A Large-Deviation Analysis for the Maximum-Likelihood Learning of Tree Structures

Vincent Tan [†] Animashree Anandkumar [†]*, Lang Tong * and Alan Willsky [†]

> [†]Stochastic Systems Group, LIDS, Massachusetts Institute of Technology

> > *School of ECE, Cornell University

ISIT (Jun 30, 2009)

不得た 不良た 不良た

- Given a set of *n* i.i.d. samples drawn from *P*, a tree distribution.
- Maximum-Likelihood (ML) learning of the structure.

< ロ > < 同 > < 回 > < 回 >

- Given a set of *n* i.i.d. samples drawn from *P*, a tree distribution.
- Maximum-Likelihood (ML) learning of the structure.
- Large-Deviation analysis of the error in learning of the set of edges or the structure.

- Given a set of *n* i.i.d. samples drawn from *P*, a tree distribution.
- Maximum-Likelihood (ML) learning of the structure.
- Large-Deviation analysis of the error in learning of the set of edges or the structure.
- Questions:



When does the error probability decay exponentially with *n*?

★ ∃ > < ∃ >

- Given a set of *n* i.i.d. samples drawn from *P*, a tree distribution.
- Maximum-Likelihood (ML) learning of the structure.
- Large-Deviation analysis of the error in learning of the set of edges or the structure.
- Questions:



- When does the error probability decay exponentially with n?
- What is the exact rate of decay of the probability of error?

A B F A B F

- Given a set of *n* i.i.d. samples drawn from *P*, a tree distribution.
- Maximum-Likelihood (ML) learning of the structure.
- Large-Deviation analysis of the error in learning of the set of edges or the structure.
- Questions:



- When does the error probability decay exponentially with n?
- What is the exact rate of decay of the probability of error?
- How does the rate (error exponent) depend on the parameters of the distribution?

< 同 ト < 三 ト < 三 ト

Main Results

- Almost every (true) tree distribution results in exponential decay.
- Quantify the exact rate of decay for a given P.

< 同 ト < 三 ト < 三 ト

Main Results

- Almost every (true) tree distribution results in exponential decay.
- Quantify the exact rate of decay for a given P.
- Rate of decay \approx SNR for learning (Intuitively appealing).

• Assume we have a set of samples $\mathbf{x}^n = {\mathbf{x}_1, \mathbf{x}_2, ..., \mathbf{x}_n}$ each drawn i.i.d. from $P \in \mathcal{P}(\mathcal{X}^d)$, where \mathcal{X} is a finite set.

• Assume we have a set of samples $\mathbf{x}^n = {\mathbf{x}_1, \mathbf{x}_2, ..., \mathbf{x}_n}$ each drawn i.i.d. from $P \in \mathcal{P}(\mathcal{X}^d)$, where \mathcal{X} is a finite set.

•
$$\mathbf{x} = (x_1, \ldots, x_d) \in \mathcal{X}^d$$
.

• Assume we have a set of samples $\mathbf{x}^n = {\mathbf{x}_1, \mathbf{x}_2, ..., \mathbf{x}_n}$ each drawn i.i.d. from $P \in \mathcal{P}(\mathcal{X}^d)$, where \mathcal{X} is a finite set.

•
$$\mathbf{x} = (x_1, \ldots, x_d) \in \mathcal{X}^d.$$

• Vertex set: $\mathcal{V} := \{1, \ldots, d\}$. Edge set: $\mathcal{E}_P \subset {\binom{\mathcal{V}}{2}}$.

くほと くほと くほとう

• Assume we have a set of samples $\mathbf{x}^n = {\mathbf{x}_1, \mathbf{x}_2, ..., \mathbf{x}_n}$ each drawn i.i.d. from $P \in \mathcal{P}(\mathcal{X}^d)$, where \mathcal{X} is a finite set.

•
$$\mathbf{x} = (x_1, \ldots, x_d) \in \mathcal{X}^d.$$

- Vertex set: $\mathcal{V} := \{1, \ldots, d\}$. Edge set: $\mathcal{E}_P \subset {\binom{\mathcal{V}}{2}}$.
 - P(x) is Markov on T_P = (V, E_P), a tree.
 - $P(\mathbf{x})$ factorizes according to T_P .
 - Example for *P* with d = 4.

• Assume we have a set of samples $\mathbf{x}^n = {\mathbf{x}_1, \mathbf{x}_2, ..., \mathbf{x}_n}$ each drawn i.i.d. from $P \in \mathcal{P}(\mathcal{X}^d)$, where \mathcal{X} is a finite set.

•
$$\mathbf{x} = (x_1, \ldots, x_d) \in \mathcal{X}^d.$$

- Vertex set: $\mathcal{V} := \{1, \ldots, d\}$. Edge set: $\mathcal{E}_P \subset {\binom{\mathcal{V}}{2}}$.
 - *P*(**x**) is Markov on *T*_{*P*} = (*V*, *E*_{*P*}), a tree.
 - $P(\mathbf{x})$ factorizes according to T_P .
 - Example for *P* with d = 4.



• Assume we have a set of samples $\mathbf{x}^n = {\mathbf{x}_1, \mathbf{x}_2, ..., \mathbf{x}_n}$ each drawn i.i.d. from $P \in \mathcal{P}(\mathcal{X}^d)$, where \mathcal{X} is a finite set.

•
$$\mathbf{x} = (x_1, \ldots, x_d) \in \mathcal{X}^d.$$

- Vertex set: $\mathcal{V} := \{1, \ldots, d\}$. Edge set: $\mathcal{E}_P \subset {\binom{\mathcal{V}}{2}}$.
 - $P(\mathbf{x})$ is Markov on $T_P = (\mathcal{V}, \mathcal{E}_P)$, a tree.
 - $P(\mathbf{x})$ factorizes according to T_P .
 - Example for *P* with d = 4.



$$P(\mathbf{x}) = P_1(x_1) \times \frac{P_{1,2}(x_1, x_2)}{P_1(x_1)} \times \frac{P_{1,3}(x_1, x_3)}{P_1(x_1)} \times \frac{P_{1,4}(x_1, x_4)}{P_1(x_1)}.$$

5/17 Vincent Tan (MIT)

Large-Deviations for Learning Trees

ISIT 5/17

イロト イ団ト イヨト イヨト

• Solve the ML problem given $\mathbf{x}^n = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$

$$P_{\mathsf{ML}} = \underset{Q \in \mathrm{Trees}}{\operatorname{argmax}} \log Q^n(\mathbf{x}^n).$$

э

< ロ > < 同 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

• Solve the ML problem given $\mathbf{x}^n = {\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n}$

$$P_{\mathsf{ML}} = \underset{Q \in \mathrm{Trees}}{\operatorname{argmax}} \log Q^n(\mathbf{x}^n).$$

• $\widehat{P}(\mathbf{x}) = \widehat{P}_{\mathbf{x}^n}(\mathbf{x})$: the empirical distribution of \mathbf{x}^n .

< ロ > < 同 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

• Solve the ML problem given $\mathbf{x}^n = {\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n}$

$$P_{\mathsf{ML}} = \underset{Q \in \mathrm{Trees}}{\operatorname{argmax}} \log Q^n(\mathbf{x}^n).$$

- $\widehat{P}(\mathbf{x}) = \widehat{P}_{\mathbf{x}^n}(\mathbf{x})$: the empirical distribution of \mathbf{x}^n .
- \widehat{P}_e : the pairwise marginal of \widehat{P} on edge e = (i, j).

• Solve the ML problem given $\mathbf{x}^n = {\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n}$

$$P_{\mathsf{ML}} = \underset{Q \in \mathrm{Trees}}{\operatorname{argmax}} \log Q^n(\mathbf{x}^n).$$

- $\widehat{P}(\mathbf{x}) = \widehat{P}_{\mathbf{x}^n}(\mathbf{x})$: the empirical distribution of \mathbf{x}^n .
- \hat{P}_e : the pairwise marginal of \hat{P} on edge e = (i, j).
- Reduces to a max-weight spanning tree problem (Chow-Liu 1968)

$$\mathcal{E}_{\mathsf{ML}} = \operatorname*{argmax}_{\mathcal{E}_Q: \, Q \in \mathrm{Trees}} \, \sum_{e \in \mathcal{E}_Q} I(\widehat{P}_e),$$

くぼう くほう くほう しほ

• Solve the ML problem given $\mathbf{x}^n = {\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n}$

$$P_{\mathsf{ML}} = \underset{Q \in \mathrm{Trees}}{\operatorname{argmax}} \log Q^n(\mathbf{x}^n).$$

- $\widehat{P}(\mathbf{x}) = \widehat{P}_{\mathbf{x}^n}(\mathbf{x})$: the empirical distribution of \mathbf{x}^n .
- \hat{P}_e : the pairwise marginal of \hat{P} on edge e = (i, j).
- Reduces to a max-weight spanning tree problem (Chow-Liu 1968)

$$\mathcal{E}_{\mathsf{ML}} = \operatorname*{argmax}_{\mathcal{E}_{\mathcal{Q}}: \mathcal{Q} \in \mathrm{Trees}} \sum_{e \in \mathcal{E}_{\mathcal{Q}}} I(\widehat{P}_{e}), \qquad I(\widehat{P}_{e}) := \sum_{x_{i}, x_{j}} \widehat{P}_{i,j}(x_{i}, x_{j}) \log \frac{\widehat{P}_{i,j}(x_{i}, x_{j})}{\widehat{P}_{i}(x_{i})\widehat{P}_{j}(x_{j})}.$$

• Samples $\Rightarrow \{I(\widehat{P}_e) : e \in \binom{\mathcal{V}}{2}\} \Rightarrow$ max-weight spanning tree.

イベト イモト イモト



æ

イロン イロン イヨン イヨン





True MIs $\{I(P_e)\}$

Max-weight spanning tree \mathcal{E}_P

ISIT 6 / 17

H N



ISIT 6 / 17



• Define \mathcal{E}_{ML} to be the ML edge set and the error event to be:

$$\{\mathcal{E}_{\mathsf{ML}}\neq\mathcal{E}_{P}\}$$
.

< ロ > < 同 > < 回 > < 回 >

• Define \mathcal{E}_{ML} to be the ML edge set and the error event to be:

$$\{\mathcal{E}_{\mathsf{ML}} \neq \mathcal{E}_{P}\}$$
.



nac

• Define \mathcal{E}_{ML} to be the ML edge set and the error event to be:

$$\{\mathcal{E}_{\mathsf{ML}} \neq \mathcal{E}_{P}\}$$
.



• Find the error exponent *K*_{*P*}:

$$K_P := \lim_{n \to \infty} -\frac{1}{n} \log \mathbb{P}\left(\{\mathcal{E}_{\mathsf{ML}} \neq \mathcal{E}_P\}\right).$$

∃ >

• Define \mathcal{E}_{ML} to be the ML edge set and the error event to be:

$$\{\mathcal{E}_{\mathsf{ML}} \neq \mathcal{E}_{P}\}$$
.



• Find the error exponent *K*_{*P*}:

$$K_P := \lim_{n \to \infty} -\frac{1}{n} \log \mathbb{P}\left(\left\{\mathcal{E}_{\mathsf{ML}} \neq \mathcal{E}_P\right\}\right).$$

• Alternatively, $\mathbb{P}(\{\mathcal{E}_{\mathsf{ML}} \neq \mathcal{E}_{P}\}) \doteq \exp(-nK_{P}).$

• Define \mathcal{E}_{ML} to be the ML edge set and the error event to be:

$$\{\mathcal{E}_{\mathsf{ML}} \neq \mathcal{E}_{P}\}$$
.



• Find the error exponent *K*_{*P*}:

$$K_P := \lim_{n \to \infty} -\frac{1}{n} \log \mathbb{P}\left(\left\{\mathcal{E}_{\mathsf{ML}} \neq \mathcal{E}_P\right\}\right).$$

- Alternatively, $\mathbb{P}(\{\mathcal{E}_{\mathsf{ML}} \neq \mathcal{E}_{P}\}) \doteq \exp(-nK_{P}).$
- Easier to consider crossover events first.

ISIT 7 / 17



ISIT 8 / 17

<ロト <回 > < 回 > < 回 > < 回 > … 回



Given two node pairs $e, e' \in \binom{\mathcal{V}}{2}$ with distribution $P_{e,e'} \in \mathcal{P}(\mathcal{X}^4)$, s.t. $I(P_e) > I(P_{e'}).$

Given two node pairs $e, e' \in \binom{\mathcal{V}}{2}$ with distribution $P_{e,e'} \in \mathcal{P}(\mathcal{X}^4)$, s.t. $I(P_e) > I(P_{e'}).$

Consider the crossover event of the empirical mutual informations

 $\{I(\widehat{P}_e) \leq I(\widehat{P}_{e'})\}.$

< 回 > < 回 > < 回 >

Given two node pairs $e, e' \in \binom{\mathcal{V}}{2}$ with distribution $P_{e,e'} \in \mathcal{P}(\mathcal{X}^4)$, s.t. $I(P_e) > I(P_{e'}).$

Consider the crossover event of the empirical mutual informations

$$\{I(\widehat{P}_e) \leq I(\widehat{P}_{e'})\}.$$

Def: Crossover Rate

$$J_{e,e'} := \lim_{n \to \infty} -\frac{1}{n} \log \mathbb{P}\left(\left\{I(\widehat{P}_e) \le I(\widehat{P}_{e'})\right\}\right).$$

・ 何 ト ・ ヨ ト ・ ヨ ト

Given two node pairs $e, e' \in {\binom{\mathcal{V}}{2}}$ with distribution $P_{e,e'} \in \mathcal{P}(\mathcal{X}^4)$, s.t. $I(P_e) > I(P_{e'}).$

Consider the crossover event of the empirical mutual informations

 $\{I(\widehat{P}_e) \leq I(\widehat{P}_{e'})\}.$

Def: Crossover Rate

$$J_{e,e'} := \lim_{n \to \infty} -\frac{1}{n} \log \mathbb{P}\left(\left\{I(\widehat{P}_e) \le I(\widehat{P}_{e'})\right\}\right).$$

This event may potentially lead to an error in structure learning. Why?

Theorem

The crossover rate for empirical mutual informations is

$$J_{e,e'} = \min_{Q \in \mathcal{P}(\mathcal{X}^4)} \Big\{ D(Q || P_{e,e'}) : I(Q_{e'}) = I(Q_e) \Big\}.$$

< ロ > < 同 > < 回 > < 回 >

Theorem

The crossover rate for empirical mutual informations is

$$J_{e,e'} = \min_{Q \in \mathcal{P}(\mathcal{X}^4)} \Big\{ D(Q || P_{e,e'}) : I(Q_{e'}) = I(Q_e) \Big\}.$$



- Sanov's Theorem and The Contraction Principle.
- Exact but not very intuitive.

< 同 ト < 三 ト < 三 ト

Non-Convex.

• Euclidean Information Theory [Borade & Zheng '08]:

$$Q \approx P \quad \Rightarrow \quad D(Q || P) \approx \frac{1}{2} ||Q - P||_P^2$$

• Euclidean Information Theory [Borade & Zheng '08]:

$$Q \approx P \quad \Rightarrow \quad D(Q || P) \approx \frac{1}{2} ||Q - P||_P^2$$

• Def: Very noisy learning condition on P_{e,e'}

$$P_e \approx P_{e'} \qquad \Rightarrow$$

< ロ > < 同 > < 回 > < 回 >

• Euclidean Information Theory [Borade & Zheng '08]:

$$Q \approx P \quad \Rightarrow \quad D(Q || P) \; \approx \; \frac{1}{2} ||Q - P||_P^2$$

Def: Very noisy learning condition on P_{e,e'}

$$P_e \approx P_{e'} \qquad \Rightarrow \qquad I(P_e) \approx I(P_{e'}).$$

< ロ > < 同 > < 回 > < 回 >

• Euclidean Information Theory [Borade & Zheng '08]:

$$Q \approx P \quad \Rightarrow \quad D(Q || P) \approx \frac{1}{2} ||Q - P||_P^2$$

Def: Very noisy learning condition on P_{e,e'}

$$P_e \approx P_{e'} \qquad \Rightarrow \qquad I(P_e) \approx I(P_{e'}).$$

• Def: Given a $P_e = P_{i,j}$ the information density function is

$$s_e(x_i, x_j) := \log rac{P_{i,j}(x_i, x_j)}{P_i(x_i)P_j(x_j)}, \quad \forall (x_i, x_j) \in \mathcal{X}^2.$$

< ロ > < 同 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

$$J_{e,e'} := \lim_{n \to \infty} -\frac{1}{n} \log \mathbb{P}\left(\left\{I(\widehat{P}_e) \le I(\widehat{P}_{e'})\right\}\right).$$

▶ E つへで ISIT 11/17

イロト イヨト イヨト イヨト

$$J_{e,e'} := \lim_{n \to \infty} -\frac{1}{n} \log \mathbb{P}\left(\left\{I(\widehat{P}_e) \le I(\widehat{P}_{e'})\right\}\right).$$

Theorem

The approximate crossover rate is:

$$\widetilde{J}_{e,e'} = \frac{(I(P_{e'}) - I(P_{e}))^2}{2 \operatorname{Var}(s_{e'} - s_{e})}.$$

Signal-to-noise ratio for structure learning.

$$SNR = \left(\frac{\text{mean}}{\text{stddev}}\right)^2.$$

A > + = + + =

Convexifying the optimization problem by linearizing the constraints.

< ロ > < 同 > < 回 > < 回 >

Convexifying the optimization problem by linearizing the constraints.



Convexifying the optimization problem by linearizing the constraints.



Convexifying the optimization problem by linearizing the constraints.



Non-Convex problem becomes a Least-Squares problem.

How good is the approximation? We consider a binary model.



< 17 ▶

(4) (5) (4) (5)

Error Exponent for Structure Learning I

• We have characterized the rate for the crossover event $\left\{ I(\widehat{P}_{e}) \leq I(\widehat{P}_{e'}) \right\}$. We called the rate $J_{e,e'}$.

Error Exponent for Structure Learning I

• We have characterized the rate for the crossover event $\left\{I(\widehat{P}_e) \leq I(\widehat{P}_{e'})\right\}$. We called the rate $J_{e,e'}$.



Error Exponent for Structure Learning I

• We have characterized the rate for the crossover event $\left\{I(\widehat{P}_e) \leq I(\widehat{P}_{e'})\right\}$. We called the rate $J_{e,e'}$.



• How to relate this to K_P, the overall error exponent?

$$\mathbb{P}\left(\{\mathcal{E}_{\mathsf{ML}}\neq\mathcal{E}_{P}\}\right) \doteq \exp(-nK_{P})$$

Error Exponent for Structure Learning II

Theorem

$$K_P = \min_{e' \notin \mathcal{E}_P} \left(\min_{e \in \operatorname{Path}(e'; \mathcal{E}_P)} J_{e,e'} \right).$$

イロト イヨト イヨト イヨト

Error Exponent for Structure Learning II

Theorem

$$K_P = \min_{e' \notin \mathcal{E}_P} \left(\min_{e \in \operatorname{Path}(e'; \mathcal{E}_P)} J_{e,e'} \right).$$



・ロト ・ 四ト ・ ヨト ・ ヨト ・

Positivity of the Error Exponent

Theorem

The following statements are equivalent:

(a) The error probability decays exponentially i.e.,

 $K_P > 0.$

(b) T_P is a spanning tree, i.e., not a proper forest.

Positivity of the Error Exponent

Theorem

The following statements are equivalent:

(a) The error probability decays exponentially i.e.,

 $K_P > 0.$

(b) T_P is a spanning tree, i.e., not a proper forest.

• Goal: Find the rate of decay of the probability of error:

$$K_P := \lim_{n \to \infty} -\frac{1}{n} \log \mathbb{P}\left(\{ \mathcal{E}_{\mathsf{ML}} \neq \mathcal{E}_P \} \right).$$

 Employed tools from Large-Deviation theory and basic properties of trees.

< 同 ト < 三 ト < 三 ト

• Goal: Find the rate of decay of the probability of error:

$$K_P := \lim_{n \to \infty} -\frac{1}{n} \log \mathbb{P}\left(\{ \mathcal{E}_{\mathsf{ML}} \neq \mathcal{E}_P \} \right).$$

- Employed tools from Large-Deviation theory and basic properties of trees.
- Found the dominant error tree that relates crossover events to overall error event.

• Goal: Find the rate of decay of the probability of error:

$$K_P := \lim_{n \to \infty} -\frac{1}{n} \log \mathbb{P}\left(\{\mathcal{E}_{\mathsf{ML}} \neq \mathcal{E}_P\}\right).$$

- Employed tools from Large-Deviation theory and basic properties of trees.
- Found the dominant error tree that relates crossover events to overall error event.
- Used Euclidean Information Theory to obtain an intuitive signal-to-noise ratio expression for the crossover rate.

- A TE N A TE N

• Goal: Find the rate of decay of the probability of error:

$$K_P := \lim_{n \to \infty} -\frac{1}{n} \log \mathbb{P}\left(\{\mathcal{E}_{\mathsf{ML}} \neq \mathcal{E}_P\}\right).$$

- Employed tools from Large-Deviation theory and basic properties of trees.
- Found the dominant error tree that relates crossover events to overall error event.
- Used Euclidean Information Theory to obtain an intuitive signal-to-noise ratio expression for the crossover rate.
- More details available on arXiv (http://arxiv.org/abs/0905.0940).

< 回 > < 回 > < 回 >