



# 潜在変数の分布推定誤差に関する 漸近解析

東京工業大学 山崎 啓介




# Agenda



1. 観測変数と潜在変数
2. 観測変数の予測誤差と漸近形
3. 潜在変数の推定誤差と漸近形
4. 考察とまとめ

# Agenda



1. 観測変数と潜在変数
2. 観測変数の予測誤差と漸近形
3. 潜在変数の推定誤差と漸近形
4. 考察とまとめ




# 潜在変数を含むモデル

$x$  : 観測変数       $y$  : 潜在変数       $w$  : パラメータ

$$p(x | w) = \sum_y p(x, y | w)$$

例: 混合正規分布

$$p(x | w) = a_1 \text{N}(x | b_1) + a_2 \text{N}(x | b_2)$$



$$p(x | w) = \sum_y p(y) p(x | y) = \sum_y p(x, y | w)$$



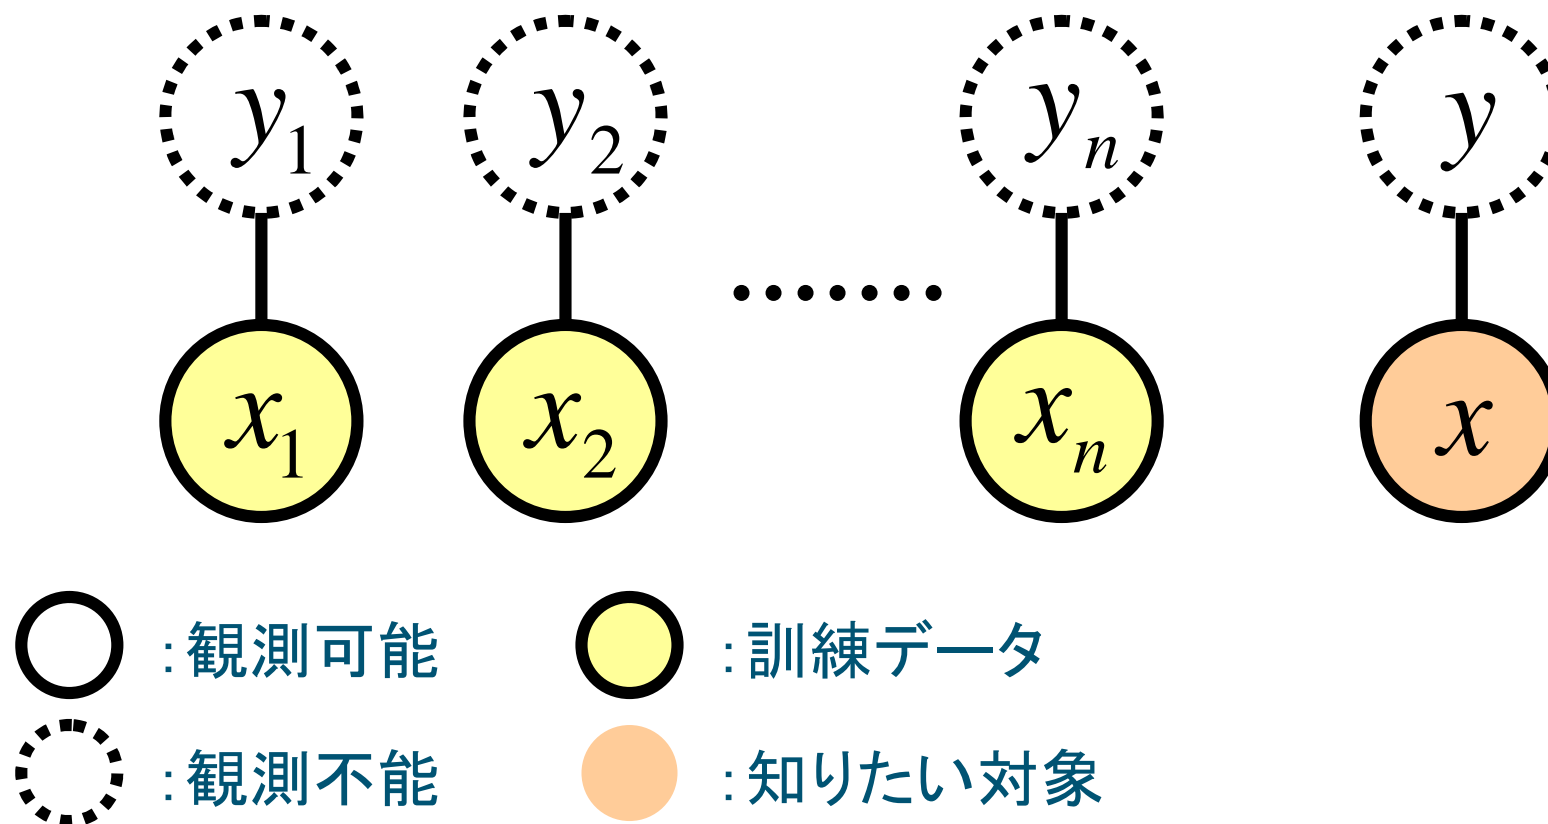
# 推定の種類

- ① 観測変数の予測
- ② 潜在変数の同時推定
- ③ 特定の潜在変数の推定
- ④ 潜在変数の予測



# ① 観測変数の予測

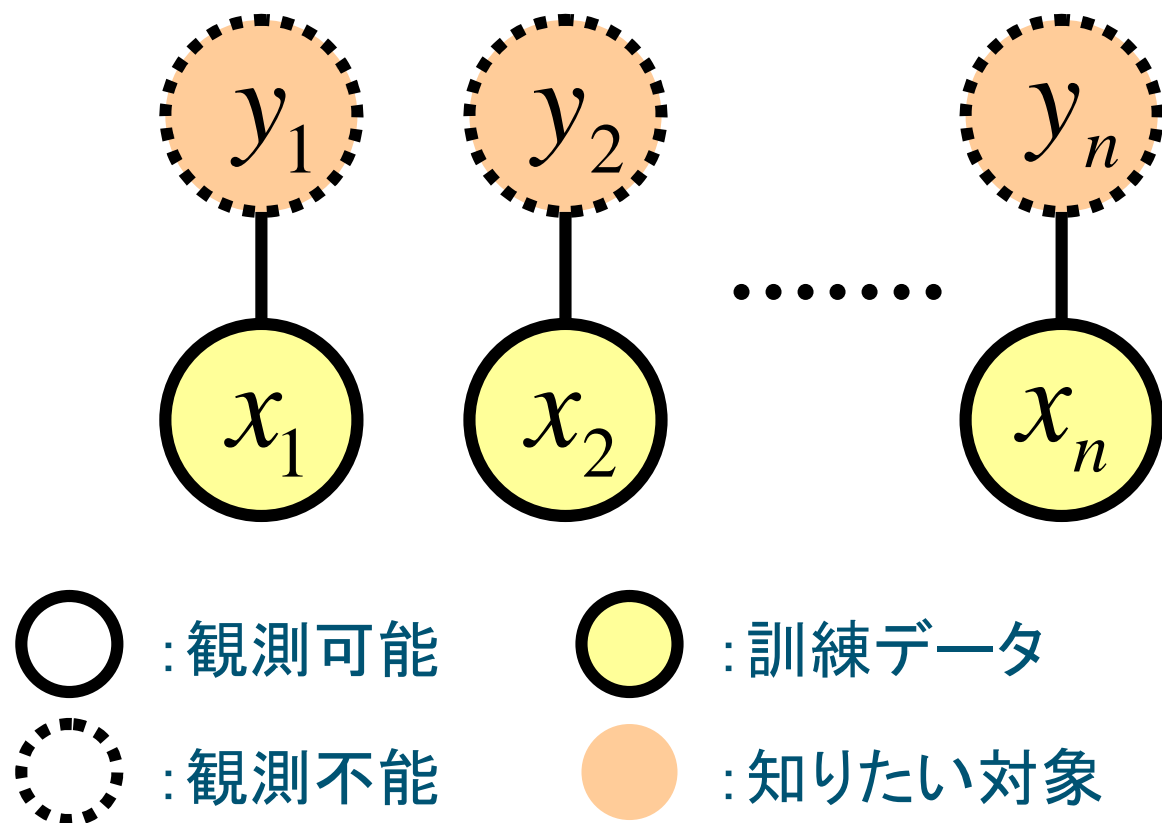
未知の観測データを予測





## ② 潜在変数の同時推定


1 与えられたデータの見えない部分全てを推定





### ③ 特定の潜在変数の推定

┆ ある特定の変数のみを推定



○ : 観測可能

● : 訓練データ

○ (dashed) : 観測不能

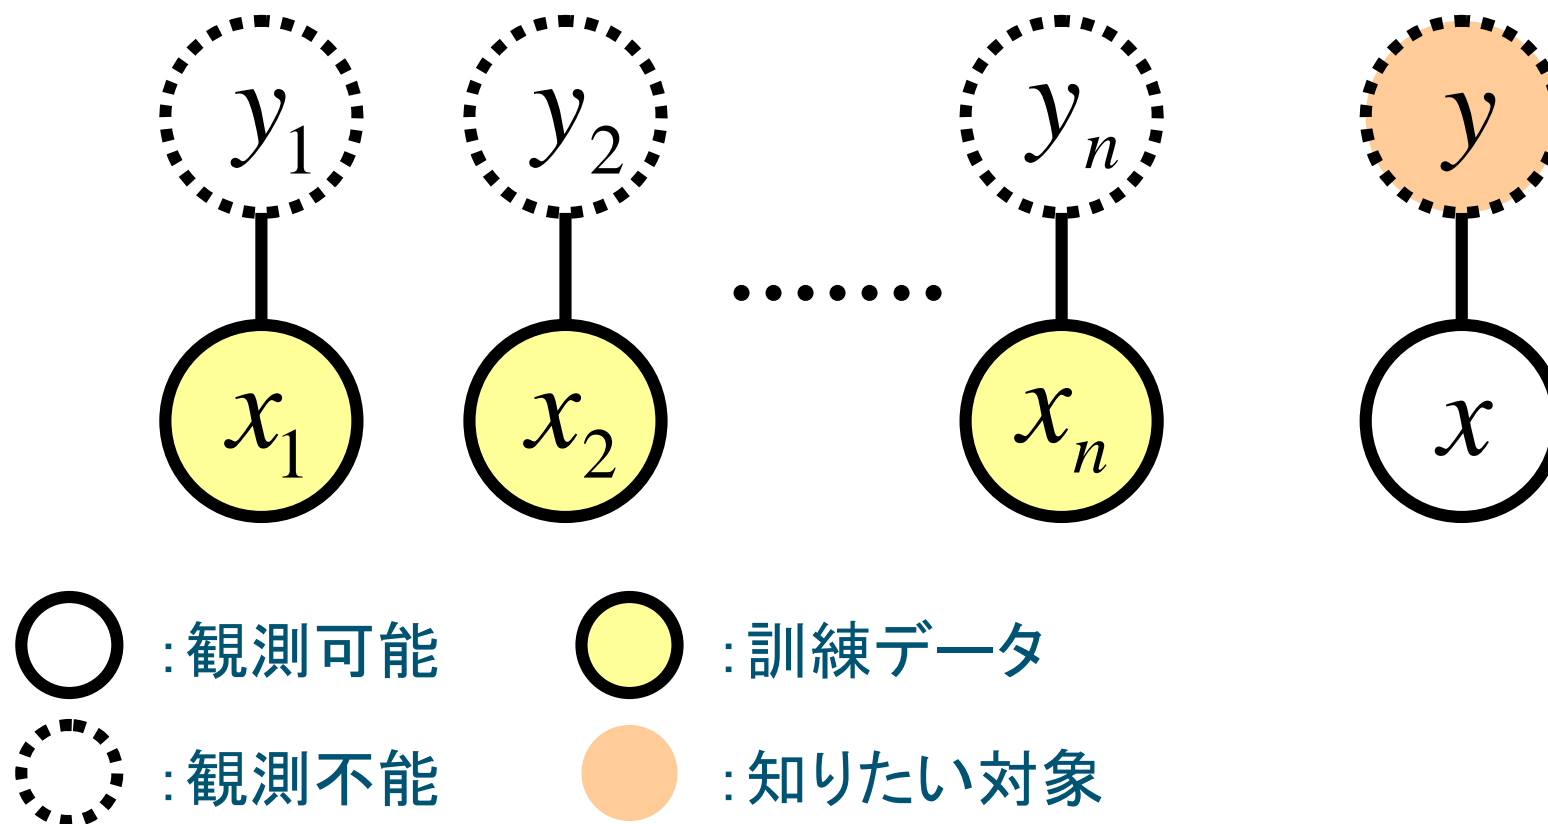
● (orange) : 知りたい対象





## ④ 潜在変数の予測

未知の潜在変数を推定






# 推定の種類

- ① 観測変数の予測
- ② 潜在変数の同時推定
- ③ 特定の潜在変数の推定
- ④ 潜在変数の予測

「② 潜在変数の同時推定」について主に紹介するが、その他の推定についても関連性を適宜述べる

# Agenda

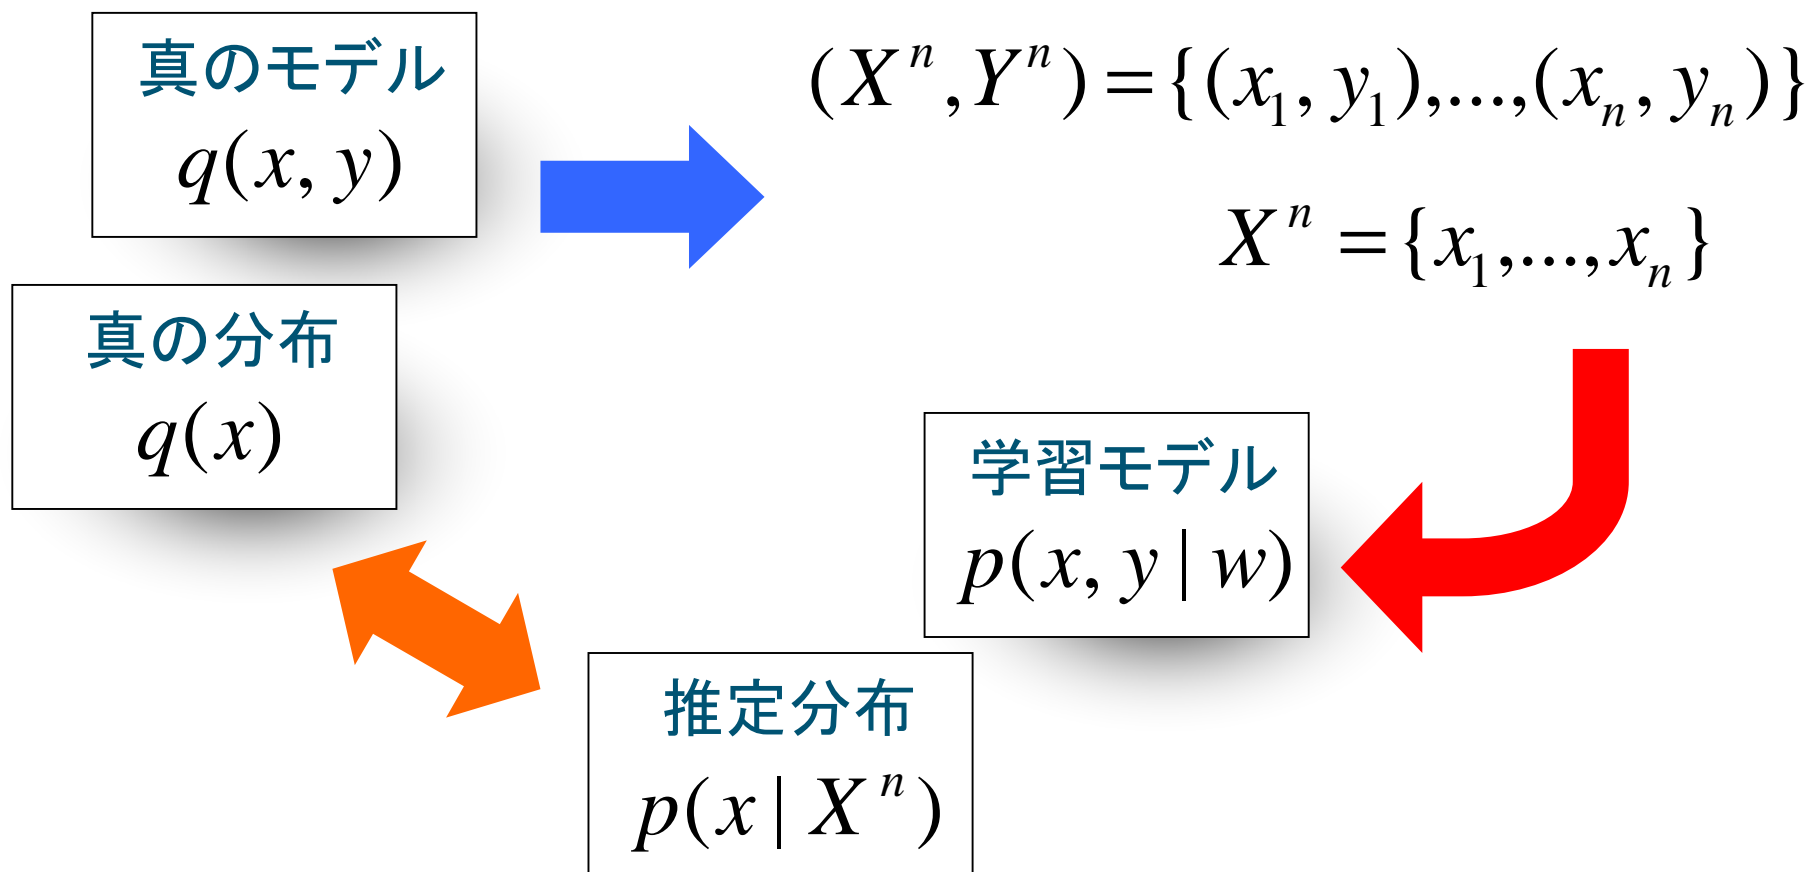


1. 観測変数と潜在変数
- ▶ 2. 観測変数の予測誤差と漸近形
3. 潜在変数の推定誤差と漸近形
4. 考察とまとめ



# 予測精度を評価する枠組み

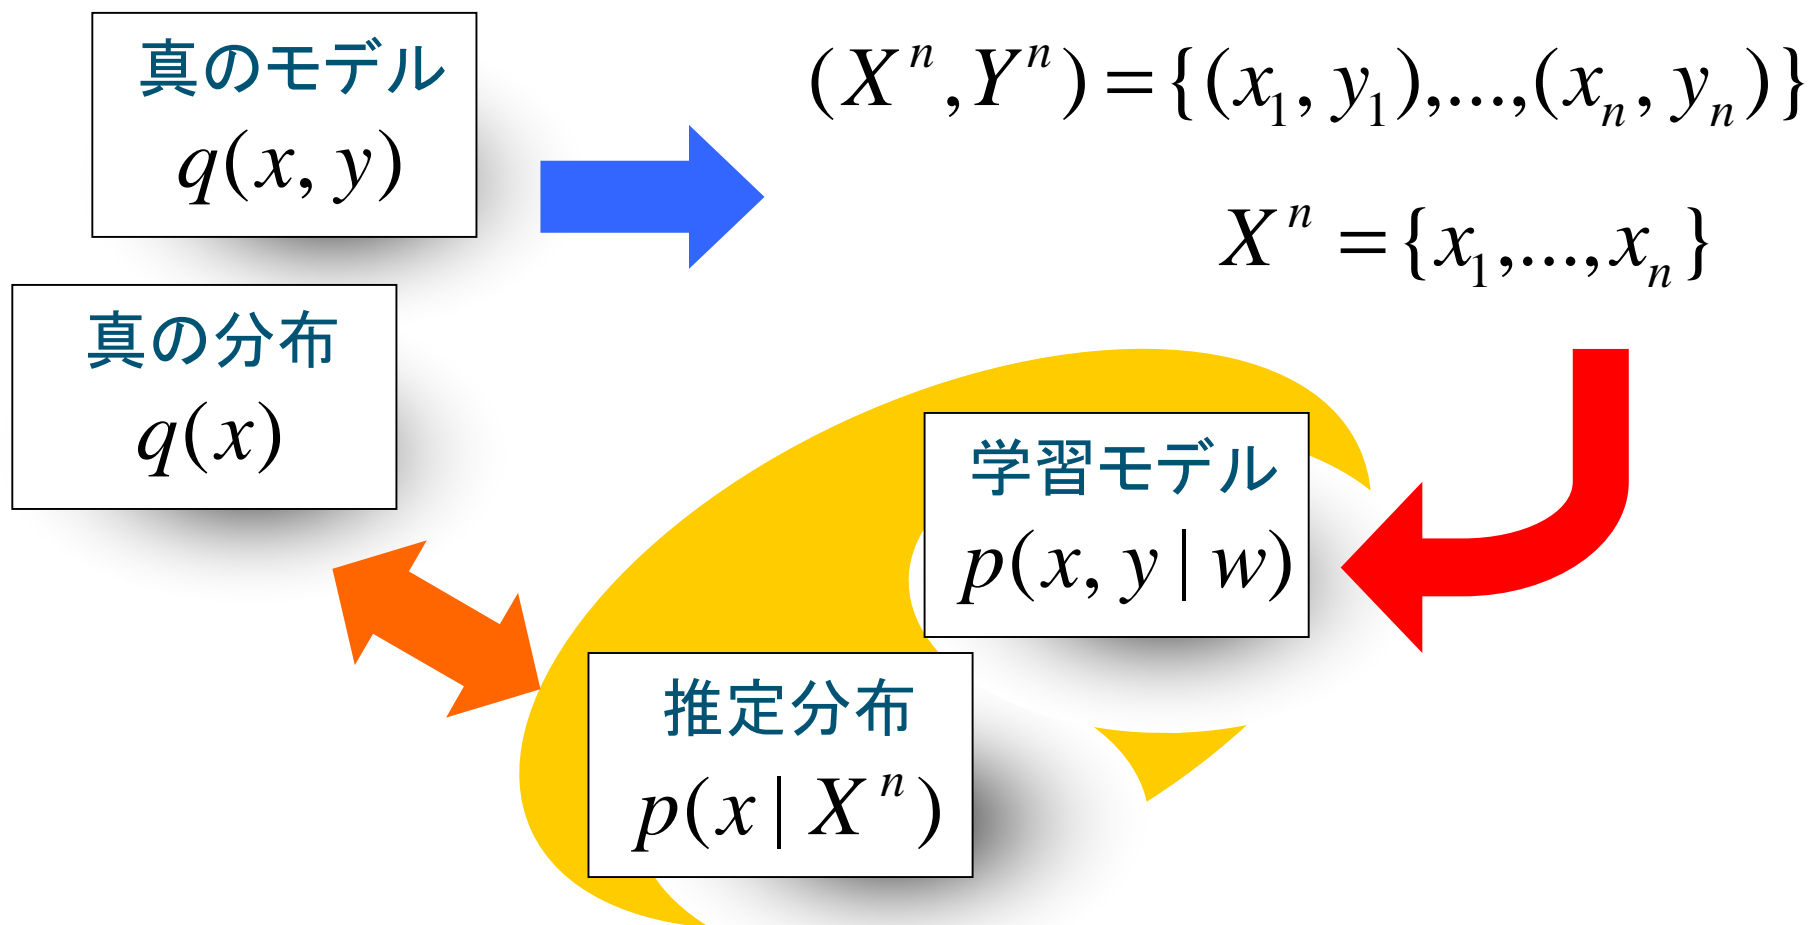
- 真の分布を仮定し推定結果が正しいかを評価





# 予測精度を評価する枠組み

- 真の分布を仮定し推定結果が正しいかを評価





# 観測変数予測の最尤推定

学習モデル  
 $p(x, y | w)$

推定分布  
 $p(x | X^n)$

- 1 訓練データの最尤推定量を用いて予測分布を構成

$$p(x | X^n) = p(x | \hat{w}) = \sum_y p(x, y | \hat{w})$$

$$\hat{w} = \arg \max_w \sum_{i=1}^n \ln p(x_i | w)$$



# 観測変数予測のベイズ推定

学習モデル  
 $p(x, y | w)$

推定分布  
 $p(x | X^n)$

- 事後分布を用いて予測分布を計算

$$p(x | X^n) = \int p(x | w) p(w | X^n) dw$$

$$p(w | X^n) = \frac{\prod_{i=1}^n p(x_i | w) j(w | h)}{\int \prod_{i=1}^n p(x_i | w) j(w | h) dw}$$

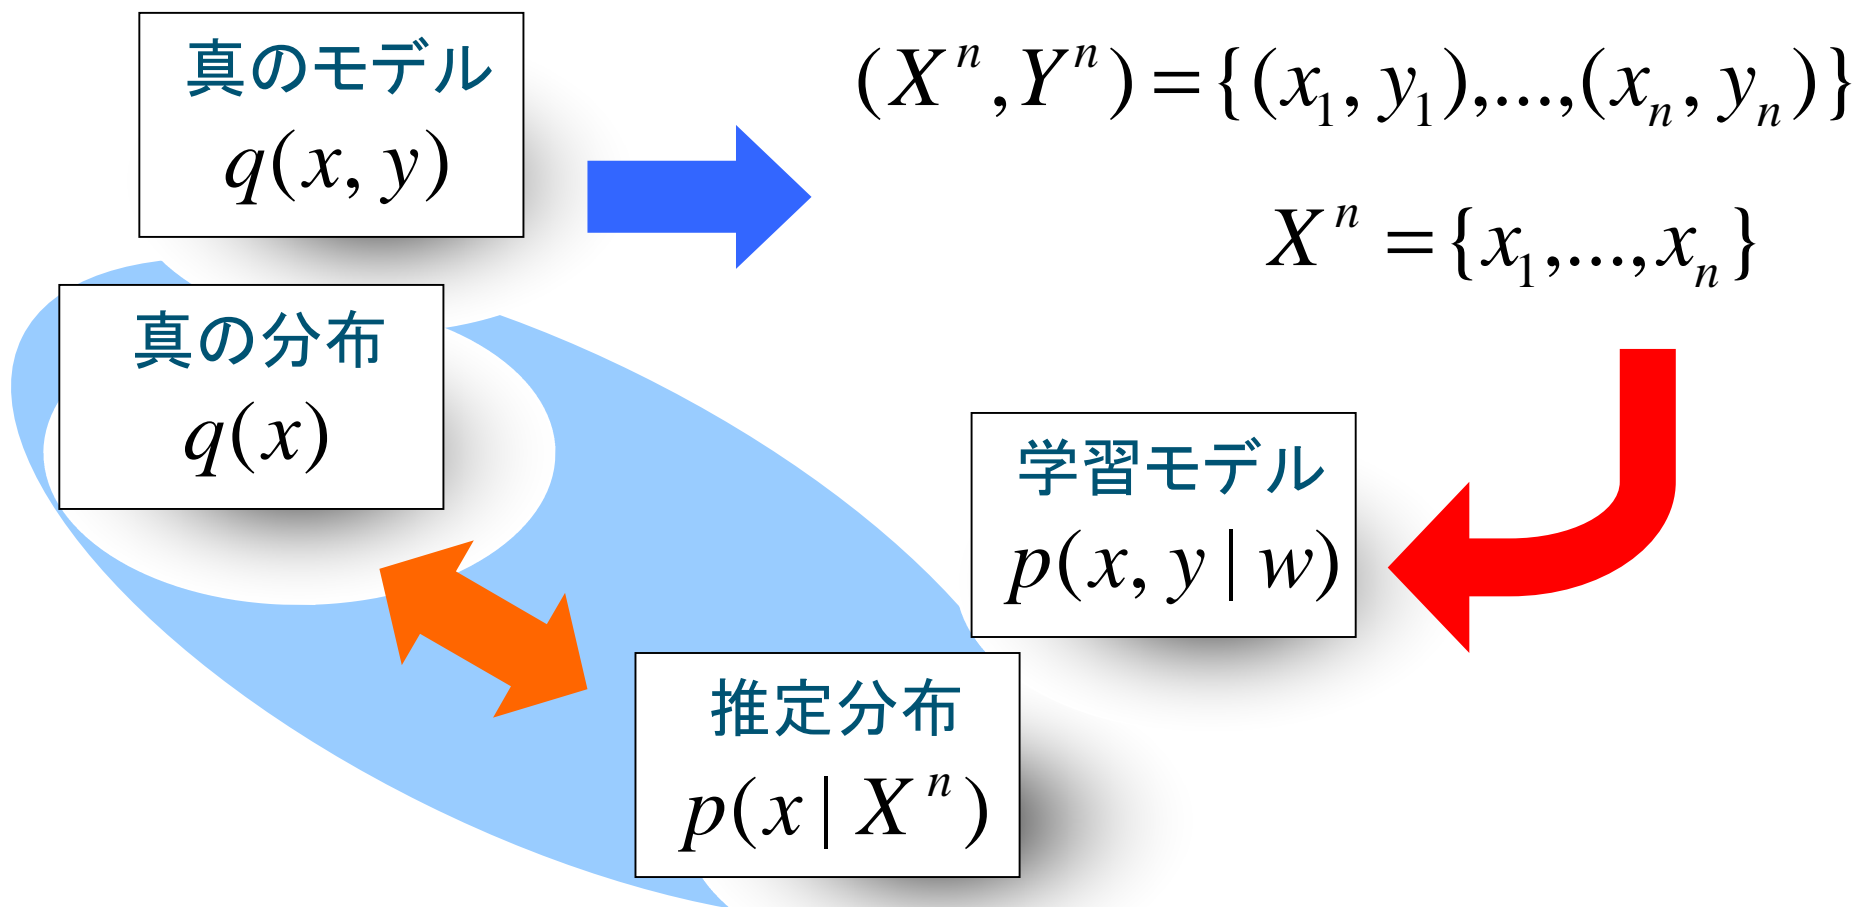
$j(w | h)$  : 事前分布

$h$  : ハイパーパラメータ




# 予測精度を評価する枠組み


- 真の分布を仮定し推定結果が正しいかを評価







# 汎化誤差とその漸近形




- 分布の誤差をKLダイバージェンスで定義

$$G(n) = E_{X^n} \left[ \int q(x) \ln \frac{q(x)}{p(x | X^n)} dx \right]$$

- その漸近形は最尤推定、ベイズ推定ともに

$$G(n) = \frac{\dim w}{2n} + o\left(\frac{1}{n}\right)$$

# Agenda

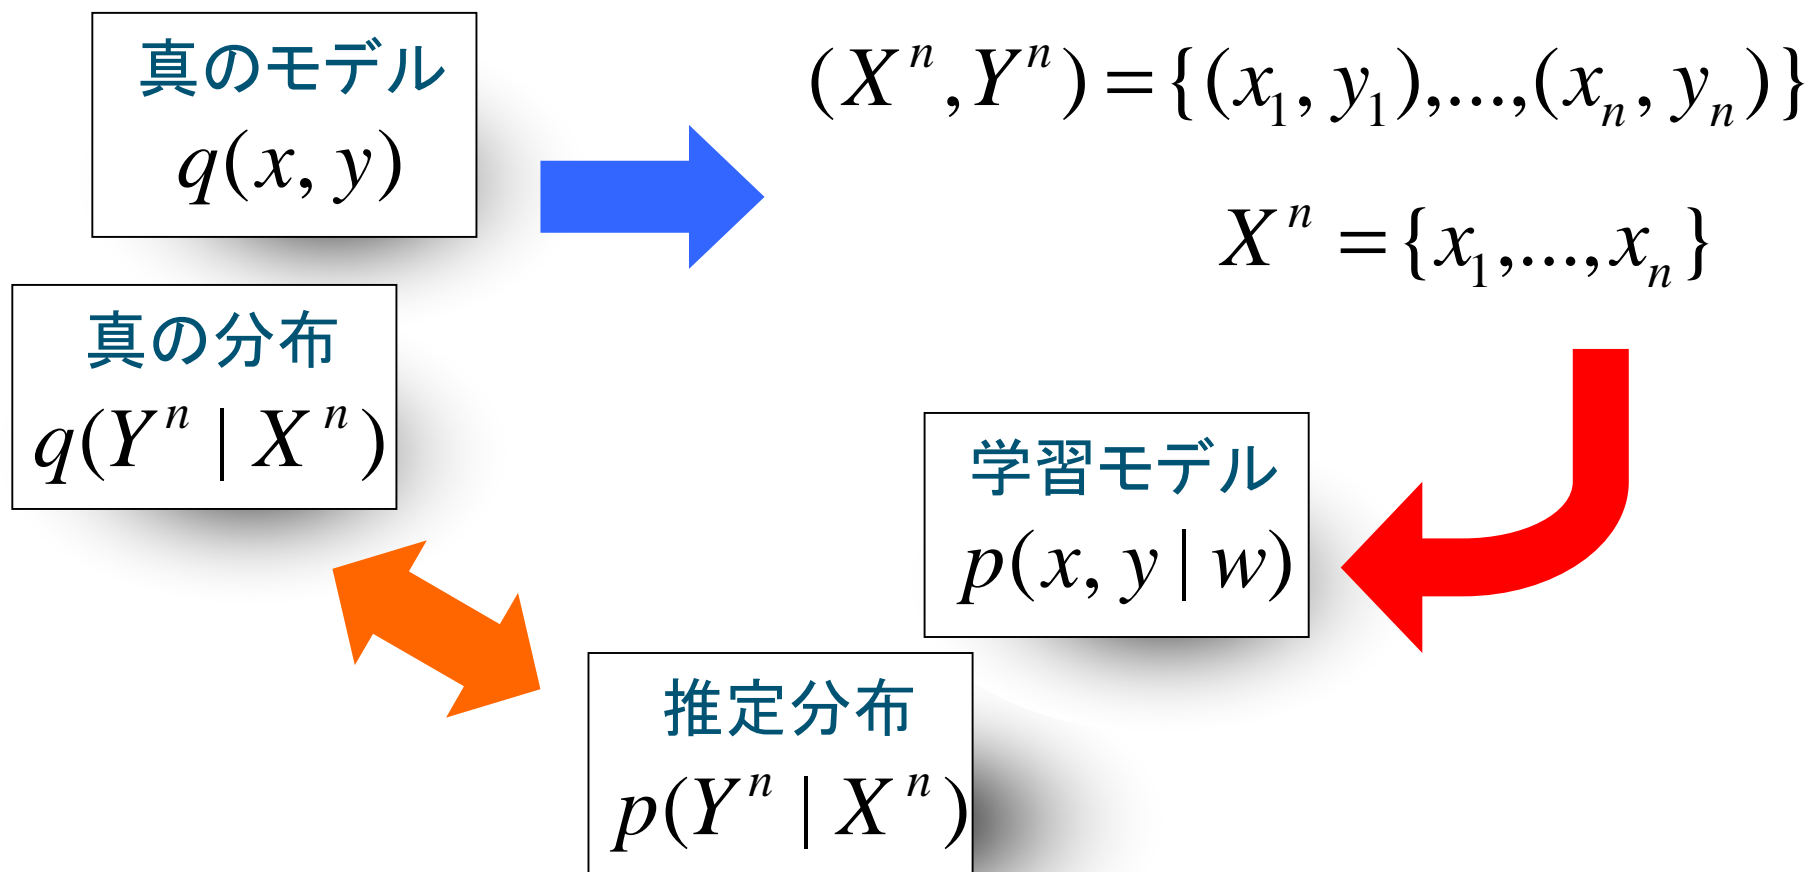


1. 観測変数と潜在変数
2. 観測変数の予測誤差と漸近形
- ▶ 3. 潜在変数の推定誤差と漸近形
4. 考察とまとめ



# 精度評価の枠組み

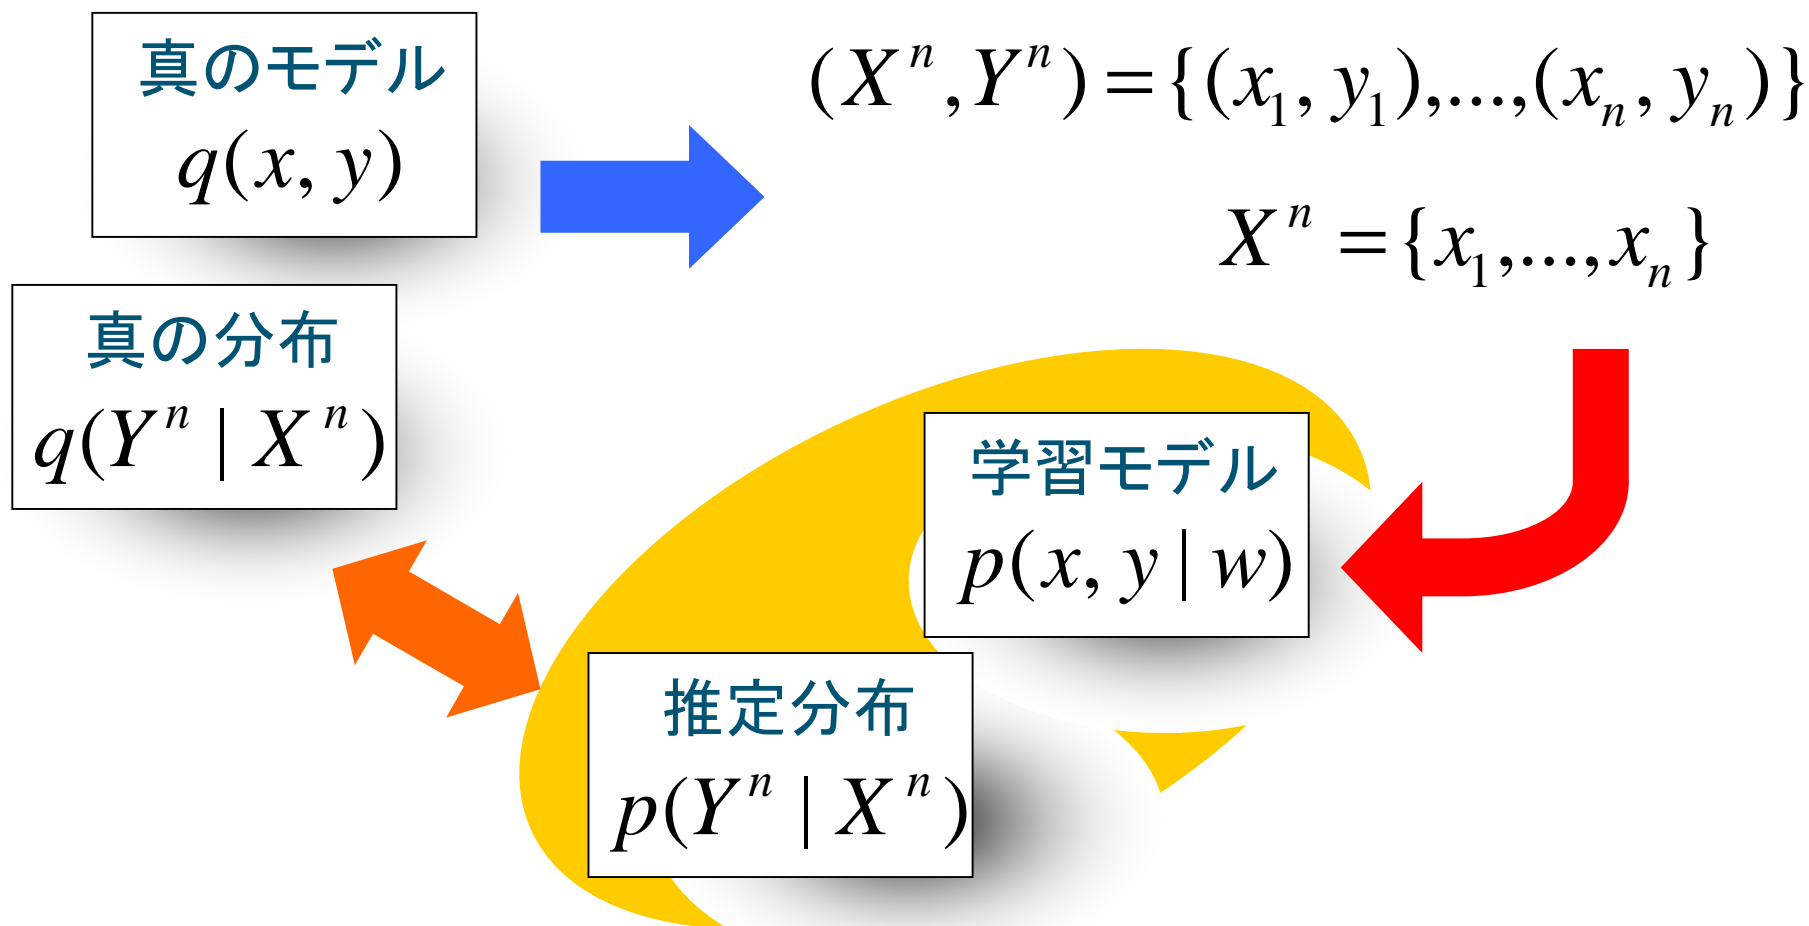
- 真の分布を仮定し推定結果が正しいかを評価





# 精度評価の枠組み

- 真の分布を仮定し推定結果が正しいかを評価





# 最尤推定

- 不完全データの最尤推定量をもとに  
潜在変数の分布を構成

$$\hat{w} = \arg \max_w \sum_{i=1}^n \ln p(x_i | w)$$

$$p(Y^n | X^n) = \prod_{i=1}^n p(y_i | x_i, \hat{w}) = \prod_{i=1}^n \frac{p(x_i, y_i | \hat{w})}{p(x_i | \hat{w})}$$



# ベイズ推定

- | 周辺尤度をもとに潜在変数の分布を構成

$j(w|h)$  : 事前分布

$h$  : ハイパーパラメータ

$$p(Y^n | X^n) = \frac{Z(X^n, Y^n)}{\sum_{Y^n} Z(X^n, Y^n)}$$

$$Z(X^n, Y^n) = \int \prod_{i=1}^n p(x_i, y_i | w) j(w|h) dw$$



# 精度評価の枠組み

- 真の分布を仮定し推定結果が正しいかを評価

真のモデル  
 $q(x, y)$

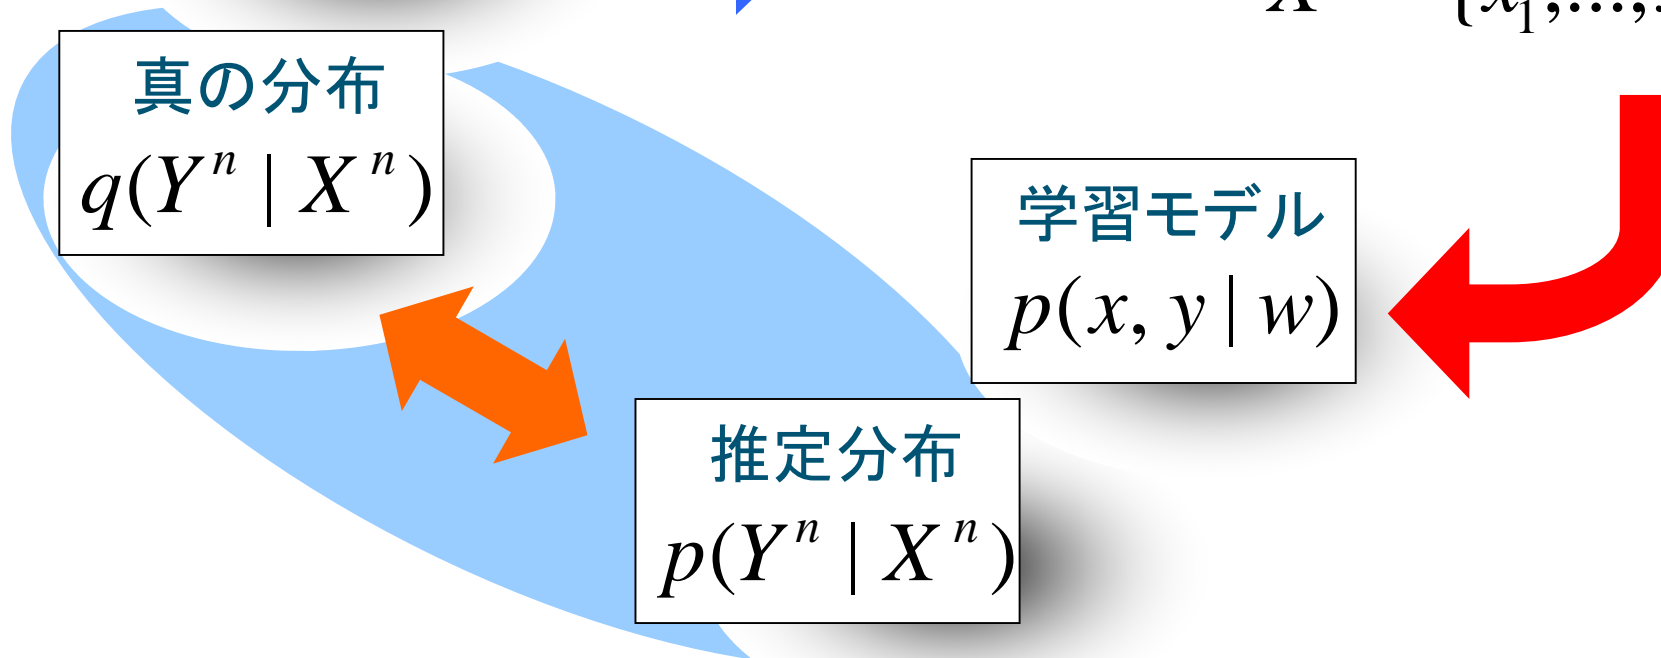
$$(X^n, Y^n) = \{(x_1, y_1), \dots, (x_n, y_n)\}$$

$$X^n = \{x_1, \dots, x_n\}$$

真の分布  
 $q(Y^n | X^n)$

学習モデル  
 $p(x, y | w)$

推定分布  
 $p(Y^n | X^n)$





# 誤差関数: KLダイバージェンス

真の分布  
 $q(Y^n | X^n)$



推定分布  
 $p(Y^n | X^n)$

分布の違いを誤差とする

$$D(n) = \frac{1}{n} E_{X^n} \left[ \sum_{Y^n}^{K^*} q(Y^n | X^n) \ln \frac{q(Y^n | X^n)}{p(Y^n | X^n)} \right]$$





## 誤差の特徴

$$D(n) = \frac{1}{n} E_{X^n} \left[ \sum_{Y^n}^{K^*} q(Y^n | X^n) \ln \frac{q(Y^n | X^n)}{p(Y^n | X^n)} \right]$$

- | データ数で正規化: 潜在変数1つあたりの誤差
- | 真の分布の潜在変数で和をとる
  - | 潜在変数の順序も正しく推定する必要あり



## 他の潜在変数推定の誤差関数

### ③ 潜在変数の周辺分布

$$D_{y|X^n}(n) = E_{X^n} \left[ \frac{1}{n} \sum_{i=1}^n \sum_{y_i} q(y_i | X^n) \ln \frac{q(y_i | X^n)}{p(y_i | X^n)} \right]$$

### ④ 潜在変数の予測

$$D_{y|x}(n) = E_{X^n} \left[ \int q(x) \sum_{y=1}^{K^*} q(y | x) \ln \frac{q(y | x)}{p(y | x, X^n)} dx \right]$$

Predictive Divergence for Indirect Observed model  
[Shimodaira, 1994] と同じもの



# 漸近解析に必要なモデルの仮定

$$p(Y^n | X^n) \rightarrow q(Y^n | X^n)$$

- 学習モデルは真のモデルを達成可能

$$q(x, y) = p(x, y | w^*)$$

- 潜在変数の順序まで推測に成功した場合
- 「真のラベル数 = 学習モデルのラベル数」を仮定

# 誤差の表現に必要な Fisher情報行列の定義



I 不完全データと完全データのFisher情報行列

$$\{I_X(w)\}_{ij} = \int \frac{\partial \ln p(x|w)}{\partial w_i} \frac{\partial \ln p(x|w)}{\partial w_j} p(x|w) dx$$

$$\{I_{XY}(w)\}_{ij} = \int \sum_y \frac{\partial \ln p(x, y|w)}{\partial w_i} \frac{\partial \ln p(x, y|w)}{\partial w_j} p(x, y|w) dx$$

以降  $I_{XY}(w^*) = I_{XY}$ ,  $I_X(w^*) = I_X$  と略記



# 誤差関数の漸近形

データ数が十分大きい場合

$$D(n) = \frac{C}{2n} + o\left(\frac{1}{n}\right)$$

$C$	観測変数予測	潜在変数同時	潜在変数周辺	潜在変数予測
最尤法	$\dim w$	$\text{Tr}[\{I_{XY} - I_X\}I_X^{-1}]$		
ベイズ法	$\dim w$	$\ln \det[I_{XY}I_X^{-1}]$	————	————



# 観測変数予測との違い


- 推定法に依存し主要項の係数が異なる
  - ベイズ法が最尤法よりも小さいことが証明できる

$C$	観測変数予測	潜在変数同時	潜在変数周辺	潜在変数予測
最尤法	$\dim w$	$\text{Tr}[\{I_{XY} - I_X\}I_X^{-1}]$		
ベイズ法	$\dim w$	$\ln \det[I_{XY}I_X^{-1}]$	—————	—————



# 観測変数予測との違い

- 真のパラメータに依存し主要項の係数が異なる
  - 真の分布における「判別のしやすさ」が誤差に表れる



$C$	観測変数予測	潜在変数同時	潜在変数周辺	潜在変数予測
最尤法	$\dim w$	$\text{Tr}[\{I_{XY} - I_X\}I_X^{-1}]$		
ベイズ法	$\dim w$	$\ln \det[I_{XY}I_X^{-1}]$	—	—

# Agenda



1. 観測変数と潜在変数
2. 観測変数の予測
3. 潜在変数の推定誤差
4. 誤差関数の漸近形
5. 考察とまとめ






# 潜在変数における漸近解析の意義



- ┃ 潜在変数は観測不能なためデータから誤差の計算が不可能
- ┃ 観測変数の予測ではクロスバリデーションなど誤差を近似計算する手法があるが、潜在変数の推定では存在しない
- ┃ 精度の検証や推定法の比較がデータから行えないため、解析を行う必要あり



## まとめ

- | 潜在変数の分布推定を定式化した
- | 精度を評価する誤差関数は分布の違い(KLダイバージェンス)で定義した
- | 誤差関数の漸近形を求めた
  - | 最尤推定とベイズ推定の導出が可能
  - | 推定法の比較、観測変数の推定との違い

ご清聴ありがとうございました

潜在変数の分布推定誤差に関する  
漸近解析

東京工業大学 山崎 啓介

