

# 'Oracle inequalities' für Netzwerkmodelle

Saskia F. Glaffig

06.12.17

---

## Modell und Bezeichnungen

### Das Modell, Schätzung der Verbindungswahrscheinlichkeiten

Wir betrachten ein Netzwerk, welches als ungerichteter Graph mit  $n$  Knoten definiert wird.  $A$  bezeichne die (symmetrische) Adjazenzmatrix des Graphen, wobei wir  $A_{i,i} = 0$  für alle  $1 \leq i \leq n$  setzen und  $A_{i,j}$  für alle  $1 \leq j < i \leq n$  unabhängige, Bernoulli-verteilte Zufallsvariablen mit Parameter  $(\Theta_0)_{i,j}$  seien. Die symmetrische  $(n \times n)$ -Matrix der Verbindungswahrscheinlichkeiten mit den Einträgen  $(\Theta_0)_{i,j}$  und  $(\Theta_0)_{i,i} = 0$  für alle  $1 \leq i \leq n$  bezeichnen wir mit  $\Theta_0$ .

Der Graph wird durch das 'stochastic block model' mit  $k \leq n$  Klassen approximiert. Jede dieser Klassen habe mindestens  $n_0$  Elemente.

### Bezeichnungen

- Für  $m \in \mathbb{N}$  sei  $[m] = \{1, \dots, m\}$ .
- Seien  $n, k, n_0 \in \mathbb{N}$ , so dass  $2 \leq k \leq n$  und  $n_0 \leq n$ . Weiter sei

$$\mathcal{Z}_{n,k,n_0} = \{z : [n] \rightarrow [k] \mid \min_{a \in [k]} |z^{-1}(a)| \geq n_0\}.$$

- $\|B\|_F$  bezeichne die Frobenius-Norm und  $\|B\|_\infty$  die Supremumsnorm einer Matrix  $B \in \mathbb{R}^{n \times n}$ .

## 1. 'Oracle inequalities'

Im Folgenden sei  $k \in \mathbb{N}$  fest.

### Kleinst-Quadrate-Schätzer (LSE)

Für  $z \in \mathcal{Z}_{n,k,n_0}$  und  $Q \in \mathbb{R}_{sym}^{k \times k}$  sei

$$L(Q, z) = \sum_{(a,b) \in [k] \times [k]} \sum_{(i,j) \in z^{-1}(a) \times z^{-1}(b), j < i} (A_{i,j} - Q_{a,b})^2.$$

Der LSE von  $(Q, z)$  ist dann

$$(\hat{Q}, \hat{z}) \in \arg \min_{Q \in \mathbb{R}_{sym}^{k \times k}, z \in \mathcal{Z}_{n,k,n_0}} L(Q, z),$$

und der LSE von  $\Theta_0$  sei definiert als symmetrische  $(n \times n)$ -Matrix mit den Einträgen

$$\begin{aligned} \hat{\Theta}_{i,j} &= \hat{Q}_{\hat{z}(i), \hat{z}(j)} & \forall i > j, \\ \hat{\Theta}_{i,i} &= 0 & \forall i. \end{aligned}$$

### Eingeschränkter kleinste-Quadrate-Schätzer

Sei  $r \in (0, 1]$  gegeben und  $\mathcal{B}_r = \{Q \in \mathbb{R}_{sym}^{k \times k} : \|Q\|_\infty \leq r\}$ . Definiere

$$(\hat{Q}_r, \hat{z}_r) \in \arg \min_{Q \in \mathcal{B}_r, z \in \mathcal{Z}_{n,k,1}} L(Q, z).$$

Der eingeschränkte LSE  $\hat{\Theta}^r$  von  $\Theta_0$  sei die symmetrische  $(n \times n)$ -Matrix mit den Einträgen

$$\begin{aligned} \hat{\Theta}_{i,j}^r &= (\hat{Q}_r)_{\hat{z}_r(i), \hat{z}_r(j)} & \forall i > j \\ \hat{\Theta}_{i,i}^r &= 0 & \forall i. \end{aligned}$$

### 'Oracle inequalities'

Sei  $\Theta_{*,n_0}$  die optimale Approximation von  $\Theta_0$  in der Menge

$$\mathcal{T}_{n_0}[k] = \{\Theta \in \mathbb{R}^{n \times n} : \exists z \in \mathcal{Z}_{n,k,n_0}, Q \in \mathbb{R}_{sym}^{k \times k}, \text{ so dass } \Theta_{i,j} = Q_{z(i), z(j)}, i \neq j \text{ und } \Theta_{i,i} = 0 \forall i\}$$

bezüglich der Frobenius-Norm.

**Theorem 1.** *Es gibt positive absolute Konstanten  $C_1, C_2, C_3$ , so dass die Ungleichung*

$$\mathbb{E} \left[ \frac{1}{n^2} \|\hat{\Theta} - \Theta_0\|_F^2 \right] \leq \frac{C_1}{n^2} \|\Theta_0 - \Theta_{*,n_0}\|_F^2 + C_2 \|\Theta_0\|_\infty \left( \frac{\log(k)}{n} + \frac{k^2}{n^2} \right) + C_3 \frac{\log(n/n_0)}{n_0} \left( \frac{\log(k)}{n} + \frac{k^2}{n^2} \right) \quad (1)$$

für alle  $n_0 \geq 2$  erfüllt ist.

Im Fall von gleichmäßigen Klassen ( $n_0 = \mathcal{O}(n/k)$ ) ergibt sich daraus das folgende Resultat.

**Korollar 2.** *Es gelte  $n_0 \geq Cn/k$  für ein  $C > 0$  und  $\|\Theta_0\|_\infty \geq \frac{k \log(k)}{n}$ . Dann gibt es positive Konstanten  $C_1, C_2$ , so dass die Ungleichung*

$$\mathbb{E} \left[ \frac{1}{n^2} \|\hat{\Theta} - \Theta_0\|_F^2 \right] \leq \frac{C_1}{n^2} \|\Theta_0 - \Theta_{*,n_0}\|_F^2 + C_2 \|\Theta_0\|_\infty \left( \frac{\log(k)}{n} + \frac{k^2}{n^2} \right) \quad (2)$$

für  $n_0 \geq 2$  erfüllt ist.

**Theorem 3.** *Es gibt positive Konstanten  $C_1, C_2$ , so dass die folgende Aussage gilt:  
Ist  $\|\Theta_0\|_\infty \leq r$ , so folgt*

$$\mathbb{E} \left[ \frac{1}{n^2} \|\hat{\Theta}^r - \Theta_0\|_F^2 \right] \leq \frac{C_1}{n^2} \|\Theta_0 - \Theta_{*,1}\|_F^2 + C_2 r \left( \frac{\log(k)}{n} + \frac{k^2}{n^2} \right). \quad (3)$$

## Literatur

- [1] O. Klopp, A. B. Tsybakov und N. Verzelen. «Oracle Inequalities for Network Models and Sparse Graphon Estimation». In: *The Annals of Statistics* 45.1 (2017), S. 316–354.