

引入激活扩散的类分布关系近邻分类器

董 飒^{1,2}, 欧阳若川³, 徐海啸¹, 刘 杰^{1,2}, 刘大有^{1,2}, 李婷婷^{1,2}, 王鑫禄^{1,4}

(1. 吉林大学 计算机科学与技术学院, 长春 130012;

2. 吉林大学 符号计算与知识工程教育部重点实验室, 长春 130012;

3. 吉林大学 党委教师工作部, 长春 130012; 4. 吉林大学 国际教育学院, 长春 130012)

摘要: 针对同质性关系分类器基于一阶 Markov 假设简化处理的局限性, 在类分布关系近邻分类器构建类向量和参考向量时, 引入局部图排序激活扩散方法, 并结合松弛标注的协作推理方法, 通过适当扩大分类时邻居节点的范围增加网络数据中待分类节点的同质性, 从而降低分类错误率。对比实验结果表明, 该方法扩大了待分类节点的邻域, 在网络数据上分类精度较好。

关键词: 人工智能; 网络数据分类; 激活扩散; 类分布关系近邻分类器; 协作推理

中图分类号: TP301 **文献标志码:** A **文章编号:** 1671-5489(2024)04-0915-08

Introducing Class-Distribution Relational Neighbor Classifier with Activation Spreading

DONG Sa^{1,2}, OUYANG Ruochuan³, XU Haixiao¹, LIU Jie^{1,2},

LIU Dayou^{1,2}, LI Tingting^{1,2}, WANG Xinlu^{1,4}

(1. College of Computer Science and Technology, Jilin University, Changchun 130012, China;

2. Key Laboratory of Symbolic Computation and Knowledge Engineering of Ministry of Education, Jilin University, Changchun 130012, China;

3. Faculty Work Department of Party Committee, Jilin University, Changchun 130012, China;

4. College of International Education, Jilin University, Changchun 130012, China)

Abstract: Aiming at the limitation of the simplifying the processing of homophily relational classifiers based on first-order Markov assumption, when constructing the class vector and reference vector in the class-distribution relational neighbor classifier, we introduced the activation spreading algorithm of local graph ranking, combined with the relaxation labeling collective inference method. By appropriately expanding the range of neighboring nodes during classification, we increased the homophily of nodes to be classified in network data, thereby reducing the error rate of classification. The comparative experimental results show that this method expands the neighborhood of nodes to be classified, and has good classification accuracy on network data.

Keywords: artificial intelligence; network data classification; activation spreading; class-distribution relational neighbor classifier; collective inference

收稿日期: 2023-09-25.

第一作者简介: 董 飒(1985—), 女, 满族, 博士, 高级工程师, 从事数据挖掘、高性能计算的研究, E-mail: dongsa@jlu.edu.cn.

通信作者简介: 李婷婷(1986—), 女, 汉族, 硕士, 副研究员, 从事人工智能的研究, E-mail: ttle@jlu.edu.cn.

基金项目: 国家自然科学基金(批准号: 61502198).

利用网络数据中分类实例之间的关系,关系分类器扩展了基于属性的分类器,并将数据集视为数学图。关系分类器适用于如下情况:实例具有可变数量的属性;属性值分布稀疏且与类别不充分相关;实例的属性较少而关系较多。

大多数关系分类器的最终解析机制基于同质性假设——相邻实例比非相邻实例更可能拥有相同的类别^[1]。这种现象在社会网络的观察和理论中普遍存在,例如人们总是根据他们的种族或民族群聚^[2]。分类任务中的同质性在若干工作中被引用,使用同义词“自相关”或“局部一致性”。大量实验表明,关系分类器的分类质量依赖于待分类网络数据的同质程度。因此,如果增加网络数据的同质度,关系分类器将会降低分类的错误率。但大部分基于同质性假设的关系方法又都是基于一阶 Markov 假设进行简化处理的。这种分类时只考虑实例直接邻域的方法必然存在信息获取的局限性。

传统机器学习方法视分类实例为独立的,而网络数据中,一个实例的类别可能对相关实例的类别产生影响。因此对实例的类别进行同时推理是有益的。协作推理起源于模式识别和统计物理学,结合协作推理的单变量关系分类器^[3]是网络分类方法的分支,其中分类实例仅通过它们之间的关系进行分类。

为扩大分类时节点邻域的范围,本文将局部图排序激活扩散方法引入到类分布关系近邻分类方法(CDRN)中,以替代原方法中基于一阶 Markov 假设的直接邻域获取方法,并结合引入模拟退火的松弛标注协作推理方法,改进方法增加了待分类节点的同质性。将改进方法与原类分布关系近邻分类方法和加权投票关系近邻分类方法(WVRN)在 5 个网络数据集上进行实验评估的结果表明,引入激活扩散的改进方法在一定程度上提高了分类精度。

1 相关工作

Vojtek 等^[4]分析了简单关系分类器与同质性的依赖性。简单关系分类器更复杂的替代是迭代强化分类算法^[5]和关系集成分类器^[6],它们都能处理更多类型的分类实例及图中的多种关系。由于页面排序和网页搜索点击全局排序算法^[7]的广泛应用,如扩散激活的图排序算法被很好地分析。扩散激活类似于带重启的随机行走局部排序方法^[8]。

Gallagher 等^[8]采用带重启的随机行走方法提高弱连接节点图的分类器性能,但没有对同质现象进行更深层次的分析。Jensen 等^[9]的研究中包含了一种关于相邻对象距离的邻域方法,但未提供其对分类器性能的影响。Macskassy 等^[10]提出的加权投票关系近邻分类器 WVRN 和 Perlich 等^[11-12]提出的类分布关系近邻分类器 CDRN 都是利用与待分类节点直接连接的邻居节点组成的邻域进行分类。许多关系分类方法^[13-19]同样是基于同质性假设并利用一阶 Markov 假设,目前很少有人提出其他邻域获取方法。其中 WVRN 方法仅利用网络数据的同质性进行分类,结合协作推理方法分类精度较高,可视作网络分类的基准方法^[3]。Tobback 等^[20]为对直接网络和隐含网络进行预测,使用 Macskassy 和 Provost 的加权投票关系邻居分类器。Maystre 等^[21]在选择启发式阶段在一定程度上还原了使用 Macskassy 和 Provost 的加权投票关系邻居分类器中的协作推理过程。Zhang 等^[22]针对噪声和稀疏数据提出了基于稀疏因子的堆叠去噪自动编码器(SDAE)学习异构网络中节点的特征,并采用松弛策略构建基于高质量的类层次结构,最后对异构信息网络的节点进行分类。Li 等^[23]提出了一个监督关系主题模型,以在文献网络上进行自动分类,该模型利用 Bayes 生成模型挖掘文档网络中单词特征与链接特征之间的关系,并利用文档之间的链接学习文档的潜在内容。Zhang 等^[24]提出了一种基于加权元图的异构信息网络分类框架(MCHIN)解决异构信息网络的分类问题。Yu 等^[25]提出了一种基于网络的分类器决策网络(DN),将属性值与类标号之间的对应关系抽象为加权二部网络。甘玲等^[26]提出了一种基于正则约束的分层仿射图神经网络文本分类模型 Text-HARC,用来解决基于图结构的文本分类方法存在边噪声和节点噪声干扰、缺乏文本层次信息和位置信息等问题。贾晨晓等^[27]实现了关系分类模型 MSF-RC,通过多重语义的层级融合进一步提升关系分类模型的性能。王进等^[28]使用图嵌入和区域注意力技术挖掘标签之间以及标签与文本之间的关系,提出的编码器优于传统多标签文本分类模型。本文采用扩散激活方法是因为它简单的可理解性和运行的时效性。

2 激活扩散

2.1 激活扩散邻域获取

网络数据可用由节点和边组成的图描述. 例如网站中, 网页为节点, 主题是标签, 网页间的超链接是图中的边. 给定网络 G , v_i 是图中的任一节点, $v_i \in V$, V 为 G 的节点集, 其中 V 由已标记节点集即标签已知的节点集 V^K 和未标记节点集 V^U 组成, 即 $V = V^K + V^U$, x_i 表示节点 v_i 的某一(估计)标签, 对于 m 个类别(标签), 有 $x_i \in \{c_1, c_2, \dots, c_m\}$.

在原始的简单关系分类器及其他关系分类器中, 节点邻域获取基于一阶 Markov 假设, 故节点的邻域被设计为一组通过边或链接直接连接的节点. 而本文方法引入的激活扩散^[7]方法是一种更鲁棒的局部图排序方法, 该方法将邻域扩展为更广泛的带有表示节点接近程度的权值的节点集合. 伪代码如下:

```

Energy ActivateSpreading(Energy E, node  $v_i$ ) {
    Energy( $v_i$ ) = Energy( $v_i$ ) + E
     $E' = E / |N_i|$ 
    if ( $E' > T$ ) {
        for each node  $v_j \in N_i$  {
            if ( $x_j \neq \text{null}$ )
                ActivateSpreading( $E', v_j$ )
        }
    }
}

```

ActivateSpreading 是输出一组节点及其权重或称能量(Energy)的递归算法, 能量用于表示节点 v_i 和排序节点之间的密切程度. 最小能量阈值 T 提供了算法的快速收敛性, 邻居节点集 N_i 包含所有通过边直接连接分类节点 v_i 的节点, $|N_i|$ 是与 v_i 直接相邻节点的个数, 激活扩散将能量值赋予节点, 而不是边.

图 1 描述了两种邻域获取方法的示例. 在图 1(A)所示的无向无权边图中, 如果分类 v_1 则直接邻域 $N_1 = \{v_2, v_3, v_4\}$. 但如果采用激活扩散(图 1(B)), 则将得到邻域 $EN_1 = \{v_2, v_3, v_4, v_5, v_6\}$ 以及表示节点之间密切度的权值 E .




图 1 两种邻域获取方法

Fig. 1 Two methods of neighborhood acquisition

2.2 度量同质性

文献[8]对同质性度量方法进行了讨论, 但同质度是基于集合的(节点集中所选属性的同质性), 而本文关注单个节点的同质性.

文献[4]的实验表明, 简单的加权投票关系近邻分类器的分类质量取决于网络数据的同质度, 该方法假设相邻节点的类标签可能相同. 同质性假设非正式定义为相关实例比非相关实例更可能拥有相同的类别^[2]. 文献[4]的信息熵同质度定义为

$$h(v_i) = 1.0 + \sum_{c_k \in C} P(x_i = c_k | N_i) \log_{\text{base}} P(x_i = c_k | N_i), \quad (1)$$

其中 $P(x_i = c_k | N_i)$ 表示根据节点 v_i 的直接邻居节点集得到的 v_i 类别标签的估计概率. 这种度量的设计是为处理类别个数无限的情形, 针对单个节点的同质性, 并且同质性的范围在 $[0, 1]$ 内. 如果考虑类别 $C = \{c+, c-\}$ 的二元分类, $\text{base} = 2$, 并且所有边的权重设为 1.0 (例如无权重图), 则可得如下边界状态: 如果所有直接邻居节点全部被指定为 $c-$ 或 $c+$ (图 2(A)), 则此时最高同质性 $h(v_k) = 1.0$; 如果 50% 的直接邻居节点被指定为 $c-$, 其余属于 $c+$, 则此时有最低同质性 $h(v_k) = 0$ (图 2(B)).




图 2 图中同质性示例

Fig. 2 Examples of homophily in graph

2.3 激活扩散提升节点同质性示例

Vojtek 等^[4]实验证明了扩散激活优于基本的直接邻域获取方法, 并提供更平滑、更鲁棒的同质性衰退, 且在斯洛伐克公司的社交网络数据上计算得到的分类概率估计与式(1)的同质度计算函数更拟合. 如图 3 所示, 如果采用基本邻域法, 则节点 v_1 被节点集 $N_1 = \{v_2, v_3\}$ 包围. 此时 $x_2 = c-$ 且 $x_3 = c+$, 应用简单关系分类器^[10]有 $P(x_1 = c+ | N_1)$ 和 $P(x_1 = c- | N_1)$ 相同均为 0.5, 并且 $h(v_1) = 0$. 但如果考虑利用激活扩散(从能量




图 3 根据不同邻域获取方法具有不同同质性图的示例
Fig. 3 Examples of graph with varying homophily according to different neighborhood acquisition methods

$E = 1.0$ 和阈值 $T = 0.15$ 开始)计算邻域, 则将得到如图 3 所示的带能量值的邻域 $EN_1 = \{v_2, v_3, v_4, v_5\}$. 如果计算该邻域的同质性, 则可得 $P(x_1 = c- | EN_1) = 0.625$ 且 $h(v_1) = 0.045$, 同质度得到提升.

3 本文方法

网络数据中节点之间的链接或边提出了传统分类中没有出现的新问题. 链接包含高质量的语义信息, 但由于噪声的原因很难从中挖掘信息, 在网络中通过链接探索未标记节点的所有邻居节点几乎不可能. 为增强易处理性, 大部分的关系分类器都基于一阶 Markov 假设进行简化处理. 但未标记节点直接邻居的分类信息有限, 为获取更多有用信息并避免过多噪声或错误信号, 本文采用适当扩展邻域范围的方法.

原始的类分布关系近邻分类器^[3]在网络数据中使用基于一阶 Markov 假设的单变量关系分类, 即只有待分类节点的直接邻居节点的标签对分类是必要的. 理论上学习邻居节点类标签分布的模型更灵活, 可能会比简单关系分类器得到更好的辨别力. 故本文考虑将扩散激活引入到类分布关系近邻分类器中, 以扩大待分类节点邻域的范围. 与基于一阶 Markov 假设的方法类似, 不对图中全部未标记节点进行联合概率分布估计, 而是使用待分类节点 v_i 激活扩散的邻居集 EN_i 对节点 v_i 的标签 x_i 进行概率估计:

$$P(x_i | G) = P(x_i | EN_i). \quad (2)$$

本文方法分类节点 v_i 的步骤如下. 在训练过程中, 忽略未知节点, 定义已标记节点 v_i 的激活扩散类别向量 $ASCV(v_i)$ 为对节点 v_i 进行激活扩散后的邻居集 EN_i 中的已标记邻居节点集 EN_i^k 中节点对

应的各类别的能量值平均值:

$$\mathbf{ASCV}(v_i)_k = \frac{1}{Z} \sum_{v_j \in EN_i^K, x_j = c_k} E(v_j), \quad (3)$$

其中 $\mathbf{ASCV}(v_i)_k$ 表示激活扩散类别向量中的第 k 个位置, $c_k \in \{c_1, c_2, \dots, c_m\}$ 为第 k 个类别, $Z = |EN_i^K|$ 为标准化因子. 基于激活扩散类别向量, 激活扩散参考向量 $\mathbf{ASRV}(c_k)$ 定义为已知类别为 c_k 的节点的激活扩散类别向量的平均值:

$$\mathbf{ASRV}(c_k) = \frac{1}{|V_{c_k}^K|} \sum_{v_i \in V_{c_k}^K} \mathbf{ASCV}(v_i)_k, \quad (4)$$

其中 $V_{c_k}^K = \{v_i \mid v_i \in V^K, x_i = c_k\}$.

预测时, 对未标记节点 v_i 进行激活扩散后的邻居集中的未标记邻居节点使用当前估计概率, 此时式(3)变为

$$\mathbf{ASCV}(v_i)_k = \frac{1}{Z} \cdot \sum_{v_j \in EN_i} E(v_j) \cdot P(x_j = c_k \mid EN_j), \quad (5)$$

其中 EN_i, EN_j 分别为节点 v_i, v_j 激活扩散的邻居集, $Z = |EN_i|$.

最后, 给定未标记节点 $v_i \in V^U$, 引入激活扩散的类分布关系近邻分类器(ASCDRN)估计类别概率 $P(x_i = c_k \mid EN_i)$ 为节点 v_i 的激活扩散类别向量 $\mathbf{ASCV}(v_i)$ 和类 c_k 的激活扩散参考向量 $\mathbf{ASRV}(c_k)$ 之间的余弦相似度:

$$P(x_i = c_k \mid EN_i) = \text{Sim}(\mathbf{ASCV}(v_i)_k, \mathbf{ASRV}(c_k)), \quad (6)$$

其中 $\text{Sim}(a, b)$ 是任意向量相似度函数(例如 $L1, L2$, 余弦 cosine 等), 归一化值在 $[0, 1]$ 内. 本文使用 cosine 余弦相似度函数. 至此得到了未标记节点 v_i 的类别概率分布.

协作推理方法可以同时一组未标记节点进行推理. 该技术已应用到计算视觉和图像处理^[29]等领域. 松弛标注保留了节点的当前不确定性, 而不像迭代分类给每个未标记的节点分配一个固定的标签. 松弛标注方法中 $(t+1)$ 步的类分布将基于 t 步的标签估计进行更新. 为保证收敛, 本文使用文献[3]中改进带有模拟退火的松弛标注协作推理方法进行同时推理:

$$P(x_i \mid EN_i)^{(t+1)} = \beta^{(t+1)} \cdot P(x_i \mid EN_i)^{(t)} + (1 - \beta^{(t+1)}) \cdot P(x_i \mid EN_i)^{(t+1)}, \quad (7)$$

其中 $\beta^0 = k$, $\beta^{(t+1)} = \beta^{(t)} \alpha$, k 为 $0 \sim 1$ 内常数, 本文设为 1, α 为衰退常量, 设为 0.99. 实验证明, 当 $0.9 < \alpha < 1$ 时本文方法性能是鲁棒的. 如果 α 太小将导致来自邻居的影响过快地衰退, 当已标记节点非常少时会降低本文方法性能. 最后, 未标记节点 v_i 由类分布中概率最大值对应的标签标记:

$$x_i = \underset{c_k}{\text{argmax}} \{P(x_i = c_k \mid EN_i)\}. \quad (8)$$

4 实验与结果

4.1 实验设置与实验数据

在网络数据中进行针对传统机器学习相互独立数据的交叉验证是不适用的, 本文希望已标记数据集 V^K 和未标记数据集 V^U 尽可能的不相交. 因此对数据集 V 进行类分层随机抽样得到 V^K 作为训练集, 抽样率从 $10\% \sim 90\%$ 变化. 测试集 V^U 由 $V - V^K$ 得到, 并对 V^U 中没有边连接到 V^K 中任何节点的节点进行剪枝. 对 10 次测试结果的精度取平均值, 遵循标准的类分层十折交叉验证.

在训练阶段, 不仅输入节点集, 也输入图和已知节点的标签, 标签未知的节点被忽略. 分类器对每个类别进行建模. 测试阶段分类一个新节点时, 已标记节点可作为背景信息.

本文使用来自机器学习研究领域中的 5 个基准数据集检验 ASCDRN 方法的分类性能, 其中有基于 WebKB 项目的来自 4 个计算机科学系的网页数据集: cornell, texas, washington, wisconsin; 来自互联网电影数据库的网络数据集 imdb, 用于建模预测 1996 年—2001 年在美国上映的电影的首映周末票房是否超过 200 万美元. 实验数据集信息列于表 1. 表 1 中给出的同质度是根据文献[30]针对整个网

络数据集的同质度:网络数据中,与已标记节点标签相同的直接邻居节点占其所有直接邻居的平均百分数.由表 1 可见,数据集 imdb 是同质性较高的网络数据,其他 4 个数据集的同质性较低,是异质性网络数据.

表 1 实验数据集信息

Table 1 Information of experimental datasets

数据集	节点数	边数	同质度	数据集	节点数	边数	同质度
imdb	1 441	40 634	0.738 337	washington	434	1 941	0.409 598
cornell	351	1 393	0.265 515	wisconsin	354	1 155	0.231 258
texas	338	1 002	0.165 911				

通过测试发现, E 和 T 的设置与网络数据边的平均度数及同质度相关.同质性数据集 imdb 的节点数和边数都较多,扩散激活初始能量 E 设为 300,并且阈值 $T=1$;另外 4 个网络数据集将初始能量 E 设为 1,阈值 T 设为 0.15.使邻域通常包含 10~100 个顶点,排序很快收敛.增加能量或降低阈值将提供更宽广的节点邻域,但将增加计算时间.相反,降低激活能量也不是有益的,因为能量只会扩散到直接邻居(流量将在阈值限制下停止),提供与基本直接邻域获取方法相同的节点邻域信息.

4.2 实验结果

为研究不同分类方法对不同网络数据的分类性能,本文将引入激活扩散的类分布关系近邻分类器 ASCDRN 与原类分布关系近邻分类器 CDRN 以及加权投票关系近邻分类器 WVRN 在 5 个数据集上进行对比实验.其中 CDRN 和 WVRN 都是基于同质性假设和一阶 Markov 假设,采用节点的直接邻居节点分类待分类节点.因为 Macskassy 等^[3]通过实验验证 WVRN 方法结合松弛标注的协作推理方法,与结合迭代或 Gibbs 抽样协作推理方法相比,显著提高了分类的准确性,可作为网络数据分类的基准方法.实验结果如图 4 所示.

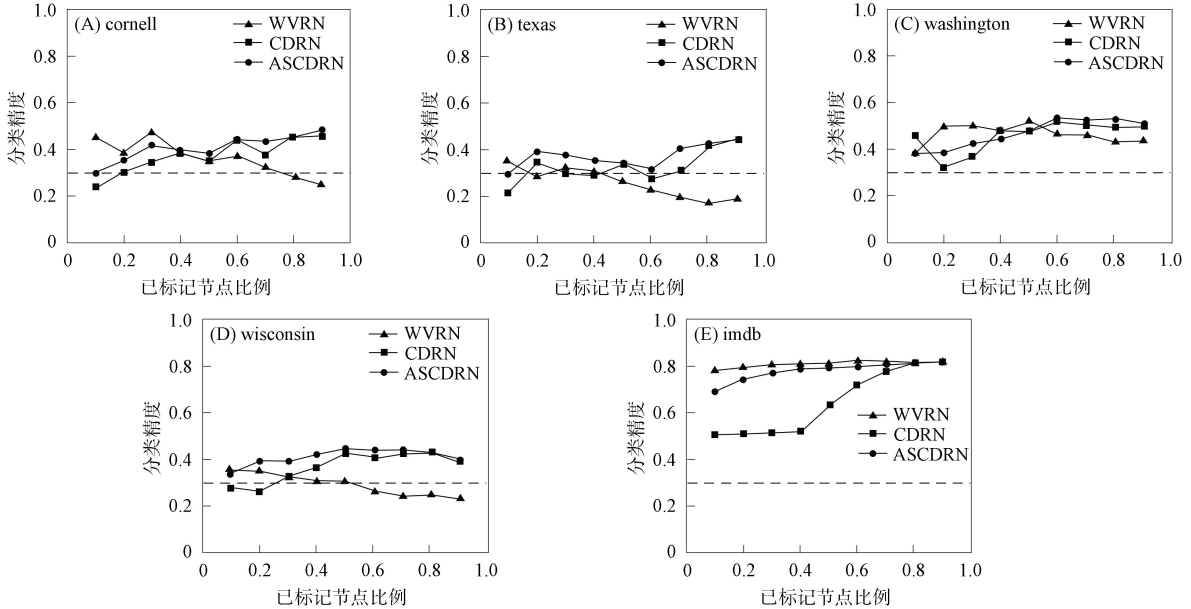


图 4 不同方法在 5 个网络数据集上的分类精度对比

Fig. 4 Comparison of classification accuracy of different methods on five network datasets

由图 4 可见,ASCDRN 方法在 5 个数据集上的分类精度相比于 CDRN 方法都有不同程度的提高,特别是在数据集 cornell, texas, wisconsin 和 imdb 上.当抽样比例大于 0.5 时,在数据集 washington 上,ASCDRN 方法也优于 CDRN 方法;当抽样比例超过 0.1 时,ASCDRN 方法在数据集 texas 和 wisconsin 上分类精度明显优于 WVRN 方法;当抽样比例大于 0.4 时,ASCDRN 方法在数据集 cornell 上优于 WVRN 方法;当抽样比例大于 0.5 时,ASCDRN 方法在数据集 washington 上也优于 WVRN 方法;在数据集 imdb 上,ASCDRN 方法的分类精度显著优于改进前的 CDRN 方法,并且逼

近 WVRN 方法, 特别是当抽样比例大于 0.7 时, 与 WVRN 方法接近. 实验结果表明, 引入激活扩散后的 ASCDRN 方法相比于原 CDRN 方法, 同质性有所提高, 从而提高了分类精度, 且由于网络数据本身同质程度的不同, 分类精度提高的程度有所不同.

综上所述, 在类分布关系近邻分类器的图节点分类中, 本文提出了采用扩散激活作为传统使用直接邻域的替代方法, 并通过实验确定了扩散激活对误分类率的积极影响.

参 考 文 献

- [1] JACKSON M O. Average Distance, Diameter, and Clustering in Social Networks with Homophily [C]// Proceedings of the 4th International Workshop on Internet and Network Economics. Berlin: Springer-Verlag, 2008: 4-11.
- [2] MCPHERSON M, LOVIN L S, COOK J M. Birds of a Feather; Homophily in Social Networks [J]. Annual Review of Sociology, 2001, 27(1): 415-444.
- [3] MACSKASSY S A, PROVOST F. Classification in Networked Data: A Toolkit and a Univariate Case Study [J]. Journal of Machine Learning Research, 2007, 8: 935-983.
- [4] VOJTEK P, BIELIKOVA M. Homophily of Neighborhood in Graph Relational Classifier [C]//Proceedings of the 36th Conference on Current Trends in Theory and Practice of Computer Science. Berlin: Springer, 2010: 721-731.
- [5] XUE G R, YU Y, SHEN D, et al. Reinforcing Web-Object Categorization through Interrelationships [J]. Data Mining and Knowledge Discovery, 2006, 12: 229-248.
- [6] PREISACH C, SCHMIDT-THIEME L. Relational Ensemble Classification [C]//Proceedings of the Sixth International Conference on Data Mining. Washington, D. C. : IEEE Computer Society, 2006: 499-509.
- [7] SUCHAL J. On Finding Power Method in Spreading Activation Search Activation Search [C]//34th Conference on Current Trends in Theory and Practice of Computer Science. [S.l.]: DBLP, 2008: 124-130.
- [8] GALLAGHER B, TONG H, ELIASSI-RAD T, et al. Using Ghost Edges for Classification in Sparsely Labeled Networks [C]//Proceeding of the 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2008: 256-264.
- [9] JENSEN D, NEVILLE J, GALLAGHER B. Why Collective Inference Improves Relational Classification [C]// Proceedings of the Tenth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2004: 593-598.
- [10] MACSKASSY S A, PROVOST F. A Simple Relational Classifier [C]//Proceedings of the Multi-relational Data Mining Workshop at 9th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2003: 64-76.
- [11] PERLICH C, PROVOST F. Distribution-Based Aggregation for Relational Learning with Identifier Attributes [J]. Machine Learning, 2006, 62(1/2): 65-105.
- [12] PERLICH C, PROVOST F. Aggregation-Based Feature Invention and Relational Concept Classes [C]// Proceedings of 9th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2003: 167-176.
- [13] CARVALHO V R, COHEN W W. On the Collective Classification of Email "Speech Acts" [C]//Proceedings of the 28th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2005: 345-352.
- [14] NEVILLE J, JENSEN D. Collective Classification with Relational Dependency Networks [C]//Proceedings ACM 2nd Workshop Multi-relational Data Mining KDD. New York: ACM, 2003: 77-91.
- [15] LU Q, GETOOR L. Link-Based Classification [C]//Proceedings of the Twentieth International Conference on Machine Learning. New York: ACM, 2003: 496-503.
- [16] LIN F, COHEN W W. Semi-supervised Classification of Network Data Using Very Few Labels [C]//2010 International Conference on Advances in Social Networks Analysis and Mining. Piscataway, NJ: IEEE, 2010: 192-199.
- [17] ZHOU D Y, BOUSQUET O, LAL T N, et al. Learning with Local and Global Consistency [C]//Proceedings of

- the 16th International Conference on Neural Information Processing Systems. New York: ACM, 2004: 321-328.
- [18] HE J R, CARBONELL J, LIU Y. Graph-Based Semi-supervised Learning as a Generative Model [C]// Proceedings of the 20th International Joint Conference on Artificial Intelligence. New York: ACM, 2007: 2492-2497.
- [19] MILAD A, HOSSEIN R, DELARAM J, et al. DDREL: From Drug-Drug Relationships to Drug Repurposing [J]. *Intelligent Data Analysis*, 2022, 26(1): 221-237.
- [20] TOBBACK E, MARTENS D. Retail Credit Scoring Using Fine-Grained Payment Data [J]. *Journal of the Royal Statistical Society Series A: Statistics in Society*, 2019, 182(4): 1227-1246.
- [21] MAYSTRE L, KUMARAPPAN N, BUTEPAGE J, et al. Collaborative Classification from Noisy Labels [C]// Proceedings of the 24th International Conference on Artificial Intelligence and Statistics (AISTATS). San Diego: PMLR, 2021, 130: 1639-1647.
- [22] ZHANG J L, JIANG Z L, DU Y P, et al. Hierarchy Construction and Classification of Heterogeneous Information Networks Based on RSDAEf [J]. *Data & Knowledge Engineering*, 2020, 127: 1-13.
- [23] LI C S, ZHANG H, CHU D H, et al. SRTM: A Supervised Relation Topic Model for Multi-classification on Large-Scale Document Network [J]. *Neural Computing and Applications*, 2020, 32: 6383-6392.
- [24] ZHANG J L, LI T, JIANG Z L, et al. A Novel Weighted Meta Graph Method for Classification in Heterogeneous Information Networks [J]. *Applied Sciences-Basel*, 2020, 10: 1-14.
- [25] YU Y, JING M, LI J, et al. Decision Network: A New Network-Based Classifier [C]// Companion of the 2020 IEEE 20th International Conference on Software Quality, Reliability, and Security(QRS-C2020). Piscataway, NJ: IEEE, 2020: 390-397.
- [26] 甘玲, 刘菊. 基于正则约束的分层仿射图神经网络文本分类模型 [J]. *重庆邮电大学学报(自然科学版)*, 2023, 35(4): 715-721. (GAN L, LIU J. Hierarchical Affine Graph Neural Network Text Classification Model Based on Regular Constraints [J]. *Journal of Chongqing University of Posts and Telecommunications (Natural Science Edition)*, 2023, 35(4): 715-721.)
- [27] 贾晨晓, 欧阳丹彤. 多重语义融合的关系分类模型 [J]. *吉林大学学报(信息科学版)*, 2023, 41(1): 50-56. (JIA C X, OUYANG D T. Relation Classification Model Based on Multiple Semantic Fusion [J]. *Journal of Jilin University (Information Science Edition)*, 2023, 41(1): 50-56.)
- [28] 王进, 徐巍, 丁一, 等. 基于图嵌入和区域注意力的多标签文本分类 [J]. *江苏大学学报(自然科学版)*, 2022, 43(3): 310-318. (WANG J, XU W, DING Y, et al. Multi-label Text Classification Based on Graph Embedding and Region Attention [J]. *Journal of Jiangsu University (Natural Science Edition)*, 2022, 43(3): 310-318.)
- [29] PELKOWITZ L. A Continuous Relaxation Labeling Algorithm for Markov Random Fields [J]. *IEEE Transactions on Systems, Man and Cybernetics*, 1990, 20(3): 709-715.
- [30] SEN P, NAMATA G, BILGIC M, et al. Collective Classification in Network Data [J]. *AI Magazine*, 2008, 29(3): 93-106.

(责任编辑: 韩 啸)