

時系列解析（7）

－局所定常ARモデル－

東京大学 数理・情報教育研究センター


北川 源四郎

区分的定常モデル：非定常時系列モデルへの第1歩


1. レベルシフトの検出
2. 局所定常ARモデル
 - (1) 任意の区間への自動分割
 - (2) 変化時点の精密な推定
 - (3) 変化時点の事後確率
3. 統計的制御
 - (1) 線形二次評価制御問題
 - (2) 船舶のオートパイロット
 - (3) 局所定常ARモデルに基づく外乱適応型自動制御

定常モデルで非定常時系列を分析する

平均非定常時系列 → 差分 + 定常モデル



分散・共分散非定常時系列 → 区分化 + 定常モデル



非定常時系列のモデリング

- ✓ ARIMAモデル

平均非定常

定常化

ARMAモデル

- レベルシフトモデル

平均非定常

区分的定常

- 局所定常ARモデル

平均・分散・共分散非定常


区分的定常

- ✓ 状態空間モデル

平均・分散・共分散非定常

直接モデル化（次回以降）

レベルシフトの検出



$$y_n \sim N(\mu_n, \sigma^2)$$

$$p(y_n | \mu_n, \sigma^2) = (2\pi\sigma^2)^{-\frac{1}{2}} \exp \left\{ -\frac{(y_n - \mu_n)^2}{2\sigma^2} \right\}$$

$k+1$: 変化点

$$\mu_n = \begin{cases} \theta_1 & n \leq k \\ \theta_2 & n > k \end{cases}$$

$y_1, \dots, y_N$ データ

変化点を $k+1$ と仮定したモデルの尤度

$$L(\theta_1, \theta_2, \sigma_k^2) = \prod_{n=1}^k p(y_n | \theta_1, \sigma_k^2) \prod_{n=k+1}^N p(y_n | \theta_2, \sigma_k^2)$$

レベルシフトの検出

尤度
$$L(\theta_1, \theta_2, \sigma_k^2) = \prod_{n=1}^k p(y_n | \theta_1, \sigma_k^2) \prod_{n=k+1}^N p(y_n | \theta_2, \sigma_k^2)$$

対数尤度
$$\ell(\theta_1, \theta_2, \sigma_k^2) = -\frac{N}{2} \log(2\pi\sigma_k^2) - \frac{1}{2\sigma_k^2} \left\{ \sum_{n=1}^k (y_n - \theta_1)^2 + \sum_{n=k+1}^N (y_n - \theta_2)^2 \right\}$$


最尤推定値
$$\hat{\theta}_1 = \frac{1}{k} \sum_{n=1}^k y_n, \quad \hat{\theta}_2 = \frac{1}{N-k} \sum_{n=k+1}^N y_n$$
$$\hat{\sigma}_k^2 = \frac{1}{N} \left\{ \sum_{n=1}^k (y_n - \hat{\theta}_1)^2 + \sum_{n=k+1}^N (y_n - \hat{\theta}_2)^2 \right\}$$

最大対数尤度
$$\ell(\hat{\theta}_1, \hat{\theta}_2, \hat{\sigma}_k^2) = -\frac{N}{2} \log(2\pi\hat{\sigma}_k^2) - \frac{N}{2}$$

パラメータ数 = 3

$$\text{AIC}_k = N \log(2\pi\hat{\sigma}_k^2) + N + 2 \times 3$$

変化点の検出



3パラメータモデル


$$y_n \sim \begin{cases} N(\mu_1, \sigma^2) & n \leq k \\ N(\mu_2, \sigma^2) & n > k \end{cases}$$

- 拡張
4パラメータモデル


$$y_n \sim \begin{cases} N(\mu_1, \sigma_1^2) & n \leq k \\ N(\mu_2, \sigma_2^2) & n > k \end{cases}$$

- さらなる拡張
正規分布 → 時系列モデル


区分的に性質が変化する時系列




地震波： 常微動，P波，S波，・・・



睡眠と脳波： 覚醒
レム期，ノンレム期




新幹線・周期的軌道狂いの検出



鉄道総研 元好，古川，神山（2004）


<http://zone-training.jp/method-neurofeedback.html>

火山性微動（有珠山）



Hokkaido, Japan March 31, 2000 13:07-
提供：北海道大学火山地震予知観測センター 高波鐵夫

局所定常 AR モデル



- 各区間 D_j では定常と仮定
- D_j の定常時系列を $AR(m_j)$ モデルで表現 ($m_j \leq M$)


$$y_n = \sum_{i=1}^{m_j} a_{ij} y_{n-i} + v_{nj}, \quad v_{nj} \sim N(0, \sigma_j^2), \quad n \in D_j$$

- 平均値の変化
- 分散の変化
- スペクトル・共分散構造（波形）の変化
- 任意時点での構造変化
- AICによる自動推定

局所定常ARモデル

$$N = N_1 + N_2 + \cdots + N_k \quad \text{時間領域の分割}$$

$$D_i = [n_{i0}, n_{i1}] \quad n_{i0} = \sum_{j=1}^{i-1} N_j + 1, \quad n_{i1} = \sum_{j=1}^i N_j$$



$$y_n = \sum_{i=1}^{m_j} a_{ji} y_{n-i} + v_{nj}, \quad v_{nj} \sim N(0, \sigma_j^2), \quad n \in D_j$$

$$\theta = (k, N_j, m_j, (a_{ji}, i = 1, \dots, m_j), \sigma_j^2; j = 1, \dots, k)^T$$

$$L = p(y_1, \dots, y_N) = \prod_{j=1}^k \prod_{n=n_{j0}}^{n_{j1}} p(y_n | y_1, \dots, y_{n-1})$$

$$\cong \prod_{j=1}^k (2\pi\sigma_j^2)^{-\frac{N_j}{2}} \exp \left\{ -\frac{1}{2\sigma_j^2} \sum_{n=n_{j0}}^{n_{j1}} \left(y_n - \sum_{i=1}^{m_j} a_{ji} y_{n-i} \right)^2 \right\}$$

局所定常ARモデル

$$\begin{aligned} \ell(k, N_j, m_j, (a_{ji}, i=1, \dots, m_j), \sigma_j^2; j=1, \dots, k) \\ = -\frac{1}{2} \sum_{j=1}^k \left\{ N_j \log 2\pi \sigma_j^2 + \frac{1}{\sigma_j^2} \sum_{n=n_{j0}}^{n_{j1}} \left(y_n - \sum_{i=1}^{m_j} a_{ji} y_{n-i} \right)^2 \right\} \end{aligned}$$

$$\hat{\sigma}_j^2 = \frac{1}{N_j} \sum_{n=n_{j0}}^{n_{j1}} \left(y_n - \sum_{i=1}^{m_j} a_{ji} y_{n-i} \right)^2$$

$$\begin{aligned} \ell(k, N_j, m_j, (a_{ji}, i=1, \dots, m_j), \hat{\sigma}_j^2; j=1, \dots, k) \\ = -\frac{1}{2} \sum_{j=1}^k \left\{ N_j \log 2\pi \hat{\sigma}_j^2 + N_j \right\} \\ = -\frac{N-m}{2} (\log 2\pi + 1) - \frac{1}{2} \sum_{j=1}^k N_j \log \hat{\sigma}_j^2 \end{aligned}$$


$$\text{AIC} = (N-m)(\log 2\pi + 1) + \sum_{j=1}^k N_j \log \hat{\sigma}_j^2 + 2 \sum_{j=1}^k (m_j + 1)$$

2 種類の実装

- すべての区分数(k)および区間長($N_1, \dots, N_k$)の候補を比較し、
最良の局所定常ARモデルを求めるのは非現実的
- 1. 任意個の区間への自動分割 $\cdot \cdot \cdot$ 大まかに分割
- 2. 変化点の精密推定 $\cdot \cdot \cdot \cdot \cdot \cdot$ 1か所を精密に推定

任意個の区間への自動分割

- (1) 定常性を仮定する小区間の長さ L , ARの最大次数 M を決める
- (2) 新しい長さ L のデータが得られる度に



を比較し, AICが小さい方をCurrent Modelとして選択する

$$N_j = c_j L$$

m

D_j 区間の長さ

AR次数の最大

初期モデル (D_1 のモデル)

$$X_0 = [Z|y] = \begin{bmatrix} y_m & \cdots & y_1 & y_{m+1} \\ y_{m+1} & \cdots & y_2 & y_{m+2} \\ \vdots & \ddots & \vdots & \vdots \\ y_{m+L-1} & \cdots & y_L & y_{m+L} \end{bmatrix} \quad \longrightarrow \quad HX = \begin{bmatrix} S \\ O \end{bmatrix} = \begin{bmatrix} s_{11} & \cdots & s_{1,m+1} \\ & \ddots & \vdots \\ & & s_{m+1,m+1} \\ O & & & \end{bmatrix}$$


$$\hat{\sigma}_0^2(j) = \frac{1}{L} \sum_{i=j+1}^{m+1} s_{i,m+1}^2$$

$$AIC_0(j) = L \log \hat{\sigma}_0^2(j) + 2(j+1)$$

$$AIC_0 \equiv \min_j AIC_0(j)$$

新しいデータのモデル

$$X_1 = \begin{bmatrix} y_{m+L} & \cdots & y_{L+1} & y_{m+L+1} \\ y_{m+L+1} & \cdots & y_{L+2} & y_{m+L+2} \\ \vdots & \ddots & \vdots & \vdots \\ y_{m+2L-1} & \cdots & y_{2L} & y_{m+2L} \end{bmatrix} \quad \Rightarrow \quad H_1 X_1 = \begin{bmatrix} R \\ O \end{bmatrix} = \begin{bmatrix} r_{11} & \cdots & r_{1,m+1} \\ & \ddots & \vdots \\ & & r_{m+1,m+1} \\ O \end{bmatrix}$$



$$\hat{\sigma}_1^2(j) = \frac{1}{L} \sum_{i=j+1}^{m+1} r_{i,m+1}^2$$

$$AIC_1(j) = L \log \hat{\sigma}_1^2(j) + 2(j+1)$$

$$AIC_1 \equiv \min_j AIC_1(j)$$


構造変化したと仮定するモデルのAIC (Switched model)

$$AIC_S \equiv AIC_0 + AIC_1 = \min_j AIC_0(j) + \min_j AIC_1(j)$$

データ併合したモデル

$$X_2 = \begin{bmatrix} S \\ R \end{bmatrix} = \begin{bmatrix} s_{11} & \cdots & s_{1,m+1} \\ \vdots & & \vdots \\ s_{1,m+1} \\ r_{11} & \cdots & r_{1,m+1} \\ \vdots & & \vdots \\ r_{1,m+1} \end{bmatrix} \quad \longrightarrow \quad H_2 X_2 = \begin{bmatrix} T \\ O \end{bmatrix} = \begin{bmatrix} t_{11} & \cdots & t_{1,m+1} \\ \vdots & & \vdots \\ t_{m+1,m+1} \\ O \end{bmatrix}$$

構造変化なしと仮定するモデルのAIC (Pooled model)



$$\hat{\sigma}_P^2(j) = \frac{1}{2L - m} \sum_{i=j+1}^{m+1} t_{i,m+1}^2$$


$$\text{AIC}_P(j) = L \log \hat{\sigma}_P^2(j) + 2(j+1)$$

$$\text{AIC}_P \equiv \min_j \text{AIC}_P(j)$$

MYE1F(地震波東西方向)データ

data(MYE1F)

lsar (MYE1F, max.arorder = 10, ns0=200)



$\Delta t = 0.02$ 秒, $N=2600$

$M = 10$ 最大AR次数

$L = 200$ 基本区間長

局所定常 AR モデリング

lsar (MYE1F, max.arorder=10, ns0=200)

<<< new data (n = 11 --- 210) >>>

initial model : NS = 200

ms = 9 sds = 9.533019e-01 aics = 578.011

<<< new data (n = 211 --- 410) >>>

switched model : (nf = 200, ns = 200)

ms = 8 sds = 7.571863e-01 aics = 1107.957

pooled model : (np = 400)

mp = 9 sdp = 8.775778e-01 aicp = 1102.915

*** pooled model accepted ***

<<< new data (n = 411 --- 610) >>>

switched model : (nf = 400, ns = 200)

ms = 8 sds = 7.353224e-01 aics = 1627.001

pooled model : (np = 600)

mp = 9 sdp = 8.567912e-01 aicp = 1629.990

*** switched model accepted ***

<<< new data (n = 611 --- 810) >>>

switched model : (nf = 200, ns = 200)

ms = 4 sds = 2.372409e+01 aics = 1734.960

pooled model : (np = 400)

mp = 10 sdp = 1.255320e+01 aicp = 2169.141

*** switched model accepted ***

<<< new data (n = 811 --- 1010) >>>

switched model : (nf = 200, ns = 200)

ms = 4 sds = 2.701266e+01 aics = 2447.710

pooled model : (np = 400)

mp = 10 sdp = 2.468140e+01 aicp = 2439.571

*** pooled model accepted ***

<<< new data (n = 1011 --- 1210) >>>

switched model : (nf = 400, ns = 200)

ms = 9 sds = 4.807289e+01 aics = 3801.690

pooled model : (np = 600)

mp = 10 sdp = 3.864933e+01 aicp = 3917.444

*** switched model accepted ***

<<< new data (n = 1211 --- 1410) >>>

switched model : (nf = 200, ns = 200)

ms = 9 sds = 3.470873e+01 aics = 2659.093

pooled model : (np = 400)

mp = 8 sdp = 4.308581e+01 aicp = 2658.428

*** pooled model accepted ***

<<< new data (n = 1411 --- 1610) >>>

switched model : (nf = 400, ns = 200)

ms = 10 sds = 1.764112e+01 aics = 3822.050

pooled model : (np = 600)

mp = 8 sdp = 3.582855e+01 aicp = 3867.973

*** switched model accepted ***

<<< new data (n = 1611 --- 1810) >>>


switched model : (nf = 200, ns = 200)

ms = 9 sds = 1.032457e+01 aics = 2218.103

pooled model : (np = 400)

mp = 10 sdp = 1.447380e+01 aicp = 2226.087


*** switched model accepted ***



data(MYE1F)
lsar (MYE1F,max.arorder=10, ns0=200)

- P波, S波の到着を適切に検出している. AICの違いも大きい
 - P波到着時($n=611$) $\Delta AIC=434.1$, $AIC_s=1735.0$, $AIC_p=2169.1$
 - S波到着時($n=1011$) $\Delta AIC=115.7$, $AIC_s=3801.7$, $AIC_p=3917.4$
- $N=411$ は誤検出かもしれないが, P波のスペクトルが多少増加している可能性もある. $\Delta AIC=5.0$ と小さい.
- 長周期($f=0$ 付近)のパワーはほぼ $p(f)=2.0$ で一貫している.
- S波到着後, パワーの減少に伴ってモデルが頻繁に変更されている. $f(0)$ は一定の一方, $f=0.1\sim 0.3$ のパワーが段々減少しているので, 一定のモデルと見なすにはモデルの工夫が必要.


地震波到着時刻の推定



到着時刻の推定

$\Delta T = 0.01 \text{ sec.}$

震源の推定



津波の予測・地震警報


自動・高速アルゴリズム

局所定常 AR モデル

+

情報量規準AICによる
自動的モデリング


変化時点の精密な推定



全体のモデルのAIC

$$AIC_j = AIC_j^L + AIC_j^R$$

変化時点の最小AIC 推定値



$$y_n = \sum_{i=1}^{m_j} a_{ij} y_{n-i} + v_{nj}$$

$$v_{nj} \sim N(0, \sigma_j^2)$$

$$y_n = \sum_{i=1}^{\ell_j} b_{ij} y_{n-i} + u_{nj}$$

$$u_{nj} \sim N(0, \tau_j^2)$$

前半のモデルのAIC

$$\text{AIC}_j^L = \min_m \left\{ j \log(2\pi\hat{\tau}_j^2) + j + 2(m+1) \right\}$$


後半のモデルのAIC

$$\text{AIC}_j^R = \min_{\ell} \left\{ (N-j) \log(2\pi\hat{\sigma}_j^2) + (N-j) + 2(\ell+1) \right\}$$

全体の局所定常ARモデルのAIC

$$\begin{aligned} \text{AIC}_j &= \text{AIC}_j^N + \text{AIC}_j^S \\ &= \min_{m,\ell} \left\{ j \log(2\pi\hat{\tau}_j^2) + (N-j) \log(2\pi\hat{\sigma}_j^2) + N + 2(m+\ell+2) \right\} \end{aligned}$$

データの逐次追加



$$N = N_1 + L + N_2$$

$$AIC_j = AIC_j^1 + AIC_j^2$$

データの逐次追加

$2m$ 個のARモデルを L 回推定
 $2mL$ ($m=10\sim 20, L=100\sim 500$)



自動処理のための高速化

$$X_{10} = [Z | y] = \begin{bmatrix} y_m & \cdots & y_1 & y_{m+1} \\ y_{m+1} & \cdots & y_2 & y_{m+2} \\ \vdots & \ddots & \vdots & \vdots \\ y_{N_1-1} & \cdots & y_{N_1-m} & y_{N_1} \end{bmatrix} \quad \Rightarrow \quad HX_{10} = \begin{bmatrix} S \\ O \end{bmatrix} = \begin{bmatrix} s_{11} & \cdots & s_{1,m+1} \\ & \ddots & \vdots \\ & & s_{m+1,m+1} \\ O & & & \end{bmatrix}$$

$$\hat{\sigma}_1^2(j) = \frac{1}{N_1 - m} \sum_{i=j+1}^{m+1} s_{i,m+1}^2$$

$$\text{AIC}_1(j) = (N_1 - m) \log \hat{\sigma}_1^2(j) + 2(j+1)$$

$$\text{AIC}_1^1 \equiv \min_j \text{AIC}_1(j)$$

計算量は加減, 乗除
それぞれ $N_1 m^2$ 程度

データの逐次追加

$$X_{11} = \begin{bmatrix} s_{1,1} & \cdots & s_{1,m} & s_{1,m+1} \\ & \ddots & \vdots & \vdots \\ & & s_{m,m} & s_{m,m+1} \\ & & & s_{m+1,m+1} \\ \hline y_{N_1} & \cdots & y_{N_1-m+1} & y_{N_1+1} \\ \vdots & & \vdots & \vdots \\ y_{N_1+p-1} & \cdots & y_{N_1-m+p} & y_{N_1+p} \end{bmatrix} \xrightarrow{\quad \text{blue arrow} \quad} H_1 X_{11} = \begin{bmatrix} R \\ O \end{bmatrix} = \begin{bmatrix} r_{11} & \cdots & r_{1,m} & r_{1,m+1} \\ & \ddots & \vdots & \vdots \\ & & r_{m,m} & r_{m,m+1} \\ \hline & & & r_{m+1,m+1} \\ & & O & \end{bmatrix}$$

p は1でもよい

$$\hat{\sigma}_1^2(j) = \frac{1}{N_1 - m + p} \sum_{i=j+1}^{m+1} r_{i,m+1}^2$$

$$\text{AIC}_1(j) = (N_1 - m + p) \log \hat{\sigma}_1^2(j) + 2(j+1)$$

$$\text{AIC}_1^1 \equiv \min_j \text{AIC}_1(j)$$

計算量は加減, 乗除
それぞれ $2m^2$ 程度
($p=1$) の場合

これを繰り返して $\text{AIC}_0^1 \Rightarrow \text{AIC}_1^1 \Rightarrow \cdots \Rightarrow \text{AIC}_{L/p}^1$

データの逐次追加（後半のモデル）

$$X_{20} = [Z|y] = \begin{bmatrix} y_{N-1} & \cdots & y_{N-m} & y_N \\ y_{N-2} & \cdots & y_{N-m-1} & y_{N-1} \\ \vdots & \ddots & \vdots & \vdots \\ y_{N-N_2} & \cdots & y_{N-N_2-m+1} & y_{N-N_2+1} \end{bmatrix} \quad \Rightarrow \quad H_{20}X_{20} = \begin{bmatrix} T \\ O \end{bmatrix} = \begin{bmatrix} t_{11} & \cdots & t_{1,m+1} \\ & \ddots & \vdots \\ & & t_{m+1,m+1} \\ O & & & \end{bmatrix}$$

$$X_{21} = \begin{bmatrix} t_{11} & \cdots & t_{1m} & t_{1,m+1} \\ & \ddots & \vdots & \vdots \\ & & t_{mm} & t_{m,m+1} \\ & & & t_{m+1,m+1} \\ y_{N-N_2-1} & \cdots & y_{N-N_2-m} & y_{N-N_2} \\ \vdots & & \vdots & \vdots \\ y_{N-N_2-p} & \cdots & y_{N-N_2-m+p-1} & y_{N-N_2-p+1} \end{bmatrix} \quad H_{21}X_{21} = \begin{bmatrix} Z \\ O \end{bmatrix} = \begin{bmatrix} z_{11} & \cdots & z_{1m} & z_{1,m+1} \\ & \ddots & \vdots & \vdots \\ & & z_{mm} & z_{m,m+1} \\ & & & z_{m+1,m+1} \\ O & & & \end{bmatrix}$$

$$\hat{\sigma}_2^2(j) = \frac{1}{N_2 - m + p} \sum_{i=j+1}^{m+1} z_{i,m+1}^2$$

$$AIC_2(j) = (N_2 - m + p) \log \hat{\sigma}_2^2(j) + 2(j+1)$$

$$AIC_{L/p-1}^2 \equiv \min_j AIC_2(j)$$

$$AIC_{L/p}^2 \Rightarrow AIC_{L/p-1}^2 \Rightarrow \cdots \Rightarrow AIC_1^2$$

- Householder法の単純適用

N 行 m 列の行列の変換 $\sim m^2N$

一つのLSARモデル $\sim m^2(N_1+j)+m^2(N_2+L-j) = m^2N$

L 個のLSARモデル $\sim m^2NL$

- Householder法による逐次追加

初期モデル $\sim m^2N_1 + m^2N_2$

データ1個の追加 $\sim 2m^2$

合計 $\sim m^2N_1 + m^2N_2 + 2Lm^2 = m^2N + Lm^2$

(例) $N = 1000$, $m = 10$, $L = 100$ のとき


$$m^2NL = 10^7$$

$$m^2N + Lm^2 = 10^5 + 10^4$$


地震波到着時刻の推定

常微動 → P波

P波 → S波









到着時刻




到着時刻

地震3成分データ（えりも付近）



ER	えりも
HI	日高
IW	岩内
KM	上杵臼
MS	御園
MY	茂寄

E	E-W成分
N	N-S成分
U	U-D成分



多変量LSARモデル



$$y_n = \begin{bmatrix} y_n^{EW} \\ y_n^{EW} \\ y_n^{EW} \end{bmatrix} \quad \begin{array}{l} \text{東西成分} \\ \text{南北成分} \\ \text{上下成分} \end{array}$$

$$y_n = \sum_{i=1}^{m_j} A_{ij} y_{n-i} + v_{nj}, \quad v_{nj} \sim N(0, \Sigma_{1j}) \quad \text{前半のMARモデル}$$



$$y_n = \sum_{i=1}^{\ell_j} B_{ij} y_{n-i} + u_{nj}, \quad u_{nj} \sim N(0, \Sigma_{2j}) \quad \text{後半のMARモデル}$$

$$\begin{aligned} \text{AIC}_j &= \text{AIC}_j^N + \text{AIC}_j^S \\ &= \ell N \log 2\pi + (N - j) \log |\Sigma_{1j}| + j \log |\Sigma_{2j}| \\ &\quad + \sum_{n=1}^j v_{nj}^T \Sigma_{1j}^{-1} v_{nj} + \sum_{n=j+1}^N u_{nj}^T \Sigma_{2j}^{-1} u_{nj} \end{aligned}$$



地震 3 成分データ (茂寄)





地震 3 成分データ (えりも)





地震 3 成分データ (岩内)



地震 3 成分データ (御園)




地震 3 成分データ (茂寄)



Rによる計算


```
data(MYE1F)
```

```
lsar.chgpt(MYE1F, max.arorder = 10, subinterval =  
c(400,800), candidate = c(600,700))
```




```
data(MYE1F)
```


```
lsar.chgpt(MYE1F, max.arorder = 10, subinterval =  
c(800,1200), candidate = c(1000,1100))
```



AICs of candidate range



AICs of candidate range



緊急地震速報

地震発生

緊急地震速報

産業プラントの
安全確保



交通管制

新幹線，高速道路
信号機制御
航空機離着陸制限



エレベーター緊急停止
緊急通信回線の確保
水門閉鎖



JR東日本新幹線

東京－新青森間：震災時27本が営業運転中
新白河－二戸間：10本（5本は270キロ走行中）
東北新幹線の被害箇所：約1,200



(JR東日本はやて)

新幹線早期地震検知システム

東北・上越・長野新幹線の沿線と海岸線に97個の地震計を設置
P波やS波を検知し、変電所から列車への送電を自動的に停止
車両の非常ブレーキを作動させて減速・停止させる

- 14時47分3秒牡鹿半島の地震計：120ガルの加速度を検知。自動的に架線を停電、新幹線は一斉に非常ブレーキをかけて減速，緊急停止
- 仙台駅-古川駅：「はやて27号」「やまびこ61号」が走行中。
非常ブレーキの9秒後，12秒後に初動，1分10秒後に最も強い揺れが起きた。
- 営業運転中の新幹線は 1本も脱線・転覆しなかった。

- 震源推定の誤差

- ✓ 少数の地震波に基づいて推定
- ✓ 一部の到着時刻推定の誤差が大きな影響を及ぼす

- 緊急地震速報の誤動作

- ✓ 主な原因： 引き続いて発生した2つの小さな地震を同一の地震と見做したこと

- ◆ 対応

- ✓ 多数の観測点の情報を使う
- ✓ 到着時刻の推定値だけでなく、事後確率を使う

変化点の事後確率

$AIC = -2 \times (\text{バイアス補正した対数尤度})$

$$p(y|j) \equiv \exp\left\{-\frac{1}{2}AIC_j\right\}$$

最尤法でパラメータ推定した
モデルの尤度

$$p(j)$$

変化点の事前確率 (例 ; $p(j) = \frac{1}{L}$)



変化点の事後確率

$$p(j|y) = \frac{p(y|j)p(j)}{\sum_{j=1}^L p(y|j)p(j)}$$


```
x <- lsar2(MYE1F, 10, c(400,800), c(600,700))
AICP <- x$aic
post <- exp( -(AICP-min(AICP))/2 )
post <- post/sum(post)
plot( post, type="l", col="red" )
```

変化点の事後確率




```
x <- lsar2(MYE1F, 10, c(400,800), c(600,700))  
AICP <- x$aic  
post <- exp( -(AICP-min(AICP))/2 )  
post <- post/sum(post)  
plot(post,type="l",col="red",lwd=2)
```





AICs of candidate range



AICs of candidate range




変化点の事後確率



統計的制御

- 最適制御の困難
 - 巨大なシステム
 - 複雑なシステム
 - 外乱の強いシステム

理論モデル



統計的モデル

[成功例]

- 火力発電所
- セメント焼成炉
- 船舶自動操舵

最適制御

- 状態空間モデル

$$x_n = Fx_{n-1} + Gr_n + w_n$$

$$y_n = Hx_n$$

- 評価関数

$$J = \sum_{n=1}^I \left\{ x_n^T Q x_n + r_n^T R r_n \right\}$$

- 最適制御

$$r_n = Kx_n$$

制御用状態空間モデル

多変量ARモデル

$$z_n = \sum_{j=1}^m A_j z_{n-j} + v_n$$

$$z_n = \begin{bmatrix} y_n \\ \vdots \\ r_n \end{bmatrix} \begin{matrix} \updownarrow p & \text{被制御変数} \\ \updownarrow q & \text{操作変数} \end{matrix}$$

ARXモデル (X: exogenous)

$$y_n = \sum_{j=1}^m a_j y_{n-j} + \sum_{j=1}^m b_j r_{n-j} + u_n$$

$$A_j = \begin{bmatrix} \overset{p}{\overleftarrow{a_j}} & \overset{q}{\overrightarrow{b_j}} \\ * & * \end{bmatrix}, \quad v_n = \begin{bmatrix} u_n \\ * \end{bmatrix} \begin{matrix} \updownarrow p \\ \updownarrow q \end{matrix}$$

制御用状態空間モデル

$$z_n = Fx_{n-1} + Gr_n + w_n$$

$$y_n = Hx_n$$

$$F = \begin{bmatrix} a_1 & I & & \\ a_2 & & \ddots & \\ \vdots & & & I \\ a_m & & & \end{bmatrix}, \quad G = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_m \end{bmatrix},$$

$$w_n = \begin{bmatrix} u_n \\ 0 \\ \vdots \\ 0 \end{bmatrix}, \quad x_n = \begin{bmatrix} y_n \\ y_{n-1} \\ \vdots \\ y_{n-m+1} \end{bmatrix}$$

最適制御則

$$y_n = K_I x_n$$

$$K_I = -\left\{G^T S_I G + R\right\}^{-1} G^T S_I F$$

ただし, S_m ($m=1, \dots, I$) は以下により求める

1. $P_0 = [0]$

2. $m=1, 2, \dots, I$ について (1), (2) を繰り返す

(1) $S_m = Q + P_{m-1}$

(2) $P_m = F^T \left[S_m - S_m G \left\{ G^T S_m G + R \right\}^{-1} G^T S_m \right] F$

最適制御則の導出

$f_m(x)$ を以下のように定義する

$$f_m(x) = \min_r J_m(z, r) = \min_{\substack{r_0, \dots, r_{m-1} \\ x_0 = x}} E \left[\sum_{n=1}^m \left\{ x_n^T Q x_n + r_{n-1}^T R r_{n-1} \right\} \right]$$

最適性の原理より

$$\begin{aligned} f_m(x) &= \min_{\substack{y_0 \\ x_0 = x}} \left[x_1^T Q x_1 + r_0^T R r_0 + \min_{r_{01}, \dots, r_{m-1}} E \left[\sum_{n=2}^m \left\{ x_n^T Q x_n + r_{n-1}^T R r_{n-1} \right\} \right] \right] \\ &= \min_{\substack{y_0 \\ x_0 = x}} \left[x_1^T Q x_1 + r_0^T R r_0 + f_{m-1}(x_1) \right] \end{aligned}$$

最適制御則の導出 (数学的帰納法)

(i) $m=1$ のとき $f_1(x) = \min_{\substack{r_0 \\ x_0=x}} E \left[x_1^T Q x_1 + r_0^T R r_0 \right]$

$$r_1(x) = -(G^T S_1 G + R)^{-1} G^T S_1 F x$$

$$f_1(x) = x^T P_1 x + \text{定数}$$

(ii) $m=k-1$ のとき定理は成り立つと仮定

$$f_{k-1}(x) = x^T P_{k-1} x + \text{定数}$$

このとき

$$f_k(x) = \min_{\substack{r_0 \\ x_0=x}} E \left[x_1^T Q x_1 + r_0^T R r_0 + x_1^T P_{k-1} x_1 \right] + \text{定数}$$

$$= \min_{\substack{r_0 \\ x_0=x}} E \left[x_1^T (Q + P_{k-1}) x_1 + r_0^T R r_0 \right] + \text{定数}$$

$$r_k = -(G^T S_k G + R)^{-1} G^T S_k F x_k$$

$$P_k = F^T \left\{ S_k - S_k G (G^T S_k G + R)^{-1} G^T S_k \right\} F$$

$$f_k(x) = x^T P_k x$$

$z = Fx + Gr + v$ について, 評価関数

$J(x, r) = E[x^T Q x + r^T R r]$ を最小とする制御入力 r^* およびその時の評価関数値は

$$r^*(x) = -(G^T Q G + R)^{-1} G^T Q F x$$

$f_1(x) = \min_r J(x, r) = J(x, r^*) = x^T P x + \text{定数}$
ただし

$$P = F^T \left\{ Q - Q G (G^T Q G + R)^{-1} G^T Q \right\} F$$

$$\begin{aligned} J(x, r) &= E[(Fx + Gr + v)^T Q (Fx + Gr + v) + r^T R r] \\ &= (Fx + Gr)^T Q (Fx + Gr) + r^T R r + E[v^T Q v] \\ &= r^T (G^T Q G + R) r + x^T F^T Q G r + r^T G^T Q F x \\ &\quad + x^T F^T Q F x + \text{定数} \\ &= \left\{ r + (G^T Q G + R)^{-1} G^T Q F x \right\}^T (G^T Q G + R) \\ &\quad \times \left\{ r + (G^T Q G + R)^{-1} G^T Q F x \right\} + x^T F Q F x \\ &\quad - x F^T Q G (G^T Q G + R)^{-1} G^T Q F x + \text{定数} \end{aligned}$$

ここで, 第1項は非負, 第2項は r と無関係


$$r^* = -(G^T Q G + R)^{-1} G^T Q F x$$

のとき上式は最小となり, このとき

$$f(r^*) = x^T F^T Q F x$$

$$- x^T F^T Q G (G^T Q G + R)^{-1} G^T Q F x + \text{定数}$$

ARオートパイロット制御結果




No.	Q	R	Pitch	Roll	Yaw	Yacc	Rudder	Diff.
1	(2,7,35,1)	0.850	1.726	4.575	1.709	0.0063	18.72	4.546
2	(3.6,7,40,1.67)	1.015	1.444	4.915	1.674	0.0062	19.12	5.052
3	(0,6.33,57.8,0)	0.860	2.242	4.473	1.672	0.0068	18.66	4.931
4	Manual		2.771	6.557	7.781	0.0081	17.62	0.832

図表は K. Ohtsu, H. Peng & G. Kitagawa (2015), Time Series modeling for Analysis and Control, Advanced Autopilot and Monitoring Systems, Springer Briefs in Statistics, Springer. P65 およびP67から転載.

NADCONと適応型オートパイロット

北川・赤池・大津 (1980)

- 船体運動モデル + 外乱モデル
- 外乱モデルに局所定常ARモデルを用いて非定常モデル化
- 外乱の変化に適応する適応制御システムを提案 (Noise Adaptive Controller; NADCON)



- 横河電子機器が大型船舶用主力システムPT500Aに採用 (2008年)
- 次世代オートパイロットPT900シリーズにBNAACを標準装備

BNAAC: Batch Noise Adaptive Autopilot Controller

<https://www.yokogawadenshikiki.co.jp/jp-ydk/mr/marine/pilot/ydkmr-ma-bnaac-ja.htm>

PT500 オートパイロット

直進中も連続的に船体運動特性を同定
BNAACが省エネ性を実現します

■ **BNAAC**: Batch Noise Adaptive Autopilot Controller

制御型自己帰帰モデルで省エネモード

PT500A アダプティブ制御

■ PT500Aにプリント基板をアドオン
新製品

BNAACの頭脳
新プリント基板

統計数理研究所 北川源四郎所長
東京海洋大学 大津皓平名誉教授 ご指導
(C) Copyright 2009 Yokogawa Denshikiki Co., Ltd.

NADCON (Noise Adaptive Controller)

船のモデル

$$y_n = \sum_{j=1}^m A_j y_{n-j} + \sum_{j=1}^m B_j r_{n-j} + u_n$$

外乱のモデル

$$u_n = \sum_{i=1}^k C_i u_{n-i} + \varepsilon_n$$


統合モデル (船 + 外乱)

$$y_n = \sum_{j=1}^{m+k} A'_j y_{n-j} + \sum_{j=1}^{m+k} B'_j r_{n-j} + \varepsilon_n$$


$$A'_j = A_j + C_j - \sum_{i=1}^j C_i A_{j-i}, \quad A_j = 0 \quad j > m$$

$$B'_j = B_j + C_j - \sum_{i=1}^j C_i B_{j-i}, \quad B_j = 0 \quad j > m$$

$$C_j = 0 \quad j > k$$



実船試験結果



図表は K. Ohtsu, H. Peng & G. Kitagawa (2015), Time Series modeling for Analysis and Control, Advanced Autopilot and Monitoring Systems, Springer Briefs in Statistics, Springer. P86から転載.