

# 言語処理における識別モデルの発展

## - HMMからCRFまで -

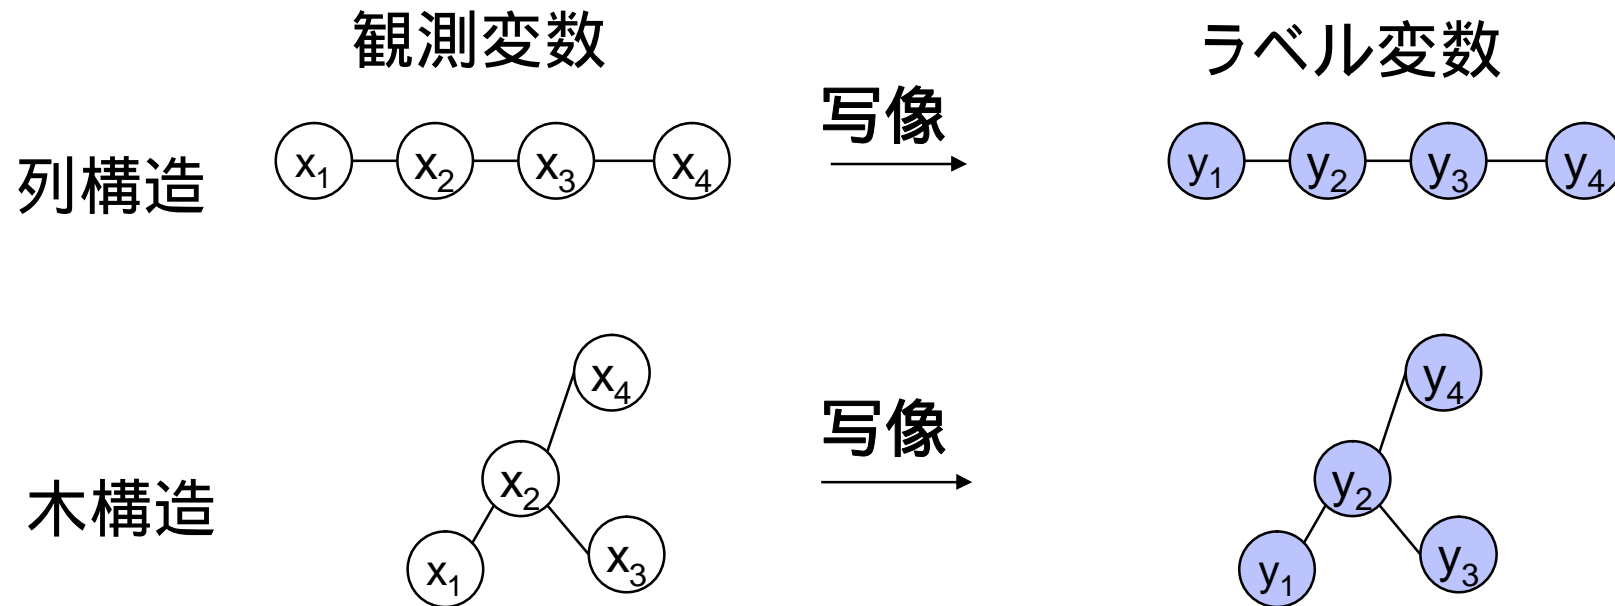
坪井祐太, 鹿島久嗣 (IBM 東京基礎研究所)  
工藤 拓 (Google)

## チュートリアルの流れ

- 構造のラベル付け問題とは (鹿島)
- 2つのアプローチとその比較
  - 生成モデル: 隠れマルコフモデル (鹿島)
  - 識別モデル: 条件付確率場 (坪井)
- そのほかの識別モデル (坪井)
- 計算機実験による性能比較 (工藤)
- 利用可能なツール (工藤)

## 構造ラベル付与問題とは？

- 観測された構造データ  $x$  に対応するラベル  $y$  への写像をおこなう問題




- 自然言語処理、バイオインフォマティクスにおいて、数多くみられる

## 構造ラベル付与問題の例(列構造)

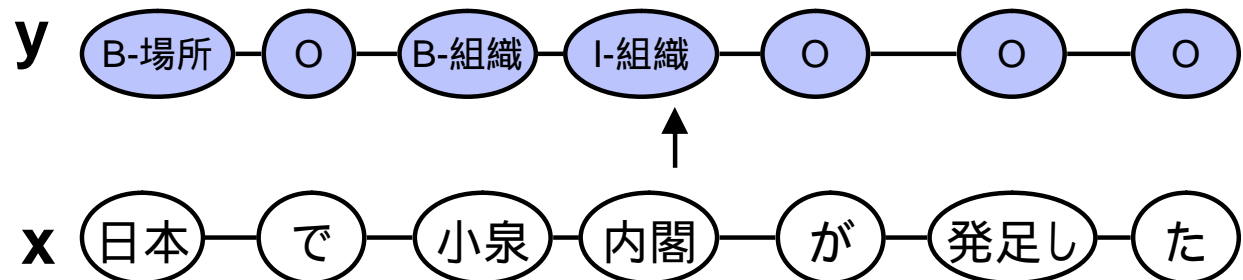
### ■ 品詞タグ付与タスク

- 単語列に対して品詞ラベル(動詞、名詞...)を付与するタスク



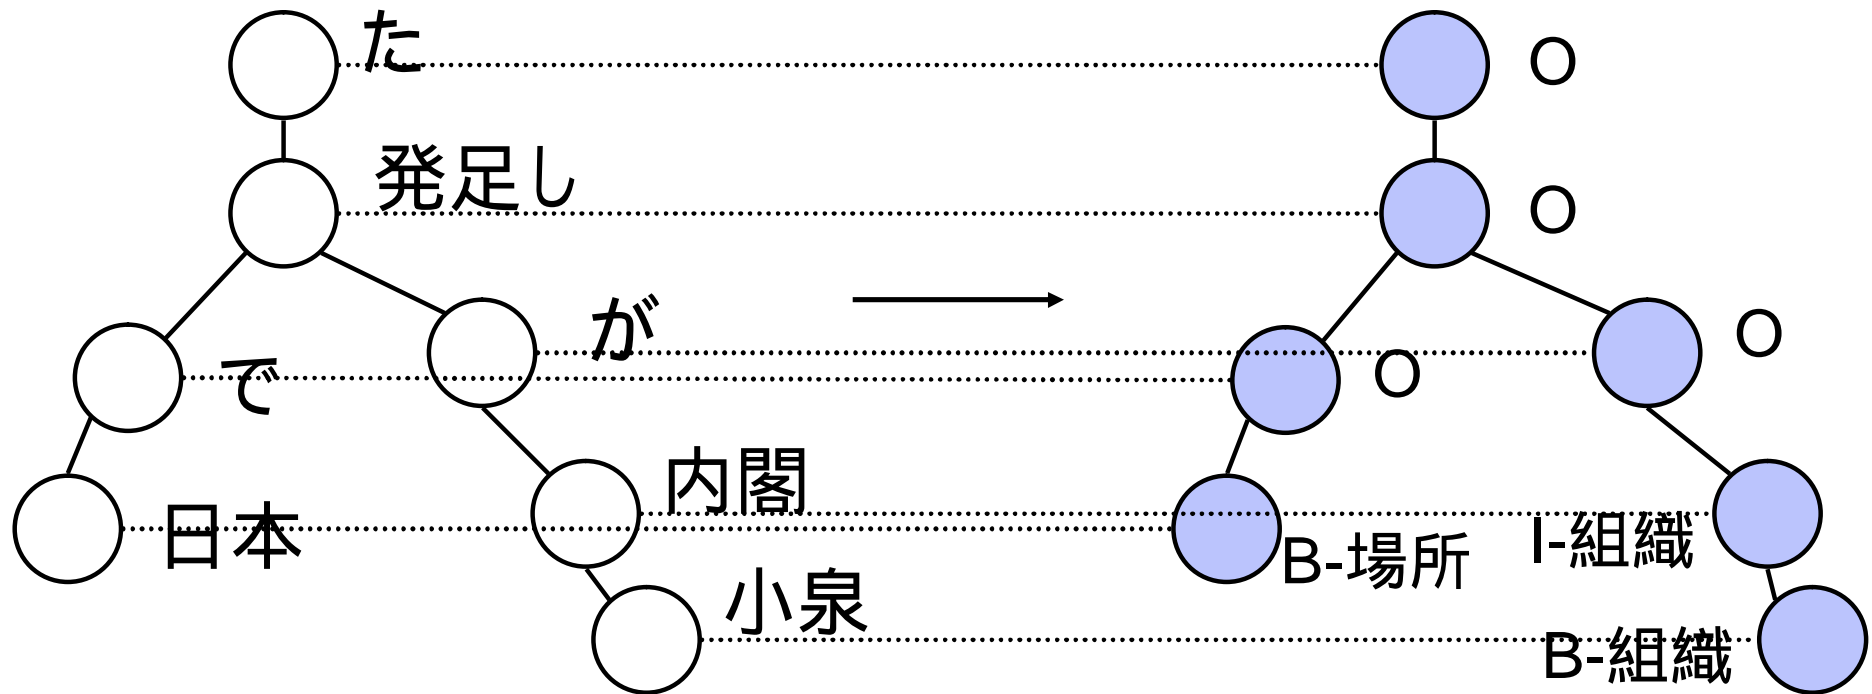
### ■ 固有表現抽出タスク

- 人名・組織名等の固有表現をテキスト中から抽出するタスク
- 単語列に対して固有表現の「始まり(B-XXX)」と「続く(I-XXX)」、「それ以外(O)」を示すラベルを付与



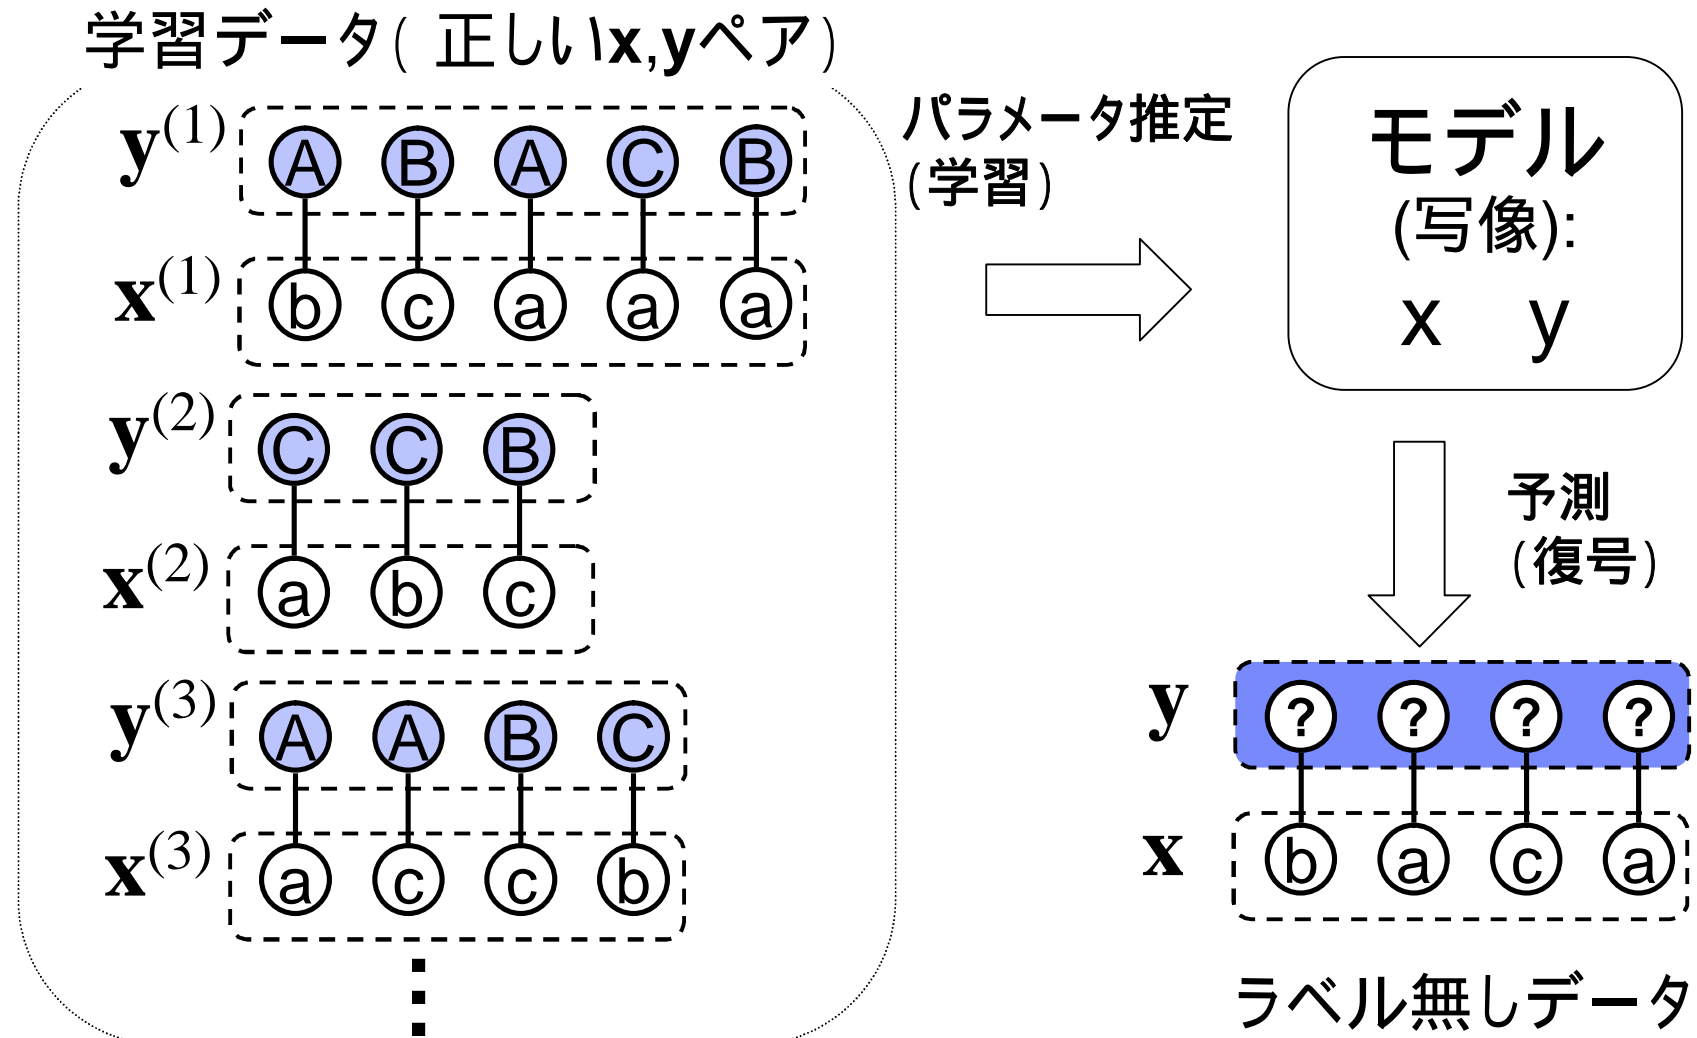
## 構造ラベル付与問題の例(木構造)

- 係り受け木に対する固有表現抽出タスク
  - 係り受け解析によって生成された、単語間の関係を表す係り受け木に対して、ラベルを付与
  - 主語と述語の関係など言語構造を考慮



# 教師付き学習によるアプローチ


- 過去に正しいラベル付けを行ったデータをもとにモデルを学習



# 教師つき学習による構造ラベル付与学習モデルへのアプローチ

- 生成モデルに基づく手法
  - 隠れマルコフモデル
- 識別モデルに基づく手法
  - 条件付確率場


# 生成モデルによる構造ラベル付与学習 隠れマルコフモデル(HMM)



- **x**と**y**の同時分布に基づくモデル
- 同時分布を出力確率と遷移確率に分解してモデル化

$$P(\mathbf{x}, \mathbf{y}) = P(\mathbf{x} | \mathbf{y}) P(\mathbf{y})$$

$$= \prod_{t=1}^T P(x_t / y_t) P(y_t | y_{t-1}) \quad (T \text{は構造} \mathbf{x}, \mathbf{y} \text{のサイズ})$$



**出力確率**  
(ある位置の観測変数は、同じ位置のラベル変数によって決定)

$y_{t-1}$  →  $y_t$

**遷移確率**  
(ある位置のラベル変数は、ひとつ前のラベル変数によって決定)



## HMMでのラベル列の予測(復号問題)

- 予測(復号): 観測 $\mathbf{x}$ が与えられたときに、確率が最大になるラベル列 $\mathbf{y}$ を見つける

*predict*


$$\mathbf{y} = \operatorname{argmax}_{\mathbf{y} \in \Sigma_y^T} P(\mathbf{y} | \mathbf{x}) = \operatorname{argmax}_{\mathbf{y} \in \Sigma_y^T} P(\mathbf{x}, \mathbf{y})$$

$$= \operatorname{argmax}_{\mathbf{y} \in \Sigma_y^T} \prod_{t=1}^T P(x_t / y_t) P(y_t | y_{t-1})$$


- しかし、あらゆるラベル列全て( $|\Sigma_y|^T$ 個)の列挙は不可能 計算の工夫が必要

( $\Sigma_y$ は、ラベル変数の取りうる値の集合)


全部で  $|\Sigma_y|^T$  個の候補



...



...



## Viterbi 復号法による最適ラベル列の求め方 (1 / 3)

- テーブル  $\delta_t(y_t)$  を使い、最適なラベル列を再帰的に計算
  - $\delta_t(y_t)$  : 位置  $t$  でラベル  $y_t$  をとる、 $t$  までのラベル列の確率の最大値

$$\delta_t(y_t) = \max_{y_1, \dots, y_{t-1} \in \Sigma^{t-1}} \prod_{\tau=1}^{t-1} P(y_\tau | y_{\tau-1}) P(x_\tau | y_\tau) \quad \delta_1(y_1) = P(x_1 | y_1)$$

$$= \max_{y_{t-1} \in \Sigma_y} \delta_{t-1}(y_{t-1}) P(y_t | y_{t-1}) P(x_t | y_t)$$

x: 観測変数

英語品詞タグ付けタスクでの

y \ x		the	man	saw	...
y: ラベル変数	冠詞	$P(\text{the}   \text{冠詞})$	$\max_{y_1 \in \Sigma_y} \delta_1(y_1) \times P(\text{冠詞}   y_1) P(\text{man}   \text{冠詞})$	$\max_{y_2 \in \Sigma_y} \delta_2(y_2) \times P(\text{冠詞}   y_2) P(\text{man}   \text{冠詞})$	...
	名詞	$P(\text{the}   \text{名詞})$	$\max_{y_1 \in \Sigma_y} \delta_1(y_1) \times P(\text{名詞}   y_1) P(\text{man}   \text{名詞})$	$\max_{y_2 \in \Sigma_y} \delta_2(y_2) \times P(\text{名詞}   y_2) P(\text{man}   \text{名詞})$	...
	動詞	$P(\text{the}   \text{動詞})$	$\max_{y_1 \in \Sigma_y} \delta_1(y_1) \times P(\text{動詞}   y_1) P(\text{man}   \text{動詞})$	$\max_{y_2 \in \Sigma_y} \delta_2(y_2) \times P(\text{動詞}   y_2) P(\text{man}   \text{動詞})$	...

## Viterbi 復号法による最適ラベル列の求め方 ( 2 / 3 )

- 具体例:  $y_t$  を最大にする  $y_{t-1}$  から  $y_t$  への遷移 ( 矢印 ) が決まった時の テーブル

$x \backslash y$	the	man	saw	...
冠詞	$P(\text{the}   \text{冠詞})$	$P(\text{the}   \text{動詞})$ $\times P(\text{冠詞}   \text{動詞}) P(\text{man}   \text{冠詞})$	$P(\text{the}   \text{名詞})$ $\times P(\text{動詞}   \text{名詞}) P(\text{man}   \text{動詞})$ $\times P(\text{冠詞}   \text{動詞}) P(\text{saw}   \text{冠詞})$	...
名詞	$P(\text{the}   \text{名詞})$	$P(\text{the}   \text{冠詞})$ $\times P(\text{名詞}   \text{冠詞}) P(\text{man}   \text{名詞})$	$P(\text{the}   \text{名詞})$ $\times P(\text{動詞}   \text{名詞}) P(\text{man}   \text{動詞})$ $\times P(\text{名詞}   \text{動詞}) P(\text{saw}   \text{名詞})$	...
動詞	$P(\text{the}   \text{動詞})$	$P(\text{the}   \text{名詞})$ $\times P(\text{動詞}   \text{名詞}) P(\text{man}   \text{動詞})$	$P(\text{the}   \text{冠詞})$ $\times P(\text{名詞}   \text{冠詞}) P(\text{man}   \text{名詞})$ $\times P(\text{動詞}   \text{名詞}) P(\text{saw}   \text{動詞})$	...

## Viterbi 復号法による最適ラベル列の求め方 (3 / 3)

- テーブルを用いて最大確率がもたらしたとする 本気に欲しいのは最大確率を実現するラベル列
- $\delta_t(y) = \max_{y_{t-1} \in \Sigma_y} \delta_{t-1}(y_{t-1})P(y_t | y_{t-1})P(x_t | y_t)$  を求めたときに、max を実現するラベル  $y_{t-1}$  を記憶するテーブル も同時に計算しておく

$$\pi_t(y_t) = \operatorname{argmax}_{y_{t-1} \in \Sigma_y} \delta_{t-1}(y_{t-1})P(y_t | y_{t-1})P(x_t | y_t)$$

- $\pi_T(y_T)$ が最大になる  $\pi_T(y_T)$  からバックトラックすることで、確率が最大になるラベル列を得ることができる。

$y \backslash x$	the	man	saw	...
冠詞		$_2(\text{冠詞}) = \text{動詞}$	$_3(\text{冠詞}) = \text{動詞}$	...
名詞		$_2(\text{名詞}) = \text{冠詞}$	$_3(\text{名詞}) = \text{動詞}$	...
動詞		$_2(\text{動詞}) = \text{名詞}$	$_3(\text{動詞}) = \text{名詞}$	...

## 隠れマルコフモデルのパラメータ推定(学習)

- 推定すべきパラメータ
  - 出力確率  $P(x_t|y_t)$
  - 遷移確率  $P(y_t|y_{t-1})$
- 最尤推定: 学習データをもっとも再現するパラメータを求める

$$\hat{\theta} = \operatorname{argmax}_{\theta} \prod_i P_{\theta}(\mathbf{x}^{(i)}, \mathbf{y}^{(i)}) \quad (i \text{は学習データの索引})$$

$$= \operatorname{argmax}_{\theta} \prod_i \prod_t^{T^{(i)}} P_{\theta}(x_t^{(i)} | y_t^{(i)}) P_{\theta}(y_t^{(i)} | y_{t-1}^{(i)})$$

- 最尤パラメータは学習データ内での出力および遷移の頻度のカウンタで計算可能
  - AのあとにAが2回、Bが3回出現していたら、 $P(A|A)=2/5$ 、 $P(B|A)=3/5$

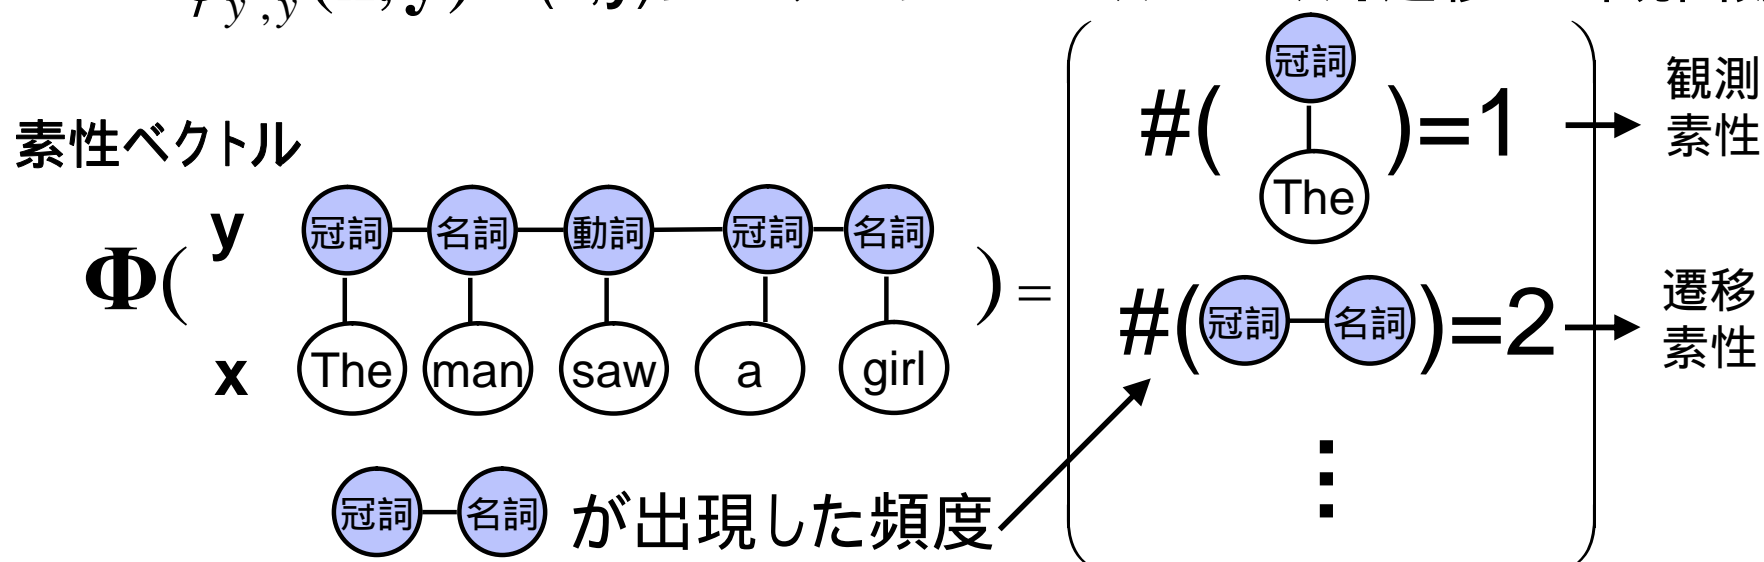
## 隠れマルコフモデル(HMM)の素性ベクトル表現 (1 / 2)

- HMMは、パラメータベクトルと素性ベクトルの内積の形でかける

$$\log P(\mathbf{x}, \mathbf{y}) = \langle \Theta, \Phi(\mathbf{x}, \mathbf{y}) \rangle$$

$$= \sum_{x \in \Sigma_x} \sum_{y \in \Sigma_y} \phi_{x,y}(\mathbf{x}, \mathbf{y}) \log P(x/y) + \sum_{y' \in \Sigma_y} \sum_{y \in \Sigma_y} \phi_{y',y}(\mathbf{x}, \mathbf{y}) \log P(y'/y)$$

- $\phi_{x,y}(\mathbf{x}, \mathbf{y})$  :  $(\mathbf{x}, \mathbf{y})$ におけるある「ラベル-観測」出力の出現回数
- $\phi_{y',y}(\mathbf{x}, \mathbf{y})$  :  $(\mathbf{x}, \mathbf{y})$ におけるある「ラベル-ラベル」遷移の出現回数



# 隠れマルコフモデル(HMM)の素性ベクトル表現

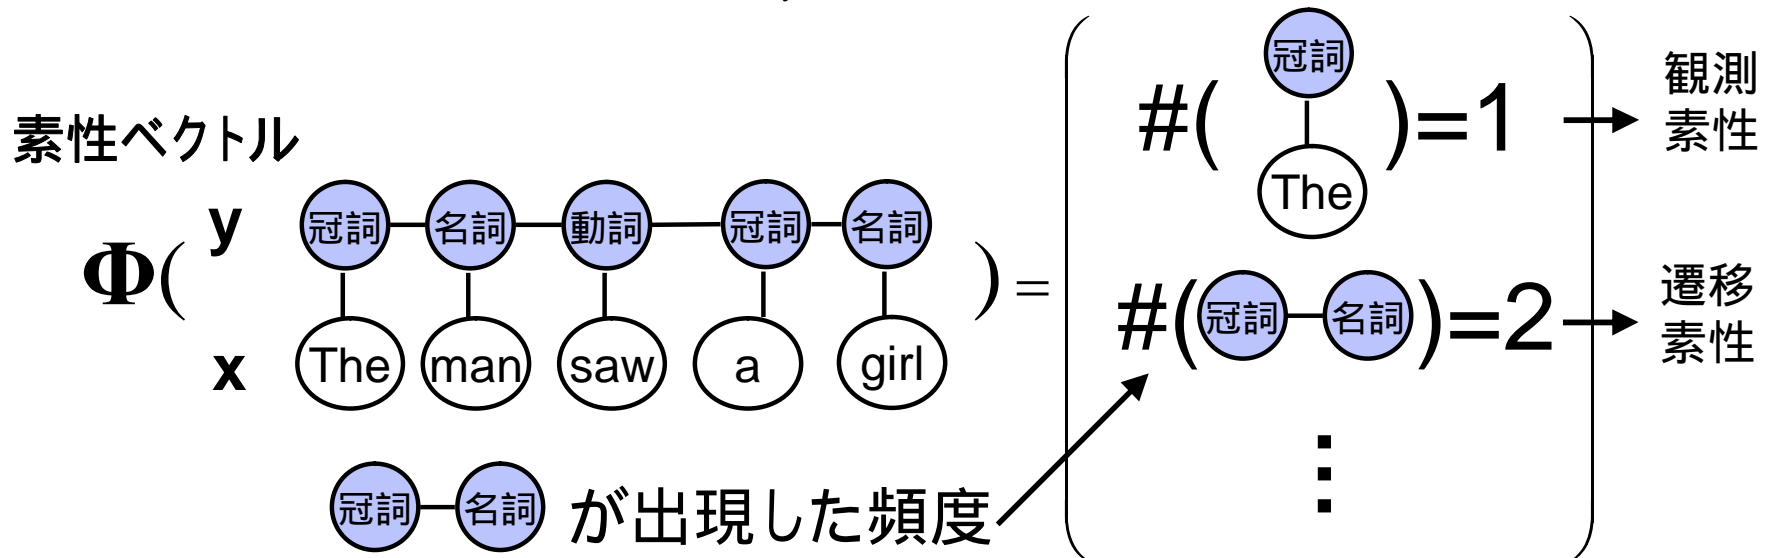
$$\log P(\mathbf{x}, \mathbf{y}) = \langle \Theta, \Phi(\mathbf{x}, \mathbf{y}) \rangle$$

- 予測: パラメータベクトルとの内積が最も大きい素性ベクトルを求める

$$\mathbf{y} = \underset{\mathbf{y} \in \Sigma_y^T}{\operatorname{argmax}} \langle \Theta, \Phi(\mathbf{x}, \mathbf{y}) \rangle$$

- 学習: 素性ベクトルとの内積が最も大きいパラメータベクトルを求める

$$\hat{\Theta} = \underset{\Theta}{\operatorname{argmax}} \prod_i \langle \Theta, \Phi(\mathbf{x}^{(i)}, \mathbf{y}^{(i)}) \rangle$$



## 隠れマルコフモデルの問題点

- 同時分布を推定しようとしている
- 素性の独立性を仮定している



## 隠れマルコフモデルの2つの問題点:(1)同時分布の推定

- HMMは、同時分布  $P(\mathbf{x}, \mathbf{y})$  の最尤推定をすることで、間接的に予測問題を解いている

- 最尤推定 
$$\hat{\theta} = \operatorname{argmax}_{\theta} \prod_i P_{\theta}(\mathbf{x}^{(i)}, \mathbf{y}^{(i)})$$

- 予測 
$$\mathbf{y}^{\text{predict}} = \operatorname{argmax}_{\mathbf{y} \in \Sigma_y} P(\mathbf{x}, \mathbf{y})$$

- ホントは、条件付分布  $P(\mathbf{y} | \mathbf{x})$  がわかれば予測はできるはず

- あるべき最尤推定？

$$\hat{\theta} = \operatorname{argmax}_{\theta} \prod_i P_{\theta}(\mathbf{y}^{(i)} | \mathbf{x}^{(i)})$$

## 隠れマルコフモデルの2つの問題点:(2)素性の独立性

- 隠れマルコフモデルが仮定している確率的な制約

$$\sum_{y_t \in \Sigma_y} P(y_t | y_{t-1}) = 1 \quad \sum_{x_t \in \Sigma_x} P(x_t | y_t) = 1$$

の意味するところ = 素性の独立性

- ある  $y_t \in \Sigma_y$  と  $y'_t \in \Sigma_y$  が同時に起こることはない

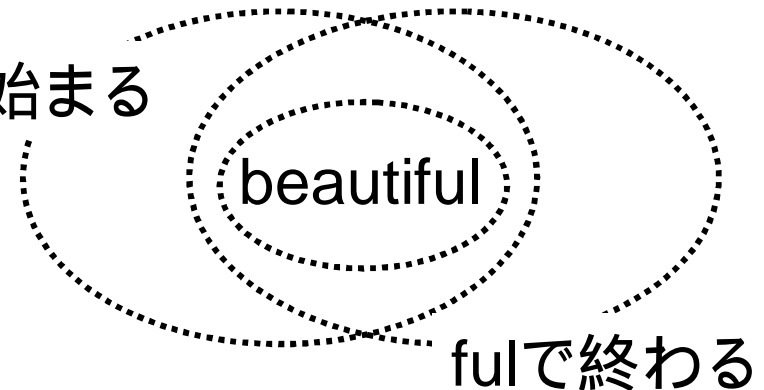
独立でない素性をうまく扱えない

- 一方、自然言語処理では単語それ自身以外に、単語の部分文字列等が素性に使われることが多い

- 品詞タグ付け

- $P(\text{beautiful} | \text{形容詞})$
- $P(\text{fulで終わる単語} | \text{形容詞})$
- $P(\text{beで始まる単語} | \text{形容詞})$

beで始まる



## 隠れマルコフモデル から 条件付確率場へ

- 同時分布を推定しようとしている
- 素性の独立性を仮定している

を解決するのが、条件付確率場 (CRF)

# 識別モデル

- $\mathbf{x}$ から $y$ を直接推定するモデル
- 識別モデルの利点
  - 直接分類問題を解くことが出来る
  - 素性間の重なりを考慮して重みを学習
- 多クラスのロジスティック回帰モデル(最大エントロピーモデル)
  - 確率分布(条件付分布)の形をした識別モデル

足して1になるように全ての $y$ の和で割る

$$P(y | \mathbf{x}) = \frac{\exp(\langle \Theta, \Phi(\mathbf{x}, y) \rangle)}{\sum_{\tilde{y} \in Y} \exp(\langle \Theta, \Phi(\mathbf{x}, \tilde{y}) \rangle)}$$

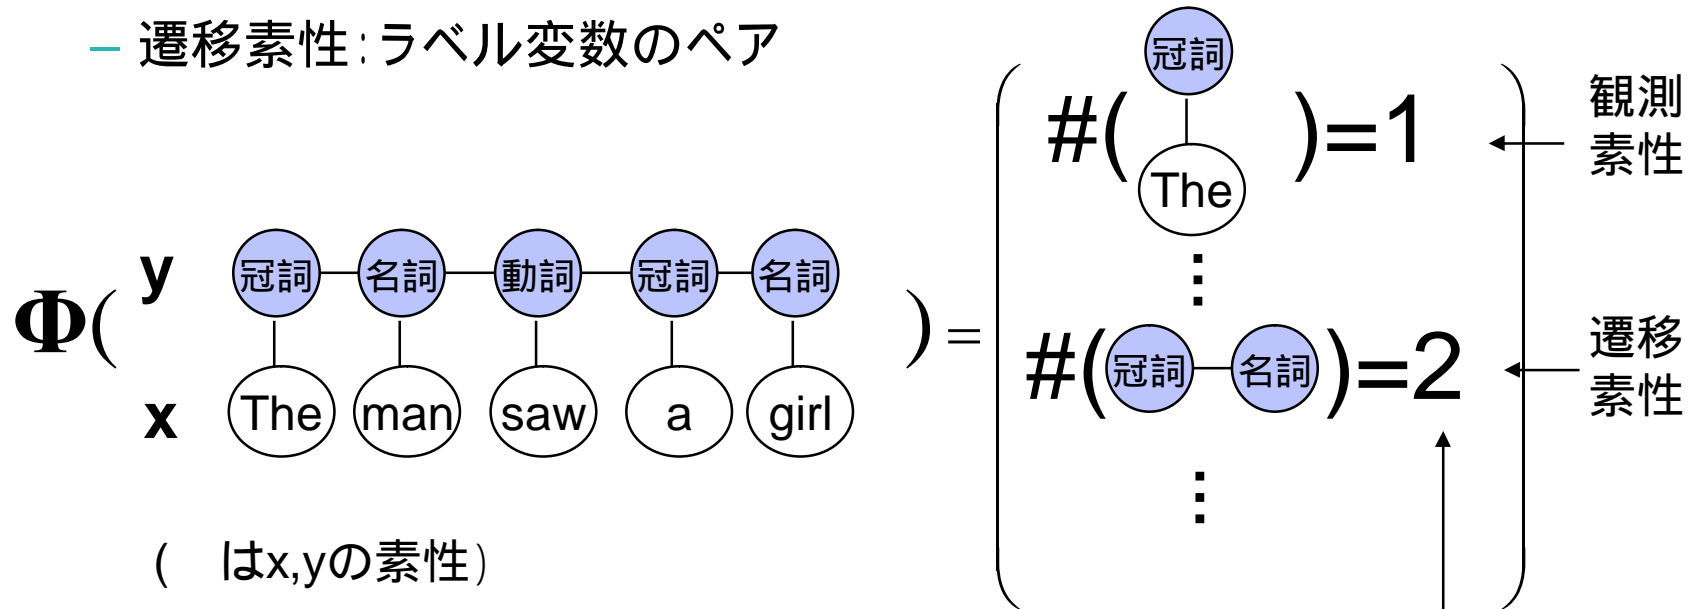
0以上になるように

$(\mathbf{x}, y)$ ペアのスコア

(  $\Phi$  は $\mathbf{x}, y$ の素性、  $\Theta$  は素性に対する重み、  $\langle a, b \rangle$  は内積)

# 識別モデルによる構造ラベル付与学習: 条件付確率場 (Conditional Random Fields: CRF)

- ロジスティック回帰モデルを基に、ローカルな変数間の関係を素性(遷移素性)で表現したモデル
- 素性ベクトルの各要素は、素性が構造中に出現した頻度
  - 観測素性: 観測変数とラベル変数のペア
  - 遷移素性: ラベル変数のペア



HMMでは...  
 $\log P(\mathbf{x}, \mathbf{y}) = \langle \Theta, \Phi(\mathbf{x}, \mathbf{y}) \rangle$

冠詞 --- 名詞 が出現した頻度

# 識別モデルによる構造ラベル付与学習: 条件付確率場 (Conditional Random Fields: CRF)

- ロジスティック回帰モデルを基に、ローカルな変数間の関係を素性(遷移素性)で表現したモデル

$$P(\mathbf{y} | \mathbf{x}) = \frac{\exp(\langle \Theta, \Phi(\mathbf{x}, \mathbf{y}) \rangle)}{\sum_{\tilde{\mathbf{y}}} \exp(\langle \Theta, \Phi(\mathbf{x}, \tilde{\mathbf{y}}) \rangle)}$$

列全体のスコア

$$= \frac{\exp\left(\sum_{t=1}^T \langle \Theta, \Phi(\mathbf{x}, \mathbf{y}_t^{t+1}) \rangle\right)}{\sum_{\tilde{\mathbf{y}}} \exp\left(\sum_{\tau=1}^T \langle \Theta, \Phi(\mathbf{x}, \tilde{\mathbf{y}}_\tau^{\tau+1}) \rangle\right)} \cdot \mathbf{y}_t^{t+1} = (y_t, y_{t+1})$$

ある点tのスコア

(  $\Theta$  は  $\mathbf{x}, \mathbf{y}$  の素性、  $\Phi$  は素性に対する重み )

## 条件付確率場の予測(復号問題)

- 隠れマルコフモデルと同じくViterbi法で行う ( $\mathbf{y}_t^{t+1} = (y_t, y_{t+1})$ )

$$\arg \max_{\mathbf{y}} \log P(\mathbf{y} | \mathbf{x}) = \arg \max_{\mathbf{y}} \log \frac{\exp\left(\sum_{t=1}^T \langle \Theta, \Phi(\mathbf{x}, \mathbf{y}_t^{t+1}) \rangle\right)}{\sum_{\tilde{\mathbf{y}}} \exp\left(\sum_{\tau=1}^T \langle \Theta, \Phi(\mathbf{x}, \tilde{\mathbf{y}}_{\tau}^{\tau+1}) \rangle\right)}$$

yに依らないので省略

$$= \arg \max_{\mathbf{y}} \sum_{t=1}^T \langle \Theta, \Phi(\mathbf{x}, \mathbf{y}_t^{t+1}) \rangle$$

logでexpが消える

➡  $\sum_{\tau=1}^T \langle \theta, \phi(\mathbf{x}, \mathbf{y}_{\tau}^{\tau+1}) \rangle$  が最大になる $\mathbf{y}$ を求めればよい

➡ スコア最大(コスト最小化)法

# 条件付確率場のパラメータ推定(学習)の概要

- 山登り法による最尤推定(関数の最大値探索問題)


1. 現在のパラメータの対数尤度(LL)の計算

$$LL(\Theta) = \sum_{i \in \text{training data}} \log P_{\Theta}(y^{(i)} | \mathbf{x}^{(i)})$$

2. 偏微分(勾配)の計算 (0なら終了)

$$\frac{LL(\Theta)}{\partial \Theta} = \sum_{i \in \text{training data}} \frac{\log P_{\Theta}(y^{(i)} | \mathbf{x}^{(i)})}{\partial \Theta}$$

3. 勾配方向へパラメータの更新(たとえば、最大勾配方向)して、1に戻る



CRFでの計算の特徴:

ステップ1,2で動的計画法で効率的に計算する必要がある



## 条件付確率場の最適化法の速度比較 (Sha et al, 2003)

- タスク: NP Chunking (82万素性を使用)
- 各手法によるCRFの収束時間の比較
  - Preconditioned conjugate-gradient (Precond. CG)
  - Mixed conjugate-gradient (Mixed CG)
  - Conjugate-gradient (Plain CG)
  - Limited-memory quasi-Newton (L-BFGS)
  - Generalized iterative scaling (GIS)
- 一般的な最適化手法が速い

training method	time	F score	$\mathcal{L}'_{\lambda}$
Precond. CG	130	94.19%	-2968
Mixed CG	540	94.20%	-2990
Plain CG	648	94.04%	-2967
L-BFGS	84	94.19%	-2948
GIS	3700	93.55%	-5668

対数尤度

収束が速いため、良く使用される



# 条件付確率場のパラメータ推定(対数尤度の計算1)

- 対数尤度の計算

$$\sum_{i \in \text{training data}} \log P(\mathbf{y}^{(i)} | \mathbf{x}^{(i)}) = \sum_i \log \frac{\exp(\langle \Theta, \Phi(\mathbf{x}^{(i)}, \mathbf{y}^{(i)}) \rangle)}{\sum_{\mathbf{y} \in \mathcal{Y}} \exp(\langle \Theta, \Phi(\mathbf{x}^{(i)}, \tilde{\mathbf{y}}) \rangle)}$$
$$= \sum_i \left( \sum_t \langle \Theta, \Phi(\mathbf{x}^{(i)}, \mathbf{y}_t^{t+1(i)}) \rangle - \log \sum_{\tilde{\mathbf{y}} \in \mathcal{Y}} \exp\left(\sum_{\tau} \langle \Theta, \Phi(\mathbf{x}^{(i)}, \tilde{\mathbf{y}}_{\tau}^{\tau+1}) \rangle\right) \right)$$

での $(\mathbf{x}^{(i)}, \mathbf{y}^{(i)})$ のスコア

Z: でのあらゆる $\mathbf{y}$ でのスコア合計  
動的計画法で効率的に計算

# 条件付確率場のパラメータ推定(対数尤度の計算2)

- 再帰式(Forward アルゴリズム)

$$\alpha_t(y) = \sum_{y' \in Y} \left( \alpha_{t-1}(y') \cdot \exp(\langle \Theta, \Phi(\mathbf{x}^{(i)}, y', y) \rangle) \right) \leftarrow$$

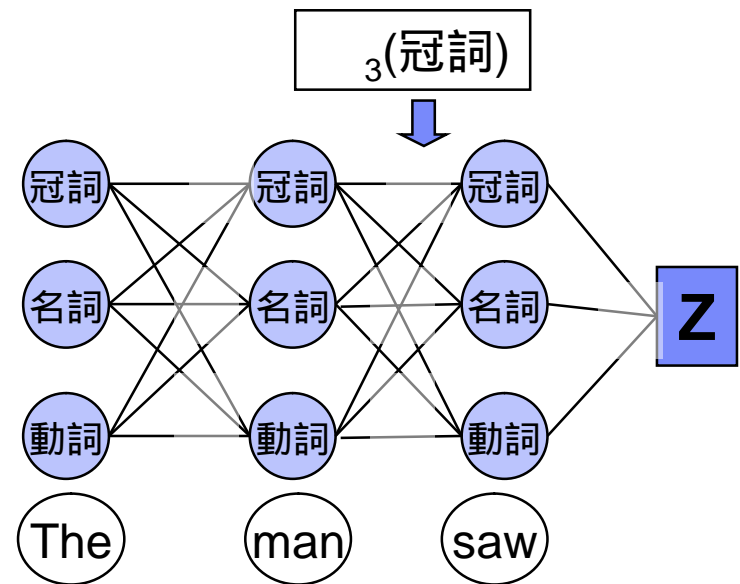
$|Y| \times |T|$ の  
2次元配列  
に記憶

= 位置tがラベルyになる $y_1^t$ までの全てのパスのスコアの合計

$$Z = \sum_{\tilde{y} \in Y} \exp\left(\sum_{\tau} \langle \Theta, \Phi(\mathbf{x}^{(i)}, \tilde{y}_{\tau}^{\tau+1}) \rangle\right)$$

$$= \sum_{y \in Y} \alpha_T(y)$$

Viterbi復号法    max  
Forward アルゴリズム    sum



# 条件付確率場のパラメータ推定 (偏微分の計算1)

- 尤度最大化の方向の計算

$$\sum_{i \in \text{training data}} \frac{\log P_{\Theta}(\mathbf{y}^{(i)} | \mathbf{x}^{(i)})}{\partial \Theta} = \sum_i \left( \Phi(\mathbf{x}^{(i)}, \mathbf{y}^{(i)}) - \sum_{\tilde{\mathbf{y}} \in Y} P(\tilde{\mathbf{y}} | \mathbf{x}^{(i)}) \Phi(\mathbf{x}^{(i)}, \tilde{\mathbf{y}}) \right)$$

素性の出現頻度

モデルでの素性期待出現頻度

$$= \sum_i \sum_t \left( \Phi(\mathbf{x}^{(i)}, \mathbf{y}_t^{t+1(i)}) - \sum_{y', y'' \in Y} \sum_{\tilde{\mathbf{y}}: \tilde{y}_t = y', \tilde{y}_{t+1} = y''} P(\tilde{\mathbf{y}} | \mathbf{x}^{(i)}) \Phi(\mathbf{x}^{(i)}, \tilde{\mathbf{y}}_t^{t+1}) \right) \leftarrow \text{位置t毎の計算}$$

位置tのラベルがy'、t+1のラベルがy''の周辺期待値

動的計画法で効率的に計算

# 条件付確率場のパラメータ推定 (偏微分の計算2)

- 再帰式(Forward-Backwardアルゴリズム)


$$\alpha_t(y) = \sum_{y' \in Y} \left( \alpha_{t-1}(y') \cdot \exp(\langle \Theta, \Phi(\mathbf{x}^{(i)}, y', y) \rangle) \right) \leftarrow \begin{array}{l} \text{「対数尤度の} \\ \text{計算2」で出て} \\ \text{来ました。} \end{array}$$

$$\beta_t(y) = \sum_{y' \in Y} \left( \exp(\langle \Theta, \Phi(\mathbf{x}^{(i)}, y, y') \rangle) \cdot \beta_{t+1}(y') \right)$$

= 位置tがラベルyになるy<sub>t</sub><sup>T</sup>までの全てのパスのスコアの合計

$$\begin{aligned} \text{周辺期待値} &= \sum_{y', y'' \in Y} \sum_{\tilde{y}: \tilde{y}_t = y', \tilde{y}_{t+1} = y''} P(\tilde{y} | \mathbf{x}^{(i)}) \Phi(\mathbf{x}^{(i)}, \tilde{y}_t^{t+1}) \\ &= \alpha_{t-1}(y') \cdot \exp(\langle \Theta, \Phi(\mathbf{x}^{(i)}, y', y'') \rangle) \cdot \beta_t(y'') \end{aligned}$$

y' = 名詞  
y'' = 動詞



# 条件付確率場のパラメータ推定のまとめ

- 山登り法による最尤推定
  - 一般的な数値計算手法が利用可能
- 動的計画法で効率的に尤度と偏微分の計算
  - 尤度計算
    - Forwardアルゴリズム
  - 尤度の偏微分計算
    - Forward- Backwardアルゴリズム

## まとめ: 隠れマルコフモデル(HMM)と条件付確率場(CRF)

	隠れマルコフモデル	条件付確率場
確率モデル	$P(Y, X)$	$P(Y X)$
定式化	生成モデル	識別モデル
学習	$P(Y, X)$ の最尤推定 計算は容易で高速	$P(Y X)$ の最尤推定 計算に工夫が必要
構造	列構造、木構造、DAG	列構造、木構造、DAG
柔軟な素性設計	困難 (独立性を仮定)	可能
予測モデル	Viterbi復号法	Viterbi復号法
言語モデルとしての使用	可能	不可能

## その他の識別モデル：分類手法に基づくアプローチ

- **CRFのパラメタ推定の別アプローチ**
  - 分類手法(パーセプトロン, SVM, ...)にもとづいたアプローチ
- **構造学習として何がうれしいか？ 通常のアプローチでは解けない問題に適用できる**



## そのほかの識別モデル：隠れマルコフパーセプトロン

- CRFの推定は、訓練データの  $y^{(i)}$  が出力される確率を「最大にする」ように学習される

$$\hat{\theta} = \arg \max_{\theta} \prod_{i \in \text{training data}} P_{\theta}(y^{(i)} | \mathbf{x}^{(i)})$$

- 別の考え方：訓練データの  $y^{(i)}$  が出力される確率が、「ほかの  $\tilde{y}^{(i)} \neq y^{(i)}$  の出力確率よりも大きければよい」

$$\log P_{\theta}(y^{(i)} | \mathbf{x}^{(i)}) > \log P_{\theta}(\tilde{y}^{(i)} | \mathbf{x}^{(i)})$$

$$\Leftrightarrow \langle \theta, \Phi(\mathbf{x}^{(i)}, y^{(i)}) \rangle - \langle \theta, \Phi(\mathbf{x}^{(i)}, \tilde{y}^{(i)}) \rangle > 0$$

# 隠れマルコフパーセプトロンのアルゴリズム

1.  $i$  番目の訓練データに対して予測してみる

$$\underset{\mathbf{y}}{\text{predict}} \mathbf{y}^{(i)} = \operatorname{argmax} P(\mathbf{y} | \mathbf{x}^{(i)})$$

2. 当たっていれば(  $\underset{\mathbf{y}}{\text{predict}} \mathbf{y}^{(i)} \neq \mathbf{y}^{(i)}$  )何もしない

3. 外れていたら、パラメータを修正

$$\boldsymbol{\theta}^{new} \leftarrow \boldsymbol{\theta}^{old} + \eta \left( \Phi(\mathbf{x}^{(i)}, \mathbf{y}^{(i)}) - \Phi(\mathbf{x}^{(i)}, \tilde{\mathbf{y}}^{(i)}) \right)$$

4. 1.に戻って繰り返す

最尤推定と隠れマルコフパーセプトロンの違いは、argmax操作のみで実現できるところ

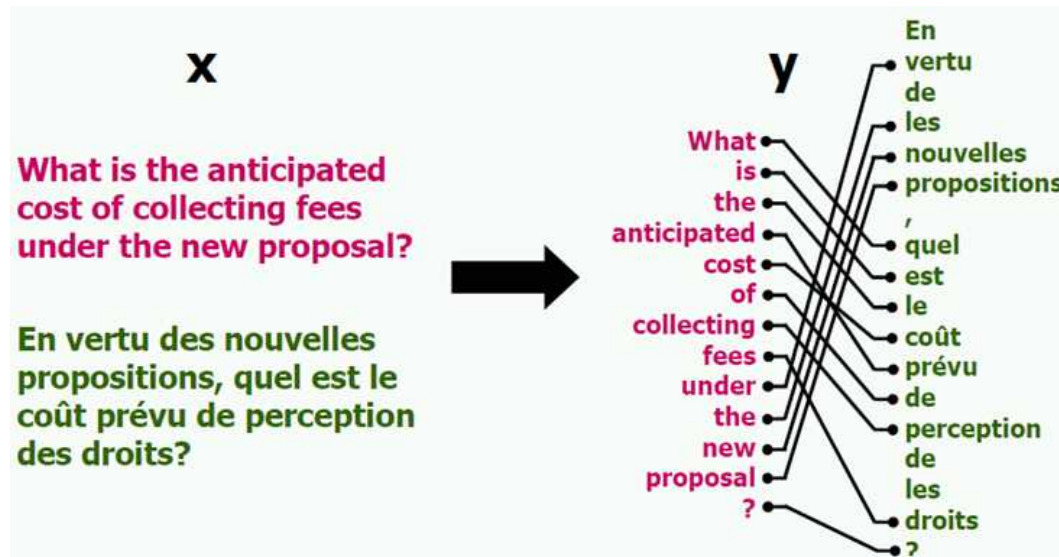
- 隠れマルコフパーセプトロンは訓練と予測が両方argmax操作

	CRF	隠れマルコフパーセプトロン
訓練	sum	argmax
予測	argmax	argmax

- 通常、argmaxも動的計画法で実現できるのであまり変わりはない...しかし...

# 隠れマルコフパーセプトロンは、最尤推定では解けない問題が解ける？

- 問題によっては、argmax操作は、動的計画法以外の多項式時間アルゴリズムで実現できる
- 動的計画法で多項式時間で解けない問題は、最尤推定では解けない
  - たとえば、異なる言語の文章間での単語のマッチング
    - argmax操作が線形計画法(多項式時間)で解ける

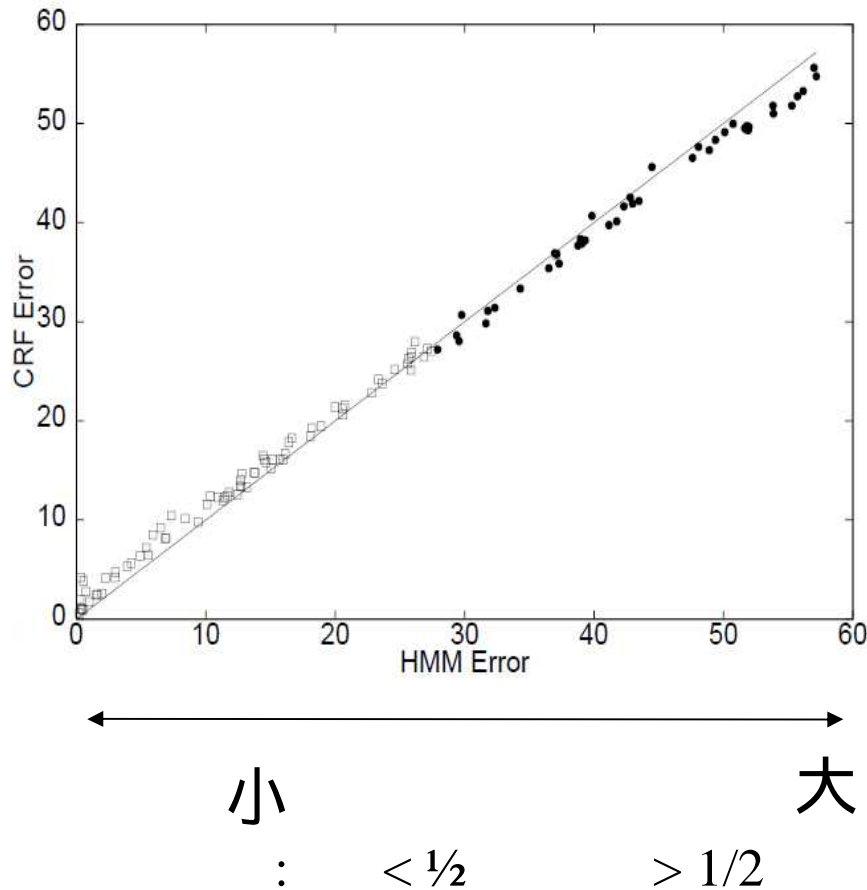


(Taskar, 2005)

# 実験

- 人工データ
- 英語の品詞タグ付け
- 日本語形態素解析

# 人工データによる HMM と CRF の比較 (Lafferty 01)



- **Second/first mixture HMMからランダムサンプリング**

- $P(y|y',y'') = P(y|y') + (1 - \quad) P(y|y',y'')$
- $P(x|y,x') = P(x|y) + (1 - \quad) P(y|y',x')$
- $|Y| = 5, |X| = 26$

- **HMM, CRF 両方とも first order**

- **結果**

- 小: HMM wins
- 大: CRF wins

- **真のモデルから外れてくると CRF の識別性能が生きてくる**

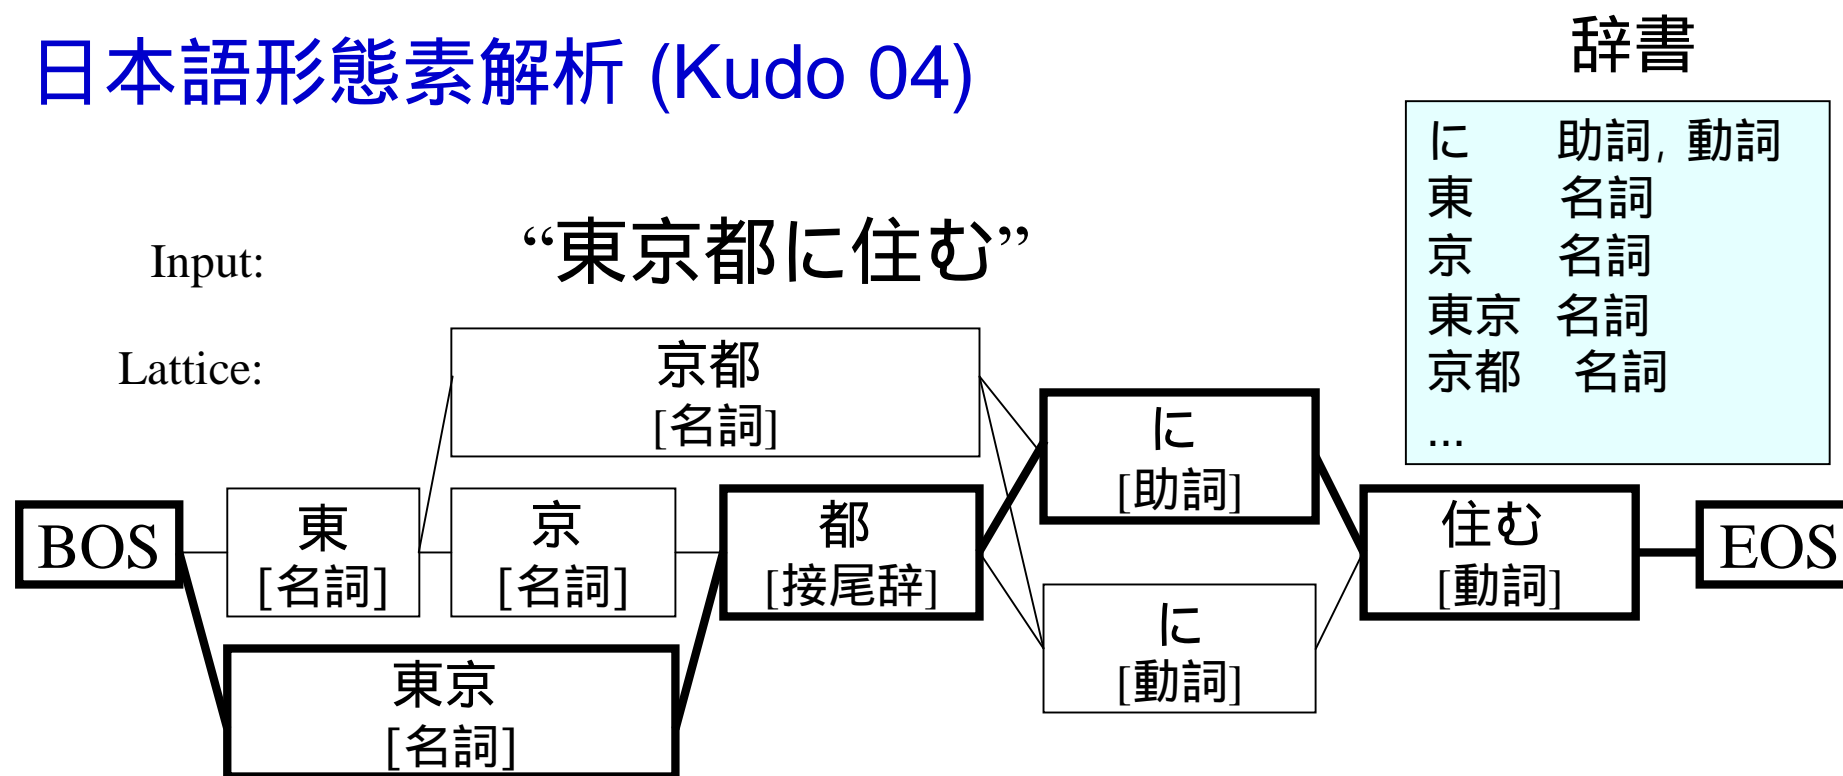
## 英語の品詞タグ付け (Lafferty 01)

<i>model</i>	<i>error</i>	<i>oov error</i>
HMM	5.69%	45.99%
MEMM	6.37%	54.61%
CRF	5.55%	48.05%
MEMM <sup>+</sup>	4.81%	26.99%
CRF <sup>+</sup>	4.27%	23.76%

<sup>+</sup>Using spelling features

- Penn treebank の 50%-50% split, first-order
- MEMM (最大エントロピー法を逐次適用するモデル)
- spelling feature
  - -ing, -ogy, -ed, -s, -ly, -ion, -tion, -ity, -ies

# 日本語形態素解析 (Kudo 04)



- 出力  $y$  の長さが出力経路によって異なる問題
- 古くから HMM が使われてきた
- CRF も HMM と同じアナロジーで応用可能



## 形態素解析における HMM の問題点

- 品詞 = 隠れクラスでいいの?
  - 品詞は階層構造を持つ
  - 何を隠れクラスにすればいいのか?
    - 名詞,動詞ぐらいの浅い階層 細かい違いを区別できない
    - 深い階層 (名詞-固有名詞-人名-姓) データスパースネス
    - 助詞(は,が,を) は語彙そのものを品詞としたい (語彙化)
  - HMMの粒度の粗さと辞書定義の粒度の細かさのギャップ

京都

名詞

固有名詞

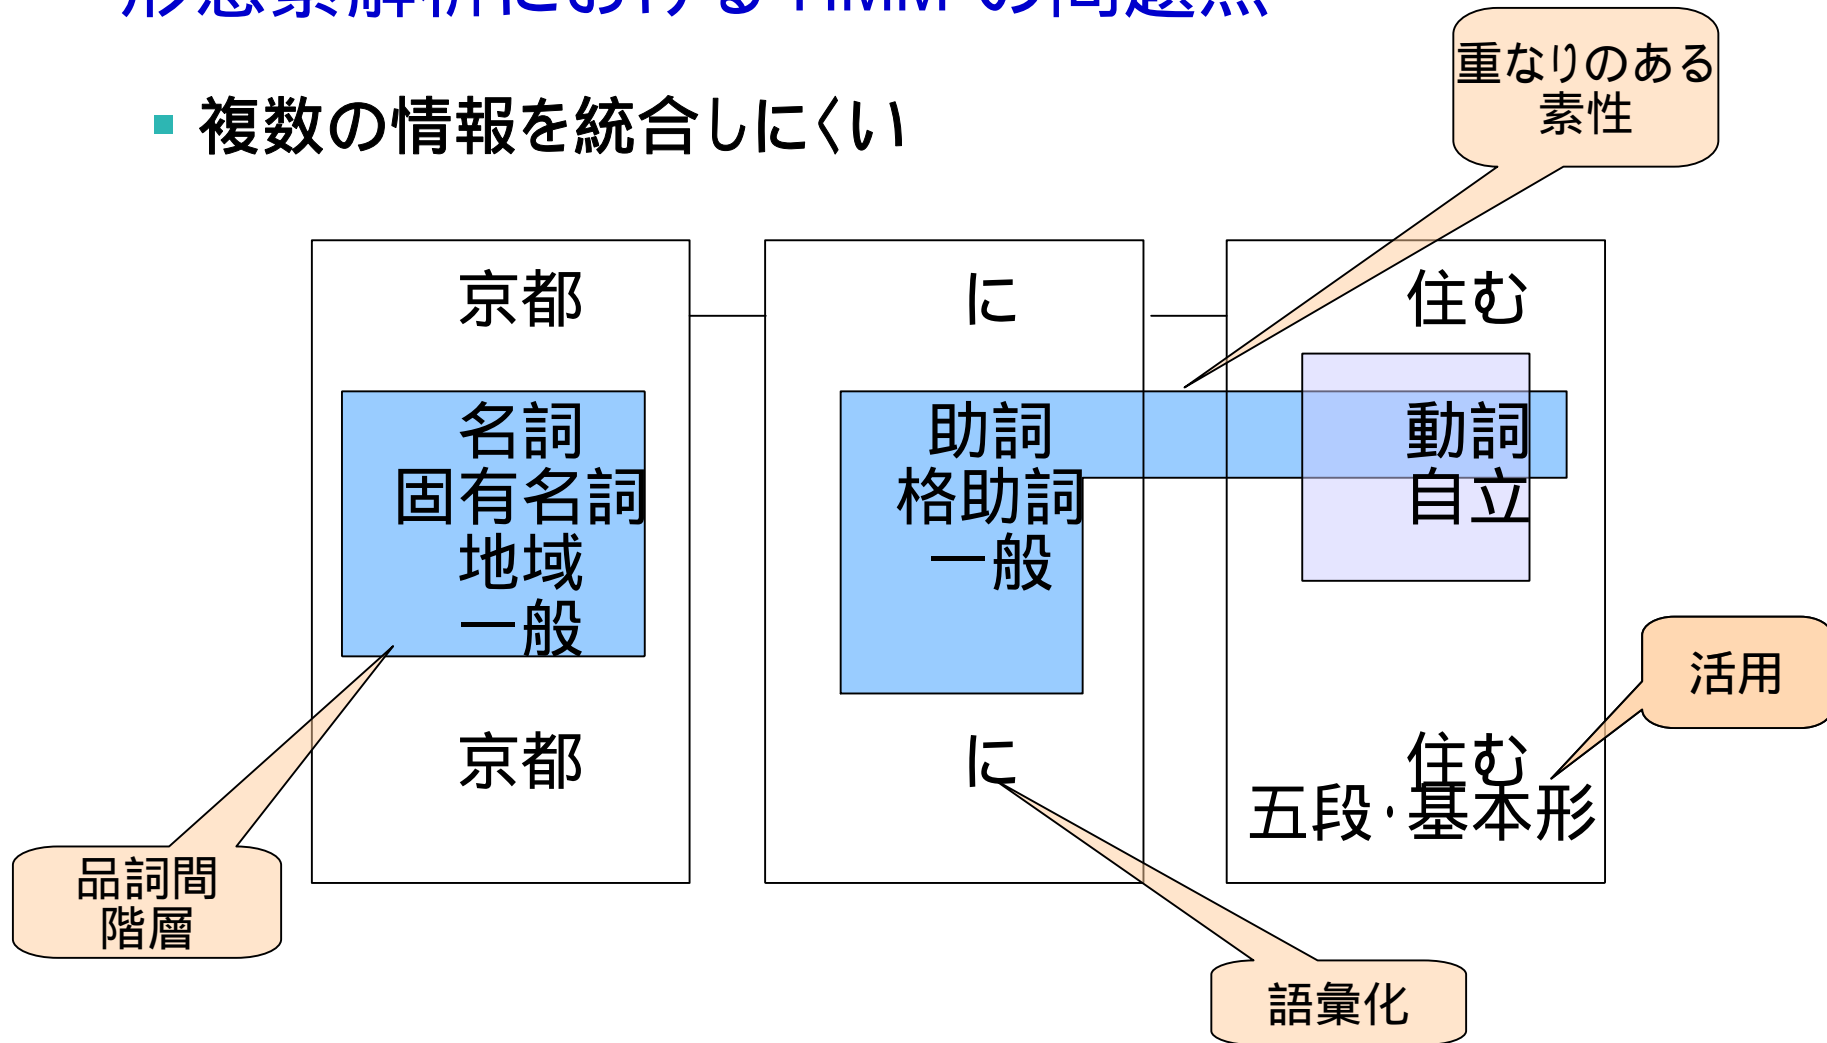
地域

一般

京都

# 形態素解析における HMM の問題点

- 複数の情報を統合しにくい



CRF は辞書定義が複雑な日本語形態素解析に適している

# 日本語形態素解析


図 3: 実験結果: KC

system	$F_{\beta=1}$ (seg / top / all)
CRF	98.96 / 98.31 / 96.75
HMM	96.22 / 94.99 / 91.85
JUMAN	98.70 / 98.09 / 94.35

図 4: 実験結果: RWCP

system	$F_{\beta=1}$ (seg / top / all)
CRF	99.11 / 98.72 / 97.65
HMM	96.42 / 95.81 / 94.16
ChaSen	98.86 / 98.38 / 97.00

図 5: 学習データ量と精度の関係



- 二つのコーパス, **seg**:分割のみ, **top**:品詞, **all**:すべて
- **CRF**: 階層化品詞, 字種, 重なりのある複数の素性
- 複雑な辞書定義を **CRF** がうまくとらえている

## CRF のツールキット

- **MALLET: A Machine Learning for Language Toolkit**
  - <http://mallet.cs.umass.edu/index.php/Main Page>
  - CRF の他に, 文書分類, クラスタリング, 情報抽出が可能
- **CRF Project Page**
  - <http://crf.sourceforge.net/>
  - API の提供がメインであり, 単体の実装よりは組み込み向け
- **FlexCRF**
  - <http://www.jaist.ac.jp/hieuxuan/flexcrfs/flexcrfs.html>
  - 1st-order の他に2nd-order (trigram) のCRFをサポート
  - 並列計算機を使って大量データの学習が可能

# CRF のツールキット

## ■ CRF++

- <http://chasen.org/~taku/software/CRF++/>
- コンパクトな設計, 導入が簡単
- 素性の定義をテンプレートファイルとして定義
- n-best 解, 周辺確率の計算
- 高速

## ■ MeCab

- <http://mecab.sourceforge.jp>
- CRF を採用した日本発の形態素解析エンジン
- 任意のコーパスから学習可能
- 素性の自由な設計
- IPA 辞書以外に Juman, CSJ コーパスをサポート

## CRF++ (日本語固有表現の例)

ノーベルカタカナ 名詞-固有名詞-人名-一般 B-ARTIFACT  
文学 漢字 名詞-一般 I-ARTIFACT  
賞 漢字名詞-一般 I-ARTIFACT  
授賞 漢字 名詞-サ変接続 O  
式 漢字 名詞-一般 O  
の ひらがな 助詞-連体化 O  
大江 漢字 名詞-固有名詞-人名-姓 B-PERSON  
健三郎 漢字 名詞-固有名詞-人名-名 I-PERSON  
さん ひらがな 名詞-接尾-人名 O  
、 記号 記号-読点 O  
晩さん 漢字-ひらがな 名詞-一般 O

学習データ

U00:%x[-2,0]  
U01:%x[-1,0]  
U02:%x[0,0]  
U03:%x[1,0]  
U04:%x[2,0]  
U05:%x[-1,0]/%x[0,0]  
U06:%x[0,0]/%x[1,0]

U10:%x[-2,1]  
U11:%x[-1,1]  
U12:%x[0,1]  
U13:%x[1,1]

素性テンプレート

- % crf\_learn template train\_corpus model
- % crf\_test -m model < test\_corpus