

1 Community detection in sparse random networks

1.1 Rahmenbedingungen und Hilfslemmata

Sei $\mathcal{G} = (\mathcal{V}, \mathcal{E})$ ein ungerichteter Graph (\mathcal{V} sei die Menge der Ecken, oBdA. $\mathcal{V} = \{1, \dots, N\}$, \mathcal{E} die Menge der Kanten). Sei $\mathbf{W} = (W_{i,j}) \in \{0, 1\}^{N \times N}$ die zugehörige Adjazenzmatrix, mit $W_{i,j} = 1 \iff (i, j) \in \mathcal{E}$ (\mathbf{W} symmetrisch) und $W_{i,i} = 0$, $i \in \{1, \dots, N\}$.

Unter der Nullhypothese ist der Graph \mathcal{G} eine Realisierung von $\mathbb{G}(N, p_0)$, Erdős–Rényi-Graph mit N Ecken und Verbindungswahrscheinlichkeit $p_0 \in (0, 1)$ (\iff Die Einträge über der Diagonalen von \mathbf{W} sind iid verteilt mit $\mathbb{P}(W_{i,j} = 1) = p_0 \forall i < j$). Außerdem sei p_0 bekannt.

Unter der Alternative existiert eine Teilmenge $S \subset \mathcal{V}$, so dass $\mathbb{P}(W_{i,j} = 1) = p_1 \forall i, j \in S, i \neq j$ mit $p_1 > p_0$. Die Teilmenge S ist nicht bekannt, es wird aber angenommen, dass $|S| = n$ bekannt ist. Bezeichne H_0 die Nullhypothese, es wird H_0 gegen $H := \cup_{|S|=n} H_S$ getestet. Es wird asymptotisches Verhalten betrachtet, mit

$$N \rightarrow \infty, n = n(N) \rightarrow \infty, n/N \rightarrow 0, n/\log(N) \rightarrow \infty.$$

Weiterhin hängen auch $p_0 = p_0(N)$ und $p_1 = p_1(N)$ von N ab. Ein Test ϕ erhalte \mathbf{W} als Eingabe, so dass $\phi(\mathbf{W}) = 1$, falls eine obige Teilmenge S existiert und $\phi(\mathbf{W}) = 0$ andernfalls. Das Risiko eines Tests ϕ sei

$$\gamma_N(\phi) = \mathbb{P}_0(\phi = 1) + \max_{|S|=n} \mathbb{P}_S(\phi = 0).$$

Eine Folge (ϕ_N) von Tests für eine Folge \mathbf{W}_N von Adjazenzmatrizen heißt asymptotisch schwach, bzw. stark, falls $\gamma_N(\phi_N(\mathbf{W}_N)) \rightarrow 0$, bzw. $\gamma_N(\phi_N(\mathbf{W}_N)) \rightarrow 1$. Die Hypothesen verschmelzen asymptotisch, falls

$$\gamma_N^* := \inf_{\phi} \gamma_N(\phi) \rightarrow 1$$

und trennen sich vollständig asymptotisch, falls

$$\gamma_N^* \rightarrow 0.$$

Wir definieren:

$$\lambda_0 := Np_0, \lambda_1 := np_1$$

$$W_n^* := \max_{|S|=n} W_S, W_{k,S}^* := \max_{T \subset S, |T|=k} W_T, W_S := \sum_{i,j \in S, i < j} W_{i,j}, W_n^\dagger := \sup_{k=n/u_N}^n \frac{W_k^*}{k}, u_N := \log(\log(N/n))$$

Wir nehmen an, dass $N^2 p_0 \rightarrow \infty, n^2 p_1 \rightarrow \infty$. Definiere weiter

$$\alpha := \frac{\log(\lambda_0)}{\log(N/n)}, H_p(q) := q \log(q/p) + (1-q) \log\left(\frac{1-q}{1-p}\right), p, q \in (0, 1).$$

Lemma 1.1 (Chernoffs bound) Für $n \in \mathbb{N}, q, p \in (0, 1)$ gilt:

$$\mathbb{P}(\text{Bin}(n, p) \geq qn) \leq \exp(-nH_p(q)).$$

Lemma 1.2 Sei $h(x) = x \log(x) - x + 1$. Für $0 < p \leq q < 1$ gilt:

$$0 \leq H_p(q) - ph(q/p) \leq O\left(\frac{q^2}{1-q}\right).$$

Lemma 1.3 Für $1 \leq k \leq n$ mit $k, n \in \mathbb{N}$ gilt

$$\left(\frac{n}{k}\right)^k \leq \binom{n}{k} \leq \left(\frac{en}{k}\right)^k$$

Lemma 1.4 Für jedes $\lambda > 1$ bezeichne η_λ den kleinsten Wert, der die Gleichung $\eta = \exp(\lambda(\eta - 1))$ löst. Sei C_m die größte Zusammenhangskomponente in $\mathbb{G}(m, \lambda/m)$ und nehme an, dass $\lambda > 1$ fest sei. Dann gilt

$$\begin{aligned} |C_m| &\sim^{\mathbb{P}} (1 - \eta_\lambda)m \\ W_{C_m} &\sim^{\mathbb{P}} \frac{\lambda}{2}(1 - \eta_\lambda^2)m. \end{aligned}$$

1.2 Resultate

Satz 1.5 (Broad Scan Test) Der Scan Test basierend auf W_n^\dagger ist asymptotisch stark, falls

$$(i) \limsup \alpha \leq 1 \text{ und } \liminf (1 - \alpha) \sup_{k=n/u_N}^n \frac{\mathbb{E}_S[W_{k,S}^*]}{k} > 1;$$

oder

$$(ii) \alpha \rightarrow 0 \text{ und } \liminf \lambda_1 > 1.$$

Satz 1.6 *Angenommen, $\zeta := \frac{(\lambda_1 - \lambda_0 n/N)^2 n^2}{\lambda_0 N} \rightarrow 0$. Dann sind alle Tests asymptotisch schwach in jedem der folgenden Szenarien:*

- (i) $\lambda_0 \rightarrow 0, \lambda_1 \rightarrow 0, \limsup \frac{I_{\lambda_0} \log(n)}{I_{\lambda_1} \log(N)} < 1$, wobei $I_\lambda := \lambda - 1 - \log(\lambda)$;
- (ii) $0 < \liminf \lambda_0 \leq \limsup \lambda_0 < \infty, \lambda_1 \rightarrow 0$;
- (iii) $\lambda_0 \rightarrow \infty$ mit $\alpha \rightarrow 0, \limsup \lambda_1 < 1$;
- (iv) $0 < \liminf \alpha \leq \limsup \alpha < 1, \limsup (1 - \alpha) \sup_{k=n/u_N}^n \frac{\mathbb{E}_S[W_{k,S}^*]}{k} < 1$.

Der Beweis des letzten Resultates ist fehlerhaft.