

基于深度卷积神经网络的多节点间链路预测方法

舒 坚¹, 张学佩¹, 刘琳岚², 杨志勇¹

(1. 南昌航空大学软件学院, 江西南昌 330063; 2. 南昌航空大学信息工程学院, 江西南昌 330063)

摘要: 目前, 链路预测的研究主要针对拓扑结构变化缓慢的社交网络, 集中在单节点对的链路预测. 本文针对拓扑变化频繁的机会网络, 提出一种基于模式分类的多节点间链路预测方法. 该方法基于混沌时间序列理论确定机会网络的切片时间, 采用状态图表征网络的拓扑结构, 借助深度卷积神经网络在特征提取上的优势, 从状态图的演化过程中提取机会网络的结构特征, 根据当前特征推断未来链路的演化模式, 实现多节点间的链路预测. 在 ITC (Imote-Traces-Cambridge) 真实数据集上的实验结果表明, 相比于基于 CN (Common Neighbor)、AA (Adamic-Adar)、Katz 等预测方法, 本文方法具有更好的精度和稳定性.

关键词: 机会网络; 多节点; 链路预测; 卷积神经网络; 模式分类

中图分类号: TP393 **文献标识码:** A **文章编号:** 0372-2112 (2018)12-2970-08

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2018.12.021

Multi-nodes Link Prediction Method Based on Deep Convolution Neural Networks

SHU Jian¹, ZHANG Xue-pei¹, LIU Lin-Lan², YANG Zhi-yong¹

(1. School of Software, Nanchang Hangkong University, Nanchang, Jiangxi 330063, China;

2. School of Information Engineering, Nanchang Hangkong University, Nanchang, Jiangxi 330063, China)

Abstract: The current research of link prediction mainly focuses on single node pair link prediction for social network, in which the topology doesn't change frequently. In this paper, for the opportunistic network with frequent topology change, we propose a multi-nodes link prediction method based on pattern classification. This method employs chaotic time series theory to determine the slicing time of opportunistic network, and the topology of the network is depicted by the state diagram. The structural features of opportunistic network can be extracted from the evolution of the state diagram in terms of the advantages of the deep convolution neural network on the feature extraction. The evolution pattern of the future link is inferred from the current features so as to realize the multi-nodes link prediction. The experimental results on the Imote-Traces-Cambridge dataset show that the proposed method has better precision and stability than the prediction methods based on CN (Common Neighbor), Adamic-Adar and Katz.

Key words: opportunistic network; multi-nodes; link prediction; convolutional neural networks; pattern classification

1 引言

机会网络是一种不需要源节点和目标节点之间存在完整链路, 利用节点移动带来的相遇机会实现通信的自组织网络, 源节点 S 向目标节点 D 传递消息的过程^[1]如图 1 所示, 以“存储-携带-转发”的路由模式实现

节点间通信^[2], 具有网络拓扑时变、节点资源受限、不要求网络全连通等特点, 更符合实际环境下的自主组网需求, 近年来成为学术界关注的热点^[3,4]. 链路预测是机会网络研究的难点, 链路预测的目标是根据节点间已知链路及节点的属性, 估计节点间链路存在的可能性. 有效的链路预测不仅能够挖掘网络节点间的潜

收稿日期: 2017-09-19; 修回日期: 2018-03-19; 责任编辑: 梅志强

基金项目: 国家自然科学基金 (No. 61762065, No. 61363015, No. 61501218, No. 61501217), 江西省自然科学基金 (No. 20171BAB202009, No. 20171ACB20018)

在关系,还能进一步分析网络消息传播的规律,为机会网络的上层应用^[5]提供支撑.




图1 机会网络通信示意图

针对机会网络节点移动性、节点间间歇性连接导致其网络结构随时间频繁变化的特点,本文采用模式分类方法,基于深度卷积神经网络(Convolutional Neural Networks, CNN)进行多节点间的链路预测.

2 相关研究

链路预测方法主要分为基于相似性的预测方法、基于概率模型的预测方法和基于分解混合的预测方法.

2.1 基于相似性的预测方法

该方法认为,节点属性或结构特征越相似,节点间产生连接的可能性越大.

针对科学引文或超文本链接中底层数据嘈杂的问题,Popescul 和 Ungar^[6]通过对数据库查询空间的结构化搜索生成潜在的预测因子,基于文献的作者、引用、单词统计等信息构建逻辑回归模型,进而对科学文献的引用关系进行预测;Scellato 等人^[7]考察了节点移动所在地理位置的属性,重点统计了节点的访问地区和相关活动等特征,利用有监督分类模型设计了基于地理位置的社交网络链接预测系统,用于预测缺失的好友关系.

相比节点属性信息,网络结构信息较易获取,如 Common Neighbor(CN)、Jaccard、Adamic-Adar(AA)、Resource Allocation(RA)、Katz 等^[8]. Pujari 等人^[9]考虑共同邻居数目 CN、Jaccard 等相似性指标,通过学习每一种特征对于准确预测连接的能力,将所有特征揉合在一起,赋予每种特征不同的权重,从而得到更为准确的预测结果;Lü 等人^[10]提出基于结构微扰的链路预测方法,通过对邻接矩阵施加微扰,观察邻接矩阵特征值的变化,并重构邻接矩阵,用它与真实邻接矩阵的差异衡量结构演化的一致性,根据差异的程度预测不同的链路变化趋势.上述方法适用于社交网络等拓扑变化较慢的网络,对结构变化频繁的网络,效果并不理想.

2.2 基于概率模型的预测方法

该方法以两个节点间相似度的拓扑或语义度量评估连接形成的概率进行预测. Wang 等人^[11]利用马尔科夫随机场和无向图,设计局部概率模型对两跳邻居进行局部建模,可预测大型图中两节点间发生连接的概率;Lü 等人^[12]提出随机关系模型,通过最大化边缘概

率将链路间的结构依赖看作矩阵中的实体依赖,并映射为自适应高斯核函数进行链路预测.该方法要求给出符合目标网络特点的概率模型,但大多数实际环境中,这一要求往往难以现实.

2.3 基于分解混合的预测方法

该方法根据网络的不同情况将网络进行拆分,再根据每一个部分的特点采用不同的方法进行混合预测. De^[13]等人根据节点的属性和网络结构将目标网络分为两层,第一层根据节点获得的信息判断两个节点之间产生连接的可能性,第二层根据网络的结构,结合 AA 指标,采用协同聚类的方式获取特征值,最后通过支持向量机完成整个预测过程;Chen^[14]等人提出网络稀疏化框架,通过四种不同的方法稀疏化目标网络,对稀疏化后的网络逐一训练分类器,并整合在一起进行综合预测.该方法将特定网络以特定方法分解后能有效预测网络链路,但普适性不佳.

上述研究主要针对拓扑结构变化缓慢的社交网络,而且是单节点对间的链路预测.本文针对拓扑变化频繁的机会网络,采用模式分类方法,基于动态网络的切片处理,以切片后的快照描绘网络结构信息,借助 CNN 在特征提取上的优势,来捕获网络结构的有效特征,并据此推断链路的演化模式,进行多节点间的链路预测.

3 网络拓扑信息的表征

本文采用时间序列分析方法,通过时间切片将原始连续数据分割成一系列状态矩阵,对矩阵可视化,将状态矩阵转换成对应的图像表征数据(本文称为状态图),状态图作为预测模型的输入.

3.1 切片时长的选取

采用时长 T 对机会通信产生的连续数据进行切片,生成一系列离散的拓扑快照图,时长 T 的大小对实验结果的精度有很大的影响, T 值的选取是切片的关键.

本文将机会网络视为一种混沌系统,借鉴混沌时间序列理论中的坐标延迟相空间重构技术,采用自相关函数法确定切片时长 T 的大小,如式(1)所示.

$$R(T) = \frac{\frac{1}{N} \sum_{i=1}^N [x(i+T) - \bar{x}][x(i) - \bar{x}]}{\frac{1}{N} \sum_{i=1}^N [x(i) - \bar{x}]^2} \quad (1)$$

其中, T 表示切片时长, N 表示切片后的快照数量, i 为快照序号, $i \in (1, N)$, $x(i)$ 表示第 i 张快照中节点的平均连接数, \bar{x} 表示全部网络快照内的平均连接数, $R(T)$ 表示全部网络快照间的自相关性. $R(T)$ 的值反映了连续数据之间的自相关性,对于大多数自学习模型,输入数据间的相关性越低,数据特征的独立性就越高,模型的学习效果也就越佳.自相关函数曲线示意图如图 2 所

示,理论上当 $R(T)$ 第一次降为 0 时,数据的独立性最高,但相关研究表明,实际应用中通常取 $R(T)$ 第一次下降到 $1/e$ (e 为自然底数)时更为合适^[15],这是本文选取最优时长 T 的依据.




图2 自相关函数曲线示意图

3.2 网络拓扑的量化

本文选用 ITC^[16] (Imote Traces Cambridge) 数据集,数据格式如图 3 所示.

Device ID	Device ID	Start Time	End Time
-----------	-----------	------------	----------

图3 节点通信数据格式

其中,DeviceID 表示设备编号,StartTime 表示两设备间产生连接时的时间戳,EndTime 表示两设备连接断开的时间戳.

对 ITC 数据进行切片,采用 MATLAB 对其进行可视化,得到网络快照集合 $\{G_1, G_2, \dots, G_n\}$, G_1 表示初始时刻的网络拓扑图, G_2 表示时隔一个切片时长后的拓扑图,依次类推, G_n 表示最后一张拓扑图,其演化过程如图 4 (a) ~ (c) 所示.

确定观测范围内的节点数量,再依据观测范围内的拓扑状态来构建对应的邻接矩阵(状态矩阵),如式 (2) 所示.

$$M_{i,j} = \sum_{k=1}^N \tau_{(i,j)}^k \quad (2)$$

其中, M 为转换后的状态矩阵, i 和 j 分别为矩阵的行、列下标, N 为快照时间内连接总次数, $\tau_{(i,j)}^k$ 表示节点对 $\langle i,j \rangle$ 第 k 次连接的持续时长.

3.3 状态矩阵的图像化

采用 MATLAB 的 imagesc 函数对状态矩阵进行图像化,如图 5 所示.

如图 5(c) 所示,设网络中包含 50 个节点,那么网络的拓扑状态信息包含在 50×50 像素的灰度图像内,状态图中每个像素点代表节点对间的链路,像素颜色深浅对应该链路的连接总时长,黑色表示 0,白色表示切片时长 T ,灰色是时长在 $0 \sim T$ 之间的一个值.




图4 机会网络拓扑的演化过程




图5 从网络拓扑到状态图的转换过程

4 深度卷积神经网络预测方法

本文以状态图作为 CNN 的输入,利用 CNN 不断抽象、提取图像数据中的有效信息,以发现潜藏在动态变化下的模式特征,从而预测下一时刻的模式.

4.1 基于模式分类的预测

通过 CNN 挖掘机会网络多节点间潜在的关系,从

而推断出局部区域内的链路演化模式. 预测方法如图 6 所示.

CNN 的输出 Y (标签值) 为下一时间片内多节点间组成区域内各节点间连接状态的组合,每种组合对应唯一一个状态编号,如式 (3) 所示.

$$Y_i = \sum_{s=1}^N 2^{S_s}, S_s = \begin{cases} i, & \text{有连接} \\ 0, & \text{无连接} \end{cases} \quad (3)$$

其中, i 为组合序号, S_s 为第 s 对组合之间的连接状态, N 为

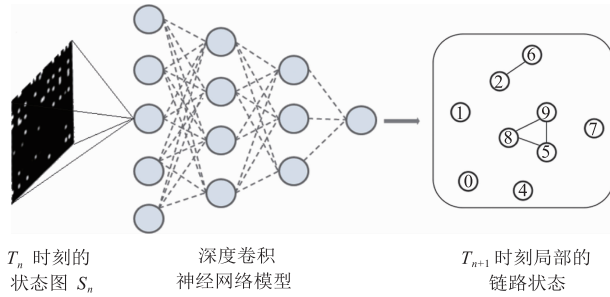


图6 模式分类预测方法

局部区域内所有节点对组合的数量,计算公式如(4)所示。

$$N = C_n^2 = \frac{n(n-1)}{2}, n \geq 2 \quad (4)$$

其中 C 为组合符号, n 为局部区域内节点数。

综上所述,本文将当前时刻的状态图作为输入,下一时刻局部区域内的连接组合作为输出标签。

4.2 CNN 模型的构建

采用 CNN 模型提取不断变化的拓扑信息中潜藏的模式特征,通过网络结构的选取、超参数的确定、训练算法的设计、性能的优化来构建模型。

4.2.1 网络结构的选取

为了提高实验效率、保障预测的精度,采用了模型相对简单但性能较好的 AlexNet 网络。AlexNet 网络共 8 层,由 5 层卷积层、2 层全连接层和 1 层输出层组成,整体结构如图 7 所示。




图7 AlexNet网络结构

4.2.2 超参数的确定

构建 CNN 模型的关键是超参数的确定,主要包括激活函数、初始权值、卷积核数和卷积核大小等。

(1) 激活函数

ReLU (Rectified Linear Unit) 是一种线性的激活函数,具有计算简单、效率高,且不会出现梯度饱和现象等特点,本文采用 ReLU 函数,以加快网络训练速度。

(2) 初始权值

权值初始化方法与激活函数的形式对深度网络的训练成功率有很大的影响。而权值初始化方法受激活函数的影响,针对选用的 ReLU 激活单元,采用文献 [17] 提出方法设定各层初始权值: $w = \text{rand}(n) / \text{sqrt}(n/2)$, 其中 w 为网络初始权值, n 为该层神经元数, rand 是高斯随机函数, sqrt 为平方根函数。

(3) 卷积核数和大小

此类超参数依赖于具体的网络结构,本文采用 AlexNet 网络结构,各层的卷积核数和大小选用默认的参数配置。

4.2.3 训练算法

训练的过程也是对整个网络进行参数寻优的过程,目前常用的算法有:SGD、Adam、Adadelta、Adagrad、RMSprop 等^[18],本文选用随机梯度下降法 SGD 进行各层参数的寻优,其中涉及了几个重要因素的选择:批训

练尺寸 batch_size 、迭代次数 epochs 、初始学习率 η 等。

选用 Bengio 在工程实践中推荐的 batch_size 常用值^[19]; epochs 通过网格搜索方式进行参数寻优;如果使用固定学习率进行训练,那么训练速度很容易受到梯度变化的影响,因此本文采用动量法实现自适应的更新调整,在梯度下降法中加入动量因子 ρ , 如式(5)所示。

$$\Delta\theta_t = \rho\Delta\theta_{t-1} - \eta \cdot g_t \quad (5)$$

其中, $\Delta\theta_t$ 为第 t 次训练时参数的更新量, ρ 为动量因子, η 为初始学习率, g_t 为初始梯度。本文中,动量因子 ρ 采用经验值 0.9, 梯度 g_t 会随 ρ 而改变,在不同的训练阶段学习率也不同,用以灵活地提升网络训练速度。

4.2.4 模型性能优化

CNN 经过多层卷积计算后,得到的数据维度一般都较高,使得其全连接层中包含的参数数量十分巨大,从而带来了计算复杂度高和易过拟合的问题。为解决这两个问题,本文采用经典的 dropout 技术^[20]进行优化,每次迭代时随机删除一些隐藏节点的连接,本文中使用的删除比例为 50%。采用 dropout 技术既能够避免由于参数过多导致的过拟合问题,使模型具有良好的泛化能力,同时也极大地提高了训练速度。

5 实验与分析

本文采用 ITC 数据集,采用分类问题中常用的性

能评价指标 AUC (Area Under the Receiver Operating Characteristic Curve) 和精确度 (Precision), 通过设计不同的对比实验来验证模型的合理性和有效性。

5.1 实验设计

(1) 实验数据集

ITC^[16] 源于剑桥大学校园学生轨迹的可视化实验, 是达特茅斯学院归档的无线自组织通信数据集之一, 具体信息如表 1 所示。

表 1 实验数据集

数据集名称	实验设备	设备数量	持续时间 (天)	通信方式	采样频率 (次/s)
ITC	iMote	50	12	Bluetooth	10

(2) 实验平台

本文模型的实质是处理模式分类问题, 且训练多组超参数模型极为耗时, 因此选用 Caffe 框架作为模型训练工具, 利用 Python 图形库 Matplotlib 对实验数据进行可视化, 同时采用 CUDA 平台实现多 GPU 编程环境, 并使用深度学习专用加速库 cuDNN 提高训练速度。

5.2 实验结果与分析

实验分为两部分, 一是使用验证集和测试集进行多组模型之间内部的比较, 考察不同参数和不同条件下模型的性能优劣, 确定最优模型; 二是使用测试集在选定的最优模型和其他相似性指标方法之间进行对比实验, 验证模型的精度。

5.2.1 实验 1

(1) 迭代次数

迭代次数 epochs 对模型的泛化精度有一定的影响, 若迭代次数太多, 模型出现过拟合, 太少又会欠拟合。本文设置了 4 个 epochs 值: 10、20、30 和 40, 预测单节点对间的链路, 以确定节点数与 epochs 之间的关系。模型训练过程中的实际效果分别如图 8 和图 9 所示。

迭代次数为 10、20、30 和 40 时, Precision 分别为 86.89%、93.25%、97.41% 和 91.84%, 在测试集上的 AUC 值分别为 0.78、0.84、0.94 和 0.88。通过比较 epochs 为 10、20 和 30 在验证集上的训练效果可知, 随着训练次数的增加, 模型的验证精度不断提高, 说明 10 次和 20 次迭代下的模型仍属于欠拟合状态; 对比 30 次和 40 次结果可以发现, 40 次迭代下的验证精度低于 30 次迭代的验证精度, 说明训练迭代 40 次时的模型已经过拟合, 其验证精度不增反降。因此, 迭代次数取 30。

(2) 切片时长

切片时长的大小对预测结果有很大的影响。本次实验进行了两轮, 预测结果均为单节点对间的链路状态, 第一轮实验验证切片时长获取方法的合理性, 设定不同的切片时长 T_1 、 T_2 、 T_3 与式(1)计算所得的最优时

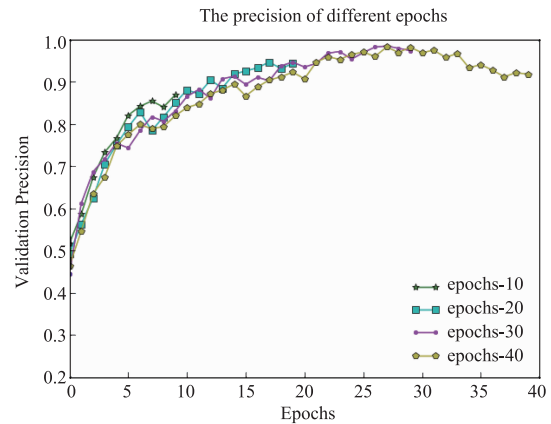


图8 不同迭代次数下的Precision

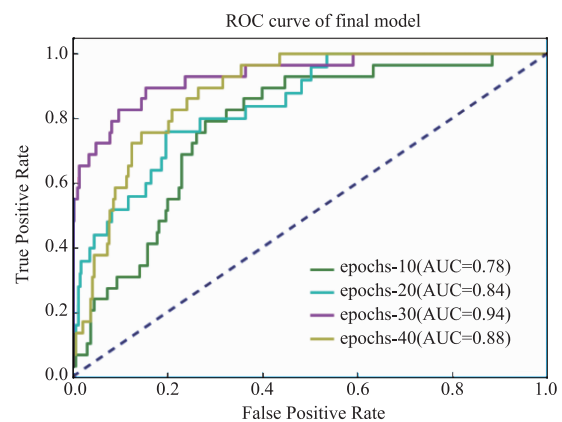


图9 不同迭代次数下的AUC

长 T_R 进行对比, 这四种时长分别为 180s、240s、480s 和 320s。第二轮实验则与文献[21]中切片效果作对比, T_{S1} 、 T_{S2} 、 T_{S3} 均为该文献中使用的切片时长, 分别为 300s、600s 和 1800s, 实验结果如图 10、11 所示。

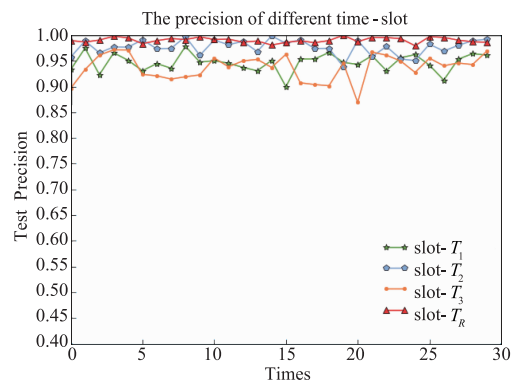


图10 本文中不同时长下的测试精度

T_1 、 T_2 、 T_3 和 T_R 的平均精度分别为 94.68%、97.64%、93.72% 和 99.03%; T_{S1} 、 T_{S2} 、 T_{S3} 和 T_R 的平均精度分别为 98.11%、93.85%、72.80% 和 98.94%。从结果中可看出, 切片时长不仅对预测精度有影响, 而且对其预测的稳定性也有一定的影响。实验结果表明, 若

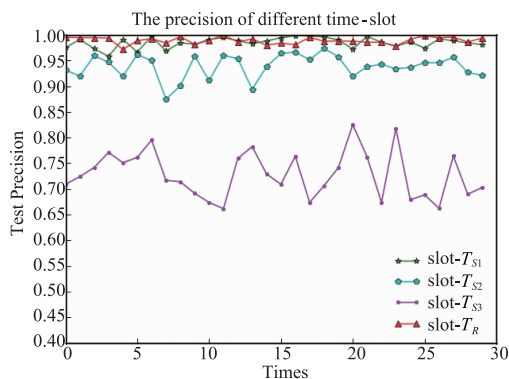


图11 本文时长与其他切片时长的对比

切片时长太短,输入数据相关性变高,模型往往对于相对独立的新特征不敏感,其预测结果更偏向于由这些冗余特征得出的值;若时间间隔太长,输入数据中出现的新特征过多,模型对其中有效特征的提取难度增加,模型难以在大量新特征中挖掘出有效特征,导致预测精度变低.因此,切片时长取计算所得时长 320s.

(3) 节点数

本文模型的主要目的是实现多节点间组成区域内链路状态的预测,但节点数的增加会导致局部区域链路状态的复杂度呈指数倍上升,使得预测难度大大增加.为了探寻节点数和预测效果之间的关系,本次实验切片时长为 320s,预测区域的节点数分别为:2、3、4,共进行了 30 次预测,实验结果如图 12 所示.

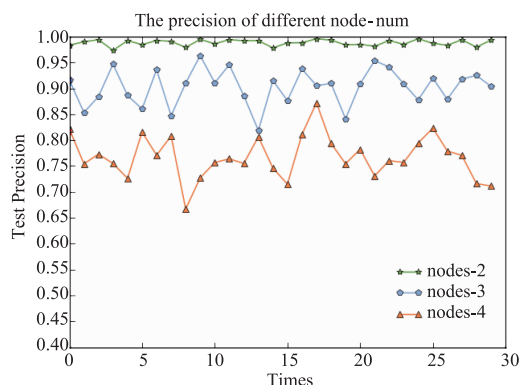


图12 模型在不同节点数下的Precision

实验中,节点数 2、3、4 时的平均精度分别为 98.82%、90.29%、76.72%,可见,随着预测节点数增多,预测精度降低,预测结果的稳定性也开始下滑.这是因为,当预测的节点数增多时,所有节点组成区域内的链路组合数量呈指数倍增长,而组合数越多,使得预测结果的搜索空间越大,模型越难准确地命中真实的情况,从而导致其预测稳定性的下滑;同时,当数据集大小有限时,对于每种组合下的输入数据就会更少,即每种标签下对应的训练样本变少,使得各标签的训练过程不充分,模型出现欠拟合现象,从而导致其预测精度变低.

5.2.2 实验 2

本次实验通过与基于结构相似性的预测方法比较,来衡量本文模型的性能,主要指标包括 CN、AA、RA、Jaccard 及 Katz.考虑到这些常见的相似性指标都只针对单节点对间的链路情况,为了确保对比实验的合理性,预测模型参数为:预测节点数 2,迭代次数 30,切片时长 320s.本次实验共进行 4 轮,每轮的测试样本从测试集中随机抽样获得,4 轮实验的测试样本大小分别为 30、50、100 和 200,实验结果如图 13~16 所示.

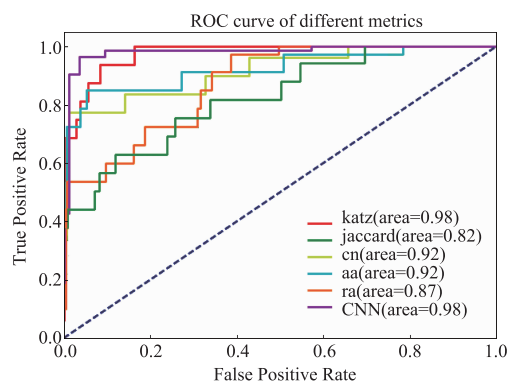


图13 第1轮对比实验(测试样本数30)




图14 第2轮对比实验(测试样本数50)




图15 第3轮对比实验(测试样本数100)

综合上述实验结果,可以看出 Jaccard 指标的预测性能相对较弱,本文模型和 Katz 指标的性能相比 CN、




图16 第4轮对比实验(测试样本数200)

AA、RA 指标更优。同时,对比本文模型与 Katz 指标的实验结果可以发现,在不同样本条件下,Katz 的预测效果表现的不稳定,本文模型的预测效果相差不大。以上结果表明,针对单节点对的链路预测,与常用的相似性预测方法(如 CN、AA、Katz 等)相比,本文模型具有更好的精度和稳定性。

6 结论

本文提出了一种移动自组织网络(机会网络)的多节点间链路预测方法,采用模式分类方法,将链路预测问题转换成模式分类问题,借助 CNN 在特征提取上的优势提取图像特征,以期抓取出相邻节点、多个节点甚至局部网络拓扑动态演化的规律。本文的主要贡献包括:①将预测问题转换成模式分类问题,利用深度学习模型来实现多节点间的链路预测;②应用混沌时间理论解决网络切片的问题;③使用图像数据来表示网络的结构特征。

本文方法能较好地辅助研究人员进行网络分析并提供合理的决策支持,具备一定的实用价值。本文不足之处是预测区域内节点数量仍然有限,未来的工作将进一步研究更多节点数间的链路预测方法。

参考文献

- [1] 熊永平,孙利民,牛建伟,刘燕. 机会网络[J]. 软件学报, 2009,20(1):124-137.
XIONG Yong-ping, SUN Li-min, NIU Jian-wei, LIU Yan. Opportunistic networks[J]. Journal of Software, 2009, 20(1):124-137. (in Chinese)
- [2] 樊秀梅,单志广,张宝贤,陈辉. 容迟网络体系结构及其关键技术研究[J]. 电子学报,2008,36(1):161-170.
FAN Xiu-mei, SHAN Zhi-guang, ZHANG Bao-xian, CHEN Hui. State-of-the-art of the architecture and techniques for delay-tolerant networks[J]. Acta Electronica Sinica, 2008, 36(1):161-170. (in Chinese)
- [3] 徐方,张沪寅,王晶,徐宁,汪志勇,邓敏. 基于社会上下

文认知的机会路由算法[J]. 电子学报,2015,43(5):833-840.

XU Fang, ZHANG Hu-yin, WANG Jing, XU Ning, WANG Zhi-yong, DENG Min. Social context-aware routing algorithms in opportunistic networks[J]. Acta Electronica Sinica, 2015, 43(5):833-840. (in Chinese)

- [4] 马学彬,白婧,郑田玉. 机会网络中基于有权社团结构图的路由协议研究[J]. 电子学报,2016,44(10):2449-2458.
MA Xue-bin, BAI Jing, ZHENG Tian-yu. A routing algorithm based on weighted community detection for opportunistic networks[J]. Acta Electronica Sinica, 2016, 44(10):2449-2458. (in Chinese)
- [5] 牛建伟,戴彬,孙利民,林佳骝,熊永平. PQBCF:一种基于中间中心度的机会网络 P2P 查询算法[J]. 电子学报, 2013,41(9):1815-1820.
NIU Jian-wei, DAI Bin, SUN Li-min, LIN Jia-liu, XIONG Yong-ping. PQBCF: a p2p query algorithm based on betweenness centrality forwarding in opportunistic networks[J]. Acta Electronica Sinica, 2013, 41(9):1815-1820. (in Chinese)
- [6] POPESCUL R, UNGAR L H. Statistical relational learning for link prediction[A]. Proceedings of the Workshop on Learning Statistical Models from Relational Data at IJCAI[C]. New York: ACM, 2003. 81-90.
- [7] SCELLATO S, NOULAS A, MASCOLO C. Exploiting place features in link prediction on location-based social networks[A]. Proceedings of the 17th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining[C]. San Diego: ACM, 2011. 1046-1054.
- [8] 吕琳媛. 复杂网络链路预测[J]. 电子科技大学学报, 2010,39(5):651-661.
LÜ Lin-Yuan. Link prediction on complex networks[J]. Journal of University of Electronic Science and Technology of China, 2010, 39(5):651-661. (in Chinese)
- [9] PUJARI M, KANAWATI R. Link prediction in complex networks by supervised rank aggregation[A]. Proceedings of the 24th IEEE International Conference on Tools with Artificial Intelligence[C]. Boca Raton: IEEE Computer Society, 2012. 782-789.
- [10] LÜ L, PAN L, ZHOU T, ZHANG YC, STANLEY HE. Toward link predictability of complex networks[J]. Proceedings of the National Academy of Sciences of the United States of America, 2015, 112(8):2325-2330.
- [11] WANG C, SATULURI V, PARTHASARATHY S. Local probabilistic models for link prediction[A]. Proceedings of the 7th IEEE International Conference on Data Mining[C]. Omaha: IEEE, 2007. 322-331.
- [12] LÜ L, ZHOU T. Link prediction in complex networks: A survey[J]. Physica A Statistical Mechanics & Its Applica-

- tions, 2011, 390(6): 1150 – 1170.
- [13] DE A, BHATTACHARYA S, SARKAR S, GANGULY N, CHAKRABARTI S. Discriminative link prediction using local, community and global signals[J]. IEEE Transactions on Knowledge & Data Engineering, 2016, 28(8): 2057 – 2070.
- [14] CHEN Y L, CHEN M S, YU P S. Ensemble of diverse sparsifications for link prediction in large – scale networks[A]. Proceedings of the 15th IEEE International Conference on Data Mining[C]. Atlantic City: IEEE, 2015. 51 – 60.
- [15] 马红光, 李夕海, 王国华, 韩崇昭, 许剑锋, 朱小菲. 相空间重构中嵌入维和时间延迟的选择[J]. 西安交通大学学报, 2004, 38(4): 335 – 338.
MA Hong-guang, LI Xi-hai, WANG Guo-hua, HAN Chong-zhao, XU Jian-feng, ZHU Xiao-fei. Selection of embedding dimension and delay time in phase space reconstruction[J]. Journal of Xi'an Jiaotong University, 2004, 38(4): 335 – 338. (in chinese)
- [16] JAMES Scott, RICHARD Gass, JON Crowcroft, PAN Hui, CHRISTOPHE Diot, AUGUSTIN Chaintreau. CRAWDAD dataset cambridge/haggle[EB/OL]. <http://crawdad.org/cambridge/haggle/20090529>, 2009 – 05 – 29.
- [17] HE K, ZHANG X, REN S, SUN J. Delving deep into rectifiers: surpassing human-level performance on imagenet classification[A]. Proceedings of the 2015 IEEE International Conference on Computer Vision. Los Alamitos[C]. Washington: IEEE Computer Society, 2015. 1026 – 1034.
- [18] Ruder S. An overview of gradient descent optimization algorithms[OL]. <http://arXiv.org/abs/1609.04747>, 2017-6-15/2017-8-28.
- [19] BENGIOY. Practical Recommendations For Gradient-Based Training Of Deep Architectures[M]. Berlin, Heidelberg, Germany: Springer, 2012. 437 – 478.
- [20] SRIVASTAVAN, HINTON G E, KRIZHEVSKY A, SUTSKEVER I, SALAKHUTDINOV R. Dropout: a simple way to prevent neural networks from overfitting [J]. Journal of Machine Learning Research, 2014, 15(1): 1929 – 1958.
- [21] ZAYANIM H, GAUTHIER V, SLAMA I, ZEGHLACHE D. Tracking topology dynamicity for link prediction in intermittently connected wireless networks[A]. Proceedings of the 8th International Wireless Communications and Mobile Computing Conference [C]. Limassol: IEEE, 2012. 469 – 474.

作者简介



舒 坚 男, 1964 年 5 月出生, 江西南昌人, 南昌航空大学教授、硕士生导师、CCF 高级会员, 主要研究方向: 无线传感器网络、分布系统、软件工程.

E-mail: shujian@nchu.edu.cn



张学佩 男, 1994 年 2 月出生, 江西景德镇人, 南昌航空大学硕士研究生, 主要研究方向: 机会网络.

E-mail: huysenZxp@163.com



刘琳岚(通信作者) 女, 1968 年 3 月出生, 湖南东安人, 南昌航空大学教授、硕士生导师, 主要研究方向: 无线传感器网络、分布系统、软件工程.

E-mail: liulinlan@nchu.edu.cn



杨志勇 男, 1982 年 12 月出生, 河南开封人, 中山大学博士, 主要研究方向: 物联网、室内定位、智能监护、压缩传感.

E-mail: yangzhy@nchu.edu.cn