

功能磁共振成像视角下的脑功能连通性分析与脑可塑性

曾卫明¹ 王倪传^{1,2} 石玉虎¹ 颜虹杰³

(1. 上海海事大学信息工程学院数字影像与智能计算实验室, 上海, 201306; 2. 深圳大学医学部生物医学工程学院, 深圳, 518060; 3. 徐州医科大学附属连云港医院神经内科, 连云港, 222002)

摘要: 依据功能磁共振成像技术探究脑功能可塑性, 对解码人脑认知活动与模拟类脑智能具有十分重要的意义, 同时也是一项极具挑战性的工作。然而, 脑功能可塑性可通过脑功能连通的变异性来体现, 而该变异性的捕捉又依赖于有效的脑功能连通性分析模型。因此, 本文首先就当前主要的脑功能连通性分析方法进行了综述, 并分析了各方法的局限性; 然后基于脑功能连通性研究的证据, 总结与分析了脑功能可塑性与职业因素之间的复杂关系; 最后对脑功能连通性分析模型、脑功能可塑性等研究方向进行了展望。

关键词: 脑功能连通性; 脑功能可塑性; 职业因素; 功能磁共振成像

中图分类号: TP391 文献标志码: A

Brain Functional Connectivity Analysis and Brain Plasticity Form Perspective of fMRI Technique

Zeng Weiming¹, Wang Nizhuan^{1,2}, Shi Yuhu¹, Yan Hongjie³

(1. Digital Image and Intelligent Computation Laboratory, College of Information Engineering, Shanghai Maritime University, Shanghai, 201306, China; 2. Department of Biomedical Engineering, School of Medicine, Shenzhen University, Shenzhen, 518060, China; 3. Department of Neurology, Affiliated Lianyungang Hospital of Xuzhou Medical University, Lianyungang, 222002, China)

Abstract: Based on functional magnetic resonance imaging (fMRI) technique, exploring the brain plasticity has a great role in the decoding of the human brain activity and simulating the brain intelligence, and it is also a challenging task. However, the brain functional plasticity could be reflected by the variability of the functional connectivity, which closely depends on the effective analysis models. Thus, firstly, the key brain functional connectivity analysis methods are reviewed and the corresponding limitations of each method are also analyzed. Then, on the evidence from the researches of brain functional connectivity, the complex relationships between the brain functional plasticity and occupational factors are summarized and analyzed. Finally, the future research directions of the brain functional connectivity analysis models and the brain functional plasticity are recommended and discussed.

Key words: brain functional connectivity; brain functional plasticity; occupational factor; functional magnetic resonance imaging

引言

人脑是迄今为止所了解到的最复杂、最精密的系统之一。世界各国学者包括神经科学家、认知学家、心理学家、社会学家以及计算机科学家等均从不同层面对人脑进行探索、研究,期待能够全面解码人脑活动,绘制相应的人脑结构与脑功能图谱,以促进脑科疾病研究以及类人脑智能研究。根据诸多学者的研究,大脑虽然复杂但工作模式至少表现出以下3方面属性:功能分离、功能整合^[1]及皮层稀疏编码属性^[2]。目前众多的脑成像研究方法的研究结果,例如:统计参数图分析方法(Statistic parametric mapping, SPM)^[3]、独立成分分析(Independent component analysis, ICA)^[4]、稀疏成分分析(Sparse component analysis, SCA)^[5]及复杂网络^[6]等,为人脑的功能分离、功能整合以及稀疏编码属性从不同角度提供了证据。在众多脑成像技术中,功能磁共振成像技术(Functional magnetic resonance imaging, fMRI)是20世纪90年代开始兴起的一种新型磁共振成像技术,结合了功能、解剖和影像3方面信息,为传统的磁共振技术从单一的形态结构研究到与功能相结合的系统研究提供强有力的技术支持。目前,功能磁共振成像技术已经在认知神经科学研究、脑科及精神疾病诊断以及心理亚健康研究等领域逐渐得到了较广泛的应用^[7-11];例如:在认知神经科学研究领域利用fMRI技术,Raichle等人提出了人脑功能活动存在着一种默认模式,该模式涉及的脑区组成了默认网络^[7];就脑科以及精神疾病,fMRI技术在注意缺陷障碍^[8]、抑郁症^[9]、精神分裂症^[10]以及阿尔茨海默症^[11]等脑科疾病的研究与诊断中,发挥着重要作用;就心理亚健康研究领域而言,上海海事大学曾卫明教授团队以海员受试者为研究对象,揭示了心理亚健康海员、心理健康海员间的脑功能网络的差异性^[12-14]。本文将从人脑的功能分离、功能整合及皮层稀疏编码属性出发,以功能磁共振成像技术为基础,首先对当前主要的脑功能网络检测模型、脑功能连接组分析模型进行综述,再讨论了脑功能可塑性、脑功能连通性和职业因素间的复杂关系,最后对脑功能连通性检测模型以及脑功能可塑性的未来研究方向进行了展望。

1 脑功能网络检测模型

当前主要的脑功能网络检测模型可分为3大类:基于假设驱动的脑功能网络检测模型、基于数据驱动的脑功能网络检测模型^[15-17]以及杂合脑功能网络检测模型。

1.1 基于假设驱动的脑功能网络检测模型

基于假设驱动的脑功能网络检测模型主要包括了互相关分析方法(Cross correlation analysis, CCA)^[18]、一致性分析方法(Coherence analysis, CA)^[19]以及SPM^[3]等。其中互相关分析简便易行,主要思想:首先选定一个种子点或感兴趣区,然后提取该种子点的时间序列,最后计算全脑中各体素的时间序列与种子点的时间序列间的相关性,便可检测到参照该种子点的脑功能网络或脑激活区^[18]。然而,互相关分析有着其自身的众多不足:首先,互相关分析是一种单变量方法,对噪声比较敏感(例如:心理噪声、血管扩张与收缩、心脏跳动及脉搏噪声等);其次,互相关分析需要预先设定种子区域,具有一定的主观性,并且只能检测与种子体素相关的连通性,无法获取全脑尺度上的脑功能连通模式。

进一步,为了克服互相关分析对噪声敏感的不足,Sun等于2004年提出了一致性分析方法^[19],其思想是将时间序列的互相关性转换为频谱域内相应的功率谱之间的一致性分析,利用脑功能信号与噪声信号在频谱域展现不同频谱特性,在一定程度上消除互相关分析方法易受生理噪声影响的不足,但该方法仍然受制于种子点选择的主观性、随意性带来的影响。

此外,就任务相关的fMRI数据分析而言,关于任务的时间域刺激模式往往已知,利用该先验信息并结合线性回归模型与统计理论,一种基于体素的统计参数图分析方法被提出,并逐步发展成为在任务状态下一种经典的脑功能网络检测方法^[3]。统计参数图分析的两大理论基础便是广义线性模型(General linear model, GLM)^[20]和高斯随机场理论^[3]。统计参数图分析法首先将原数据建模成广义线性模型来估计待定参数,然后对所估计的参数进行统计分析,从而形成统计参数图,并利用高斯随机场理论

来完成多重比较中的统计推理,以获取相应于刺激模式的脑功能区域激活图。然而,统计参数图分析要求根据任务刺激模式的先验信息构建设计矩阵,这就限制了统计参数图分析在静息状态下的适用性。

综上所述,基于假设驱动的脑功能网络检测模型均受限于预先给定的先验信息,为破除此种局限性,基于数据驱动的脑功能网络检测模型便应运而生。

1.2 基于数据驱动的脑功能网络检测模型

基于数据驱动的脑功能网络检测模型主要包括聚类分析、独立成分分析以及基于稀疏性的脑功能网络检测方法^[16,17],下面对其逐一进行介绍。

1.2.1 聚类分析方法

聚类分析主要包括模糊聚类分析(Fuzzy clustering analysis, FCA)^[21,22]、层次聚类分析(Hierarchical clustering analysis, HCA)^[23]及仿射传播聚类分析(Affinity propagation clustering, APC)^[24-26]等方法。Golay等于1998年采用FCA对任务状态fMRI数据进行脑激活区检测,其实验结果表明FCA具有较好的检测效果^[21]。就FCA而言,需要预先设定聚类个数;然而不同的聚类个数对最终提取的脑激活区准确性有较大影响^[22],并且其中采用基于相关性的单变量距离测度易受到生理噪声的干扰。为解决FCA需要预先指定聚类个数,Cordes等将HCA引入到fMRI信号分析,并定义了一种频域上的相关性度量准则,取得了较好的脑激活区分割效果,但HCA计算时间复杂度高,故实际应用很受限制^[23]。为解决FCA中单变量的相关性度量准则函数易受噪声干扰的问题,多变量的RV系数与自适应RV系数便被提出,能够有效地压制噪声,提升脑功能网络检测性能^[27,28]。

近年来,APC作为一种新型聚类方法,在人脸识别、基因数据分析等应用领域中均表现出较优的分类性能和较低的时间复杂度^[24]。2011年,Zhang等^[25]将APC方法应用到任务状态fMRI数据的脑激活区检测中,取得了较优检测性能,但其算法空间复杂度极高,而fMRI本身数据量巨大,其分析过程相当消耗内存,是一种典型以较大的空间存储代价换取时间性能的方法。为缓解APC巨大空间代价的限制,Ren等^[26]于2014年提出了一种名为基于稀疏近似集的仿射聚类(Sparse approximation based APC, SAAPC)算法,该算法首先采用稀疏近似理论^[29]进行初次数据约减,再采用Split APC算法对fMRI数据的稀疏近似集进行聚类分析,其实验结果表明:相比于APC,SAAPC方法能够更优更精确地进行脑功能网络检测,同时具有较低时间与空间复杂度^[26],并能应用于检测静息状态下的脑功能网络,但性能稍逊于ICA方法。

1.2.2 独立成分分析方法

ICA方法是一种基于高阶统计量的盲源信号分析方法,其目标是基于高阶统计量的概率统计特性。假定源信号之间相互独立,将混合数据分解为一系列相互独立的成分^[30,31]。在fMRI数据的应用分析中,假定空间域/时间域上的独立性,便形成了Spatial/temporal ICA模型^[4,32-33]。McKeown等于1998年首次将Spatial ICA方法应用到任务状态下单被试fMRI数据分析中,成功提取了与持续任务相关或瞬时任务相关的脑功能成分^[4]。2001年,Calhoun等首次应用spatial ICA方法对多被试的fMRI数据进行组水平的脑功能网络提取,提出了著名的TCGICA(Temporal concatenation group ICA)方法^[34]。为提升TCGICA在处理大规模数据时的速度,Jing等基于图形处理器(Graphics processing units, GPU)对其进行了并行化,形成了TCGICA的GPU并行化版本,使得其处理提升了6~11倍^[35]。2002年,Svensen提出了SCGICA(Spatial concatenation group ICA)方法,该方法把单个fMRI数据在空间域内进行连接,然后再应用Temporal ICA进行独立成分提取^[36]。2004年,Beckmann与Smith提出一种Tensor ICA模型来提取组水平脑功能网络,该模型首先将多被试fMRI数据在空间域3个维度上进行连接,再采用Probabilistic ICA^[37]进行脑功能网络的提取,使得基于ICA的组分析框架得到进一步发展^[38]。Schmithorst与Holland对上述3种基于多被试数据级联策略的ICA组分析方法进行了性能比较分析,其结果表明:TCGICA模型具有更优的脑功能网络检测性能^[39]。为解决多被试数据级联组分析方法(例如:TCGICA)在面临处理超多被试fMRI数据时需要执行多级主成分分析(Principal compo-

nent analysis, PCA) 压缩, 可能丢失某些精细功能信号^[40], 被试数据不同级联顺序导致 PCA 压缩性能不同等问题^[41], Schöpf 等提出了基于 ICA 的完全探索脑网络(Fully exploratory network ICA, FENICA)方法^[42], Wang 等于 2012 年提出了 Fast-FENICA 方法^[43], 这些方法均基于单被试 fMRI 数据的 ICA 分解, 省略了 PCA 多级压缩步骤, 进一步完善与发展了组 fMRI 数据的分析处理技术。

经典 ICA 模型完全依据源信号间的统计独立性假设来求解。若对于待求解的源信号在时间域或空间域上已知部分先验信息(尽管不精确), 便可以将其融合在 ICA 模型中, 以期提取更精确的脑功能成分, 称之为约束型 ICA(Constrained ICA, CICA) 或者带参考信号的 ICA 模型(ICA-R)。ICA-R 模型首先由 Lu 与 Rajapakse 提出^[44, 45], 采用牛顿迭代法进行模型求解。Lin 等通过对 Spatial ICA 模型中引入空间先验信息, 并采用固定点迭代法求解, 有效地提升了脑功能成分的提取精度^[46]。进一步, Du 与 Fan 提出了 GIG-ICA 模型(Group-information guided ICA), 通过在 ICA-R 在单被试数据分析中引入组水平下的脑功能网络的空间先验信息, 并采用多目标优化算法来进行模型求解, 提取了在单被试水平上具有更优独立性的脑功能网络^[47]。为获得更精确的组水平脑功能网络, Shi 等基于 ICA-R 框架提出了 GICA-IR 模型(Group ICA with intrinsic reference)。其结果表明, GICA-IR 所提取到的组水平脑功能成分与组内单被试水平下的相应脑功能网络之间的相关性显著提高, 并且脑激活区精确度显著提高^[48]。然而, 以上几种模型均只关注空间域的先验信息来提升脑功能网络提取的精度, 却忽略了 fMRI 信号具有的时间域属性。基于此, Wang 等于 2014 年提出了时空约束的独立成分分析模型(Temporally and spatially constrained ICA, TSCICA), 该模型同时引入了时间域与空间域的先验信息, 采用拟牛顿梯度算法进行求解, 其结果表明: 相比于 ICA、时间域约束 ICA 以及空间域约束 ICA, TSCICA 拥有更优异的抗噪性能; 与此同时, TSCICA 对时间域或者空间精度依赖性更低^[49]。

以上研究表明, 不论 ICA 还是 ICA-R 模型在脑功能网络检测领域有效, 是一项非常受欢迎的 fMRI 数据分析方法。然而, ICA 模型在脑功能网络提取过程中仅仅考虑了功能分离属性, 并未关注功能整合与皮层稀疏编码属性^[17]; 与此同时, ICA 中统计独立性假设并非完全满足于人脑的功能活动模式, 例如: Calhoun 等通过设计 4 种任务刺激模式(即 4 种呈现刺激方式: 刺激在空间域、时间域均呈现不相关性; 刺激仅在空间域呈现相关性; 刺激仅时间域呈现相关性; 刺激在时间域、空间域上均呈现相关性)来评测 Spatial ICA 与 Temporal ICA 的性能, 其研究表明: Spatial ICA 仅对刺激在空间域上不呈现相关性的脑功能网络有很好的分离性能; 同样地, Temporal ICA 仅对刺激在时间域呈现不相关性的脑功能网络具有很好的分离性能^[50]。因此该研究也表明, 在不同状态下的人脑功能活动图谱往往存在很大差异, 并非完全满足空间或时间域独立性假设, 某些脑功能网络在空间、时间域上存在着很强的依赖性。

1.2.3 基于稀疏性的脑功能网络检测方法

近年来, 不少神经认知科学家发现: 大脑皮层不少区域(例如: 主视觉区域, 内侧颞叶等)的神经元往往是选择性地对外界刺激进行编码, 即采用一种并非完全编码的稀疏方式对刺激进行编码, 体现了大脑皮层神经元反应的稀疏性^[2, 51-54]。这一神经生理学上的重大发现, 表明了稀疏性或许更加符合人脑功能活动的编码机制。对于脑功能成像, 所谓稀疏性就是对于某个认知活动, 其相应的大脑激活功能区只占整个大脑区域的小部分, 其激活面积较小, 并呈现出成团成簇的特性, 这种特性可能主要来自于神经元的稀疏编码特性^[29]。最近, Daubechies 等强调在脑功能网络检测模型(例如: ICA)中引入其他的一些数学特性, 如稀疏性, 可能会取得更优的性能^[55], 而 Calhoun 等也承认这是一个合理的目标^[56]。

基于稀疏性的脑功能网络检测主要包括以下两个方向: (1) 先利用稀疏性对原混合数据进行预表达, 获得原混合数据的稀疏近似表达集, 再对稀疏近似表达集进行盲源分离来获得精确的解混矩阵, 最后基于分离的解混矩阵进行源信号重构; (2) 构造关于原混合数据稀疏性特征优化函数, 并基于该优化函数, 分离出满足稀疏性表达的功能连通网络^[17]。对于第 1 个研究方向, Wang 等提出了基于稀疏近似的独立成分分析(Sparse approximation based ICA, SACICA)模型与基于小波阈值收缩的独立成分分析(Wavelet-shrinkage based ICA, WASICA)模型, 此两种模型首先利用稀疏近似原理构造了关于原 fMRI

数据集的稀疏近似集,再采用 ICA 对稀疏近似集进行解混矩阵的估计,最后采用解混操作提取脑功能网络^[29,57],取得较 ICA 更为精确的时空分离效果。SACICA 与 WASICA 的成功表明了稀疏近似集的更优稀疏性能够有效地提升对解混矩阵的准确估计,从而辅助提取出更高质量的脑功能网络。值得注意的是,WASICA 是 SACICA 的进一步发展,基于更加宽松的源信号概率密度函数假设,能够有效地分离超高斯信号与一些类高斯信号^[17]。就第 2 个研究方向,将稀疏性看作是 fMRI 信号空间域上的一种内在属性,Georgiev 等基于脑功能成分的稀疏性假设提出 SCA,相比于 ICA 模型,其实验结果表明该方法对检测具有依赖性的脑功能网络有着很大的潜力^[5]。2015 年,Feng 等依据脑功能网络的稀疏逼近在稀疏字典学习过程中更容易获得准确估计的想法对 SCA 模型进行了改进,其相应实验结果进一步表明:相比于 ICA 模型,Feng 等的模型更加能提取更高质量的脑功能网络^[58]。近来,Wang 等提出了一种 SDLC(Sparse dictionary learning clustering)模型对小脑的脑功能网络划分,该模型首先对静息状态 fMRI 数据进行完备稀疏字典表达,再采用 K-means 算法依据稀疏表达系数对静息状态 fMRI 信号进行分类,从而获得关于小脑功能网络的划分,实验结果表明,SDLC 能够有效地对小脑功能区进行划分^[59]。然而,正如前所述,人脑工作模式同时具有功能整合、功能分离以及皮层稀疏编码 3 方面属性。基于此,Wang 等于 2016 年提出了一种名为 SDLS(Sparse dictionary learning separation)的脑功能网络检测模型,该模型采用了最小描述长度(Minimum description length, MDL)测度对字典原子间的互不一致性(对应于功能整合与功能分离的程度)与脑功能网络的稀疏度进行自适应建模,其实验结果表明:SDLS 相比于 ICA, SACICA 等模型,具有更优时空分离精度^[60]。然而,对于稀疏字典学习而言,其稀疏模型的求解本身是 NP 难问题,当问题规模过大时(对于单个 fMRI 信号,当每个体素分辨率为 2 mm^3 时,往往具有 902 629 个样本),稀疏模型求解便变得非常困难^[61,62],因此快速有效的稀疏学习算法还待进一步研究与扩展。

1.3 杂合脑功能网络检测模型

在众多基于假设驱动的脑功能网络检测模型中,GLM 为任务状态 fMRI 数据分析中广泛使用的模型,然而 SPM 是一种融合了 GLM 与随机场推理的有效脑成像分析工具^[20]。一方面,SPM 中的 GLM 于 fMRI 数据分析而言,往往具有如下几方面的局限性:(1) fMRI 信号非常复杂,残差项的正态分布与独立性假设可能不能完全满足,可能存在服从于非高斯分布的残差项;(2) fMRI 信号中源成分具有较大的变异性,例如:心信号、脉搏信号等,难于对其进行精确的建模;(3) GLM 中通常采用典型血液动力学响应函数并非具有普适性^[63],这样便会产生关于错误激活区的估计,例如:不同脑区的体素可能具有不同的血液动力学响应模式,并且不同的任务刺激也产生不同的动力学响应模式。另一方面,基于 GLM 的 SPM 方法采用的随机场推理模式对于解决神经影像数据中多因素推理具有优异性能。相应地,就数据驱动的脑功能网络检测模型而言,其优异性在于能够充分利用 fMRI 数据的内在分布,获取脑激活区域与相应的脑活动模式;然而,其主要不足在于:(1) 难于将其统一到统计框架下推断某个体素相对于某个假设激活与否^[64,65];(2) 难于有效提取瞬时任务相关(Transiently task related, TTR)的脑激活区^[64]。

综合假设驱动模型与数据驱动模型各自长处,特别是 SPM,ICA、稀疏学习模型,扬长避短,学者们提出为数众多的杂合脑功能网络检测模型。例如:2000 年,McKeown 基于 Spatial ICA 与 SPM 提出了一种名为杂合独立成分分析(Hybrid ICA, HYBICA)模型,该模型首先利用 Spatial ICA 分离出多种激活区的相应时间过程,再依据 TTR 的先验模式组合出关于 TTR 有效的时间过程,最后采用 GLM 获取最终的关于 TTR 刺激的脑激活区^[64]。紧接着,Hu 等于 2005 年结合 Temporal ICA 与 SPM 方法,提出了名为 SPM-ICA 的杂合模型,该模型直接采用 Temporal ICA 从 fMRI 数据中提取任务态时间过程,据此进行 GLM 参数估计,并采用随机场理论进行推理,以更优地定位脑功能激活区^[65]。进一步,基于稀疏字典学习来获取不同脑激活区的时间过程与 SPM 的优越性, Lee 等于 2011 年提出了一种 Sparse GLM 模型,用于任务状态下单被试脑功能网络检测,其实验结果表明了该模型相对于 Spatial ICA,

Temporal ICA 更具优越性^[66];最近,作为 Sparse GLM 模型的进一步发展, Lee 等提出了一种用于静息态下的脑激活区检测的 Sparse SPM 杂合模型,进一步表明了杂合模型在脑激活区检测上的优势^[67]。此外, Kelly 等对众多的杂合脑激活区检测模型进行了系统性评测,验证了杂合模型的有效性^[68]。

2 脑功能连接组分析模型

脑功能连接组分析模型主要包括了基于图理论的脑功能连接组模型与脑功能连接组特征化模型^[17],下面对这两种模型进行介绍。

2.1 基于图理论的脑功能连接组模型

上述的脑功能网络检测模型均只能刻画大脑的局部属性或局部子网路,不能完全反映全脑尺度的功能连接。因此,研究全脑尺度的功能连接属性及特性,便形成了脑功能连接组学。2005年, Salvador 等首次对静息状态下的正常受试者构建了脑功能连接组,该构建过程首先通过一个先验的自动解剖标记脑图谱模板(Automated anatomical labeling, AAL)将大脑皮层划分成若干个区域,然后计算每个受试者不同脑区之间 fMRI 时间序列的皮尔逊相关系数,最后通过统计检验定位出在该组受试者中显著存在的连接,从而获得脑功能连接组^[69,70]。随着研究深入,若将脑功能连接组中组成元素:脑区与脑区间的连接分别看作图模型中的节点与边,再结合复杂网络分析理论与统计理论,便能够有效地抽象出真实脑系统所体现出的诸多共同拓扑性质,进而通过研究网络的拓扑性质来揭示脑系统组织原理、形成机制以及演化规律等^[71]。研究者发现:复杂网络的拓扑性质对揭示人脑功能属性^[72,73]有着非常重要的作用,例如:聚类系数,刻画人脑功能分离属性;最短路径长度:刻画人脑功能整合属性;全局效率:刻画人脑信息处理效率;“小世界”性:综合体现了人脑功能整合与功能分离属性的平衡性^[74,75]。复杂网络的拓扑性质往往可以作为生物特异性指标,来研究某两对照组之间脑功能连接组的差异性,例如:AD 患者、正常老年人以及轻度认知障碍患者(Mild cognitive impairment, MCI)对照组^[76-79],偏头痛患者与正常受试者对照组等^[80,81]。

对于人脑而言,其往往具有在长时间尺度上动态整合、定位并响应内在或者外在刺激能力,因而动态脑功能连接组将更能体现人脑认知状态的时变特性,众多学者推荐采用动态脑功能连接组来研究对照组状态之间共性与差异^[82,83]。Yu 等首先采用 TCGICA 方法对健康受试者组与精神分裂症患者组分别提取内在连通网络和相应时间过程,再利用内在连通网络做节点,以加窗后的时间过程之间的皮尔逊相关系数做边,构造了动态功能连接组,最后采用复杂网络分析动态图图谱指标,其研究结果表明:精神分裂症患者组的动态图指标,例如:连接强度、聚类系数以及全局效率等在时间维度上具有更低变异性^[84]。然而,复杂网络的拓扑性质(不论是静态拓扑性质还是动态拓扑性质)却无法直观刻画与显示具有区分性的或者公共性的脑功能连接组模式,这便促成了脑功能连接组特征化模型产生。

2.2 脑功能连接组特征化模型

考虑人脑活动的实时动态响应属性, Zhang 等基于动态脑功能连接组与判别稀疏字典学习(Fisher discrimination dictionary learning, FDDL)^[85]方法,提出了一种新颖的动态脑功能连接组特征化模型(Dynamic brain functional connectivity characterization, DBFCC),该模型成功地提取到表征了静息状态与任务状态共享的公共原子连接组模式(Atomic connectome pattern, ACP)以及各自的区分性原子连接组模式^[86]。进一步,2014年 Li 等采用 DBFCC 模型提取了关于受创后心理紊乱(Post-traumatic stress disorder, PTSD)病人组的两种原子连接组模式,这些原子连接组模式能够有效地区分正常人受试者组与受创后心理紊乱病人组,有望成为一种生物指标来特征化受创后心理紊乱疾病组的脑功能活动^[87]。作为 DBFCC 模型的进一步发展,针对 DBFCC 中公共原子连接组模式与区分性原子连接组模式不容易划分、K-means 初始化全脑近似稳定连接组模式集(Whole-brain quasi-stable connectome pattern, WQCP)具有随机性与聚类结果不稳定性不足等问题, Wang 等提出了一种基于可重现性的公共

原子连接组模式与区分性连接组模式划分算法,形成了改进型的 Improved-DBFCC 模型,并将其应用到了海员组与非海员组对照组状态,有效地提取了对照组下公共原子连接组模式与区分性原子连接组模式,其中区分性原子连接组模式,能够有效系统地刻画对照组间的差异性,有望作为生物特异性指标来特征化海员组的人脑活动状态^[17]。以上研究表明:动态脑功能连接组特征化模型能够有效动态地描述两对照组或多个对照组间的公共连接模式与区分性连接模式,有助于提取到差异性生物指标,并且有效地克服了基于图理论的脑功能连接组研究中无法直观揭示具有区分性的或者公共性的脑功能连接组模式的缺陷。

3 脑功能可塑性与职业因素

脑功能连通性的改变往往和诸多因素相关,例如:脑科疾病(如老年痴呆症^[10])、精神疾病(如精神分裂症^[9])及不同年龄阶段^[88](如:儿童、青少年及老年期)等。与此同时,脑功能连通性的多样性与变异性在一定程度上反映了脑功能可塑性。近年来基于 fMRI 技术的研究不断表明:不同职业的对照组群体间展现出了显著差异的脑功能连通模式,一定程度上揭示了脑功能可塑性与职业因素间的紧密关系,即:对于长期从事某项专业职业的受试者群体,会形成相应于其职业因素需求的脑功能连通模式。下面以职业海员^[17]、职业出租车司机^[89]以及同声传译工作者^[90,91]的研究为例进行介绍。

3.1 脑功能可塑性与职业海员

就职业海员而言,其职业具有以下几方面的特殊性:(1) 长期工作在海上环境,并且工作与生活空间狭小且夹杂强机器噪声;(2) 需要较好的心理素质、较强的环境适应能力、应急能力以及较高的安全警觉性;(3) 需要专业航海技能;(4) 需要较强的命令执行能力^[17]。鉴于此,上海海事大学曾卫明教授课题组对职业海员与非海员对照组的静息状态 fMRI 数据采用 Improved-DBFCC 模型进行了脑功能连接组特征化研究^[17],其研究表明:相对于非海员群体,职业海员存在 3 种区分性的原子连接组模式,分别为:认知-情感处理系统(单一长时间海况使得呈现一定连接改变)、安全预警系统(连接增强)与海员特征化原子连接组模式。海员组的认知-情感处理系统中脑功能连接的变化可能体现了海员被试对长期单一的海上工作环境的适应性;海员组的安全预警系统相比于非海员组具有显著连接增强性能,体现了海上工作对警觉性的较高要求。海员组的特征化原子连接组模式是一种综合性的网络,包含 4 种子网络,分别为视觉网络、听觉网络、执行控制网络以及前庭功能相关网络,与海员航行经验密切相关,例如:持续性噪声干扰、维持海上环境身体平衡、在海上三维空间中定位以及服从命令等。因此,该研究表明:得益于脑功能可塑性,职业海员的职业经验能够有效重组人脑功能拓扑,以满足于职业需求。

3.2 脑功能可塑性与职业出租车司机

国防科技大学胡德文教授课题组对职业出租车司机组与非出租车司机组的脑功能连通性差异性进行了对比研究^[89],其研究表明:预警网络所涉及的大脑皮层区域间的连接模式存在着非常显著的差异性,该种连接差异性能以 90% 的准确率将职业出租车司机与非司机进行区分。与此同时,于出租车司机组而言,预警网络所涉及区域的低频振幅连通性的幅值随着驾驶年龄的增加而降低,而非司机组并未表现出该种特性;该种现象可能表明:从静态脑功能连通性层面看,预警相关的脑皮层区域之间的连接随着驾龄增加更稳定、更高效,预警网络更能轻松地完成与驾驶相关的预警功能;进一步,从动态脑功能连接性来看,多种预警相关的功能连接状态在停留时间测度上在两对照组之间具有显著差异性。因此,该研究进一步验证了,长期的出租车驾驶经验能够有效重塑脑功能连通性,体现了人脑较强的功能可塑性。

3.3 脑功能可塑性与同声传译工作者

同声传译是一项具有高强度执行控制要求的双语转译工作,不仅需要实时地对词汇、术语和措辞进

行斟酌,同时还需要保存信息在工作记忆模块,并持续地监控双语的输入输出流^[90]。一般来讲,同声传译工作者需要经过长期的专业语言技能训练。瑞士日内瓦大学的 Hervais-Adelman 等采用 fMRI 技术对高强度执行控制要求下的同声传译过程中的神经生理机理进行了探究,其研究结果表明:尾状核主要和词义—语义系统的选择与控制功能相关,而豆状核主要与语言输出的持续控制相关^[91]。Hervais-Adelman 等进一步研究表明:受试者在接受 15 个月密集型的同声传译训练后,其右侧尾状核在同声传译过程中的激活强度降低,该种现象可能来自于在执行同声传译任务中所需的两种词义—语义集间相互转换效率增强^[92]。因此,以上关于同声传译研究亦表明脑功能可塑性有助于特定经验训练满足特定职业的需求。

4 结束语

构建精确的脑功能连通性分析模型对揭示脑功能可塑性非常重要。就脑功能网络检测模型的研究而言,GLM,ICA 模型是目前较为广泛使用的方法,但近年兴起的基于稀疏性的脑功能网络检测模型依赖于脑皮层稀疏编码属性,有异军突起之势。然而,稀疏字典学习模型求解是 NP 问题,特别在面临超大神经影像数据时,其求解相当困难。因此,融合在稀疏字典学习框架下的数据压缩算法以及快速可靠的求解算法将是以后脑功能网络划分模型研究的重要方向。就脑功能连接组分析模型的研究而言,研究针对多模态数据的脑功能连接组分析模型,对更为精确地揭示脑功能可塑性有着相当重要的作用。就脑功能可塑性、脑功能连通性以及职业因素之间的复杂关系研究而言,至少有以下几个方面还待进一步探讨:(1) 探讨脑功能可塑性在职业技能培训不同阶段(例如:初级阶段、掌握阶段及熟练阶段等)作用,绘制相应不同阶段的脑功能图谱,并探讨相应阶段的特征化脑连接模式,对揭开人脑智能之谜有非常重要作用。(2) 探讨脑功能可塑性在某特定职业工作人群在其退休或者脱离该项职业后的后效应问题,例如:于职业海员而言,探究退休职业海员的特征化原子连接组模式是否会随时间改变,是否会消失。(3) 进一步扩大脑功能可塑性与多种特定职业(例如:音乐家、数学家、飞行员、画家和文学家等)之间关系的研究,形成关于脑功能可塑性与特定职业库之间脑映射图谱,为指导特定职业培训提供神经生理上的支撑知识。

本文以功能磁共振成像技术为线,首先综述了脑功能连通性分析的多种模型,例如:脑功能网络检测模型与脑功能连接组分析模型等。其中,脑功能网络检测模型主要包括了基于假设驱动的脑功能网络检测模型,基于数据驱动的脑功能网络检测模型以及杂合脑功能网络检测模型;脑功能连接组分析模型主要包括了基于图理论的脑功能连接组模型与脑功能连接组特征化模型。然后对脑功能可塑性与职业因素之间关系,以脑功能连通性分析为基础,以职业海员、职业出租车司机以及同声传译工作者为例进行了探讨。最后,对脑功能连通性分析模型,脑功能可塑性与职业因素之间关系的待研究方向进行了展望。

参考文献:

- [1] Friston K J. Functional and effective connectivity: A review[J]. *Brain Connect*, 2011, 1(1):13-36.
- [2] Olshausen B A, Field D J. Emergence of simple-cell receptive field properties by learning a sparse code for natural images [J]. *Nature*, 1996, 381(6583):607-609.
- [3] Penny W D, Friston K J, Ashburner J T, et al. *Statistical parametric mapping: The analysis of functional brain images*[M]. New York: Academic Press, 2011.
- [4] McKeown M J, Makeig S, Brown G G, et al. Analysis of fMRI data by blind separation into spatial independent component analysis [J]. *Hum Brain Mapp*, 1998, 6(3):160-188.
- [5] Georgiev P, Theis F, Cichocki A, et al. Sparse component analysis: A new tool for data mining[J]. *Data Mining in Biomedicine*, Springer Optimization and Its Applications, 2007, 7(1):91-116.
- [6] Sporns O. The human connectome: A complex network[J]. *Ann N Y Acad Sci*, 2011, 1224(1):109-125.
- [7] Raichle M E, MacLeod A M, Snyder A Z, et al. A default mode of brain function[J]. *Proc Natl Acad Sci U S A*, 2001, 98

(2):676-682.

- [8] Zang Y F, Jin Z, Weng X C, et al. Functional MRI in attention-deficit hyperactivity disorder: Evidence for hypofrontality [J]. *Brain Dev*, 2005, 27(8): 544-550.
- [9] 邱天爽, 戴睿娇, 刘亚洁. 基于静息态 fMRI 低频振幅的首发抑郁症与功能脑区关联研究[J]. *数据采集与处理*, 2015, 30(5):940-947.
Qiu Tiansuang, Dai Ruijiao, Liu Yajie. Amplitude of low-frequency fluctuation in first-episode depressed patients on resting-state functional magnetic resonance imaging[J]. *Journal of Data Acquisition and Processing*, 2015, 30(5):940-947.
- [10] Zhou Y, Shu N, Liu Y, et al. Altered resting-state functional connectivity and anatomical connectivity of hippocampus in schizophrenia[J]. *Schizophr Res*, 2008, 100(1):120-132.
- [11] Wang J, Zuo X, Dai Z, et al. Disrupted functional brain connectome in individuals at risk for Alzheimer's disease[J]. *Biol Psychiatry*, 2013, 73(5): 472-481.
- [12] Shi Y, Zeng W, Wang N, et al. Early warning for human mental sub-health based on fMRI data analysis: An example from a seafarers' resting-data study[J]. *Front Psychol*, 2015, 6:1030.
- [13] 时莹超, 曾卫明, 黄志坚, 等. 基于功能磁共振成像技术的海员心理健康评估方法研究[J]. *中华航海医学与高气压医学杂志*, 2015, 22(1): 19-23.
Shi Yingchao, Zeng Weiming, Huang Zhijian, et al. Research on the assessment of mental health status of seafarers by using fMRI [J]. *Chinese Journal of Nautical Medicine and Hyperbaric Medicine*, 2015, 22(1): 19-23.
- [14] 刘瑛华, 曾卫明, 时莹超, 等. 一种基于独立成分指纹和支持向量机的海员心理状况评估方法[J]. *中华航海医学与高气压医学杂志*, 2015, 22(6):452-455.
Liu Yinghua, Zeng Weiming, Shi Yingchao, et al. A Method based on independent component and support vector machine for the evaluation of mental status of sailors[J]. *Chinese Journal of Nautical Medicine and Hyperbaric Medicine*, 2015, 22(6):452-455.
- [15] Li K, Guo L, Nie J, et al. Review of methods for functional brain connectivity detection using fMRI[J]. *Comput Med Imaging Graph*, 2009, 33(2): 131-139.
- [16] 王倪传. 脑功能磁共振图像的 ICA 组分析方法研究[D]. 上海:上海海事大学, 2012.
Wang Nizhuan. ICA-based group-level methods modeling for human brain fMRI signal [D]. Shanghai: Shanghai Maritime University, 2012.
- [17] 王倪传. 基于稀疏性的功能磁共振信号分析方法研究[D]. 上海:上海海事大学, 2016.
Wang Nizhuan. FMRI signal analysis modeling based on sparsity [D]. Shanghai: Shanghai Maritime University, 2016.
- [18] Cao J, Worsley K. The geometry of correlation fields with an application to functional connectivity of the brain[J]. *Ann Appl Probab*, 1999, 9(4):1021-1057.
- [19] Sun F T, Miller L M, Desposito M. Measuring interregional functional connectivity using coherence and partial coherence analyses of fMRI data[J]. *NeuroImage*, 2004, 21(2):647-658.
- [20] Friston K J, Holmes A P, Worsley K J, et al. Statistical parametric maps in functional imaging: A general linear approach [J]. *Hum Brain Mapp*, 1994, 2(4): 189-210.
- [21] Golay X, Kollias S, Stoll G, et al. A new correlation-based fuzzy logic clustering algorithm for fMRI[J]. *Mag Reson Med*, 1998, 40(2):249-260.
- [22] Windischberger C, Barth M, Lamm C, et al. Fuzzy cluster analysis of high-field functional MRI data[J]. *Artif Intell Med*, 2003, 29(3):203-223.
- [23] Cordes D, Haughton V, Carew J, et al. Hierarchical clustering to measure connectivity in fMRI resting-state data[J]. *Magn Reson Imaging*, 2002, 20(4):305-317.
- [24] Frey B J, Dueck D. Clustering by passing messages between data points[J]. *Science*, 2007, 315(5814):972-976.
- [25] Zhang J, Li D, Chen H, et al. Analysis of activity in fMRI data using affinity propagation clustering[J]. *Comput Methods Biomech Biomed Engin*, 2011, 14(3):271-281.
- [26] Ren T, Zeng W, Wang N, et al. A novel approach for fMRI data analysis based on the combination of sparse approximation and affinity propagation clustering[J]. *Magn Reson Imaging*, 2014, 32(6): 736-746.
- [27] Zhang H, Zhang X, Sun Y, et al. A weighted-RV method to detect fine-scale functional connectivity during resting state[J]. *NeuroImage*, 2011, 54(4): 2885-2898.
- [28] Tang X, Zeng W, Wang N, et al. An adaptive RV measure based fuzzy weighting subspace clustering (ARV-FWSC) for fMRI data analysis[J]. *Biomed Signal Process Control*, 2015, 22: 146-154.

- [29] Wang N, Zeng W, Chen L. SACICA: A sparse approximation coefficient-based ICA model for functional magnetic resonance imaging data analysis[J]. *J Neurosci Methods*, 2013, 216(1): 49-61.
- [30] 杨竹青, 李勇, 胡德文. 独立成分分析方法综述[J]. *自动化学报*, 2002, 28(5):762-772.
Yang Zhuqing, Li Yong, Hu Dewen. Independent component analysis: A survey [J]. *Acta Automatica Sinica*, 2002, 28(5):762-772.
- [31] 陈华富, 尧德中. 独立成分分析及其应用的研究进展[J]. *生物医学工程学杂志*, 2003, 20(2):366-370.
Chen Huaifu, Yao Dezhong. Advances in independent component analysis and its application[J]. *Chinese Journal of Biomedical Engineering*, 2003, 20(2):366-370.
- [32] Yao S, Zeng W, Wang N, et al. Validating the performance of one-time decomposition for fMRI analysis using ICA with automatic target generation process[J]. *Magn Reson Imaging*, 2013, 31(6): 970-975.
- [33] Biswal B B, Ulmer J L. Blind source separation of multiple signal sources of fMRI data sets using independent component analysis[J]. *J Comput Assist Tomogr*, 1999, 23(2): 265-271.
- [34] Calhoun V D, Adali T, Pearlson G D, et al. A method for making group inferences from functional MRI data using independent component analysis[J]. *Hum Brain Mapp*, 2001, 14(3): 140-151.
- [35] Jing Y, Zeng W, Wang N, et al. GPU-based parallel group ICA for functional magnetic resonance data[J]. *Comput Methods Programs Biomed*, 2015, 119(1): 9-16.
- [36] Svensen M, Kruggel F, Benali H. ICA of fMRI group study data[J]. *NeuroImage*, 2002, 16(3):551-563.
- [37] Beckmann C F, Smith S M. Probabilistic independent component analysis for functional magnetic resonance imaging[J]. *IEEE Trans Med Imaging*, 2004, 23(2): 137-152.
- [38] Beckmann C F, Smith S M. Tensorial extensions of independent component analysis for multisubject FMRI analysis[J]. *NeuroImage*, 2005, 25(1): 294-311.
- [39] Schmithorst V J, Holland S K. Comparison of three methods for generating group statistical inferences from independent component analysis of functional magnetic resonance imaging data[J]. *J Magn Reson Imaging*, 2004, 19(3): 365-368.
- [40] Cordes D, Nandy R R. Investigating the reliability of ICA Sources obtained after PCA preprocessing[J]. *Proc Intl Soc Mag Reson Med*, 2004, 11:1086.
- [41] Zhang H, Zuo X N, Ma S Y, et al. Subject order-independent group ICA (SOI-GICA) for functional MRI data analysis[J]. *NeuroImage*, 2010, 51(4): 1414-1424.
- [42] Schöpf V, Kasess C H, Lanzenberger R, et al. Fully exploratory network ICA (FENICA) on resting state fMRI data [J]. *J Neurosci Methods*, 2010, 192:207-213.
- [43] Wang N, Zeng W, Chen L. A fast-FENICA method on resting state fMRI data[J]. *J Neurosci Methods*, 2012, 209(1):1-12.
- [44] Lu W, Rajapakse J C. Approach and applications of constrained ICA[J]. *IEEE Trans Neural Netw*, 2005, 16(1): 203-212.
- [45] Lu W, Rajapakse J C. ICA with reference[J]. *Neurocomputing*, 2006, 69(16): 2244-2257.
- [46] Lin Q H, Liu J, Zheng Y R, et al. Semiblind spatial ICA of fMRI using spatial constraints[J]. *Hum Brain Mapp*, 2010, 31(7): 1076-1088.
- [47] Du Y, Fan Y. Group information guided ICA for fMRI data analysis[J]. *NeuroImage*, 2013, 69: 157-197.
- [48] Shi Y, Zeng W, Wang N, et al. A novel fMRI group data analysis method based on data-driven reference extracting from group subjects[J]. *Comput Methods Programs Biomed*, 2015, 122(3): 362-371.
- [49] Wang Z, Xia M, Jin Z, et al. Temporally and spatially constrained ICA of fMRI data analysis[J]. *PloS One*, 2014, 9(4): e94211.
- [50] Calhoun V D, Adali T, Pearlson G D, et al. Spatial and temporal independent component analysis of functional MRI data containing a pair of task-related waveforms[J]. *Hum Brain Mapp*, 2001, 13(1): 43-53.
- [51] Olshausen B A, Field D J. Sparse coding of sensory inputs[J]. *Curr Opin Neurobiol*, 2004, 14(4):481-487.
- [52] Quiroga R Q, Reddy L, Kreiman G, et al. Invariant visual representation by single neurons in the human brain[J]. *Nature*, 2005, 435(7045):1102-1107.
- [53] Quiroga R Q, Kreiman G, Koch C, et al. Sparse but not 'grandmother-cell' coding in the medial temporal lobe[J]. *Trends Cogn Sci*, 2008, 12(3):87-91.
- [54] Bizley J K, Cohen Y E. The what, where and how of auditory-object perception[J]. *Nat Rev Neurosci*, 2013, 14(10):693-707.
- [55] Daubechies I, Roussos E, Taskerkart S, et al. Independent component analysis for brain fMRI does not select for independence[J]. *Proc Natl Acad Sci U S A*, 2009, 26(106):10415-10422.

- [56] Calhoun V D, Potluru V K, Phlypo R, et al. Independent component analysis for brain fMRI does indeed select for maximal independence[J]. *PLoS ONE*, 2013, 8(8):e73309.
- [57] Wang N, Zeng W, Shi Y, et al. WASICA: An effective wavelet-shrinkage based ICA model for brain fMRI data analysis [J]. *J Neurosci Methods*, 2015, 246: 75-96.
- [58] Feng B, Yu Z L, Gu Z, et al. Analysis of fMRI data based on sparsity of source components in signal dictionary[J]. *Neurocomputing*, 2015, 156: 86-95.
- [59] Wang C, Kipping J, Bao C, et al. Cerebellar functional parcellation using sparse dictionary learning clustering[J]. *Front Neurosci*, 2016, 10: 1-12.
- [60] Wang N, Zeng W, Chen D. A novel sparse dictionary learning separation (SDLS) model with adaptive dictionary mutual incoherence constraint for fMRI data analysis[EB/OL]. <http://ieeexplore.ieee.org/document/7416195/?arnumber=7416195&tag=1>, 2016-02-24.
- [61] Donoho D L. Compressed sensing[J]. *IEEE Trans Inform Theory*, 2006, 52(4): 1289-1306.
- [62] Baraniuk R G. Compressive sensing[J]. *IEEE Signal Process Mag*, 2007, 24(4):118-121.
- [63] Della-Maggiore V, Chau W, Peres-Neto P R, et al. An empirical comparison of SPM preprocessing parameters to the analysis of fMRI data[J]. *NeuroImage*, 2002, 17(1): 19-28.
- [64] McKeown M J. Detection of consistently task-related activations in fMRI data with hybrid independent component analysis [J]. *NeuroImage*, 2000, 11(1): 24-35.
- [65] Hu D, Yan L, Liu Y, et al. Unified SPM-ICA for fMRI analysis[J]. *NeuroImage*, 2005, 25(3): 746-755.
- [66] Lee K, Tak S, Ye J C. A data-driven sparse GLM for fMRI analysis using sparse dictionary learning with MDL criterion[J]. *IEEE Trans Med Imaging*, 2011, 30(5): 1076-1089.
- [67] Lee Y B, Lee J, Tak S, et al. Sparse SPM: Group sparse-dictionary learning in SPM framework for resting-state functional connectivity MRI analysis[J]. *NeuroImage*, 2016, 125: 1032-1045.
- [68] Kelly R E, Wang Z, Alexopoulos G S, et al. Hybrid ICA-seed-based methods for fMRI functional connectivity assessment: A feasibility study[J]. *Int J Biomed Imaging*, 2010, 2010: 1-24.
- [69] Salvador R, Suckling J, Coleman M R, et al. Neurophysiological architecture of functional magnetic resonance images of human brain[J]. *Cereb Cortex*, 2005, 15(9):1332-1342.
- [70] Salvador R, Suckling J, Schwarzbauer C, et al. Undirected graphs of frequency-dependent functional connectivity in whole brain networks[J]. *Philos Trans R Soc Lond B Biol Sci*, 2005, 360(1457):937-946.
- [71] 梁夏, 王金辉, 贺永. 人脑连接组研究: 脑结构网络和脑功能网络[J]. *科学通报*, 2010, 55(16): 1565-1583.
Liang Xia, Wang Jinhui, He Yong. Human connectome: Structural and functional brain networks[J]. *Chinese Science Bulletin*, 2010, 55(16):1565-1583.
- [72] Newman M E J. The structure and function of complex networks[J]. *SIAM Review*, 2003, 45(2): 167-256.
- [73] Stam C J, Reijneveld J C. Graph theoretical analysis of complex networks in the brain[J]. *Nonlinear Biomed Phys*, 2007, 1(1):1-19.
- [74] Bassett D S, Bullmore E D. Small-world brain networks[J]. *Neuroscientist*, 2006, 12(6):512-523.
- [75] Sporns O, Zwi J D. The small world of the cerebral cortex[J]. *Neuroinformatics*, 2004, 2(2):145-162.
- [76] Supekar K, Menon V, Rubin D, et al. Network analysis of intrinsic functional brain connectivity in Alzheimer's disease[J]. *PLoS Comput Biol*, 2008, 4(6):1-11.
- [77] Yao Z, Zhang Y, Lin L, et al. Abnormal cortical networks in mild cognitive impairment and Alzheimer's disease[J]. *PLoS Comput Biol*, 2010, 6(11):1-11.
- [78] Sanz-Arigita E J, Schoonheim M M, Damoiseaux J S, et al. Loss of 'small-world' networks in Alzheimer's disease: Graph analysis of FMRI resting-state functional connectivity[J]. *PloS one*, 2010, 5(11):1-14.
- [79] Dai Z, Yan C, Li K, et al. Identifying and mapping connectivity patterns of brain network hubs in Alzheimer's disease[J]. *Cereb Cortex*, 2015, 25(10): 3723-3742.
- [80] Liu J, Zhao L, Li G, et al. Hierarchical alteration of brain structural and functional networks in female migraine sufferers [J]. *PloS one*, 2012, 7(12): 1-10.
- [81] 陈敦耀, 杨嘉君, 曾卫明, 等. 基于复杂网络的偏头痛患者脑功能连通性研究[J]. *中国医学影像学杂志*, 2015, 23(6):424-428.
Chen Dunyao, Yang Jiajun, Zeng Weiming, et al. Brain functional connectivity in patients with migraine based on complex

- networks analysis[J]. Chinese Journal of Medical Imaging, 2015, 23(6):424-428.
- [82] Hutchison R M, Womelsdorf T, Allen E A, et al. Dynamic functional connectivity: Promise, issues, and interpretations [J]. NeuroImage, 2013, 80:360-378.
- [83] Calhoun V D, Miller R, Pearlson G, et al. The chronnectome: Time-varying connectivity networks as the next frontier in fMRI data discovery[J]. Neuron, 2014, 84(2):262-274.
- [84] Yu Q, Erhardt E B, Sui J, et al. Assessing dynamic brain graphs of time-varying connectivity in fMRI data: Application to healthy controls and patients with schizophrenia[J]. NeuroImage, 2015, 107:345-355.
- [85] Yang M, Zhang L, Feng X, et al. Fisher discrimination dictionary learning for sparse representation[C]//Computer Vision (ICCV), Spain, 2011 IEEE International Conference on. Barcelona: IEEE, 2011: 543-550.
- [86] Zhang X, Guo L, Li X, et al. Characterization of task-free and task-performance brain states via functional connectome patterns[J]. Med Image Anal, 2013, 17(8):1106-1122.
- [87] Li X, Zhu D, Jiang X, et al. Dynamic functional connectomics signatures for characterization and differentiation of PTSD patients[J]. Hum Brain Mapp, 2014, 35(4):1761-1778.
- [88] 左西年, 张喆, 贺永, 等. 人脑功能连接组: 方法学、发展轨线和行为关联[J]. 科学通报, 2012, 57(35): 3399-3413. Zuo Xinian, Zhang Zhe, He Yong, et al. The human functional connectome: Its methodology, developmental trajectory and behavioral association[J]. Chinese Science Bulletin, 2012, 57(35): 3399-3413.
- [89] Shen H, Li Z, Qin J, et al. Changes in functional connectivity dynamics associated with vigilance network in taxi drivers[J]. NeuroImage, 2016, 124: 367-378.
- [90] Hervais-Adelman A, Moser-Mercer B, Golestani N. Executive control of language in the bilingual brain: Integrating the evidence from neuroimaging to neuropsychology[J]. Front Psychol, 2011, 2: 1-8.
- [91] Hervais-Adelman A, Moser-Mercer B, Michel C M, et al. fMRI of simultaneous interpretation reveals the neural basis of extreme language control[J]. Cereb Cortex, 2015, 25(12): 4727-4739.
- [92] Hervais-Adelman A, Moser-Mercer B, Golestani N. Brain functional plasticity associated with the emergence of expertise in extreme language control[J]. NeuroImage, 2015, 114: 264-274.

作者简介:



曾卫明 (1971-), 男, 博士, 教授, 博士生导师, 研究方向: 图像处理与模式识别、大数据与数据挖掘、脑科学与人工智能等, E-mail: Zengwm86@163.com。



王倪 (1985-), 男, 博士, 研究方向: 神经影像与机器学习, 脑连接组学、脑可塑性与脑机接口等。



石玉虎 (1989-), 男, 博士研究生, 研究方向: 智能信息处理与应用。



颜虹杰 (1987-), 女, 博士, 研究方向: 神经影像与大脑疾病的预防、诊断及治疗。

