

# 目录

摘要.....	2
Abstract.....	3
1 引言.....	4
2 相关工作.....	6
3 相关技术理论.....	8
3.1 图神经网络.....	8
3.1.1 图卷积神经网络.....	8
3.1.2 超图卷积神经网络.....	8
3.1.3 有向图卷积神经网络.....	8
3.2 长短期记忆神经网络.....	8
3.3 卷积神经网络.....	8
4 基于双图模型的兴趣追踪方法.....	8
4.1 本章方法.....	8
4.2 双图模型的基本结构.....	11
4.3 主题关联超图的特征嵌入.....	12
4.4 有向转移图的特征嵌入.....	12
4.5 LSTM 交互序列处理.....	14
5 基于神经网络模型的分类.....	14
6 实验.....	16
7 结束语.....	16

# 摘要

在数字化时代，社交网络成为揭示用户兴趣动态的宝贵窗口。本文旨在通过结合创新的双图模型和神经网络分类技术，探索用户在社交网络上的兴趣状态变化。双图模型的核心理念是利用两种不同类型的图 ( Graphs ) 来建模和分析复杂的数据结构。在这种模型中，每个图代表数据中的不同关系或交互，从而能够更全面地捕捉和表达数据中的多维度关系。双图模型通过主题关联超图和有向转移图来捕捉用户传播交互中的复杂关系。在此基础上，我们扩展了模型，融合了长短期记忆神经网络 ( LSTM )，使其能够处理微博用户每个时间步的行为数据。每个时间步的隐藏状态输出被串联起来，构成一个综合表征用户兴趣的时间序列。然后，将双图模型中学习到的特征进行拼接得到表示各个时间步的特征矩阵输入卷积神经网络 ( CNN ) 进行分类，我们能够有效地识别出不同时间步骤下用户的兴趣状态，即对应的主题概率。实验表明，该方法在识别社交网络用户兴趣方面，相比传统单一模型具有更高的准确性和可靠性。

将以上模型结合有以上优点：(i) 时间步特征整合：通过将每个时间步的状态表示为矩阵的一行，您有效地保留了时间序列信息。这有助于 CNN 捕捉时间维度上的模式。(ii) 利用 CNN 的空间特征提取能力：CNN 在提取复杂模式方面表现出色，特别是当数据以类似于图像的格式呈现时。(iii) 动态知识追踪：此方法允许动态地追踪学生的知识状态，为每个时间步提供一个掌握概率估计。

关键词：社交网络，用户兴趣识别，双图模型，多粒度文本特征，神经网络分类

# Abstract

In the digital era, social networks have become valuable windows for revealing users' dynamic interests. This article aims to explore changes in users' interests on social networks by combining innovative dual-graph models and neural network classification techniques. The dual-graph model captures complex relationships in user propagation interactions through a combination of topic-associated hypergraphs and directed transfer graphs. Building upon this, we extend the model by incorporating Long Short-Term Memory (LSTM) networks to handle behavioral data of Weibo users at each time step. The hidden state outputs at each time step are concatenated to form a comprehensive representation of the user's interest over time. Subsequently, the features learned from the dual-graph model are concatenated to create feature matrices representing different time steps, which are then fed into Convolutional Neural Networks (CNNs) for classification. This approach effectively identifies users' interest states at different time steps, corresponding to topic probabilities. Experimental results demonstrate that this method outperforms traditional single models in recognizing social network users' interests, with higher accuracy and reliability.

Combining the above models offers the following advantages:

Integration of time-step features: By representing the state at each time step as a row in a matrix, you effectively retain temporal sequence information, aiding CNNs in capturing temporal patterns.

Utilization of CNN's spatial feature extraction capability: CNNs excel in extracting complex patterns, especially when data is presented in a format similar to images.

Dynamic knowledge tracking: This method allows dynamic tracking of a student's knowledge state, providing a mastery probability estimate for each time step.

Keywords: Social networks, user interest recognition, dual-graph model, multi-granularity text features, neural network classification

# 1 引言

随着互联网技术的迅猛发展，社交网络已成为现代人日常生活的一个不可或缺的部分。用户在这些平台上的互动和内容分享行为，逐渐成为研究人员分析和理解社会动态、个人行为习惯及兴趣偏好的重要渠道。特别是在信息过载的时代背景下，准确识别和跟踪用户兴趣状态变化，对于提升信息推荐系统的质量、优化内容分发策略以及增强用户体验具有重大意义。

传统的用户兴趣分析方法大多依赖于静态的用户属性或简单的行为分析，难以捕捉到用户兴趣的动态变化和复杂性。随着深度学习技术的发展，尤其是神经网络在特征提取和模式识别方面的优势，为更准确地理解和预测用户在社交网络上的兴趣提供了新的可能性。本文借鉴了两种先进的深度学习模型——双图模型和神经网络模型，以探索一种新的用户兴趣状态识别方法。

首先，双图模型的理念在于通过两种不同的图结构来综合分析数据，从而提供更深入、

全面的洞察。这种方法特别适合于处理那些具有复杂内在关系和多层次交互的数据集。下面是双图模型概念的关键要素：

(1) 多维关系的建模：双图模型通过两个独立的图结构来捕捉数据中的不同维度的关系。

这种方法允许模型更加精细地理解和表示数据之间的复杂相互作用。

(2) 图结构的应用：图 ( Graphs ) 是一种能够表达实体 ( 如节点 ) 和它们之间关系 ( 如边 ) 的数学结构。在双图模型中，两个不同的图结构被用来代表不同类型的关系或交互。

(3) 数据的高阶表示：每个图可以捕捉数据中的特定方面或层面，从而提供更丰富、高阶的数据表示。这种多层次的分析方法有助于更深入地理解数据的内在结构。

(4) 综合分析：通过将两个图的分析结果综合起来，双图模型能够提供比单一图模型更全面、更精确的数据洞察。这种综合视角有助于揭示数据中可能被忽视的复杂模式和关系。

然后将此理念应用于社交网络环境，我们探索如何利用这种模型来捕捉和理解社交媒体用户行为的复杂性。

神经网络分类模型是数据分析和模式识别领域的重要工具。特别是对于结构化数据，CNN 能够表现出十分良好的效果。我们将双图模型中获得的数据作为输入，能够充分发挥出 CNN 在处理结构化数据时的优势。神经网络分类模型通常包括多层的结构，每一层都负责从输入数据中提取不同级别的特征。这种分层的特征提取机制使得模型能够捕捉到数据中的细微差别，甚至是那些肉眼难以察觉的模式。此外，通过训练，这些模型能够自动调整其内部参数，以适应特定的数据特性和分类任务。这种自适应性是神经网络分类模型的一大优势，使其能够在各种不同的应用环境中表现出色。

本文的核心贡献在于提出一种新的方法，将每一时间步的交互行为作为双图模型的输入，通过双图模型可以得到各个点的特征嵌入，然后结合长短期记忆神经网络得到每个时间的隐

藏状态,并利用卷积神经网络进行有效的分类,以准确识别用户在不同时间步下的兴趣状态。

我们的方法不仅在理论上具有创新性,而且在实验上也显示出优于传统方法的性能。

通过本文的研究,我们期望为社交网络中用户兴趣识别的研究领域提供新的思路和方法,同时为相关应用如个性化推荐、内容定制化等领域提供实际指导。

## 2 相关工作

在社交网络用户兴趣识别领域,研究主要集中于三个方向:基于用户行为、用户社交关系和用户文本内容的兴趣识别。

(i) 基于用户行为的兴趣识别:该方法通过分析用户的交互行为,如阅读、评论、转发、点赞等,来识别用户兴趣。然而,由于社交网络用户行为的稀疏性和离散性,捕捉完整的行为轨迹成为一大挑战,加之用户隐私的保护,使得这类方法的应用受到限制。

(ii) 基于用户社交关系的兴趣识别:此方法利用用户间的社交关系来识别兴趣。例如,Wang[1]等利用微博用户间的交互关系构建有向加权图,通过用户自定义标签传播兴趣;石伟杰[2]等结合用户及其关注用户的微博数据,根据社交相关度挖掘兴趣。尽管这类方法能够提供一定的用户兴趣洞察,但其所提取的信息通常只能间接描述用户兴趣,不够直观和可靠。

(iii) 基于用户文本内容的兴趣识别:这种方法认为用户发表的微博内容可以代表其兴趣。例如,Liu[4]等采用机器翻译和词频方法提取微博内容关键字,表征用户兴趣。另外,隐含狄利克雷分布(LDA)作为一种能够有效提取文档中隐含主题信息的模型,被广泛用于微博用户兴趣挖掘。例如,Liu[7]等利用LDA从用户生成和接收的微博内容中提取兴趣特征。然而,LDA在处理文本时并未考虑词与词之间的语序关系,导致主题语义不连贯。针对

此问题，曾金[14]等研究者采用了结合图像、文本和标签特征的方法，通过机器学习的分类算法预测用户兴趣。

近年来，对于社交网络数据的多样性和稀疏性，研究者开始探索结合多种数据源和技术的综合方法。例如，宋巍[11]等通过结合主题层次和词语层次构造特征空间，杜雨萌[12]等构建了结合连续语义特征和离散主题特征的卷积神经网络模型，用于对用户微博内容的分类。这些方法展示了在复杂的社交网络环境中，通过多角度、多层面的文本分析与深度学习技术相结合，可以更加准确地描述和预测用户的兴趣特征。

## 3 相关技术理论

### 3.1 图神经网络

#### 3.1.1 图卷积神经网络

#### 3.1.2 超图卷积神经网络

#### 3.1.3 有向图卷积神经网络

### 3.2 长短期记忆神经网络

### 3.3 卷积神经网络

## 4 基于双图模型的兴趣追踪方法

### 4.1 本章方法

在探索社交网络用户兴趣状态的变化过程中，双图模型显现出其独特的优势。该模型通过构建两种图结构，一方面捕捉标签与主题间的关联关系；另一方面考虑到了用户在社交网络上的传播交互路径也是考量用户兴趣状态变化的重要性因素。这种双重视角使得双图模型在分析兴趣追踪问题时更为全面和精确。通过将静态和动态数据结合，双图模型不仅能够深入理解用户的行为模式，还能准确捕捉和预测用户兴趣状态的变化趋势。其在处理具有丰富关系和动态特性的社交网络数据中的应用，为我们提供了一个更为丰富和细致的视角，以理解和分析用户在社交网络中的行为和兴趣。

选择超图来描述标签和主题之间的关联是出于对复杂关系结构深度挖掘的需求。超图允



许我们将一个标签与多个主题或者多个标签与单一主题关联起来,这种多对多的关系表达能力是普通图模型所无法提供的。在社交网络的背景下,用户的标签和主题之间的关系通常是多对多的,使用超图能够更准确地捕捉和反映这种复杂的网络结构。

另一方面,当描述用户在社交网络中的传播交互行为时,采用有向转移图则是因为它能够更好地揭示用户交互的方向性和序列性。在社交网络中,用户间的信息传播并非随机发生,而是有明确的方向和顺序。有向转移图通过其有向边清晰地表示了这种传播的方向,同时也体现出用户交互行为的时间序列特征。

所以在社交网络用户兴趣状态识别的研究中,利用超图来揭示标签和主题间复杂的多对多关系,以及使用有向转移图来清晰表达用户传播交互行为的方向性和序列性,不仅提高了分析的精度,也增强了理解用户行为和兴趣演变的深度。

在本文中,继对数据应用双图模型之后,我们进一步采用长短时记忆网络(LSTM)来加强对时间序列数据的分析。首先,双图模型的结果向量被拼接起来,形成一个综合的特征表示,随后这些向量被输入到LSTM中。LSTM通过其特殊的网络结构,能够有效地处理和记忆时间序列数据中的信息,为每一时间步生成一个状态向量。这些向量反映了用户在不同时间点的兴趣状态,为进一步的分析提供了丰富的信息。

选择LSTM而非传统的循环神经网络(RNN)的原因在于LSTM在处理时间序列数据时具有显著优势,尤其是在应对长期依赖问题上。传统的RNN在处理长序列时常常面临梯度消失或梯度爆炸的问题,这限制了模型捕捉长期依赖信息的能力。相比之下,LSTM通过引入遗忘门、输入门和输出门的机制,能够有效地控制信息的存储和忘记,从而更好地捕捉时间序列数据中长距离的依赖关系。在社交网络用户兴趣状态分析的背景下,这意味着LSTM可以更准确地追踪和分析用户兴趣随时间的演变,为识别用户兴趣的动态变化提供了强有力的工具。

本章提出了一个基于双图神经网络的兴趣追踪方法(Bi-Graph Neural Networks for Interest Tracing, BGNIT)。整体流程如图 1 所示。从模型的输入角度, 用户的传播交互序列可以表示为  $I = \{(v_1, r_1), (v_2, r_2), \dots, (v_t, r_t)\}$ , 其中  $v_i$  表示用户在第  $i$  个时间步所使用的标签,  $t$  表示时间步的总步数, 用户对标签  $v_i$  是否喜欢用  $r_i$  来表示, 若喜欢, 则  $r_i = 1$ , 否则,  $r_i = 0$ 。

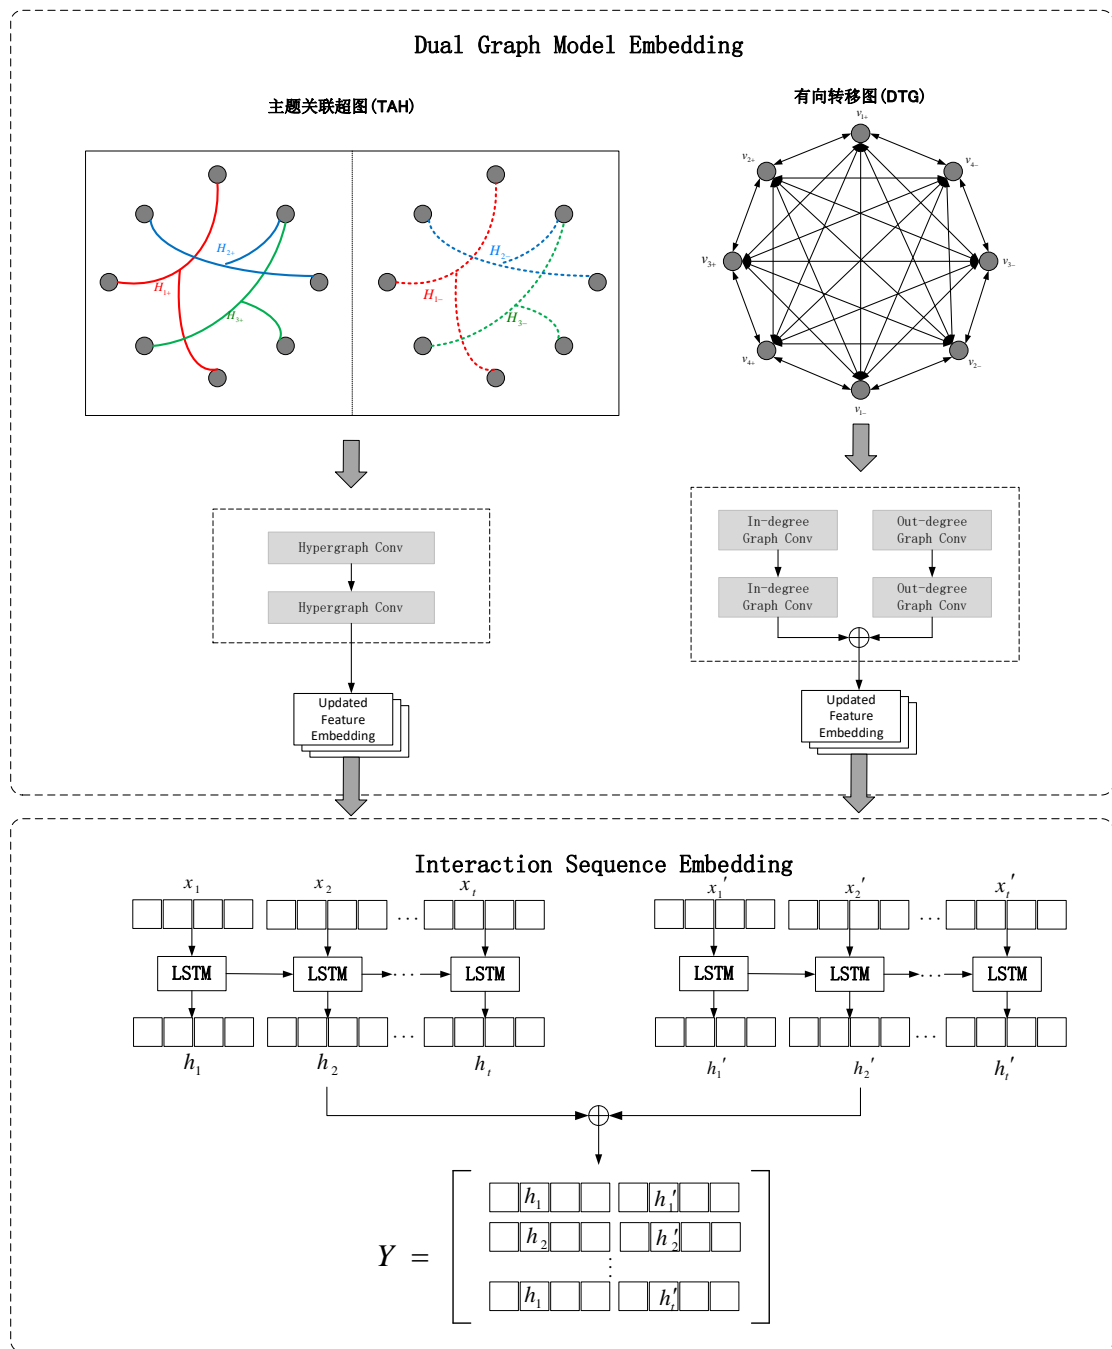


图 1 BGNIT 的整体架构

## 4.2 双图模型的基本结构

以下先给出双图模型的基本结构：

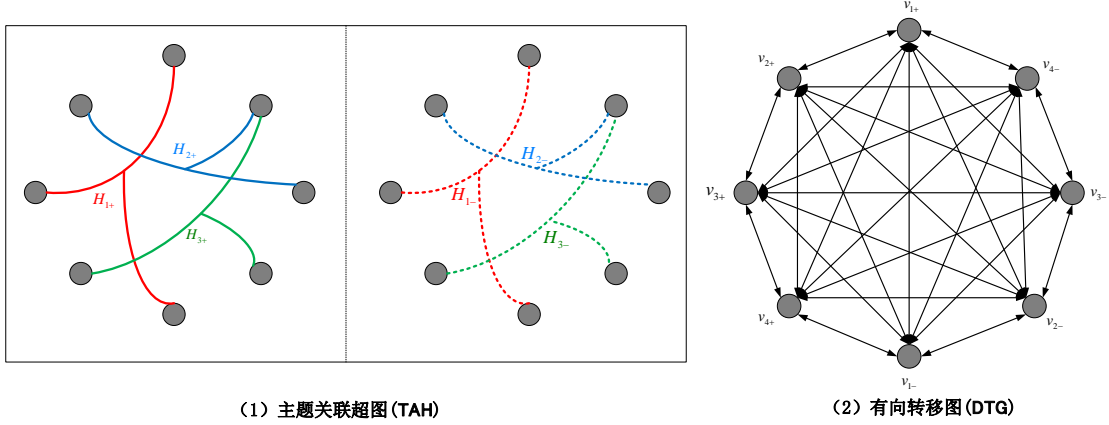


图 2 双图结构

主题关联超图(Topic Association Hypergraph , TAH) : 如图 2-(1)所示, 在这部分, 超图能够有效地捕获用户标签与相关主题之间的复杂关系。这种多对多的关系映射非常适合于描绘用户标签与多元化主题之间的关联, 例如一个用户的特定标签可能与多个主题相关联, 反映出用户兴趣的广泛性和多样性。在社交网络中, 这种复杂的关联关系能够更全面地反映出用户的兴趣模式和偏好。具体而言, 设  $G_T = (V, E)$ , 其中,  $E = \{H_{1+}, H_{1-}, H_{2+}, H_{2-}, \dots, H_{m+}, H_{m-}\}$  表示超边的集合, 每个主题  $C_j$  被分解成两个超边  $H_{j+}$  和  $H_{j-}$ , 分别表示用户对标签持喜欢和不喜欢的态度, 故超边  $E$  的个数是概念数的两倍。

有向转移图(Directed Transition Graph , DTG) : 如图 2-(2)所示, 这一部分专注于捕捉用户在不同时间步骤的传播行为, 如信息的分享、转发等。有向转移图通过其有向边展现了传播行为的方向性, 揭示了用户交互的时间序列特性。这在理解用户兴趣如何随时间和社交互动而演变方面至关重要。具体而言,  $G_D = (V, E_D)$ , 假设共有  $n$  个标签。

$V = \{v_{1+}, v_{1-}, v_{2+}, v_{2-}, \dots, v_{n+}, v_{n-}\}$  表示图中的节点, 每一个标签节点  $v_i$  被分成  $v_{i+}$  和  $v_{i-}$ , 分别

表示用户对标签持喜欢和不喜欢的态度，故节点数也是标签数量的两倍。

在双图模型中，考虑到用户对于自己在社交网络上发表内容中的标签并不一定表示喜欢，有时对于标签持批判态度，因此建立用户不喜欢某种标签的交互也是重要的一环。在社交网络环境下，了解用户不喜欢或不关注的标签，可以为我们提供关于用户兴趣负面方面的重要信息。正如在教育环境中学生的错误回答能够帮助教师了解学生的知识盲点一样，在社交网络分析中，识别用户对某些标签的不喜欢或避免可以帮助我们更准确地构建其兴趣模型，从而在推荐系统、内容过滤等应用中实现更加精准的个性化服务。这种正面和负面信息的结合，使得兴趣模型更为全面和真实，提升了兴趣预测的准确性和有效性。

### 4.3 主题关联超图的特征嵌入

在超图中，包含节点  $v_i$  的超边子集可以定义为  $U_i = \{H_j \mid v_i \in H_j\}$ ，基于此，我们定义  $v_i$  的度数为  $d_i = |U_i|$ 。此外，超边  $H_j$  的度数为其中的节点数，表示为  $g_j = |H_j|$ 。用户的传播交互序列对应着一条唯一的路径，通过该路径可以建模出一个确定的主题关联超图。通过TAH 应用超图卷积网络来学习节点的嵌入，聚合来自  $v_i$  本身以及  $v_i$  所属的每个超边中的局部邻居信息来更新  $x_i$ ，即节点的嵌入：

$$x_i^{(l)} = \theta \left( \sum_{H_j \in U_i} \frac{1}{g_j} \sum_{v_q \in H_j} \frac{1}{\sqrt{d_i d_q}} w^{(l)} x_q^{(l-1)} \right) \quad (4-1)$$

其中  $x_i^{(l-1)}$  是第  $l-1$  层的输出嵌入也是第  $l$  层的输入嵌入， $x_i^{(l)}$  是第  $l$  层的输出嵌入， $w^{(l)}$  是可学习的参数矩阵， $\theta$  表示非线性激活函数，如 *Leaky ReLU*，每次更新平滑了由相同超边局部链接的节点的嵌入。

### 4.4 有向转移图的特征嵌入

以上是对主题和标签之间的关联进行探讨，本节我们对用户的传播交互路径进行探讨，

因为探究用户的传播交互路径也是探究用户兴趣追踪的重要因素。同样的，根据用户的传播交互序列可以唯一的建模有向转移图。我们假设用户的传播交互序列为  $\{v_1, v_2\}$ ，即传播完带有  $v_1$  标签的内容后有传播了带有  $v_2$  标签的内容，在有向转移图的邻接矩阵中可以体现为  $A(v_1, v_2) = 1$ ，这里有向转移图 DTG 我们用  $G_d = \{V, E_d\}$  表示，对于每个被发布过的标签而言，我们需要考虑它的出度和入度两种情况，因为对于每一个标签既是上一个标签的未来传播序列，也是它写一个标签的最近传播序列。因此，邻接矩阵需要以下两种情况来表示(感觉这里的公式有问题)：

$$A_{i,j}^{(in)} = \begin{cases} \frac{n_{j,i}}{\sum_k n_{k,i}} & (v_j, v_i) \in e \\ 0 & others \end{cases} \quad (4-2)$$

$$A_{i,j}^{(out)} = \begin{cases} \frac{n_{i,j}}{\sum_k n_{i,k}} & (v_i, v_j) \in e \\ 0 & others \end{cases} \quad (4-3)$$

其中， $n_{j,i}$  表示整个传播交互序列中  $v_i$  紧接着在  $v_j$  之后出现的次数。通过这种方式，不同用户的历史传播记录可以得到隐示的利用。并且，图中每个节点都包含自循环，即  $A_{i,i}^{(in)} = 1$  和  $A_{i,i}^{(out)} = 1$ 。 $v_i$  的入度和出度分别为：

$$d_i^{(in)} = \sum_k A_{i,k}^{(in)} \quad (4-4)$$

$$d_i^{(out)} = \sum_k A_{i,k}^{(out)} \quad (4-5)$$

在 DTG 中，通过并行的双向信息传播来更新  $v_i$  的特征嵌入  $x_i$ ，一是沿着边的方向扩散信息，通过从祖先节点接受信息来更新节点的特征嵌入，另一方面是将信息扩散到途中边缘的方向，以便后代节点可以接收信息来更新节点的特征嵌入：

$$\bar{x}_i^{(l)} = \theta \left( \sum_{v_j \in N_i^{(in)} \cup \{v_i\}} \frac{A_{i,j}^{(in)}}{\sqrt{d_i^{(in)} d_j^{(out)}}} \phi^{(l)} x_j^{(l-1)} \right) \quad (4-6)$$

$$x_i^{(l)} = \theta \left( \sum_{v_j \in N_i^{(out)} \cup \{v_i\}} \frac{A_{i,j}^{(out)}}{\sqrt{d_i^{(out)} d_j^{(in)}}} \psi^{(l)} x_j^{(l-1)} \right) \quad (4-7)$$

其中， $\phi^{(l)}$  和  $\psi^{(l)}$  是第  $l$  层的可学习参数， $N_i^{(in)}$  和  $N_i^{(out)}$  分别是  $v_i$  的祖先节点和后续节点的集合。然后直接将  $x_i^{-{(l)}}$  和  $x_i^{(l)}$  相加得到  $x_i^l$  的特征嵌入表示。

## 4.5 LSTM 交互序列处理(用 self-attention ?)

经过主题关联超图和有向转移图的特征嵌入后，我们获得了每个时刻更新且更加丰富的特征嵌入  $\{x_1, x_2, \dots, x_t\}$  和  $\{x'_1, x'_2, \dots, x'_t\}$ 。将这些特征嵌入输入到长短时记忆网络。LSTM 能够有效地捕捉和利用时间序列数据中的长期依赖关系。由于 LSTM 特有的门控机制，它能够选择性地记忆重要信息并忘记不相关的信息，从而在保留关键特征的同时，避免了长序列数据中常见的梯度消失问题。这种处理机制使得 LSTM 特别适合于处理和解析具有复杂时间动态的数据。

在将经过双图模型处理的特征嵌入输入到 LSTM 之后，我们得到了两个向量序列  $\{h_1, h_2, \dots, h_t\}$  和  $\{h'_1, h'_2, \dots, h'_t\}$ 。这两个序列分别代表了经过时间序列处理后的特征表示，捕捉了用户兴趣状态的动态变化和演进。将这两个向量进行拼接，得到的矩阵  $Y$  每行由  $h_i$  和  $h'_i$  组成，列数为  $t$ 。

## 5 基于神经网络模型分类

卷积神经网络 (CNN) 是一种深度学习模型，特别适用于处理结构化数据。CNN 的核心是卷积层，它通过滤波器 (或称为核) 在输入数据上进行滑动窗口操作，有效地捕获局部特征，每个滤波器专注于提取特定类型的特征。CNN 的这些特点使其在图像处理和其他领域表现卓越。在此研究中，CNN 能有效处理和分析时间序列数据，捕捉到用户兴趣状态的

时间动态。其次, CNN 的局部感知能力使其能够识别出时间序列数据中的关键模式和特征, 这对于理解用户在不同时间步骤的兴趣变化至关重要。最后, CNN 的强大分类能力有助于准确地识别用户的兴趣状态, 从而提高兴趣识别的准确性和效率。图 3 为卷积神经网络分类模型结构图。

(1) 输入层。这一层负责接收文本特征表示矩阵。这个矩阵即前一节的矩阵  $Y$ , 其中每行待变一个时间步, 列则是经过双图模型和 LSTM 处理的每一步的特征嵌入。

(2) 卷积层。根据不同尺寸的卷积核建立相应尺寸的卷积层, 对输入矩阵做卷积操作。

$$a_i = f(\omega \cdot x_i + b) \quad (5-1)$$

其中,  $a_i$  表示卷积操作得到的第  $i$  个特征;  $x_i$  是特征  $x$  的第  $i$  个输入;  $\omega$  表示该卷积核的权重矩阵;  $b$  是偏置项;  $f$  是非线性激活函数。将式(5-2)生成的所有特征连接起来得到卷积层的特征输出  $A = [a_1, a_2, \dots, a_i]$

(3) 池化层。该层利用最大池化方法对卷积层输出的特征图进行抽样。这一过程旨在进一步抽象特征, 以捕捉最关键的信息, 并减少特征维度。将所有的最大池化结果连接起来得到  $A' = [a'_1, a'_2, \dots, a'_M]$

(4) 全连接层。模型通过  $2 \times M$  维的权值矩阵将池化层输出的二维特征图转换为一维特征向量, 准备用于最后的分类任务。

(5) 输出层。使用 softmax 分类器计算每个时间步下回答对错的概率, 其中最高概率值对应的类别即为模型预测的结果。

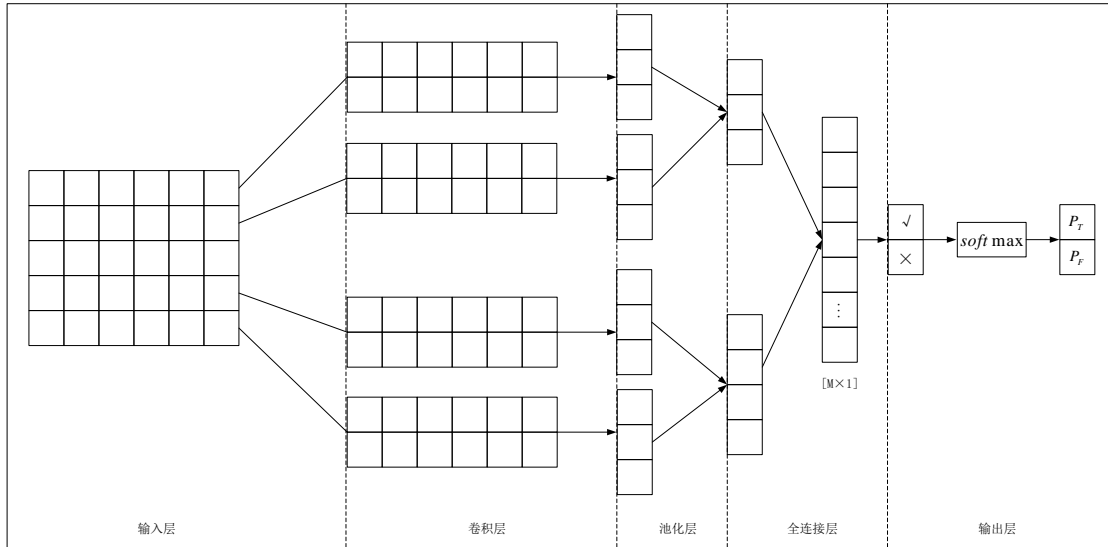


图 3 卷积神经网络分类模型

## 6 实验

## 7 结束语

在本文中，我们深入探讨了如何利用双图模型和卷积神经网络（CNN）来分析和预测社交网络用户的兴趣状态。本研究构建了一个独特的分析框架，能够从用户在社交网络上的不同时间步的传播事件中，提取并理解用户的兴趣动态。

本文的核心贡献在于将双图模型中的每一个时间步的隐藏状态输出拼接成矩阵，并将其作为输入数据输入到 CNN 中。这一创新步骤不仅利用了 CNN 在特征提取和分类方面的强大能力，同时也保留了双图模型在捕捉时间序列数据上的精细细节。这种方法为理解用户兴趣的演化提供了新的视角，展示了深度学习技术在解析复杂社交网络行为中的潜力。

未来的研究可以在此基础上进一步探索，例如，通过引入更先进的深度学习技术或结合更丰富的用户行为数据，来提高模型的准确性和适应性。此外，此方法的应用潜力也非常广



泛，它不仅可以应用于社交媒体数据，也可以扩展到其他领域，如电子商务、在线教育等，为用户行为分析和个性化推荐系统提供支持。通过这些努力，我们可以更好地理解并预测用户兴趣的变化，为用户提供更加精准和个性化的服务。