

## 基于条件互信息的动态贝叶斯法探明生物神经元网络连接结构

任婧雯<sup>1,2</sup>,董朝轶<sup>1,2</sup>,朱美佳<sup>1,2</sup>,白鹏辉<sup>1,2</sup>,赵肖懿<sup>1,2</sup>,马爽<sup>1,2</sup>,贾婷婷<sup>1,2</sup>

1. 内蒙古工业大学电力学院, 内蒙古 呼和浩特 010080; 2. 内蒙古机电控制重点实验室, 内蒙古 呼和浩特 010051

**【摘要】**准确辨识生物神经网络(BNN)连接结构对于进一步理解其网络行为与功能,构建具有生物真实性、结构更加优化的人工智能网络具有重要意义。本文提出基于条件互信息的动态贝叶斯网络法,以探明BNN的连接结构。首先,利用积分点火原理构造脉冲神经网络,经过网络仿真后得到多通道动态响应数据;然后,针对该数据集,计算神经元节点间的条件互信息,通过与给定阈值 $\delta$ 进行比较,判断节点间的连接情况;最后,辨识出动态贝叶斯网络的连接结构。实验结果表明基于条件互信息的动态贝叶斯网络法对于BNN具有较高的辨识正确率。

**【关键词】**生物神经网络;贝叶斯网络;条件互信息;积分点火模型

**【中图分类号】**R318;Q612

**【文献标志码】**A

**【文章编号】**1005-202X(2021)06-0773-07

## Identification of biological neuron network connection structures by dynamic Bayesian network method based on conditional mutual information

REN Jingwen<sup>1,2</sup>, DONG Chaoyi<sup>1,2</sup>, ZHU Meijia<sup>1,2</sup>, BAI Penghui<sup>1,2</sup>, ZHAO Xiaoyi<sup>1,2</sup>, MA Shuang<sup>1,2</sup>, JIA Tingting<sup>1,2</sup>

1. School of Electric Power, Inner Mongolia University of Technology, Hohhot 010080, China; 2. Inner Mongolia Key Laboratory of Electromechanical Control, Hohhot 010051, China

**Abstract:** The accurate identification of biological neural network (BNN) connection structures helps to further understand their network behaviors and functions, and contributes to constructing biologically realistic artificial intelligent networks with more optimized structures. Dynamic Bayesian network method based on conditional mutual information is proposed for accurately identifying the connection structures of BNN. Spike neural network is firstly constructed by integrate-and-fire principle, and the multi-channel dynamic response data are obtained after network simulation. Based on the obtained data set, the conditional mutual information between neuron nodes are calculated, and the connection between nodes is assessed by comparing the calculated results with the given threshold  $\delta$ . Finally, dynamic Bayesian network connection structures are identified. The experimental results reveal that dynamic Bayesian network method based on conditional mutual information has a high identification accuracy for BNN.

**Keywords:** biological neural network; Bayesian network; conditional mutual information; integrate-and-fire model

### 前言

大脑的连接结构错综复杂,是迄今为止人类已知最为复杂的系统之一,为了进一步探明大脑连接结构并深入研究与大脑相关的生理与病理功能,多种探究脑网络的技术手段,如脑电图(Electroencephalograph, EEG)<sup>[1]</sup>,

脑磁图(Magnetoencephalograph, MEG)<sup>[2-3]</sup>,功能磁共振成像(functional Magnetic Resonance Imaging, fMRI)<sup>[4]</sup>,双光子显微镜(Two-Photon Microscope, TPM)<sup>[5-6]</sup>和多电极阵列(Multielectrode Array, MEA)<sup>[7]</sup>等得到了快速发展。目前,通过以上技术手段,可获得高通量具有较高时空分辨率的生物神经网络(Biological Neural Network, BNN)多通道时间序列数据。计算神经生物学者们则利用这些脑网络响应数据,发展出多种BNN功能性连接结构反向辨识算法,试图建立大脑的功能性图谱。目前,针对BNN的连接结构辨识方法有动态贝叶斯网络算法<sup>[8]</sup>、隐马尔可夫模型算法<sup>[9]</sup>、线性格兰特因果性(Linear Grant Causality, LGC)算法<sup>[10]</sup>和互信息算法<sup>[11]</sup>等。虽然这些传统方法对辨识生物调控网络的功能性连接结构均具有一

**【收稿日期】**2021-02-21

**【基金项目】**国家自然科学基金(61863029, 61364018);内蒙古自然科学基金杰出青年培育基金(2016JQ07);内蒙古自治区高等学校“青年科技英才计划”(NJYT-15-A05)

**【作者简介】**任婧雯,硕士研究生,研究方向:复杂生物网络建模、仿真与网络结构辨识,E-mail: rjw\_94@163.com

**【通信作者】**董朝轶,博士,教授,研究方向:复杂生物网络建模、仿真与网络结构辨识等,E-mail: dongchaoyi@hotmail.com

定的有效性,但对于复杂的、具有神经元点火的本质非线性和突触连接塑性的BNN而言,大部分方法难以获得较高的辨识精度,且计算运行时间较长。而互信息算法和动态贝叶斯网络算法相结合探明BNN连接结构克服了以上算法的弊端,对于以后探究大脑的功能性连接结构和构建人工智能网络具有重要意义。

本研究采用基于条件互信息的动态贝叶斯网络法(Dynamic Bayesian Network Method Based on Conditional Mutual Information, DBNM-BCMI)以辨识人工构造的BNN连接结构。主要思想为:(1)利用积分点火(Integrate-and-Fire, IF)原理构建具有一定生物真实性的脉冲神经网络(Spike Neural Network, SNN)。因为其能够以较高精度模拟BNN的IF、传输延时等机制,所以SNN被称为“第三代人工神经网络”,已被广泛应用于计算神经生物学研究<sup>[10]</sup>。通过调整建模参数使其接近真实的BNN,在MATLAB环境下运行网络仿真程序获得SNN多通道脉冲响应序列数据。(2)利用提出的DBNM-BCMI算法探明SNN的功能性连接结构。(3)对比互信息算法、LGC算法和DBNM-BCMI算法的辨识效果,结果表明DBNM-BCMI算法优于互信息算法和LGC算法,其对4、10、20、50、100节点SNN连接结构的辨识准确率均高于互信息算法和LGC算法,且运行时间较短,验证了所提出算法的有效性。

## 1 方法

### 1.1 互信息算法

假设两个随机变量 $X$ 、 $Y$ 的联合概率密度函数表示为 $p(x, y)$ ,变量的边缘概率密度函数为 $p(x)$ 、 $p(y)$ 。定义信息熵 $H$ ,表示变量的不确定度。

$$H(X) = - \sum_{x \in X} p(x) \log p(x) \quad (1)$$

$$H(Y) = - \sum_{y \in Y} p(y) \log p(y) \quad (2)$$

$$H(X, Y) = - \sum_{x \in X} \sum_{y \in Y} p(x, y) \log p(x, y) \quad (3)$$

$$H(X|Y) = - \sum_{x \in X} \sum_{y \in Y} p(x, y) \log p(x|y) \quad (4)$$

$$H(Y|X) = - \sum_{x \in X} \sum_{y \in Y} p(x, y) \log p(y|x) \quad (5)$$

其中, $H(X, Y)$ 称为 $X$ 、 $Y$ 的联合信息熵, $H(X|Y)$ 和 $H(Y|X)$ 被称为条件信息熵。联合信息熵与边缘信息熵和条件信息熵之间具有如下关系<sup>[12]</sup>:

$$H(X, Y) = H(X) + H(Y|X) = H(Y) + H(X|Y) \quad (6)$$

互信息 $I(X, Y)$ 用于量化任意两个随机变量 $X$ 、 $Y$ 间的相互作用关系,图1描绘了信息熵和互信息间的关系<sup>[13]</sup>。




图1 信息熵和互信息的关系

Fig.1 Relationship between information entropy and mutual information

由式(6)可得到互信息的计算公式,即式(7)、(8):

$$I(X, Y) = H(X) - H(X|Y) = H(Y) - H(Y|X) \quad (7)$$

$$I(X, Y) = \sum_{x \in X} \sum_{y \in Y} p(x, y) \log \frac{p(x, y)}{p(x)p(y)} \quad (8)$$

互信息算法通过计算BNN在放电活动中各网络节点(神经元)数据携带信息的相关性来辨识网络连接结构。即使神经元在放电活动中没有明显的同步性,仍可利用变量间作用的延时性,辨识出因果性的动态连接关系。因突触前神经元点火的时间一般发生在突触后神经元点火之前,基于互信息的因果性辨识法,可同时辨识出突触连接的作用方向。因此,式(8)可修正为:

$$I(X, Y) = \sum_{x \in X} \sum_{y \in Y} p(x(k - \tau), y(k)) \log \frac{p(x(k - \tau), y(k))}{p(x(k - \tau))p(y(k))} \quad (9)$$

表示在动态贝叶斯网络框架下( $k$ 为当前时刻, $\tau$ 为突触前神经元到突触后神经元动态作用的纯滞后,两者均为正数),节点 $X$ 指向节点 $Y$ 的因果性互信息。这里约定本研究所有涉及到的互信息计算均具有方向性的因果性互信息。

目前,基于互信息的网络功能性连接辨识算法的详细流程为:通过将两个神经元节点变量间的互信息值与给定的阈值 $\delta$ 进行比较。若该互信息值大于 $\delta$ ,说明两者之间具有相互依赖关系,用数字“1”表示,反之,如果互信息的值小于 $\delta$ ,说明两者间相互独立,用数字“0”表示<sup>[9]</sup>。这样就可以得到表示网络连接关系的关联矩阵,构造出神经网络的连接结构。由于该算法计算了突触前神经元数据和延时了突触传递纯滞后时间后的突触后神经元数据,所以该算法能够辨识网络连接的方向。但是该算法存在显著的不足:忽略了在复杂非线性BNN中,其余神经元节点对这两个神经元节点的影响和作用,即未能区分直接连接和间接连接。因此,在实际应用中,存在一定的局限性。

### 1.2 改进互信息算法

为解决BNN中第三方神经元节点对两个神经元节点间互信息计算值的影响。引入条件互信息的概念,对已有的互信息算法进行改进,提出DBNM-BCMI算法。该算法采用动态贝叶斯网络作为初始网络构架,利用互信息或条件互信息计算值对网络连接进行修剪,从而得到正确的网络连接图。在动态贝叶斯网络中,存在3种基本连接结构:依赖结构( $A \rightarrow B \rightarrow C$ )、非依赖结构( $A \leftarrow B \rightarrow C$ )、导出依赖结构( $A \rightarrow B \leftarrow C$ )。构建动态贝叶斯网络结构时,要利用互信息或条件互信息保留依赖结构,删除非依赖结构和导出依赖结构<sup>[14-16]</sup>。

具体算法描述如下:(1)对于一个含有 $N$ 个神经元节点SNN,通过网络仿真产生多通道动态响应数据 $D$ 。(2)计算两两神经元节点 $X, Y$ 在数据集 $D$ 条件下的因果互信息值,与给定的阈值 $\delta_1$ 进行比较。若 $I(X, Y|D) < \delta_1$ ,说明这两个神经元节点之间无边连接,关联矩阵中相应位置的元素置为“0”;如果 $I(X, Y|D) > \delta_1$ ,说明神经元节点之间有边连接,记录关联矩阵数字为“1”。逐次考察并计算所有两节点间的互信息值,得到关联矩阵 $T(X, Y)$ ,依据关联矩阵中的连接情况,可获得初始动态贝叶斯网络图 $O$ 。(3)在 $O$ 的基础上增加其它依赖结构的边。如果在 $O$ 中发现 $X, Y$ 之间不存在边,则用 $Z_x(X, Y)$ 表示在 $X$ 的邻域中, $X$ 和 $Y$ 的通路上的节点集合; $Z_y(X, Y)$ 表示在 $Y$ 的邻域中, $X$ 和 $Y$ 的通路上的节点集合。选择 $Z_x(X, Y)$ 和 $Z_y(X, Y)$ 中边数较少的一方,用 $Z(X, Y)$ 表示。通过与给定的阈值 $\delta_2$ 进行比较,如果 $I(X, Y|Z(X, Y)) > \delta_2$ ,则在 $O$ 中增加边 $X \rightarrow Y$ ,记录数字为“1”,反之不变,直到 $O$ 中所有符合条件的神经元节点检验过为止。将记录的数据存入新的关联矩阵 $T_1(X, Y)$ 中,并得到新的动态贝叶斯网络图 $O_1$ ,即得到增加依赖结构边后的贝叶斯网络图。(4)在 $O_1$ 的基础上剔除非依赖结构边。如果在 $O_1$ 中发现 $X, Y$ 之间存在边,则用 $Z1_x(X, Y)$ 表示在 $X$ 的邻域中, $X$ 和 $Y$ 的通路上的节点集合; $Z1_y(X, Y)$ 表示在 $Y$ 的邻域中, $X$ 和 $Y$ 的通路上的节点集合。选择 $Z1_x(X, Y)$ 和 $Z1_y(X, Y)$ 中边数较少的一方,用 $Z1(X, Y)$ 表示。通过与给定的阈值 $\delta_3$ 进行比较,如果 $I(X, Y|Z1(X, Y)) < \delta_3$ ,则在 $O_1$ 中剔除边 $X \rightarrow Y$ ,记录数字为“0”,反之不变,直到 $O1$ 中所有符合条件的神经元节点检验过为止。将记录的数据存入关联矩阵 $T_2(X, Y)$ ,并生成关联矩阵图 $O_2$ ,即得到剔除非依赖结构边后的动态贝叶斯网络图。(5)在 $O_2$ 的基础上剔除导出依赖结构的边。对于任意的神经元节点对 $X, Y$ ,如果 $I(X, Y) < \delta_4$ ,与 $X$ 和 $Y$ 可能形成导出依赖结构的结点可能为 $X_{v1}, \dots, X_{vt}$ ,需要对每一个可能的导出依赖结构进行碰撞

识别<sup>[14-16]</sup>,假设:

$$\frac{I(X, Y|X_{vh}, D)}{I(X, Y|D)} > (1 + \delta_4), 1 \leq h \leq t \quad (10)$$

如果 $X, Y$ 和 $X_{vh}$ 形成导出依赖结构,判断是否存在 $X \rightarrow X_{vh}$ 和 $Y \rightarrow X_{vh}$ ,如果存在,则剔除边 $X \rightarrow Y$ <sup>[12]</sup>,记录关联矩阵相应位置数字为“0”,反之不变,直到将 $O_2$ 中所有符合条件的神经元节点对全部检验过为止。将记录的数据存入新的关联矩阵 $T_3(X, Y)$ 并生成剔除导出依赖结构边后的动态贝叶斯网络图 $O_3$ 。

在每一步计算中,将需要保留边的最小互信息值和需要删除边的最大互信息值平均后,确定为阈值 $\delta_1, \delta_2, \delta_3, \delta_4$ 的取值,这样就可保证较高的网络结构辨识度。

### 1.3 动态贝叶斯网络算法

在DBNM-BCMI算法进行网络辨识的过程中,对网络初始结构的假设来源于动态贝叶斯网络结构形式。动态贝叶斯网络是静态贝叶斯网络的扩展,在一阶马尔科夫过程的假设下,所有网络变量的联合概率密度可表示为在父节点作用下子节点发生的条件概率密度乘积<sup>[17]</sup>,其中父子节点的数据间存在一个纯滞后的时间推移。

假设BNN有 $N$ 个神经元节点,节点变量集合为 $X = \{X_1, X_2, X_3, \dots, X_n\}$ ,用 $P_a(X_i)$ 表示节点 $X_i$ 的父结点集合。静态贝叶斯网络在变量集 $X$ 的联合概率密度表示为:

$$P_{BN}(X_1, \dots, X_n) = \prod_{i=1}^n P(X_i | P_a(X_i)) \quad (11)$$

在贝叶斯网络基础上加入时间推移,演变为动态贝叶斯网络,式(11)变为:

$$P_{DBN}(X_1, \dots, X_n) = \prod_{i=1}^n P(X_i(k - \tau) | P_a(X_i(k))) \quad (12)$$

图2和图3分别表示了具有相同网络结构的静态贝叶斯网络和动态贝叶斯网络的示意图。在动态贝叶斯网络中,每个变量之间在前后相邻时间片间的因果性概率依赖关系描述了SNN的网络拓扑结构,可采用定量化推理方法对动态贝叶斯网络进行动态建模、分析、预测和控制,这一网络结构推理方法已被广泛应用于语音识别、系统控制、演化分析中<sup>[18]</sup>。采用动态贝叶斯网络算法辨识BNN的结构不仅可以减少模型结构的复杂度,而且可以增加学习推理的效率。




图2 静态贝叶斯网络的先验图

Fig.2 Predictive diagram of static Bayesian network






图3 动态贝叶斯网络图

Fig.3 Dynamic Bayesian network diagram

## 2 IF 模型

为验证 DBNM-BCMI 算法的有效性,本研究采用 SNN 对 BNN 进行仿真模拟。常见的 SNN 建模和仿真模型有 IF 模型、Hodgkin-Huxley 模型、二维神经元模型等<sup>[19]</sup>。其中,Hodgkin-Huxley 模型和二维神经元模型基于多变量非线性微分方程组,求解过程复杂,不适用于大规模网络仿真;而 IF 模型在考虑所有突触前神经元脉冲电压对突触后神经元膜电位的累积效应的同时,仅涉及到一元积分,计算量小,所以更适合于大规模 BNN 仿真,相对于其他两种模型更适合本研究。

IF 模型由 Louis Lapicque 在 1907 年提出,主要用于 BNN 网络脉冲编码、记忆和网络动态研究。本研究利用 IF 模型构建 SNN,从而实现对大规模 BNN 进行仿真、模拟以及网络结构反向辨识算法验证<sup>[20]</sup>。

IF 模型将神经元网络视为开关网络,对突触后神经元  $i$  的动作电位进行建模,膜电位  $u(t)$  受钠、钾离子通道和氯离子通道影响,表示为:

$$\tau_m \frac{du}{dt} = -u(t) + RI(t - \Delta_{ax}), \tau_m = RC \quad (13)$$

其中,  $\tau_m$  为神经元膜电位动态时间常数,  $R$  和  $C$  分别为膜电阻和膜电容。输入电流  $I(t)$  由突触前神经元电活动产生,每一突触前尖峰都可产生一个突触后电流脉冲。若突触前神经元  $j$  在  $t_j^{(i)}$  时刻点火,神经脉冲信号经轴突传播后,突触后神经元  $i$  将获得输入电流  $\alpha(t - t_j^{(i)})$ 。此时,神经元  $i$  的总输入电流为所有输入电流之和:

$$I_i(t) = \sum_j w_{ij} \sum_f \alpha(t - t_j^{(i)}) + I_m(t) \quad (14)$$

多个突触前神经元  $j$  对突触后神经元  $i$  膜电位的贡献度不同,这种不同效应用权值  $w_{ij}$  表示。当膜电位高于阈值电压  $\theta$  时:

$$t^{(i)}: u(t^{(i)}) = \theta \text{ 且 } \left. \frac{du(t)}{dt} \right|_{t=t^{(i)}} > 0 \quad (15)$$

突触后神经元  $i$  被点火。点火后,膜电位迅速下降到静息电位水平:

$$\lim_{t \rightarrow t^{(i)}; t > t^{(i)}} u(t) = u_r \quad (16)$$

在点火后的绝对不应期内,即使膜电位再次高于  $\theta$ ,突触后神经元也不会被点火。IF 模型具有结构简单、计算量小等特点,相比二维或多维微分方程模型,更适用于大规模 BNN 仿真和建模。本研究采用 IF 模型对大规模 BNN 进行仿真,最终将所提出的 DBNM-BCMI 算法应用于网络动态响应数据,验证算法的正确性。

## 3 仿真与分析

### 3.1 10个神经元节点 SNN 结构辨识

以 10 个神经元节点 SNN 为例,分别验证互信息算法、LGC 算法和 DBNM-BCMI 算法对 SNN 结构的辨识精度。另外矩阵  $B$  和矩阵  $T_3$  分别表示真实 SNN 的关联矩阵和辨识出的网络关联矩阵,维数均为  $N \times N$ 。辨识精度被定义为:满足条件  $B(i, j)=1$  且  $T_3(i, j)=1$  或  $B(i, j)=0$  且  $T_3(i, j)=0$  ( $i, j=1, 2, 3, \dots, N$ ) 的所有有向支路数,除以  $N$  节点网络的全连接支路数  $N(N-1)$ 。根据 BNN 的连接特点,网络连接度通常在 10%~30% 之间<sup>[19]</sup>,本研究所构造 SNN 的随机连接比为 0.2,即每一神经元同网络中 20% 的其他神经元随机相连。假设每个神经元均受到当地噪声电流  $I_m(t)$  作用,  $I_m(t)$  均为高斯白噪声。仿真参数为:突触传递动态时间常数  $\tau_s = 3.5 \text{ ms}$ ,胞膜动态时间常数  $\tau_m = 8 \text{ ms}$ ,突触传递纯时延  $\tau = 50 \text{ ms}$ ,神经元的绝对不应期  $T_{\text{refractory}} = 2 \text{ ms}$ ,膜电位的点火阈值  $\theta = -40 \text{ mV}$ ,突触后神经元静息电位  $u_r = -65 \text{ mV}$ 。

经网络仿真后,以产生的 10 个神经元节点中前 5 个神经元节点的神经脉冲响应数据(经 10 ms 等周期采样,记录平均点火率)为例,如图 4 所示。所构造的随机连接的 10 个神经元节点 SNN 的关联矩阵如表 1 所示(突触连接的方向遵循“列作用于行”的原则),其基于 IF 模型构建的 SNN 结构如图 5 所示。

采用互信息算法、LGC 算法和 DBNM-BCMI 算法对该 SNN 结构进行辨识。互信息算法的阈值  $\delta$  为 1.5; LGC 算法的阈值为 0.2; DBNM-BCMI 算法的阈值分别取  $\delta_1=0.3$ 、 $\delta_2=0.1$ 、 $\delta_3=0.1$ 、 $\delta_4=0.3$ 。辨识后的结果如图 6 所示。其中,粗虚线表示真实网络结构中边未连,而辨识网络结构中边相连;虚点线表示真实网络结构中边相连,而辨识网络结构中边未连。

DBNM-BCMI 算法辨识的准确率为 0.98, LGC 算法辨识的准确率为 0.93, MI 算法辨识的准确率 0.92。由此可见, DBNM-BCMI 算法对该 10 个神经




图4 10个神经元节点中前5个神经元节点SNN仿真所产生的脉冲序列

Fig.4 Pulse sequences generated by spike neural network (SNN) simulation of the first 5 neuron nodes of 10 neuron nodes

Time表示脉冲时间; Neuron1~Neuron5表示神经元节点1~5

表1 在IF模型构建的SNN结构B矩阵

Tab.1 SNN structure B matrix constructed in integrate-and-fire (IF) model

神经元 节点	神经元节点									
	1	2	3	4	5	6	7	8	9	10
1	0	0	0	0	0	0	0	0	0	0
2	0	0	0	0	1	0	0	0	0	0
3	0	0	0	0	0	0	0	1	0	0
4	1	0	0	0	0	0	0	1	0	0
5	0	0	1	0	0	0	0	0	0	1
6	0	0	0	1	0	0	0	0	0	0
7	0	1	0	0	0	0	0	0	0	0
8	1	0	0	0	0	0	0	0	0	0
9	0	0	1	0	0	0	0	0	0	0
10	0	0	0	0	0	0	0	0	0	0




图5 基于IF模型构建的SNN结构

Fig.5 SNN structure constructed based on IF model

元节点 SNN 结构的辨识准确率明显高于另外两种方法。

3.2 不同规模的 SNN 结构辨识

分别对 4、10、20、50、100 节点的 SNN 结构进行辨识。对每一种规模网络,进行 10 轮,每轮 100 次测试。在每一次测试中,以 0.1、0.2、0.3 网络连接比各随机产生一个 SNN。最后,统计在每一网络规模和每一网络连接比下的平均辨识准确率,结果如表 2~4 所示。

结果表明:(1)无论对于传统方法还是改进方法,在同一连接比下,随着网络规模的增大,辨识准确率降低,且消耗计算时间显著增加;同时,在同一网络规模下,网络连接比越大,辨识准确率显著降低,且消耗计算时间增加。(2)虽然随着网络规模增加,辨识准确

率降低,但 50 个神经元节点网络和 100 个神经元节点网络相比,辨识准确率变化不大,提示对于大规模网络而言,辨识准确度趋于平台期,下降并不显著。(3) DBNM-BCMI 算法的辨识准确率显著高于互信息算法和 LGC 算法,且对于大规模网络,其辨识准确率均保持在 80% 以上。

4 结 论

辨识复杂 BNN 的功能性连接结构,从而探明各种生理、病理功能的网络结构特点。本研究对传统的互信息网络结构辨识法进行改进,提出 DBNM-BCMI 算法,对人工构造的具有一定生物真实性的

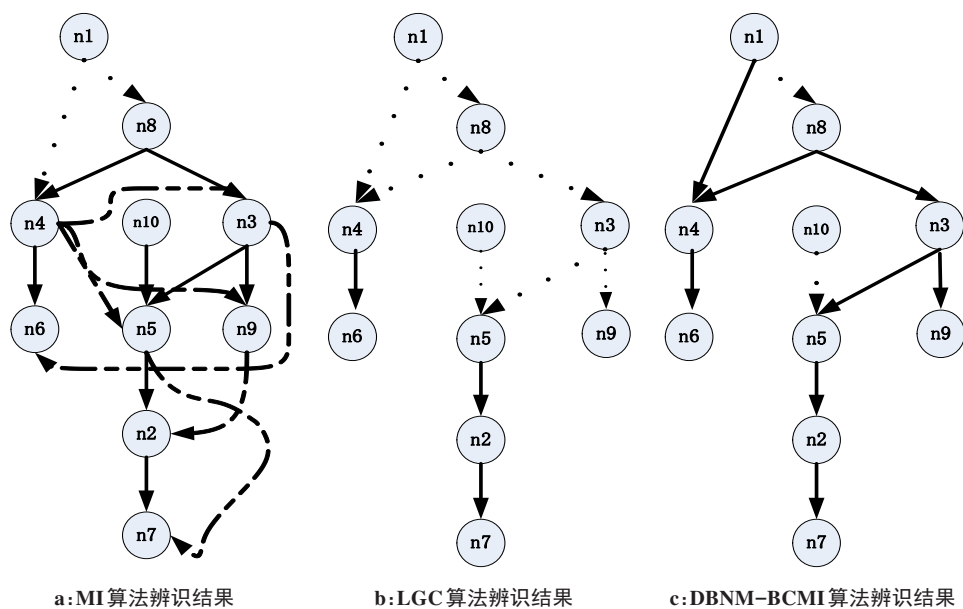


图6 3种不同方法辨识出的SNN结构

Fig.6 SNN structures identified by 3 different methods

表2 连接比为0.1时不同方法辨识准确率的对比

Tab.2 Comparison of identification accuracy among different methods when the connection ratio is 0.1

算法	神经元节点数				
	4	10	20	50	100
互信息	0.93	0.91	0.90	0.87	0.85
LGC	0.97	0.94	0.91	0.87	0.86
DBNM-BCMI	0.98	0.96	0.93	0.89	0.88

表3 连接比为0.2时不同方法辨识准确率的对比

Tab.3 Comparison of identification accuracy among different methods when the connection ratio is 0.2

算法	神经元节点数				
	4	10	20	50	100
互信息	0.87	0.81	0.76	0.74	0.71
LGC	0.94	0.84	0.81	0.79	0.77
DBNM-BCMI	0.96	0.89	0.87	0.83	0.82

表4 连接比为0.3时不同方法辨识准确率的对比

Tab.4 Comparison of identification accuracy among different methods when the connection ratio is 0.3

算法	神经元节点数				
	4	10	20	50	100
互信息	0.81	0.77	0.74	0.71	0.69
LGC	0.89	0.79	0.75	0.71	0.70
DBNM-BCMI	0.93	0.86	0.85	0.82	0.80

SNN结构进行辨识。DBNM-BCMI算法通过计算条件互信息,删除动态贝叶斯网络中非依赖结构和导出

依赖结构,最终辨识出动态贝叶斯网络的连接结构。结果表明相比较传统的网络结构辨识法,DBNM-BCMI算法对于BNN具有较高的辨识正确率,验证了该算法的有效性。

除此之外,本研究提出的算法源于条件互信息计算和动态贝叶斯网络结构,仅需要网络多通道响应的时间序列数据,不依赖于网络结构和模型阶数的先验知识,且能较好地适应生物神经元网络的本质非线性动态,是一种较有效的非线性概率方法。相比较传统的线性方法,尤其适用于BNN的网络结构辨识任务。

【参考文献】

[1] 段之宇. EEG信号构建的复杂脑网络同步性研究[D]. 太原: 太原理工大学, 2016.  
DUAN Z Y. Study on synchronization of complex brain network constructed by EEG signal [D]. Taiyuan: Taiyuan University of Technology, 2016.

[2] 聂英男. 脑磁图功能网络分析方法的研究及工具包的开发[D]. 北京: 北京工业大学, 2017.  
NIE Y N. Research on functional network analysis method of magnetoencephalography and development of tool kit [D]. Beijing: Beijing University of Technology, 2017.

[3] 杨丹. 认知的脑科学研究概述[J]. 大江周刊: 论坛, 2011, 11: 164-165.  
YANG D. Overview of cognitive brain science research [J]. Dajiang Weekly: Forum, 2011, 11: 164-165.

[4] 张梓青. 静息态大脑fMRI数据分析[D]. 武汉: 中国科学院研究生院(武汉物理与数学研究所), 2015.  
ZHANG Z Q. FMRI data analysis of resting brain [D]. Wuhan: Graduate School of Chinese Academy of Sciences (Wuhan Institute of Physics and Mathematics), 2015.

[5] 赵君, 王晋辉. 双光子显微镜在神经药理学活体研究中的应用[J]. 神经药理学, 2012, 2(1): 45-65.  
ZHAO J, WANG J H. Application of two-photon microscope in vivo study of neuropharmacology [J]. Acta Neuropharmacologica, 2012, 2(1): 45-65.

[6] 韦洁瑶. 基于fMRI与MEG数据融合的大脑语言处理的激活分析[J]. 中央民族大学学报(自然科学版), 2018, 27(1): 41-48.  
WEI J Y. Activation analysis of brain language processing based on

- fMRI and MEG data fusion[J]. Journal of Central University for Nationalities (Natural Science Edition), 2018, 27(1): 41-48.
- [7] 张壮壮. 基于MEA的PC12细胞网络和海马脑片在盐酸利多卡因作用下电刺激响应特性研究[D]. 南京: 东南大学, 2016.
- ZHANG Z Z. Study on the response characteristics of PC12 cell network and hippocampal slices to lidocaine hydrochloride electrical stimulation based on MEA[D]. Nanjing: Southeast University, 2016.
- [8] 陈晓艳, 董朝轶. 动态贝叶斯网络结构搜索法辨识生物神经网络连接[J]. 生命科学研究, 2017, 21(6): 527-533.
- CHEN X Y, DONG C Y. Identification of biological neural network connections by dynamic Bayesian network structure search method[J]. Life Science Research, 2017, 21(6): 527-533.
- [9] 朱晓峰. 贝叶斯网络及马尔科夫毯的学习算法研究[D]. 西安: 西安电子科技大学, 2014.
- ZHU X F. Research on learning algorithm of Bayesian network and Markov blanket[D]. Xi'an: Xi'an University of Electronic Science and Technology, 2014.
- [10] DOERFLER H, LYON D, NGELE T, et al. Granger causality in integrated GC-MS and LC-MS metabolomics data reveals the interface of primary and secondary metabolism[J]. Metabolomics, 2013, 9(3): 564-574.
- [11] 刘剑钊, 董朝轶, 冯丽斐, 等. 基于互信息的生物神经网络功能性连接辨识[J]. 传感器与微系统, 2016, 35(6): 59-61.
- LIU J Z, DONG C Y, FENG L F, et al. Functional connectivity identification of biological neural networks based on mutual information[J]. Sensors and Microsystems, 2016, 35 (6): 59-61.
- [12] 程龙, 刘洋. 脉冲神经网络: 模型、学习算法与应用[J]. 控制与决策, 2018, 33(5): 158-172.
- CHENG L, LIU Y. Impulsive neural network: model, learning algorithm and application [J]. Control and Decision, 2018, 33(5): 158-172.
- [13] 邓彩凤. 中文文本分类中互信息特征选择方法研究[D]. 重庆: 西南大学, 2011.
- DENG C F. Research on mutual information feature selection method in Chinese text classification[D]. Chongqing: Southwest University, 2011.
- [14] 王双成. 贝叶斯网络学习、推理与应用[M]. 上海: 立信会计出版社, 2010.
- WANG S C. Bayesian network learning, reasoning and application [M]. Shanghai: Lixin Accounting Press, 2010.
- [15] 王双成. 混合贝叶斯网络隐藏变量学习研究[J]. 计算机学报, 2005, 28(9): 1564-1564.
- WANG S C. Study on hidden variable learning in hybrid Bayesian networks[J]. Chinese Journal of Computers, 2005, 28(9): 1564-1564.
- [16] 王双成, 刘喜华, 唐海燕. 具有隐藏变量的贝叶斯网络结构学习[J]. 模式识别与人工智能, 2006, 19(5): 561-563.
- WANG S S, LIU X H, TANG H Y. Bayesian network learning with hidden variables[J]. PR and AI, 2006, 19(5): 561-563.
- [17] 张连文, 郭海鹏. 贝叶斯网络引论[M]. 北京: 科学出版社, 2006: 194-196.
- ZHANG L W, GUO H P. Introduction to Bayesian networks [M]. Beijing: Science Press, 2006: 194-196.
- [18] 唐孝威. 神经信息学与计算神经科学[M]. 杭州: 浙江科学技术出版社, 2012.
- TANG X W. Neuroinformatics and computational neuroscience [M]. Hangzhou: Zhejiang Science and Technology Press, 2012.
- [19] KOZAWA S, SAKUMURA Y, TORIYAMA M. Bayesian cell force estimation considering force directions[J]. Neural Process Lett, 2015, 41(2): 191-200.
- [20] GERSTENER W, KISTLE W M. Spiking neuron models [M]. The United States of America: Encyclopedia of Neuroscience, 2002, 241 (22): 277-280.

(编辑: 谭斯允)