

静态人脑功能超网络模型鲁棒性对比分析

张程瑞 陈俊杰 郭 浩

太原理工大学信息与计算机学院 山西 晋中 030600

(zcr130613@163.com)

摘要 鲁棒性作为一种动态行为也是超网络领域的研究热点,对构建鲁棒网络具有重要的现实意义。尽管对超网络的研究越来越多,但对其动态研究相对较少,尤其是在神经影像领域。在现有的脑功能超网络研究中,大多是探究网络的静态拓扑属性,并没有相关研究对脑功能超网络的动力学特性——鲁棒性展开分析。针对这些问题,文中首先引入 lasso, group lasso 和 sparse group lasso 方法来求解稀疏线性回归模型以构建超网络;然后基于蓄意攻击中的节点度和节点介数攻击两种实验模型,利用全局效率和最大连通子图相对大小探究脑功能超网络在应对攻击时的节点失效网络的鲁棒性,最后通过实验进行对比分析,以探究更为稳定的网络。实验结果表明,在蓄意攻击模式下,group lasso 和 sparse group lasso 方法构建的超网络的鲁棒性更强一些。同时,综合来看,group lasso 方法构建的超网络最稳定。

关键词: 脑网络;超网络;lasso;group lasso;sparse group lasso;蓄意攻击;鲁棒性

中图法分类号 TP393

Comparative Analysis of Robustness of Resting Human Brain Functional Hypernetwork Model

ZHANG Cheng-rui, CHEN Jun-jie and GUO Hao

School of Information and Computer, Taiyuan University of Technology, Jinzhong, Shanxi 030600, China

Abstract As a kind of dynamic behavior, robustness is also a research hotspot in the field of hypernetworks, which has important practical significance for the construction of robust networks. Although there are more and more researches on hypernetwork, the dynamic research is relatively less, especially in the field of neural imaging. Most of the existing researches on brain functional hypernetworks are about the static topological properties of the networks, and there is no relevant research on the dynamic characteristics robustness of brain functional hypernetworks. To solve these problems, lasso, group lasso and sparse group lasso methods are used to solve the sparse linear regression model to construct a hypernetwork. Then, based on the two experimental models of deliberate attack, node degree and node betweenness attack, the robustness of brain functional hypernetwork in response to node failure is explored by using the global efficiency and the relative size of the largest connected subgraph. Finally, a comparative analysis is made to explore a more stable network. The experimental results show that the hypernetwork constructed by group lasso and sparse group lasso is more robust in intentional attack mode. At the same time, the hypernetwork constructed by group lasso method is the most stable.

Keywords Brain network, Hypernetwork, Lasso, Group lasso, Sparse group lasso, Intentional attack, Robustness

1 引言

近年来,脑网络分析成为了一个热门话题,以核磁共振成像(Magnetic Resonance Imaging, MRI)为主的脑成像技术的发展为探究脑功能网络提供了良好的基础,并得到了广泛的应用。图论作为数学的一个分支已被广泛应用于大脑区域之间的功能交互分析^[1],基于图论对大脑拓扑特性的研究已被用于分析各种神经和精神疾病^[2-3]。

除了传统的度量网络拓扑特性的图论指标外,还有一些其他的指标如鲁棒性也被广泛用于研究网络更深层次的拓扑

到稿日期:2020-12-07 返修日期:2021-05-17

基金项目:国家自然科学基金(61672374,61741212,61876124,61873178);山西省科技厅应用基础研究项目青年面上项目(201601D021073,201801D121135);山西省教育厅高等学校科技创新研究项目(2016139);教育部赛尔网络下一代互联网技术创新项目(NGII20170712);山西省重点研发计划项目(201803D31043);国家留学基金资助出国留学项目(201708140216);国家基金面上项目(61976150)。This work was supported by the National Natural Science Foundation of China(61672374,61741212,61876124,61873178), Applied Basic Research Project of Shanxi Provincial Department of Science and Technology Youth General Project(201601D021073,201801D121135), Science and Technology Innovation Research Project of Shanxi(2016139), CERNET Innovation Project Provincial Department of Education(NGII20170712), Key R & D projects In Shanxi Province(201803D31043), Study Abroad Program Supported by National Study Fund(201708140216) and General Projects of National Fund(61976150)。

通信作者:郭浩(feiyu_guo@sina.com)

特性。鲁棒性是系统的一个基本特性,是伴随不确定性的一种常见现象,反映了网络对故障和攻击的容忍度^[4]。以脑网络为例,作为高效的动态网络,某个节点的失效或破坏尤其是脑网络中核心节点的失效,会对网络拓扑结构产生一定影响^[5]。

目前关于复杂网络鲁棒性的研究引起了诸多研究者的注意。He 等^[6]利用最大连通子图来度量阿尔兹海默症患者脑网络的鲁棒性;Ajilore 等^[7]采用最大连通子图法测量老年抑郁症患者脑功能网络的稳健性;Lo 等^[5]用网络效率度量精神分裂症患者脑功能网络的鲁棒性。目前,大部分研究还是基于复杂网络模型来对脑网络的鲁棒性进行评估和分析的。一直以来,复杂网络成为分析网络鲁棒性的工具,通过复杂网络理论提供的一系列方法可以有效且动态地研究网络。然而,传统的复杂网络模型存在局限性,它通常是基于不同脑区之间的成对相关性来构建的,更多的是描述两个区域之间的关系,忽略了脑区中存在的高阶信息^[8]。因此,为了探究这种高阶信息,超网络被提出,其超边可以连接两个或两个以上的节点,其已被通过多种方法来实现并被成功应用于脑精神疾病的预测中^[8-11]。但是在现有的脑功能超网络研究中,大多是探究网络的静态拓扑属性,用于脑疾病的分类研究,对其动态研究还相对较少。据我所知,目前基于超网络模型的脑网络鲁棒性研究基本没有。

针对上述问题,本文将鲁棒性理论引入脑功能超网络模型中,用于分析不同方法下构建的超网络的稳定性。具体来说,引入 lasso^[8] 方法 (least absolute shrinkage and selection operator)、group lasso^[12-14] 方法 和 sparse group lasso^[13-14] 方法 来求解稀疏线性回归模型以构建超网络,并利用基于节点度与节点介数的攻击策略,从网络构建的角度来探讨不同超网络模型的稳定性。本文的主要工作包括:1) 分别基于不同方法进行脑功能超网络构建;2) 计算网络的节点属性,并利用全局效率和最大连通子图探究脑功能超网络在应对攻击时的节点失效网络的鲁棒性;3) 将不同方法构建的脑功能超网络进行对比分析,评估其鲁棒性,以探究更为稳定的网络。

2 材料和方法

2.1 数据采集与预处理

本研究在实行前,遵照山西医学伦理委员会(参考编号:2012013)的建议与所有被采集人员均达成了书面协议,符合《赫尔辛基宣言》中规定的道德标准。共有 38 例抑郁症患者参加本次实验,且所有的被试均为右利手(见表 1)。使用西门子 3T 核磁共振扫描设备对所有被试进行静息态功能磁共振扫描。

表 1 被试的人口统计和临床特征

Table 1 Demographic and clinical characteristics of subjects

category	depression group
age	17~49(28.4 ±9.68)
Gender(male/female)	15/23
handedness(right/left)	0/38
HAMD	15~42(22.8 ±13.3)

注:HAMD 表示汉密尔顿抑郁量表,采用 24 项版本

实验数据采集工作由山西医科大学第一附属医院来完成,全部扫描工作均由熟习磁共振的放射科医师完成。在扫描期间,被试被要求放松、闭眼,不去想具体的事情,但要保持清醒不能睡着。扫描参数设置如下:33 axial slices, repetition time(TR)=2000 ms, echo time(TE)=30 m, thickness/skip=4/0 mm, field of view(FOV)=192 × 192 mm, matrix=64 × 64 mm, flip angle=90°。

数据预处理采用 SPM8¹⁾。首先,对数据集进行时间片校正和头动校正,剔除头动大于 3 mm 或转动大于 3° 的被试数据,最终的 38 例被试中不包含被剔除的数据。然后,对校正后符合要求的图像进行 12 维度的优化仿射变换,将其标准化到 3 mm 体素的 MNI (Montreal Neurological Institute) 标准空间中。最后,进行低频滤波以降低低频漂移和高频生物噪声的影响。

2.2 超网络的构建

2.2.1 超图

在神经影像学中,图论作为数学的一个分支,在脑网络领域得到了广泛的应用,可以从宏观上计算整个大脑的各种图论指标^[15-16]。以前的研究大多使用传统的图来构建网络模型,其中大脑区域由节点表示,两个节点之间的连接由一条边表示。然而,这只能表示大脑区域之间的成对相关,而忽略了大脑区域的高阶关系。超图是传统图的拓展,超图中的一条超边可以包含多个节点。本文主要基于超图理论对脑功能超网络进行研究,超图的定义如下:超图可以用二元关系 $H = (V, E)$ ^[17] 表示,其中, V 中的元素表示超图的节点, E 中的元素表示超图的超边,超边 $e \in E$ 是 V 的子集。超图可以用关联矩阵 H 表示,定义如下:

$$H(v, e) = \begin{cases} 1, & v \in e \\ 0, & v \notin e \end{cases} \quad (1)$$

其中,关联矩阵中对应的元素用 $H(v, e)$ 来表示, $v \in V$ 表示节点, $e \in E$ 表示超边。关联矩阵中每一行代表一条超边,每一列代表一个节点,每个节点可属于多条超边,同时每条超边可以包含多个节点。

2.2.2 稀疏线性回归模型

本文研究采用了自动解剖模板^[18] (Automated Anatomical Labeling, AAL) 对脑区进行划分,将大脑区域划分为 90 个感兴趣的解剖区域(ROIs),每个 ROI 代表功能性脑网络的一个节点,然后使用基于 Rs-fMRI 时间序列的线性回归^[19] 方法 构建超网络。现有的脑功能超网络主要通过两种不同的方法来进行构建,分别是基于星型扩展^[20-21] 和基于稀疏表示的方法^[22-23]。星型扩展方法对选取有效的最近邻居数是具有挑战性的,其对噪声的敏感性限制了数据建模的性能^[21]。在此基础上,稀疏表示被提出来创建超网络,其主要是将一个区域表示为其他区域的线性组合,来表征该区域与其他区域的交互作用。该方法能够克服星型扩展的局限性,具有数据自适应的特性^[22],因此,本文主要评估基于稀疏表示的不同脑功能超网络的稳定性。

稀疏线性回归模型的具体表示如下:

¹⁾ <http://www.fil.ion.ucl.ac.uk/spm>

$$x_m = \mathbf{A}_m \boldsymbol{\alpha}_m + \tau_m \quad (2)$$

其中, x_m 表示第 m 个 ROI 的平均时间序列; $\mathbf{A}_m = [x_1, x_2, \dots, x_{m-1}, 0, x_{m+1}, \dots, x_M]$ 表示 ROIs 的平均时间序列的矩阵(除第 m 个大脑区域外的 ROIs 的平均时间序列); $\boldsymbol{\alpha}_m$ 是量化其他 ROIs 对第 m 个 ROI 的影响程度的系数向量; τ_m 显示噪声。

2.2.3 基于 lasso 方法的超网络构建

求解稀疏线性回归模型常见的 lasso 方法^[8-9], 它的优化目标函数如下:

$$\min_{\boldsymbol{\alpha}_m} \|x_m - \mathbf{A}_m \boldsymbol{\alpha}_m\|_2 + \lambda \|\boldsymbol{\alpha}_m\|_1 \quad (3)$$

其中, $x_m, \mathbf{A}_m, \boldsymbol{\alpha}_m$ 与式(2)中的含义相同。 $\|\cdot\|_2$ 表示 l_2 范数, $\|\cdot\|_1$ 表示 l_1 范数。 λ 作为正则化参数, 用于控制连接矩阵的稀疏性, 不同的 λ 值对应不同的稀疏性, λ 值越大, 网络越稀疏, 反之网络越密集。

实验使用 SLEP 包^[24] 中的 lasso 方法来解决优化问题。通过稀疏线性模型为每个被试构建一个超网络, 其中每个节点表示一个大脑区域, 超边包含特定的脑区(即第 m 个 ROI 和 $\boldsymbol{\alpha}_m$ 中的非零元素所对应的脑区。对于每个 ROI, 将 λ 的范围设置为(0.1, 0.9), 增量为 0.1, 在 λ 取值范围内改变 λ 值来生成超边。

2.2.4 基于 group lasso 方法的超网络构建

虽然传统的脑功能超网络是通过 lasso 方法实现的, 但是 lasso 方法也存在一定的局限性, 它缺乏组效应表达的能力, 只能选择单个变量^[25]。group lasso 方法可以人为事先定义分组来体现组结构特性且可对任意变量组实现组选择^[12], 以解决分组效应的问题。

进行超网络构建之前, 分别通过 k 中心点聚类算法^[26] 与统一概率模型^[27], 根据 ROIs 的平均时间序列进行聚类, 得到 90 个脑区的分组。接着使用 group lasso 方法求解稀疏线性回归模型进行超边的构建。以下是优化目标函数:

$$\min_{\boldsymbol{\alpha}_m} \|x_m - \mathbf{A}_m \boldsymbol{\alpha}_m\|_2 + \beta \sum_{i=1}^k \|\boldsymbol{\alpha}_m G_i\|_{2,1} \quad (4)$$

其中, $\boldsymbol{\alpha}_m$ 通过聚类被分为非重叠的组; $\|\cdot\|_2$ 表示 l_2 范数, $\|\cdot\|_{2,1}$ 表示 $l_{2,1}$ 范数; β 是正则化参数, 不同 β 表明模型不同的稀疏性, β 值越大, 网络越稀疏, 选择的组越少; $\boldsymbol{\alpha}_m G_i$ 表示第 i 个组。

在实验中, 与 lasso 方法类似, 为每个被试构建一个超网络, 其中每个节点表示一个大脑区域, 超边包含特定的脑区(即第 m 个 ROI 和 $\boldsymbol{\alpha}_m$ 中的非零元素所对应的脑区。对于每个脑区, 从 0.1 到 0.9 的区间范围内改变 β 值, 增量为 0.1。

2.2.5 基于 sparse group lasso 方法的超网络构建

group lasso 虽然是预设组选择, 可以定义分组来体现组结构特性, 但是该方法只能从组级上选择变量, 忽略了组间变量的选择。稀疏组 lasso 方法在求解稀疏回归问题构建超边时, 既可以选择组级变量, 也可以选择组间变量, 实现了双级选择, 即体现了人脑中的层次结构, 避免了在超边中加入一些虚假的连接^[13-14]。

建立超网络时首先使用聚类方法将强相关的大脑区分为一个组, 本文使用 k 中心点聚类算法与统一概率模型, 根据 ROIs 的平均时间序列进行聚类, 得到 90 个脑区的分组关系。

然后使用 sparse group lasso 方法, 求解稀疏线性回归模型构建超网络。具体的优化目标函数如下:

$$\min_{\boldsymbol{\alpha}_m} \|x_m - \mathbf{A}_m \boldsymbol{\alpha}_m\|_2 + \lambda_1 \|\boldsymbol{\alpha}_m\|_1 + \lambda_2 \sum_{i=1}^k \|\boldsymbol{\alpha}_m G_i\|_2 \quad (5)$$

其中, $\boldsymbol{\alpha}_m$ 通过聚类被分为了不重叠的组; $\|\cdot\|_2$ 表示 l_2 范数, $\|\cdot\|_1$ 表示 l_1 范数; λ_1 和 λ_2 是正则化参数, λ_1 用于调整组内的稀疏性以控制非零组中的非零系数, λ_2 用于调整组级别稀疏性来控制具有非零系数的组的数目, λ_2 值越大, 表明网络越稀疏, 选择的组越少; $\boldsymbol{\alpha}_m G_i$ 表示第 i 个组。

类似地, 对于每一个 ROI, 固定 λ_2 值, 在(0.1, 0.9)区间内, 以增量 0.1 来改变 λ_1 值, $\boldsymbol{\alpha}_m$ 中非零元素对应的脑区与选定的 ROI 生成超边, 最后由所有超边组合构成超网络。

2.3 节点属性

现有研究结果表明, 在网络中存在多种指标来衡量节点的中心性, 常使用的度和介数^[28] 是网络分析中衡量节点重要性的最直接的指标^[29-30]。在网络鲁棒性研究中, 一般将节点度和介数作为量化网络节点中心性的指标^[31-32]。节点度表征了节点在网络中的连通性, 节点度越大, 该节点的中心度越高, 该节点在网络中就越重要; 节点介数越大, 经过该节点的路径越短, 对其余节点传达信息的概率影响越大, 该节点对网络的影响就越大。因此, 本文将其引入脑功能超网络模型中来参与鲁棒性的评估。

节点 i 的度 $d(i)$ 的数学定义为:

$$d(i) = \sum a_{ij} \quad (6)$$

其中, a_{ij} 为超网络的邻接矩阵中第 i 行第 j 列的元素, 表征着第 i 个节点和第 j 个节点之间的连接。

节点 i 的介数的数学定义如下:

$$B_i = \sum_{j,h \in V, j \neq h} \frac{N_{jh}(i)}{N_{ij}} \quad (7)$$

其中, V 表示节点集合, $N_{jh}(i)$ 指节点 j 和节点 h 通过节点 i 之间的最短路径数目, N_{ij} 是超网络中全部节点之间的最短路径总数。

2.4 鲁棒性仿真分析

2.4.1 鲁棒性内涵及度量指标

鲁棒性反映了网络的抗干扰性和稳固性。如果系统能够在干扰下稳定地工作并保持其功能, 那么该系统就是鲁棒的^[33]。鲁棒性的相关研究已经被拓展到了超网络, 并被应用到了交通运输、电子通信等诸多领域^[34-36], 但神经影像领域还很少。本文将鲁棒性指标^[34, 37] 应用到人脑网络上, 以探究不同方法构建的脑功能超网络的稳健性, 度量指标如下:

(1) 网络全局效率:

$$E^{\text{global}} = \frac{1}{N(N-1)} \sum_{i,j \in N, i \neq j} \frac{1}{d_{ij}} \quad (8)$$

其中, N 是网络中的节点数, d_{ij} 是节点 v_i 与 v_j 之间的最短距离。简而言之, 网络全局效率就是从所有节点对之间距离的倒数得到的平均值。全局效率越小, 表明攻击对网络鲁棒性的影响就越大。

(2) 最大连通子图的相对大小:

$$S = \frac{N'}{N} \quad (9)$$

其中, N' 表示最大连通子图中的节点数, N 是整个网络中的

节点数。最大连通子图的相对大小反映了网络结构的稳健性。 S 表示最大连通子图的相对大小, 随着被攻击节点数目的增加, S 值会变小; S 值越大, 网络的连通性越好, 鲁棒性就越强。

2.4.2 攻击策略

本研究通过移除网络的节点来模拟对超网络的蓄意攻击, 然后计算每移除一个节点后剩余网络的鲁棒性指标。蓄意攻击^[33]也称为选择性攻击或目标攻击, 指网络中的节点按一定的策略被破坏。具体地, 为了模拟蓄意攻击^[38-40], 首先, 计算超网络的节点度和介数, 并分别将这两组指标按照从小到大的顺序排序; 然后, 将该顺序作为蓄意攻击的攻击次序, 攻击节点的数目由 0 依次增加, 对超网络进行攻击; 最后, 采用归一化的全局效率(与全局效率最大值的比值)和最大连通子图相对大小(与最大连通子图相对大小最大值的比值)作为度量超网络鲁棒性的指标来衡量每种脑功能超网络模型的稳定性。对脑功能超网络模拟攻击的流程如图 1 所示。

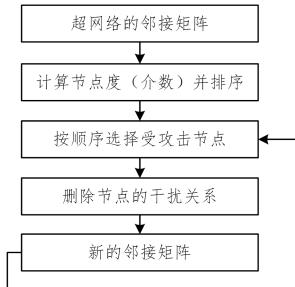


图 1 蓄意攻击过程

Fig. 1 Intentional attack process

3 结果与讨论

超网络理论已经被广泛用于人脑研究中, 但大多数是将计算静态拓扑属性用于脑疾病诊断中, 动态研究则较少。而鲁棒性作为动态指标之一, 在脑功能超网络的研究中并没有

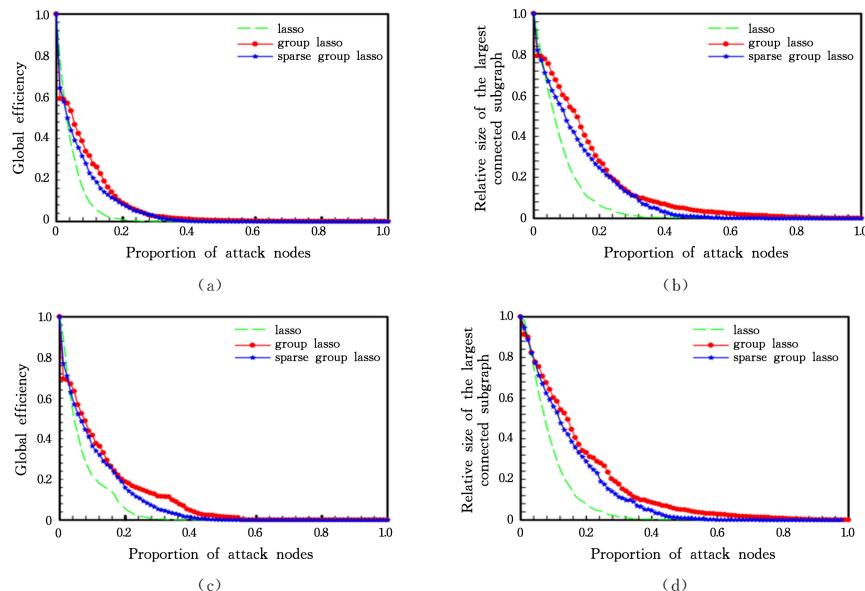


图 2 3 种方法构建的超网络在基于节点度攻击下, 归一化全局效率与归一化最大连通子图的相对大小

Fig. 2 Normalized global efficiency and the relative size of the normalized maximum link subgraph of the hypernetwork constructed by the three methods under the attack of node degree

相关报道, 因此, 本文将鲁棒性理论引入脑功能超网络模型中, 来分析不同方法所构建的超网络的稳定性。具体来说, 本文分别用 lasso 方法、group lasso 方法与 sparse group lasso 方法来求解稀疏线性回归模型, 以构建超网络, 然后在此基础上探讨不同方法构建的脑功能超网络在分别基于节点度、节点介数两种攻击策略下进行蓄意攻击时的鲁棒性。本文把归一化的全局效率(与最大值的比值)与归一化的最大连通子图相对大小(与最大值的比值)作为度量不同超网络鲁棒性的指标, 从而进行对比分析, 以探究更为稳定的网络。图 2 和图 3 给出了 3 种方法构建的脑功能超网络在基于节点度(介数)攻击下, 归一化全局效率与归一化最大连通子图的相对大小。图 2(a) 和图 2(b)、图 3(a) 和图 3(b) 表示采用 k 中心点聚类算法来确定超边而构建的超网络的鲁棒性指标的变化情况; 图 2(c) 和图 2(d)、图 3(c) 和图 3(d) 表示采用统一概率模型来确定超边而构建的超网络的鲁棒性指标的变化情况。

由图 2 和图 3 可知, 在蓄意攻击模式下, 3 种方法构建的脑功能超网络的全局效率都是随着攻击节点比例的增加而不断下降, 直到为 0, 但基于 group lasso 与 sparse group lasso 方法构建的超网络的全局效率下降得相对缓慢。综合来看, 基于 group lasso 方法构建的超网络的全局效率下降得最慢。如图 2(a) 所示, 在基于节点度攻击下, lasso 方法构建的超网络被攻击的节点比例为 0.25 时, 其全局效率降为 0; 而 group lasso 和 sparse group lasso 方法构建的超网络在度攻击节点比例分别为 0.40 和 0.34 时, 全局效率才降为 0。如图 3(a) 所示, 不同方法构建的脑功能网络在应对基于节点介数的蓄意攻击时所表现出来的网络行为(全局效率)与基于节点度的网络攻击大致相似。在基于节点介数的攻击下, lasso 方法构建的超网络被攻击的节点比例为 0.25 时, 其全局效率降为 0; 而 group lasso 和 sparse group lasso 方法构建的超网络在度攻击节点比例分别为 0.50 和 0.36 时, 全局效率才降为 0。图 2(c) 与图 3(c) 也得到了类似的结果。

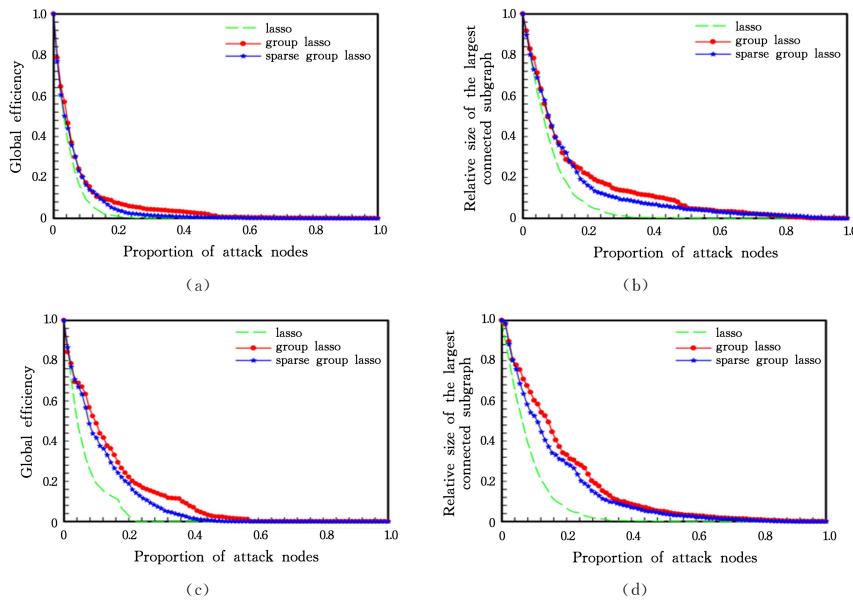


图 3 3 种方法构建的超网络在基于节点介数攻击下,归一化全局效率与归一化最大连通子图的相对大小

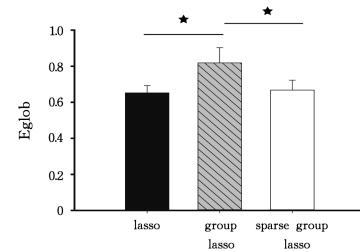
Fig. 3 Normalized global efficiency and the relative size of the normalized maximum link subgraph of the hypernetwork constructed by three methods under the node betweenness attack

对于网络连通性(见图 2(b)和图 3(b)),3 种方法构建的脑功能超网络在受到基于节点度(介数)的蓄意攻击时,最大连通子图的相对大小均在不断下降,直至为 0,而基于 group lasso 与 sparse group lasso 方法构建的超网络的最大连通子图的相对大小下降得相对缓慢。综合来看,基于 group lasso 方法构建的超网络的最大连通子图的相对大小下降得最慢。如图 2(b)所示,lasso 方法构建的超网络被攻击的节点比例为 0.20 时,最大连通子图相对大小降为 0.08,此时网络已经基本瘫痪。而 group lasso 和 sparse group lasso 方法构建的超网络在攻击节点比例分别为 0.40 和 0.35 时,最大连通子图的相对大小才下降到 0.07。同样,如图 3(b)所示,在基于节点介数攻击的情况下,当攻击节点比例为 0.20 时,lasso 方法构建的超网络的最大连通子图相对大小降为 0.06,但此时 group lasso 和 sparse group lasso 方法构建的超网络的最大连通子图相对大小分别为 0.22 和 0.17。同样的分析适用于图 2(d)与图 3(d)。也就是说,被蓄意攻击的节点数相同的情况下,基于 group lasso 与 sparse group lasso 方法构建的超网络的连通性是优于 lasso 方法构建的超网络的,并且 group lasso 方法构建的超网络的连通性最强。

以上是全局效率和最大连通子图相对大小两个指标在蓄意攻击模式下的变化。在基于节点度(介数)的蓄意攻击模式下,lasso 方法构建的超网络鲁棒性指标的变化会相对剧烈,即 group lasso 和 sparse group lasso 方法构建的超网络的全局性(全局效率)与连通性(最大连通子图相对大小)优于基于 lasso 构建的超网络。进一步地,group lasso 方法构建的超网络的全局性和连通性又强于 sparse group lasso 方法构建的超网络,这可能与不同超网络模型的网络结构不同有关。构建超边时,lasso 方法只能用于选择一个存在群体结构的大脑区域,一些相关的大脑区域没有被选择,相对严格,对群体结构信息的解读能力较差;group lasso 方法只能从组级上选择变量,不能进行组间变量的选择,当选择一个组中的大脑区域

时,组中所有的大脑区域都是相关的,因此构建超网络时选择的变量较多,基于 group lasso 方法构建的超网络可能会包含一些假连接;sparse group lasso 方法对变量的选择不仅在组水平上,而且会在单个变量水平上进行双级选择,将 lasso 与 group lasso 惩罚项混合,选择了一些与群体结构相关的大脑区域,选择的变量相对较少^[41]。因此,3 种网络的网络拓扑结构存在差异,其中,lasso 方法选取的变量最少,group lasso 选择的变量最多,而 sparse group lasso 方法处于中间,通过 group lasso 选择脑区时脑区间交互所包含的脑区相比其他方法会多。这可能是造成 group lasso 方法构建的超网络模型的全局性和连通性指标缩减较慢的潜在原因。group lasso 方法构建的超网络应对蓄意攻击的鲁棒性更强。

除此之外,如图 4 所示,通过非参数置换检验来判断 3 种超网络的效率是否存在显著的组间差异。研究中将显著性水平设为 0.05,即当 $p < 0.05$ 时,认为组间的差异性显著。



注:★表示组间差异, $p < 0.05$

图 4 全局效率差异
Fig. 4 Global efficiency differences

研究表明,对于网络全局效率,3 种超网络间存在显著差异,group lasso > sparse group lasso > lasso,group lasso 方法构建的超网络全局效率更高。节点效率异常的脑区包括左颞横回、左后扣带皮层、左侧角回、右边缘上回等。其中,group lasso 方法构建的超网络在左后扣带皮层、右边缘上回、左侧

角回节点上的效率显著增加,在左颞横回节点上的效率显著降低,从总体上提高了节点效率,脑网络的完整性增加,这在很大程度上与全局效率的差异是一致的。已有研究表明,在抑郁症患者脑网络中观察到的增加的鲁棒性可能与异常的脑网络中枢节点有关^[42]。本文找到的与抑郁症病理有关的脑区中,有的与之前的关于抑郁症患者脑网络文献中提到的结果是一致的^[11,42],因此,在 group lasso 组超网络中观察到的增强的鲁棒性可能与异常的脑网络中枢节点有关。

在蓄意攻击模式下,group lasso 和 sparse group lasso 方法构建的超网络的鲁棒性相比,group lasso 方法构建的超网络的鲁棒性更强。同时,综合来看,group lasso 方法构建的超网络的鲁棒性最强,网络也最稳定。

结束语 已有的脑网络鲁棒性研究是在传统的脑功能网络模型的基础上进行的。然而,与传统的网络模型相比,超网络模型能够更真实地反映人脑之间的直接交互作用,构建出更加真实有效的脑网络。这对于更加准确地探究脑网络的鲁棒性是非常重要的。但是,在现有的脑功能超网络研究中,大多是探究超网络的静态拓扑属性,对其动态特性-鲁棒性的研究相对较少。为了解决这个问题,采用稀疏线性回归模型构建超边,并分别根据 lasso 方法、group lasso 方法和 sparse group lasso 方法求解稀疏线性回归模型以构建超网络,探索 3 种超网络分别在应对目标攻击时节点失效网络的鲁棒性。结果表明,3 种方法构建的超网络存在鲁棒性差异。与常用的 lasso 方法构建的超网络相比,在蓄意攻击模式下,group lasso 和 sparse group lasso 方法构建的超网络的鲁棒性更强一些。同时,综合来看,group lasso 方法构建的超网络应对目标攻击的鲁棒性最强,网络也最稳定。本文的创新之处在于,将鲁棒性理论引入到脑功能超网络研究中,比较 3 种方法构建的超网络的鲁棒性差异。然而,在目前的研究中也存在问题,主要问题是,实验中使用最稀疏解对应参数的比例来作为超网络模型参数,由于技术限制,很难确定准确的数值;同时聚类方法的差异可能会造成超网络拓扑结构的不同,给结果带来差异性。因此,在未来的研究中可以合理地进行参数组合,采用不同的聚类方法进行分组,以确保构建更稳定的超边缘,进一步完善超网络,更有效地探究脑功能超网络模型下的鲁棒性。

参 考 文 献

- [1] KHALIL H K. Nonlinear Systems [M]. Publishing House of Electronics Industry, 2002.
- [2] OSOBA A, HÄNGGI J, LI M, et al. Disease severity is correlated to tract specific changes of fractional anisotropy in MD and CM thalamus—A DTI study in major depressive disorder[J]. Journal of Affective Disorders, 2013, 149(1/2/3): 116-128.
- [3] LIU F, GUO W, LIU L, et al. Abnormal amplitude low-frequency oscillations in medication-naïve, first-episode patients with major depressive disorder: A resting-state fMRI study[J]. Journal of Affective Disorders, 2012, 146(3): 401-406.
- [4] TAN Y J, LU X, WU J, et al. On the invulnerability research of complex networks[J]. Systems Engineering Theory and Practice, 2008, 6: 116-120.
- [5] LO C, SU T W, HUANG C C, et al. Randomization and resilience of brain functional networks as systems-level endophenotypes of schizophrenia[J]. Proceedings of the National Academy of Sciences, 2015, 112(29): 9123-9128.
- [6] HE Y, CHEN Z, EVANS A. Structural Insights into Aberrant Topological Patterns of Large-Scale Cortical Networks in Alzheimer's Disease[J]. The Journal of Neuroscience: The Official Journal of the Society for Neuroscience, 2008, 28(18): 4756-4766.
- [7] AJILORE O, LAMAR M, LEOW A, et al. Graph Theory Analysis of Cortical-Subcortical Networks in Late-Life Depression[J]. American Journal of Geriatric Psychiatry, 2014, 22(2): 195-206.
- [8] JIE B, WEE C Y, SHEN D, et al. Hyper-Connectivity of Functional Networks for Brain Disease Diagnosis[J]. Medical Image Analysis, 2016, 32(17): 84-100.
- [9] WANG M L, HAO X K. Discovering network phenotype between genetic risk factors and disease status via diagnosis-aligned multi-modality regression method in Alzheimer's Disease[J]. Bioinformatics, 2018(11): 11.
- [10] GUO H, LI Y, XU Y, et al. Resting-State Brain Functional Hyper-Network Construction 1129 Based on Elastic Net and Group Lasso Methods [J]. Frontiers in Neuroinformatics, 2018, 12: 25-43.
- [11] JIN Y Y, GUO H, CHEN J J. Optimization of resting state brain functional hypernetwork construction based on elasticnet method[J]. Computer Applied Research, 2018, 33(11): 3276-3280, 3297.
- [12] MEIER L, GEER S V D, BÜHLMANN P. The group Lasso for logistic regression[J]. Journal of the Royal Statistical Society: Series B (Statistical Methodology), 2008, 70: 53-71.
- [13] FRIEDMAN J, HASTIE T, TIBSHIRANI R. A note on the group lasso and a sparse group lasso[J]. Stats, 2010, 34(1): 1-8.
- [14] OGUTU J O, PIEPHO H P. Regularized group regression methods for genomic prediction: Bridge, MCP, SCAD, group bridge, group lasso, sparse group lasso, group MCP and group SCAD[J]. Bmc Proceedings, 2014, 8(5): 1-9.
- [15] FORNITO A, ZALESKY A, BREAKSPEAR M. Graph analysis of the human connectome: promise, progress, and pitfalls[J]. Neuroimage, 2013, 80: 426-444.
- [16] ZHANG C, YONG H. Revealing Modular Architecture of Human Brain Structural Networks by Using Cortical Thickness from MRI[J]. Cerebral Cortex, 2008, 18(10): 2374-2381.
- [17] SANTOS G S, GIREESH E D, PLENZ D, et al. Hierarchical Interaction Structure of Neural Activities in Cortical Slice Cultures [J]. The Journal of Neuroscience, 2010, 30(26): 8720.
- [18] TZOURIO-MAZOYER N, LANDEAU B, PAPATHANASIOU D, et al. Automated Anatomical Labeling of Activations in SPM Using a Macroscopic Anatomical Parcellation of the MNI MRI Single-Subject Brain[J]. Neuroimage, 2002, 15(1): 273-289.
- [19] SANTOS G S, GIREESH E D, PLENZ D, et al. Hierarchical Interaction Structure of Neural Activities in Cortical Slice Cultures [J]. The Journal of Neuroscience, 2010, 30(26): 8720.
- [20] LI Y, GAO X Q, JIE B, et al. Multimodal Hyper-connectivity

- Networks for MCI Classification[J]. Medical image computing and computer-assisted intervention; MICCAI. International Conference on Medical Image Computing and Computer-Assisted Intervention, 2017, 20: 433-441.
- [21] ZU C, YUE G, BRENT M, et al. Identifying disease-related sub-network connectome biomarkers by sparse hypergraph learning [J]. Brain Imaging and Behavior, 2018, 13: 879-892.
- [22] WEE C Y, YAP P T, ZHANG D, et al. Group-constrained sparse fMRI connectivity modeling for mild cognitive impairment identification [J]. Brain Structure and Function, 2014, 219(2): 641-656.
- [23] HYEKYOUNG L, DONG S L, HYEJIN K, et al. Sparse Brain Network Recovery Under Compressed Sensing[J]. IEEE Transactions on Medical Imaging, 2011, 30(5): 1-31.
- [24] LIU J, JI S W, YE J P. SLEP: sparse learning with efficient projections[R]. Arizona: Arizona State University, 2013.
- [25] YUAN M, LIN Y. Model selection and estimation in regression with grouped variables[J]. Journal of the Royal Statistical Society: Series B (Statistical Methodology), 2006, 68(1): 49-67.
- [26] PARK H S, JUN C H. A Simple And Fast Algorithm For K-means Clustering[J]. Expert Systems with Applications, 2009, 36(Part2): 3336-3341.
- [27] MONTI R P, HYVÄRINEN A. A Unified Probabilistic Model for Learning Latent Factors and Their Connectivities from High-Dimensional Data[J]. Conference on Uncertainty in Artificial Intelligence, 2018.
- [28] SUO Q, GUO J L. The structure and dynamics of hypernetworks [J]. Systems Engineering-theory & Practice, 2017, 37(3): 720-734.
- [29] LIANG X, WANG J H, HE Y. Brain connectome study: brain structural network and brain functional network[J]. Scientific Bulletin, 2010, 55(16): 1565-1583.
- [30] ESTRADA E, RODRÍGUEZ-VELÁZQUEZ J A. Subgraph centrality and clustering in complex hyper-networks[J]. Physica A, 2006, 364(none): 581-594.
- [31] WANG F H, WAN N, WANG L, et al. Study on Location and Robustness of Freight High-railway Hypernetwork [J]. Technoeconomics & Management Research, 2017(10): 17-23.
- [32] SMART A G, AMARAL L A N, OTTINO J M. Cascading failure and robustness in metabolic networks[J]. Proceedings of the National Academy of Sciences, 2008, 105(36): 13223-13228.
- [33] IYER S, KILLINGBACK T, SUNDARAM B, et al. Attack robustness and centrality of complex networks [J]. PloS one, 2013, 8(4): 1-17.
- [34] DAI F, LIN J, HU J, et al. Analysis of robustness in electromagnetic compatibility supernetwork[C]// 2013 5th IEEE International Symposium on Microwave, Antenna, Propagation and EMC Technologies for Wireless Communications. IEEE, 2013: 515-518.
- [35] LU R M, GUO J L. Topological characteristics and robustness analysis of Shanghai public transport super network[J]. Mathematics in Practice and Theory, 2018, 58 (20): 131-139.
- [36] YU W, WANG T, ZHENG Y, et al. Parameter Selection and Evaluation of Robustness of Nanjing Metro Network Based on Supernetwork[J]. IEEE Access, 2019, 7: 70876-70890.
- [37] PEI W D, XIA W, MA X R, et al. Robustness and Statistical Characters of a Class of Complex Network Models[J]. Recent Advances in Computer Science and Information Engineering, 2012, 129: 747-752.
- [38] XIE T Y, KANG K, WANG J J, et al. Robustness analysis of supply chain network with random and intentional attacks[J]. Mathematics in Practice and Theory, 2018(16): 40-47.
- [39] ZHANG H, WU W, ZHAO L. A study of knowledge supernetworks and network robustness in different business incubators [J]. Physica A: Statistical Mechanics and its Applications, 2016, 447: 545-560.
- [40] ALBERT R, JEONG H, BARABASI A L. Error and attack tolerance of complex networks[J]. Nature, 2000, 340(6794): 378-382.
- [41] LI Y, SUN C, LI P, et al. Hypernetwork Construction and Feature Fusion Analysis Based on Sparse Group Lasso Method on Functional fMRI Dataset [J]. Frontiers in Neuroence, 2020, 14(60): 243-244.
- [42] LI H, ZHOU H, YANG Y, et al. More randomized and resilient in the topological properties of functional brain networks in patients with major depressive disorder [J]. Journal of Clinical Neuroscience Official Journal of the Neurosurgical Society of Australasia, 2017, 44: 274-278.



ZHANG Cheng-rui, born in 1996, M.S candidate. Her main research interests include intelligent information processing, brain informatics.



GUO Hao, born in 1981, Ph.D, professor, is a senior member of China Computer Federation. His main research interests include artificial intelligence, intelligent information processing, brain informatics.

(责任编辑:喻藜)