

## 基于多变量格兰杰因果关系的运动想象因效网络构建

裴文清, 孙曜

杭州电子科技大学自动化学院, 浙江 杭州 310018

**【摘要】**运动想象神经活动规律的探索为脑损伤肢体瘫痪患者康复训练新方法研发等提供理论指导。基于格兰杰因果关系构建的因效网络是分析运动想象神经活动状态的重要工具,但是格兰杰因果关系只能反映两个变量之间的相互作用,而一个简单的运动想象过程也需要多个神经节点参与,针对该问题,本研究引入可反映一个集群中多个变量之间相互作用的多变量格兰杰因果分析,优化运动想象因效网络构建方法。针对4位受试者,利用多变量及传统格兰杰因果关系,分别构建同一人两种不同运动想象模式的因效网络,并提取网络特征进行运动想象模式分类。结果表明,基于多变量格兰杰因效网络进行4位受试者运动想象模式分类的正确率分别为90.4%、88.8%、91.1%、90.3%,基于格兰杰因效网络的正确率为88.5%、89.3%、90.2%、89.7%。与传统格兰杰因果关系相比,基于多变量格兰杰因果关系构建因效网络,能更准确地反映运动想象神经活动特征状态。

**【关键词】**多变量格兰杰因果关系;运动想象;因效网络

**【中图分类号】**R319;TP3

**【文献标志码】**A

**【文章编号】**1005-202X(2018)12-1457-05

## Construction of motion imagination causal network based on multivariable Granger causality

CHANG Wenqing, SUN Yao

School of Automation, Hangzhou Dianzi University, Hangzhou 310018, China

**Abstract:** The exploration of the rules of neural activity in motion imagination can provide theoretical guidance for the development of new methods of rehabilitation training for patients with cerebral injuries and acroparalysis. The causal network constructed based on Granger causality is an important tool for analyzing the state of neural activity in motion imagination. However, Granger causality can only reflect the interaction between two variables, and a simple motion imagination process requires multiple neural nodes to participate. To solve this problem, a multivariable Granger causal analysis that can reflect the interaction among multiple variables in a cluster is introduced to optimize the construction method of motion imagination causal network. For the 4 subjects, multivariate and traditional Granger causality relationships are used to construct two different motion imaging patterns of the same subject, and the network characteristics are extracted to classify the motion imaginary patterns. The results show that the accuracy rate of motion imaging pattern classification in 4 subjects is 90.4%, 88.8%, 91.1%, and 90.3% in multivariable Granger causal network, as compared with 88.5%, 89.3%, 90.2%, 89.7% in traditional Granger causal network. Compared with the traditional Granger causality, causal network based on multivariable Granger causality can more accurately reflect the characteristics of neural activity in motion imagination.

**Keywords:** multivariable Granger causality; motion imagination; causal network

### 前言

运动想象作为近年来最具临床应用前景的康复治疗新方法之一,引起了越来越多研究者的关注,已

有研究表明,运动想象能够与实际运动一样有效激活运动相关的大脑皮层区域<sup>[1-3]</sup>。脑损伤肢体瘫痪患者可以通过运动想象来进行康复训练。大脑是人体结构和功能最为复杂的器官之一,它是由多个神经元、神经元簇和多个脑区组成的复杂网络<sup>[4]</sup>。各部分神经元相互配合完成大脑的各个功能<sup>[5]</sup>,大脑由不同的区域组成<sup>[6]</sup>,将不同的功能子区域抽象为相应的节点,并将各个区域之间的连接视为边界,这样就组成了脑功能网络<sup>[7-9]</sup>。脑功能网络分为功能性网络和因效性网络。而因效网络是一种有向网络,它可以反

**【收稿日期】**2018-06-09

**【基金项目】**国家自然科学基金(61671197)

**【作者简介】**裴文清,硕士研究生,研究方向:模式识别,E-mail: wenqing1002@126.com

**【通信作者】**孙曜,博士,高级实验师,研究方向:生物医学信号处理、模式识别,E-mail: sunyao@hdu.edu.cn

映出神经元交互作用区域之间的有向信息交互,即一个神经元系统对另一个系统的影响,因此因效网络的研究对于认识大脑有着重要的意义<sup>[10]</sup>。常见的因效网络的构建都是基于格兰杰因果关系<sup>[11-12]</sup>。如果联合两个变量 $X$ 和 $Y$ 的过去信息对变量 $Y$ 进行预测比使用 $Y$ 过去的信息进行预测更加精准,那么 $X$ 对 $Y$ 具有格兰杰因果关系<sup>[13-14]</sup>。格兰杰因果关系只能反映两个变量之间的相互作用。然而相互作用不一定只发生在两个变量之间,也可能发生在群体和变量的集群中,针对大脑的因效网络就是这样一个集群,因此运动想象因效网络因果关系的度量不能只简单地使用格兰杰因果关系。本研究通过引入多变量格兰杰因果关系(Multivariable Granger Causality, MVGC)的方法来构建运动想象的因效网络。MVGC是基于格兰杰因果关系的概念,然后推广到相互关联的 $X$ 、 $Y$ 集合和条件多变量情况下 $Z$ 的相互作用,它反映的是在一个集群中多个变量之间的因果关系<sup>[15]</sup>。为了说明利用MVGC所构建的运动想象因效网络能更有效地反映运动想象神经活动状态,本研究最后将基于MVGC构建的因效网络矩阵和基于格兰杰因果关系构建的因效网络矩阵使用余青山等<sup>[16]</sup>提出的奇异值分解方法对其进行分解和特征提取,然后将特征输入到支持向量机中进行分类。采用BCI Competition IV dataset 1数据进行实验验证<sup>[17]</sup>。结果表明,利用MVGC构建运动想象因效网络,经特征提取后,同一个人两种不同运动想象任务的脑电信号可以被区分开来,并且相比于基于格兰杰的有较好的识别效果,验证了基于MVGC构建运动想象因效网络能更准确地反映运动想象神经活动特征状态。

## 1 运动想象因效网络的构建

### 1.1 实验数据

采用BCI Competition IV dataset 1数据进行实验验证<sup>[17]</sup>。本研究分别提取大脑的主运动区(M1)、体感觉区(S1)和辅助运动区(SMA)的脑电信号,分别是F1、F3、F2、F4、FC3、FC4、CP1、CP3、C1、C3、CP2、CP4、C2、C4。BCI Competition IV dataset 1实验范式为7名健康受试者(记为A~F),根据面前电脑的提示做运动想象,其中有2名受试者进行左手和脚的运动想象,另外5名受试者进行左手和右手的运动想象。整个实验中,对每一名受试者采集了59导脑电信号,采用频率是100 Hz,带通滤波范围是0.05~200.00 Hz,实验最终得到了7组标定数据。

受试者每次实验持续8 s,实验过程为首先给受试者2 s的安静时间,然后根据电脑屏幕的提示进行4 s的运动想象,紧接着2 s的停止运动想象。实验过程如图1所示。




图1 单次实验时序图

Fig.1 Single experiment timing diagram

当电脑屏幕中心显示+号时,是受试者安静2 s的时间。2 s结束后,屏幕显示或左或右或下的箭头,这是提示受试者左手、右手、脚的运动想象。最后屏幕黑屏,指示受试者停止运动想象,准备进行下一次实验。每个受试者进行200次的实验。

### 1.2 MVGC

首先定义 $\oplus$ 表示向量的垂直级联, $X^{\sim}$ 表示 $X$ 的滞后, $Y^{\sim}$ 表示 $Y$ 的滞后, $Z^{\sim}$ 表示 $Z$ 的滞后, $\sum(X)$ 表示 $X$ 的 $n \times n$ 的协方差矩阵, $\sum(X, Y)$ 表示 $X$ 、 $Y$ 的协方差矩阵, $\text{tr}[]$ 表示矩阵的迹。

让我们考虑一个随机向量 $X$ (被预测者)在另一个随机向量 $Y$ 上的多元线性回归:

$$X = A \cdot Y + \varepsilon \quad (1)$$

其中, $A$ 是 $n \times m$ 包含残差。该模型的系数通过残差和回归预测因子 $Y$ 之间施加零相关来唯一确定。由Yule-Walkers公式,可以得到:

$$A = \sum(X, Y) \sum(Y)^{-1} \quad (2)$$

残差的协方差矩阵:

$$\begin{aligned} \sum(\varepsilon) &= \sum(X|Y) \\ &= \sum(X) - \sum(X, Y) \sum(Y)^{-1} \sum(X, Y)^T \end{aligned} \quad (3)$$

假设现在我们有3个联合分布的平稳多变量随机过程 $X_t$ 、 $Y_t$ 、 $Z_t$ 。为了测量给定 $Z$ 从 $Y$ 到 $X$ 的格兰杰因果关系,我们要比较以下两个多变量自回归MVAR模型:

$$X_t = A(X_{t-1}^p \oplus Z_{t-1}^r) + \varepsilon_t \quad (4)$$

$$X_t = A'(X_{t-1}^p \oplus Y_{t-1}^q \oplus Z_{t-1}^r) + \varepsilon_t' \quad (5)$$

因此,预测变量 $X$ 首先在先前的自身延迟上加上条件变量 $Z$ 的滞后,然后再加上预测变量 $Y$ 的滞后。根据标准的格兰杰因果关系度量,即由回归残

差方差比率给出。那么根据我们的公式可以得出：

$$F_{Y \rightarrow X|Z} \equiv \ln \left( \frac{\text{var}(\varepsilon_t)}{\text{var}(\varepsilon_t')} \right) = \ln \left( \frac{\sum \varepsilon_t}{\sum \varepsilon_t'} \right) \quad (6)$$

$$= \ln \left( \frac{\sum (X|X^- \oplus Z^-)}{\sum (X|X^- \oplus Y^- \oplus Z^-)} \right)$$

使用格兰杰因果关系的标准度量仅限于对预测变量和预测变量  $Y$  和  $X$  进行定义,因为第一个回归残差方差总是大于或等于第二个回归残差方差,所以上式总是大于等于0。我们现在考虑预测变量不在被约束为单变量情况下,即多变量格兰杰因果关系,对于多变量的预测情况,格兰杰因果关系还没有一个标准的定义,一种可能性是简单地使用多变量的均方误差,即多变量残差的总方差或预期多元残差的平方长度。因此我们可以得出：

$$F_{Y \rightarrow X|Z}^w = \ln \left\{ \frac{\text{tr}[\sum (X|X^- \oplus Z^-)]}{\text{tr}[\sum (X|X^- \oplus Y^- \oplus Z^-)]} \right\} \quad (7)$$

上式为MVGC。

### 1.3 因效网络构建步骤

首先确定网络的节点,对于多通道脑电信号,通常是把每个脑电导联对应的电极覆盖的区域定义为一个节点<sup>[18]</sup>。本研究分别将F1、F3、F2、F4、FC3、FC4、CP1、CP3、C1、C3、CP2、CP4、C2、C4作为节点。然后利用MVGC量化节点之间的关系,最后经过显著性检验,确定各节点之间的因果流,即确定节点之间的边的大小与方向。

## 2 运动想象脑电特征分类

对提取的运动想象脑电信号进行MVGC分析,从而生成一个二维的因效网络矩阵,此矩阵能很好地反映出各个导联运动想象脑电信号之间的因果关系。我们可以通过矩阵谱分析来提取我们需要的特征<sup>[19]</sup>。采用参考文献[17]所提出的方法对因效网络矩阵进行奇异值分解并进行特征提取与分类。

根据奇异值分解的定理,已知  $A$  是  $N \times N$  的矩阵,不管其行列是否相关,必定存在  $N$  阶正定矩阵  $U = (u_1, u_2, \dots, u_n)$  和  $V = (v_1, v_2, \dots, v_n)$  使得：

$$A = UDV^T \quad (8)$$

其中,对角矩阵  $D = \text{diag}\{\delta_1, \delta_2, \dots, \delta_n\}$ ,  $\delta_i (i = 1, 2, \dots, N)$  是矩阵的奇异值。根据文献[17]所提出的方法,将全部非零奇异值组成一个特征向量  $x = (\delta_1, \delta_2, \dots, \delta_r)$ ,由特征向量定义3个特征参数,即最大奇异值( $x_1$ )、特征向量的方差( $x_2$ )、特征向量的能量( $x_3$ )。将这3个特征

参数作为运动想象脑电信号的特征,对不同运动想象任务的类别进行识别。其中：

$$x_1 = \max(x) = \max(\delta_1, \delta_2, \dots, \delta_r) \quad (9)$$

$$\bar{x} = \frac{1}{r} \sum_{i=1}^r \delta_i \quad (10)$$

$$x_2 = \frac{1}{r} \sum_{i=1}^r (\delta_i - \bar{x})^2 \quad (11)$$

$$x_3 = \frac{1}{r} \sum_{i=1}^r \delta_i^2 \quad (12)$$

因为支持向量机能较好地解决小样本、非线性、高维数和局部极小点等实际问题<sup>[20]</sup>,所以本研究采用支持多类分类的LIBSVM工具箱对提取的运动想象脑电特征进行分类。按照80/20的拆分比率将数据拆分为训练集和测试集,采用5倍交叉验证方法寻找最优参数构建最佳分类模型,然后将测试集输入到最佳分类模型中进行预测,重复上述分类过程20次。

## 3 实验结果与分析

因为BCI Competition IV dataset 1数据中C、D、E是人工合成的数据,因此本研究随机抽取受试者A、B、F、G各两个不同运动想象的脑电信号,按照上述方法构建运动想象的因效网络,然后对因效网络进行特征提取,并对特征进行统一的缩放,得到4位受试者A、B、F、G的3个特征(图2)。其中,“o”表示的是左手运动想象的特征值,“+”表示的是脚的运动想象的特征值,“\*”表示的是右手运动想象的特征值。由图2可知,通过提取基于MVGC构建的运动想象因效网络的特征可以区分一个人两种不同运动想象任务的脑电信号。然后将这些特征送入支持向量机中,得到的分类结果如图3所示。

由图3可知,受试者A、F、G的分类平均准确率都可以达到90%以上,受试者B的分类平均准确率也在88%以上,得到了比较好的分类结果。由此我们可以得出结论,通过MVGC构建运动想象因效网络能反映运动想象神经活动状态。比较基于格兰杰因果关系构建的因效网络矩阵和基于MVGC构建的因效网络矩阵进行分类的准确率,结果如表1所示。

由表1可知,基于MVGC的运动想象脑电特征提取分类准确率相比于基于格兰杰因果关系的分类准确率有所提高,这说明基于MVGC所构建的运动想象因效网络相比于基于格兰杰因果关系构建的运动想象因效网络能更有效地反映运动想象神经活动状态。

## 4 结论

本研究引入MVGC来构建运动想象的因效网



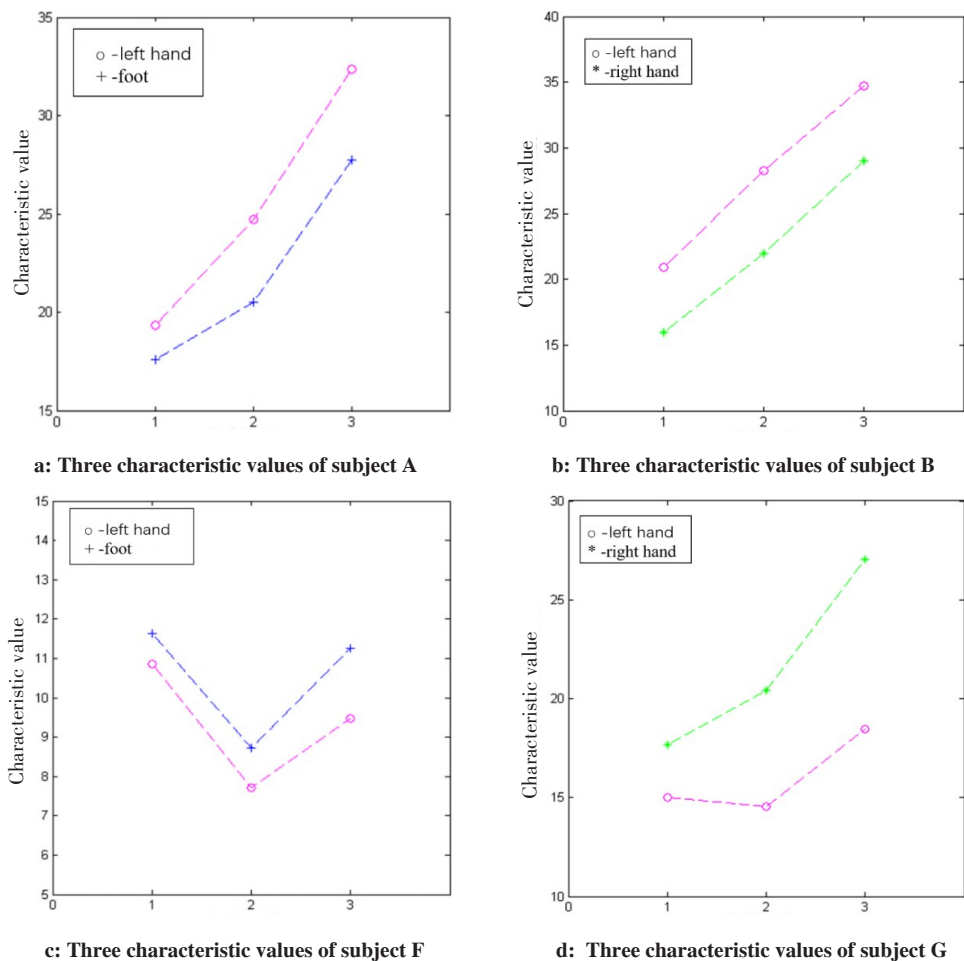


图2 不同运动想象任务的特征值

Fig.2 Characteristic values of different motion imaging tasks




图3 四位受试者分类结果

Fig.3 Classification results in 4 subjects

络,并使用该网络提取不同运动想象的脑电特征进行分类以验证其反映运动想象神经活动的状态的有效性。实验结果表明,同一受试者两种不同运动想象任务的脑电信号可以被区分开来,且用支持向量机对其分类时,受试者A、B、F、G的正确率分别达到90.4%、88.8%、91.1%、90.3%,相比基于传统的格兰杰

表1 分类结果对比(%)

Tab.1 Comparison of classification results (%)

Subject	Granger causality	Multivariable Granger causality
A	88.5	90.4
B	89.3	88.8
F	90.2	91.1
G	89.7	90.3

有较好的准确率。可以使用MVGC构建运动想象因效网络。此外,与传统格兰杰因果关系相比,基于MVGC构建因效网络能更准确地反映运动想象神经活动特征状态。

## 【参考文献】

- [1] LI H J, WANG H, CHEN L. Measuring robustness of community structure in complex networks[J]. EPL-Europhys Lett, 2014, 108(6): 68009.
- [2] JOHNSON-FREY S H. Stimulation through simulation? Motor imagery and functional reorganization in hemiplegic stroke patients [J]. Brain Cogn, 2004, 55(2): 328-331.

- [3] ANG K K, GUAN C, CHUA K S, et al. A large clinical study on the ability of stroke patients to use an EEG-based motor imagery brain-computer interface[J]. Clin EEG Neurosci, 2011, 42(4): 253.
- [4] ZHANG Y D, WANG S H, PHILLIPS P, et al. Three-dimensional eigenbrain for the detection of subjects and brain regions related with Alzheimer's disease[J]. J Alzheimers Dis, 2016, 50(4): 1163-1179.
- [5] JIAO Z Q, ZOU L, CAO Y, et al. Effective connectivity analysis of fMRI data based on network motifs[J]. J Supercomput, 2014, 67(3): 806-819.
- [6] MIŠIĆ B, SPORNS O. From regions to connections and networks: new bridges between brain and behavior[J]. Curr Opin Neurobiol, 2016, 40: 1-7.
- [7] ZHANG Y, YANG J, WANG S, et al. Pathological brain detection in MRI scanning via Hu moment invariants and machine learning[J]. J Exp Theor Artif Intel, 2016, 29(2): 299-312.
- [8] JIAO Z Q, WANG H, MA K, et al. Effective connectivity in the default network using Granger causal analysis[J]. J Med Imag Health Inf, 2017, 7(2): 407-415.
- [9] JIAO Z Q, WANG H, MA K, et al. Directed connectivity of brain default networks in resting state using GCA and motif[J]. Front Biosci, 2017, 22 (10) :1634.
- [10] BULLMORE E, SPORNS O. Complex brain networks: graph theoretical analysis of structural and functional systems[J]. Nat Rev Neurosci, 2009, 10(3): 186-198.
- [11] BROVELLI A, DING M, LEDBERG A, et al. Beta oscillations in a large-scale sensorimotor cortical network: directional influences revealed by Granger causality[J]. Proc Natl Acad Sci U S A, 2004, 101 (26): 9849-9854.
- [12] GRANGER C W. Investigating causal relations by econometric models and cross-spectral methods[M]. Cambridge: Harvard University Press, 2001.
- [13] 袁勤, 蒋涛. 基于格兰杰因果方法的注意脑电网络分析[J]. 生物医学工程学杂志, 2016, 33(1): 56-60.
- [14] YUAN Q, JIANG T. Brain efficient connectivity analysis of attention based on the Granger causality method[J]. Journal of Biomedical Engineering, 2016, 33(1): 56-60.
- [15] KAMIŃSKI M, DING M, TRUCCOLO W A, et al. Evaluating causal relations in neural systems: Granger causality, directed transfer function and statistical assessment of significance[J]. Biol Cybern, 2001, 85(2): 145-157.
- [16] BARRETT A B, BARNETT L, SETH A K. Multivariate Granger causality and generalized variance[J]. Phys Rev E, 2010, 81(4): 041907.
- [17] 余青山, 昌凤玲, 范影乐, 等. 基于邻接矩阵分解的脑电特征提取与分类方法[J]. 传感技术学报, 2012, 25(9): 1204-1209.
- [18] SHE Q S, CHANG F L, FAN Y L, et al. Feature extraction and classification of EEG based on adjacent matrix decomposition[J]. Chinese Journal of Sensors and Actuators, 2012, 25(9): 1204-1209.
- [19] BLANKERTZ B, DORNHEGE G, KRAULEDAT M, et al. The non-invasive Berlin brain-computer interface: fast acquisition of effective performance in untrained subjects[J]. Neuroimage, 2007, 37(2): 539-550.
- [20] 陈玲. 基于脑疲劳的脑网络研究与分析[D]. 天津: 河北工业大学, 2014.
- [21] CHEN L. Research on brain networks based on mental fatigue[D]. Tianjin: Hebei University of Technology, 2014.
- [22] KONG W, GUO X, ZHAO X, et al. Spectral analysis of brain function network for the classification of motor imagery tasks[C]//International Conference on Biomedical Engineering and Informatics, 2011: 850-853.
- [23] BURGESS C C. A tutorial on support vector machines for pattern recognition[J]. Data Min Knowl Discov, 1998, 2(2): 121-167.

(编辑:谭斯允)