

# 基于螺旋注意力网络的方面级别情感分析模型

杜成玉<sup>1</sup> 刘鹏远<sup>2</sup>

(1. 北京语言大学 信息科学学院, 北京市 100083; 2. 北京语言大学 信息学院, 北京市 100083)

**摘要:** 方面级别情感分析是一项细粒度的情绪分类任务, 它旨在确定特定方面的情感极性。以往的方法大都是基于方面或上下文向量的平均值来学习上下文或目标词的注意力权重, 但当方面词和上下文较长时, 这种方法可能会导致信息丢失。本文提出了一种建立在 BERT 表示上的螺旋注意力网络 (BHAN) 来解决这一问题, 模型中的螺旋注意力机制与之前注意力机制不同的是, 基于方面词得到加权后的上下文表示后, 接着用这个新的表示计算方面词的权重, 下一步则用这个新的方面词的表示重新计算上下文的权重, 如此循环往复, 上下文和方面词的表示会得到螺旋式的提高。本文在 2014 年 SemEval 任务 4 和 Twitter 数据集上进行了模型评估, 实验结果表明, 其性能超过了之前最佳模型的结果。

**关键词:** 螺旋注意力; 方面级别情感分析; 向量表示

中图分类号: TP391

文献标识码: A

## Helical Attention Networks for Aspect-level Sentiment Classification

Chengyu Du<sup>1</sup>, Pengyuan Liu<sup>2</sup>

(1. Beijing Language and Culture University, Beijing, 100083, China; 2. Beijing Language and Culture University, Beijing, 100083, China)

**Abstract:** Aspect-level sentiment classification is a fine-grained sentiment classification task. It aims to identify the sentiment polarity for a particular aspect. Most of the previous approaches learn the attention weights to the context/aspect words based on the averaged aspect/context vector, which might cause information loss, especially for the aspect with multiple words or larger context. To address this issue, this paper proposes an BERT-based Helical Attention Networks (BHAN) which employ a helical attention mechanism to get a better representation of context/aspect based on BERT. Specifically, after get the weighted context representation based on averaged target vector, we use it to compute the attention weight of target. Then we use the new weight target representation to compute the context attention weight again. In a similar way, after we run these steps multiple times, we can get a better representation of context and target step by step. We evaluate our proposed approach on SemEval 2014 Task 4 and Twitter dataset. The experimental results shows the performance of our approach is state-of-the-art.

**Key words:** Helical Attention; Aspect-level Sentiment Classification; Better Representation

## 1 引言

---

收稿日期: ; 定稿日期:

基金项目: 北京市自然科学基金资助项目 (4192057)

作者简介: 杜成玉 (1995.8), 女, 硕士, 情感分析; 刘鹏远 (1974.5), 男, 副教授, 自然语言处理。

方面级别情感分析，是情感分析领域当前关注的重要问题之一，它包括两个子任务：方面词提取任务和方面级别情感分类任务。一个句子中可能有多个方面词，方面词可以是一个单词，也可以是一个短语。

本文研究方面级别情感分类问题，这是一项细粒度的情感分类任务，旨在确定句子中明显出现的方面词的情感极性（如消极、中性或积极）。比如，“Great food but the service was dreadful!”这句话中描述了两个方面：“food”和“service”，相应的方面级别情感分类结果分别是：积极和消极。早期关于方面级别的情感分类的研究主要集中在设计一组特征来训练分类器<sup>[1-3]</sup>。然而，这种特征工程工作耗时且泛化能力较弱。近年来，随着深度学习方法，特别是神经语言模型的发展，出现了许多基于循环神经网络的方面级别情绪分析模型，如 Recursive NN<sup>[4]</sup>, Recursive NTN<sup>[5]</sup>和 Tree-LSTM<sup>[6]</sup>，并且越来越多的学者开始使用注意力机制来融合方面词与上下文的信息。Wang<sup>[7]</sup>等，Tang<sup>[8]</sup>等和 Chen<sup>[9]</sup>等根据方面词向量使用一层或多层注意力机制来计算上下文的词的权重；Ma<sup>[10]</sup>等提出了一个交互式注意力网络，该网络分别学习上下文和目标词的注意力权重。这些方法都根据平均后的方面词或上下文向量来学习对应的上下文或目标词的注意力权重，因此，当方面词或上下文都较长时，这类方法可能会导致信息损失。

为了解决这个问题，本文提出了螺旋注意力机制来减少信息损失，以获得更好的上下文和方面词的表示向量。首先，根据平均后的方面词向量计算上下文词的注意力权重，得到一个加权后的上下文表示，接着用它来计算方面词的注意力权重，得到一个加权后的方面词向量。这个向量优于平均的方面词向量，下一步，用它重新计算上下文词的注意力权重，这时这个权重能更加准确的表示上下文中每个词的重要程度，得到的新的加权后的上下文表示也优于上次的表示。然后，接着用这个更好的表示重新计算方面词的权重，得到更好的方面词的表示，如此循环往复，上下文和方面词的表示会得到螺旋式的提升。

本文的贡献在于：

- 1) 提出了基于螺旋式注意力机制的方面级别情感分析模型，该模型能够在 Bert 对文本进行表示后，充分进行方面词与上下文之间的交互；
- 2) 在标准数据集上的评价实验表明，本文模型性能超过了以往模型，取得了当前最佳性能。

## 2 相关工作

传统的基于方面词的情感分析方法包括基于规则的方法<sup>[11]</sup>和基于统计的方法<sup>[12-13]</sup>。这些方法侧重于将一组分类线索转化为特征向量，但这既需要费力的特征工程工作，也需要大量的额外语言资源。

近年来，有许多基于循环神经网络的方面级别情绪分析模型，如 Recursive NN<sup>[4]</sup>, Recursive NTN<sup>[5]</sup>和 Tree-LSTM<sup>[6]</sup>，这些模型取得了不错的效果，但单纯基于 RNN 的模型无法很好地捕捉到长句子中与方面词距离相对较远的情感极性词或短语之间的潜在关联。

为了解决上述问题，越来越多的研究人员致力于引入注意力机制来解决这个问题。例如，Wang<sup>[8]</sup>等提出了一个基于注意力机制的 ATAE-LSTM 模型，该模型对句子和给定的方面词用 LSTM 进行编码后，采用注意力机制对隐藏层输出进行处理，将得到的注意力向量与方面词向量拼接得到关于方面词的情感极性表达。Tang<sup>[9]</sup>等提出了基于注意力机制的 MemNet 模型，该模型基于输入句子的词向量构成的外部记忆进行注意力学习，模型的每一层基于上一层输出的结果重新计算注意力分布，最终得到关于给定方面词的情感极性表达。Chen<sup>[14]</sup>等提出了 RAM 模型，该模型是在 MemNet 模型基础上产生的，它侧重于对不同注意力层捕获到的信息进行非线性组合来得到给定方面词的情感极性表达。Ma<sup>[10]</sup>等提出了基于交互注意力机制的 IAN 模型，该模型不仅计算句子隐藏层输出的注意力分布，还计算方面词的注意力分布，最终将这两方面的信息进行拼接，得到给定方面词的情感极性表达。Zheng<sup>[15]</sup>等提出了 LCR-Rot 模型，该模型分别用了 3 个 BI-LSTM 对方面词及其左边和右边上下文进行编码，接着用旋转

注意力机制对他们之间的关系建模。Huang<sup>[16]</sup>等提出了基于注意力机制的 AOA 的网络，以联合的方式建模方面词和句子，并明确捕捉方面词和上下文句子之间的交互。LI<sup>[17]</sup>等提出了基于层次注意力的 HAPN 模型，该模型将位置嵌入作为输入的一部分，并用层次注意力机制来融合目标和上下文词的信息。

BERT 提出后，一些研究在它基础上对上下文进行编码，来更好地解决方面级别情感分类任务。Song<sup>[18]</sup>等运用标签平滑化的方法来解决中性类别方面词情感模糊的问题，并运用了多个不同注意力机制对上下文和方面词进行建模。Zhao<sup>[19]</sup>等运用双向注意力机制，分别计算了上下文和方面词的注意力权重，最终将得到的表示放入图网络中，对句子不同方面词之间的关系进行建模。

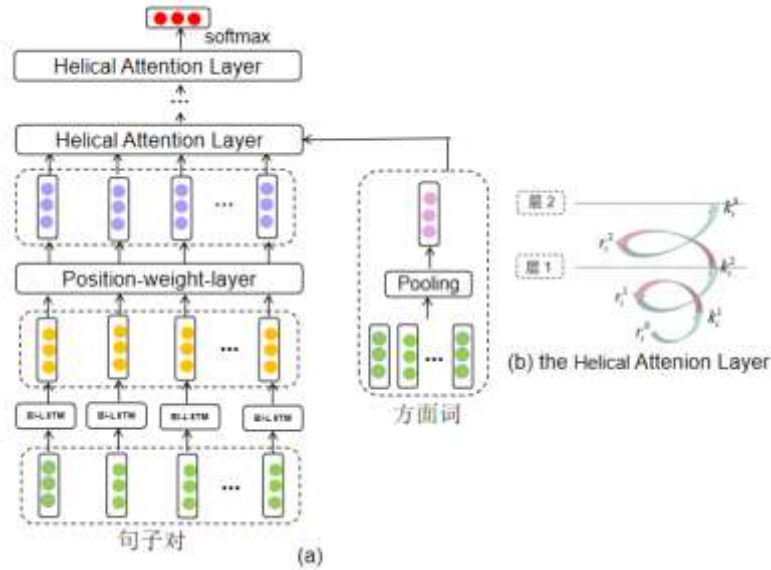


图 1: 模型整体框架

### 3 模型

假设一个句子由  $n$  个单词组成， $w^c = \{w_1^c, w_2^c \dots w_m^c\}$ ，一个方面词有  $m$  个单词， $w^t = \{w_1^t, w_2^t \dots w_m^t\}$ ， $w^c$  是  $w^t$  的子序列，模型的目标是预测方面词的情感极性。本文的模型架构如图 1 所示，下面将对模型进行详细介绍。

#### 3.1 BERT

BERT<sup>[20]</sup>是一种预训练语言表示的方法，是在大量文本语料（维基百科）上训练得到的一个通用的“语言理解”模型，它是第一个用在预训练 NLP 上的无监督的、深度双向系统，因此比之前的方法表现更出色。本文使用预先训练好的 BERT<sup>1</sup>来生成序列的字向量，BERT 有单个句子和句子对两种输入方式。受 Sun<sup>[21]</sup>等的启发，本文认为句子对的输入更适合方面级别的情感分类任务，因此我们利用方面词构造了一个辅助句子，将其与上下文组成句子对进行输入，输入方式为“[CLS]+“how about the”+target+[SEP]+context+[SEP]”，得到向量  $e^c \in R^{d_{BERT}}$ ， $d_{BERT}$  是词向量的维度。

#### 3.2 双向 LSTM

双向 LSTM 网络<sup>[22]</sup>是 LSTM 网络的进一步优化，它不仅可以保存序列前面的信息，同时也可以获取序列后面的信息，从整体上有效提取文本的上下文信息。本文使用双向 LSTM 对上下文进行编码，在每个时间步的更新过程如下：

$$i_t = \sigma(w_i[h_{t-1}, e^c] + b_i)$$

$$f_t = \sigma(w_f[h_{t-1}, e^c] + b_f)$$

<sup>1</sup> We use uncased BERT-base from <https://github.com/google-research/bert>.

$$\begin{aligned}
o_t &= \sigma(w_o[h_{t-1}, e^c] + b_o) \\
\tilde{c}_t &= \tanh(w_c[h_{t-1}, e^c] + b_c) \\
c_t &= \tilde{c}_t * i_t + c_{t-1} * f_t \\
h_t &= o_t * \tanh(c_t)
\end{aligned}$$

其中,  $w_i, w_f, w_o, w_c \in R^{d_{BERT} \times d_h}$ ,  $b_i, b_f, b_o, b_c \in R^{d_h}$  更新门  $i_t$ , 遗忘门  $f_t$ , 输出门  $o_t$  模拟开关, 分别控制是否从当前输入更新信息、是否忘记存储单元中的信息以及是否将存储单元中的信息显示给输出。 $d_h$  是隐藏层的维度。向后的 LSTM 做同样的事情, 只不过它的输入序列是相反的。最后, 上下文的输出为:

$$h_i = \vec{h}_i \oplus \overleftarrow{h}_i, h_i \in R^{2d_h}$$

### 3.3 融合位置信息

与 Chen<sup>[14]</sup>等人相似, 我们在模型中加入了位置信息, 距离方面词越近的上下文词越重要, 具体权重计算过程如下:

$$p_n = 1 - \frac{|n - \gamma|}{n_{max}}$$

其中,  $n_{max}$  是句子长度, 当方面词是短语时,  $|n - \gamma|$  是上下文词与方面词左边或右边的相对距离。

同时, 本文计算了  $u_n = \frac{|n - \gamma|}{n_{max}}$ , 将它做为二维向量拼接上下文向量中。最终融入位置信息的上下

文  $M = \{m_1, m_2, \dots, m_n\}$ ,  $m_n = [h_n \bullet p_n, u_n] \in R^{2d_h+1}$ 。

### 3.4 螺旋注意力机制

注意力机制 (attention) 是松散的基于人脑注意力的一种机制, 在文本中通过自动加权的方法能够有效的捕捉到文本中重要的信息。以前的方法<sup>[9-10][14]</sup>简单地为目标/上下文向量进行平均, 以指导学习上下文和方面词的注意权重, 这可能会导致信息丢失, 尤其是对于长度较长的上下文和方面词。为了解决这一问题, 我们提出了一种螺旋式的注意机制, 它可以捕获上下文和方面词的重要信息。

**螺旋上下文注意力:** 本文认为对于不同的方面词, 每个上下文词语对于句子情感倾向的贡献是不一致的。举例来说, “这家店的菜很好吃, 但是服务不好。”在这句话中, 对于方面词“菜”来说, “很好吃”比“不好”更加重要, 相反的, 对于方面词“服务”来说, “不好”则更加重要。因此, 根据方面词计算上下文每个词对应的权重是有必要的。之前工作在计算权重时, 往往要将方面词进行平均, 而本文则是用上层带权重的方面词的表示来计算上下文词的权重, 因此能得一个更好的上下文表示。对于上下文中的每个词, 其注意力权重按以下公式计算:

$$\begin{aligned}
f_c([r_i^{g-1}, m_i]) &= \tanh(w_{att}^c \cdot [r_i^{g-1}, m_i]) \\
\alpha_i^c &= \frac{\exp(f_c([r_i^{g-1}, m_i]))}{\sum_{i=1}^n \exp(f_c([r_i^{g-1}, m_i]))}
\end{aligned}$$

其中,  $r_i^{g-1}$  是上一层带权重的方面词,  $g$  表示当前的层数,  $w_{att}^c \in R^{2d_h+1+d_{BERT}}$  是上下文注意力权重矩阵,  $f_c([r_i^{g-1}, m_i])$  表示上下文中每个词的重要程度, 加权后的上下文表示如下:

$$k_i^g = \sum_{i=1}^n \alpha_i^c \cdot m_i$$

**螺旋方面词注意力:** 本文采用螺旋方面词注意力层来捕获方面词的表示。具体来说, 方面词的注意力权重是通过上一次层输出的带权重的上下文表示来计算的, 这相对于平均的上下文向量来说, 可以得到一个更好的方面词表示, 计算过程如下:

$$f_i\left(\left[k_i^g, e_i^t\right]\right) = \tanh\left(w_{att}^t \cdot \left[k_i^g, e_i^t\right]\right), w_{att}^t \in \mathbb{R}^{2d_h+1+d_{BERT}} \quad \alpha_i^t = \frac{\exp\left(f_i\left(\left[k_i^g, e_i^t\right]\right)\right)}{\sum_{i=1}^m \exp\left(f_i\left(\left[k_i^g, e_i^t\right]\right)\right)}$$

$$r_i^g = \sum_{i=1}^m \alpha_i^t \cdot e_i^t$$

其中,  $k_i^g$  是  $g$  层螺旋上下文注意力层的输出, 是带权重的上下文表示,  $e_i^t \in \mathbb{R}^{d_{BERT}}$  是方面词向量,  $w_{att}^t$  是方面词注意力权重矩阵,  $\alpha_i^t$  是方面词的权重,  $r_i^g$  是  $g$  层新的方面词表示。

**多个计算层:** 单个螺旋上下文注意力层和螺旋方面词注意力层不足以处理语言中的否定、强化等复杂计算。因此, 本文在模型中使用了  $j$  层螺旋注意力层, 每层包含一个螺旋上下文注意力层和一个螺旋方面词注意力层。在图 1 (b) 中, 蓝色箭头表示螺旋上下文注意力机制, 红色箭头表示螺旋方面词注意力机制。在第一层中, 本文使用平均后的方面词向量  $r_i^0$  计算上下文词的注意力权重。在得到加权后的上下文表示  $k_i^1$  后, 计算方面词的注意力权重, 从而得到一个更好的方面词表示  $r_i^1$ , 接着将它做为第二层螺旋上下文注意力层的输入, 重新计算上下文词的注意权重, 这时这个权重能更加准确的表示上下文中每个词的重要程度, 得到的新的加权后的上下文表示  $k_i^2$  也优于上层上下文的表示  $k_i^1$ , 然后接着用这个更好的表示重新计算方面词的权重, 得到更好的方面词的表示, 如此循环往复, 上下文和方面词的表示会得到螺旋式的提升, 如图 1 (b) 中所示。本文将最后一层上下文注意力层的输出  $k_i^j$  做为基于方面词的最终的句子表示, 并被进一步用作情感分类的特征。

### 3.5 输出层

得到当前句子的最终表示  $k_i^j$ , 将其输入一个 SoftMax 层, 以预测方面词的情感倾向, 然后模型通过最小化交叉熵来进行训练:

$$l = - \sum_{(x,y) \in D} \sum_{c \in C} y^c \log f^c(x; \theta) + \lambda \|\theta\|^2$$

其中,  $C$  为情感类别集,  $D$  为训练样本数,  $f^c(x; \theta)$  为模型的预测情感分布,  $\lambda$  是 L2 正则化的系数,  $\theta$  是需要训练的参数。

## 4 实验

### 4.1 实验设置

为验证模型的有效性, 本文采用了 SemEval 2014 任务四中的两组公开数据集<sup>[23]</sup>和 Twitter 数据集<sup>[24]</sup>进行测试, 详细信息见表 1。

表 1: 数据集详细信息

| 数据集        | 积极   |     | 中性   |     | 消极   |     |
|------------|------|-----|------|-----|------|-----|
|            | 训练集  | 测试集 | 训练集  | 测试集 | 训练集  | 测试集 |
| Twitter    | 1561 | 173 | 3127 | 346 | 1560 | 173 |
| Restaurant | 2164 | 728 | 637  | 196 | 807  | 196 |
| Laptop     | 994  | 341 | 464  | 169 | 870  | 128 |

SemEval 2014 任务四数据集包含 Restaurant、Laptop 两个数据集, 其中方面词的极性有四种, 分别为积极、消极、中立、冲突。由于具有冲突极性的样本在数据集中的比例较低, 本文参照其他研究者的工作对数据进行了预处理, 去除了包含冲突极性的样本。参数设置如表 2 所示, 在训练过程中通过 Adam<sup>[25]</sup>来优化模型参数。评价指标为分类的精确率。

表 2: 模型参数设置

|      |               |            |              |
|------|---------------|------------|--------------|
| 超参数  | Embedding dim | Hidden dim | Dropout rate |
| BERT | 786           | 300        | 0.1          |
| 超参数  | Learning rate | Batch size | Weight of L2 |
| BERT | 0.001         | 32         | 0.0001       |

## 4.2 对比模型

在本节中，本文给出了一些在相同数据集上取得最佳性能的方法来进行比较，以评估模型的性能。

**TD-LSTM<sup>[7]</sup>**: 采用两个 LSTM 分别对方面词及其左边句子和方面词及其右边句子进行建模，用最后一个时间步的隐藏状态来进行预测。

**MemNet<sup>[9]</sup>**: 基于输入句子的词向量构成的外部记忆进行注意力学习，模型的每一层基于上一层输出的结果重新计算注意力分布，最终得到关于给定方面词的情感极性表达。

**ATAE-LSTM<sup>[8]</sup>**: 对句子和给定的方面词用 LSTM 进行编码后，采用注意力机制对隐藏层输出进行处理，将得到的注意力向量与方面词向量拼接得到关于方面词的情感极性表达。

**IAN<sup>[10]</sup>**: 以交互方式学习上下文和方面词中的注意力分布，并分别生成方面词和上下文的表示。

**RAM<sup>[14]</sup>**: 使用双向 LSTM 的隐藏层构建位置加权记忆，然后利用注意力机制从位置加权记忆中捕获远距离分隔开的情感特征。

**LCR-Rot<sup>[15]</sup>**: 分别用了 3 个 BI-LSTM 对方面词及其左边和右边上下文进行编码，接着用旋转注意力机制对他们之间的关系建模。

**HAPN<sup>[17]</sup>**: 将位置嵌入作为输入的一部分，并用层次注意的机制来融合目标和上下文词的信息。

**AEN-BERT<sup>[18]</sup>**: 运用标签平滑化的方法来解决中性类别方面词情感模糊的问题，并运用了多个不同注意力机制对上下文和方面词进行建模。

**SDGCN-BERT<sup>[19]</sup>**: 运用双向注意力机制，分别计算了上下文和方面词的注意力权重，最终将得到的表示放入图网络中，对句子不同方面词之间的关系进行建模。

**BHAN w/o HA**: 将位置权重层的输出进行平均，来计算方面词的注意力权重，然后用平均的方面词向量计算上下文词的注意力权重。最后，将这两个向量进行拼接用于分类。

**BHAN(singe)**: 将句子序列 “[CLS]+context+[SEP]” 作为 BERT 输入，进行分类。

## 4.3 实验结果

表 3: 模型的精确率 (括号中的数字是所使用的层数)

| Dataset      | Restaurant (%)  | Laptop (%)      | Twitter(%)      |
|--------------|-----------------|-----------------|-----------------|
| TD-LSTM      | 75.63           | 68.13           | 70.80           |
| Mem Net      | 79.98           | 70.33           | 68.50           |
| ATAE-LSTM    | 77.20           | 68.70           | -               |
| IAN          | 78.60           | 72.10           | -               |
| RAM          | 80.23           | 74.49           | -               |
| LCR-Rot      | 81.34           | 75.24           | 72.69           |
| HAPN         | 82.23           | 77.27           | -               |
| AEN-BERT     | 83.12           | 79.93           | 74.71           |
| SDGCN-BERT   | 83.57           | 81.35           | -               |
| BHAN w/o HA  | 83.21           | 79.47           | 73.90           |
| BHAN (singe) | 85.18           | 80.09           | 75.58           |
| <b>BHAN</b>  | <b>86.52(4)</b> | <b>81.35(5)</b> | <b>76.45(3)</b> |

从表 3 可知，BHAN 比 BHAN(singe) 性能更好，这证实了在方面级别的情感分类任务上将句子对作为 BERT 的输入更加有效，但不论模型是以单个句子作为 BERT 输入，还是以自动构造的句子对作为输入，都达到了最佳性能，证明了模型的有效性。

以上方法中，TD-LSTM 方法的性能最差，因为它无法捕获足够的与方面词相关的上下文信息。ATAE-LSTM、MENNEN 和 IAN 都使用注意力机制来使模型更加关注上下文中与方面词相关的信息，因此模型性能优于 TD-LSTM。RAM 提出了一种深度记忆网络来整合方面词信息，并且将多个注意力机制的结果进行非线性结合，因此 RAM 的性能优于以上基于注意力机制的模型。与 RAM 相比，LCR-Rot 具有更好的性能，因为它使用三个 BILSTM 来建模左上下文、目标上下文和右上下文，从而可以获得更多的上下文信息。在基于 GloVe 编码模型中，HAPN 取得了最佳性能。这表明位置信息和多个注意力层对任务会有帮助。AEN-BERT 和 SDGCN-BERT 都使用双向注意力机制，但 SDGCN-BERT 的性能更好，这是因为 SDGCN-BERT 将句子中多个方面词经过双向注意力层的结果输入到图网络中，对他们之间的关系进

行建模。




图 2 不同注意力机制的注意力权重对比

#### 4.4 螺旋注意力机制的效能

为了验证螺旋注意力机制的性能，本文将其替换为普通的注意力机制，构造了 BHAN w/o HA 模型，即在经过融入位置信息层后，将方面词进行平均来计算上下文的注意力权重，将上下文进行平均来计算方面词的权重，最后将这两方面的信息进行拼接，用做分类。结果如表 3 所示 BHAN 模型在餐厅、笔记本电脑和 Twitter 这三个数据集上的准确率分别为 86.34%、80.25%和 76.45%，分别比 BHAN w/o HA 高出 3.13%、0.78%和 2.55%。

本文还对这两个模型在同一个句子上的注意力权重进行了可视化，如图 2 所示，图中颜色越深代表权重越大，这句话中的方面短语是“traffic noise”，其情感倾向是积极的，“noise”代表这个短语的主要语义，但在 BHAN w/o HA 中，“noise”并没有得到突出，因此导致模型分类错误，相反，在 BHAN 模型中，“noise”权重较大，这表明了螺旋注意力机制是有效的。

### 5 实验分析与讨论

为考察各模型与 BERT 结合的效果，本文设计了一组对比实验，采用 Stanford 大学公开发布的 300 维的预训练 GloVe 词向量作为词典，词典大小为  $1.9M^{[26]}$ 。相应地，LSTM 隐藏层维度设置为 300，学习步长设置为 0.001，batch 的大小为 64，dropout 为 0.1，使用 Adam 更新参数。

实验结果如表 4 所示。从表 4 中可以看出，BHAN-BERT 在餐厅、笔记本电脑和 Twitter 数据集三个上的性能分别比 BHAN-GloVe 高出 4.91%、7.52%和 5.06%，与其他模型相比提高的更多。这一结果表明，本文提出的模型比其他模型更适合使用预先训练的 BERT 来对单词进行编码。

表 4: 基于 GloVe 模型的性能

| Dataset     | Restaurant (%) | Laptop (%)   | Twitter(%)   |
|-------------|----------------|--------------|--------------|
| AEN-GloVe   | 80.98          | 73.51        | 72.83        |
| SDGCN-GloVe | 82.95          | 75.55        | -            |
| BHAN-GloVe  | 80.71          | 74.14        | 72.11        |
| AEN-BERT    | 83.12(+2.26)   | 79.93(+6.42) | 74.71(+1.88) |
| SDGCN-BERT  | 83.57(+0.62)   | 81.35(+5.8)  | -            |
| BHAN-BERT   | 85.18(+4.47)   | 80.09(+5.95) | 75.58(+3.47) |




图 3: 螺旋注意力机制权重的可视化

为了更好地对螺旋式注意力网络进行分析，并验证该模型是否能够选择与特定方面词或上下文相对应的信息，我们将不同层的注意力权重进行了可视化。

图 3 显示了句子“The folding chair I was seated at was uncomfortable”的注意力可视化效果。这句话中的方面词是“folding chair”，其情感极性是消极的。在图 3 中，颜色深度表示注意力权重的大小，颜色越深权重越大。在第一层螺旋注意力机制中，目标词“folding”和“chair”在开始时具有相似的权重。经过三层后，“chair”的权重远远超过“folding”。对于上下文的权重，在第一层中相关词“seated”和“uncomfortable”较其他词来说，权重较大，但仍没有得到充分的强调。随着层数的增加，与方面词相关且对其情感倾向有影响的词“uncomfortable”，它的权重越来越大。这表明本文提出的方法能够有效地找出信息量较大的单词，从而得到更好地上下文和方面词的代表。

本文对使用不同的层数的模型进行了测试，实验结果如图 4 所示。我们可以发现模型的层数并不

是越多越好。模型学习了较好的表示后，层数的增加反而将降低模型的性能。

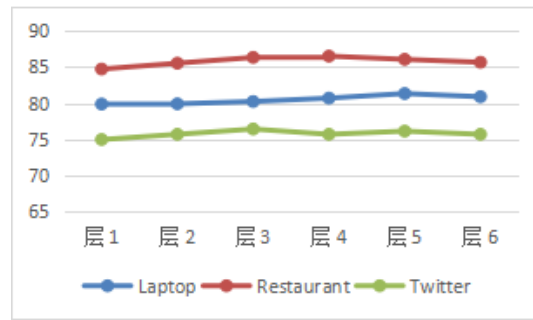


图 3: 不同层数的实验性能

## 6 结论与未来工作

本文提出了一个建立于 BERT 上的基于螺旋注意力机制的神经网络模型来解决方面级别情感分类任务。该模型的核心思想是利用螺旋上下文注意力层和螺旋方面词注意力层来更好地表示上下文和方面词。我们在标准测试集上对该模型进行了评测，实验结果表明，螺旋注意力机制能够有效找出信息量较大的单词，减小上下文与方面交互的信息损失，本文模型的性能，达到了当前最佳。

螺旋注意力机制能够有效降低信息交互的损失，因此，我们下一步工作将：

- 1、对降低信息交互损失的机理进行研究；
- 2、将该机制用于如阅读理解等信息交互较强的相关任务中。

## 参考文献

- [1] Svetlana Kiritchenko, Xiaodan Zhu, Colin Cherry, et al. Nrc-canada-2014: Detecting aspects and sentiment in customer reviews[C]//In Proceedings of Sem Eval. 2014: 437-442.
- [2] Joachim Wagner, Piyush Arora, Santiago Cortes, et al. Dcu: Aspect-based polarity classification for sem eval task 4[C]//In Proceedings of Sem Eval. 2014: 223-229.
- [3] Duy-Tin Vo, Yue Zhang. Target-dependent twitter sentiment classification with rich automatic features[C]//In Proceedings of IJCAI. 2015:1347-1353.
- [4] Richard Socher, Jeffrey Pennington, Eric H. Huang, et al. Semi-supervised recursive autoencoders for predicting sentiment distributions[C]//In Proceedings of the 2011 Conference on Empirical Methods in Natural Language Processing. 2011: 151 - 161.
- [5] Richard Socher, Alex Perelygin, Jean Wu, et al. Recursive deep models for semantic compositionality over a sentiment treebank[C]//In Proceedings of the 2013 Conference on Empirical Methods in Natural Language Processing. 2013.
- [6] Kai Sheng Tai, Richard Socher, et al. Improved semantic representations from tree-structured long short-term memory networks[C]//In Proceedings of ACL-2015. 2015: 1556 - 1566.
- [7] Duyu Tang, Bing Qin, et al. Effective lstms for target-dependent sentiment classification[C]//In Proceedings of COLING-2016. 2016(a): 3298 - 3307.
- [8] Yequan Wang, Minlie Huang, et al. Attention-based LSTM for aspect-level sentiment classification[C]//In Proceedings of EMNLP-2016. 2016: 606 - 615.
- [9] Duyu Tang, Bing Qin, et al. Aspect level sentiment classification with deep memory network[C]//In Proceedings of EMNLP-2016. 2016(b): 214 - 224.
- [10] Dehong Ma, Sujian Li, Xiaodong Zhang, et al. Interactive attention networks for aspect-level sentiment classification[C]//In Proceedings of IJCAI-2017. 2017: 4068 - 4074.
- [11] Xiaowen Ding, Bing Liu, Philip S Yu. A holistic lexicon-based approach to opinion mining[C]//In Proceedings of the 2008 international conference on web search and data mining. 2008: 231 - 240.
- [12] Long Jiang, Mo Yu, Ming Zhou, et al. Target-dependent twitter sentiment classification[C]//In Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics: Human Language Technologies-Volume 1. 2011: 151 - 160.
- [13] Wayne Xin Zhao, Jing Jiang, Hongfei Yan, et al. Jointly modeling aspects and opinions with a maxent-lda



- hybrid[C]In Proceedings of the 2010 Conference on Empirical Methods in Natural Language Processing, EMNLP' 10. 2010: 56 - 65.
- [14] Chen P, Sun Z, Bing L, et al. Recurrent attention network on memory for aspect sentiment analysis[C]//Proceedings of the 2017 conference on empirical methods in natural language processing. 2017: 452-461.
- [15] Shiliang Zheng, Rui Xia. Left-Center-Right Separated Neural Network for Aspect-based Sentiment Analysis with Rotatory Attention[J]. arXiv preprint arXiv:1802.00892. 2018.
- [16] Binxuan Huang, Yanglan Ou, Kathleen M. Carley. Aspect Level Sentiment Classification with Attention-over-Attention Neural Networks[J]. arXiv preprint arXiv:1804.06536. 2018.
- [17] Li L, Liu Y, Zhou A Q. Hierarchical Attention Based Position-aware Network for Aspect-level Sentiment Analysis[C]//Proceedings of the 22nd Conference on Computational Natural Language Learning. 2018: 181-189.
- [18] Song Y, Wang J, Jiang T, et al. Attentional Encoder Network for Targeted Sentiment Classification[J]. arXiv preprint arXiv:1902.09314. 2019.
- [19] Zhao P, Houb L, Wua O. Modeling Sentiment Dependencies with Graph Convolutional Networks for Aspect-level Sentiment Classification[J]. arXiv preprint arXiv:1906.04501, 2019.
- [20] 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, 2018.
- [21] Joachim Wagner, Piyush Arora, Santiago Cortes, et al. Dcu: Aspect-based polarity classification for semeval task 4[C]//In Proceedings of Sem Eval. 2014: 223-229.
- [22] SCHUSTER M, PALIWAL K. Bidirectional recurrent neural networks[M]. USA:IEEE Press, 1997.
- [23] Joachim Wagner, Piyush Arora, Santiago Cortes, et al.: Dcu: Aspect-based polarity classification for semeval task 4. In Proceedings of Sem Eval., 223-229 (2014).
- [24] Li Dong, Furu Wei, Chuanqi Tan, et al. Adaptive recursive neural network for target-dependent twitter sentiment classification[C]//In Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers), volume 2. 2014: 49 - 54.
- [25] Diederik P Kingma, Jimmy Ba. Adam: A method for stochastic optimization[J]. arXiv preprint arXiv:1412.6980. 2014.
- [26] Jeffrey Pennington, Richard Socher, Christopher Manning. Glove: Global vectors for word representation[C]//In Proceedings of the 2014 conference on empirical methods in natural language processing (EMNLP). 2014: 1532 - 1543.

作者联系方式: 杜成玉 北京市海淀区学院路北京语言大学 100083 18811717715 2550611409@qq.com