

確率伝播とスペクトラル手法

— 平均時解析のための方法 —

山本 真基

京都大学 情報学研究科

2007年12月15日

with 渡辺治 (東京工業大学)

- ① 平均時解析 (Average-Case Analysis) とは ?
- ② スペクトラル手法 (Spectral Methods)
- ③ 確率伝播 (Belief Propagation)
- ④ 我々のアルゴリズムとその解析
- ⑤ まとめ

- ① 平均時解析 (Average-Case Analysis) とは ?
- ② スペクトラル手法 (Spectral Methods)
- ③ 確率伝播 (Belief Propagation)
- ④ 我々のアルゴリズムとその解析
- ⑤ まとめ

M. Yamamoto and O. Watanabe, “Belief Propagation and Spectral Methods”,
Research Reports (Series C: Computer Science) C-248, Dept. of Math. and
Comp. Sciences, Tokyo Institute of Technology, November, 2007.

平均時解析 (Average-Case Analysis) とは？

平均時解析 (Average-Case Analysis) とは？

問題の **平均的な** 難しさを解析する：

平均時解析 (Average-Case Analysis) とは？

問題の **平均的な** 難しさを解析する：

- 上界の解析
- 下界の解析

平均時解析 (Average-Case Analysis) とは？

問題の **平均的な** 難しさを解析する：

- 上界の解析 ← 問題が最悪の場合で計算困難 (e.g., \mathcal{NP} -困難) であっても，ほとんどの例題は簡単なのでは？
- 下界の解析 ← 計算論的暗号理論などでは，問題の平均的な難しさを仮定する (e.g., 一方向性関数の存在) .

平均時解析 (Average-Case Analysis) とは？

問題の **平均的な** 難しさを解析する：

- **上界の解析** ← 問題が最悪の場合で計算困難 (e.g., \mathcal{NP} -困難) であっても，ほとんどの例題は簡単なのでは？
- **下界の解析** ← 計算論的暗号理論などでは，問題の平均的な難しさを仮定する (e.g., 一方向性関数の存在) .

1. Suppose : 問題 L とその例題の族 $\mathcal{I} = \{\mathcal{I}_n\}_{n \geq 1}$

平均時解析 (上界): シナリオ

1. Suppose : 問題 L とその例題の族 $\mathcal{I} = \{\mathcal{I}_n\}_{n \geq 1}$
2. Define : $\left\{ \begin{array}{l} \text{i. } \mathcal{I}_n \text{ 上の分布 } \mathcal{G}_n = \mathcal{G}_{n,p,q,\dots} \\ \text{ii. } L \text{ を解くアルゴリズム } A \end{array} \right.$

平均時解析 (上界): シナリオ

1. Suppose : 問題 L とその例題の族 $\mathcal{I} = \{\mathcal{I}_n\}_{n \geq 1}$

2. Define : $\left\{ \begin{array}{l} \text{i. } \mathcal{I}_n \text{ 上の分布 } \mathcal{G}_n = \mathcal{G}_{n,p,q,\dots} \\ \text{ii. } L \text{ を解くアルゴリズム } A \end{array} \right.$

3. Analyze : $\sum_{J \in \mathcal{I}_n} \Pr \{I = J\} \cdot \text{time}_A(J)$

3'. : $\Pr_{I \in \mathcal{G}_n} \{A(I) = \text{OPT}(I)\}$
ただし, A は多項式時間アルゴリズム

平均時解析 (上界): シナリオ

1. Suppose : 問題 L とその例題の族 $\mathcal{I} = \{\mathcal{I}_n\}_{n \geq 1}$
2. Define : $\begin{cases} \text{i. } \mathcal{I}_n \text{ 上の分布 } \mathcal{G}_n = \mathcal{G}_{n,p,q,\dots} \\ \text{ii. } L \text{ を解くアルゴリズム } A \end{cases}$
3. Analyze : $\sum_{J \in \mathcal{I}_n} \Pr \{I = J\} \cdot \text{time}_A(J)$
- 3'. : $\Pr \{A(I) = \text{OPT}(I)\}$
ただし, A は多項式時間アルゴリズム

このシナリオの **目標** は?

平均時解析 (上界): シナリオ

1. Suppose : 問題 L とその例題の族 $\mathcal{I} = \{\mathcal{I}_n\}_{n \geq 1}$
2. Define : $\begin{cases} \text{i. } \mathcal{I}_n \text{ 上の分布 } \mathcal{G}_n = \mathcal{G}_{n,p,q,\dots} \\ \text{ii. } L \text{ を解くアルゴリズム } A \end{cases}$
3. Analyze : $\sum_{J \in \mathcal{I}_n} \Pr \{I = J\} \cdot \text{time}_A(J) = \mathbf{poly}(n)$
- 3'. : $\Pr \{A(I) = \text{OPT}(I)\} = \mathbf{1 - o_n(1)}$
ただし, A は多項式時間アルゴリズム

このシナリオの **目標** は?

例

1. L : Min-Bisection 問題, \mathcal{I}_n : n 頂点の全無向グラフの集合
2. $\left\{ \begin{array}{l} \mathcal{G}_n : n \text{ 頂点の全無向グラフ上の一様分布} \\ A : (L \text{ のための}) \text{ 多項式時間アルゴリズム} \end{array} \right.$

平均時解析 (上界) : 例

例

1. L : Min-Bisection 問題, \mathcal{I}_n : n 頂点の全無向グラフの集合
2. $\begin{cases} \mathcal{G}_n & : n \text{ 頂点の全無向グラフ上の一様分布} \\ A & : (L \text{ のための}) \text{ 多項式時間アルゴリズム} \end{cases}$

定義 (Min-Bisection (最小 2 等分割) 問題)

例題 : 無向グラフ $G = (V, E)$

質問 : カット辺の数が最小となる V の 2 等分割 (V_L, V_R) は?

平均時解析 (上界) : 例

例

1. L : Min-Bisection 問題, \mathcal{I}_n : n 頂点の全無向グラフの集合
2. $\begin{cases} \mathcal{G}_n & : n \text{ 頂点の全無向グラフ上の一様分布} \\ A & : (L \text{ のための}) \text{ 多項式時間アルゴリズム} \end{cases}$

定義 (Min-Bisection (最小 2 等分割) 問題)

例題 : 無向グラフ $G = (V, E)$

質問 : カット辺の数が最小となる V の 2 等分割 (V_L, V_R) は ?

事実

Min-Bisection 問題は \mathcal{NP} -困難 である .

平均時解析 (上界): 例

例

1. L : Min-Bisection, \mathcal{I}_n : n 頂点の全無向グラフの集合

2. $\begin{cases} \mathcal{G}_n & : n \text{ 頂点の全無向グラフ上の一様分布} \\ A & : (L \text{ のための}) \text{ 多項式時間アルゴリズム} \end{cases}$

3. $\sum_{J \in \mathcal{I}_n} \Pr \{I = J\} \cdot \text{time}_A(J) = \text{poly}(n)$

3'. $\Pr \{A(I) = \text{OPT}(I)\} = 1 - o_n(1)$

ただし, A は多項式時間アルゴリズム

平均時解析 (上界): 例

例

1. L : Min-Bisection, \mathcal{I}_n : n 頂点の全無向グラフの集合

2. $\begin{cases} \mathcal{G}_n & : n \text{ 頂点の全無向グラフ上の一様分布} \\ A & : (L \text{ のための}) \text{ 多項式時間アルゴリズム} \end{cases}$

3. $\sum_{J \in \mathcal{I}_n} \Pr \{I = J\} \cdot \text{time}_A(J) = \text{poly}(n)$

3'. $\Pr \{A(I) = \text{OPT}(I)\} = 1 - o_n(1)$

ただし, A は多項式時間アルゴリズム

定義 ($\mathcal{G}_{2n,p,r}$: for Min-Bisection)

$\mathcal{G}_{2n,p,r}$: 以下の PTM (パラメータ: p, r) により定義される分布:

定義 ($\mathcal{G}_{2n,p,r}$: for Min-Bisection)

$\mathcal{G}_{2n,p,r}$: 以下の PTM (パラメータ: p, r) により定義される分布:

入力 : $2n$: 頂点の個数, $V \stackrel{\text{def}}{=} \{1, \dots, n\} \cup \{-1, \dots, -n\}$

出力 : $G = (V, E)$

例題の分布 for Min-Bisection

定義 ($\mathcal{G}_{2n,p,r}$: for Min-Bisection)

$\mathcal{G}_{2n,p,r}$: 以下の PTM (パラメータ: p, r) により定義される分布:

入力 : $2n$: 頂点の個数, $V \stackrel{\text{def}}{=} \{1, \dots, n\} \cup \{-1, \dots, -n\}$

出力 : $G = (V, E)$

① $\phi \stackrel{\text{def}}{=} (V_L, V_R)$: V の (ランダムな) 2等分割

$$\left. \begin{array}{l} V_L = \{1, \dots, n\} \\ V_R = \{-1, \dots, -n\} \end{array} \right\} \longrightarrow \begin{cases} \phi(i) = 1 & i \in V_L \\ \phi(i) = -1 & i \in V_R \end{cases}$$

例題の分布 for Min-Bisection

定義 ($\mathcal{G}_{2n,p,r}$: for Min-Bisection)

$\mathcal{G}_{2n,p,r}$: 以下の PTM (パラメータ: p, r) により定義される分布:

入力 : $2n$: 頂点の個数, $V \stackrel{\text{def}}{=} \{1, \dots, n\} \cup \{-1, \dots, -n\}$

出力 : $G = (V, E)$

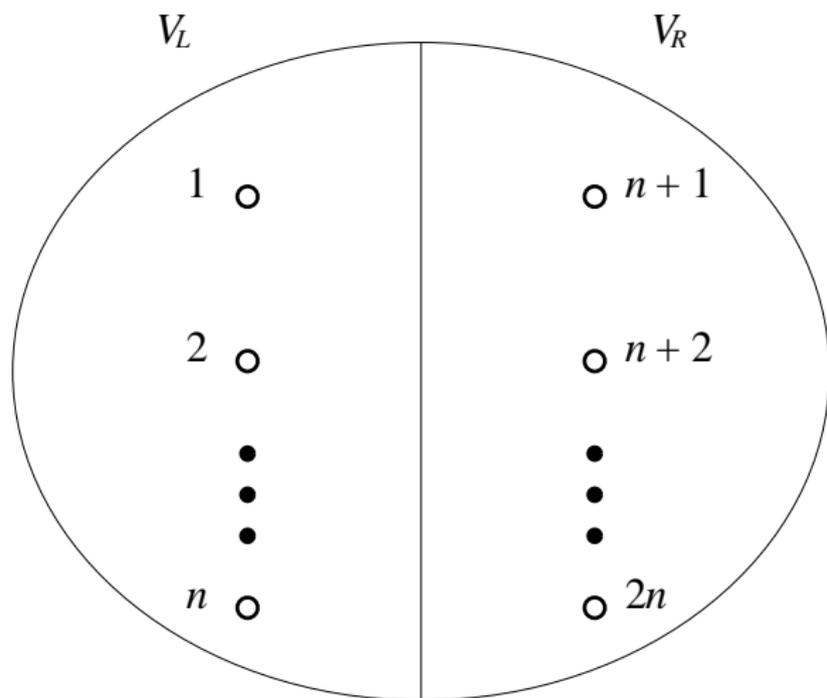
① $\phi \stackrel{\text{def}}{=} (V_L, V_R)$: V の (ランダムな) 2等分割

$$\left. \begin{array}{l} V_L = \{1, \dots, n\} \\ V_R = \{-1, \dots, -n\} \end{array} \right\} \longrightarrow \left\{ \begin{array}{ll} \phi(i) = 1 & i \in V_L \\ \phi(i) = -1 & i \in V_R \end{array} \right.$$

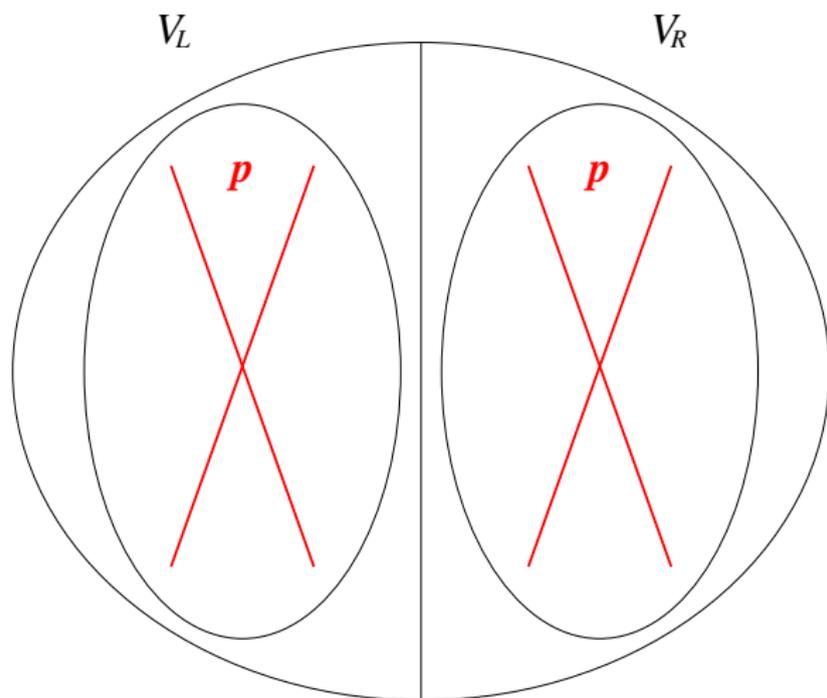
② 以下の規則で辺集合 E を生成する:

内部辺 : $\forall i \in \{L, R\}, \forall v, v' \in V_i$ $\left[\Pr\{(v, v') \in E\} = p \right]$

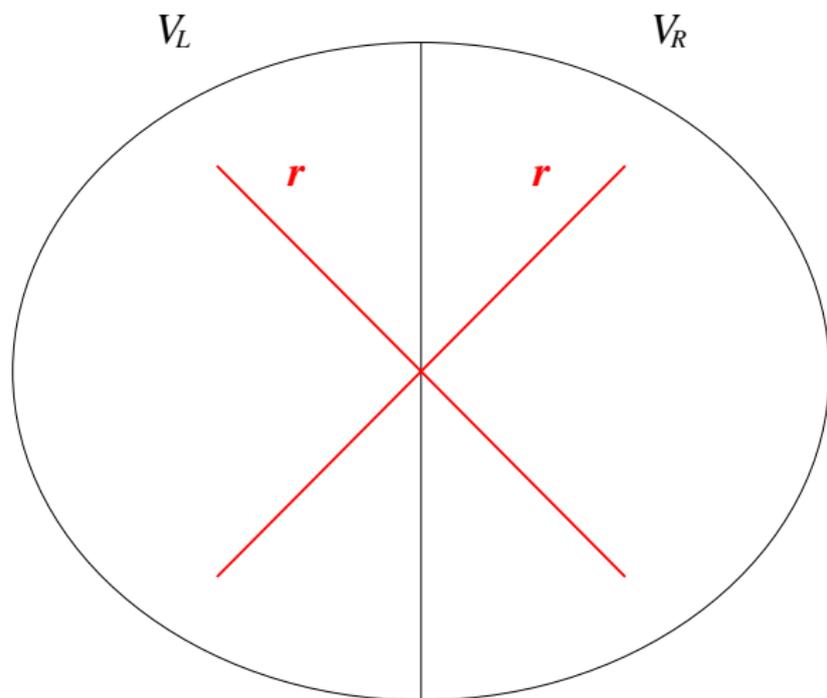
外部辺 : $\forall v \in V_L, \forall v' \in V_R$ $\left[\Pr\{(v, v') \in E\} = r \right]$



$\mathcal{G}_{2n,p,r}$ for Min-Bisection



$\mathcal{G}_{2n,p,r}$ for Min-Bisection



例題の分布 for Min-Bisection

定義 ($\mathcal{G}_{2n,p,r}$: for Min-Bisection)

$\mathcal{G}_{2n,p,r}$: 以下の PTM (パラメータ: p, r) により定義される分布:

入力 : $2n$: 頂点の個数, $V \stackrel{\text{def}}{=} \{1, \dots, n\} \cup \{-1, \dots, -n\}$

出力 : $G = (V, E)$

- ① $\phi \stackrel{\text{def}}{=} (V_L, V_R)$: V の (ランダムな) 2 等分割
- ② 以下の規則で辺集合 E を生成する:

内部辺 : $\forall i \in \{L, R\}, \forall v, v' \in V_i \quad \left[\Pr\{(v, v') \in E\} = p \right]$

外部辺 : $\forall v \in V_L, \forall v' \in V_R \quad \left[\Pr\{(v, v') \in E\} = r \right]$

例題の分布 for Min-Bisection

定義 ($\mathcal{G}_{2n,p,r}$: for Min-Bisection)

$\mathcal{G}_{2n,p,r}$: 以下の PTM (パラメータ: p, r) により定義される分布:

入力 : $2n$: 頂点の個数, $V \stackrel{\text{def}}{=} \{1, \dots, n\} \cup \{-1, \dots, -n\}$

出力 : $G = (V, E)$

- ① $\phi \stackrel{\text{def}}{=} (V_L, V_R)$: V の (ランダムな) 2 等分割
- ② 以下の規則で辺集合 E を生成する:

内部辺 : $\forall i \in \{L, R\}, \forall v, v' \in V_i \quad \left[\Pr\{(v, v') \in E\} = p \right]$

外部辺 : $\forall v \in V_L, \forall v' \in V_R \quad \left[\Pr\{(v, v') \in E\} = r \right]$

$\mathcal{G}_{2n,p,r}$: **Planted Solution Model**

命題

ある定数 $c \gg 1$ に対して $p \geq c \log n/n$ かつ $p/r \geq c$ であるならば,

$$\Pr_{G \in \mathcal{G}_{2n,p,r}} \{ \phi = \text{OPT}(G) \} = 1 - o_n(1)$$

覚え書き

$$\begin{aligned} \text{内部辺} &: \forall i \in \{L, R\}, \forall v, v' \in V_i \quad \left[\Pr\{(v, v') \in E\} = p \right] \\ \text{外部辺} &: \forall v \in V_L, \forall v' \in V_R \quad \left[\Pr\{(v, v') \in E\} = r \right] \end{aligned}$$

歴史：平均時解析 in the Planted Solution Model

頂点 3-彩色問題 : N. Alon and N. Kahale, “A spectral technique for coloring random 3-colorable graphs”, SIAM J. Comp. 26, 1997.

最大クリーク問題 : N. Alon, M. Krivelevich, and B. Sudakov
“Finding a Large Hidden Clique in a Random Graph”, SODA98, 1998.

3-SAT 問題 : A. Flaxman, “A spectral technique for random satisfiable 3CNF formulas”, SODA03, 2003.

Min-Bisection 問題 : A. Coja-Oghlan “A Spectral Heuristic for Bisecting Random Graphs”, SODA05, 2005.

MAX2SAT 問題 : Masaki Yamamoto, “A Spectral Method for MAX2SAT in the Planted Solution Model”, ISAAC07, 2007.

スペクトラル手法 (Spectral Methods)

スペクトラル手法 : Spect by Coja-Oghlan [SODA05]

$\text{Spect}(G = (V, E), p, r) \quad // \hat{A} : G \text{ の隣接 (対称) 行列}$
{

スペクトラル手法 : Spect by Coja-Oghlan [SODA05]

$\text{Spect}(G = (V, E), p, r) \quad // \hat{A} : G \text{ の隣接 (対称) 行列}$
{

Let $\hat{U} \stackrel{\text{def}}{=} \hat{A} - ((p + r)/2)J;$

スペクトラル手法 : Spect by Coja-Oghlan [SODA05]

$\text{Spect}(G = (V, E), p, r) \quad // \hat{A} : G \text{ の隣接 (対称) 行列}$
{

Let $\hat{U} \stackrel{\text{def}}{=} \hat{A} - ((p + r)/2)J;$

Calculate the largest eigenvector \mathbf{e}_1 of $\hat{U};$

スペクトラル手法 : Spect by Coja-Oghlan [SODA05]

$\text{Spect}(G = (V, E), p, r) \quad // \hat{A} : G \text{ の隣接 (対称) 行列}$
{

Let $\hat{U} \stackrel{\text{def}}{=} \hat{A} - ((p+r)/2)J;$

Calculate the largest eigenvector $\hat{\mathbf{e}}_1$ of $\hat{U};$

Let $\begin{cases} b_i = +1 & \hat{\mathbf{e}}_1(i) > 0 \\ b_i = -1 & \text{o.w.} \end{cases}$

スペクトラル手法 : Spect by Coja-Oghlan [SODA05]

Spect($G = (V, E), p, r$) // \hat{A} : G の隣接 (対称) 行列
{

Let $\hat{U} \stackrel{\text{def}}{=} \hat{A} - ((p+r)/2)J$;

Calculate the largest eigenvector $\hat{\mathbf{e}}_1$ of \hat{U} ;

Let $\begin{cases} b_i = +1 & \hat{\mathbf{e}}_1(i) > 0 \\ b_i = -1 & \text{o.w.} \end{cases}$

repeat UPDATES times do {

スペクトラル手法 : Spect by Coja-Oghlan [SODA05]

$\text{Spect}(G = (V, E), p, r) \quad // \hat{A} : G \text{ の隣接 (対称) 行列}$
{

Let $\hat{U} \stackrel{\text{def}}{=} \hat{A} - ((p + r)/2)J;$

Calculate the largest eigenvector $\hat{\mathbf{e}}_1$ of $\hat{U};$

Let $\begin{cases} b_i = +1 & \hat{\mathbf{e}}_1(i) > 0 \\ b_i = -1 & \text{o.w.} \end{cases}$

repeat UPDATES times do {
 for each $i \in V$ do (in parallel)

$b_i = +1 \quad \# \text{Pos}(i) > \# \text{Neg}(i)$
 $b_i = -1 \quad \text{o.w.}$

}
output $(b_1, \dots, b_{2n});$

}

Spect に関する定理

定理 (Coja-Oghlan; SODA05)

$$p - r = \Omega\left(\frac{\log n}{n}\right), \quad \text{UPDATES} \geq \log n$$

→

定理 (Coja-Oghlan; SODA05)

$$p - r = \Omega\left(\frac{\log n}{n}\right), \quad \text{UPDATES} \geq \log n$$

$$\longrightarrow \Pr_{G \in \mathcal{G}_{2n,p,r}} \{\text{Spect}(G, p, r) = \phi\} = 1 - o(1)$$

定理 (Coja-Oghlan; SODA05)

$$p - r = \Omega\left(\frac{\log n}{n}\right), \quad \text{UPDATES} \geq \log n$$

$$\longrightarrow \Pr_{G \in \mathcal{G}_{2n,p,r}} \{\text{Spect}(G, p, r) = \phi\} = 1 - o(1)$$

注

Coja-Oghlan [SODA05] は, $p - r = \Omega(1/n)$ (i.e., $E[|E|] = \Omega(n)$) に対する同様の結果も与えている.

スペクトラル手法 : Spect by Coja-Oghlan [SODA05]

$\text{Spect}(G = (V, E), p, r) \quad // \hat{A} : G \text{ の隣接 (対称) 行列}$
{

Let $\hat{U} \stackrel{\text{def}}{=} \hat{A} - ((p + r)/2)J;$

Calculate the largest eigenvector $\hat{\mathbf{e}}_1$ of $\hat{U};$

Let $\begin{cases} b_i = +1 & \hat{\mathbf{e}}_1(i) > 0 \\ b_i = -1 & \text{o.w.} \end{cases}$

repeat UPDATES times do {
 for each $i \in V$ do (in parallel)

$b_i = +1 \quad \# \text{Pos}(i) > \# \text{Neg}(i)$
 $b_i = -1 \quad \text{o.w.}$

}
output $(b_1, \dots, b_{2n});$

}

スペクトラル手法 : Spect by Coja-Oghlan [SODA05]

$\text{Spect}(G = (V, E), p, r) \quad // \hat{A} : G \text{ の隣接 (対称) 行列}$
{

Let $\hat{U} \stackrel{\text{def}}{=} \hat{A} - ((p + r)/2)J;$

Calculate the largest eigenvector $\hat{\mathbf{e}}_1$ of $\hat{U};$

Let $\begin{cases} b_i = +1 & \hat{\mathbf{e}}_1(i) > 0 \\ b_i = -1 & \text{o.w.} \end{cases}$

repeat UPDATES times do {
 for each $i \in V$ do (in parallel)

$b_i = +1 \quad \# \text{Pos}(i) > \# \text{Neg}(i)$
 $b_i = -1 \quad \text{o.w.}$

}
output $(b_1, \dots, b_{2n});$

}

\hat{e}_1 と ϕ について

$$\hat{U} \stackrel{\text{def}}{=} \hat{A} - \frac{p+r}{2} J$$

$$U \stackrel{\text{def}}{=} E[\hat{U}]$$

\hat{e}_1 : \hat{U} の最大固有ベクトル

e_1 : U の最大固有ベクトル

\hat{e}_1 と ϕ について

$$\hat{U} \stackrel{\text{def}}{=} \hat{A} - \frac{p+r}{2} J$$

$$U \stackrel{\text{def}}{=} E[\hat{U}]$$

\hat{e}_1 : \hat{U} の最大固有ベクトル

e_1 : U の最大固有ベクトル

事実

$$e_1 = (\underbrace{1, \dots, 1}_{n \text{ 個}}, \underbrace{-1, \dots, -1}_{n \text{ 個}})$$

\hat{e}_1 と ϕ について

$$\hat{U} \stackrel{\text{def}}{=} \hat{A} - \frac{p+r}{2} J$$

$$U \stackrel{\text{def}}{=} E[\hat{U}]$$

\hat{e}_1 : \hat{U} の最大固有ベクトル

e_1 : U の最大固有ベクトル

事実

$$e_1 = \underbrace{(1, \dots, 1)}_{n \text{ 個}}, \underbrace{(-1, \dots, -1)}_{n \text{ 個}} = \phi$$

$\hat{\mathbf{e}}_1$ と ϕ について

$$\hat{U} \stackrel{\text{def}}{=} \hat{A} - \frac{p+r}{2} J$$

$$U \stackrel{\text{def}}{=} E[\hat{U}]$$

$\hat{\mathbf{e}}_1$: \hat{U} の最大固有ベクトル

\mathbf{e}_1 : U の最大固有ベクトル

事実

$$\mathbf{e}_1 = \underbrace{(1, \dots, 1)}_{n \text{ 個}}, \underbrace{(-1, \dots, -1)}_{n \text{ 個}} = \phi$$

補題

$$\text{sgn}(\hat{\mathbf{e}}_1) \approx \text{sgn}(\mathbf{e}_1) = \phi$$

$\hat{\mathbf{e}}_1$ と ϕ について

$$\text{error}(G) \stackrel{\text{def}}{=} \{i \in V : \text{sgn}(\hat{\mathbf{e}}_1(i)) \neq \text{sgn}(\mathbf{e}_1(i))\}, \quad (\text{c.f.}, \text{sgn}(\mathbf{e}_1) = \phi)$$

$\hat{\mathbf{e}}_1$ と ϕ について

$$\text{error}(G) \stackrel{\text{def}}{=} \{i \in V : \text{sgn}(\hat{\mathbf{e}}_1(i)) \neq \text{sgn}(\mathbf{e}_1(i))\}, \quad (\text{c.f.}, \text{sgn}(\mathbf{e}_1) = \phi)$$

補題 (Coja-Oghlan; SODA05)

$$p - r = \Omega\left(\frac{\log n}{n}\right) \longrightarrow \Pr_{G \in \mathcal{G}_{2n,p,r}} \{|\text{error}(G)| = o(1)\} = 1 - o(1)$$

定理 (Coja-Oghlan; SODA05)

$$p - r = \Omega\left(\frac{\log n}{n}\right), \quad \text{UPDATES} \geq \log n$$

$$\longrightarrow \Pr_{G \in \mathcal{G}_{2n,p,r}} \{\text{Spect}(G, p, r) = \phi\} = 1 - o(1)$$

定理 (Coja-Oghlan; SODA05)

$$p - r = \Omega\left(\frac{\log n}{n}\right), \quad \text{UPDATES} \geq \log n$$

$$\longrightarrow \Pr_{G \in \mathcal{G}_{2n,p,r}} \{\text{Spect}(G, p, r) = \phi\} = 1 - o(1)$$

N. Alon and N. Kahale, “A spectral technique for coloring random 3-colorable graphs”, SIAM J. Comp. 26, 1997.

U. Feige and E. Ofek, Spectral techniques applied to sparse random graphs, Random Structure and Algorithms 27, 2005.

確率伝播 (Belief Propagation)

Pseudo-BP($G = (V, E), p, r$)
{

Pseudo-BP($G = (V, E), p, r$)

{

set $b_i = 0$ except for $b_1 = 1$;

```
Pseudo-BP( $G = (V, E), p, r$ )  
{  
    set  $b_i = 0$  except for  $b_1 = 1$ ;  
    repeat MAXTIMES times do {
```

Pseudo-BP($G = (V, E), p, r$)

{

set $b_i = 0$ except for $b_1 = 1$;

repeat MAXTIMES times do {

for each $i \in V$ do (in parallel) {

$$b_i = \sum_{j \in N_i} f_+(b_j) + \sum_{j \notin N_i} f_-(b_j);$$

};

if all b_i are stabilized, then break;

};

output $(\text{sgn}(b_1), \dots, \text{sgn}(b_{2n}))$;

}

Pseudo-BP($G = (V, E), p, r$)

{

set $b_i = 0$ except for $b_1 = 1$;

repeat MAXTIMES times do {

for each $i \in V$ do (in parallel) {

$$b_i = \sum_{j \in N_i} f_+(b_j) + \sum_{j \notin N_i} f_-(b_j);$$

};

if all b_i are stabilized, then break;

};

output ($\text{sgn}(b_1), \dots, \text{sgn}(b_{2n})$);

}

$$b_i = \sum_{j \in N_i} f_+(b_j) + \sum_{j \notin N_i} f_-(b_j)$$

$$b_i = \sum_{j \in N_i} f_+(b_j) + \sum_{j \notin N_i} f_-(b_j)$$

$$f_+(z) \stackrel{\text{def}}{=} \begin{cases} h_+ \theta_+ & z > \theta_+ \\ h_+ (-\theta_+) & z < \theta_+ \\ h_+ z & \text{o.w.} \end{cases}$$

$$f_-(z) \stackrel{\text{def}}{=} \begin{cases} h_- \theta_- & z > \theta_- \\ h_- (-\theta_-) & z < \theta_- \\ h_- z & \text{o.w.} \end{cases}$$

$h_+, \theta_+, \theta_- > 0$: p, r の関数

$h_- < 0$: p, r の関数

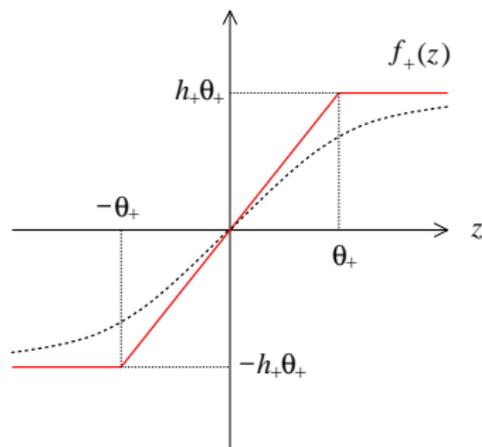
伝播規則 by Onsjö and Watanabe [ISAAC06]

$$b_i = \sum_{j \in N_i} f_+(b_j) + \sum_{j \notin N_i} f_-(b_j)$$

$$f_+(z) \stackrel{\text{def}}{=} \begin{cases} h_+ \theta_+ & z > \theta_+ \\ h_+ (-\theta_+) & z < \theta_+ \\ h_+ z & \text{o.w.} \end{cases}$$

$$f_-(z) \stackrel{\text{def}}{=} \begin{cases} h_- \theta_- & z > \theta_- \\ h_- (-\theta_-) & z < \theta_- \\ h_- z & \text{o.w.} \end{cases}$$

$h_+, \theta_+, \theta_- > 0$: p, r の関数
 $h_- < 0$: p, r の関数



Pseudo-BP($G = (V, E), p, r$)

{

set $b_i = 0$ except for $b_1 = 1$;

repeat MAXTIMES times do {

for each $i \in V$ do (in parallel) {

$$b_i = \sum_{j \in N_i} f_+(b_j) + \sum_{j \notin N_i} f_-(b_j);$$

};

if all b_i are stabilized, then break;

};

output ($\text{sgn}(b_1), \dots, \text{sgn}(b_{2n})$);

}

Pseudo-BP に関する定理

Pseudo-BP[r]: Pseudo-BP with MAXTIMES= r

Pseudo-BP に関する定理

Pseudo-BP[r]: Pseudo-BP with MAXTIMES= r

定理 (Onsjö and Watanabe; ISAAC06)

$$p - r = \Omega\left(\frac{\log n}{\sqrt{n}}\right) \longrightarrow$$

Pseudo-BP に関する定理

Pseudo-BP[r]: Pseudo-BP with MAXTIMES= r

定理 (Onsjö and Watanabe; ISAAC06)

$$p - r = \Omega\left(\frac{\log n}{\sqrt{n}}\right) \longrightarrow$$

$$\Pr_{G \in \mathcal{G}_{2n,p,r}} \{\text{Pseudo-BP}[2](G, p, r) = \phi\} = 1 - o(1)$$

Pseudo-BP に関する定理

Pseudo-BP[r]: Pseudo-BP with MAXTIMES= r

定理 (Onsjö and Watanabe; ISAAC06)

$$p - r = \Omega\left(\frac{\log n}{\sqrt{n}}\right) \longrightarrow$$

$$\Pr_{G \in \mathcal{G}_{2n,p,r}} \{\text{Pseudo-BP}[2](G, p, r) = \phi\} = 1 - o(1)$$

注

$$p - r = \Omega\left(\frac{\log n}{\sqrt{n}}\right) \longrightarrow \mathbb{E}[|E|] = \omega(n^{1.5})$$

我々のアルゴリズムとその解析

アルゴリズム：MP-threshold

MP-threshold($G = (V, E), p, r$)
{

アルゴリズム : MP-threshold

MP-threshold($G = (V, E), p, r$)
{
 set $b_i = 0$ except for $b_1 = 1$;

アルゴリズム : MP-threshold

```
MP-threshold( $G = (V, E), p, r$ )
{
    set  $b_i = 0$  except for  $b_1 = 1$ ;
    repeat MAXTIMES1 times do {
        repeat-procedure1;
    };
}
```

アルゴリズム : MP-threshold

```
MP-threshold( $G = (V, E), p, r$ )
{
    set  $b_i = 0$  except for  $b_1 = 1$ ;
    repeat MAXTIMES1 times do {
        repeat-procedure1;
    };
    repeat MAXTIMES2 times do {
        repeat-procedure2;
    };
}
```

アルゴリズム : MP-threshold

```
MP-threshold( $G = (V, E), p, r$ )
{
    set  $b_i = 0$  except for  $b_1 = 1$ ;
    repeat MAXTIMES1 times do {
        repeat-procedure1;
    };
    repeat MAXTIMES2 times do {
        repeat-procedure2;
    };
    output ( $\text{sgn}(b_1), \dots, \text{sgn}(b_{2n})$ )
}
```

```
repeat-procedure1:  
{  
    for each  $i \in V$  do (in parallel) mp-procedure( $i$ );  
};
```

repeat-procedure1:

```
{  
    for each  $i \in V$  do (in parallel) mp-procedure( $i$ );  
};
```

mp-procedure(i):

$$b_i = \sum_{j \in N_i} h'_+ b_j + \sum_{j \notin N_i} h'_- b_j;$$

repeat-procedure1:

```
{  
    for each  $i \in V$  do (in parallel) mp-procedure( $i$ );  
};
```

$$\text{mp-procedure}(i): \quad b_i = \sum_{j \in N_i} h'_+ b_j + \sum_{j \notin N_i} h'_- b_j;$$

c.f. Pseudo-BP では :

$$b_i = \sum_{j \in N_i} f_+(b_j) + \sum_{j \notin N_i} f_-(b_j);$$

repeat-procedure1:

```
{  
    for each  $i \in V$  do (in parallel) mp-procedure( $i$ );  
};
```

repeat-procedure2: // θ : 正のパラメータ

```
{  
    apply thresholds:  $\begin{cases} b_i = \theta & \text{if } b_i > \theta, \\ b_i = -\theta & \text{if } b_i < -\theta \end{cases}$   
    for each  $i \in V$  do (in parallel) mp-procedure( $i$ );  
};
```

mp-procedure(i):

$$b_i = \sum_{j \in N_i} h'_+ b_j + \sum_{j \notin N_i} h'_- b_j;$$

c.f. Pseudo-BP では :

$$b_i = \sum_{j \in N_i} f_+(b_j) + \sum_{j \notin N_i} f_-(b_j);$$

アルゴリズム : MP-threshold

```
MP-threshold( $G = (V, E), p, r$ )
{
    set  $b_i = 0$  except for  $b_1 = 1$ ;
    repeat MAXTIMES1 times do {
        repeat-procedure1;
    };
    repeat MAXTIMES2 times do {
        repeat-procedure2;
    };
    output ( $\text{sgn}(b_1), \dots, \text{sgn}(b_{2n})$ )
}
```

MP-threshold に関する定理

MP-threshold $[r_1, r_2, \alpha]$: MP-threshold with $\begin{cases} \text{MAXTIMES1} = r_1 \\ \text{MAXTIMES2} = r_2 \\ \theta = \alpha \end{cases}$

MP-threshold に関する定理

MP-threshold $[r_1, r_2, \alpha]$: MP-threshold with $\begin{cases} \text{MAXTIMES1} = r_1 \\ \text{MAXTIMES2} = r_2 \\ \theta = \alpha \end{cases}$

定理

$p - r = \Omega(\log n/n)$ であるとする .

MP-threshold に関する定理

MP-threshold $[r_1, r_2, \alpha]$: MP-threshold with $\begin{cases} \text{MAXTIMES1} = r_1 \\ \text{MAXTIMES2} = r_2 \\ \theta = \alpha \end{cases}$

定理

$p - r = \Omega(\log n/n)$ であるとする . この時 , 次のようなパラメータ :

$$\begin{aligned} r_1 &= \Omega(\log n / \log(pn)), \\ r_2 &= \Omega(\log n), \\ \alpha &= \Omega(1), \end{aligned}$$

に対して , 以下が成り立つ :

MP-threshold に関する定理

MP-threshold $[r_1, r_2, \alpha]$: MP-threshold with $\begin{cases} \text{MAXTIMES1} = r_1 \\ \text{MAXTIMES2} = r_2 \\ \theta = \alpha \end{cases}$

定理

$p - r = \Omega(\log n/n)$ であるとする . この時 , 次のようなパラメータ :

$$\begin{aligned} r_1 &= \Omega(\log n / \log(pn)), \\ r_2 &= \Omega(\log n), \\ \alpha &= \Omega(1), \end{aligned}$$

に対して , 以下が成り立つ :

$$\Pr_{G \in \mathcal{G}_{2n,p,r}} \{ \text{MP-threshold}[r_1, r_2, \alpha](G, p, r) = \phi \} = 1 - o(1)$$

定理

$p - r = \Omega(\log n/n)$ であるとする。この時、次のようなパラメータ：

$$\begin{aligned}r_1 &= \Omega(\log n / \log(pn)), \\r_2 &= \Omega(\log n), \\ \alpha &= \Omega(1),\end{aligned}$$

に対して、以下が成り立つ：

$$\Pr_{G \in \mathcal{G}_{2n,p,r}} \{ \text{MP-threshold}[r_1, r_2, \alpha](G, p, r) = \phi \} = 1 - o(1)$$

注

$$p - r = \Omega\left(\frac{\log n}{n}\right) \longrightarrow \mathbb{E}[|E|] = \Omega(n \log n)$$

Spect, Pseudo-BP との比較

Spect との比較

MP-threshold : 確率伝播のみ

Spect : 固有値計算 + 確率伝播

Spect, Pseudo-BP との比較

Spect との比較

MP-threshold : 確率伝播のみ

Spect : 固有値計算 + 確率伝播

Pseudo-BP との比較

MP-threshold : $\max\{\text{MAXTIMES1}, \text{MAXTIMES2}\} = \Omega(\log n)$

Pseudo-BP : $\text{MAXTIMES} = 2$

Spect, Pseudo-BP との比較

Spect との比較

MP-threshold : 確率伝播のみ

Spect : 固有値計算 + 確率伝播

Pseudo-BP との比較

MP-threshold : $\max\{\text{MAXTIMES1}, \text{MAXTIMES2}\} = \Omega(\log n)$
→ $E[|E|] = \Omega(n \log n)$

Pseudo-BP : $\text{MAXTIMES} = 2$
→ $E[|E|] = \omega(n^{1.5})$

repeat-procedure1:

```
{  
    for each  $i \in V$  do (in parallel) mp-procedure( $i$ );  
};
```

repeat-procedure2: // θ : 正のパラメータ

```
{  
    apply thresholds:  $\begin{cases} b_i = \theta & \text{if } b_i > \theta, \\ b_i = -\theta & \text{if } b_i < -\theta \end{cases}$   
    for each  $i \in V$  do (in parallel) mp-procedure( $i$ );  
};
```

mp-procedure(i):

$$b_i = \sum_{j \in N_i} h'_+ b_j + \sum_{j \notin N_i} h'_- b_j;$$

c.f. Pseudo-BP では :

$$b_i = \sum_{j \in N_i} f_+(b_j) + \sum_{j \notin N_i} f_-(b_j);$$

Pseudo-BP の伝播規則

$$b_i = \sum_{j \in N_i} f_+(b_j) + \sum_{j \notin N_i} f_-(b_j)$$
$$\left[\begin{array}{l} f_+(z) \\ f_-(z) \end{array} \right] \stackrel{\text{def}}{=} \left\{ \begin{array}{ll} \begin{array}{l} h_+ \theta_+ \\ h_+ (-\theta_+) \\ h_+ z \end{array} & \begin{array}{l} z > \theta_+ \\ z < \theta_+ \\ \text{o.w.} \end{array} \\ \begin{array}{l} h_- \theta_- \\ h_- (-\theta_-) \\ h_- z \end{array} & \begin{array}{l} z > \theta_- \\ z < \theta_- \\ \text{o.w.} \end{array} \end{array} \right.$$

伝播規則

$$b_i = \sum_{j \in N_i} f_+(b_j) + \sum_{j \notin N_i} f_-(b_j)$$
$$\left[\begin{array}{l} f_+(z) \\ f_-(z) \end{array} \right] \stackrel{\text{def}}{=} \left\{ \begin{array}{ll} \begin{array}{l} h_+ \theta_+ \\ h_+ (-\theta_+) \\ h_+ z \end{array} & \begin{array}{l} z > \theta_+ \\ z < \theta_+ \\ \text{o.w.} \end{array} \\ \begin{array}{l} h_- \theta_- \\ h_- (-\theta_-) \\ h_- z \end{array} & \begin{array}{l} z > \theta_- \\ z < \theta_- \\ \text{o.w.} \end{array} \end{array} \right.$$

$$b_i = \sum_{j \in N_i} f_+(b_j) + \sum_{j \notin N_i} f_-(b_j) \quad \left[\begin{array}{l} f_+(z) \stackrel{\text{def}}{=} h_+ z \\ f_-(z) \stackrel{\text{def}}{=} h_- z \end{array} \right.$$

伝播規則

$$b_i = \sum_{j \in N_i} f_+(b_j) + \sum_{j \notin N_i} f_-(b_j) \quad \left[\begin{array}{l} f_+(z) \stackrel{\text{def}}{=} h_+ z \\ f_-(z) \stackrel{\text{def}}{=} h_- z \end{array} \right.$$

$$\implies b_i = \sum_{j \in N_i} h_+ b_j + \sum_{j \notin N_i} h_- b_j$$

$$b_i = \sum_{j \in N_i} f_+(b_j) + \sum_{j \notin N_i} f_-(b_j) \quad \left[\begin{array}{l} f_+(z) \stackrel{\text{def}}{=} h_+ z \\ f_-(z) \stackrel{\text{def}}{=} h_- z \end{array} \right.$$

$$\begin{aligned} \Rightarrow \quad b_i &= \sum_{j \in N_i} h_+ b_j + \sum_{j \notin N_i} h_- b_j \\ &= \sum_j a_{ij} h_+ b_j + \sum_j (1 - a_{ij}) h_- b_j \end{aligned}$$

$$b_i = \sum_{j \in N_i} f_+(b_j) + \sum_{j \notin N_i} f_-(b_j) \quad \left[\begin{array}{l} f_+(z) \stackrel{\text{def}}{=} h_+ z \\ f_-(z) \stackrel{\text{def}}{=} h_- z \end{array} \right.$$

$$\begin{aligned} \Rightarrow \quad b_i &= \sum_{j \in N_i} h_+ b_j + \sum_{j \notin N_i} h_- b_j \\ &= \sum_j a_{ij} h_+ b_j + \sum_j (1 - a_{ij}) h_- b_j \\ &= h_+ \hat{A} \mathbf{b} + h_- (J - \hat{A}) \mathbf{b} \end{aligned}$$

$$b_i = \sum_{j \in N_i} f_+(b_j) + \sum_{j \notin N_i} f_-(b_j) \quad \left[\begin{array}{l} f_+(z) \stackrel{\text{def}}{=} h_+ z \\ f_-(z) \stackrel{\text{def}}{=} h_- z \end{array} \right.$$

$$\begin{aligned} \Rightarrow \quad b_i &= \sum_{j \in N_i} h_+ b_j + \sum_{j \notin N_i} h_- b_j \\ &= \sum_j a_{ij} h_+ b_j + \sum_j (1 - a_{ij}) h_- b_j \\ &= h_+ \hat{A} \mathbf{b} + h_- (J - \hat{A}) \mathbf{b} \\ &= \left((h_+ - h_-) \hat{A} + h_- J \right) \mathbf{b} \end{aligned}$$

伝播規則の行列表現

$$\mathbf{b} = \left((h_+ - h_-)\hat{A} + h_-J \right) \mathbf{b}$$

伝播規則の行列表現

$$\mathbf{b} = \left((h_+ - h_-)\hat{A} + h_-J \right) \mathbf{b}$$

$b_i^{(k)}$: k 回の伝播後の頂点 i の信念
 $\mathbf{b}^{(k)}$: $b_i^{(k)}$ のベクトル

伝播規則の行列表現

$$\mathbf{b} = \left((h_+ - h_-)\hat{A} + h_-J \right) \mathbf{b}$$

$b_i^{(k)}$: k 回の伝播後の頂点 i の信念
 $\mathbf{b}^{(k)}$: $b_i^{(k)}$ のベクトル

伝播規則の漸化式表現

$$\mathbf{b}^{(k)} = \left((h_+ - h_-)\hat{A} + h_-J \right) \mathbf{b}^{(k-1)}$$

覚え書き

$$\mathbf{b}^{(k)} = \left((h_+ - h_-)\widehat{A} + h_-J \right) \mathbf{b}^{(k-1)}$$

$$\left. \begin{aligned} h_+ &= \frac{p-r}{p+r} \\ h_- &= -\frac{p-r}{2-(p+r)} \end{aligned} \right\}$$

覚え書き

$$\mathbf{b}^{(k)} = \left((h_+ - h_-)\widehat{A} + h_-J \right) \mathbf{b}^{(k-1)}$$

$$\left. \begin{array}{l} h_+ = \frac{p-r}{p+r} \\ h_- = -\frac{p-r}{2-(p+r)} \end{array} \right\} \xrightarrow{\text{c.f. } \frac{h_-}{h_+} = \frac{h'_-}{h'_+}} \left\{ \begin{array}{l} h'_+ = 1 - \frac{p+r}{2} \\ h'_- = -\frac{p+r}{2} \end{array} \right.$$

覚え書き

$$\mathbf{b}^{(k)} = \left((h_+ - h_-)\hat{A} + h_- J \right) \mathbf{b}^{(k-1)}$$

$$\begin{aligned} \mathbf{b}^{(k)} &= \left((h'_+ - h'_-)\hat{A} + h'_- J \right) \mathbf{b}^{(k-1)} \\ &= \left(\hat{A} - \frac{p+r}{2} J \right) \mathbf{b}^{(k-1)} \end{aligned}$$

覚え書き

$$\mathbf{b}^{(k)} = \left((h_+ - h_-)\widehat{A} + h_-J \right) \mathbf{b}^{(k-1)}$$

$$\begin{aligned} \mathbf{b}^{(k)} &= \left((h'_+ - h'_-)\widehat{A} + h'_-J \right) \mathbf{b}^{(k-1)} \\ &= \underbrace{\left(\widehat{A} - \frac{p+r}{2}J \right)}_{\text{Spect の行列 } \widehat{U}} \mathbf{b}^{(k-1)} \end{aligned}$$

覚え書き

$$\mathbf{b}^{(k)} = \left((h_+ - h_-)\widehat{A} + h_-J \right) \mathbf{b}^{(k-1)}$$

$$\begin{aligned}\mathbf{b}^{(k)} &= \left((h'_+ - h'_-)\widehat{A} + h'_-J \right) \mathbf{b}^{(k-1)} \\ &= \underbrace{\left(\widehat{A} - \frac{p+r}{2}J \right)}_{\text{Spect の行列 } \widehat{U}} \mathbf{b}^{(k-1)} \\ &= \widehat{U} \cdot \mathbf{b}^{(k-1)}\end{aligned}$$

覚え書き

$$\mathbf{b}^{(k)} = \left((h_+ - h_-)\hat{A} + h_- J \right) \mathbf{b}^{(k-1)}$$

$$\mathbf{b}^{(k)} = \left((h'_+ - h'_-)\hat{A} + h'_- J \right) \mathbf{b}^{(k-1)}$$

$$= \underbrace{\left(\hat{A} - \frac{p+r}{2} J \right)}_{\text{Spect の行列 } \hat{U}} \mathbf{b}^{(k-1)}$$

$$= \hat{U} \cdot \mathbf{b}^{(k-1)} \quad (\text{確率伝播規則からの導出})$$

覚え書き

$$\mathbf{b}^{(k)} = \left((h_+ - h_-)\hat{A} + h_-J \right) \mathbf{b}^{(k-1)}$$

$$\begin{aligned}\mathbf{b}^{(k)} &= \left((h'_+ - h'_-)\hat{A} + h'_-J \right) \mathbf{b}^{(k-1)} \\ &= \underbrace{\left(\hat{A} - \frac{p+r}{2}J \right)}_{\text{Spect の行列 } \hat{U}} \mathbf{b}^{(k-1)} \\ &= \hat{U} \cdot \mathbf{b}^{(k-1)} \quad (\text{確率伝播規則からの導出}) \\ &= \hat{U}^k \cdot \mathbf{b}^{(0)}\end{aligned}$$

$|\widehat{\lambda}_1| \geq \cdots \geq |\widehat{\lambda}_{2n}|$: \widehat{U} の固有値
 $\widehat{\mathbf{e}}_1, \dots, \widehat{\mathbf{e}}_{2n}$: \widehat{U} の固有ベクトル

$$\begin{aligned} |\widehat{\lambda}_1| \geq \cdots \geq |\widehat{\lambda}_{2n}| & : \widehat{U} \text{ の固有値} \\ \widehat{\mathbf{e}}_1, \dots, \widehat{\mathbf{e}}_{2n} & : \widehat{U} \text{ の固有ベクトル} \\ \mathbf{b}^{(0)} & : (1, \underbrace{0, \dots, 0}_{2n-1 \text{ 個}}) \end{aligned}$$

$$\begin{aligned} |\widehat{\lambda}_1| \geq \cdots \geq |\widehat{\lambda}_{2n}| & : \widehat{U} \text{ の固有値} \\ \widehat{\mathbf{e}}_1, \dots, \widehat{\mathbf{e}}_{2n} & : \widehat{U} \text{ の固有ベクトル} \\ \mathbf{b}^{(0)} & : (1, \underbrace{0, \dots, 0}_{2n-1 \text{ 個}}) = \sum_{i=1}^{2n} c_i \widehat{\mathbf{e}}_i, \quad (c_i = (\mathbf{b}^{(0)}, \widehat{\mathbf{e}}_i)) \end{aligned}$$

$|\widehat{\lambda}_1| \geq \dots \geq |\widehat{\lambda}_{2n}|$: \widehat{U} の固有値

$\widehat{\mathbf{e}}_1, \dots, \widehat{\mathbf{e}}_{2n}$: \widehat{U} の固有ベクトル

$\mathbf{b}^{(0)}$: $(1, \underbrace{0, \dots, 0}_{2n-1 \text{ 個}}) = \sum_{i=1}^{2n} c_i \widehat{\mathbf{e}}_i, \quad (c_i = (\mathbf{b}^{(0)}, \widehat{\mathbf{e}}_i))$

$$\mathbf{b}^{(k)} = \widehat{U}^k \cdot \mathbf{b}^{(0)} = \widehat{U}^k \sum_{i=1}^{2n} c_i \widehat{\mathbf{e}}_i$$

$|\widehat{\lambda}_1| \geq \dots \geq |\widehat{\lambda}_{2n}|$: \widehat{U} の固有値

$\widehat{\mathbf{e}}_1, \dots, \widehat{\mathbf{e}}_{2n}$: \widehat{U} の固有ベクトル

$\mathbf{b}^{(0)}$: $(1, \underbrace{0, \dots, 0}_{2n-1 \text{ 個}}) = \sum_{i=1}^{2n} c_i \widehat{\mathbf{e}}_i$ ($c_i = (\mathbf{b}^{(0)}, \widehat{\mathbf{e}}_i)$)

$$\begin{aligned} \mathbf{b}^{(k)} &= \widehat{U}^k \cdot \mathbf{b}^{(0)} = \widehat{U}^k \sum_{i=1}^{2n} c_i \widehat{\mathbf{e}}_i \\ &= \widehat{\lambda}_1^k c_1 \widehat{\mathbf{e}}_1 + \widehat{\lambda}_2^k c_2 \widehat{\mathbf{e}}_2 + \dots + \widehat{\lambda}_{2n}^k c_{2n} \widehat{\mathbf{e}}_{2n} \end{aligned}$$

$|\widehat{\lambda}_1| \geq \dots \geq |\widehat{\lambda}_{2n}|$: \widehat{U} の固有値

$\widehat{\mathbf{e}}_1, \dots, \widehat{\mathbf{e}}_{2n}$: \widehat{U} の固有ベクトル

$\mathbf{b}^{(0)}$: $(1, \underbrace{0, \dots, 0}_{2n-1 \text{ 個}}) = \sum_{i=1}^{2n} c_i \widehat{\mathbf{e}}_i$, $(c_i = (\mathbf{b}^{(0)}, \widehat{\mathbf{e}}_i))$

$$\begin{aligned}\mathbf{b}^{(k)} &= \widehat{U}^k \cdot \mathbf{b}^{(0)} = \widehat{U}^k \sum_{i=1}^{2n} c_i \widehat{\mathbf{e}}_i \\ &= \widehat{\lambda}_1^k c_1 \widehat{\mathbf{e}}_1 + \widehat{\lambda}_2^k c_2 \widehat{\mathbf{e}}_2 + \dots + \widehat{\lambda}_{2n}^k c_{2n} \widehat{\mathbf{e}}_{2n} \\ &= \widehat{\lambda}_1^k \left(c_1 \widehat{\mathbf{e}}_1 + \left(\frac{\widehat{\lambda}_2}{\widehat{\lambda}_1} \right)^k c_2 \widehat{\mathbf{e}}_2 + \dots + \left(\frac{\widehat{\lambda}_{2n}}{\widehat{\lambda}_1} \right)^k c_{2n} \widehat{\mathbf{e}}_{2n} \right)\end{aligned}$$

$|\widehat{\lambda}_1| \geq \dots \geq |\widehat{\lambda}_{2n}|$: \widehat{U} の固有値

$\widehat{\mathbf{e}}_1, \dots, \widehat{\mathbf{e}}_{2n}$: \widehat{U} の固有ベクトル

$\mathbf{b}^{(0)}$: $(1, \underbrace{0, \dots, 0}_{2n-1 \text{ 個}}) = \sum_{i=1}^{2n} c_i \widehat{\mathbf{e}}_i, \quad (c_i = (\mathbf{b}^{(0)}, \widehat{\mathbf{e}}_i))$

$$\mathbf{b}^{(k)} = \widehat{\lambda}_1^k \left(c_1 \widehat{\mathbf{e}}_1 + \left(\frac{\widehat{\lambda}_2}{\widehat{\lambda}_1} \right)^k c_2 \widehat{\mathbf{e}}_2 + \dots + \left(\frac{\widehat{\lambda}_{2n}}{\widehat{\lambda}_1} \right)^k c_{2n} \widehat{\mathbf{e}}_{2n} \right)$$

事実

$$|\widehat{\lambda}_1| > |\widehat{\lambda}_2| \longrightarrow \mathbf{b}^{(k)} \approx \widehat{\lambda}_1^k c_1 \widehat{\mathbf{e}}_1 \quad \text{as } k \rightarrow \infty$$

事実

$$|\hat{\lambda}_1| > |\hat{\lambda}_2| \longrightarrow \mathbf{b}^{(k)} \approx \hat{\lambda}_1^k c_1 \mathbf{e}_1 \quad \text{as } k \rightarrow \infty$$

事実

$$|\hat{\lambda}_1| > |\hat{\lambda}_2| \longrightarrow \mathbf{b}^{(k)} \approx \hat{\lambda}_1^k c_1 \hat{\mathbf{e}}_1 \quad \text{as } k \rightarrow \infty$$

補題 (Coja-Oghlan)

$$\Pr_{G \in \mathcal{G}_{2n,p,r}} \{ \text{sgn}(\hat{\mathbf{e}}_1) \approx \phi \} = 1 - o(1)$$

事実

$$|\hat{\lambda}_1| > |\hat{\lambda}_2| \longrightarrow \mathbf{b}^{(k)} \approx \hat{\lambda}_1^k c_1 \hat{\mathbf{e}}_1 \quad \text{as } k \rightarrow \infty$$

補題 (Coja-Oghlan)

$$\Pr_{G \in \mathcal{G}_{2n,p,r}} \{ \text{sgn}(\hat{\mathbf{e}}_1) \approx \phi \} = 1 - o(1)$$

系 (Watanabe and Yamamoto)

$$\Pr_{G \in \mathcal{G}_{2n,p,r}} \{ \text{sgn}(\mathbf{b}^{(k)}) \approx \phi \} = 1 - o(1)$$

repeat-procedure1:

```
{  
    for each  $i \in V$  do (in parallel) mp-procedure( $i$ );  
};
```

repeat-procedure2: // θ : 正のパラメータ

```
{  
    apply thresholds:  $\begin{cases} b_i = \theta & \text{if } b_i > \theta, \\ b_i = -\theta & \text{if } b_i < -\theta \end{cases}$   
    for each  $i \in V$  do (in parallel) mp-procedure( $i$ );  
};
```

mp-procedure(i):

$$b_i = \sum_{j \in N_i} h'_+ b_j + \sum_{j \notin N_i} h'_- b_j;$$

c.f. Pseudo-BP では :

$$b_i = \sum_{j \in N_i} f_+(b_j) + \sum_{j \notin N_i} f_-(b_j);$$

$$\text{error}(G) \stackrel{\text{def}}{=} \text{error}_L \cup \text{error}_R$$

$$\begin{aligned}\text{error}(G) &\stackrel{\text{def}}{=} \text{error}_L \cup \text{error}_R \\ \text{error}_L &\stackrel{\text{def}}{=} \left\{ i \in V_L : \mathbf{b}^{(k)}(i) < \theta \right\} \\ \text{error}_R &\stackrel{\text{def}}{=} \left\{ i \in V_R : \mathbf{b}^{(k)}(i) > -\theta \right\}\end{aligned}$$

$$\begin{aligned}\text{error}(G) &\stackrel{\text{def}}{=} \text{error}_L \cup \text{error}_R \\ \text{error}_L &\stackrel{\text{def}}{=} \left\{ i \in V_L : \mathbf{b}^{(k)}(i) < \theta \right\} \\ \text{error}_R &\stackrel{\text{def}}{=} \left\{ i \in V_R : \mathbf{b}^{(k)}(i) > -\theta \right\}\end{aligned}$$

補題 (Watanabe and Yamamoto)

$$\Pr_{G \in \mathcal{G}_{2n,p,r}} \{ |\text{error}(G)| = o(1) \} = 1 - o(1)$$

補題 (Watanabe and Yamamoto)

$$\Pr_{G \in \mathcal{G}_{2n,p,r}} \{ \text{Repeat1}(G) \text{ almost recovers} \} = 1 - o(1)$$

補題 (Watanabe and Yamamoto)

$$\Pr_{G \in \mathcal{G}_{2n,p,r}} \{\text{Repeat1}(G) \text{ almost recovers}\} = 1 - o(1)$$

補題 (Watanabe and Yamamoto)

$$\Pr_{G \in \mathcal{G}_{2n,p,r}} \{\text{Repeat2}(G) = \phi \mid \text{Repeat1}(G) \approx \phi\} = 1 - o(1)$$

補題 (Watanabe and Yamamoto)

$$\Pr_{G \in \mathcal{G}_{2n,p,r}} \{\text{Repeat1}(G) \text{ almost recovers}\} = 1 - o(1)$$

補題 (Watanabe and Yamamoto)

$$\Pr_{G \in \mathcal{G}_{2n,p,r}} \{\text{Repeat2}(G) = \phi \mid \text{Repeat1}(G) \approx \phi\} = 1 - o(1)$$

定理 (Watanabe and Yamamoto)

$$\Pr_{G \in \mathcal{G}_{2n,p,r}} \{\text{MP-threshold}(G, p, r) = \phi\} = 1 - o(1)$$

ま と め

定理

$$\Pr_{G \in \mathcal{G}_{2n,p,r}} \{ \text{MP-threshold}(G, p, r) = \phi \} = 1 - o(1)$$

定理

$$\Pr_{G \in \mathcal{G}_{2n,p,r}} \{ \text{MP-threshold}(G, p, r) = \phi \} = 1 - o(1)$$

Spect との比較

MP-threshold : 確率伝播のみ

Spect : 固有値計算 + 確率伝播

Pseudo-BP との比較

MP-threshold : $\max\{\text{MAXTIMES1}, \text{MAXTIMES2}\} = \Omega(\log n)$

Pseudo-BP : $\text{MAXTIMES} = 2$

今後の課題

```
MP-threshold( $G = (V, E), p, r$ ) // 一つの repeat 文
{
    set  $b_i = 0$  except for  $b_1 = 1$ ;
    repeat MAXTIMES times do {
        repeat-procedure;
    };
}

repeat-procedure: //  $\theta$  : 正のパラメータ
{
    apply thresholds:  $\begin{cases} b_i = \theta & \text{if } b_i > \theta, \\ b_i = -\theta & \text{if } b_i < -\theta \end{cases}$ 
    for each  $i \in V$  do (in parallel) mp-procedure( $i$ );
};
```