

# 主文献研读论文汇报

## ✓ *A block model for node popularity in networks with community*

### *structure*

- 作者: Sengupta Srijan & Chen Yuguo
- 期刊: JRSSB
- 发表时间: 2018年

## ✓ *Estimation and clustering in popularity adjusted block model*

- 作者: Noroozi Majid, Ramchandra Rimal, and Marianna Pensky
- 期刊: JRSSB
- 发表时间: 2021年

- 论文1: Sengupta, S., & Chen, Y. (2018). A block model for node popularity in networks with community structure. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 80(2), 365-386.

## □ 主要内容

论文提出了流行度调整的块模型 (*popularity-adjusted block model, PABM*) , 更好地对节点在每个社区中的流行度进行建模, 在PABM下建立了作为社区检测的最大化目标的似然模块度, 并证明了似然模块度和节点流行度及模型参数估计的一致性。

PABM是随机块模型 (stochastic block model, SBM) 的一个拓展模型, 实际上就是设定节点*i*和节点*j*之间的连接概率为:

$i$ 到*j*所在社区的流行度参数  $\times$   $j$ 到*i*所在社区的流行度参数

并基于泊松分布进行统计推断。对该“似然模块度”的优化可以用变分方法, Kernighan-Lin型算法, 伪似然算法等方法进行, 本文使用的是Le等 (2016) <sup>[1]</sup>提出的EPs算法求解。

[1] Le, C. M., Levina, E. and Vershynin, R. (2016) Optimization via low-rank approximation for community detection in networks. *Ann. Statist.*, 44, 373–400.

## □ Review: SBM & DCBM

### ◆ 基于模型的社区检测/网络聚类

➤ 设无向网络邻接矩阵的元素服从贝努利分布,  $p_{ij}$ 为节点*i*和*j*的连接概率  $A_{ij} \sim \text{Ber}(p_{ij})$ ,

- SBM假设节点*i*和节点*j*的连接只与它们所在的社区 $c_i$ 和 $c_j$ 有关, 即

$$p_{ij} = P_{c_i c_j},$$

- DCBM则考虑了节点本身的度, 在SBM基础上增加了度参数, 节点*i*和节点*j*的连接不仅和它们所在的社区 $c_i$ 和 $c_j$ 有关, 还跟它们本身的度有关, 即

$$p_{ij} = \theta_i \omega_{c_i c_j} \theta_j,$$

其中 $\theta_i$ 和 $\theta_j$ 为度系数,  $\omega_{rs}$ 为社区*r*和*s*的连接系数。DCBM存在可识别性问题, 因此加上限制

(每个社区里的节点度系数之和为1) :  $\sum_{i \in \mathcal{N}_a} \theta_i = 1, \forall a = 1, \dots, K,$

## □ 节点在社区中的流行度

- 节点在社区中的流行度是和网络社区结构紧密相关的一个特征，节点 $i$ 在社区 $r$ 中的流行度定义为节点到该社区中所有节点的边数（的期望）。
- 注意到，对于同一社区，不同节点的流行度不同；同一节点在不同社区里的流行度也不同。可能节点 $i$ 在社区 $r$ 中的流行度比节点 $j$ 大，但在社区 $s$ 中相反。

## □ SBM和DCBM无法很好地刻画节点流行度

- SBM为了让同一社区的节点具有相同的行为，会对节点流行度产生限制；
- DCBM对每个节点引入了度参数，会一致地放大或降低节点的流行度，因此如果同一社区内的节点 $i$ 和 $j$ ，在一个社区里 $i$ 比 $j$ 流行度更高，那么在所有社区里 $i$ 的流行度都会比 $j$ 高。
- SBM和DCBM里计算节点流行度可以发现，SBM里同一社区的节点流行度是相同的，而DCBM中同一社区节点，流行度和度存在比例关系，度越大的节点流行度就越大。

**Table 1.** Illustrative nodes for political blogs, with popularities fitted by the DCBM in parentheses

| <i>Name</i>               | <i>Observed (fitted by DCBM)</i> |                           |                                |               |
|---------------------------|----------------------------------|---------------------------|--------------------------------|---------------|
|                           | <i>Community</i>                 | <i>Liberal popularity</i> | <i>Conservative popularity</i> | <i>Degree</i> |
| andrewsullivan.com        | Conservative                     | 58 (10)                   | 85 (133)                       | 143 (142)     |
| blogsforbush.com          | Conservative                     | 5 (21)                    | 296 (278)                      | 301 (299)     |
| democraticunderground.com | Liberal                          | 59 (85)                   | 34 (7)                         | 93 (93)       |
| liberaloasis.com          | Liberal                          | 169 (157)                 | 2 (13)                         | 171 (170)     |

- 行表示四个样本博客，列分别表示从属社区，分别在两个社区的流行度，节点度。括号外是观测值，括号内是DCBM拟合值。
- 第一行和第二行（属于同一社区）：2的节点度约为1的两倍，DCBM拟合得到的流行度，在两个社区里都是2约为1的两倍，但实际上在liberal里1流行度远大于2，在conservative里则相反。

**Table 2.** Illustrative nodes for British MPs†

| <i>Name</i>    | <i>Observed (fitted by DCBM)</i> |                                |                          | <i>Degree</i> |
|----------------|----------------------------------|--------------------------------|--------------------------|---------------|
|                | <i>Community</i>                 | <i>Conservative popularity</i> | <i>Labour popularity</i> |               |
| Zac Goldsmith  | Conservative                     | 46 (62)                        | 25 (8)                   | 71 (70)       |
| Matt Hancock   | Conservative                     | 68 (62)                        | 3 (8)                    | 71 (70)       |
| Seema Malhotra | Labour                           | 0 (4)                          | 88 (84)                  | 88 (88)       |
| Ian Austin     | Labour                           | 11 (3)                         | 76 (83)                  | 87 (87)       |

- 第一行和第二行（属于同一社区）：两个节点实际上在两个社区里的流行度相差较大，但由于二者的度相同，DCBM可以很好地拟合节点度，但得到两个节点在两个社区的流行度也是相同的。与实际情况不符。

†Identities were looked up by using tweeterid.com.

## □ 流行度调整的随机块模型 (Popularity-adjusted block model, PABM)

- 在PABM中, 节点*i*和*j*分别从属于社区*c<sub>i</sub>*和*c<sub>j</sub>*, 这两个节点的连接取决于“*i*在*c<sub>j</sub>*中的流行度”和“*j*在*c<sub>i</sub>*中的流行度”, 即

$$p_{ij} = \lambda_{ic_j} \lambda_{jc_i},$$

其中 $\lambda_{ir}$ 表示节点*i*在社区*r*中的流行度参数。

- PABM也需要给定一个限制条件以解决可识别性问题, 令*r*中所有节点到*s*的流行度参数之和与*s*中所有节点到*r*的流行度参数之和相同, 即:

$$\Lambda_{rs} = \Lambda_{sr} \quad \Lambda_{rs} := \sum_{j \in \mathcal{N}_r} \lambda_{js}.$$

- 设 $M_{ir}$ 为节点*i*到社区*r*所有社区的连接数, 在PABM下, 节点流行度计算为

$$\mu_{ir} = E[M_{ir}] = \sum_{j \in \mathcal{N}_r} p_{ij} = \lambda_{ir} \Lambda_{rc_i}$$

## □ PABM下的似然模块度

- 这里考虑似然函数时，不用伯努利分布而改用泊松分布作为节点连接的假设（即考虑多边情况）。DCBM提出的时候使用的也是泊松分布的假设，Zhao等（2012）说明了使用泊松分布在实际理论证明中带来了很大的便利，而产生的误差成本是很小的。

- 计算似然函数：

$$L = \left\{ \prod_{i < j} \frac{(\lambda_{ic_j} \lambda_{jc_i})^{A_{ij}}}{A_{ij}!} \exp(-\lambda_{ic_j} \lambda_{jc_i}) \right\} \prod_i \frac{(\frac{1}{2} \lambda_{ic_i}^2)^{A_{ii}/2}}{(A_{ii}/2)!} \exp\left(-\frac{1}{2} \lambda_{ic_i}^2\right).$$

- 对数似然：

$$\begin{aligned} l &= \sum_{i < j} A_{ij} \log(\lambda_{ic_j}) + \sum_{i < j} A_{ij} \log(\lambda_{jc_i}) + \sum_i A_{ii} \log(\lambda_{ic_i}) - \left( \sum_{i < j} \lambda_{ic_j} \lambda_{jc_i} + \frac{1}{2} \sum_i \lambda_{ic_i}^2 \right) \\ &= \sum_i \sum_r M_{ir} \log(\lambda_{ir}) - \frac{1}{2} \sum_i \sum_j \lambda_{ic_j} \lambda_{jc_i}, \end{aligned}$$

- 对数似然对 $\lambda_{ir}$ 求导=0，得到  $\hat{\lambda}_{ir} = \frac{M_{ir}}{\sqrt{O_{rc_i}}}$ .

这里 $M_{ir}$ 为节点 $i$ 到社区 $r$ 所有节点的连接数， $O_{rs}$ 表示社区 $r$ 和 $s$ 之间的连接数。

## □ PABM下的似然模块度

- 把 $\lambda_{ir}$ 带入对数似然函数中进行化简，最后得到只关于节点分配 $c$ 的轮廓似然函数，由于最后只需要求解使得该轮廓似然最大的节点分配，和之前模块度函数的本质是类似的，它也可以看作是某种模块度，称为“似然模块度”：

$$Q(c) = 2 \sum_i \sum_r M_{ir} \log\left(\frac{M_{ir}}{\sqrt{O_{rc_i}}}\right) = 2 \sum_i \sum_r M_{ir} \log(M_{ir}) - \sum_r \sum_s O_{rs} \log(O_{rs}).$$

- 在候选的节点分配策略中，选择使得似然模块度最大的节点分配，之后代入到参数估计的公式中，可得到流行度的参数估计结果。

## □ 一致性结果

- 引入稀疏性参数, 考虑PABM 模块度的scaled version

$$Q(e) = \frac{2}{n^2 \rho_n} \sum_i \sum_r M_{ir} \log\left(\frac{M_{ir}}{\sqrt{O_{eir}}}\right) = \frac{1}{n^2 \rho_n} \left\{ 2 \sum_i \sum_r M_{ir} \log(M_{ir}) - \sum_r \sum_s O_{rs} \log(O_{rs}) \right\}.$$

- 似然模块度的population version

$$\tilde{Q}(e) = \frac{2}{n^2 \rho_n} \sum_i \sum_r \mu_{ir}(e) \log\left\{ \frac{\mu_{ir}(e)}{\sqrt{o_{rei}(e)}} \right\},$$

- 假设条件:

*Assumption 1* (number of communities). The number of communities  $K$  is fixed and known. The true assignment  $c$  as well as all candidate assignments  $e$  have exactly  $K$  non-empty communities.

*Assumption 2* (sparsity parameter).  $\rho_n = \omega\{\log(n)/\sqrt{n}\}$ , i.e.  $n\rho_n^2/\log^2(n) \rightarrow \infty$  as  $n \rightarrow \infty$ .

*Assumption 3* (identifiability). For any two communities  $1 \leq a, b \leq K$ ,  $\Lambda_{ab} = \Lambda_{ba}$ , where  $\Lambda_{ab}$  is defined in equation (6).

*Assumption 4* (detectability). For any two distinct communities  $1 \leq a \neq b \leq K$  and any two nodes  $j_1 \in \mathcal{N}_a$ ,  $j_2 \in \mathcal{N}_b$ , the set  $\{p_{ij_1}/p_{ij_2}\}_{i=1}^n$  assumes at least  $K+1$  distinct values.

## □ 一致性结果

- 社区检测的一致性：对样本似然模块度求最大值对应的节点分配，就会和真实分配情况很接近。

*Theorem 1 (community detection).* Under assumptions 1–4,

$$\xi_n(\hat{c}) \xrightarrow{P} 0$$

where  $\hat{c} = \arg \max_e Q(e)$ ,  $\xi_n(e) = \min_{e' \in \Pi(e)} \frac{1}{n} \sum_{i=1}^n I(e'_i \neq c_i)$ ,

- 参数估计的一致性：在求解最大似然模块度得到节点分配  $\hat{c}$  的基础上，带入公式得到流行度参数和流行度的估计，以一定速度依概率收敛到真实参数值。

*Theorem 2 (parameter estimation).* Under assumptions 1–6,

$$\Delta_n(\hat{c}) \xrightarrow{P} 0$$

where  $\hat{c}$  is defined in equation (11) and  $\Delta_n$  is defined in equation (13).

where  $\Delta_n(\hat{c}) = \frac{1}{\sqrt{n}} \|\hat{\lambda}_{n \times K} - \lambda_{n \times K}\|_F$ .

## □ Simulation

- 对于该目标函数的求解文中提到可以使用变分方法, Kernighan-Lin型算法, 伪似然算法等。本文采用的Le等 (2016) [1]提出的EPs算法。
- EPs算法本质上是寻找候选分配集合, 缩小优化范围。以 $K=2$ 为例, 找到邻接矩阵的前2个主特征向量张成的空间, 将 $[-1, 1]^n$ 投影到空间里, 投影构成的凸包的极值点所对应的标签子集即为候选分配集合。

In this paper, we use the so-called **EPs algorithm**, which is a state of the art low dimensional optimization algorithm proposed by Le *et al.* (2016). Briefly, for  $K=2$  the algorithm computes the two leading eigenvectors of the adjacency matrix  $A$  and finds the candidate assignments that are associated with the EPs of the projection of the cube  $[-1, 1]^n$  onto the space that is spanned by the two leading eigenvectors of  $A$ . Let  $\mathcal{B}_{\text{can}}$  be the set of all such candidate assignments. The modularity function  $Q$  (or  $Q_{\text{DC}}$ ) is evaluated on all assignments  $b \in \mathcal{B}_{\text{can}}$ , and the best assignment is defined as the maximizer of  $Q$  (or  $Q_{\text{DC}}$ ) over  $\mathcal{B}_{\text{can}}$ , i.e.  $\hat{c} := \arg \max_{b \in \mathcal{B}_{\text{can}}} Q(b)$  for the PABM, and  $\hat{c} := \arg \max_{b \in \mathcal{B}_{\text{can}}} Q_{\text{DC}}(b)$  for the DCBM. Some advantages of EPs over the competing

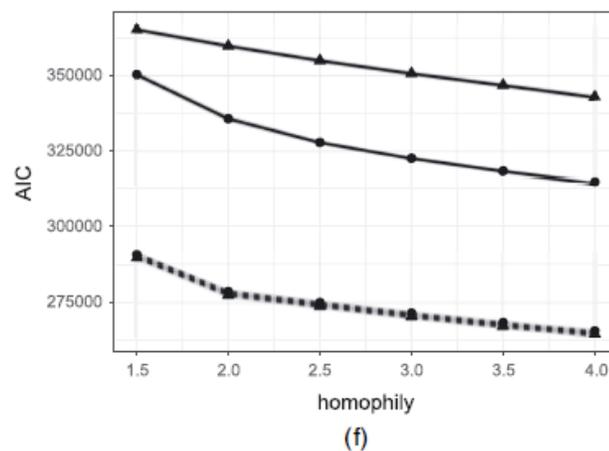
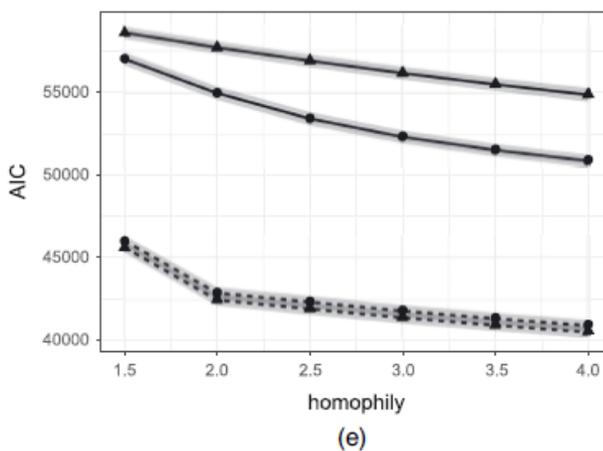
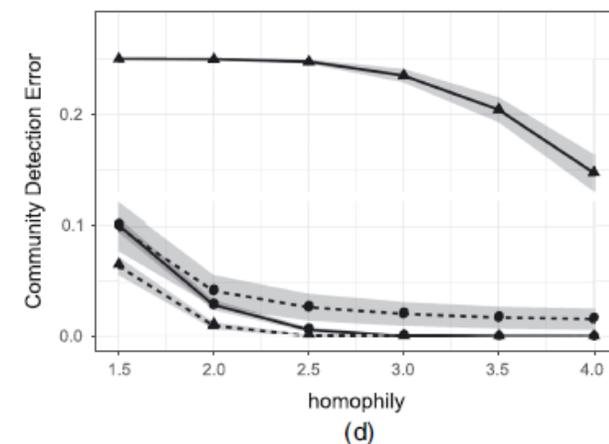
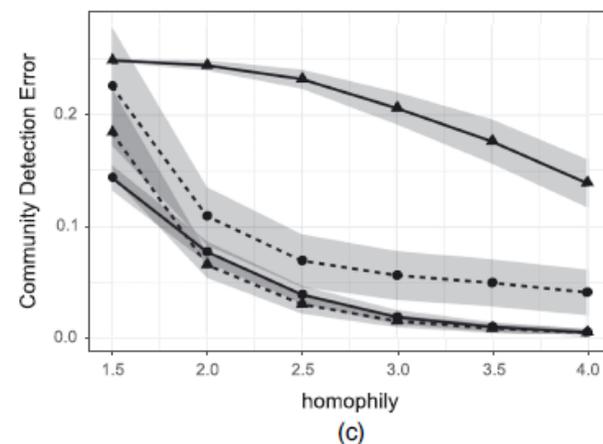
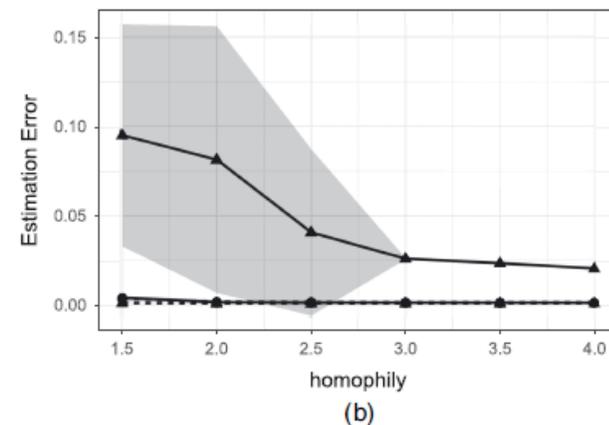
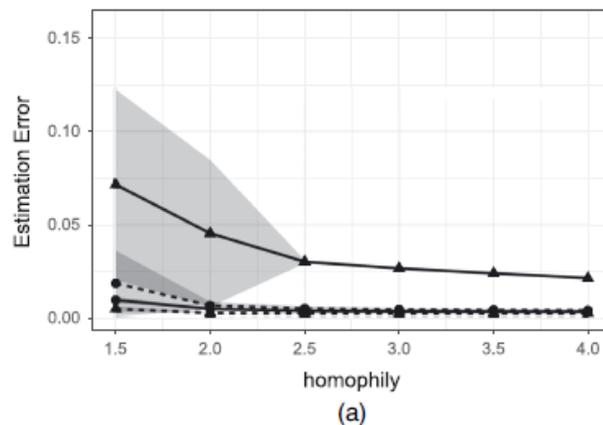
## □ Simulation

- 分别在PABM和DCBM的设定下生成网络，分别在PABM和DCBM的似然模块度下进行网络社区检测和节点流行度的估计。（二分类 $K = 2$ ）
  - PABM设定:  $\lambda_{ir} = \alpha\sqrt{h/(1+h)}$  when  $r = c_i$ , and  $\lambda_{ir} = \beta\sqrt{1/(1+h)}$  when  $r \neq c_i$ , 第一类节点 $\alpha = 0.8$  and  $\beta = 0.2$ , 第二类节点 $\alpha = 0.2$  and  $\beta = 0.8$ ,  $h$ 是homophily factor,  $h$ 越大则网络社区结构越强。
  - DCBM设定:  $P(\theta_i = 1.6) = P(\theta_i = 0.4) = 0.5$   $\omega = \frac{0.2}{h+1} \begin{pmatrix} h & 1 \\ 1 & h \end{pmatrix}$
  - 节点数:  $n = 400$  ( $n_1 = 200$  and  $n_2 = 200$ ),  $n = 1000$  ( $n_1 = 500$  and  $n_2 = 500$ )
- 比较: 节点流行度的估计表现; 社区检测准确性的表现
- 流行度估计误差  $\frac{1}{n\mathcal{E}} \sum_{i=1}^n \sum_{r=1}^K \{\hat{\mu}_{ir}(\hat{c}) - \mu_{ir}(c)\}^2$ ,

## Simulation

- ✓ 实线：由PABM生成网络；虚线：由DCBM生成网络
- ✓ 圆点：求解PABM似然模块度；三角点：求解DCBM似然模块度
- ✓ 左列： $n = 400$ ；右列： $n = 1000$
- ✓ 上：流行度估计误差；中：社区检测误差；下：AIC

- 对于由PABM生成的网络，基于DCBM模块度的表现很差，体现了DCBM无法很好刻画节点流行度。PABM模块度一致地比DCBM模块度好。
- 对于由DCBM生成的网络，PABM模块度增加了很多不必要的参数，会增加噪音影响效果，但流行度估计和AIC表现来看，PABM只是略差于DCBM，还是comparable的。



## □ Data analysis

- ✓ The political blogs network: 美国政治博客网络, 节点博客之间通过超链接相连
- ✓ The British MPs Twitter network: 英国议员推特网络, 节点议员之间通过转发推特相连
- ✓ The DBLP network: 计算机类的文献检索数据库系统, 节点作者通过参加了同一个会议相连

### ➤ goodness-of-fit measures

$$F_1 = \frac{1}{2E} \sum_{i=1}^n \sum_{r=1}^K \{\hat{\mu}_{ir}(\hat{c}) - M_{ir}(c)\}^2,$$

$$F_2 = \frac{1}{2E} \sum_{i=1}^n \sum_{r=1}^K \{\hat{\mu}_{ir}(c) - M_{ir}(c)\}^2,$$

Where  $F_1$  measures the overall goodness of fit originating from **community detection and model fit**, whereas  $F_2$  measures the community-corrected goodness of fit that originates **purely from the model fit**.

## □ Data analysis

**Table 3.** Community detection error rates<sup>†</sup>

| Network     | Nodes | Error from unregularized EPs (%) |            | Error from regularized EPs (%) |            |
|-------------|-------|----------------------------------|------------|--------------------------------|------------|
|             |       | PABM                             | DCBM       | PABM                           | DCBM       |
|             |       | Political blogs                  | 1222       | 4.99 (61)                      | 5.07 (62)  |
| British MPs | 329   | 0.30 (1)                         | 0.61 (2)   | 0.00 (0)                       | 0.61 (2)   |
| DBLP        | 2203  | 2.81 (62)                        | 4.77 (105) | 2.81 (62)                      | 5.17 (114) |

<sup>†</sup>The numbers of misclustered nodes are given in parentheses.

- PABM在社区检测误差和拟合优度上表现都要优于DCBM，尤其是拟合优度（考虑了节点流行度）

**Table 5.** Illustrative nodes for political blogs (regularized EPs)

| Name                      | Observed (fitted by PABM) |                    |                         |           |
|---------------------------|---------------------------|--------------------|-------------------------|-----------|
|                           | Community                 | Liberal Popularity | Conservative Popularity | Degree    |
| andrewsullivan.com        | Conservative              | 58 (59)            | 85 (84)                 | 143 (143) |
| blogsforbush.com          | Conservative              | 5 (6)              | 296 (292)               | 301 (298) |
| democraticunderground.com | Liberal                   | 59 (62)            | 34 (31)                 | 93 (93)   |
| liberaloasis.com          | Liberal                   | 169 (169)          | 2 (1)                   | 171 (170) |

- PABM不仅能很好地刻画度，还能准确地表现实际流行度。（与最开头DCBM拟合结果对比）

**Table 4.** Goodness-of-fit measures for node popularity

| Network     | $F_1$ from unregularized EPs |        | $F_1$ from regularized EPs |        | $F_2$ |        |
|-------------|------------------------------|--------|----------------------------|--------|-------|--------|
|             | PABM                         | DCBM   | PABM                       | DCBM   | PABM  | DCBM   |
|             | Political blogs              | 0.06   | 1.157                      | 0.057  | 1.155 | 0.002  |
| British MPs | 0.002                        | 0.282  | 0.002                      | 0.282  | 0.002 | 0.284  |
| DBLP        | 2.255                        | 52.430 | 2.255                      | 52.430 | 0.000 | 61.425 |

**Table 6.** Illustrative nodes for British MPs<sup>†</sup>

| Name           | Observed (fitted by PABM) |                         |                   |         |
|----------------|---------------------------|-------------------------|-------------------|---------|
|                | Community                 | Conservative popularity | Labour popularity | Degree  |
| Zac Goldsmith  | Conservative              | 46 (46)                 | 25 (25)           | 71 (71) |
| Matt Hancock   | Conservative              | 68 (67)                 | 3 (3)             | 71 (70) |
| Seema Malhotra | Labour                    | 0 (0)                   | 88 (88)           | 88 (88) |
| Ian Austin     | Labour                    | 11 (11)                 | 76 (76)           | 87 (87) |

<sup>†</sup>Identities of the nodes of this network were looked up by using tweeterid.com.

- 论文2: Noroozi, M., Rimal, R., & Pensky, M. (2021). Estimation and clustering in popularity adjusted block model. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*.

## □ 主要内容

本文从另一个角度对Sengupta和Chen(2018)<sup>[1]</sup>提出的PABM进行了拓展理解, 对PABM的公式进行了转换, 将概率矩阵写成了**分块矩阵**的形式, 每个块都是一个秩一矩阵; 利用**Bregman散度**提出了PABM社区检测的一般目标, 在F范数下可以写出已知社区数K的目标函数, 并且通过加入对K的惩罚项可以处理K未知的情况; 根据一定假设下该分块矩阵的性质, 可以将**稀疏子空间聚类 (SSC) 算法**运用到目标函数的求解中。

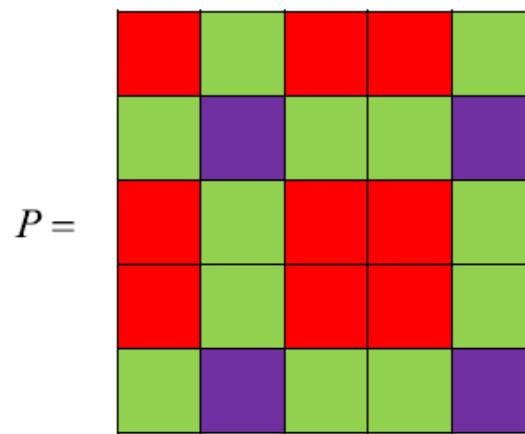
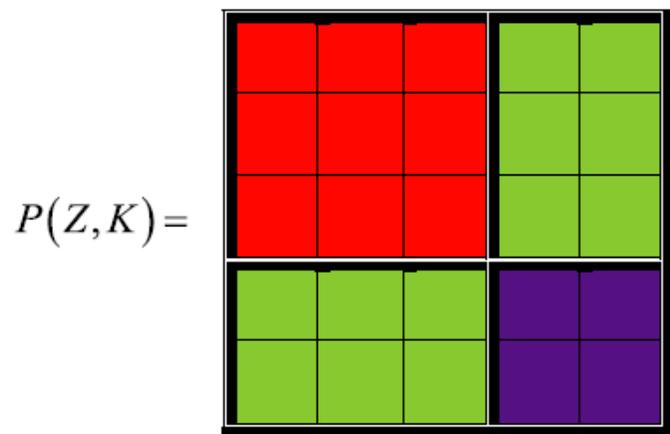
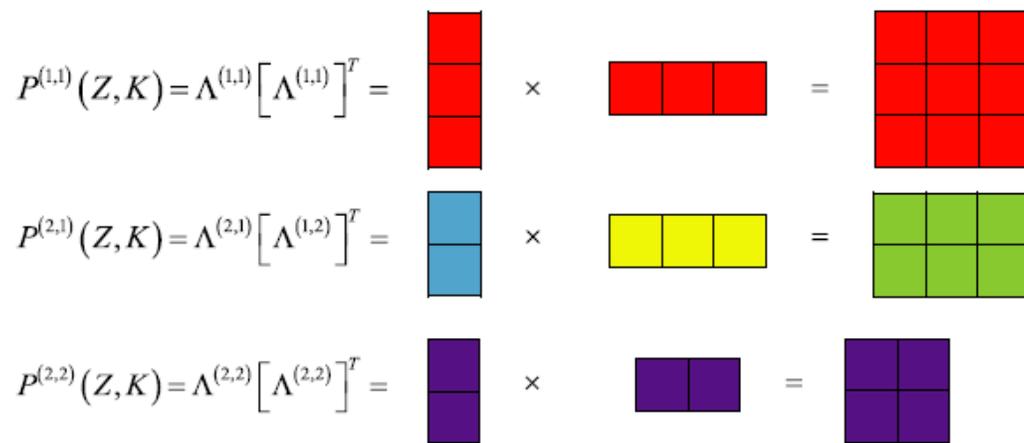
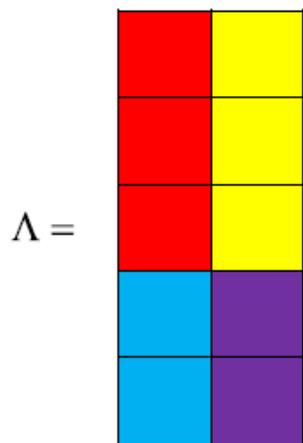
[1] Sengupta, S., & Chen, Y. (2018). A block model for node popularity in networks with community structure. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 80(2), 365-386.

## □ 从分块角度理解PABM

- 对于节点间连接概率 $P_{i,j} = V_{i,c_j} V_{j,c_i}$ 的PABM, 为了更好地理解这个模型, 在已知社区数 $K$ 和节点分配矩阵 $Z$  ( $Z \in R^{n \times K}$ ) 时, 考虑对概率矩阵 $P$ 按照节点分配形式进行重排, 得到 $P(Z, K)$ , 前 $n_1$ 行和列表示第一个社区里的节点, 以此类推, 最后 $n_K$ 行和列表示第 $K$ 个社区的节点。
- $P(Z, K)$ 是一个分块矩阵,  $(k, l)$ 块 $P^{(k,l)}(Z, K)$ 是 $n_k \times n_l$ 的矩阵, 每个元素 $P_{i,j}^{(k,l)} = V_{i_{k,l}} V_{j_{l,k}}$ , 容易看出,  $P^{(k,l)}(Z, K)$ 是一个秩一矩阵, 可以表示成一组唯一的一维向量乘积。
- ◆ 记 $\Lambda^{(k,l)}$ 为 $n_k$ 维向量, 分量 $\Lambda_i^{(k,l)} = V_{i_{k,l}}$ 为社区 $k$ 的第 $i$ 个元素在社区 $l$ 中的流行度参数, 则有如下关系

$$P^{(k,l)}(Z, K) = \Lambda^{(k,l)} [\Lambda^{(l,k)}]^T.$$

# □ 从分块角度理解PABM



## □ 从分块角度理解PABM

- ◆ 整个重排后的概率矩阵就有如下的分块形式

$$P(Z, K) = \begin{bmatrix} \Lambda^{(1,1)}(\Lambda^{(1,1)})^T & \Lambda^{(1,2)}(\Lambda^{(2,1)})^T & \dots & \Lambda^{(1,K)}(\Lambda^{(K,1)})^T \\ \Lambda^{(2,1)}(\Lambda^{(1,2)})^T & \Lambda^{(2,2)}(\Lambda^{(2,2)})^T & \dots & \Lambda^{(2,K)}(\Lambda^{(K,2)})^T \\ \vdots & \vdots & \dots & \vdots \\ \Lambda^{(K,1)}(\Lambda^{(1,K)})^T & \Lambda^{(K,2)}(\Lambda^{(2,K)})^T & \dots & \Lambda^{(K,K)}(\Lambda^{(K,K)})^T \end{bmatrix}$$

- 这说明矩阵 $P(Z, K)$ 是由很多个秩一块矩阵组成的。本文最主要的落脚点就是认识到PABM的概率矩阵是由一些秩一矩阵组合而成，这是Sengupta和Chen(2018)没有意识到的。这可以帮助我们从另一个角度对PABM进行估计和聚类，建立基于F范数最小化的聚类目标。
- 之后也发现在可检测条件下，任一社区对应的概率矩阵的列都在一个K维的子空间里，并且这个社区的子空间与其他社区所在子空间不同。本文基于这个结论引入了SSC进行社区检测。

## □ 估计和聚类的过程推导

- 当真实社区数 $K_*$ 已知时，给定节点分配 $Z$ ，可以用一个置换矩阵 $\mathcal{P}_{Z,K_*}$ 对邻接矩阵 $A$ 进行重排，即 $A(Z, K_*) = \mathcal{P}_{Z,K_*}^T A \mathcal{P}_{Z,K_*}$ ，回忆概率矩阵分块

$$P^{(k,l)}(Z, K) = \Lambda^{(k,l)} [\Lambda^{(l,k)}]^T.$$

- 很直观地，如果 $K_*$ 已知，想要得到 $Z_*$ 和 $P_*$ 的估计，我们可以在分块意义下最小化 $A(Z, K_*)$ 和 $\Lambda^{(k,l)} [\Lambda^{(l,k)}]^T$ 构成的概率矩阵之间的某个散度度量。
- 考虑Bregman散度（ $F$ 是连续可微严格凸函数）： $D_F(x, y) = F(x) - F(y) - \langle \nabla F(y), x - y \rangle$
- 目标函数就可以一般化为最小化 $A(Z, K_*)$ 和 $P(Z, K_*)$ 之间的Bregman散度
- 不难发现，取 $F(x) = \sum_i (x_i \ln x_i - x_i)$ 时，就可以推导得到Sengupta和Chen(2018)得到的基于泊松分布的似然模块度。

## □ 估计和聚类的过程推导

➤ 这里考虑取  $F(x) = \|x\|^2$ ，对应矩阵的F范数，得到给定  $K$  下的优化目标

$$(\hat{\Lambda}, \hat{Z}) \in \operatorname{argmin}_{\Lambda, Z} \left\{ \sum_{k,l=1}^K \|A^{(k,l)}(Z, K) - \Lambda^{(k,l)} [\Lambda^{(l,k)}]^T\|_F^2 \right\} \quad \text{s.t.} \quad A(Z, K) = \mathcal{P}_{Z,K}^T A \mathcal{P}_{Z,K}$$

◆ 这个目标对  $\Lambda$  的求解是需要之前Sengupta和Chen(2018)提出的可识别性条件的，但是我们知道了它的每个块都是一个秩一矩阵，就可以转化为一个求秩一矩阵  $\Theta^{(k,l)}$  的目标。另外针对  $K$  未知的情况，再加上一个对  $K$  的惩罚项  $\text{Pen}(n, K)$ ，得到完整的目标函数为

$$(\hat{\Theta}, \hat{Z}, \hat{K}) \in \operatorname{argmin}_{\Theta, Z, K} \left\{ \sum_{k,l=1}^K \|A^{(k,l)}(Z, K) - \Theta^{(k,l)}\|_F^2 + \text{Pen}(n, K) \right\}$$

s.t.  $A(Z, K) = \mathcal{P}_{Z,K}^T A \mathcal{P}_{Z,K}, \quad \text{rank}(\Theta^{(k,l)}) = 1; \quad k, l = 1, 2, \dots, K.$

## □ 估计和聚类的过程推导

- ◆ 假设 $\hat{Z}$ 和 $\hat{K}$ 已知, 用 $A^{(k,l)}(\hat{Z}, \hat{K})$ 的秩一估计作为 $\hat{\Theta}^{(k,l)}$ , 即

$$\hat{\Theta}^{(k,l)}(\hat{Z}, \hat{K}) = \Pi_{\hat{u}, \hat{v}} \left( A^{(k,l)}(\hat{Z}, \hat{K}) \right) = \hat{\sigma}_1^{(k,l)} \hat{u}^{(k,l)}(\hat{Z}, \hat{K}) (\hat{v}^{(k,l)}(\hat{Z}, \hat{K}))^T,$$

- ◆ 上式代入原目标, 假设 $\hat{K}$ 已知时, 求解 $Z$ , 即

$$\hat{Z}_K \in \operatorname{argmin}_{Z \in \mathcal{M}_{n,K}} \left\{ \sum_{k,l=1}^K \|A^{(k,l)}(Z, K) - \Pi_{\hat{u}, \hat{v}}(A^{(k,l)}(Z, K))\|_F^2 \right\} \quad (12)$$

- ◆ 再代回原目标, 得到一个只含 $K$ 的函数, 对 $K$ 进行搜索找到最优社区数

$$\hat{K} \in \operatorname{argmin}_K \left\{ \sum_{k,l=1}^K \|A^{(k,l)}(\hat{Z}_K, K) - \Pi_{\hat{u}, \hat{v}}(A^{(k,l)}(\hat{Z}_K, K))\|_F^2 + \operatorname{Pen}(n, K) \right\}. \quad (13)$$

- 选择惩罚项为

$$\operatorname{Pen}(n, K) = H_1 nK + H_2 K^2 \ln n + H_3 n \ln K,$$

## □ 稀疏子空间聚类 (Sparse Subspace Clustering, SSC)

- 子空间聚类就是为对处于不同子空间的点的分离而设计的, 令  $\{x_j \in \mathbb{R}^D\}_{j=1}^n$  是一组点, 来自  $K$  个线性或仿射子空间  $\{S_i\}_{i=1}^K$ , 每个子空间维度是  $d_i = \dim(S_i)$ , 以线性子空间为例, 即

$$S_i = \{x \in \mathbb{R}^D : x = U_i y\}, \quad i = 1, \dots, K$$

其中  $U_i$  为  $S_i$  的基,  $y$  为  $x$  在  $S_i$  中的低维表示。

- 子空间聚类的目的就是找到子空间数目  $K$ , 每个子空间的维数  $\{d_i\}_{i=1}^K$  和基  $\{U_i\}_{i=1}^K$ , 以及每个点的分配。子空间聚类算法包括: 代数方法, 迭代方法, 基于谱聚类的方法。这里考虑的是 基于谱聚类的算法。
- 谱聚类算法依靠的是构建一个亲和 (相似) 矩阵 (affinity matrix), 里面的元素是两点间的某种距离度量。比如 SBM 直接用邻接矩阵  $A$ , DCBM 则通过对  $A$  进行一些规范化处理。
- 但是子空间聚类就不太适用, 因为有可能两个点离得很近, 但是在两个子空间里。

## □ 稀疏子空间聚类 (Sparse Subspace Clustering, SSC)

- 一个解决的办法就是构建亲和矩阵的时候利用“点的自表示”，希望这个点能够更可能被在它自己子空间里的其他点表示，而不是来自其他子空间的点。
- 构建方法包括低秩表示(low-rank representation)和稀疏子空间聚类(SSC)。
- 本文用的是SSC，可以利用到之前得到的结论：给定 $K$ 时， $P_*$ 实际上是处在 $K$ 个子空间的并集里，每个子空间至多是 $K$ 维的。
- 如果 $P_*$ 已知，权重矩阵 $W$ 就可以在将每个点写成所有其他点的稀疏线性组合的条件下，通过最小化非零分量的数量（0范数）得到，即

$$\min_{W_j} \|W_j\|_0 \quad \text{s.t. } (P_*)_j = \sum_{k \neq j} W_{kj} (P_*)_k$$

- 在数据含噪声的情况下，上面的条件太过于精确，可以引入调整参数 $\gamma > 0$ ，得到

$$\hat{W}_j \in \operatorname{argmin}_{W_j} \{ \|W_j\|_0 + \gamma \|A_j - AW_j\|_2^2 \quad \text{s.t. } W_{jj} = 0 \}, \quad j = 1, \dots, n,$$

## □ 稀疏子空间聚类 (Sparse Subspace Clustering, SSC)

◆ 前面的优化目标可以改写成

$$\hat{W}_j \in \operatorname{argmin}_{W_j} \{ \|A_j - AW_j\|_2^2 \quad \text{s.t.} \quad \|W_j\|_0 \leq L, \quad W_{jj} = 0 \}, \quad j = 1, \dots, n, \quad (32)$$

对于PABM的求解，取 $L = K$ 。

- 利用正交匹配追踪(orthogonal matching pursuit, OMP)算法可以解决(32)这个问题。
- 给定 $\hat{W}$ ，就可以根据权重矩阵的对称形式得到SSC的亲（相）似矩阵

$$S = |\hat{W}| + |\hat{W}^T| \quad (33)$$

- ◆ SSC的基本流程为两步：
1. 估计权重矩阵 $W$ （用OMP算法求解(32)）
  2. 在亲和矩阵 $S$ 上运用谱聚类（33）

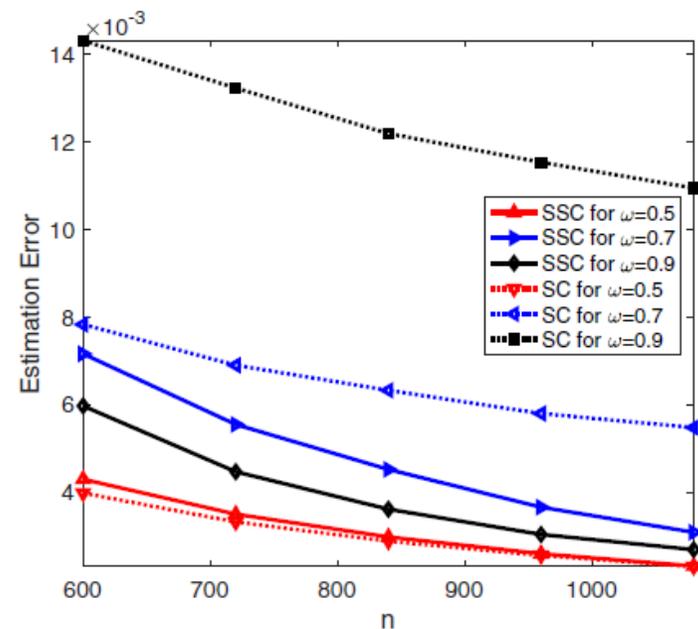
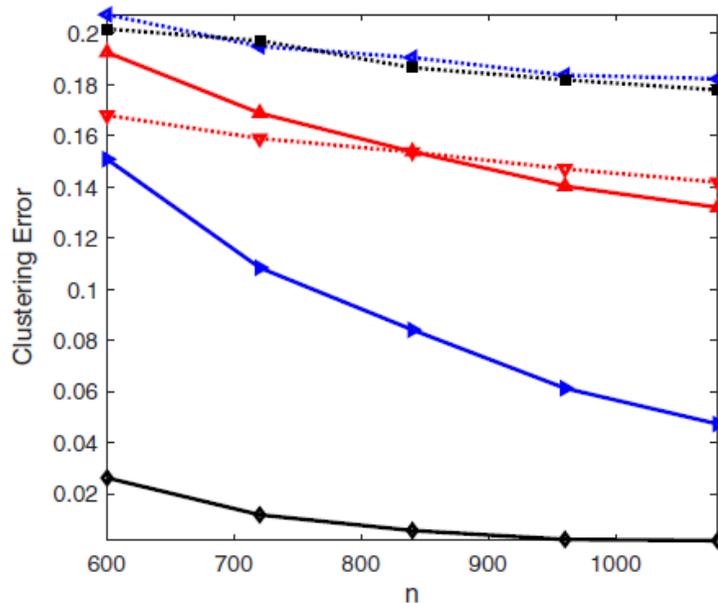
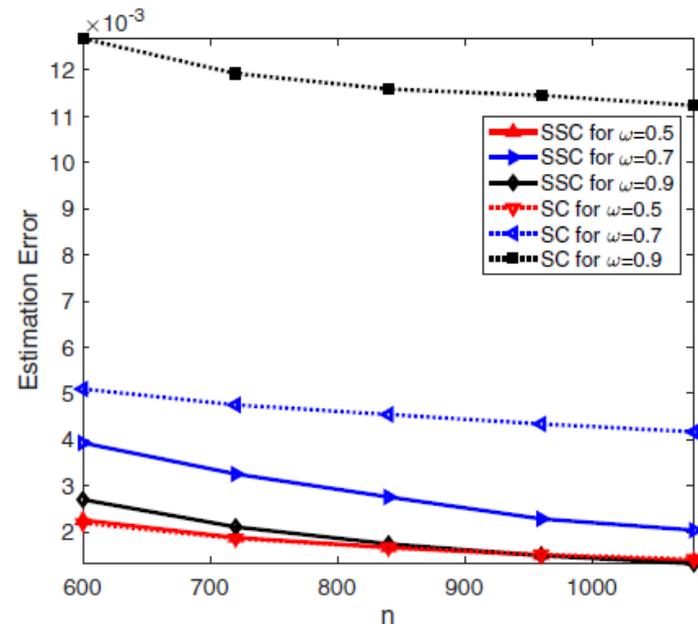
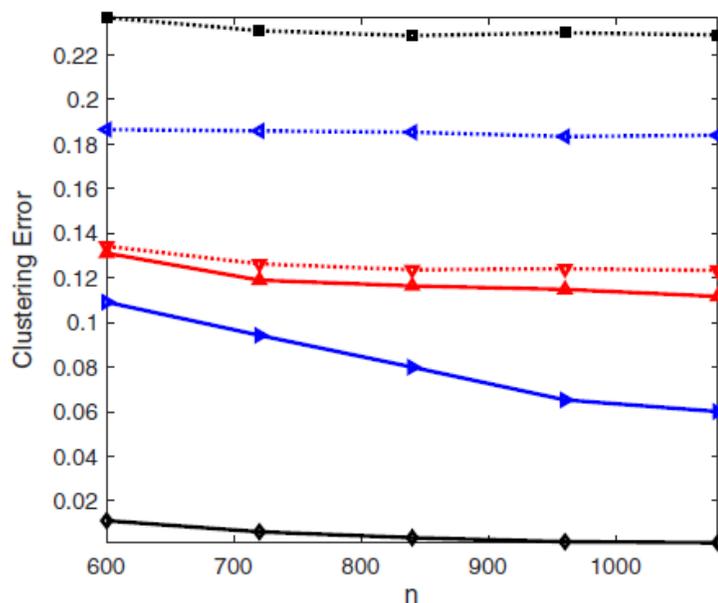
## □ Simulations

- 在Sengupta和Chen(2018)里的模拟中，只考虑了二分类问题，并且设定的人工网络虽然是从PABM中生成的，但是太过于平衡了，其实谱聚类也能得到较准确的结果。因此这里考虑生成连接概率多样化且符合PABM的人工网络，并且考虑 $K$ 取多种值。
- 具体生成过程这里不展开。
- ◆ 对PABM的求解步骤：
  1. 用OMP算法优化(32)，得到权重矩阵 $W$ 的估计；  
(全程 $K$ 是给定的)
  2. 对相似矩阵 $S$ 应用谱聚类算法，得到聚类矩阵 $Z$ 的估计；
  3. 给定 $\hat{Z}$ ，可以得到 $A$ 分块形式，根据每个块的秩一估计得到 $\hat{\Theta}$ ；
  4. 最后把 $\hat{\Theta}$ 用置换矩阵还原到原来的样本顺序，得到 $\hat{P}$ 。
- 尝试不同的 $K$ 取值，找到目标函数最小的那个作为最优社区数。

## □ Simulations

✓ 随着 $\omega$ 的增加, SSC比SC的效果更准确。因为SSC更加适合处理更加多样化的连接概率。

- 左边是聚类估计误差, 右边是概率矩阵估计误差;
- 实线为SSC, 虚线为SC;
- $\omega$  越大表示生成的网络异质性 (不均匀) 越强;
- $K = 4$  (上),  $K = 8$  (下)。



## □ Simulations

✓ 出现频率最高的都是真实的社区数，说明选择 $K$ 的方法是合理的。

- 每个模型设定下生成50个网络，统计网络选择的最优社区数出现的频率。

TABLE 1 The relative of the estimators  $\hat{K}$  of  $K_*$  for  $K_*$  ranging from 3 to 6,  $n = 420$  and  $n = 840$  and  $\omega = 0.5, 0.7$  and  $0.9$

| $K_*$ | $\hat{K}$ | n = 420        |                |                | n = 840        |                |                |
|-------|-----------|----------------|----------------|----------------|----------------|----------------|----------------|
|       |           | $\omega = 0.5$ | $\omega = 0.7$ | $\omega = 0.9$ | $\omega = 0.5$ | $\omega = 0.7$ | $\omega = 0.9$ |
| 3     | 2         | 0              | 0              | 0              | 0              | 0              | 0              |
|       | 3         | <b>0.76</b>    | <b>0.80</b>    | <b>0.90</b>    | <b>0.52</b>    | <b>0.60</b>    | <b>0.80</b>    |
|       | 4         | 0.24           | 0.16           | 0.10           | 0.36           | 0.26           | 0.16           |
|       | 5         | 0              | 0.04           | 0              | 0.12           | 0.14           | 0.02           |
|       | 6         | 0              | 0              | 0              | 0              | 0              | 0.02           |
| 4     | 2         | 0              | 0              | 0              | 0              | 0              | 0              |
|       | 3         | 0.06           | 0.14           | 0              | 0.02           | 0.02           | 0              |
|       | 4         | <b>0.64</b>    | <b>0.66</b>    | <b>0.96</b>    | <b>0.56</b>    | <b>0.64</b>    | <b>0.76</b>    |
|       | 5         | 0.28           | 0.16           | 0.04           | 0.30           | 0.26           | 0.22           |
|       | 6         | 0.02           | 0.04           | 0              | 0.12           | 0.08           | 0.02           |
| 5     | 2         | 0              | 0.02           | 0              | 0              | 0              | 0              |
|       | 3         | 0.02           | 0              | 0.02           | 0              | 0              | 0              |
|       | 4         | 0.14           | 0.16           | 0.04           | 0.04           | 0.04           | 0              |
|       | 5         | <b>0.64</b>    | <b>0.66</b>    | <b>0.82</b>    | <b>0.78</b>    | <b>0.68</b>    | <b>0.90</b>    |
|       | 6         | 0.20           | 0.16           | 0.12           | 0.18           | 0.28           | 0.10           |
| 6     | 2         | 0              | 0.04           | 0              | 0              | 0              | 0              |
|       | 3         | 0.06           | 0.18           | 0.02           | 0              | 0              | 0              |
|       | 4         | 0.18           | 0.22           | 0.02           | 0              | 0              | 0              |
|       | 5         | 0.28           | 0.22           | 0.08           | 0.12           | 0.16           | 0.10           |
|       | 6         | <b>0.48</b>    | <b>0.34</b>    | <b>0.88</b>    | <b>0.88</b>    | <b>0.84</b>    | <b>0.90</b>    |

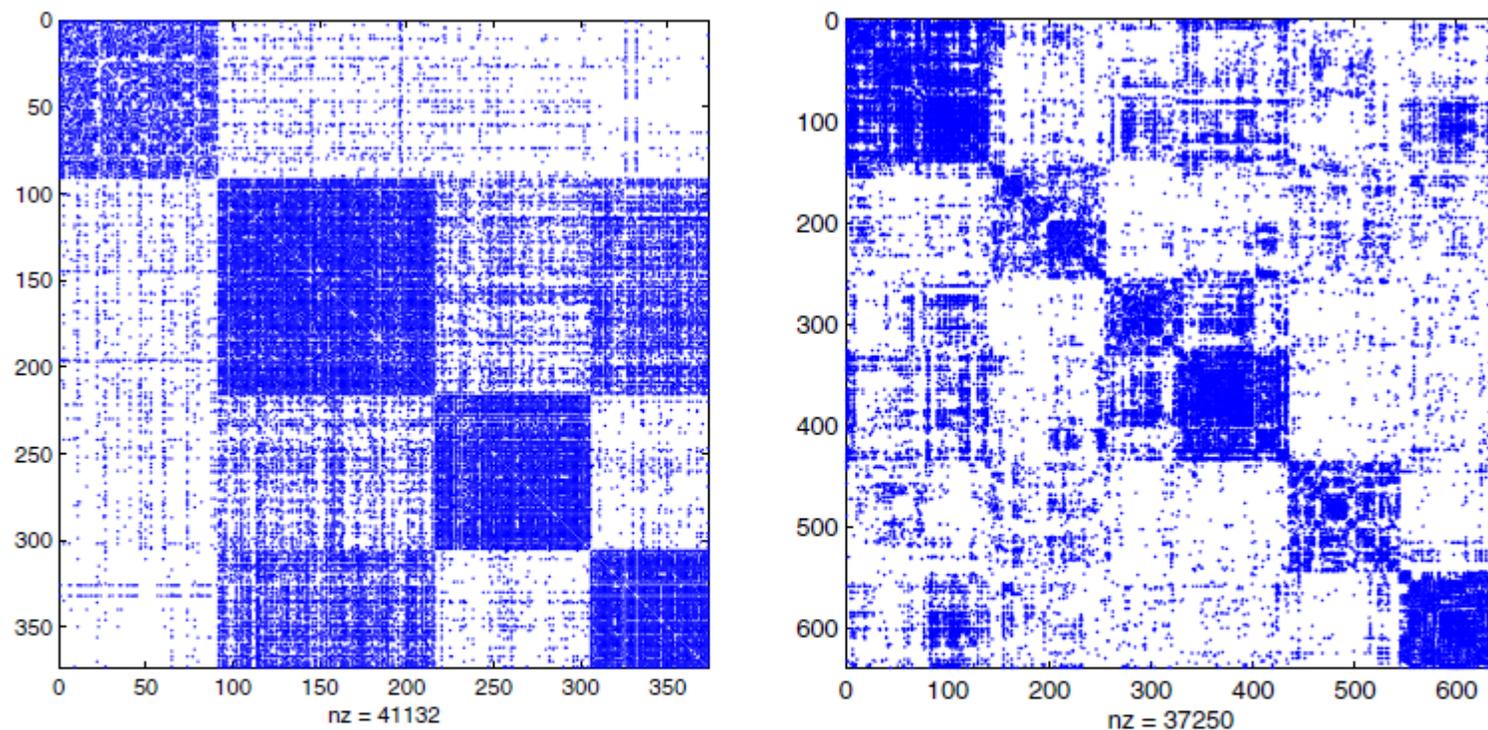
The probabilities for the true values of  $K$  are given in bold.

## □ Real data examples

- 社交网络往往具有比较强的同配行为，这种现象可能和人类倾向于建立强关联的趋势有关。
- Sengupta和Chen(2018)采用的政治博客、英国推特等网络都比较接近分块对角的邻接矩阵，实际上SC在这些网络上的表现也会很好。
- PABM能够对于更加多样的网络提供精确的描述，尤其是出现在生物学中的网络。
- 这里考虑了两个网络：蝴蝶相似性网络和人脑功能网络
  - 蝴蝶相似性网络：节点为几百种蝴蝶，边是通过细粒度图得到的表型相似性的0-1值，总共有4个种群大类。
  - 人脑功能网络：节点为人脑划分出的几百个区域，边是各区域之间的某种功能性连接，根据以往的研究有6个功能大类。

## □ Real data examples

- 在真实数据上分别采用SSC, SC和加权k-median算法, 和真实结果进行比较, SSC的调整兰德系数(ARI)最高。



**FIGURE 5** Adjacency matrices of the butterfly similarity network with 41,132 nonzero entries and 4 clusters (left) and the brain network with 37,250 nonzero entries and 6 clusters (right)

Fig5. 估计得到的邻接矩阵的分块形式  
(左: 蝴蝶网络, 右: 人脑网络)