk/translate/bleu\\_score.html](https://www.nltk.org/_modules/nltk/translate/bleu_score.html)

(平滑) [23] 计算  $n$ -gram=3 的 BLEU 得分, 简称为 BLEU-3。在每次测试的语料中生成 10 个回复, 然后计算出它们的 BLEU-3 分数。遵循 CVAE [5] 的做法, 本文将 10 个回复的 BLEU 平均值和最大值分别作为精确率  $P$  和召回率  $R$ 。

2) BOW Embedding (Bag-of-word Embedding): 计算预测回复与参考回复之间的词向量相似性。本文使用 3 个度量来计算词向量的相似度:

(1) 贪婪度量 [24]: 根据两个句子中的所有词的词向量两两匹配求余弦值, 并对得到的分数进行平均, 主要用于判断两个句子中各词的相似性。

(2) 平均度量 [25]: 两个句子中单词的词向量相加后再平均得到的余弦值, 适合用于判断整个句子的相似性。

(3) 极值度量 [26]: 在两个句子的词中最大的词向量之间的余弦距离。这种方法优先考虑信息量大的词语, 适合用于判断句子多样性。

本文使用 Glove 向量 [27] 作为词向量。对于每次测试推理, 本文在 10 个预测回答中取最大的 BOW Embedding 作为得分。

3) Distinct: 计算生成回复的多样性。Dist- $n$  被定义为生成回复中唯一  $n$ -gram ( $n=1, 2$ ) 与所有  $n$ -gram 的比值。本文将 Intra-Dist 和 Inter-Dist 分别定义为在单个回复内和不同回复内的比值。

### 4.3 基准与训练细节

本文将以往研究中使用相似评价方法的模型作为基线进行比较。相关基线模型包括: 1) CVAE [5], 具有单调 Beta 退火的基础 CVAE 模型; 2) MIRROR [10], 引入倒退推理并具有单个隐变量的 VAE 模型; 3) IVAE [28], 具有对偶形式 KL 散度的 VAE 模型; 4) DialogWAE [29], 将 KL 散度替换成 Wasserstein 距离并且结合了 GAN 的 VAE 模型; 5) DB-VAE [15], 引入两个词本并且对词本进行切分和预训练的 VAE 模型; 6) TWRWAE [30], 具有时间步正则化的 VAE 模型; 7) Optimus [12], 结合预训练语言模型的 VAE 模型。

本文将基线模型分成两类, 其中, CVAE 和 MIRROR 使用了传统的 KL 散度, 能引入 Beta 退火和 PID 控制权重, 所以将它们与 MLVBI 进行同条件实验; IVAE, DialogWAE, VAE, TWRWAE 和 Optimus 未采用传统的 KL 散度, 故结果均直接来源于各文献。

MLVBI 遵循 CVAE 和 TWRVAE 的实施细节, 3 个实验中的相同参数如表 2 所列, 其他参数如训练轮数等将在对应实验中列出。

表 2 实验的具体参数

参数名称	参数值
隐藏层维度	300
隐变量维度	200
词向量维度	200
初始权重采样	均匀分布 $[-0.02, 0.02]$
词汇表大小	10000
批大小	96
优化器	Adam Optimizer
学习率	$2 \times 10^{-4}$
权重衰减	$1 \times 10^{-5}$
最大句子长度	40
对话窗口大小	[3, 10]

### 4.4 实验一: 引入 beta 退火以获取 KL

在该实验中, MLVBI 将用简单的 beta 退火方法对 KL 值进行控制, beta 将从 0.1 开始, 随着每轮中的 batch 数缓慢变大, beta 逐渐保持在 1。

本实验将 CVAE [5], MIRROR [10], MLVBI 这 3 个模型分别训练 200 轮, 并对 KL 值的变化进行统计, 从图 7 可以直观地看出各模型 KL 值的收敛过程。图 7(a) 为 DailyDialog 数据集, 图 7(b) 为 PersonalChat 数据集。

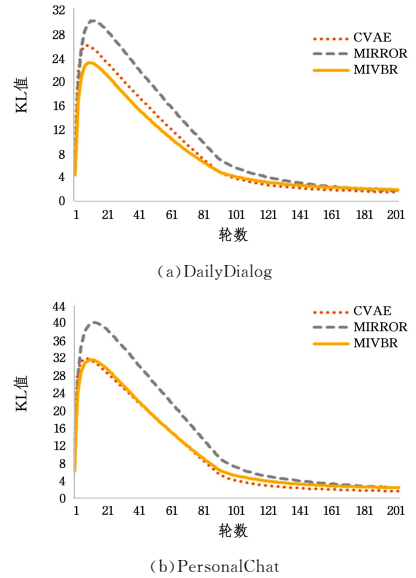


图 7 CVAE/MIRROR/MLVBI 在两个数据集上 KL 值的收敛过程

Fig. 7 Convergence process of KL value of CVAE/MIRROR/MLVBI on two datasets

在图 7 中, 3 个模型在两个数据集的曲线均呈现出先快速升高再缓慢下降的趋势。在初始阶段, 因为得到的信息很少, KL 值的增长速度很快。而在第十轮之后, 因为模型已经学到足够的信息, 所以逐渐趋于生成相同的回复, 并且 KL 值越来越小直至为 0, 即后验崩溃。而在具体数值上, 可以看到 MIRROR 的峰值最大, 下降的速度也最快; 而 MLVBI 的峰值最小, 下降更为平缓。从表 3 中也能看出, MIRROR 最后收敛的 KL 值略大于其他两个模型。

表 3 3 个模型 KL 的收敛值和合适的选取值

Table 3 Convergence value and appropriate selection value of KL value of three models

模型	DailyDialog			PersonalChat		
	$KL_{vae}$	最大 KL	合适 KL	$KL_{vae}$	最大 KL	合适 KL
CVAE	1.629	6.126	5	1.524	6.023	5
MIRROR	2.399	6.815	5	1.829	6.316	5
MLVBI	2.437	6.847	5	1.992	6.464	5

故通过分析图 7 可以得出结论: 虽然 3 个模型的 KL 变化趋势一致, 但与 CVAE 和 MIRROR 相比, MLVBI 的特征是最高值更小, 最低值更大, 下降曲线更缓。这证明了多个隐变量能学到更多信息。接下来, 为了使各模型避免受到后验崩溃的影响, 本文引入了 ControlVAE [18] 中的 PID。

ControlVAE 提出了收敛的 KL 值和合适的 KL 值之间

的关系,若用  $d(d>0)$  表示 KL 散度的最佳范围,  $KL_{vae}$  表示基本 VAE 收敛时 KL 散度的值,那么引入 PID 后的 KL 散度范围可以表示为:

$$0 \leq d \leq 2 + 2\sqrt{2KL_{vae} + 1} \quad (12)$$

因为生成回复的多样性很重要,当 KL 值越大,隐变量空间也越大且存储信息越多。但一般而言,生成回复的多样性与准确性之间存在一定的对抗。因此,根据式(12),本文不取理论最大值为合适的 KL 值,而是取最大值减 1 再往下取整后的值作为合适的 KL 值。对各模型计算并选择的 KL 值如表 3 所列,合适的 KL 值将被用于实验二中,作为超参数进行控制。

#### 4.5 实验二:引入 PID 得到最终结果

本实验根据实验一中的结果,引入 PID 控制各模型的 KL 值权重,将 KL 值稳定在合适的范围。从实验一可以得知 3 个模型的 KL 值将被控制在 5。在 3 个模型都引入 PID 后,分别训练 300 轮。训练结果如表 4 所列,粗体数字表示同一数据集中所有模型的最优值。

表 4 CVAE/MIRROR/MLVBI 在两个数据集上复现的结果

Table 4 Results of CVAE/MIRROR/MLVBI reproduced on two datasets respectively

评价指标	DailyDialog			PersonalChat		
	CVAE	MIRROR	MLVBI	CVAE	MIRROR	MLVBI
BLEU-R	0.378	0.403	<b>0.433</b>	<b>0.377</b>	0.367	0.376
BLEU-P	0.257	0.262	<b>0.276</b>	0.297	0.286	<b>0.301</b>
F1	0.306	0.318	<b>0.337</b>	0.333	0.322	<b>0.335</b>
Bow Gre	<b>0.877</b>	0.851	0.864	0.869	0.870	<b>0.875</b>
Bow Avg	0.955	0.954	<b>0.957</b>	0.954	0.952	<b>0.954</b>
Bow Ext	0.636	0.633	<b>0.653</b>	<b>0.608</b>	0.596	0.603
Intra Dist1	0.907	0.915	<b>0.918</b>	0.881	<b>0.914</b>	0.903
Intra Dist2	0.985	0.990	<b>0.991</b>	0.968	<b>0.986</b>	0.982
Inter Dist1	0.450	0.464	<b>0.483</b>	0.396	0.468	<b>0.463</b>
Inter Dist2	0.759	0.760	<b>0.804</b>	0.664	0.750	<b>0.762</b>

通过分析表 4 的结果,可以得出以下结论:

1) BLEU 指标表明, MLVBI 在两个数据集的召回率和 F1 值方面均处于领先地位, F1 值分别为 0.337 和 0.335, 综合准确率达到了最佳的效果。说明 MLVBI 能够在合适的数据集上生成更符合目标的响应。

2) BOW Embedding 指标表明, MLVBI 在两个数据集上的平均 BOW 值最佳, 并且贪婪 BOW 值和极值 BOW 值各有领先。这体现了 MLVBI 生成的句子具有最好的平均相似度, 整体相似性和多样性达到了与基线相当的效果。

3) Dist 指标表明, 3 个模型在句子层面上都能生成不同的词, 没有太大的差异。而在段落层面上, 通过生成 10 个回复, 更能看出模型的多样性。MLVBI 的多样性在两个数据集上最高, 证明 MLVBI 更能生成多样的回复, 生成的句子长度也更长。

对于 IVAE<sup>[27]</sup>, DialogWAE<sup>[28]</sup>, DB-VAE<sup>[29]</sup>, TWRVAE<sup>[30]</sup>, OPTIMUS<sup>[12]</sup> 这些模型, 由于它们仅在 DailyDialog 数据集上使用了相同的评价指标, 故本实验直接将它们的实验结果在 DailyDialog 数据集上与 MLVBI 进行比较。比较结果如表 5 所列, 粗体数字表示所有模型的最优值。

表 5 其他模型在 DailyDialog 上的结果

Table 5 Results of other models on DailyDialog

评价指标	DailyDialog					
	DialogWAE	IVAE	DB-VAE	TWRVAE	Optimus	MLVBI
BLEU-R	0.341	0.355	0.373	0.407	0.362	<b>0.433</b>
BLEU-P	0.278	0.239	0.276	0.281	<b>0.313</b>	0.276
F1	0.286	0.285	0.317	0.333	0.336	<b>0.337</b>
Bow Gre	0.846	<b>0.872</b>	0.839	0.865	—	0.864
Bow Avg	0.948	0.951	0.944	0.952	—	<b>0.957</b>
Bow Ext	0.578	0.609	0.615	0.603	—	<b>0.653</b>
Intra Dist1	0.830	0.897	<b>0.954</b>	0.921	—	0.918
Intra Dist2	0.940	0.975	<b>0.997</b>	0.990	—	0.991
Inter Dist1	0.327	<b>0.501</b>	0.467	0.497	—	0.483
Inter Dist2	0.583	<b>0.868</b>	0.787	0.817	—	0.804

通过分析表 5 的结果, 可以得出以下结论: 尽管 MLVBI 在某些指标上并不优于最先进基线, 但差异很小。从 BLEU 和 BOW Embedding 指标来看, MLVBI 的准确率优于所有基线, 特别是优于使用预训练语言模型的 Optimus, 证明 MLVBI 能生成更连贯的回复。而在 Dist 指标上, MLVBI 略差于 IVAE, 但是 IVAE 的准确率不高, 综合准确率和多样性来看, 这个差异是可以接受的。

总体来看, MLVBI 在这两个数据集上在大多数指标上相比基线模型均有较大的提升, 尤其是 BLEU 指标和 BOW Embedding 指标得到了显著改善, 并且在 Dist 指标上达到了与基线相当的效果。

#### 4.6 消融实验

本消融实验研究正向推理、反向推理、隐变量个数等因素对生成效果的影响。其中, 在推理层面分别只采用正向推理和反向推理, 即模型只包含一个方向的分步推理, 单步推理即为 CVAE。而在隐变量层面分别只用一个隐变量空间和两个隐变量空间, 前者指将隐状态  $C, X, Y$  共处一个隐变量空间, 后者指在正向两阶段和反向两阶段各用一个隐变量表示。本文将这些模型在 PersonalChat 数据集上分别训练 300 轮, KL 散度控制在 5, 其他参数与 4.3 小节一致。训练结果如表 6 所列。

表 6 消融实验

Table 6 Ablation experiment

评价指标	MLVBI(Forward+Reverse+Z*4)				
	ALL	Forward+ z*2	Reverse+ z*2	F+R+ z*2	F+R+ z*1
BLEU-R	0.376	0.381	0.364	0.370	0.366
BLEU-P	0.301	0.303	0.292	0.289	0.286
F1	0.335	0.337	0.325	0.325	0.321
Bow Gre	0.875	0.878	0.867	0.872	0.867
Bow Avg	0.954	0.955	0.950	0.952	0.952
Bow Ext	0.603	0.609	0.581	0.595	0.593
Intra Dist1	0.903	0.894	0.919	0.917	0.913
Intra Dist2	0.982	0.978	0.976	0.977	0.980
Inter Dist1	0.463	0.436	0.459	0.420	0.472
Inter Dist2	0.762	0.730	0.755	0.659	0.754

通过分析表 6 的结果, 可以得出如下结论:

1) 在推理层面, 仅正向推理模型的 BLEU 值和 BOW Embedding 值较高, 但是 Dist 较低; 仅反向推理的模型 Dist 尚可, 但是 BLEU 和 BOW Embedding 较低。说明在正向推理中, 因为模型推断回复的顺序与训练时一致, 所以模型更能

生成相近且单调的回复。而在反向推理中,因为模型相当于只是在学习上文信息,所以模型更能生成多样的回复。因此结合了正向和反向推理的 MLVBI 在 BLEU 和 BOW Embedding 上处于较高水平且在 Dist 上处于最优,在准确性和多样性上取得了均衡,满足同时提高准确性和多样性的目标。

2)在隐变量层面,有两个隐变量空间的模型与有一个隐变量空间的模型相比,准确率更高、多样性更低,但与 MLVBI 相比仍有一定差距。从结果上看,MLVBI 在所有指标上都处于最优,证明 MLVBI 的多隐变量能学习到更多信息,更能生成多样和连贯的回复。

**结束语** 为了解决从对话上文信息进行单向推断不能生成高质量回复和在双向推理中单个隐变量解释性不足的问题,本文提出了一个基于多隐变量的双向推理模型 MLVBI。MLVBI 结合了正向推理和反向推理,并且在每个推理步骤中都加入了隐变量。本文进行了 3 个实验,MLVBI 在生成回复的大部分指标上都获得了比所有基线更好的结果,证明 MLVBI 可以生成更相关的、更丰富的回复。

在下一步工作中,一方面将继续研究变分自编码器与预训练语言模型的结合,另一方面将研究对后验崩溃的处理并提升模型的效果。

## 参 考 文 献

- [1] SUTSKEVER I, VINYALS O, LE Q V. Sequence to sequence learning with neural networks[C]//Proceedings of the 27th International Conference on Neural Information Processing Systems (Volume 2). 2014;3104-3112.
- [2] 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. 2017; 6000-6010.
- [3] ORIOL V, QUOC V L. A neural conversational model [J]. arXiv:1506.05869,2015.
- [4] LI J, GALLEY M, BROCKETT C, et al. A Diversity-Promoting Objective Function for Neural Conversation Models[C]//Proceedings of NAACL-HLT. 2016;110-119.
- [5] BAHETI A, RITTER A, LI J, et al. Generating More Interesting Responses in Neural Conversation Models with Distributional Constraints[C]//Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. 2018;3970-3980.
- [6] ZHAO T, RAN Z, ESKENAZI M. Learning Discourse-level Diversity for Neural Dialog Models using Conditional Variational Autoencoders[C]//Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). 2017;654-664.
- [7] BOWMAN S R, VILNIS L, VINYALS O, et al. Generating sentences from a continuous space[C]//20th SIGNLL Conference on Computational Natural Language Learning (CoNLL 2016). Association for Computational Linguistics (ACL), 2016; 10-21.
- [8] FENG S, REN X, CHEN H, et al. Regularizing Dialogue Generation by Imitating Implicit Scenarios[C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). 2020;6592-6604.
- [9] ZHOU W, LI Q, LI C. Learning from Perturbations; Diverse and Informative Dialogue Generation with Inverse Adversarial Training[C]//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing (Volume 1: Long Papers). 2021;694-703.
- [10] LI Z, KISELEVA J, DE RIJKE M. Improving response quality with backward reasoning in open-domain dialogue systems[C]//Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. 2021; 1940-1944.
- [11] BAO S, HE H, WANG F, et al. PLATO-2: Towards Building an Open-Domain Chatbot via Curriculum Learning[C]//Findings of the Association for Computational Linguistics: ACL (IJCNLP 2021). 2021;2513-2525.
- [12] LI C, GAO X, LI Y, et al. Optimus: Organizing Sentences via Pre-trained Modeling of a Latent Space[C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). 2020;4678-4699.
- [13] KINGMA D P, WELING M. Auto-encoding variational bayes [J]. arXiv:1312.6114,2013.
- [14] SUN B, FENG S, LI Y, et al. Generating Relevant and Coherent Dialogue Responses using Self-Separated Conditional Variational AutoEncoders[C]//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing (Volume 1: Long Papers). 2021;5624-5637.
- [15] ZHAO Y, YU P, MAHAPATRA S, et al. Improve Variational Autoencoder for Text Generation with Discrete Latent Bottleneck[J]. arXiv:2004.10603,2020.
- [16] YOOKOON P, JAEMIN C, AND GUNHEE K. A hierarchical latent structure for variational conversation modeling [C]//Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics; Human Language Technologies, New Orleans, Louisiana. Association for Computational Linguistics. 2018;1792-1801.
- [17] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8):1735-1780.
- [18] SHAO H, XIAO Z, YAO S, et al. ControlVAE: Tuning, Analytical Properties, and Performance Analysis[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2021, 44 (12): 9285-9297.
- [19] LI Y, SU H, SHEN X, et al. DailyDialog: A Manually Labelled Multi-turn Dialogue Dataset[C]//Proceedings of the Eighth International Joint Conference on Natural Language Processing (Volume 1: Long Papers). 2017;986-995.
- [20] ZHANG S, DINAN E, URBANEK J, et al. Personalizing Dialogue Agents: I have a dog, do you have pets too? [C]//Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). 2018;2204-2213.
- [21] PAPANENI 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. Association for Computational Linguistics, 2002;311-318.
- [22] LIU C W,LOWE R,SERBAN I V,et al. How not to evaluate your dialogue system: An empirical study of unsupervised evaluation metrics for dialogue response generation[C]// Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing. 2016;2122-2132.
- [23] CHEN B,CHERRY C. A systematic comparison of smoothing techniques for sentence level BLEU[C]// Proceedings of the Ninth Workshop on Statistical Machine Translation. 2014;362-367.
- [24] RUS V,LINTEAN M. A Comparison of Greedy and Optimal Assessment of Natural Language Student Input Using Word-to-Word Similarity Metrics[C]// Proceedings of the Seventh Workshop on Building Educational Applications Using NLP. Association for Computational Linguistics, 2012;157-162.
- [25] LAPATA M,MITCHELL J. Vector-based models of semantic composition[C]// Proceedings of ACL-08: HLT. 2008;236-244.
- [26] FORGUES G,PINEAU J,LARCHEVÊQUE J M,et al. Bootstrapping dialog systems with word embeddings[C]// Nips, Modern Machine Learning and Natural Language Processing Workshop. 2014;168-173.
- [27] PENNINGTON J,SOCHER R,MANNING C. Glove:Global Vectors for Word Representation[C]// Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing(EMNLP). 2014;1532-1543.
- [28] FANG L,LI C,GAO J,et al. Implicit Deep Latent Variable Models for Text Generation[C]// Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing(EMNLP-IJCNLP). 2019;3946-3956.
- [29] GU X,CHO K,HA J W,et al. Dialogwae: Multimodal response generation with conditional Wasserstein auto-encoder[C]// 7th International Conference on Learning Representations. 2019; 2-12.
- [30] LI R,LI X,CHEN G,et al. Improving Variational Autoencoder for Text Modelling with Timestep-Wise Regularisation[C]// Proceedings of the 28th International Conference on Computational Linguistics. International Committee on Computational Linguistics, 2020;2381-2397.



**ZHAO Yanbin**, born in 1998, master. His main research interests include natural language processing and multi-turn dialogue.



**SU Jindian**, born in 1980, Ph. D, associate professor. His main research interests include deep learning and natural language processing.

(责任编辑:何杨)