

# 基于双图注意力网络的篇章级散文情绪变化分析方法

李爱琳<sup>1</sup>, 李旸<sup>2</sup>, 王素格<sup>1,3,\*</sup>, 李书琪<sup>1</sup>

1.山西大学计算机与信息技术学院, 山西省 太原 030006

2.山西财经大学金融学院, 山西省 太原 030006

3.山西大学计算智能与中文信息处理教育部重点实验室, 山西省 太原 030006

wsg@sxu.edu.cn

## 摘要

在散文中, 作者的情绪会随着文章的段落或者句子发生变化, 比如从悲伤到快乐、从喜悦到愤怒。为此, 本文构建散文情绪变化数据集, 提出一种基于双图注意力网络的多种知识融合的情绪变化分析方法。首先, 引入意象知识库, 建立融合意象知识的句子表示; 其次, 构建上下文带权依赖图和语篇带权依赖图, 通过融合上下文知识和语篇结构, 建立了融合上下文知识、语篇结构的句子表示; 同时设计愉悦效价识别层, 获得融合愉悦效价信息的句子表示; 在此基础上, 将以上三者表示进行拼接, 通过全连接网络得到最终的情绪变化结果。实验结果表明, 本文提出的方法可以有效识别情绪变化, 为散文阅读理解中的思想情绪变化类问题的解答提供帮助。

**关键词:** 情绪变化; 散文; 图注意力网络

## A Document-Level Emotion Change Analysis Method Based on DualGATs for Prose

Ailin Li<sup>1</sup>, Yang Li<sup>2</sup>, Suge Wang<sup>1,3,\*</sup>, Shuqi Li<sup>1</sup>

1.School of Computer and Information Technology,  
Shanxi University, Shanxi 030006

2.Shanxi University of Finance and Economics, Shanxi 030006

3.Key Laboratory Computational Intelligence and Chinese Information  
Processing of Ministry of Education, Shanxi University, Shanxi 030006

wsg@sxu.edu.cn

## Abstract

In Prose, the author's emotions evolve within passages or sentences, transitioning from sadness to happiness, or from joy to anger. To this end, this paper constructs a dataset of prose emotion changes and proposes emotion analysis method based on multi-knowledge fusion utilizing Dual-Graph Attention Network. Firstly, this paper incorporates image knowledge to get the deep representation of sentence. Secondly, the context-weighted dependency graph and the discourse-weighted dependency graph are constructed, and the sentence representation is established by integrating context knowledge and discourse structure. Additionally, a pleasure valence recognition layer is designed to integrate pleasure valence information into the sentence representation. Experimental results indicate the method is effective for identifying emotion changes, which can provide help for understanding the ideological and emotional changes in prose comprehension.

**Keywords:** Emotion change, Prose, Graph Attention Network

## 1 引言

散文在文学作品中的表现形式较为自由和灵活(王小环, 2023), 并具有较强的抒情性。散文中的情绪变化是指在文学作品中, 作者通过语言表达和叙述, 展现了自身情绪的波动、变化和发展的过程, 而散文的情绪变化往往与散文的主题紧密相连。而对于读者, 可以通过理解作者的情绪变化, 使自身更能全面、深刻地理解散文的主旨和作者的观点。

正如图1所示, 文章开始描述了荷塘“已不是以往模样”, 呈现了对时光流逝带来的感慨。然而, 随着“平静地浮在水面的叶子已亭亭玉立于荷塘”, 使荷塘展现出了美丽和生机, 作者对它的喜爱由此而生。在文章的后半部分, 作者揭示了周围人们的行为, 特别是对年轻女子的描述“装扮不予年龄相仿, 裸露着玉腿, 半舒着胸房”, 表达了作者对社会道德和价值观的不满和担忧, 情绪逐渐转向厌恶。

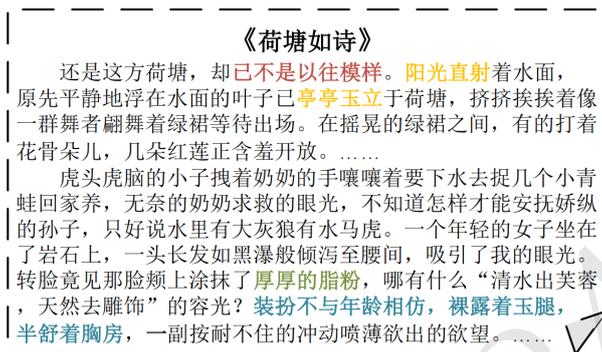


图 1: 示例《荷塘如诗》

《荷塘如诗》一文展示了散文的典型特点, 而目前的方法存在不足之处。首先, 散文常采用隐晦的语言和象征手法来表达情绪, 比如“已不是以往模样”、“厚厚的脂粉”等, 现有的情绪分析方法难以准确捕捉其中的隐含情绪(Zhang and Qian, 2020)。其次, 散文中充满了丰富的意象, 比如“荷塘”、“叶子”等, 但现有方法往往缺乏对意象的深层表示, 无法充分挖掘其中的情绪信息, 从而影响了情绪分析结果的准确性。此外, 散文通常具有复杂的组织结构, 包含多个段落和句子, 文章的长度可能达到30多个句子。然而, 现有方法在理解文章整体思路和内在联系方面的能力有限(Tran and Phan, 2020), 无法全面把握文章的意义和情绪变化。

因此, 为了提高对散文情绪的准确理解和深度分析能力, 需要充分考虑散文特点对散文情绪变化进行分析。本文利用意象知识库, 并通过注意力机制将意象引入到句子表示中, 以丰富句子的语境信息。同时, 构建上下文依赖图CotGAT和语篇依赖图DepGAT, 对全局上下文及结构信息进行建模, 获取全局的上下文理解。

本文的主要贡献如下:

- (1) 构建了一个全新的散文情绪变化数据集, 为本任务的研究者提供数据支持。
- (2) 提出了基于双图注意力网络的篇章级散文情绪变化分析方法。通过意象知识库、上下文依赖图、语篇依赖图以及愉悦效价识别, 获得丰富的句子表示, 增强了模型的情绪理解能力。
- (3) 在散文情绪变化数据集上, 与对比方法的实验结果表明, 本文方法具有较好的性能。

## 2 相关工作

散文情绪变化分析研究的基础是剖析文章的情绪, 因此, 情绪变化分析技术关联于文本情绪分类技术, 涉及到词语级、句子级和篇章级文本情绪分析。Zhao等人(2022)提出情绪词选择这一情绪感知辅助任务, 旨在让模型学习从给定的选项中选择正确的情绪词。Tian等人(2020)提出了SKEP模型, 该模型随机地将输入文本中的一些方面项-情绪词对替换为MASK, 并进行预测。而Huang等人(2019)采用滑动窗口的方法, 为每个输入句子生成一个文本级图, 其中, 句子中的每个单词与其左右相邻的p个词相连。散文中的情绪常以含蓄的方

©2024 中国计算语言学大会

根据《Creative Commons Attribution 4.0 International License》许可出版

\* 通讯作者 Corresponding Author.

基金项目: 国家自然科学基金项目(62076158,62106130,62376143); 山西省基础研究计划项目(20210302124084); 山西省高等学校科技创新项目(2021L284)

式表达，语境信息对于散文情绪的探究至关重要。然而，句子级情绪分析往往忽视了文章中句子间的复杂关系，限制了对文章的全面理解。

与句子级情绪分析不同，篇章级情绪分析考虑到文本的整体语境和结构，以及句子之间的关系。Yao等人(2019)为整个数据集构建了一个异构图，其利用词的共现信息建立边，在词节点与文档节点之间利用词的词频和词的文档词频建立边。Abreu等人(2019)将注意力机制应用于句子级上下文向量，对句子间的关系进行建模。Dai等人(2022)使用预训练的RoBERTa模型对每个句子进行编码，并且使用两层Transformer捕获不同句子之间的交互。这些方法都对上下文关系进行了建模，但缺乏对语篇依赖关系的考虑。然而，在对散文进行情绪分析时，需要充分考虑文章结构信息，才能精确地把握作者的情绪。因此，本文选择构建CotGAT和DepGAT，分别建模上下文关系和语篇依赖信息，以较全面地理解文章结构并把握文章情绪，从而提升散文情绪变化的分析性能。

### 3 散文情绪变化数据集构建

由于本文的任务是面向散文的情绪变化分析方法，任务较新，目前并没有公开的标注数据集，因此，我们构建了一个全新的散文情绪变化数据集。具体来说，首先搜集了290篇散文作为初始数据，来源于近几年全国各地的高考语文阅读理解题目和“中国散文网”。其中，“中国散文网”是以散文团体、散文作家、散文报刊及散文爱好者为主要服务对象，集文化资讯、散文报道、佳作交流、散文比赛、编辑翻译等于一体的大型文学网站。下面详细介绍数据集的构建过程。

#### 3.1 标注体系的制定

为了建立散文情绪变化分析，首先制定了一个标注体系，旨在确保数据集的规范性、通用性和可扩展性。本任务涉及五种标注信息：(1)愉悦效价类别(PVC)；(2)情绪类别(SC)；(3)情绪(S)；(4)情绪变化(SCH)；(5)情绪变化的原因(RSCH)。

标注者按照以上五种标注信息的顺序进行标注。对于每一条数据，ID代表“文章编号\_句子编号”，例如，“2.0”代表本条数据为文章2的第一个句子。Russell和Mehrabian的PAD情绪三维理论中指出，效价又称愉悦度(Pleasure-displeasure)，用于表示情绪状态的正负性，是衡量情绪的重要维度。对于情绪类别(SC)，我们借鉴Demszky等人(2020)的方法，结合《礼记》中的“七情”以及《白虎通》中的“六情”，综合散文的情绪特点，共分为十三类，包括乐、爱、敬、赞、愿、怒、哀、惧、恶、惊、信、羞、其他。因此，对于愉悦效价类别(PVC)，参照PAD三维理论和圆环模型(Russell, 1980)，通过情绪极性划分为正面、中性、负面，随后将十三类的情绪映射到这三类，形成了一个层次结构，具体结构如图2所示。在这个结构中，前三类提供了情绪极性价，有助于识别句子中存在的情绪。例如，“况且，湖景若无可观，湖中的出产可是很名贵呀”这个句子唤起了正面的情绪效价，有助于从底部的六个类别中识别情绪。

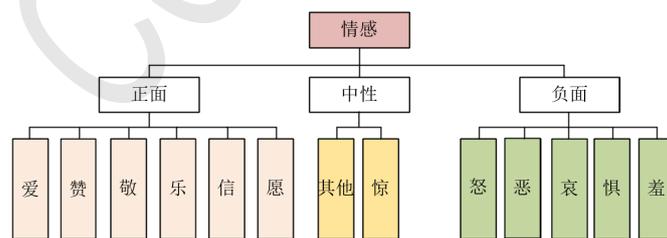


图 2: 情绪层次结构

在标注情绪类别(SC)的同时，我们也对文章中细节情绪(S)进行了标注，例如“喜爱”、“厌恶”等，有助于加深对文章情绪的理解。情绪变化(SCH)中的“YES”表示文章在该文本处发生情绪变化，而“NO”则表示没有发生变化；情绪变化的原因(RSCH)则记录了情绪变化(即SCH=“YES”)的详细原因。

#### 3.2 数据标注

为了保证数据的准确性和可用性，本文首先对收集到的文章进行句子级的划分，以保证每条数据包含较为完整的语义信息；其次，由人工对句子进行合并或删除，以进一步提高数据的

质量；最后，过滤数据中的特殊符号、网页地址等冗余内容，以保证数据的准确性和可用性。至此，获得散文情绪变化分析的初始数据。在此基础上，借助ChatGPT<sup>0</sup>进行“预标注”。

ChatGPT是一个基于GPT3.5的自然语言处理模型，具有出色的语言理解和生成能力，可以应用于多种自然语言处理任务，如情绪分析、语言理解等。为了提高标注效率及准确率，由ChatGPT和两位具有良好的文学素养和语言学背景的标注者共同标注。为了使用ChatGPT，构建两种提示如下：

(1) 请按照情绪类别，依次输出每个句子的情绪类别及具体的情绪，比如乐-快乐。注意只需要列出最主要的情绪类别。其中，情绪类别分为13类，分别为：乐，爱，敬，赞，愿，怒，哀，惧，恶，惊，信，羞，其他。文章：CONTENT。

(2) 给出文章CONTENT的情绪脉络及变化的原因。

利用上述两类提示，借助ChatGPT生成相应的标注结果，在此基础上，针对每一条数据，由两位标注者分别进行“再标注”，对于标注不一致的样例，通过多数投票机制获得最终的标注结果。经过数据标注，总共整理出7788条散文情绪变化分析数据，部分样例如下表1所示。

ID	Text	PVC	SC	S	SCH	RSCH
2.0	还是这方荷塘，却已不是以往模样。	负面	哀	感慨	NO	NONE
2.1	阳光直射着水面，原先平静地浮在水面的叶子已亭亭玉立于荷塘，挤挤挨挨着像一群舞者翩舞着绿裙等待出场。	正面	爱	喜爱	YES	描述阳光直射和叶子亭亭玉立，显示了荷塘的美丽和生命力的提升，体现了喜爱的情绪。
2.2	在摇晃的绿裙之间，有的打着花骨朵儿，几朵红莲正含羞开放。	正面	爱	喜爱	NO	NONE

表 1: 散文情绪变化数据集标注样例

通过对以上标注结果的统计，两组标注者的标注结果的Kappa值为85.54%，表现了标注结果的一致性和可靠性；人工标注的情绪类别与GPT标注的情绪类别的Kappa值为32.71%，说明ChatGPT在理解文章情绪具有局限性。

## 4 双图注意力网络的情绪变化分析模型

针对散文情绪变化分析任务，本文综合意象知识库，提出了基于双图注意力网络的篇章级散文情绪变化分析模型。整个模型包括五个主要部分：特征提取层、愉悦效价识别层、DualGATs层、情绪预测层和情绪变化识别层。首先，利用意象知识库，获得基于意象知识增强的句子表示；进一步，利用上下文依赖图、语篇依赖图以及相互交叉注意机制进行多层地提取和迭代，获得基于上下文知识增强的句子表示、基于语篇依赖信息增强的句子表示。其次，将这些表示添加愉悦效价识别层，通过线性变化和ReLU函数，获得基于愉悦效价知识增强的句子表示。最后，将以上三者进行拼接，通过全连接网络对各个句子的情绪类别进行预测，得到最终的情绪变化结果。模型的整体框架如图3所示。其中，散文 $D = [S_1, S_2, \dots, S_N]$ ， $N$ 表示散文中句子的数量， $S_i$ 为第 $i$ 个句子， $y_i \in Y$ 和 $y_i^v \in V$ 分别是情绪标签和愉悦效价， $Y$ 和 $V$ 分别为情绪标签集合和愉悦效价集合。

### 4.1 特征提取层

本模型使用预训练RoBERTa-large<sup>1</sup>模型，将散文 $D = [S_1, S_2, \dots, S_N]$ (图3中 $N=5$ )中的每个句子 $S_i$ 进行编码，获得 $N$ 个句子的嵌入表示分别为 $h_1^s, h_2^s, \dots, h_N^s$ 。由于意象知识对句子的情绪识别具有重要的指导作用，因此，利用课题组建立的意象知识库 $KB = (k_1, k_2, \dots, k_M)$ ，查询句子中是否存在意象，对存在意象的句子，进行再次嵌入表示 $h_i^k$ 。最后，使用注意力机制，为两种表示分配权重，融合句子及意象知识的特征表示为 $h_i$ 。该过程如图4所示，具体操作如下：

<sup>0</sup><https://chat.openai.com>

<sup>1</sup><https://huggingface.co/hfl/chinese-roberta-wwm-ext-large>

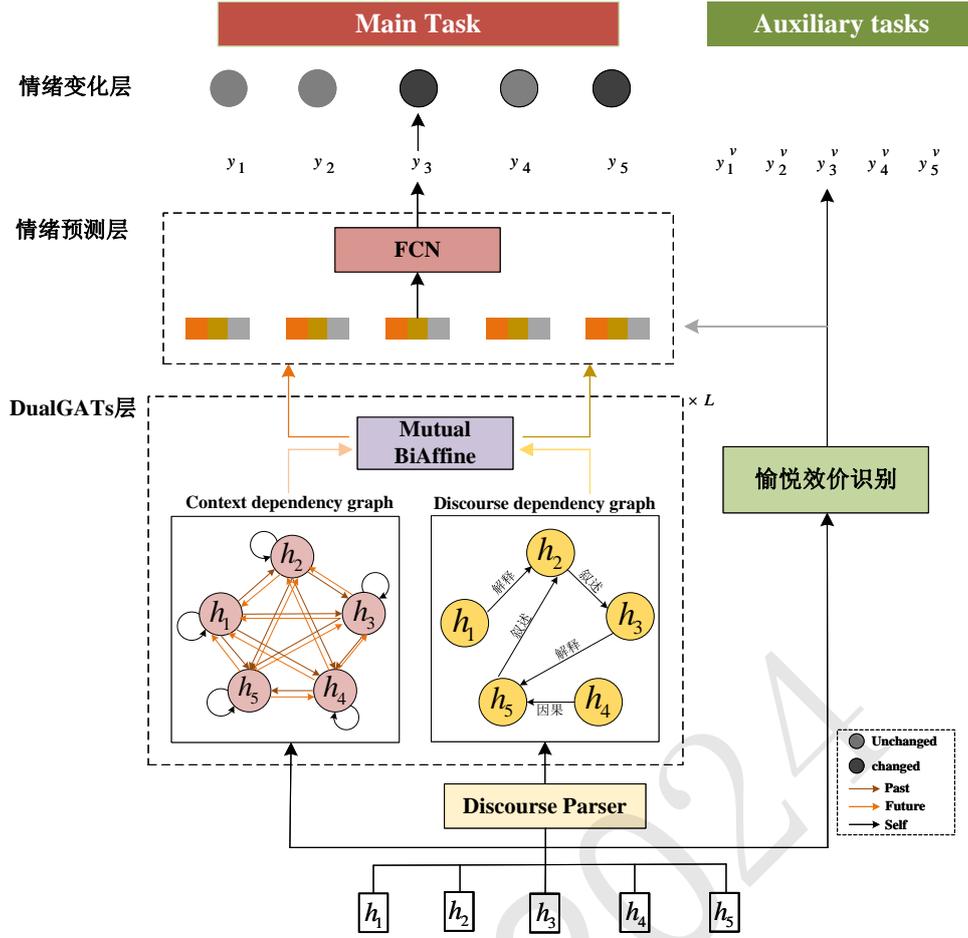


图 3: 散文情绪变化分析模型的框架图

$$a = V^T \tanh(W[h_i^s || h_i^k]) \quad (1)$$

$$h_i = \alpha \begin{bmatrix} h_i^{s^T} \\ h_i^{k^T} \end{bmatrix} \quad (2)$$

其中,  $h_i \in R^{d_s}$ ,  $d_s$ 表示特征表示的维度, 所有句子的特征表示为  $H^s \in R^{N \times d_s}$ 。

#### 4.2 愉悦效价识别层

依据图2中提出的情绪层次结构, 本文设计愉悦效价识别层, 利用句子的特征表示  $h_i$  作为输入, 通过公式(3), 获得给定句子的愉悦分布, 以期使用该分布提升主要的情绪变化分析任务的性能。

$$val_i^v = \text{ReLU}(W_h^v h_i + b_h^v) \quad (3)$$

其中,  $W_h^v \in R^{d_h \times d_s}$ ,  $b_h^v \in R^{d_h}$ 是可训练的参数,  $val_i^v \in R^{d_h}$ 表示句子  $S_i$  的愉悦效价分布。通过softmax函数, 对散文  $D$  中每个句子  $S_i$  的愉悦效价类别进行分类:

$$\hat{p}_i^v = \text{softmax}(W_l^v val_i^v + b_l^v) \quad (4)$$

$$\hat{y}_i^v = \arg \max_i(\hat{p}_i^v) \quad (5)$$

其中,  $W_l^v \in R^{d_e \times d_h}$ ,  $b_l^v \in R^{d_e}$ 是可训练的参数,  $\hat{y}_i^v$ 表示预测的句子  $S_i$  的愉悦效价标签。

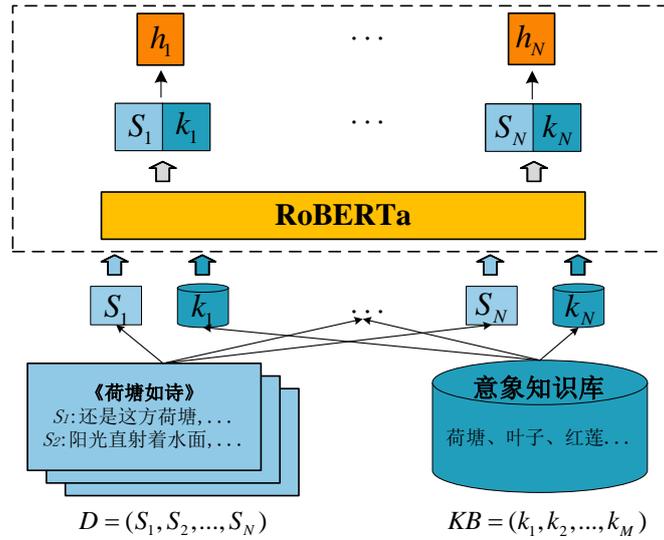


图 4: 特征提取层的概述图

### 4.3 DualGATs层

为了有效地捕获文章中的上下文知识和语篇依赖结构, 本文设计了DualGATs层, 包括三个基本模块: 上下文依赖图、语篇依赖图及交互模块。本节概述初始层中每个模块的计算过程, 随后将其扩展到多个后续层。

#### (1) 上下文依赖图

通过构建上下文依赖图(CotGAT), 能够较好地理解文章的情绪变化过程。CotGAT的构建基于三种上下文依赖类型: Past、Future和Self (简称为集合 $R^{Cot}$ )。其中, Past表示过去句子对当前句子的影响, 有助于理解前文情绪对当前情绪的延续和转折; Future指的是将来句子对当前句子的影响, 反映后续内容对当前情绪的预设和引导作用; Self表示当前句子内部的情绪变化和发展。

本文将文章的上下文依赖图定义为 $G^{Cot} = (V^{Cot}, E^{Cot})$ , 其中 $V^{Cot}$ 表示节点集合,  $E^{Cot}$ 是描述节点(句子)之间的上下文依赖关系的邻接矩阵。 $v_i^{Cot}$ 表示 $S_i$ (第 $i$ 个句子), 其表示用相应的特征表示 $h_i$ 进行初始化。对于任何 $S_i$ 和 $S_j$ , 如果它们满足上下文依赖类型 $r^{Cot} \in R^{Cot}$ , 那么 $e_{i,j}^{Cot} = r^{Cot}$ 。构建上下文依赖图之后, 应用CotGAT模块在图节点间传播和聚合上下文信息。CotGAT模块建立在GAT(Velickovic et al., 2018)之上, 但包含类型编码, 以考虑节点之间的时间依赖类型。具体来说, 对于给定节点 $v_i^{Cot}$ , CotGAT对其相邻节点进行信息聚合, 具体操作如式(6)-(7)所示。

$$a_{i,j} = \text{softmax}(\text{LRL}(a^T [Wh_i || Wh_j | e_{i,j}^{Cot}])) \quad (6)$$

$$h_i^{Cot} = \sum_{j \in N_i^{Cot}} a_{i,j} Wh_j \quad (7)$$

$a_{i,j}$ 表示从节点 $v_i^{Cot}$ 到邻居 $v_j^{Cot}$ 的边权值, LRL表示LeakyReLU激活函数,  $W$ 和 $a$ 表示可训练的参数,  $e_{i,j}^{Cot} \in R^{|R^{Cot}|}$ 表示节点 $v_i^{Cot}$ 和 $v_j^{Cot}$ 之间的语篇依赖类型对应的one-hot编码(模型训练时固定),  $|R^{Cot}|$ 表示语篇依赖类型的数量,  $||$ 表示连接操作,  $N_i^{Cot}$ 表示图 $G^{Cot}$ 中节点 $v_i^{Cot}$ 的邻居,  $h_i^{Cot} \in R^{d_h}$ 表示节点 $v_i^{Cot}$ 在CotGAT模块更新后的隐藏表示。更新后的所有节点的隐藏表示可以表示为 $H^{Cot} \in R^{N \times d_h}$ 。将初始层的CotGAT计算过程进行总结, 如式(8)所示。

$$H^{Cot} = \text{CotGAT}(H^s, E^{Cot}) \quad (8)$$

#### (2) 语篇依赖图

文章的语篇结构反映了内容的逻辑框架, 也是情绪变化分析的重要依据。根据Asher等人(2016)中的概述, 依赖逻辑类型共十五种: 注释、澄清问题、解释、背景、叙述、确认、细

化、延续、条件、问答对、交替、结果、纠正、平行和对比（简称为集合 $R^{Dep}$ ）。这些依赖类型在文章中扮演着不同的角色。注释、澄清问题、解释、背景、叙述和确认这六种类型，提供了情绪变化的背景信息和解释说明，有助于更好地理解情绪变化的背景和原因。细化和延续这两种类型延续了情绪变化的主题，有助于深入探讨情绪变化的细节。此外，条件和问答对的运用，促进了对于情绪变化的思考和探索。而交替、结果、纠正、平行和对比这五种类型，则呈现不同情绪状态之间的对比和转变。因此，本文利用这些依赖逻辑类型，建立语篇依赖图(DepGAT)，以刻画情绪变化的内在逻辑。

在本方法中，文章中的每个句子都被视为一个基本语篇单元(记作EDUs)。因此，本文将文章的语篇依赖图定义为 $G^{Dep} = (V^{Dep}, E^{Dep})$ ，其中 $V^{Dep}$ 表示EDUs的节点集， $E^{Dep}$ 表示EDUs之间语篇依赖关系的邻接矩阵。 $v_i^{Dep}$ 表示与句子 $S_i$ 对应的节点，其表示用相应的特征表示 $h_i$ 进行初始化。使用预训练的解析器(Shi and Huang, 2019)预测文章中各个句子之间的语篇依赖关系。如果从句子 $S_i$ 到句子 $S_j$ ，存在语篇依赖类型 $r^{Dep} \in R^{Dep}$ ，边 $E_{i,j}^{Dep}$ 被赋予相应的依赖类型。构建文章的语篇依赖图后，应用DepGAT模块在图节点之间传播和聚合句子依赖信息。同样，总结初始层DepGAT的计算过程，如式(9)所示。

$$H^{Dep} = \text{DepGAT}(H^s, E^{Dep}) \quad (9)$$

### (3) 交互模块

为了有效融合上下文知识和语篇依赖信息，采用相互交叉注意机制，建立融合语篇依赖结构的上下文表示、融合上下文信息的语篇结构表示。具体计算见式(10)-(12)所示。

$$A_1 = \text{softmax}(H^{Cot} W_1 (H^{Dep})^T) \quad (10)$$

$$A_2 = \text{softmax}(H^{Dep} W_2 (H^{Cot})^T) \quad (11)$$

$$H^{Cot'}, H^{Dep'} = A_1 H^{Dep}, A_2 H^{Cot} \quad (12)$$

其中， $W_1, W_2 \in R^{d_h \times d_h}$ 是可学习的参数， $A_1, A_2 \in R^{N \times N}$ 分别是 $H^{Cot}$ 到 $H^{Dep}$ ，从 $H^{Dep}$ 到 $H^{Cot}$ 的变化矩阵， $H^{Cot'}, H^{Dep'} \in R^{N \times d_h}$ 分别是所有句子的融合语篇依赖结构的上下文表示和融合上下文信息的语篇结构表示。

### (4) DualGATs层的多次迭代

为了深度提取句子的上下文知识和语篇依赖信息，使用 $L$ 层的DualGATs进行迭代。具体过程如式(13)-(16)所示。

$$H^{Cot,[l]} = \text{CotGAT}(D^{[l]}, E^{Cot}) \quad (13)$$

$$H^{Dep,[l]} = \text{DepGAT}(S^{[l]}, E^{Dep}) \quad (14)$$

$$H^{Cot',[l]}, H^{Dep',[l]} = \text{Inter}(H^{Cot,[l]}, H^{Dep,[l]}) \quad (15)$$

$$D^{[l+1]}, S^{[l+1]} = H^{Cot',[l]}, H^{Dep',[l]} \quad (16)$$

其中， $D^{[0]} = S^{[0]} = H^s$ ， $l \in [0, L - 1]$ 。

## 4.4 情绪预测层

通过连接第 $L$ 层DualGATs的输出和愉悦效价分布得到 $S_i$ 的最终表示，通过全连接网络进行分类，具体操作如式(17)-(19)所示。

$$l_i = \text{ReLU}(W_h [h_i^{Cot',[L]} || h_i^{Dep',[L]} || val_i^v] + b_h) \quad (17)$$

$$\hat{p}_i = \text{softmax}(W_l l_i + b_l) \quad (18)$$

$$\hat{y}_i = \arg \max_i(\hat{p}_i) \quad (19)$$

其中 $\hat{y}_i$ 是预测的句子 $S_i$ 的情绪标签， $h_i^{Cot',[L]}, h_i^{Dep',[L]} \in R^{d_h}$ 表示 $H^{Cot',[L]}$ 和 $H^{Dep',[L]}$ 中的第 $i$ 个表示， $val_i^v \in R^{d_h}$ 表示句子 $S_i$ 的愉悦效价分布， $W_h \in R^{d_h \times 3d_h}$ ， $W_l \in R^{d_e \times d_h}$ ， $b_h \in R^{d_h}$ ， $b_l \in R^{d_e}$ 是全连接网络的可学习参数。

对于情绪标签识别与愉悦效价识别两个任务，采用交叉熵损失进行约束，损失函数分别如式(20)、(21)所示。

$$L_e = -\frac{1}{BN} \sum_{\beta=1}^B \sum_{i=1}^N (y_{\beta,i} \log \hat{p}_{\beta,i} + (1 - y_{\beta,i}) \log(1 - \hat{p}_{\beta,i})) \quad (20)$$

$$L_v = -\frac{1}{BN} \sum_{\beta=1}^B \sum_{i=1}^N (y_{\beta,i}^v \log \hat{p}_{\beta,i}^v + (1 - y_{\beta,i}^v) \log(1 - \hat{p}_{\beta,i}^v)) \quad (21)$$

其中， $B$ 是文章的数量， $N$ 是第 $\beta$ 篇文章的句子总数， $\hat{p}_{\beta,i}$ ， $\hat{p}_{\beta,i}^v$ 为预测的句子 $S_i$ 的愉悦效价及情绪的标签分布。

利用多任务学习的方式，联合情绪标签识别和愉悦效价识别两者的损失得到最终损失 $L$ ：

$$L = L_e + L_v \quad (22)$$

#### 4.5 情绪变化识别层

在获得文章 $D$ 中各个句子的情绪标签 $y_1, y_2, \dots, y_N$ 之后，对文章的情绪脉络具有清晰的认知。通过比较相邻句子的情绪类别，可以揭示情绪变化的位置和趋势。正如图5所示，随着文章的叙述，《荷塘如诗》经历了从感慨到喜爱，再到厌恶的情绪变化。

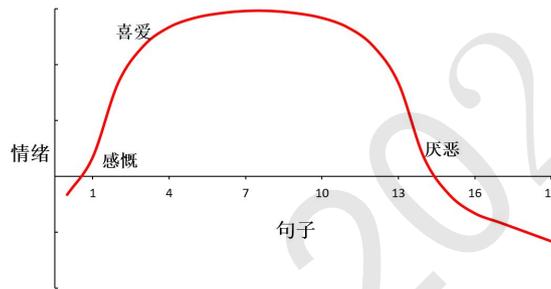


图 5: 篇章情绪变化分析图

## 5 实验

### 5.1 数据集介绍

根据人工标注整理后的7788条散文数据，按照7:1:2的比例进行随机划分，分为训练集、验证集和测试集。表2展示了数据集的具体划分情况。

划分	训练	验证	测试	总计
文章	200	30	60	290
句子	5203	1743	842	7788
变化	946	282	145	1373
文章长度(平均)	26.02	28.06	29.05	26.85

表 2: 数据集划分介绍

### 5.2 评价指标及参数设置

为了多维度评价模型的性能，本文从情绪类别和愉悦效价两个方面，采用准确率 (Accuracy) 以及Macro-F1作为主要评价指标。本方法使用Adam优化器进行训练。使用验证集的F1得分对DaulGAT层数进行超参数搜索，范围为{1, 2, 3, 4, 5, 6}。对于其余超参数，学习率为5e-05，Drouput率为0.4，RoBERTa的特征表示的维数为1024，隐藏表示的维数为300，最大输入文本长度设置为128。使用验证集中的最佳检查点来评估测试集。所有的实验都是在一个具有40GB内存的NVIDIA A100 GPU上进行的，并且平均超过五次运行。

### 5.3 实验设计

鉴于本文提出的任务较为新颖，目前还没有针对该任务的相关方法。同时，由于篇章级情绪分类方法相对较少，为验证本文提出方法的有效性，我们主要采用近年来用于句子级情绪分类任务的方法作为对比。在散文情绪变化数据集上将本文的方法与以下八种方法进行比较。

RoBERTa-large(Liu et al., 2019): 该模型对整个词进行MASK处理，模型能够充分理解上下文及语义关联。

ERNIE<sup>2</sup>: 该模型基于BERT(Devlin et al., 2019)模型，在预训练阶段增加外部知识，实现了实体级别的掩码机制。

Text-level GNN(Huang et al., 2019): 该模型没有构建单个语料库级图，而是为每个输入文本生成一个文本级图，节点从相邻节点获取信息以更新其表示。

Vanilla-VGCN-BERT: 类似于(Jeong et al., 2019)，通过BERT和VGCN产生两个独立的表示，并将它们连接起来。最后对连接表示应用ReLU和全连接层以进行分类。

VGCN-BERT(Lu et al., 2020): 该模型通过注意机制实现局部信息与全局信息的交互，允许它们相互影响，并共同构建用于分类的最终表示。

SKEP(Tian et al., 2020): 该模型构建了三个情绪知识预测目标，将词、极性和方面层面的情绪信息嵌入到预训练的情绪表示中。

SentiWSP(Fan et al., 2022): 该模型通过设计对比学习框架，提升已训练的判别器对于句子情绪层面的信息捕捉能力。

KESA(Zhao et al., 2022): 该模型提出情绪词选择和条件情绪预测两个情绪感知辅助任务，并相应地将它们整合到下游任务的目标中。

### 5.4 实验结果及分析

#### 5.4.1 实验比较及分析

利用5.3节设计的八种方法与本文方法进行对比实验，实验结果如表3所示。

模型	情绪(%)		愉悦效价(%)	
	Acc	MacF1	Acc	MacF1
RoBERTa-large	48.22	45.78	62.31	63.14
ERNIE	37.89	32.30	64.13	60.77
Text-level GNN	18.81	18.47	44.62	44.01
Vanilla-VGCN-BERT*	48.40	45.47	62.42	62.55
VGCN-BERT*	48.64	45.56	62.77	62.67
SKEP*	48.41	44.15	63.30	63.08
SentiWSP	47.82	46.10	60.19	58.45
KESA	50.45	45.65	66.43	61.63
Ours	<b>52.61</b>	<b>51.60</b>	<b>77.57</b>	<b>77.27</b>

表 3: 情绪及愉悦效价识别结果(标记\*表示使用RoBERTa-large模型)

通过表3可以看出:

(1) 本文提出的模型在散文数据集上始终优于所有对比方法。这些结果表明，本文的方法可以有效分析散文情绪。

(2) SKEP模型使用情绪词、方面项进行预训练，其性能显著优于ERNIE等没有使用这些知识的方法。因此，本文利用意象知识库，获取意象信息，从而较为准确地了解情绪来源。

(3) 本文提出的方法明显优于SentiWSP、VGCN-BERT等句子级情绪分析方法，其原因在于本文方法依据散文的复杂性和逻辑性，充分考虑句间信息，对上下文关系及语篇依赖关系进行建模，从而提升了模型的效果。

#### 5.4.2 消融实验

为了验证模型中每个组件的有效性，我们进行了广泛的消融研究。将模型去除上下文依赖图记为-CotGAT；将模型去除语篇依赖图记为-DepGAT；将模型去除注意力网络间的交互模块记为-交互模块；将模型去除意象知识库记为-意象；将模型去除愉悦效价识别模块记为-愉悦效价识别。结果如表4所示。

<sup>2</sup><https://github.com/PaddlePaddle/ERNIE>

模型	情绪(%)		愉悦效价(%)	
	Acc	MacF1	Acc	MacF1
Ours	<b>52.61</b>	<b>51.60</b>	<b>77.57</b>	<b>77.27</b>
-CotGAT	51.12	50.84	76.25	76.00
-DepGAT	50.66	51.01	76.42	76.45
-交互模块	51.41	50.70	75.62	75.38
-意象	50.37	50.09	77.40	77.02
-愉悦效价识别	51.04	50.43	76.49	76.47

表 4: 消融实验结果

由表4可以看出:

(1) 本文的方法 (Ours) 是所有性能中最佳的。从完整的模型中删除交叉注意模块、意象知识库、愉悦效价识别层的任何一个, 性能都会下降。其中意象模块对散文数据集的影响最大, 可能是由于散文是以意象为线索, 将情绪贯穿于文章中。

(2) -DepGAT仅对文章的上下文关系进行建模, 而散文具有含蓄细腻的特点, 它获取的句子表示比较浅层。

(3) -CotGAT只对文章的语篇依赖关系进行建模, 并且取得了比DepGAT更高的准确率, 说明语篇依赖结构有助于提取深层句间信息。

### 5.4.3 DualGAT层数的影响

为了研究DualGAT层数的影响, 我们在散文情绪变化数据集上对一到六层的DualGAT进行评估。如图6所示, 具有两个DualGAT层的模型表现最佳。一方面, 在层数较少的情况下, 上下文信息和语篇依赖信息可能无法得到充分的提取。另一方面, 当层数过多时, 产生了冗余或者兼容的信息, 导致模型的性能下降。

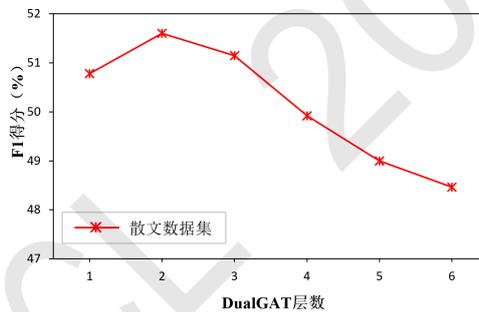


图 6: DualGAT层数的影响

### 5.4.4 错误分析

在本节对错误结果进行分析。表5列出一些本文模型未能正确识别出情绪类别的例子。

文章号	例句	情绪类别	模型识别
12	而突然冒出的尖厉噪声当然属于鸣蝉, 这些心里只有自己的家伙个个愤世嫉俗、怀才不遇, 不停歇地嚷着:“是我——是我——”。	恶	怒
225	实际, 我向来对于花木无所爱好。	其他	恶

表 5: 部分情绪类别识别错误示例

根据表5, 在文章编号为12的一个句子中, “恶”与“怒”都属于负面情绪, 但两者代表着不同的含义, 而模型无法界定两者的区别, 导致结果有误。在文章编号为225的一个句子中, 模型错误地将情绪识别为“恶”, 可能是由于“向来”、“无所爱好”等具有负面情绪色彩的词语, 然而结合上下文信息, 该句并没有表达明确的情绪倾向。

## 6 结论

本文利用意象知识库，提出一个基于双图注意力网络的篇章级散文情绪变化分析方法，同时设计愉悦效价识别层，可以较精确地对散文情绪变化进行分析。其中为了有效地交互上下文依赖图与语篇依赖图之间的信息，使用相互交叉注意机制。在散文数据集上的大量实验表明，本模型可以有效地建模文章信息，提升对情绪变化分析的能力，为散文阅读理解中的思想情绪变化类问题的解答提供支持。

## 参考文献

- Jader Abreu, Luis Fred, David Macêdo, and Cleber Zanchettin. 2019. Hierarchical attentional hybrid neural networks for document classification. In *Artificial Neural Networks and Machine Learning – ICANN 2019: Workshop and Special Sessions: 28th International Conference on Artificial Neural Networks*, page 396–402.
- Nicholas Asher, Julie Hunter, Mathieu Morey, Benamara Farah, and Stergos Afantenos. 2016. Discourse structure and dialogue acts in multiparty dialogue: the STAC corpus. In *Proceedings of the Tenth International Conference on Language Resources and Evaluation*, pages 2721–2727.
- Xiang Dai, Ilias Chalkidis, Sune Darkner, and Desmond Elliott. 2022. Revisiting transformer-based models for long document classification. In *Findings of the Association for Computational Linguistics: EMNLP 2022*, pages 7212–7230.
- Dorottya Demszky, Dana Movshovitz-Attias, Jeongwoo Ko, Alan Cowen, Gaurav Nemade, and Sujith Ravi. 2020. GoEmotions: A dataset of fine-grained emotions. In *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics*, pages 4040–4054.
- Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. 2019. BERT: Pre-training of deep bidirectional transformers for language understanding. In *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, pages 4171–4186.
- Shuai Fan, Chen Lin, Haonan Li, Zhenghao Lin, Jinsong Su, Hang Zhang, Yeyun Gong, Jian Guo, and Nan Duan. 2022. Sentiment-aware word and sentence level pre-training for sentiment analysis. In *Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing*, pages 4984–4994.
- Lianzhe Huang, Dehong Ma, Sujian Li, Xiaodong Zhang, and Houfeng Wang. 2019. Text level graph neural network for text classification. In *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing*, pages 3444–3450.
- Chanwoo Jeong, Sion Jang, Hyuna Shin, Eunjeong Lucy Park, and Sungchul Choi. 2019. A context-aware citation recommendation model with bert and graph convolutional networks. *Scientometrics*, 124:1907–1922.
- Yinhan Liu, Myle Ott, Naman Goyal, Jingfei Du, Mandar Joshi, Danqi Chen, Omer Levy, Mike Lewis, Luke Zettlemoyer, and Veselin Stoyanov. 2019. Roberta: A robustly optimized bert pretraining approach. *ArXiv*, abs/1907.11692.
- Zhibin Lu, Pan Du, and Jianyun Nie. 2020. Vgcn-bert: Augmenting bert with graph embedding for text classification. *Advances in Information Retrieval*, 12035:369–382.
- James A. Russell. 1980. A circumplex model of affect. *Journal of Personality and Social Psychology*, 39:1161–1178.
- Zhouxing Shi and Minlie Huang. 2019. A deep sequential model for discourse parsing on multi-party dialogues. *Proceedings of the AAAI Conference on Artificial Intelligence*, 33(01):7007–7014.
- Hao Tian, Can Gao, Xinyan Xiao, Hao Liu, Bolei He, Hua Wu, Haifeng Wang, and Feng Wu. 2020. SKEP: Sentiment knowledge enhanced pre-training for sentiment analysis. In *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics*, pages 4067–4076.
- Thien Khai Tran and Tuoi Thi Phan. 2020. Capturing contextual factors in sentiment classification: An ensemble approach. *IEEE Access*, 8:116856–116865.

- Petar Velickovic, Guillem Cucurull, Arantxa Casanova, Adriana Romero, Pietro Lio', and Yoshua Bengio. 2018. Graph attention networks. *International Conference on Learning Representations*.
- Liang Yao, Chengsheng Mao, and Yuan Luo. 2019. Graph convolutional networks for text classification. *Proceedings of the AAAI Conference on Artificial Intelligence*, 33(01):7370–7377.
- Mi Zhang and Tiejun Qian. 2020. Convolution over hierarchical syntactic and lexical graphs for aspect level sentiment analysis. In *Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing*, pages 3540–3549.
- Qinghua Zhao, Shuai Ma, and Shuo Ren. 2022. KESA: A knowledge enhanced approach to sentiment analysis. In *Proceedings of the 2nd Conference of the Asia-Pacific Chapter of the Association for Computational Linguistics and the 12th International Joint Conference on Natural Language Processing*, pages 766–776.
- 王小环. 2023. 论中国现代散文语言的美学呈现. 青岛科技大学学报:社会科学版, 39(01):59–65.