

鈴木讓「ベイジアンネットワーク入門」(培風館)

### 3. 統計的学習

#### 3.6 Gauss 型 Bayesian ネットワークの学習

鈴木讓

大阪大学

2010年7月7日

あらまし

ARMA

線形回帰

ガウス型 Bayesian ネットワークの構造学習

## 自己回帰移動平均, **AutoRegressive Moving Average**

$\{W_i\}_{i=-\infty}^{\infty}$ : 平均 0 分散 1 の独立同一分布にしたがう確率変数の列

$\{\lambda_i\}_{i=1}^k$ : 実数の列

$\{X_i\}_{i=-\infty}^{\infty}$ : 平均 0 の確率変数の列

$$X_i = \sum_{j=1}^k \lambda_j X_{i-j} + W_i$$

## Yule-Waker 方程式

$\{X_i\}$ : 定常 より、 $\gamma_m := E[X_i X_{i+m}]$ ,  $m \geq 0$  が、 $i$  によらない

### Yule-Waker 方程式

$$\gamma_m = \sum_{j=1}^k \lambda_j \gamma_{m-j} + \delta_{0m} \sigma^2$$

$\{\gamma_m\}_{m=0}^k$  の値から、 $\lambda_0 := \sigma^2$ ,  $\{\lambda_m\}_{m=1}^k$  の値を求める

$$\begin{bmatrix} -1 & \gamma_1 & \gamma_2 & \cdots & \gamma_k \\ 0 & \gamma_0 & \gamma_1 & \cdots & \gamma_{k-1} \\ 0 & \gamma_1 & \gamma_0 & \cdots & \gamma_{k-2} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & \gamma_{k-1} & \gamma_{k-2} & \cdots & \gamma_0 \end{bmatrix} \begin{bmatrix} \sigma_k^2 \\ \lambda_1 \\ \lambda_2 \\ \vdots \\ \lambda_k \end{bmatrix} = \begin{bmatrix} -\gamma_0 \\ -\gamma_1 \\ -\gamma_2 \\ \vdots \\ -\gamma_k \end{bmatrix},$$

$k$ : 既知、 $\{\gamma_m\}_{m=0}^k$ : 未知 のとき

$x = (x_1, \dots, x_n) \in X_1(\Omega) \times \dots \times X_n(\Omega)$  から、

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

$$\hat{\gamma}_m := \hat{\gamma}_{-m} := \frac{1}{n} \sum_{i=1}^{n-m} (x_i - \bar{x})(x_{i+m} - \bar{x})$$

を計算して  $\gamma_m$  の推定値とする

$$\begin{bmatrix} -1 & \hat{\gamma}_1 & \hat{\gamma}_2 & \cdots & \hat{\gamma}_k \\ 0 & \hat{\gamma}_0 & \hat{\gamma}_1 & \cdots & \hat{\gamma}_{k-1} \\ 0 & \hat{\gamma}_1 & \hat{\gamma}_0 & \cdots & \hat{\gamma}_{k-2} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & \hat{\gamma}_{k-1} & \hat{\gamma}_{k-2} & \cdots & \hat{\gamma}_0 \end{bmatrix} \begin{bmatrix} \hat{\sigma}^2 \\ \hat{\lambda}_1 \\ \hat{\lambda}_2 \\ \vdots \\ \hat{\lambda}_k \end{bmatrix} = \begin{bmatrix} -\hat{\gamma}_0 \\ -\hat{\gamma}_1 \\ -\hat{\gamma}_2 \\ \vdots \\ -\hat{\gamma}_k \end{bmatrix},$$

$k$ : 未知、 $\{\gamma_m\}_{m=0}^k$ : 未知 のとき

1.

$$\begin{bmatrix} -1 & \hat{\gamma}_1 & \hat{\gamma}_2 & \cdots & \hat{\gamma}_k \\ 0 & \hat{\gamma}_0 & \hat{\gamma}_1 & \cdots & \hat{\gamma}_{k-1} \\ 0 & \hat{\gamma}_1 & \hat{\gamma}_0 & \cdots & \hat{\gamma}_{k-2} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & \hat{\gamma}_{k-1} & \hat{\gamma}_{k-2} & \cdots & \hat{\gamma}_0 \end{bmatrix} \begin{bmatrix} \hat{\sigma}_k^2 \\ \hat{\lambda}_{1,k} \\ \hat{\lambda}_{2,k} \\ \vdots \\ \hat{\lambda}_{k,k} \end{bmatrix} = \begin{bmatrix} -\hat{\gamma}_0 \\ -\hat{\gamma}_1 \\ -\hat{\gamma}_2 \\ \vdots \\ -\hat{\gamma}_k \end{bmatrix},$$

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

を計算して、この値を最小にする  $k$  ( $\hat{k}$  とおく) を推定値

2. そのときの連立方程式の解  $\hat{\lambda}_{0,k} := \hat{\sigma}_{\hat{k}}^2$ ,  $\{\hat{\lambda}_{m,\hat{k}}\}_{m=1}^{\hat{k}}$

## Hannan-Quinn, 1979

一般に、

$$\hat{\sigma}_k^2 = \{1 - \hat{\lambda}_{k,k}^2\} \hat{\sigma}_{k-1}^2$$

$k = 1, 2, \dots$  が成立し、

$$\begin{aligned} 2\{L(x^n, k) - L(x^n, k-1)\} &= n \log \frac{\hat{\sigma}_k^2}{\hat{\sigma}_{k-1}^2} + d_n \\ &\leq -n\left(1 - \frac{\hat{\sigma}_k^2}{\hat{\sigma}_{k-1}^2}\right) + d_n = -n\hat{\lambda}_{k,k}^2 + d_n \end{aligned}$$

## Hannan-Quinn, 1979 (続)

$k^*$ : 真の  $k$

$n \rightarrow \infty$

$k \leq k^*$  確率 1 で  $\frac{\hat{\sigma}_k^2}{\hat{\sigma}_{k-1}^2} \rightarrow \exists K < 1$

$$L(x^n, 0) > L(x^n, 1) > \cdots > L(x^n, k^* - 1) > L(x^n, k^*)$$

$k \geq k^* + 1$  確率 1 で  $\frac{\hat{\sigma}_k^2}{\hat{\sigma}_{k-1}^2} \rightarrow 1$

重複対数の法則から、 $\frac{\hat{\lambda}_{k,k}^2}{2n^{-1} \log \log n} \leq 1$  を導出

$$d_n = 2c \log \log n, c > 1 \implies L(x^n, k^*) < L(x^n, k^* + 1) < \cdots$$



## 線形回帰

$$\epsilon \sim \mathcal{N}(0, \sigma^2)$$

$Y, X_1, \dots, X_p$ :  $Y = \sum_{j=1}^p \alpha_j X_j + \epsilon$  にしたがう確率変数

$X_{p+1}, \dots, X_m$ :  $Y - \sum_{j=1}^p \alpha_j X_j$  と独立な確率変数 ( $0 \leq p \leq m$ )

独立に生成した  $n$  個の例  $\{(y_i, x_{i,1}, \dots, x_{i,m})\}_{i=1}^n$

$$y_i \in Y(\Omega), (x_{i,1}, \dots, x_{i,m}) \in X_1(\Omega) \times \dots \times X_m(\Omega)$$

### 仮定

$$\begin{bmatrix} x_{1,j} \\ \vdots \\ x_{n,j} \end{bmatrix}, j = 1, \dots, m : \text{確率 1 で一次独立}$$

## 最小 2 乘法

$$\boldsymbol{\alpha} := \begin{bmatrix} \alpha_1 \\ \vdots \\ \alpha_m \end{bmatrix} \text{ (未知)}$$

$$\mathbf{y} = \mathbf{X}_m \boldsymbol{\alpha} + \boldsymbol{\epsilon}$$

$$\mathbf{X}_m := \begin{bmatrix} x_{1,1} & \cdots & x_{1,m} \\ \vdots & \ddots & \vdots \\ x_{n,1} & \cdots & x_{n,m} \end{bmatrix}, \quad \mathbf{y} := \begin{bmatrix} y_1 \\ \vdots \\ y_n \end{bmatrix}$$

$$\Rightarrow \hat{\boldsymbol{\alpha}} = \begin{bmatrix} \hat{\alpha}_1 \\ \vdots \\ \hat{\alpha}_m \end{bmatrix} := (\mathbf{X}_m^T \mathbf{X}_m)^{-1} \mathbf{X}_m^T \mathbf{y}$$

## 2乗誤差の差

$$P_m := \mathbf{X}_m(\mathbf{X}_m^T \mathbf{X}_m)^{-1} \mathbf{X}_m^T$$

$$P_m^2 = P_m$$

$$(I - P_m)^2 = I - P_m$$

$$\begin{aligned} S_m &:= \sum_{i=1}^n (y_i - \sum_{j=1}^m \hat{\alpha}_j x_{i,j})^2 = \|\mathbf{y} - \mathbf{X}_m \hat{\boldsymbol{\alpha}}\|^2 \\ &= \|(I - P_m)\mathbf{y}\|^2 = \mathbf{y}^T (I - P_m) \mathbf{y} \end{aligned}$$

$$P_p := \mathbf{X}_p(\mathbf{X}_p^T \mathbf{X}_p)^{-1} \mathbf{X}_p^T$$

$$S_p := \mathbf{y}^T (I - P_p) \mathbf{y}$$

$$S_p - S_m = \mathbf{y}^T (I - P_p) \mathbf{y} - \mathbf{y}^T (I - P_m) \mathbf{y} = \mathbf{y}^T (P_m - P_p) \mathbf{y}$$

## 冪等 (Idempotent) 行列

$$P_m^T = (X_m^T)^T \{(X_m^T X_m)^{-1}\}^T X_m^T = X_m \{(X_m^T X_m)^T\}^{-1} X_m^T = P_m$$

$$P_p^T = P_p$$

$P_p X_p = X_p$ ,  $P_m X_p = X_p$  より、

$$P_m P_p = P_m X_p (X_p^T X_p)^{-1} X_p^T = X_p (X_p^T X_p)^{-1} X_p^T = P_p$$

$$P_p P_m = P_p^T P_m^T = (P_m P_p)^T = P_p^T = P_p$$

- ▶  $P_m^2 = P_m$
- ▶  $(I - P_m)^2 = I - P_m$
- ▶  $(P_m - P_p)^2 = P_m^2 - P_m P_p - P_p P_m + P_p^2 = P_m - P_p$

$$\frac{S_p - S_m}{S_p/n} \sim \chi_q^2, \quad q := m - p$$

一般に、 $P^2 = P \implies x = Px + (I - P)x$ ,  $(Px, (I - P)x) = 0$

$V_1 := \{Px | x \in \mathbb{R}^n\}$ : 次元  $\text{rank } P$

$V_0 := \{(I - P)x | x \in \mathbb{R}^n\}$ : 次元  $n - \text{rank } P$

- ▶  $P_p$ : 固有値 0,1 のみ、rank  $p$
- ▶  $P_m$ : 固有値 0,1 のみ、rank  $m$

	rank	$V_1$ の次元	$V_0$ の次元
$P_p$	$p$	$p$	$n - p$
$I - P_p$	$n - p$	$n - p$	$p$
$P_m - P_p$	$q$	$q$	$n - q$

$$\frac{S_p - S_m}{S_p/n} \sim \chi_q^2, \quad q := m - p \text{ (続)}$$

$I - P_p$  の直交行列  $U = (u_{i,j})$ :

- ▶  $\mathbf{u}_1, \dots, \mathbf{u}_{n-p}$  の固有値が 1
- ▶  $\mathbf{u}_{n-p+1}, \dots, \mathbf{u}_n$  の固有値が 0

$V[Y] = \sigma^2$ 、 $\sum_{i=1}^n u_{i,j}^2 = 1$ 、 $\mathbf{u}_j^T \mathbf{u}_k = 0 (j \neq k)$  より、 $1 \leq j \leq n-p$  で、

$$z_j := \mathbf{u}_j^T \mathbf{y} = \sum_{i=1}^n u_{i,j} y_i \sim \mathcal{N}(0, \sigma^2)$$

大数の強法則より、確率 1 で

$$\frac{1}{n} S_p = \frac{1}{n} \sum_{j=1}^{n-p} z_j^2 \rightarrow \sigma^2$$

$$\frac{S_p - S_m}{S_p/n} \sim \chi_q^2, \quad q := m - p \text{ (続)}$$

$P_m - P_p$  の直交行列  $V = (v_{i,j})$ :

- ▶  $\mathbf{v}_1, \dots, \mathbf{v}_q$  の固有値が 1
- ▶  $\mathbf{v}_{q+1}, \dots, \mathbf{v}_n$  の固有値が 0

$V[Y] = \sigma^2$ 、 $\sum_{i=1}^n v_{i,j}^2 = 1$ 、 $\mathbf{v}_j^T \mathbf{v}_k = 0 (j \neq k)$  より、 $1 \leq j \leq q$  で

$$r_j := \mathbf{v}_j^T \mathbf{y} = \sum_{i=1}^n v_{i,j} y_i \sim \mathcal{N}(0, \sigma^2)$$

大数の強法則より、確率 1 で

$$\frac{S_p - S_m}{S_p/n} \rightarrow \frac{S_p - S_m}{\sigma^2} = \sum_{j=1}^q \frac{r_j^2}{\sigma^2} \sim \chi_q^2$$

## 過学習の誤り率

$$\pi \subseteq \{1, \dots, N\}$$

$S(\pi)$ :  $\{X_j\}_{j \in \pi}$ ,  $Y$  の 2 乗誤差を

$$L(z^n, \pi) := n \log S(\pi) + \frac{k(\pi)}{2} d_n$$

$$k(\pi) := |\pi|$$

$\pi_* \subseteq \{1, \dots, N\}$ : 真の  $\pi$

$L(z^n, \pi) < L(z^n, \pi_*)$  となる確率

$$\pi \supset \pi_* \implies \int_{\frac{k(\pi) - k(\pi_*)}{2} d_n}^{\infty} f_{k(\pi) - k(\pi_*)}(x) dx$$



## 過学習の誤り率 (続)

証明:

$$\begin{aligned} & 2\{L(z^n, \pi) - L(z^n, \pi_*)\} \\ = & 2n \log \frac{S(\pi)}{S(\pi_*)} + \{k(\pi) - k(\pi_*)\}d_n \\ = & 2n \log\left(1 - \frac{S(\pi_*) - S(\pi)}{S(\pi_*)}\right) + \{k(\pi) - k(\pi_*)\}d_n \\ = & -2 \frac{S(\pi_*) - S(\pi)}{S(\pi_*)/n} - R_n + \{k(\pi) - k(\pi_*)\}d_n \end{aligned}$$

確率 1 で、 $R_n := \frac{1}{n} \frac{(nh)^2}{(\theta h - 1)^2} \rightarrow 0$

$$h := \frac{S(\pi_*) - S(\pi)}{S(\pi_*)}, 0 < \theta < 1$$

$$L(z^n, \pi) < L(z^n, \pi_*) \iff \frac{S(\pi_*) - S(\pi)}{S(\pi_*)/n} > \frac{k(\pi) - k(\pi_*)}{2} d_n$$

## 未学習の誤り率

$L(z^n, \pi) < L(z^n, \pi_*)$  となる確率

$\pi \not\equiv \pi_* \implies$  確率 1 で  $L(z^n, \pi) > L(z^n, \pi_*)$

証明: 確率 1 で  $\frac{S(\pi)}{S(\pi_*)} > 0$  となり、また  $d_n/n \rightarrow 0$

$$\frac{S_p - S_m}{S_p} \leq \frac{q}{n} \log \log n \text{ の証明}$$

$p + 1 \leq j \leq m$  を固定して、 $Z_i := \frac{\sqrt{n} \mathbf{v}_{i,j}^T \mathbf{y}}{\sigma}$

$$\sum_{i=1}^n Z_i = \frac{\sqrt{n} r_j}{\sigma} \sim \mathcal{N}(0, n)$$

$$E[\sum_{i=1}^n Z_i] = 0, E[(\sum_{i=1}^n Z_i)^2] = n$$

$Z_i$  は i.i.d. なので、 $E[Z_i] = 0, E[Z_i^2] = 1$ 、重複対数の法則を適用

$$\frac{\sqrt{n} \mathbf{v}_j^T \mathbf{y} / \sigma}{\sqrt{n \log \log n}} \leq 1$$

$$\frac{\mathbf{v}_j^T \mathbf{y}}{\sigma} \leq \sqrt{\log \log n}$$

$$\frac{S_p - S_m}{S_p/n} \leq q \log \log n$$

が確率 1 で成立

## Hannan-Quinn の命題は線形回帰でも成立

### Hannan-Quinn の命題

$d_n := 2c \log \log n$  ( $c > 1$ ) のとき、確率 1 で  $L(z^n, \pi) > L(z^n, \pi_*)$

## Hannan-Quinn の命題は線形回帰でも成立

$X^{(1)}, \dots, X^{(N)}$ : 確率変数

$\epsilon^{(i)} \sim \mathcal{N}(0, \sigma_i^2)$

### ガウス型 Bayesian ネットワークの構造学習

$$X^{(i)} = \sum_{j \in \pi^{(i)}} \alpha^{(j)} X^{(j)} + \epsilon^{(i)}$$

なる  $\pi^{(i)}$  を見出す

1.  $\pi^{(i)} (\supset \pi_*^{(i)})$  への誤り率は、

$$\int_{\frac{k(\pi^{(i)}) - k(\pi_*^{(i)})}{2}}^{\infty} d_n f_{k(\pi^{(i)}) - k(\pi_*^{(i)})}(x) dx$$

2. 確率 1 で、 $\pi^{(i)} (\not\supset \pi_*^{(i)})$  への誤り確率は 0
3.  $d_n = 2c \log \log n$  ( $c > 1$ ) で、確率 1 で誤り確率は 0