

ガウス型ベイジアンネットワークの構造学習の一致性について

鈴木讓

大阪大学

2009年8月26日
和歌山大学紀南サテライト

あらまし

- 1 確率的学習
- 2 条件付確率の学習
- 3 ARMA の学習
- 4 ガウス型 BN
- 5 ガウス型 BN の学習
- 6 まとめ

確率空間 $(\Omega, \mathcal{F}, \mu)$

Ω : 全体集合

\mathcal{F} が Ω 上の σ 集合体

- ① $\Omega, \phi \in \mathcal{F}$
- ② $A, B \in \mathcal{F} \implies A \cup B, A \cap B, A \setminus B \in \mathcal{F}$

\mathcal{F} の要素を事象という

μ が \mathcal{F} 上の測度

- ① $\mu(\phi) = 0$
- ② $A \in \mathcal{F} \implies \mu(A) \geq 0$
- ③ $A, B \in \mathcal{F}, A \cap B = \phi \implies \mu(A \cup B) = \mu(A) + \mu(B)$

$\mu(\Omega) = 1$ を仮定 (確率測度)

確率的学習

X : 確率変数

μ_X : X の確率測度

$x_1, \dots, x_n \in X(\Omega)$

帰納と演繹

- $x_1, \dots, x_n \mapsto \mu_X$ (確率的学習、設計段階)
- $\mu_X \mapsto x_1, \dots, x_n$ (乱数生成、運用段階)

モデル選択をとまなう問題：条件付確率の学習、ARMA の学習

条件付確率	ARMA
有限型 BN	ガウス型 BN

本研究の目標

ガウス型 BN の構造学習の誤り率の公式を証明
(有限型 BN の構造学習の公式から予想できる)

条件付確率の学習

X, Y : 確率変数

$\mu_{Y|X}$: Y の X のもとでの条件付測度

X のもとでの Y の条件付学習

$$x \sim x' \iff \mu_{Y|X}(y|x) = \mu_{Y|X}(y|x'), \quad y \in Y(\Omega)$$

n 個の例から $X(\Omega)$ の同値関係 \sim を見出す

仮定

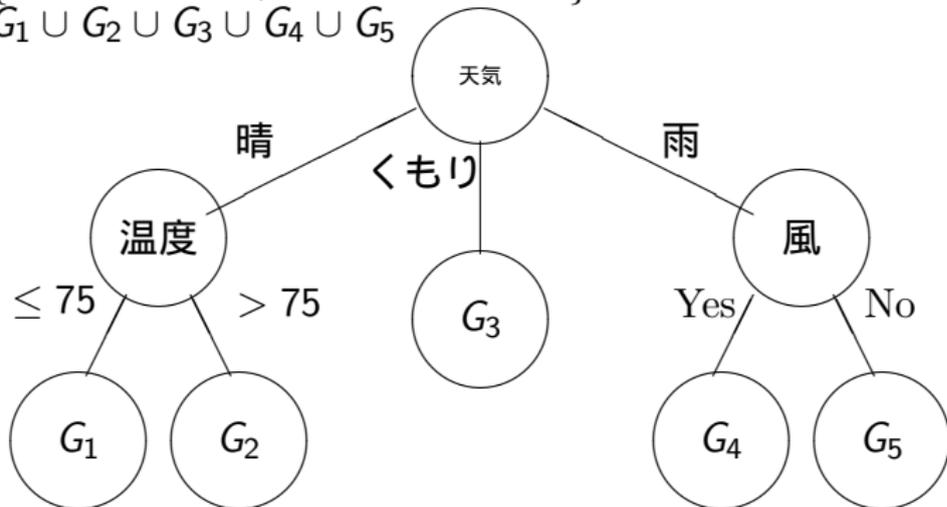
$$|Y(\Omega)| < \infty$$

条件付確率の学習: 応用

確率的決定木 $Y|X$ 例から $X(\Omega)$ の分割を見出す

$$Y(\Omega) = \{ \text{ゴルフできる, ゴルフできない} \}$$

$$X(\Omega) = G_1 \cup G_2 \cup G_3 \cup G_4 \cup G_5$$

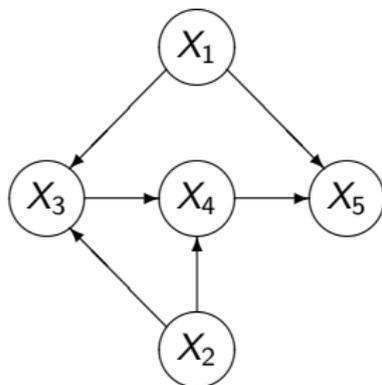


条件付確率の学習: 応用

有限型 BN $X_i | X_j, j \in \pi(i)$

例から $\pi(i) \subseteq \{1, \dots, i-1\}$ を見出す

- ① X_2 は X_1 とは独立
- ② X_3 は X_1, X_2 に依存
- ③ X_4 は X_2, X_3 に依存
- ④ X_5 は X_1, X_4 に依存



条件付確率の学習: 定式化

n 個の例 $z^n := (z_1, \dots, z_n) \in Z^n(\Omega)$ から、 $X(\Omega)$ の分割を見出す

$$z_i := (x_i, y_i) \in Z(\Omega) := X(\Omega) \times Y(\Omega)$$

仮定

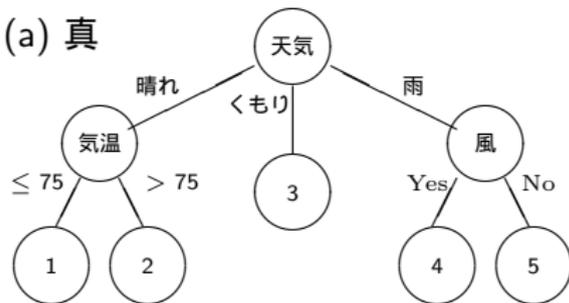
有限個に分割される

2 種類の誤り

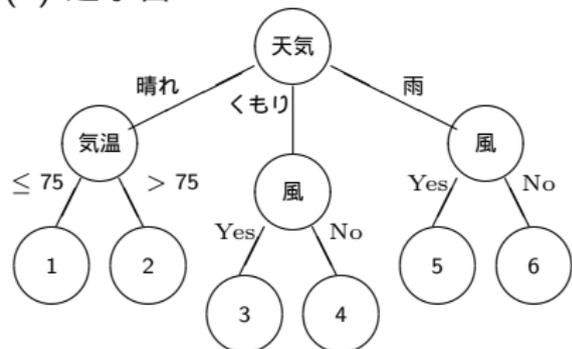
- 真のものより細かく分割される (過学習)
- 荒く分割されてる箇所がある (未学習)

例: Quinlan の Q4.5

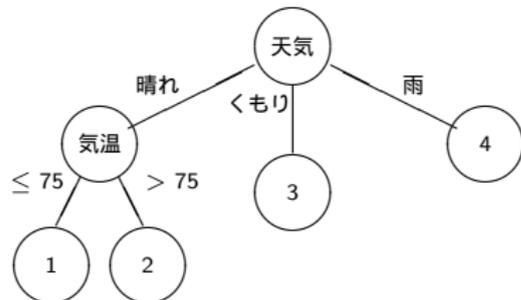
(a) 真



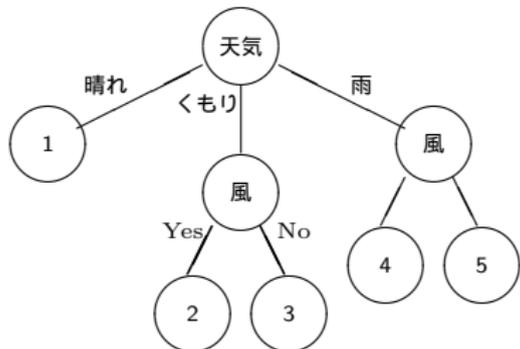
(b) 過学習



(c) 未学習



(d) 未学習



情報量基準の適用

例 $z^n \in Z^n(\Omega)$ から、

$$l(\mathcal{G}, z^n) := H(\mathcal{G}, z^n) + \frac{k(\mathcal{G})}{2} d_n$$

を最小にする分割 \mathcal{G} を見出す

$H(\mathcal{G}, z^n)$: 経験的エントロピー (例 z^n の分割 \mathcal{G} への適合性)

$k(\mathcal{G})$: パラメータ数 (\mathcal{G} の簡潔さ)

$$d_n \geq 0: \frac{d_n}{n} \rightarrow 0$$

$$d_n = \log n \quad \text{BIC/MDL}$$

$$d_n = 2 \quad \text{AIC}$$

一貫性

一貫性 ($n \rightarrow \infty$ で、推定結果が真のそれに一致)

弱一貫性 確率収束 ($O(1) < d_n < o(n)$)

強一貫性 概収束 (MDL/BIC etc.)

AIC ($d_n = 2$) は、 $\{d_n\}$ が小さすぎて、一貫性を満足しない

問題

強一貫性を満足する最小の $\{d_n\}$ は何か？

答え (Suzuki, 2006)

$$d_n = 2 \log \log n$$

(重複対数の法則)

誤り確率

\mathcal{G}^* : 真の分割

$$\mu\{\omega \in \Omega \mid I(\mathcal{G}, Z^n(\omega)) < I(\mathcal{G}^*, Z^n(\omega))\}$$

分割 \mathcal{G} が \mathcal{G}^* の過学習

$$\int_{(K(\mathcal{G}) - K(\mathcal{G}^*))d_n}^{\infty} f_{K(\mathcal{G}) - K(\mathcal{G}^*)}(x) dx$$

f_l : 自由度 l の χ^2 分布の確率密度関数

分割 \mathcal{G} が \mathcal{G}^* の未学習

n とともに指数的に 0 に低減

ARMA の学習

$$k \geq 0$$

$$\{\lambda_j\}_{j=1}^k: \lambda_i \in \mathbb{R}$$

$$\sigma^2 \in \mathbb{R}_{>0}$$

ARMA (Autoregressive Moving Average, 自己回帰移動平均)

$$\{X_n\}_{n=-\infty}^{\infty}: X_n + \sum_{j=1}^k \lambda_j X_{n-j} = \epsilon_i \sim \mathcal{N}(0, \sigma^2)$$

ARMA の学習

n 個の例から

次数 k が既知 係数 $\{\lambda_j\}_{j=1}^k$ を見出す

次数 k が未知 次数 k と係数 $\{\lambda_j\}_{j=1}^k$ を見出す

Yule-Walker 方程式

次数 k が既知のとき、以下を $\{\hat{\lambda}_{j,k}\}_{j=1}^k$ および $\hat{\sigma}_k^2$ について解く。

$$\bar{x} := \frac{1}{n} \sum_{i=1}^n x_i$$

$$c_j := \frac{1}{n} \sum_{i=1}^{n-j} (x_i - \bar{x})(x_{i+j} - \bar{x}), \quad j = 0, \dots, k$$

$$\begin{bmatrix} -1 & c_1 & c_2 & \cdots & c_k \\ 0 & c_0 & c_1 & \cdots & c_{k-1} \\ 0 & c_1 & c_0 & \cdots & c_{k-2} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & c_{k-1} & c_{k-2} & \cdots & c_0 \end{bmatrix} \begin{bmatrix} \hat{\sigma}_k^2 \\ \hat{\lambda}_{1,k} \\ \hat{\lambda}_{2,k} \\ \vdots \\ \hat{\lambda}_{k,k} \end{bmatrix} = \begin{bmatrix} -c_0 \\ -c_1 \\ -c_2 \\ \vdots \\ -c_k \end{bmatrix}$$

情報量基準の適用

次数 k が未知のとき、例 $x^n \in X^n(\Omega)$ から、 $l(k, x^n)$ 最小の k を見出す

$$l(k, x^n) := \frac{1}{2} \log \hat{\sigma}_k^2 + \frac{k}{2} d_n$$

$\hat{\sigma}_k^2$: Yule-Walker 方程式から

$$d_n \geq 0: \frac{d_n}{n} \rightarrow 0$$

$$d_n = \log n \quad \text{BIC/MDL}$$

$$d_n = 2 \quad \text{AIC}$$

$$d_n = 2 \log \log n \quad \text{Hannan-Quinn (1979)}$$

\implies 強一致性を満足する **最小の** $\{d_n\}$

- Suzuki (2006)
- Hannan-Quinn (1979)

誤り確率 (未学習, ARMA)

k_* : 真の次数

$$\mu\{\omega \in \Omega \mid I(k, X^n(\omega)) < I(k_*, X^n(\omega))\}$$

$k_* > k$ (未学習, ARMA)

n とともに指数的に 0 近づく (Hannan-Quinn, 1979)

研究のねらい

	条件付確率 (領域分割 \mathcal{G})	ARMA (次数 k)
強一致性 のための 最小の d_n	$2 \log \log n$ (Suzuki, 2006)	$2 \log \log n$ (Hannan-Quinn, 1979)
誤り確率 (未学習)	指数的に 0 (Suzuki, 2006)	指数的に 0 (Hannan-Quinn, 1979)
誤り確率 (過学習)	$\int_{(K(\mathcal{G})-K(\mathcal{G}^*))d_n}^{\infty} f_{K(\mathcal{G})-K(\mathcal{G}^*)}(x) dx$ (Suzuki, 2006)	$\int_{(k-k_*)d_n}^{\infty} f_{k-k_*}(x) dx$?

$k^* < k$ (過学習, ARMA)

$$\int_{(k-k_*)d_n}^{\infty} f_{k-k_*}(x) dx$$

を証明する

証明のスケッチ

$k = k_* + 1, k_* + 2, \dots$ に対して、確率 1 で、

$$2\{l(k, x^n) - l(k-1, x^n)\} = -n\hat{\lambda}_{k,k}^2 + d_n$$

が成立する (Hannan-Quinn, 1979) ので、

$$\mu_k := \sqrt{n}\hat{\lambda}_{k,k} \sim \mathcal{N}(0, 1)$$

でしかも独立であることをいえば、

$$\sum_{j=k_*+1}^k 2\{l(j, x^n) - l(j-1, x^n)\} = \sum_{j=k_*+1}^k \mu_j^2 \sim \chi_{k-k_*}^2$$

が成立する。

定常エルゴードな確率過程の中心極限定理

$\{X_j\}_{j=-\infty}^{\infty}$: 定常エルゴード
 $S_n := \sum_{j=1}^n X_j$

Hyde, 1974

① $E[X_0] = 0, E[X_0^2] < \infty$

X_0 が \mathcal{G} 上可測 ($\mathcal{G} \subseteq \mathcal{F}$) であるとして、

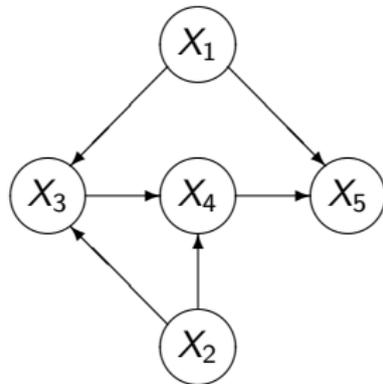
② $\sum_{j=1}^{\infty} E[X_j E[X_N | \mathcal{G}]]$ が、各 $N \geq 1$ で収束

③ $\sum_{j=J}^{\infty} E[X_j E[X_N | \mathcal{G}]]$ が、 J について一様に、 $N \rightarrow \infty$ で 0 に収束

$\implies S_n / (\sigma \sqrt{n}) \sim \mathcal{N}(0, 1)$

ガウス型 BN

- ① $X_2 = \epsilon^{(2)} \sim \mathcal{N}(0, \sigma_2^2)$
- ② $\lambda_1^{(3)} X_1 + \lambda_2^{(3)} X_2 + X_3 = \epsilon^{(3)} \sim \mathcal{N}(0, \sigma_3^2)$
- ③ $\lambda_2^{(4)} X_2 + \lambda_3^{(4)} X_3 + X_4 = \epsilon^{(4)} \sim \mathcal{N}(0, \sigma_4^2)$
- ④ $\lambda_1^{(5)} X_1 + \lambda_4^{(5)} X_4 + X_5 = \epsilon^{(5)} \sim \mathcal{N}(0, \sigma_5^2)$



ガウス型 BN の学習

$$i = 1, \dots, N$$

$$\sum_{j \in \pi(i)} \lambda_j^{(i)} X_j + X_i = \epsilon^{(i)}$$

n 個の例 $x^n = (x_1, \dots, x_n)$

$x_m = (x_{m,1}, \dots, x_{m,N}) \in X_1(\Omega) \times \dots \times X_N(\Omega), m = 1, \dots, n$

Yule-Walker 方程式

$$c_{j,h} := \frac{1}{n} \sum_{m=1}^n x_{m,j} x_{m,h}, j, h \in \pi(i) \cup \{i\}$$

$$\sum_{j \in \pi(i)} \lambda_j^{(i)} c_{j,h} + c_{i,h} = \sigma_i^2 \delta_{i,h}, h \in \pi(i) \cup \{i\}$$

$(|\pi(i)| + 1)$ 個の変数、 $|\pi(i)| + 1$ 式の連立方程式

ガウス型 BN の構造学習の誤り率

正しい $\pi_*(i) = \pi(i)$

過学習 $\pi_*(i) \subset \pi(i)$

未学習 $\pi_*(i) \not\subset \pi(i)$

強一様性のための最小の d_n

$$d_n = 2 \log \log n$$

誤り確率 (過学習)

$$\int_{(|\pi(i) - \pi_*(i)|) d_n}^{\infty} f_{|\pi(i) - \pi_*(i)|}(x) dx$$

誤り確率 (未学習)

n とともに指数的に 0

まとめ

条件付確率	ARMA
有限型 BN	ガウス型 BN

証明したこと: ARMA

- 誤り確率 (過学習)

証明したこと: ガウス型 BN

- 強一致性のための最小の d_n
- 誤り確率 (過学習)
- 誤り確率 (未学習)

課題

なぜ似てくるのか、指数分布族で共通の特徴があるのか