

Learning annotated hierarchies from relational data

Daniel M. Roy, Charles Kemp, Vikash K. Mansinghka, and Joshua B. Tenenbaum

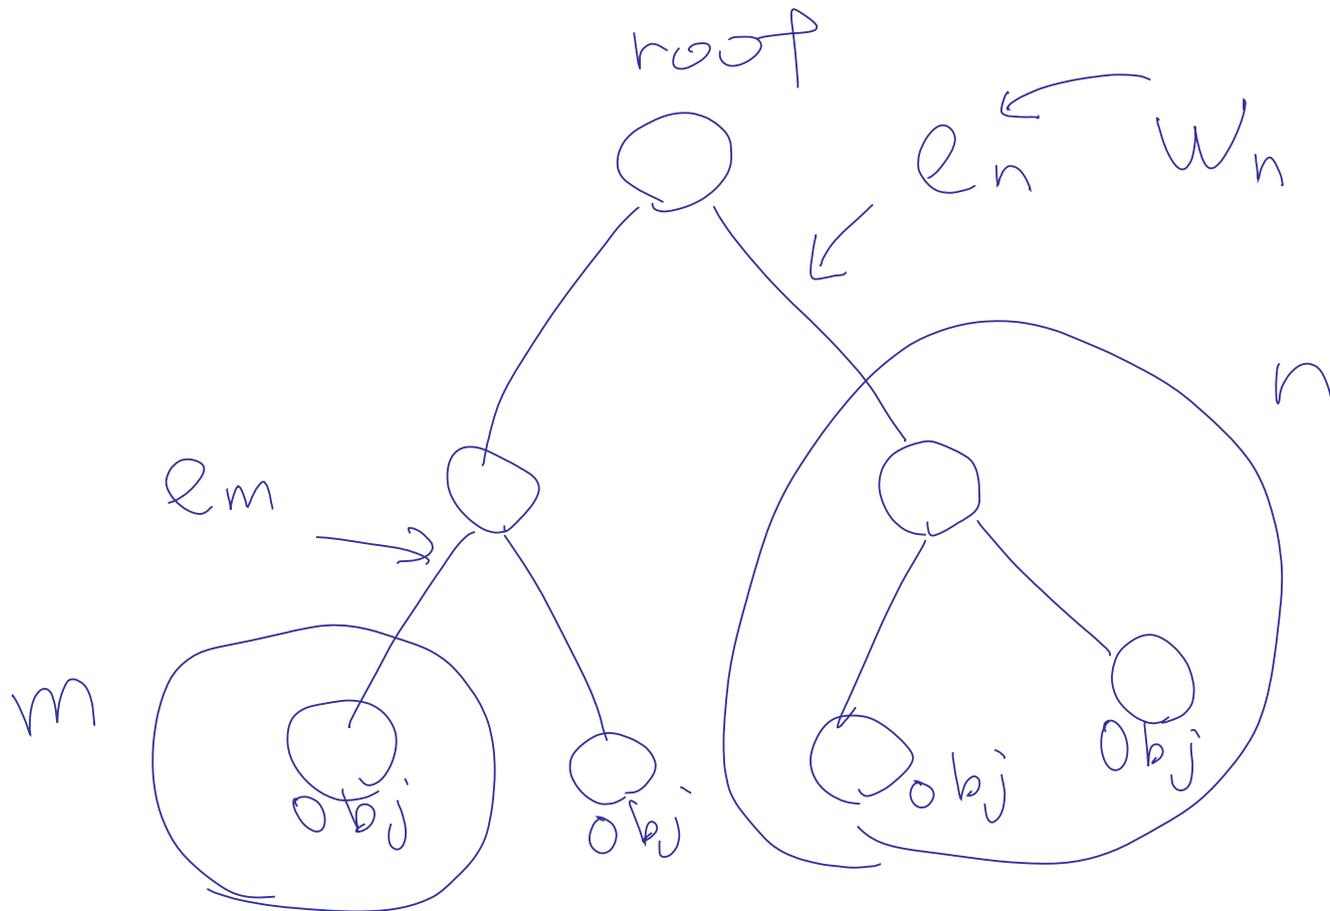
発表者: 清水伸幸 (東大)

目次

- 目的
 - RelationやFeatureを持った物体のデータから、階層のある分類表を発見したい。
- 方法
 - 設定
 - 全体像
 - Generative Model
 - Inference
 - MCMC
- 結論

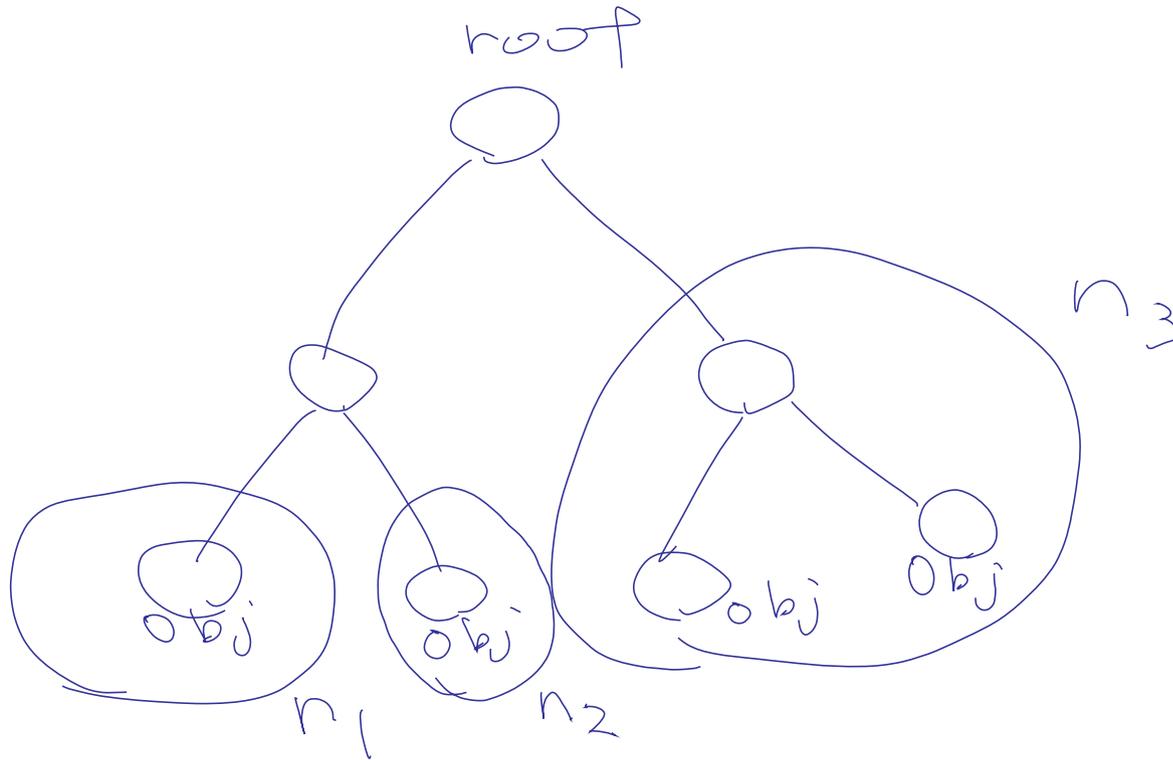
設定 1

- Weighted Binary Tree



設定 2

- Tree Consistent Partition
 - Each Object Belongs to Exactly One Subtree
 - Set of Subtrees, $\{n_1, n_2, n_3\}$



全体像 1

- こういった tree から、weight が重いと同じ値を持ちやすくなるような、feature を generate するモデルを考える。
- 同じく、relation を generate するモデルも考える。

全体像 2

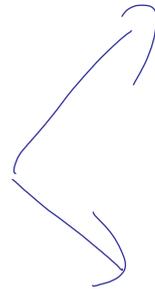
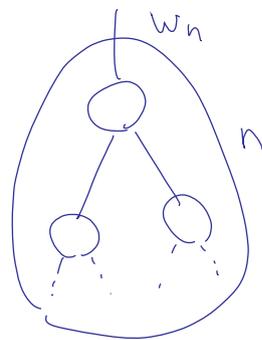
- feature と relation のデータが与えられた後の tree の posterior probability は、feature と relation の marginal probability の掛け算がある式で決まる。
- Marginal Probability を見つける必要がある。

全体像 3

- この、posterior が高いtreeを探すために、MCMC スキームで検索する。
- 一番はじめの weight は、agglomerative hierarchical clusteringで決める

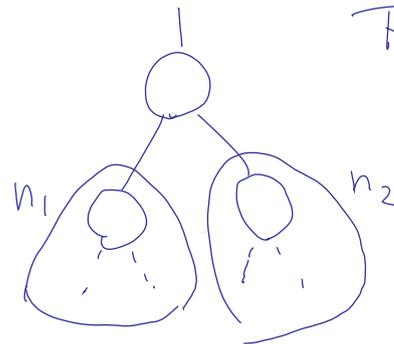
Generative Model 1

- uniform distribution から tree を選ぶ。
- exponential prior distribution から weight をサンプルする。
- Partition を generate する。



$1 - e^{-w_n}$ の確率で
 n を partition の l
にする

そこでなければ
T ∧ .



Generative Model 2

- partitionごとに、Beta distribution から feature が起こる確率を引く。
- その確率を元に、Bernoulli distributionから、featureが出たかどうかを引く。
- 以上で、featureのgeneration終わり。
- relationについても、partitionのペアについて同じようなことをすればよい。

Inference 1

$$P(T|D, \lambda, \gamma) \propto P(T|\lambda) P(D|T, \gamma)$$

$$= \prod_{i=1}^{2\mathcal{O}-1} \lambda e^{-\lambda w_{ni}} \prod_{f=1}^F P(\mathbf{d}_f|T, \gamma_f) \prod_{r=1}^R P(\mathbf{D}_r|T, \gamma_r)$$

- Posterior Probability of tree T given data D
- Dynamic Programming Algorithmで、featureとrelation の marginal probabilityが¹出せる。

$$P(\mathbf{d}_f|T, \gamma_f)$$

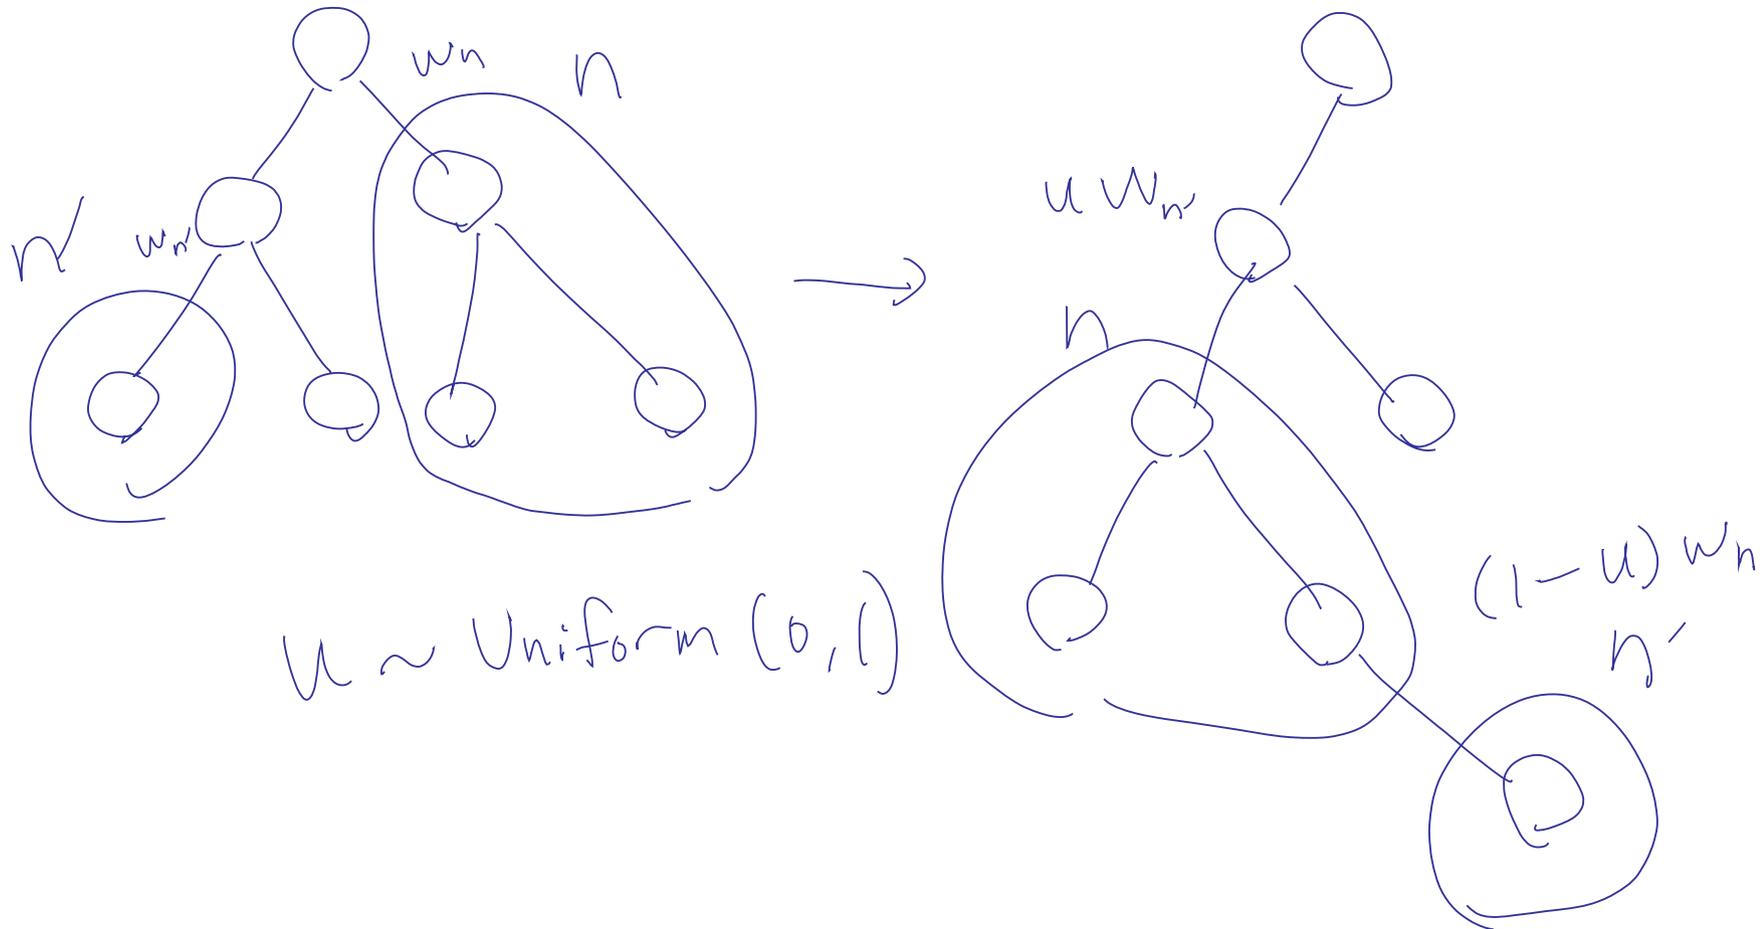
$$P(\mathbf{D}_r|T, \gamma_r)$$

Inference 2

- $\mathbb{M}_f(n)$ は、beta-binomial distributionのmarginal likelihood.
 - $\mathbb{T}_f(T) = P(\mathbf{d}_f | T, \gamma_f)$
 - $\mathbb{T}_f(n) = \begin{cases} (1 - e^{-w_n})\mathbb{M}_f(n) + e^{-w_n}\mathbb{T}_f(n.\text{left}) \mathbb{T}_f(n.\text{right}) \\ \mathbb{M}_f(n) \end{cases}$ if n is an internal node
 - otherwise.
- Feature の marginal likelihoodはこうして得られる。

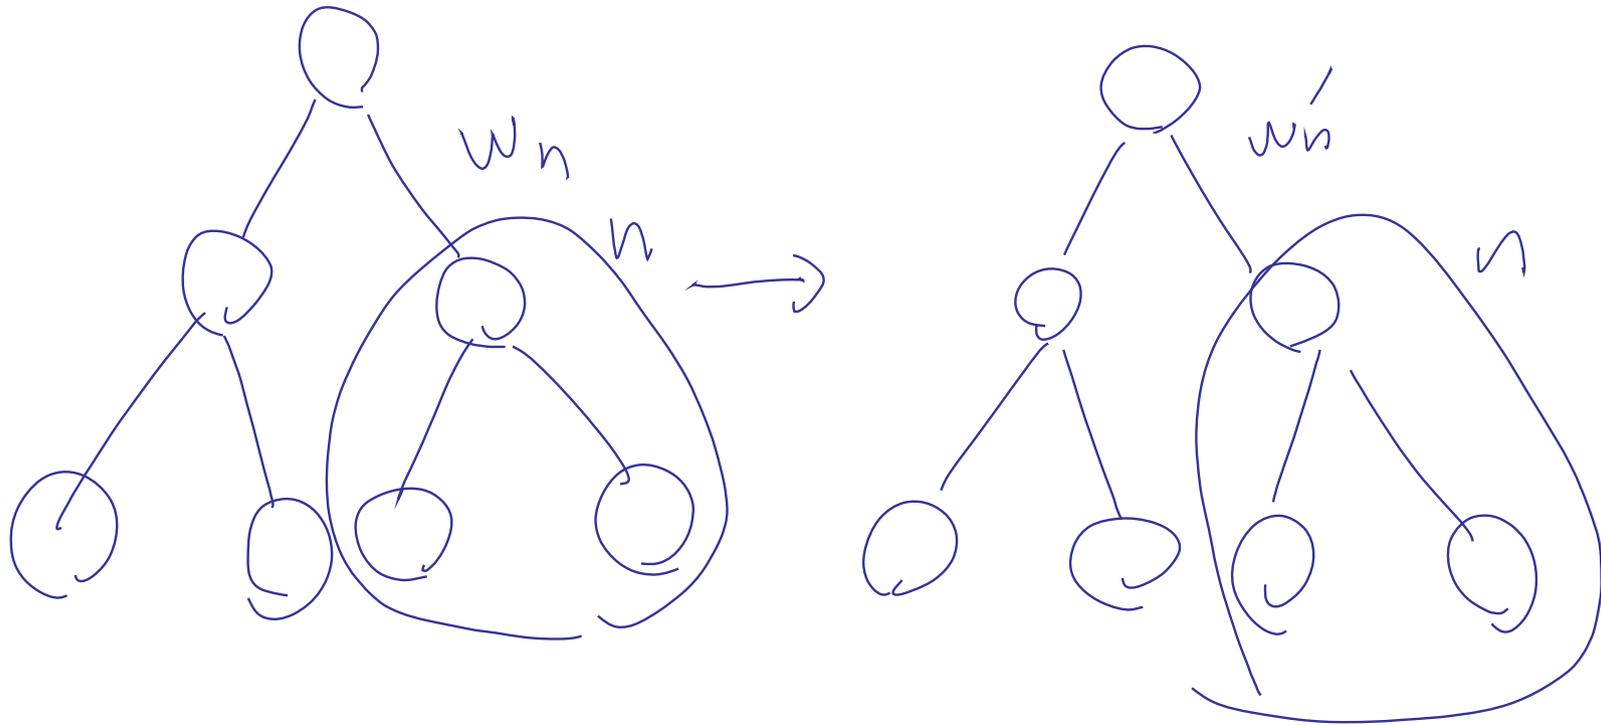
MCMC 1

- Subtree Pruning & Regrafting (? ? ?)



MCMC 2

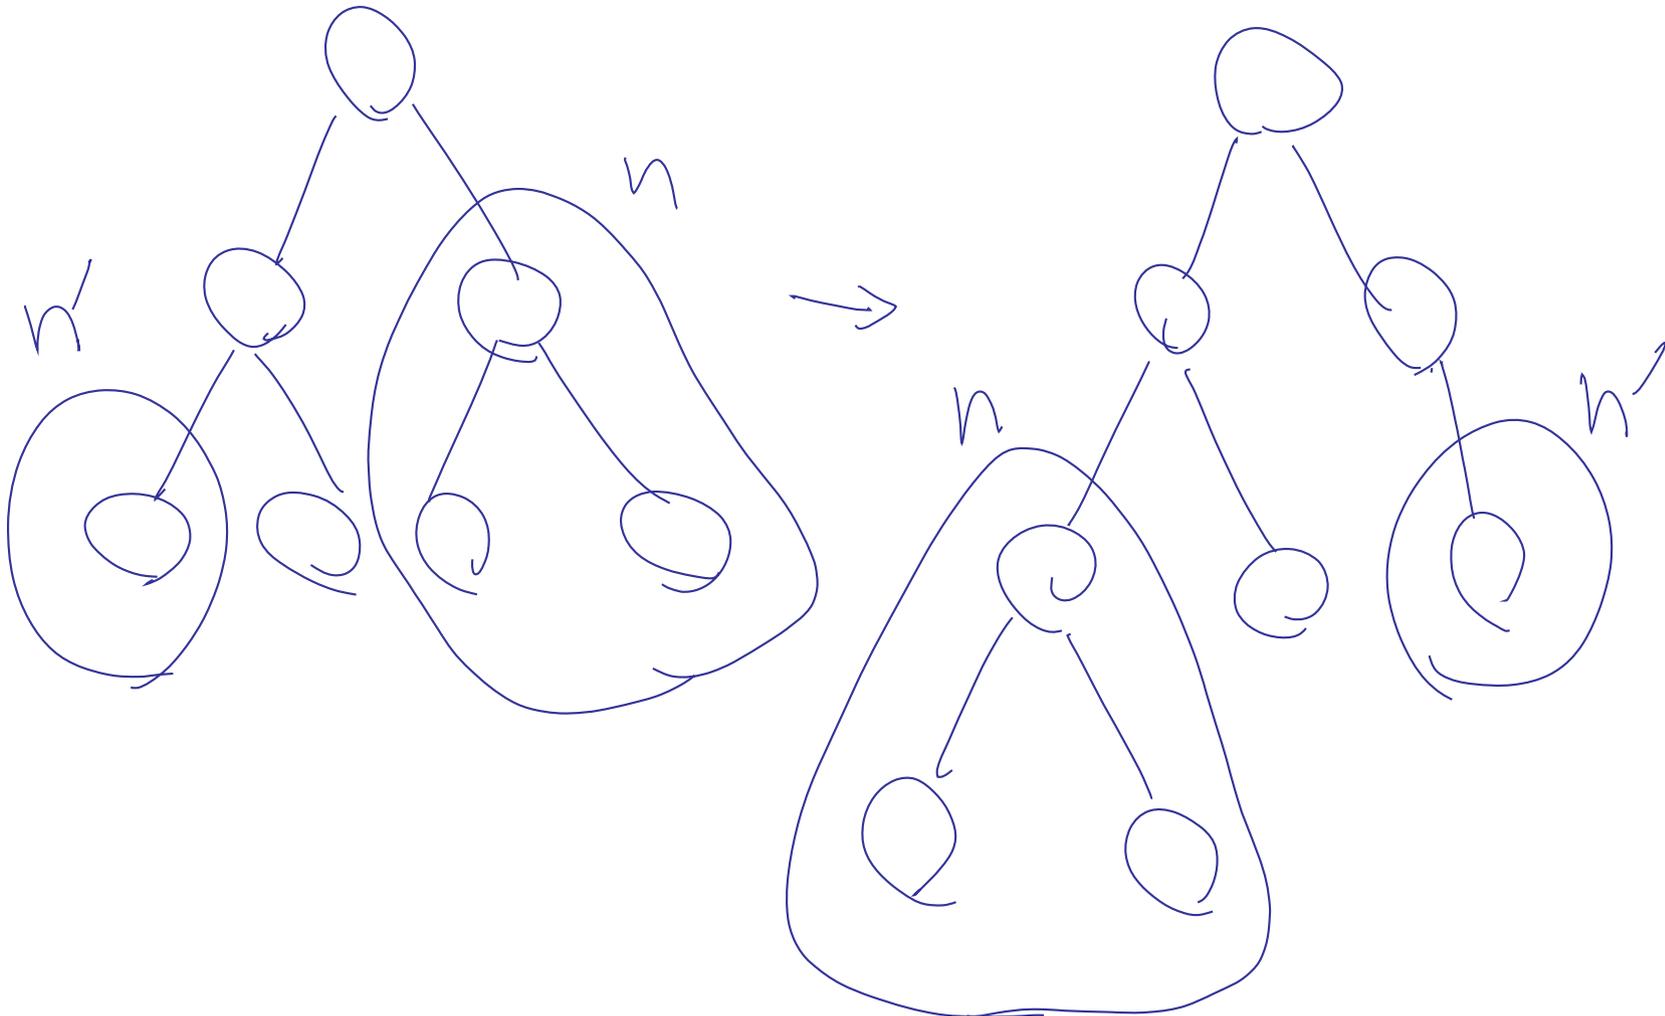
- Edge Weight Adjustment



$$w'_n \sim \text{Normal}(\log(w_n), 1)$$

MCMC 3

- Subtree Swapping



結論

- 今までのモデルと違い、いろいろなfeatureやrelationを混ぜても大丈夫。
- いくつかのデータできれいな階層構造を発見した。