

基于知识图谱与双重图卷积的情感分类模型

林军利*, 李 婷

重庆人文科技学院有限责任公司计算机工程学院, 重庆

收稿日期: 2025年10月17日; 录用日期: 2025年11月17日; 发布日期: 2025年11月25日

摘 要

在情感分析的任务中, 获取文本语义信息、句法信息和外部知识是至关重要的。但是目前的算法模型中, 文本与外部知识的关联较少, 导致语义表示不够全面。所以本文提出一种基于知识图谱与双重图卷积的情感分类模型。模型先利用LSTM算法提取文本的上下文信息, 同时采用知识图谱卷积网络获取与文本相关的实体的外部知识; 再通过实体对齐和对齐预测, 进行动态融合文本嵌入与知识嵌入; 最后将融合了文本和知识的信息作为输入, 使用句法图卷积网络和语义图卷积网络获取句法和语义信息, 实现情感分析。根据实验表明, 该模型融合了文本与实体知识, 增强了语义语法信息, 有效提升了情感分类的准确性。

关键词

知识图谱, 图卷积神经网络, 情感分析

Emotion Classification Model Based on Knowledge Graph and Dual Graph Convolution

Junli Lin*, Ting Li

School of Computer Science and Engineering, Chongqing College of Humanities, Science & Technology, Chongqing

Received: October 17, 2025; accepted: November 17, 2025; published: November 25, 2025

Abstract

In sentiment analysis tasks, acquiring textual semantic information, syntactic information, and external knowledge is crucial. However, current algorithmic models often lack sufficient association between text and external knowledge, resulting in incomplete semantic representation. Therefore, this paper proposes a sentiment classification model based on a knowledge graph and dual graph convolution. The model first employs the LSTM algorithm to extract contextual information from the text,

*通讯作者。

文章引用: 林军利, 李婷. 基于知识图谱与双重图卷积的情感分类模型[J]. 计算机科学与应用, 2025, 15(11): 207-219.
DOI: 10.12677/csa.2025.1511298

while using a knowledge graph convolutional network to acquire external knowledge related to entities in the text. Then, through entity alignment and alignment prediction, it dynamically integrates text embeddings and knowledge embeddings. Finally, the fused information combining text and knowledge is used as input, and a syntactic graph convolutional network and a semantic graph convolutional network are applied to capture syntactic and semantic information, thereby achieving sentiment analysis. Experiments demonstrate that this model effectively integrates text and entity knowledge, enhances semantic and syntactic information, and significantly improves the accuracy of sentiment classification.

Keywords

Knowledge Graph, Graph Convolutional Neural Network, Sentiment Analysis

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

方面级情感分析[1]是自然语言处理的重要任务之一,它能够根据文本分析出用户对产品的喜爱或厌恶,常用的分析方式有两种:句子级情感分析和方面级情感分析。例如对“演技都在线,但是配乐不好听。”进行句子级情感分析时,给出的情感分析结果是用户对该电影表达出了中性情感。如果它进行方面级情感分析,可以分析出用户对“演技”方面表达出了积极情感,对“配乐”表达出了消极情感。由此可以看出,方面级情感分析对文本具有更细的粒度。方面级情感分析在实际生活中有极其重要的作用,例如提升用户体验,提升产品质量,监督舆情等,对提升人们生活品质占据着关键地位。

目前,方面级情感分析常用的算法主要有基于(Convolutional Neural Network, CNN) [2]的算法和基于图神经网络(Graph Convolutional Network, GCN) [3]-[6]的算法。基于卷积神经网络的算法主要通过卷积核提取局部特征,并结合方面词的位置进行信息增强。但卷积神经网络存在对文本上下文捕捉能力不足,以及对复杂的句子提取失真的问题。基于图卷积神经网络的算法将文本处理成图结构数据,通过多层图卷积操作,有效捕捉方面词与情感词的关联[7]。所以本文主要采用句法 GCN [8]和语义 GCN [9]双 GCN 结构,对融合了文本和外部知识图谱信息的图数据进行捕捉,弥补语义知识不够全面的问题,以此对文本中的情感进行精准分析。

本文中的贡献总结如下:

- 1) 本文提出一种基于知识图谱与双重图卷积的情感分类模型(KGDGCN),用于情感分析。模型融合文本和外部知识图谱信息,利用双 GCN 捕捉语义和句法信息,通过多维度特征交互与知识增强提升情感分析性能。
- 2) 为了将外部知识融合到语义和句法信息之中,本文采用 KGCN 算法[10][11]对外部实体进行编码,以此聚合邻居实体和用户的信息,并将编码后的序列通过实体对齐和对齐预测动态融合文本信息,进而提升了文本的信息量。
- 3) 本文提供了中文的情感分析任务的数据,以及外部知识图谱。本文数据是来自真实的电影评论数据,以及相关电影知识图谱。经过数据处理,文本数据包含语义信息、句法信息、词性等细粒度语言学特征,电影知识图谱包含电影的基本信息。该数据扩充了中文情感分析任务中的实验数据,为算法验证提供了真实的数据支撑。

2. 相关工作

方面级情感分析算法从传统的机器学习方法到现在的深度学习。传统的机器学习算法主要有支持向量机[12]、朴素贝叶斯[13]等经典算法,其解释性强、训练成本低,但对文本语义的捕捉能力有限,无法处理复杂语境。为改进这个问题,提出了LSTM[14]、RNN[15]算法,利用序列模型提取文本的上下文信息,通过注意力机制,着重将注意力聚焦到与方面词相关的词语之中,但对句法结构不太重视,难以充分利用语法层面的约束信息。卷积神经网络能够有效提取数据局部特征,降低模型的复杂度,提高训练速度,但对于图结构数据无法有效提取特征。图卷积神经网络和卷积神经网络都对特征的提取有着极大的优势,而图卷积神经网络对于处理图结构数据更高的适配性。而知识图谱[16]-[21]就是一种图结构数据,其优点是能够充分保留实体之间的关系,若将知识图谱作为情感分析文本的外部知识,并采用图卷积神经网络算法对融合了文本和知识图谱进行特征捕获,能够有效提高情感分析的效果。

基于此,本文采用KGCN算法对知识图谱进行编码,该编码能够保留实体与用户之间潜在关系,同时融合了文本的句法信息和语法信息,并采用双图卷积神经网络提取句法和语义特征,实现多维度信息的深度协同。

3. 模型

本文提出的模型结构如图1所示:




Figure 1. Emotion classification model based on knowledge graph and dual graph convolution
图1. 基于知识图谱与双重图卷积的情感分类模型

本文提出的模型结构如图 1 所示, 主要由 5 个部分构成。

- 1) 文本特征提取模块。其目标是预处理文本输入数据, 生成句法邻接矩阵, 调用 GCN 核心模块并聚合特征。
 - 2) 知识图谱模块。其目标是从知识图谱中聚合实体信息, 生成用户与物品的知识嵌入。
 - 3) 文本 - 知识图谱嵌入模块。动态融合文本嵌入与知识图谱嵌入, 增强文本语义表示。
 - 4) 双 GCN 模块。将融合了文本和知识图谱特征的输入, 使用句法图卷积网络和语义图卷积网络来捕捉文本结构和语义。
 - 5) 分类模块: 协调整体流程, 整合特征并输出预测结果, 计算惩罚项。
- 各部分职责明确且协同工作, 共同完成从输入处理到输出预测的全过程。

3.1. 文本特征提取模块

本文采用 LTP 工具包(Language Technology Platform) [22]处理中文评论。LTP 提供了一系列中文自然语言处理工具, 用户可以使用这些工具对于中文文本进行分词、词性标注、句法分析等工作。例如评论“演技都在线, 但是配乐不好听。”通过 LTP 之后可以得到: "token": ['演技', '都', '在线', ',', '但是', '配乐', '不', '好听', '.'], "pos": ['n', 'd', 'v', 'wp', 'c', 'n', 'd', 'a', 'wp'], "head": [3, 3, 0, 3, 8, 8, 3, 8], "deprel": ['EXP', 'mDEPD', 'Root', 'mPUNC', 'mRELA', 'EXP', 'mNEG', 'eSUCC', 'mPUNC'], 其中 token 表示分词; pos 表示词性标注; head 表示依存句法头部; deprel 表示依存关系。

将 LTP 处理过后的数据, 进行编码及嵌入处理(词嵌入、词性嵌入、位置嵌入拼接)后, 再利用 LSTM 算法提取评论中上下文信息, 生成文本输入。此外, 将 LTP 处理后的句法依存信息, 生成生成句法邻接矩阵, 作为句法 GCN 的输入。

3.2. 知识图谱模块

知识图谱模块主要包括知识图谱构建和知识图谱编码。

知识图谱由“实体 - 关系 - 实体”的三元组组成, 实体之间可通过关系进行相互连接, 形成网状的知识结构。本文采用豆瓣电影的数据构建知识图谱, 原始数据是结构性数据, 所以构建方式只需要选择需要的电影信息即可。电影的知识图谱有电影类型, 语言, 来源国家, 主演, 导演, 电影标签, 年份, 豆瓣评分, 片长等信息。由于全部电影的知识图谱图片较大, 本文只展示部分的电影知识图谱作为示例。构建的知识图谱如图 2 所示:

图 2 中展示了部分电影知识图谱。标注“绿色节点(电影《之子于归》及其关联实体, 如类型、语言、来源国家、年份等)”“紫色节点(电影《理查二世》及其关联实体, 如主演、导演、标签、年份等)”“边(实体间的关系, 如‘被分类为’‘演绎’‘被指导’等)”。该图为基于豆瓣电影数据构建的电影知识图谱部分示例, 以《之子于归》《理查二世》两部电影为核心, 展示其与类型、语言、主演、导演等实体的关联关系, 呈现“实体 - 关系 - 实体”的网状知识结构, 用于直观体现电影知识图谱的构建形式与信息关联逻辑。

知识图谱编码的目的是需要获取评论对应的物品的知识, 聚合了相关实体和用户知识。步骤主要有数据采样、聚合邻居节点信息、组合当前节点和邻居节点, 各步骤详情如下:

1) 数据采样

有知识图谱 $G(h, r, t)$, 其中 $h \in \mathcal{E}$, $r \in \mathcal{R}$, $t \in \mathcal{E}$; $\mathcal{E}$ 表示知识图谱中实体集; $\mathcal{R}$ 表示知识图谱中的关系集。物品节点 v 的知识图谱示例, 如图 3 所示。




Figure 2. Partial movie knowledge graph
图 2. 电影知识图谱(部分)




Figure 3. Example of a knowledge graph for item v
图 3. 物品 v 的知识图谱示例

图 3 是关系图采样得到的子图，展示目标物品该图为关系图采样得到的子图，展示目标物品 v 与其邻接实体 e_i 通过关系 r_i 构成的知识图谱结构，其中关系的权重反映其对用户行为偏好的影响程度，用于辅助收集节点周围信息以支持分析或预测任务。与其邻接实体通过关系构成的知识图谱结构，其中关系的权重反映其对用户行为偏好的影响程度，用于辅助收集节点周围信息以支持分析或预测任务。中间的节点是要预测的目标物品 v 。 e_i ， v_i 表示物品 v 的邻居实体， r_i 表示实体之间的关系。

G 作为有权图，关系会变为权重。这个权重可被理解是该关系影响用户行为的偏好程度，可以帮助本文收集节点周围信息。

$$\pi_r^u = g(u, r) \quad (1)$$

π_r^u 是 G 的权重, u 是用户向量, r 是物品之间的关系。

$\tilde{\pi}_{r_{v,e}}^u$ 表示为物品之间归一化后的权重:

$$\tilde{\pi}_{r_{v,e}}^u = \frac{\exp(\pi_{r_{v,e}}^u)}{\sum_{e \in N(v)} \exp(\pi_{r_{v,e}}^u)} \quad (2)$$

2) 聚合邻居节点信息

为了将邻居的节点信息传递给当前节点, 需要将邻居节点进行加权求和。邻居节点进行加权求和公式如公式(3)所示。

$$v_{N(v)}^u = \sum_{e \in N(v)} \tilde{\pi}_{r_{v,e}}^u e \quad (3)$$

例如图 3 中, e_i 代表第 i 个邻居的特征向量。根据图采样的思想, 消息传递是有外而内进行的。所以例如在进行图 3 中的节点 e_8 , e_9 传递到 e_3 时, 那么 e_3 就带入上述式子中 $v_{N(v)}^u$ 的位置即可, 利用上述公式得到 e_3 消息聚合后的特征向量后, 最终传递给中心 v , 得到特征向量 $v_{N(v)}^u$ 。

总体来说, 这部分就是一个聚合器。把邻居节点的信息聚合起来。

由于会出现某一个结点 n 存在过多的邻居的情况, 会为整体的模型的计算带来巨大的压力。此时定义一个超参数 K , 对于每一个结点 v , 只是选取 K 个邻居进行计算。也就是说, 此时 n 的邻域表示记作 S , 且满足:

$$S(n) \rightarrow \{e | e \in N(n)\} \text{ or } \{f \in N(u)\}, |S(n)| = K \quad (4)$$

3) 组合当前节点和邻居节点

到当前节点之间需要进行一次消息组合, 需要将节点信息与邻居节点信息组合, 更新节点信息。组合公式, 如公式(9)所示。

$$E_k = \sigma_v \left(W_v \cdot \text{agg} \left(e, v_{S(v)}^u \right) + b_v \right) \quad (5)$$

其中 σ_v 是非线性激活函数, 如 Relu, sigmoid。 W_v 就是线性变换矩阵, b_v 是偏置项。这些都是一个全阶层的基本元素。而 $\text{agg} \left(e, v_{S(v)}^u \right)$ 即表示对物品 v 再做一次消息聚合, $S(v)$ 表示 v 的所有邻域, $v_{S(v)}^u$ 指物品 v 前一轮迭代更新产生的向量。

组合有三种方式:

1) 求和组合:

$$\text{agg}_{sum} = e + v_{S(v)}^u \quad (6)$$

即将 $e + v_{S(v)}^u$ 对应元素位相加。

2) 拼接组合:

$$\text{agg}_{concat} = \text{concat} \left(e, v_{S(v)}^u \right) \quad (7)$$

即将向量 $v_{S(v)}^u$ 与向量 e 拼接起来。如果原来它们的维度都为 F , 那么拼接后的向量维度就 $2F$, 所以外面的线性变化矩阵 W 和偏置项 b 的维度也需要相应的变化。

3) 邻居组合:

$$\text{agg}_{neighbor} = v_{S(v)}^u \quad (8)$$

就是直接采用 $v_{S(v)}^u$ 当作网络输出向量。

3.3. 文本 - 知识图谱嵌入模块

将知识拓展与文本维度一致:

$$E_k^{expanded} = expanded(E_k) \quad (9)$$

其中, $E_k \in R^{B \times D_k}$ 表示知识经过 KGCN 算法处理之后的数据, D_k 为知识嵌入维度, $E_k^{expanded} \in R^{B \times L \times D_t}$, B 为批次大小, L 为文本长度, D_t 为文本嵌入维度。

拼接文本嵌入和扩展后的知识嵌入:

$$C = [E_t; E_k^{expanded}] \quad (10)$$

其中, C 表示文本和沿最后一维拼接, E_t 表示评论文本序列。

计算注意力权重, 衡量每个文本位置与知识的相关性:

$$\alpha = softmax(tanh(C \cdot W_a + b_a) \cdot W_b + b_b) \quad (11)$$

其中, α 表示注意力权重, W_a 注意力第一层权重, b_a 注意力第一层偏置, W_b 注意力第二次权重, b_b 注意力第二次偏置。

用对齐矩阵过滤无效权重并重新归一化:

$$\alpha' = normalize(\alpha \odot M) \quad (12)$$

其中, α' 表示过滤后无效关联的权重, $normalize()$ 表示归一化, M 用于标记文本序列中每个位置与知识图谱实体之间的对齐关系强度, $\odot$ 为元素积。

知识嵌入投影到文本维度并加权聚合:

$$E_k^{proj} = E_k^{expanded} \cdot W_p + b_p \quad (13)$$

其中, E_k^{proj} 为投影后的知识序列, W_p , b_p 分别表示投影的权重、偏置。

知识加权求和:

$$E_k^{exp} = expand\left(\sum_{l=1}^L \alpha'_l \cdot E_{k_l}^{proj}\right) \quad (14)$$

其中, E_k^{exp} 表示加权聚合后并扩展与文本序列一致的知识序列。

融合文本嵌入和知识嵌入

$$E_{fused} = E_t + E_k^{exp} \quad (15)$$

其中, E_{fused} 表示融合了文本序列和知识序列的编码, 作为双 GCN 模块的输入。

3.4. 双 GCN 模块

本模块由两个 GCN 模型构成, 其中句法 GCN 来捕捉句子的句法结构信息, 语义 GCN 来捕捉句子的语义关联。对于图结构化数据, GCN 可以在直接连接的节点上应用卷积运算来对局部信息进行编码。通过多层 GCN 的消息传递, 图中的每个节点都可以学习更多的全局信息, 其中对于第 l 层的第 i 个节点, 其隐藏状态表示(记为 h_i^l)。GCN 计算方法如下:

$$h_i^l = \sigma\left(\sum_{j=1}^n A_{ij} W^l h_j^{l-1} + b^l\right) \quad (16)$$

其中, A_{ij} 表示邻接矩阵(两个 GCN 采用不同的邻接矩阵), W^l 是权重矩阵, b^l 是偏差项, 是 σ 激活函数。

句法 GCN 的输入除了有文本序列和知识序列的编码以外, 还包括句法编码。为了对句法信息进行编码, 利用依赖解析器输出的依赖弧的概率矩阵, 依赖概率矩阵能够通过输入提供的句法结构捕捉句法信息。本文中, 使用依赖性解析模型 LAL-Parser 获取句法编码得到邻接矩阵 A^{syn} 。该模型通过注意力机制计算出每个词与方面词之间的分数, 分数越高, 表示该词与方面词的紧密程度越高。

语义 GCN 没有像句法 GCN 一样用额外的句法知识, 而是通过基于多头注意力机制构建语义邻接矩阵, 能够很好地反映词语间的语义相关性, 不依赖语法结构。

$$A^{sem} = softmax \left(\frac{QW^Q \times (KW^K)^T}{\sqrt{d}} \right) \quad (17)$$

其中矩阵 Q 和 K 是语义 GCN 模块上一层的图表示, 而 W^Q 和 W^K 是可学习的权重矩阵。此外, d 是输入节点特征的维度。

为了让句法 GCN 和语义 GCN 模块之间有效地交换相关特征, 采用公式, 让两者进行交流:

$$H^{syn'} = softmax \left(H^{syn} W_1 (H^{sem})^T \right) H^{sem} \quad (18)$$

$$H^{sem'} = softmax \left(H^{sem} W_2 (H^{syn})^T \right) H^{syn} \quad (19)$$

其中 W_1 和 W_2 是可训练的参数。

最后将句法 GCN 和语义 GCN 的隐藏层进行平均池化和拼接操作:

$$h_a^{syn} = f(h_{a_1}^{syn}, h_{a_2}^{syn}, \dots, h_{a_m}^{syn}) \quad (20)$$

$$h_a^{sem} = f(h_{a_1}^{sem}, h_{a_2}^{sem}, \dots, h_{a_m}^{sem}) \quad (21)$$

然后, 将获得的表示 m 输入到线性层中。

$$m = [h_a^{syn}, h_a^{sem}] \quad (22)$$

3.5. 情感分类

因为情感分为积极的、消极的、中性的, 所以要把最后的结果经过 $softmax()$, 得到最后的结果:

$$p(a) = softmax(Wm + b) \quad (23)$$

其中 W 和 b 是可学习的权重和偏差。

模型的损失函数包含了两个正则化, 一是约束语义关联矩阵的正交性 R_O , 二是平衡语义和句法信息 R_D , 具体计算方式如下:

$$R_O = \left\| A^{sem} (A^{sem})^T - I \right\|_F \quad (24)$$

$$R_D = \left\| A^{sem} - A^{syn} \right\|_F^{-1} \quad (25)$$

其中 I 是单位矩阵, F 弗罗贝尼乌斯范数。

模型的损失函数如公式:

$$L_T = L_C + \lambda_1 R_O + \lambda_2 R_D + \lambda_3 \|\Theta\|_2 \quad (26)$$

其中 λ_1 和 λ_2 是 λ_3 正则化系数, Θ 表示所有可训练的模型参数。 L_C 是标准交叉熵损失, 公式如下:

$$L_C = - \sum_{(s,a) \in D} \sum_{c \in C} \log p(a) \quad (37)$$

其中 D 表示包含所有句子 - 方面对, C 是不同情感极性的集合。

4. 实验结果分析

4.1. 数据集

本文的模型的数据来自真实的豆瓣网站电影的相关数据, 包含知识图谱数据和中文评论数据。

针对电影的中文评论处理时, 需要明确评论中体现出的情感分类情况, 情感分类有三种消极情感, 中性情感和积极情感, 其中消极情感数量为 1528, 中性情感数量为 524, 积极情感数量为 3056。

电影知识图谱是实体 - 关系 - 实体三元组组成, 由电影的基本信息构成, 其中电影数量为 211, 关系数量为 9, 实体数量为 1565, 知识图谱关系的详细情况如表 1 所示。

Table 1. Statistics on the number of entity-relationship-entity triples in the movie knowledge graph

表 1. 电影知识图谱实体 - 关系 - 实体三元组数量统计

头节点	关系	尾节点	数量
电影	被分类	类型	449
电影	被翻译	语言	256
电影	来源	国家	271
电影	演绎	主演	1180
电影	被指导	导演	220
电影	被评论	电影标签	167
电影	诞生于	年份	212
电影	评分	分数	1570
电影	演绎时间	片长	196

表 1 展示了电影知识图谱中 9 类三元组数量。其中, “电影 - 评分 - 分数” 的数量最多; “电影 - 演绎 - 主演” 也较为突出。这些关系涵盖了电影的类型、语言、来源、主创(主演、导演)、评论标签、年份、评分、片长等维度, 全面构建了电影的基本信息知识网络, 为模型提供了数据支撑。

4.2. 算法比较

本文在数据集上使用 KGDGCN, 并与以下算法进行比较, 其中 ATEA-LSTM [23] 是在 LSTM 算法的基础上加入了注意力机制, 有效提高了对序列数据的处理; IAN [24] 对输入文本的不同部分赋予不同的权重, 捕捉文本的语义信息和特征; DualGCN 采用双 GCN 获取语义和语法信息。为验证算法性能, 本文用精确率、召回率和 F1 值来评估。不同算法的实验对比结果, 如表 2 所示。

从表 2 中, 可以看到 DualGCN、KGDGCN 算法比 ATEA-LSTM、IAN 的性能更加优秀。从而可以得出运用图卷积神经网络有助于精确推荐。此外, 通过 DualGCN 与 KGDGCN 的精确率、召回率和 F1 值的对比, 可看出在结合了知识图谱后, 其性能得到了提升。

在本文模型中有三种组合当前节点和邻居节点方式, 即求和组合、拼接组合和邻居组合。不同组合方式的结果, 如表 3 所示。

Table 2. Classification results based on accuracy, precision, and F1-score
表 2. 基于准确率、精确率和 F1 指标的分类结果

基线算法	精确率	召回率	F1 值
ATEA-LSTM	0.665	0.655	0.660
IAN	0.663	0.664	0.664
DualGCN	0.697	0.647	0.685
Ours	0.773	0.721	0.746

Table 3. System resulting data of standard experiment
表 3. 标准试验系统结果数据

在一个当前节点和邻居节点方式	精确率	召回率	F1 值
求和组合	0.773	0.721	0.746
拼接组合	0.706	0.668	0.686
邻居组合	0.766	0.715	0.740
平均	0.748	0.701	0.724

根据表 3 所示, 组合当前节点和邻居节点方式中求和组合的精确率、召回率和 F1 值最高, 效果最好, 能够有效结合各个节点的信息。

4.3. 消融实验

为研究模型各部分的组成对实验结果的影响, 本文对 KGDGCN 模型设计了消融实验。实验过程中, 除了去掉动态对齐分数预测部分, 只采用句法 GCN 部分, 只采用语义 GCN 部分以外, 其他部分均不发生改变。

由表 4 可知, 去掉动态对齐分数预测部分后结果最差, 只采用句法 GCN 部分或只采用语义 GCN 部分后结果低于采用双 GCN 的结果, 由此得出各模块需要共同协作, 缺一不可。

Table 4. System resulting data of standard experiment
表 4. 标准试验系统结果数据

模型	精确率	召回率	F1 值
去掉动态对齐分数预测部分	0.709	0.679	0.694
句法 GCN	0.732	0.679	0.704
语义 GCN	0.741	0.688	0.713

4.4. 讨论

1) 探讨邻居节点抽样规模对结果的影响, 如表 5 所示。

表 5 中可以得到 $K=8$ 时, 推荐性能最好。这是因为 K 太小时, 不能有效获得领域信息。 K 太大时, 获得过多信息, 噪音较大。

Table 5. Impact of neighbor node sampling size**表 5.** 邻居节点抽样规模对结果的影响

K	2	4	8	16
精确率	0.731	0.766	0.773	0.747
召回率	0.689	0.700	0.721	0.690
F1 值	0.713	0.732	0.746	0.717

2) 探讨“聚合-组合”的次数, 即感受野深度。感受野深度对结果的影响, 如表 6 所示。

Table 6. Impact of depth of receptive field**表 6.** 感受野深度对结果的影响

H	1	2	3	4
精确率	0.773	0.669	0.669	0.680
召回率	0.721	0.650	0.670	0.652
F1 值	0.746	0.659	0.670	0.666

由表 6 可知, 当 H 从 1 到 4 的变化时, $H = 1$ 时效果最好。由于 h 设置过大, 一方面容易造成计算量大, 另一方面会导致信息重合。

3) 探讨 GCN 层数对模型的影响

由表 7 可知, 当 GCN 层数从 1 到 4 的变化时, 层数为 1 时效果最好。由于层数设置过大, 一方面容易造成过拟合, 另一方面会导致卷积过程中传递的噪声过大。

Table 7. Impact of GCN layers on the model**表 7.** GCN 层数对模型的影响

层数	1	2	3	4
精确率	0.773	0.758	0.699	0.656
召回率	0.721	0.700	0.674	0.625
F1 值	0.746	0.728	0.686	

5. 结束语

本文提出了 KGDGCN 算法, 该算法融合文本和外部知识图谱信息, 利用双 GCN 捕捉语义和句法信息。通过对豆瓣电影数据集的实验, 可以有效证明 KGDGCN 算法提高了结果的精确度。此外, 文中进行了消融实验, 如去掉动态对齐分数预测部分, 只采用句法 GCN 或者语义 GCN 提取特征, 从实验结果可以看出对比各个模块缺一不可。

本文的未来工作主要为两个方面。

(1) 语义信息的挖掘深度。中文博大精深, 虽然算法中采用了语义 GCN 捕获信息, 但是对于复杂的句子还需进一步加强, 包括反讽、隐喻等文本。

(2) 电影评论数据问题。本文采用的是豆瓣电影评论的数据。评论的情感分析是由本人进行人工标注, 所以主观较强。由于受真实数据影响, 中评情感数据较少, 后期会考虑多收集中性情感的数据。

参考文献

- [1] 李阳, 王石, 朱俊武, 等. 方面级情感分析综述[J]. 计算机科学, 2023, 50(S1): 34-40.
- [2] Krizhevsky, A., Sutskever, I. and Hinton, G.E. (2012) Imagenet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems*, **25**, 1097-1105.
- [3] 夏敏捷, 师钰博, 樊银亨. 双特征增强的图卷积网络用于方面级情感分析[J]. 计算机工程与设计, 2025, 46(8): 2426-2433.
- [4] 张凤, 邵玉斌, 杜庆治, 等. 基于双通道图卷积网络的多模态方面级情感分析[J]. 计算机工程与科学, 2025, 47(7): 1321-1330.
- [5] 张焕香, 彭俊杰. 基于方面级情感分析的深度语义挖掘模型[J]. 电子学报, 2024, 52(7): 2307-2319.
- [6] Li, J., Liu, Y. and Zou, L. (2020) Dyngcn: A Dynamic Graph Convolutional Network Based on Spatial-Temporal Modeling. In: Huang, Z., Beek, W., Wang, H., Zhou, R. and Zhang, Y., Eds., *Lecture Notes in Computer Science*, Springer International Publishing, 83-95. https://doi.org/10.1007/978-3-030-62005-9_7
- [7] Li, R., Chen, H., Feng, F., Ma, Z., Wang, X. and Hovy, E. (2021) Dual Graph Convolutional Networks for Aspect-Based Sentiment Analysis. *Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing*, **1**, 6319-6329.
- [8] Marcheggiani, D. and Titov, I. (2017) Encoding Sentences with Graph Convolutional Networks for Semantic Role Labeling. *Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing*, Copenhagen, 7-11 September 2017, 1506-1515. <https://doi.org/10.18653/v1/d17-1159>
- [9] Peng, C., Zhang, X., Yu, G., Luo, G. and Sun, J. (2017) Large Kernel Matters—Improve Semantic Segmentation by Global Convolutional Network. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, 21-26 July 2017, 1743-1751. <https://doi.org/10.1109/cvpr.2017.189>
- [10] Wang, H., Zhao, M., Xie, X., Li, W. and Guo, M. (2019) Knowledge Graph Convolutional Networks for Recommender Systems. *The World Wide Web Conference*, San Francisco, 13-17 May 2019, 3307-3313. <https://doi.org/10.1145/3308558.3313417>
- [11] Lin, J., Yin, S., Jia, B. and Wang, N. (2022) A Recommendation Algorithm for Auto Parts Based on Knowledge Graph and Convolutional Neural Network. In: Li, T., et al., Eds., *Communications in Computer and Information Science*, Springer, 57-71. https://doi.org/10.1007/978-981-19-8331-3_4
- [12] Cortes, C. and Vapnik, V. (1995) Support-Vector Networks. *Machine Learning*, **20**, 273-297. <https://doi.org/10.1023/a:1022627411411>
- [13] Friedman, N., Geiger, D. and Goldszmidt, M. (1997) Bayesian Network Classifiers. *Machine Learning*, **29**, 131-163. <https://doi.org/10.1023/a:1007465528199>
- [14] Shi, X., Chen, Z., Wang, H., Yeung, D.Y., Wong, W.K. and Woo, W.C. (2015) Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting. *Neural Information Processing Systems*, 802-810.
- [15] Lipton, Z.C., Berkowitz, J. and Elkan, C. (2015) A Critical Review of Recurrent Neural Networks for Sequence Learning. *Computer Science*, **215**, 15-25.
- [16] 徐增林, 盛泳潘, 贺丽荣, 王雅芳. 知识图谱技术综述[J]. 电子科技大学学报, 2016, 45(4): 589-606.
- [17] Bai, H., Wang, D., Feng, S. and Zhang, Y. (2025) EKBSA: A Chinese Sentiment Analysis Model by Enhancing K-BERT. *Journal of Computer Science and Technology*, **40**, 60-72. <https://doi.org/10.1007/s11390-024-2870-9>
- [18] Li, D.Y., Liang, Y.Y., Qian, S.Y., Wu, H.G., Jia, W., Fu, Y.L. and Sun, Y.F. (2025) A Review of Background, Methods, Limitations and Opportunities of Knowledge Graph Completion. *Computer Science Review*, **58**, 100809. <https://doi.org/10.1016/j.cosrev.2025.100809>
- [19] Slam, S.M. and Bhattacharya, S. (2021) Scalable End-to-End Training of Knowledge Graph-Enhanced Aspect Embedding for Aspect Level Sentiment Analysis. arXiv: 2108.11656
- [20] 邓立明, 魏晶晶, 吴运兵, 余小燕, 廖祥文. 基于知识图谱与循环注意力网络的视角级情感分析[J]. 模式识别与人工智能, 2020, 33(6): 479-487.
- [21] 刘斐瑜, 俞卫琴. 融合 BERT 和知识图谱的文本情感分析模型[J]. 建模与仿真, 2023, 12(4): 4195-4200.
- [22] Che, W., Feng, Y., Qin, L. and Liu, T. (2021) N-LTP: An Open-Source Neural Language Technology Platform for Chinese. *Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing: System Demonstrations*, 7-11 November 2021, 42-49. <https://doi.org/10.18653/v1/2021.emnlp-demo.6>
- [23] Wang, Y., Huang, M., Zhu, X. and Zhao, L. (2016) Attention-Based LSTM for Aspect-Level Sentiment Classification. *Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing*, Austin, 1-5 November

- 2016, 606-615. <https://doi.org/10.18653/v1/d16-1058>
- [24] Ma, D., Li, S., Zhang, X. and Wang, H. (2017) Interactive Attention Networks for Aspect-Level Sentiment Classification. *Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence*, Melbourne, 19-25 September 2017, 4068-4074. <https://doi.org/10.24963/ijcai.2017/568>