

基于强化学习和注意力机制的朝鲜语 文本结构发现

赵亚慧, 杨飞扬, 张振国, 崔荣一

(延边大学 计算机科学与技术系, 吉林 延吉 133002)

摘 要:将注意力机制与深度强化学习相结合,利用标签信息研究如何自主学习出有效的朝鲜语文本结构化表示,提出了两种结构化表示模型:信息蒸馏注意力模型(ID-Attention)和层次结构注意力模型(HS-Attention)。ID-Attention选择与任务相关的重要单词,而HS-Attention在句中发现短语结构。两种表示模型中的结构发现是一个顺序决策问题,使用强化学习中的Policy Gradient实现。实验结果表明:ID-Attention能够识别朝鲜语重要单词;HS-Attention能够很好地提取出句子结构,在文本分类任务上有很好的性能表现,同时,两模型的结果对语料库的标注有很好的辅助作用。

关键词:人工智能;深度强化学习;注意力机制;文本结构发现;朝鲜语自然语言处理

中图分类号:TP391.1 **文献标志码:**A **文章编号:**1671-5497(2021)04-1387-09

DOI:10.13229/j.cnki.jdxbgxb20200358

Korean text structure discovery based on reinforcement learning and attention mechanism

ZHAO Ya-hui, YANG Fei-yang, ZHANG Zhen-guo, CUI Rong-yi

(Department of Computer Science & Technology, Yanbian University, Yanji 133002, China)

Abstract: In this paper, attention mechanism is combined with deep reinforcement learning, and label information is used to study how to learn effective Korean language text structured representation independently. Two structured representation models are proposed, which are called Information Distilled Attention (IDA) and Hierarchically Structured Attention (HSA). IDA selects the important words related to the task, and HSA finds the phrase structure in the sentence. The structural discovery in both presentation models is a sequential decision problem that can be implemented using Policy Gradient (PG) in reinforcement learning. The experimental results show that the proposed IDA can recognize the important words of Korean, and HSA can extract the sentence structure well, and have good performance in the task of text classification. At the same time, the results of the two models have a good auxiliary effect on corpus tagging.

Key words: artificial intelligence; deep reinforcement learning; attention mechanism; text structure

收稿日期:2020-05-22.

基金项目:国家语委科研项目(YB135-76);延边大学外国语言文学一流学科建设项目(18YLPY13).

作者简介:赵亚慧(1974-),女,教授.研究方向:自然语言文本处理. E-mail:yhzhaoy@ybu.edu.cn

通信作者:张振国(1981-),男,讲师,博士.研究方向:机器学习,数据挖掘. E-mail:zgzhang@ybu.edu.cn

discovery; Korean natural language processing

0 引言

表征学习是人工智能领域中的一个基本问题,对于自然语言处理(NLP)尤其重要^[1]。表征学习在文本分类、情感分析、问题分类和语言推理等领域具有广泛的应用^[2]。目前,我国在朝鲜语自然语言处理研究方面还处于发展阶段,相对于韩国乃至朝鲜还比较滞后。现阶段朝鲜语语言资源建设还没有统一的规划和布局,各家资源难以融合,对相关研究有很大的限制,从知识产权及夺取信息优势的角度来看,我国对于朝鲜语信息化建设还未给予足够重视^[3]。因此,本文以朝鲜语为研究对象,构建了其文本结构化并进行了文本分类任务,其结构化表示无需人工标注,大大减少了人力,节省了研究资源。

用于文本分类的主流表示模型大致可以分成词袋表示模型、序列表示模型、结构表示模型、注意力模型 4 种类型。其中,词袋表示模型往往会忽略单词的顺序,例如深度平均网络、自编码器模型^[4];序列表示模型往往只考虑了单词本身,却忽视了短语结构,例如 CNN、RNN 等神经网络模型^[5];结构表示模型往往依赖预先指定的解析树来构建结构化表示,例如 Tree-LSTM、递归自编码器等^[6];基于注意力机制的表示模型需要对输入的单词或句子利用注意力打分函数来构建表示形式,例如 Self-Attention 等^[7],效果非常依赖打分的可靠性。在现有的结构化表示模型中,可以将结构作为输入,也可以使用显式树注释的有监督方法来预测,却很少有研究对具有自动优化结构的表示进行学习,Yogatama 等^[8]提出仅在下流任务的监督下,为句子表示构建二叉树结构,但是这种结构非常复杂而且深度过大,导致分类性能不理想,Chung 等^[9]提出了一种分层表示模型来捕获具有潜在语义的序列潜在结构,但结构只能在隐空间中被发现。Zhang 等^[10]提出了一种将强化学习中策略梯度与深度学习中 LSTM 模型结合在一起的方法,将文本分类的结果作为强化学习策略选择的反馈信息,进行文本的结构化学习,其结构化效果更接近于人类,并且对于文本分类任务有很好的效果。

本文将柔性注意力机制引入到深度强化学习

中,提出了通过识别与任务相关的结构,而无需人工标注来构建句子的表示模型。模型中结构发现问题被转化为一个序列决策问题,利用强化学习中策略梯度方法(Policy gradient),将延迟的 reward 函数值用于指导结构自我发现的学习, reward 函数的定义根据结构化表示在同一文本分类器的分类效果得出,每次得到的结构化表示需要在所有顺序决策都完成后才可以使用,该模型在前人的基础上加入了注意力机制以及强化学习收敛的基线,使其收敛速度与模型效果得以优化。本文设计了两种朝鲜语文本结构化表示的模型: ID-Attention 模型和 HS-Attention 模型。在 ID-Attention 模型中,删去文本中不重要的单词,使用与任务最相关的词构建句子表示形式;在 HS-Attention 模型中,发现短语结构并使用单词级-短语级的层次结构模式构建句子的表示形式。在整个模型框架中策略网络、结构化表示、分类网络三者无缝集成,策略网络用于发现结构的策略,分类网络在结构化句子表示的基础上进行分类准确率计算,并将结果作为 reward 传递给策略网络促进整个网络模型自我优化。

1 结合注意力机制的强化学习策略网络

策略网络的核心思想是 Policy Gradient^[11],与传统方法不同,这里不通过误差进行反向传播,而是以观测 reward 值对选择动作的可能性进行增强或减弱,即,好的动作下一次被选中的概率会增大,不好的动作会下一次被选中的概率会减小。一个完整的策略代表在一个回合中,对每个状态下所采取的动作构成的序列,而每个动作产生的回报的累计总和代表一个回合的 reward 值。

本文采用随机策略 $\pi(a_t|s_t; \theta)$,并使用每一个回合延迟产生的 reward 来指导策略学习,对生成的结构化模型的每个状态所对应的动作进行采样,其中 s_t 表示当前时刻下的状态; a_t 表示当前状态下对应的动作; π 表示概率; θ 表示模型参数。首先,对整个句子的所有单词都要进行动作采样,从而确定一个句子所对应的所有状态的动作;其次,将确定的动作序列传入表示模型,生成新的结构化表示;然后将生成的结构化表示传入分类网

络,使用此表示模型计算分类准确率 $P(y|X)$,其中 y 为分类的标签; X 表示输入的文本;最后,用 $P(y|X)$ 计算的reward用于策略学习。通过循环迭代,找到较好的策略,从而得到较好的结构化表示,进而得到更好的分类效果。策略定义如下:

$$\pi(a_t|s_t; \Theta) = \sigma(W^*s_t + b) \quad (1)$$

式中: $\pi(a_t|s_t; \Theta)$ 为选择 a_t 的概率; σ 为sigmoid函数; $\Theta = \{W, b\}$ 为策略网络的参数,其中 W, b 分别表示策略网络中的矩阵权重与参数。

在训练期间,根据式(1)中的概率对动作进行采样,在测试过程中,选择具有最大概率的动作,从而达到更好的分类效果,即

$$a_t^* = \operatorname{argmax}_a \pi(a|s_t; \Theta) \quad (2)$$

在所有动作被策略网络采样时,句子的结构化表示由表示模型确定,将确定的表示模型传递给分类网络以获得 $P(y|X)$,reward将从预测的分布中被计算出来。结合强化学习算法中的Policy Gradient方法优化策略网络的参数^[12],从而达到最大化预期收益,如下所示:

$$\begin{aligned} J(\Theta) &= \mathbb{E}_{(s_t, a_t) \sim P_{\Theta}(s_t, a_t)} r(s_1 a_1 \cdots s_L a_L) = \\ &= \sum_{s_1 a_1 \cdots s_L a_L} P_{\Theta}(s_1 a_1 \cdots s_L a_L) R_L = \\ &= \sum_{s_1 a_1 \cdots s_L a_L} p(s_1) \prod_t \pi_{\Theta}(a_t|s_t) p(s_{t+1}|s_t, a_t) R_L = \\ &= \sum_{s_1 a_1 \cdots s_L a_L} \prod_t \pi_{\Theta}(a_t|s_t) R_L \end{aligned} \quad (3)$$

式中: $\mathbb{E}$ 表示当前策略下的数学期望; R_L 表示随环境变化的累计反馈值。

此reward计算仅针对一个回合得出,因为在步骤 $t+1$ 的状态完全由步骤 t 的状态决定,因此概率 $p(s_1)$ 与 $p(s_{t+1}|s_t, a_t)$ 为1。通过似然比技巧,最终使用以下梯度更新策略网络^[13],如下所示:

$$\nabla_{\Theta} J(\Theta) = -\frac{1}{N} \sum_{n=1}^N \sum_{t=1}^L (R_L - b) \nabla_{\Theta} \log \pi_{\Theta}(a_t|s_t) \quad (4)$$

式中: N 为回合数, $b \approx E[R_L]$,在强化学习的迭代过程中,方差一般较大,loss值若一直是正的,则迭代方向容易朝着错误的方向一直进行,因此引入 b 后可加速收敛。

在此基础上,在策略网中引入注意力机制,使用Bi-LSTM^[14]作为encoder模型,将结构化表示模型的输出作为策略网络的输入,记忆单元设置

了传统的3种门结构,即遗忘门 f_t 、输入门 i_t 和输出门 O_t ,用于记录和更新,其中各个门更新状态如下:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (5)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (6)$$

$$z_t = \tanh(W_z \cdot [h_{t-1}, x_t] + b_z) \quad (7)$$

$$V_t = f_t \otimes V_{t-1} + i_t \otimes z_t \quad (8)$$

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (9)$$

$$h_t = O_t \otimes \tanh(V_t) \quad (10)$$

式中: x 为输入数据; h 为前后两个方向LSTM的单元输出; V 为记忆细胞单元值; z_t 为补给主线记忆的强度; σ 表示激活函数。

在Bi-LSTM的基础上引入注意力机制,模型由从局部得到每个单词所对应的动作序列,优化为从整个句子得到对应的动作序列。

因为注意力模型的核心逻辑就是从关注整体到关注重点,这一核心与本文的目的的一致,故将强化学习与Soft Attention机制结合,来弥补前人在传统注意力模型进行文本分类过程中,十分依赖打分函数的不足^[15]。在引入注意力机制后,输出每个状态下对应的动作如图1所示。




图1 柔性注意力机制

Fig. 1 Soft attention

$$S_t = f(S_{t-1}, Y_{t-1}, C_t) \quad (11)$$

$$C_t = \sum_{j=1}^T \alpha_{tj} h_j \quad (12)$$

$$\alpha_{tj} = \frac{\exp(e_{tj})}{\sum_{k=1}^T \exp(e_{tk})} \quad (13)$$

$$e_{tj} = g(S_{t-1}, h_j) \quad (14)$$

式中: h_j 为输入的隐向量; f 为激活函数; C_t 为注意力分布; α_{tj} 为每个输入获取的注意力。

在引入注意力机制后,表示模型能够更好地

对全局进行观测,从而使得产生的动作序列在策略梯度与注意力机制这两个方面得到优化,进而提升模型效果。

2 朝鲜语文本结构化表示模型

2.1 主要思路

朝鲜语属于典型的黏着语语种,而黏着语的特点是具有一定意义的附加成分接在词根上构成形态变化,但结合不紧。朝鲜语语法关系和结构由语言成分的自由组合表示,词根与附加成分本身一般无变化,按一定顺序黏着起来组合成词,所以不同于常见的孤立语和屈折语的处理方式。采用隔写之后许多虚词成分往往是构成短语句子的重要成分,所以朝鲜语句子的结构划分是语言信息化处理的难点。针对这一难点,本文建立的模型可以在无需人工标注的条件下,有效地规避词

根与词缀的分离或连接错误。本文通过发现重要的、与任务相关的结构来学习和得到用于朝鲜语文本分类的结构化表示,通过优化的结构化表示改善文本分类的结果,在分类性能得到改善的同时,结构化表示也得到优化,二者相互促进,此增彼长。模型包含 3 个部分:策略梯度网络、结构化表示模型、分类网络,其中策略网络采取随机策略对每个状态对应的动作进行抽样,一直采样至句尾,为当前句子生成一个动作序列。表示模型将动作序列转化为结构化表示,分类网络基于得到的结构化表示进行分类,并为策略网络提供 reward 函数计算,由于一个完整的结构化表示给出后就可以计算当前结构化表示的 reward,因此可以通过 Policy Gradient 方法求解此过程。具体模型如图 2 所示。




图 2 基于强化学习的网络模型结构图

Fig. 2 Network model structure diagram based on reinforcement learning

此模型由 3 个部分交错在一起,策略网络的状态表示形式来自结构化模型,结构化模型由策略网络的动作序列与句子的输入所生成,分类网络由最终生成的结构化模型进行分类预测,策略网络从分类网络得到的分类效果获取 reward 值,从而指导策略学习更好的结构化表示。

2.2 识别句子中重要单词的 ID-Attention 模型

受文献[10]中的 ID-LSTM 启发,在原有的策略网络里引入注意力机制,其中注意力机制能够关注到朝鲜语单词的重要程度,从而影响动作序列做出更好的动作,其优势在于弥补了强化学习本身难以拟合的天然缺陷,节省了训练时间,同时与策略梯度下降结合,双重优化动作序列。ID-Attention 的主要出发点是通过提取重要的单

词,并删除句中不相关的单词来建立句子的结构化表示。在熟知的中英文文本处理任务中,存在很多例如:“的”、“和”、“in”、“of”等停用词,此类停用词很少会有助于完成文本处理任务,所以提炼句子中重要的特征是有必要的。与之不同的是,本方法不建立朝鲜语停用词表,将所有停用词一并删去。因为语言本身与中英文不同,其中大量虚词是构成单词的重要部分,许多停用词往往会构成特殊的短语结构,梳理前、后文逻辑关系,删去部分虚词会影响朝鲜语文本本身的含义,造成语言内容、语义信息的丢失,故在处理朝鲜语文本时并不需要剔除停用词,用甄别句子中重要单词的方式将句子浓缩并突出重点,以提升分类任务的效果。

ID-Attention 将策略网络传递来的动作序列

转化为的句子结构化表示:给定一个句子 $X(X=x_1x_2\cdots x_L)$,将句子 X 传入策略网络后,单词位置 x_i 上对应的每个动作 a_i 是从保留当前单词或删除当前单词中选择的,满足以下规则:

$$S_t, C_t = \begin{cases} S_{t-1}, C_{t-1}, & a_t = Delete \\ \Phi(S_{t-1}, C_t, Y_{t-1}), & a_t = Retain \end{cases} \quad (15)$$

式中: Φ 为整个模型的功能(包括门控单元与更新函数等); S 为Decoder细胞单元对应的隐状态; Y 为细胞单元对应隐状态的输出; C 为Encoder细胞单元的隐状态分布;当删除一个词时,会从前一个位置复制当前位置的存储单元和隐状态注意力分布。

为完成分类任务,将ID-Attention的最后一个隐状态作为分类网络的输入,如下式所示:

$$P(y|X) = \text{softmax}(W_s S_L + b_s) \quad (16)$$

式中: $W_s \in \mathbb{R}^{d \times K}$, $b_s \in \mathbb{R}^K$ 为分类网络的参数; d 为隐状态的维度; $y \in \{c_1, c_2, \dots, c_K\}$ 为类别的标签, K 为分类簇数。

分类网络使用从ID-Attention获得的结构化表示,在类标签上产生概率分布,为计算reward,取式(16)中分类网络计算得出的输出概率的对数,如式(17)所示,其中 c_g 代表分类标签。为了使模型尽量使用更少的单词,通过计算句子中删除单词的数量与句子长度的比值来控制式中两项相互牵制,使保持准确率与使用少量词这两种效果相平衡,其中 L' 代表删除的单词数, γ 代表平衡两项的超参数。

$$R_L = \log P(c_g|X) + \gamma L'/L \quad (17)$$

ID-Attention整体模型如图3所示。




图3 ID-Attention模型

Fig. 3 ID-Attention model

对朝鲜语文本进行单词识别后,只保留重要单词,保留的数量与删去的数量的比值由reward函数控制。

2.3 识别重要结构的HS-Attention模型

分层模型已经广泛应用于分类任务,如Tang等^[16]的门控递归神经网络与Chung等^[17]的分层多角度语言模型,本文提出了层次结构的HS-Attention,通过发现句子中的层次结构来构建结构化表示。引入注意力机制后能够更好地覆盖到短语的关注度,注意力机制能够辅助强化学习更快地拟合,不但可以提升学习效率,而且随机策略梯度下降在短语连接方式的关注度受到改变后,能够更容易获取到连接更合理的短语结构,从而起到优化整体模型的作用。HS-Attention将动作转化为句子的层次结构表示,构成新划分的结构或片段。在HS-Attention中,有两级结构:单词级Attention,连接单词序列形成一个短语表示;短语

级Attention,连接短语形成一个句子表示。通过对每个单词位置设置相应的判定动作实现采样,即判断单词在短语结构的内部还是结尾。

单词级Attention的转换取决于动作 a_{t-1} ,如果动作 a_{t-1} 是认为当前位置在短语末尾,则位置 t 处的单词为下一个短语的开头,其他情况则认为当前位置在短语中间。在此基础上连接前项的状态,单词级Attention从初始化状态开始,整个过程如式(18)所示:

$$S_t^w, C_t^w = \begin{cases} \Phi^w(0, 0, Y_{t-1}^w), & a_{t-1} = End \\ \Phi^w(S_{t-1}^w, C_{t-1}^w, Y_{t-1}^w), & a_{t-1} = Inside \end{cases} \quad (18)$$

式中: Φ^w 为单词级Attention的结构函数; S 为Decoder细胞单元对应的隐状态; Y 为细胞单元对应隐状态的输出; C 为Encoder细胞单元的隐状态分布。

从单词级到短语级 Attention 的过渡取决于当前位置的动作 a_t , 当 a_t 为 *End* 时, 短语在位置 t 结束, 表示短语已构建完成。单词级 Attention 的隐状态将传递到短语级 Attention, 其他情况则认为采用 *Inside* 操作, 在此操作中固定短语级 Attention, 并从前项复制变量, 整个过程如式 (19) 所示:

$$S_t^p, C_t^p = \begin{cases} \Phi^p(S_{t-1}^p, C_{t-1}^p, Y_{t-1}^p), & a_t = \text{End} \\ S_{t-1}^p, C_{t-1}^p, & a_t = \text{Inside} \end{cases} \quad (19)$$

式中: Φ^p 为短语级 Attention 结构函数, 将单词级 Attention 的隐状态 C_t^w 作为输入, HS-Attention 的运转依赖于 a_{t-1} 和 a_t 。

为进行分类任务, 与 ID-Attention 相似, 将短语级 Attention 的最后一个隐状态作为分类网络的输入, 分类网络以从 HS-Attention 获得的结构化表示为输入, 利用分类标签信息过程如下:

$$P(y|X) = \text{softmax}(W_s S_L^p + b_s) \quad (20)$$

同样, 基于分类网络的分类效果来预测表示结构的选择趋势, 与 ID-Attention 不同的是, HS-Attention 模型着重于短语结构。一个标准的句子应该包含不能过多也不能过少的短语结构, 因此, 采用短语数量的单峰函数来反映结构选择的趋势, 使用函数 $f(x) = 1.2x + 0.1/x$ 。具体 reward 计算如下所示:

$$R_L = \log P(c_g|X) - \gamma(1.2L'/L + 0.1L/L') \quad (21)$$

式中: 第二项的目的是保证分类的准确率的同时, 根据朝鲜语本身特点, 尽量保持词组数为句子长度的 0.3 倍左右, 即在句子长度 $L=10$ 时, 尽量满足有两到三个词组在这个句子中被发现, 这与使用的朝鲜语数据语言本身的特点有关。

HS-Attention 整体模型如图 4 所示。




图 4 HS-Attention 模型

Fig. 4 HS-Attention model

在切分朝鲜语句子时利用 reward 函数控制切分的大小, 切割出的每个部分为朝鲜语词组或句子的断句处, 无需人工显式标注也可以获取划分短语断句的句子结构。

2.4 模型训练

在训练分类网络时, 采用交叉熵损失函数, 其中 $\hat{p}(y, X)$ 为 one-hot 编码对应句子的标签的概率分布, 如下所示:

$$\mathcal{L} = - \sum_{X \in \mathcal{D}} \sum_{y=1}^K \hat{p}(y, X) \log P(y|X) \quad (22)$$

在表示模型中词向量初始化时, 使用 GloVe 训练词向量^[18], 维度设置为 200 维, 并与其他参数一同更新。在用梯度下降法做参数更新时, 模型学习的速度取决于学习率与偏导值, 为平滑 Policy Gradient 的更新, 将抑制因子 γ 乘以式 (4) 并设

置为 0.1, γ 在 ID-Attention (即式 (18)) 中设置为 0.2, γ 在 HS-Attention (即式 (22)) 中设置为 0.3, 在训练过程中使用 Adam 优化器^[19]来优化参数, 学习率为 0.0005, 在分类网络分类前采用 Dropout 剪裁, 概率为 0.5, mini-batch 为 5。

由于表示模型与分类网络部分交织在一起, 因此应先进行联合训练, 首先对结构化模型与分类网络进行训练, 然后再引入策略网络共同训练, 直至收敛。由于从头开始训练强化学习比较困难, 方差很大, 因此要采用一些预热结构对强化学习模块进行预训练, 对于 ID-Attention, 利用原始句子进行预训练; 对于 HS-Attention, 将句子拆分为长度很小的基本短语 (一般小于句子长度的平方根)。与预先需要人工解析结构完全不同, 因此本方法泛化能力更强, 对数据的限制更少。

3 实验结果及分析

3.1 数据集说明

本文实验所用的数据集来源于本实验室承担“中韩科技信息加工综合平台”项目构建的语料^[20],将其进一步整理成朝鲜语科技文献摘要构成的语料文档32 688篇,分为动物、海洋、航天等13个类别,其中各类别按8:1:1的比例随机选取文档形成训练集、测试集和验证集。数据集详情如表1所示。

表1 朝鲜语文本数据集基本信息

Table 1 Details of Korean text dataset

类别	词条数	类别	词条数
动物	4582	植物	6172
微生物	5472	生物技术	1215
生物医学	2752	气候	708
海洋环境	810	地质	1735
海洋技术	819	材料工程	781
测控技术	1728	航天	4436
其他	1478		

对于朝鲜语语料,句子是由空格分隔的短语构成,这些短语后面一般黏着助词或终结词尾。根据朝鲜语的语法特性,在预处理过程中,使用韩国科技大学开发的Hannanum分词系统切分出短语中的助词和终结词尾,并将谓词还原成词语本身。

3.2 训练细节及对比实验

在模型训练过程中,使用ID-Attention与HS-Attention所得到的文本结构对分类准确率的影响随迭代次数变化如图5所示,两种模型的文本分类正确率在训练初期都在68%左右,正确率随着迭代次数的增加而提高。迭代次数在400到600次之间,模型的分类正确率上升最快,在迭代800次后多语种文本分类正确率趋于稳定,此时ID-Attention模型的文本分类的正确率达到了84.84%,而HS-Attention模型的文本分类的正确率达到了85.11%。

ID-Attention模型与HS-Attention模型在朝鲜语文本分类时的整体损失函数随迭代次数的增加不断下降,以HS-Attention为例,得到图6的变化曲线。采用交叉熵作为损失函数,随着迭代次数的增加损失函数值趋于稳定,损失函数值越小,预测的概率分布与标签的概率分布的差异性越小,模型的准确率随之提高。

为了验证方法的有效性,将本文与以下方法




图5 ID-Attention模型与HS-Attention模型训练过程

Fig. 5 Training process of ID-Attention and HS-Attention




图6 HS-Attention损失函数值变化图

Fig. 6 Changes in HS-Attention loss function value

进行实验对比:不使用特定结构的基本神经网络模型CNN、LSTM;Bi-LSTM;经过主题模型改良的神经网络叠加模型T-BLSTM-CNN^[21],机器翻译模型MT;注意力模型Self-Attention^[22,23],强化学习模型ID-LSTM、HS-LSTM。模型所使用的词向量维度与本文相同,分类结果对比见表2。

表2 不同分类模型下的准确率

Table 2 Accuracy under different classifiers models

模型	准确率/%	模型	准确率/%
CNN	78.50	Self-Attention	82.91
LSTM	74.60	ID-LSTM	82.11
Bi-LSTM	78.14	HS-LSTM	83.65
MT	76.50	ID-Attention	84.84
T-BLSTM-CNN	81.68	HS-Attention	85.11

分类效果表明:在不同的模型中,本方法分类效果表现出色,与ID-LSTM比较,分类准确率提升2.73%;与HS-LSTM比较,分类准确率提升1.46%。与只注重序列模型及其优化不同,本文

从强化学习与注意力两个方面设计模型,实验结果也证明了文本结构化的有效性与必要性。

3.3 结构化表示结果实例

为了更清晰地展示模型发现的句子结构,本

文以 3 个不同类别的朝鲜语文本为例,分别经过 ID-Attention 和 HS-Attention 模型后,句子结构化的文本表示如表 3 所示。

表 3 ID-Attention 与 HS-Attention 结构表示实例

Table 3 Examples of structures distilled and discovered by ID-Attention and HS-Attention

原始文本	도시는 인류 활동의 영향을 가장 크게 받는 지구의 표면 이고 도시 시스템의 탄소 순환은 세계 및 지역의 탄소 순환에서 중요한 위치와 역할을 한다(城市是受人类活动影响最大的地球表面,城市系统的碳循环在世界及地区的碳循环中具有重要的位置和作用。)
ID-Attention	도시는 인류 활동의 영향을 가장 크게 받는 지구의 표면 이고 도시 시스템의 탄소 순환은 세계 및 지역의 탄소 순환에서 중요한 위치와 역할을 한다
HS-Attention	도시는 인류 활동의 영향을 가장 크게 받는 지구의 표면 이고 도시 시스템의 탄소 순환은 세계 및 지역의 탄소 순환에서 중요한 위치와 역할을 한다
原始文本	곤충 병원체에서 직접 샘플을 채취하고 검출 및 정량화하는 것은 곤충 유행병학 조사에서 병원체 풍도를 직접 반영할 수 있다(从昆虫病原直接取样,检出及量化可直接反映昆虫流行病学调查中病原丰度)
ID-Attention	곤충 병원체에서 직접 샘플을 채취하고 검출 및 정량화하는 것은 곤충 유행병학 조사에서 병원체 풍도를 직접 반영할 수 있다
HS-Attention	곤충 병원체에서 직접 샘플을 채취하고 검출 및 정량화하는 것은 곤충 유행병학 조사에서 병원체 풍도를 직접 반영할 수 있다
原始文本	온실가스 배출 인벤토리는 현재 도시 탄소의 배출량을 계산하는데 가장 많이 이용되는 기법이며 서로 다른 산업 혹은 영역에서 온실가스 배출 현황을 연구하는데 도움이 된다(温室气体排放清单是目前计算城市碳排放量最常用的机理,并有助于在不同的产业或领域研究温室气体排放现状)
ID-Attention	온실가스 배출 인벤토리는 현재 도시 탄소의 배출량을 계산하는데 가장 많이 이용되는 기법이며 서로 다른 산업 혹은 영역에서 온실가스 배출 현황을 연구하는데 도움이 된다
HS-Attention	온실가스 배출 인벤토리는 현재 도시 탄소의 배출량을 계산하는데 가장 많이 이용되는 기법이며 서로 다른 산업 혹은 영역에서 온실가스 배출 현황을 연구하는데 도움이 된다

表 3 中的删除线表示在原始文本上要删除的单词,竖线表示将原始文本划分短语结构或在此处断句。在 ID-Attention 模型中,朝鲜语文本语气词、助词以及部分形容词被删除,重要的部分名词被保留;在 HS-Attention 模型中,朝鲜语文本被切割成“短语”,模型分割的结构接近于人工断句,原始文本通过这两种模型结构化之后更利于下游文本分类任务。

4 结束语

本文将注意力机制与深度强化学习相结合,通过发现任务相关结构来学习朝鲜语句子表示。提出了两种表示模型:ID-Attention 模型,用其识别与任务相关的单词以提炼的句子表示;HS-Attention 模型,用于发现短语结构以形成分层的句子表示。强化学习依据朝鲜语文本分类的准确率作为奖励,对动作序列进行优化,而动作序列可以生成更适合分类的文本结构表示。在动作序列生成的过程中引入了注意力机制,不仅弥补了强化学习方法方差过大、难以拟合的劣势,还弥补了只

使用注意力机制过于依赖打分函数的效果,做到既具有顾及全局的优势,又能识别出更重要的句子成分。另一方面也提升了分类任务的准确率。在朝鲜语文本上的实验表明,本文所提出的两种模型能够在没有显式结构注释的情况下有效地发现朝鲜语句子的结构。

参考文献:

- [1] Bengio Y, Courville A, Vincent P. Representation learning: a review and new perspectives[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(8):1798-1828.
- [2] Socher R, Pennington J, Huang E H. Semi-supervised recursive auto encoders for predicting sentiment distributions[C]//The Conference on Empirical Methods in Natural Language Processing, Edinburgh, UK, 2011, 151-161.
- [3] 毕玉德. 朝鲜语自然语言处理研究管窥[J]. 中文信息学报, 2011, 25(6):166-169, 182.
Bi Yu-de. A research on Korean natural language processing[J]. Journal of Chinese Information Pro-

- cessing, 2011, 25 (6): 166-169, 182.
- [4] Joulin A, Grave E, Bojanowski P. Bag of tricks for efficient text classification[C]//The European Chapter of the ACL, Valencia, Spain, 2017:427-431.
- [5] Kim Y. Convolutional neural networks for sentence classification[C]//The Conference on Empirical Methods in Natural Language Processing, Doha, Qatar, 2014:1746-1751.
- [6] Zhu X, Sobihani P, Guo H. Long short-term memory over recursive structures[C]//International Conference on Machine Learning, Miami, Florida, USA, 2015:1604-1612.
- [7] Yang Z, Yang D, Dyer C. Hierarchical attention networks for document classification[C]//Annual Conference of the North American Chapter of the Association for Computational Linguistics, San Diego, USA, 2016:1480-1489.
- [8] Yogatama D, Blunsom P, Dyer C. Learning to compose words into sentences with reinforcement learning [C]// International Conference on Learning Representations, Toulon, France, 2017.
- [9] Chung J, Gulcehre C, Cho K. Empirical evaluation of gated recurrent neural networks on sequence modeling[C]//NIPS, Montreal, Canada, 2014.
- [10] Zhang Tian-yang, Huang Min-lie, Zhao Li. Learning structured representation for text classification via reinforcement learning[C]//The Association for the Advance of Artificial Intelligence, New Orleans, USA, 2018:6053-6060.
- [11] Williams R J. Simple statistical gradient-following algorithms for connectionist reinforcement learning[J]. Machine Learning, 1992, 2(3/4):229-256.
- [12] Keneshloo Y, Ramakrishnan N, Reddy C K. Deep transfer reinforcement learning for text summarization [J]. Society for Industrial and Applied Mathematics, 2019, arxiv:1810.06667v2.
- [13] Sutton R S, McAllester D A, Singh S P. Policy gradient methods for reinforcement learning with function approximation[C]//NIPS, Denver, USA, 2000:1057-1063.
- [14] Graves A, Jürgen Schmidhuber. Frame wise phoneme classification with bidirectional LSTM and other neural network architectures[J]. Neural Networks, 2005, 18(5/6):602-610.
- [15] Bahdanau D, Cho K, Bengio Y. Neural machine translation by jointly learning to align and translate [C]// International Conference on Machine Learning, Florida, USA, 2015, arXiv:1409.0473v7.
- [16] Tang D, Qin B, Liu T. Document modeling with gated recurrent neural network for sentiment classification[C]// Proceedings of the Conference on Empirical Methods in Natural Language Processing, Lisbon, Portugal, 2015:1422-1432.
- [17] Chung J, Ahn S, Bengio Y. Hierarchical multiscale recurrent neural networks[C] //International Conference on Learning Representations, Toulon, France, 2017.
- [18] Pennington J, Socher R, Manning C D. Glove:Global vectors for word representation[C]//Proceedings of the Conference on Empirical Methods in Natural Language Processing, Doha, Qatar, 2014:1532-1543.
- [19] Kingma D, Ba J. Adam: a method for stochastic optimization[C] //International Conference on Learning Representations, Sandiego, USA, 2015.
- [20] Mingjie T, Yahui Z, Rongyi C. Identifying word translations in scientific literature based on labeled bilingual topic model and co-occurrence features[C]// The 17th China National Conference on Computational Linguistics, Changsha, China, 2018:79-92.
- [21] 孟先艳, 崔荣一, 赵亚慧, 等. 基于双向长短时记忆单元和卷积神经网络的多语种文本分类方法[J]. 计算机应用研究, 2020, 37(9):2669-2673.
- Meng Xian-yan, Cui Rong-yi, Zhao Ya-hui, et al. Multilingual text classification method based on bidirectional long-short memory unit and convolutional neural network[J]. Computer Application Research, 2020, 37(9):2669-2673.
- [22] Vaswani A, Shazeer N, Parmar N. Attention is all you need[J]. Advances in Neural Information Processing Systems, 2017:5999-6009.
- [23] Lin Z, Feng M, Santos C N. A structured self-attentive sentence embedding[C] //International Conference on Learning Representations, Toulon, France, 2017.