

金融時系列と線型モデル，条件付き分散不均一モデル

[AR(p)]

$$x_t = \mu + \phi_1 x_{t-1} + \dots + \phi_p x_{t-p} + \varepsilon_t$$

[AR(p)の場合の ACF の求め方]

$$x_t = \phi_1 x_{t-1} + \dots + \phi_p x_{t-p} + \varepsilon_t \text{ のとき，}$$

$$\gamma(k) = \phi_1 \gamma(k-1) + \dots + \phi_p \gamma(k-p) \quad (k \geq p)$$

$1 < k < p$ については， $\gamma(-k) = \gamma(k)$ で書き換える．

ただし，初期条件は，

$$\begin{bmatrix} 0 & -\phi_1 & \dots & -\phi_{p-1} & -\phi_p \\ 0 & -\phi_2 & \ddots & -\phi_p & 0 \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ 0 & -\phi_p & \ddots & 0 & 0 \\ 0 & 0 & \dots & 0 & 0 \end{bmatrix} + \begin{bmatrix} 1 & 0 & \dots & 0 & 0 \\ -\phi_1 & 1 & \dots & 0 & 0 \\ \vdots & \ddots & \ddots & & \vdots \\ -\phi_{p-1} & -\phi_{p-2} & \ddots & 1 & 0 \\ -\phi_p & -\phi_{p-1} & \dots & -\phi_1 & 1 \end{bmatrix} \begin{bmatrix} \gamma(0) \\ \gamma(1) \\ \vdots \\ \gamma(p-1) \\ \gamma(p) \end{bmatrix} = \begin{bmatrix} \sigma^2 \\ 0 \\ \vdots \\ 0 \\ 0 \end{bmatrix}$$

の方程式から求める． $\rho(k) = \gamma(k) / \gamma(0)$

(説明)

< 変形規則 >

$$E[\varepsilon_t x_{t-k}] = 0 \quad (k \geq 1)$$

$$E[\varepsilon_t^2] = \sigma^2$$

$$E[x_t x_{t-k}] = \gamma(k)$$

$$E[x_t x_{t+k}] = \gamma(-k) = \gamma(k)$$

$$E[x_t x_{t-(k-m)}] = E[x_{t-k} x_{t-m}] = \gamma(k-m) = \gamma(m-k)$$

< 派生規則 >

$$E[x_t \varepsilon_t] = E[\varepsilon_t (\phi_1 x_{t-1} + \dots + \phi_p x_{t-p} + \varepsilon_t)] = \phi_1 E[\varepsilon_t x_{t-1}] + \dots + \phi_p E[\varepsilon_t x_{t-p}] + E[\varepsilon_t^2] = \sigma^2$$

< DGP >

$$x_t = \phi_1 x_{t-1} + \dots + \phi_p x_{t-p} + \varepsilon_t$$

<漸化式の導出>

× x_{t-k} ($k > 1$) して, 期待値をとる

$$E[x_t x_{t-k}] = \phi_1 E[x_{t-1} x_{t-k}] + \dots + \phi_p E[x_{t-p} x_{t-k}] + E[\varepsilon_t x_{t-k}]$$

$$\gamma(k) = \phi_1 \gamma(k-1) + \dots + \phi_p \gamma(k-p)$$

<初期条件の決定>

× x_t して, 期待値をとる

$$E[x_t^2] = \phi_1 E[x_{t-1} x_t] + \dots + \phi_p E[x_{t-p} x_t] + E[\varepsilon_t x_t]$$

$$\gamma(0) = \phi_1 \gamma(1) + \dots + \phi_p \gamma(p) + \sigma^2$$

$$\gamma(k) = \phi_1 \gamma(k-1) + \dots + \phi_p \gamma(k-p) \text{ で } k=1 \text{ とする.}$$

$$\gamma(1) = \phi_1 \gamma(0) + \phi_2 \gamma(1) + \dots + \phi_p \gamma(p-1)$$

$$\gamma(2) = \phi_1 \gamma(1) + \phi_2 \gamma(0) + \phi_3 \gamma(1) + \dots + \phi_p \gamma(p-2)$$

:

$$\gamma(p) = \phi_1 \gamma(p-1) + \phi_2 \gamma(p-2) + \dots + \phi_p \gamma(0)$$

以上の式を連立して初期条件を計算し, その後, $\gamma(k) = \phi_1 \gamma(k-1) + \dots + \phi_p \gamma(k-p)$ で逐次計

算する. $p=4$ の場合は,

$$\begin{bmatrix} 1 & -\phi_1 & -\phi_2 & -\phi_3 & -\phi_4 \\ -\phi_1 & 1-\phi_2 & -\phi_3 & -\phi_4 & 0 \\ -\phi_2 & -\phi_1-\phi_3 & 1-\phi_4 & 0 & 0 \\ -\phi_3 & -\phi_2-\phi_4 & -\phi_1 & 1 & 0 \\ -\phi_4 & -\phi_3 & -\phi_2 & -\phi_1 & 1 \end{bmatrix} \begin{bmatrix} \gamma(0) \\ \gamma(1) \\ \gamma(2) \\ \gamma(3) \\ \gamma(4) \end{bmatrix} = \begin{bmatrix} \sigma^2 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}$$

一般的な場合について, 要素の法則性を明らかにした形で初期値の決定式を表すと,

$$\begin{bmatrix} 0 & -\phi_1 & \cdots & -\phi_{p-1} & -\phi_p \\ 0 & -\phi_2 & \ddots & -\phi_p & 0 \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ 0 & -\phi_p & \ddots & 0 & 0 \\ 0 & 0 & \cdots & 0 & 0 \end{bmatrix} + \begin{bmatrix} 1 & 0 & \cdots & 0 & 0 \\ -\phi_1 & 1 & \cdots & 0 & 0 \\ \vdots & \ddots & \ddots & & \vdots \\ -\phi_{p-1} & -\phi_{p-2} & \ddots & 1 & 0 \\ -\phi_p & -\phi_{p-1} & \cdots & -\phi_1 & 1 \end{bmatrix} \begin{bmatrix} \gamma(0) \\ \gamma(1) \\ \vdots \\ \gamma(p-1) \\ \gamma(p) \end{bmatrix} = \begin{bmatrix} \sigma^2 \\ 0 \\ \vdots \\ 0 \\ 0 \end{bmatrix}$$

(例)

AR(2)の場合,

$$\begin{bmatrix} 0 & -\phi_1 & -\phi_2 \\ 0 & -\phi_2 & 0 \\ 0 & 0 & 0 \end{bmatrix} + \begin{bmatrix} 1 & 0 & 0 \\ -\phi_1 & 1 & 0 \\ -\phi_2 & -\phi_1 & 1 \end{bmatrix} \begin{bmatrix} \gamma(0) \\ \gamma(1) \\ \gamma(2) \end{bmatrix} = \begin{bmatrix} \sigma^2 \\ 0 \\ 0 \end{bmatrix}$$

$$\begin{bmatrix} 1 & -\phi_1 & -\phi_2 \\ -\phi_1 & 1-\phi_2 & 0 \\ -\phi_2 & -\phi_1 & 1 \end{bmatrix} \begin{bmatrix} \gamma(0) \\ \gamma(1) \\ \gamma(2) \end{bmatrix} = \begin{bmatrix} \sigma^2 \\ 0 \\ 0 \end{bmatrix}$$

$$\text{これを解くと, } \gamma(0) = \frac{1-\phi_2}{(1-\phi_1-\phi_2)(1+\phi_1-\phi_2)(1+\phi_2)} \sigma^2$$

$$\gamma(1) = \frac{\phi_1}{(1-\phi_1-\phi_2)(1+\phi_1-\phi_2)(1+\phi_2)} \sigma^2$$

$$\gamma(2) = \frac{\phi_1^2 + \phi_2 - \phi_2^2}{(1-\phi_1-\phi_2)(1+\phi_1-\phi_2)(1+\phi_2)} \sigma^2$$

$$\gamma(3) = \phi_1 \gamma(2) + \phi_2 \gamma(1) \text{ より}$$


$$\gamma(3) = \frac{\phi_1(\phi_2^2 - 2\phi_2 + \phi_1^2)}{(1-\phi_1-\phi_2)(1+\phi_1-\phi_2)(1+\phi_2)} \sigma^2$$

よって,

$$\rho(1) = \frac{\phi_1}{1-\phi_2}, \rho(2) = \frac{\phi_1^2 + \phi_2 - \phi_2^2}{1-\phi_2}, \rho(3) = \frac{\phi_1(\phi_2^2 - 2\phi_2 + \phi_1^2)}{1-\phi_2}$$

(注意)

$\phi_2 = 1$ のとき分散が 0 になるように見えるが, この場合は, 定常ではないため, 分散の式そのものが成立しない. そのため, 自己相関関数の式も成立しない. ちなみに, $x_t = x_{t-2} + \varepsilon_t$ の場合の系列は下左図のようになる. これは, 季節単位根過程と呼ばれるもので, 偶数期と奇数期がそれぞれ別なランダムウォーク過程になる. 下右図の下側が偶数期, 上側が奇数期である.



さらに、定常性の条件は $\gamma(0) = \frac{1 - \phi_2}{(1 - \phi_1 - \phi_2)(1 + \phi_1 - \phi_2)(1 + \phi_2)} \sigma^2$ の分母が 0 になる条件、すなわち、 $\phi_1 + \phi_2 = 1$, $\phi_1 - \phi_2 = -1$, $\phi_2 = -1$ の (ϕ_1, ϕ_2) の内側となる。

[PAC(k)の求め方]

以下の方程式をとりて PAC(k)を決定する。(この式は、PAC(k)の決定にのみ有効で、PAC(m) ($m \neq k$)の決定には使ってはいけない。)

$$E \begin{bmatrix} x_{t-1} \\ x_{t-2} \\ \vdots \\ x_{t-k} \end{bmatrix} \begin{bmatrix} x_{t-1} \\ x_{t-2} \\ \vdots \\ x_{t-k} \end{bmatrix}^t \begin{bmatrix} a_1 \\ \vdots \\ a_{k-1} \\ \text{PAC}(k) \end{bmatrix} = E \begin{bmatrix} x_{t-1} \\ x_{t-2} \\ \vdots \\ x_{t-k} \end{bmatrix} x_t$$

これは、<変形規則>を利用すると、

$$\begin{bmatrix} \gamma(0) & \gamma(1) & \cdots & \gamma(k-2) & \gamma(k-1) \\ \gamma(1) & \gamma(0) & \ddots & \gamma(k-3) & \gamma(k-2) \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ \gamma(k-2) & \gamma(k-3) & \ddots & \gamma(0) & \gamma(1) \\ \gamma(k-1) & \gamma(k-2) & \cdots & \gamma(1) & \gamma(0) \end{bmatrix} \begin{bmatrix} a_1 \\ \vdots \\ a_{k-1} \\ \text{PAC}(k) \end{bmatrix} = \begin{bmatrix} \gamma(1) \\ \gamma(2) \\ \vdots \\ \gamma(k) \end{bmatrix}$$

となる。

[PAC と AR 過程]

AR(p)すなわち、 $x_t = \phi_1 x_{t-1} + \cdots + \phi_k x_{t-p} + \varepsilon_t$ ($\phi_k \neq 0$)に従っていたなら、

$$\text{PAC}(p) = \phi_k \neq 0, \text{PAC}(p+m) = 0 \quad (m \geq 1)$$

$$\left(E \begin{bmatrix} x_{t-1} \\ x_{t-2} \\ \vdots \\ x_{t-k} \end{bmatrix} \begin{bmatrix} x_{t-1} \\ x_{t-2} \\ \vdots \\ x_{t-k} \end{bmatrix}^t \right) \begin{bmatrix} a_1 \\ \vdots \\ a_{k-1} \\ \text{PAC}(k) \end{bmatrix} = E \begin{bmatrix} x_{t-1} \\ x_{t-2} \\ \vdots \\ x_{t-k} \end{bmatrix} x_t \quad \text{で PAC を決める意味)$$

(説明)

もし, $x_t = \phi_1 x_{t-1} + \dots + \phi_k x_{t-k} + \varepsilon_t$ に従っていれば,

$$x_t = \begin{bmatrix} x_{t-1} \\ x_{t-2} \\ \vdots \\ x_{t-k} \end{bmatrix}^t \begin{bmatrix} \phi_1 \\ \phi_2 \\ \vdots \\ \phi_k \end{bmatrix} + \varepsilon_t \text{ と書き直せるので, } E \begin{bmatrix} x_{t-1} \\ x_{t-2} \\ \vdots \\ x_{t-k} \end{bmatrix} \begin{bmatrix} x_{t-1} \\ x_{t-2} \\ \vdots \\ x_{t-k} \end{bmatrix}^t \begin{bmatrix} a_1 \\ \vdots \\ a_{k-1} \\ \text{PAC}(k) \end{bmatrix} = E \begin{bmatrix} x_{t-1} \\ x_{t-2} \\ \vdots \\ x_{t-k} \end{bmatrix} x_t \text{ に代}$$

入して,

$$\begin{aligned} E \begin{bmatrix} x_{t-1} \\ x_{t-2} \\ \vdots \\ x_{t-k} \end{bmatrix} \begin{bmatrix} x_{t-1} \\ x_{t-2} \\ \vdots \\ x_{t-k} \end{bmatrix}^t \begin{bmatrix} a_1 \\ \vdots \\ a_{k-1} \\ \text{PAC}(k) \end{bmatrix} &= E \begin{bmatrix} x_{t-1} \\ x_{t-2} \\ \vdots \\ x_{t-k} \end{bmatrix} \left(\begin{bmatrix} x_{t-1} \\ x_{t-2} \\ \vdots \\ x_{t-k} \end{bmatrix}^t \begin{bmatrix} \phi_1 \\ \phi_2 \\ \vdots \\ \phi_k \end{bmatrix} + \varepsilon_t \right) \\ &= E \begin{bmatrix} x_{t-1} \\ x_{t-2} \\ \vdots \\ x_{t-k} \end{bmatrix} \begin{bmatrix} x_{t-1} \\ x_{t-2} \\ \vdots \\ x_{t-k} \end{bmatrix}^t \begin{bmatrix} \phi_1 \\ \phi_2 \\ \vdots \\ \phi_k \end{bmatrix} + E \begin{bmatrix} x_{t-1} \\ x_{t-2} \\ \vdots \\ x_{t-k} \end{bmatrix} \varepsilon_t = E \begin{bmatrix} x_{t-1} \\ x_{t-2} \\ \vdots \\ x_{t-k} \end{bmatrix} \begin{bmatrix} x_{t-1} \\ x_{t-2} \\ \vdots \\ x_{t-k} \end{bmatrix}^t \begin{bmatrix} \phi_1 \\ \phi_2 \\ \vdots \\ \phi_k \end{bmatrix} \end{aligned}$$

となる.

$$E \begin{bmatrix} x_{t-1} \\ x_{t-2} \\ \vdots \\ x_{t-k} \end{bmatrix} \begin{bmatrix} x_{t-1} \\ x_{t-2} \\ \vdots \\ x_{t-k} \end{bmatrix}^t = \begin{bmatrix} \gamma(0) & \gamma(1) & \dots & \gamma(k-2) & \gamma(k-1) \\ \gamma(1) & \gamma(0) & \ddots & \gamma(k-3) & \gamma(k-2) \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ \gamma(k-2) & \gamma(k-3) & \ddots & \gamma(0) & \gamma(1) \\ \gamma(k-1) & \gamma(k-2) & \dots & \gamma(1) & \gamma(0) \end{bmatrix}$$

が逆行列を持てば, $\text{PAC}(k) = \phi_k$ となる.(実際持つことがわかっている)

$$\text{さらに, PAC}(k+1) \text{ については, } x_t = \begin{bmatrix} x_{t-1} \\ x_{t-2} \\ \vdots \\ x_{t-k} \\ x_{t-(k+1)} \end{bmatrix}^t \begin{bmatrix} \phi_1 \\ \phi_2 \\ \vdots \\ \phi_k \\ 0 \end{bmatrix} + \varepsilon_t \text{ と表せることから, 先ほどの考え方}$$

により, $\text{PAC}(k+1) = 0$ となることがいえる. $\text{PAC}(k+m) = 0$ も同様.

[x_t の期待値が 0 でない場合]

期待値を引いて考える . つまり , x_t を $x_t - E[x_t]$ に置き換えて考える .

[SPACF の求め方]

$$\begin{bmatrix} \gamma(0) & \gamma(1) & \cdots & \gamma(k-2) & \gamma(k-1) \\ \gamma(1) & \gamma(0) & \ddots & \gamma(k-3) & \gamma(k-2) \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ \gamma(k-2) & \gamma(k-3) & \ddots & \gamma(0) & \gamma(1) \\ \gamma(k-1) & \gamma(k-2) & \cdots & \gamma(1) & \gamma(0) \end{bmatrix} \begin{bmatrix} a_1 \\ \vdots \\ a_{k-1} \\ \text{PAC}(k) \end{bmatrix} = \begin{bmatrix} \gamma(1) \\ \gamma(2) \\ \vdots \\ \gamma(k) \end{bmatrix}$$

の自己共分散を標本自己

共分散に変える .

$$\begin{bmatrix} \hat{\gamma}(0) & \hat{\gamma}(1) & \cdots & \hat{\gamma}(k-2) & \hat{\gamma}(k-1) \\ \hat{\gamma}(1) & \hat{\gamma}(0) & \ddots & \hat{\gamma}(k-3) & \hat{\gamma}(k-2) \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ \hat{\gamma}(k-2) & \hat{\gamma}(k-3) & \ddots & \hat{\gamma}(0) & \hat{\gamma}(1) \\ \hat{\gamma}(k-1) & \hat{\gamma}(k-2) & \cdots & \hat{\gamma}(1) & \hat{\gamma}(0) \end{bmatrix} \begin{bmatrix} a_1 \\ \vdots \\ a_{k-1} \\ \text{PAC}(k) \end{bmatrix} = \begin{bmatrix} \hat{\gamma}(1) \\ \hat{\gamma}(2) \\ \vdots \\ \hat{\gamma}(k) \end{bmatrix}$$

[定常性]

弱定常性 (2 次定常性 , 共分散定常)

$$E[x_t] = \mu \quad (\text{時間に関して不変})$$

$$\gamma(k) = E[(x_t - \mu)(x_{t-k} - \mu)] = \gamma_k \quad (\text{いかなる } k \text{ に対しても } k \text{ のみに依存})$$

このほかに strictly stationary (狭義定常性) があるが省略 (こちらは構造変化の問題を扱う)

[AR(1) としてのランダムウォーク過程]

$x_t = \phi x_{t-1} + \varepsilon_t$ において $\phi = 1$ とすると RW3 , すなわち $\Delta x_t = \varepsilon_t$ ($E[\varepsilon_t] = 0, E[\varepsilon_t \varepsilon_{t-k}] = 0$) が得られる . $x_t = x_{t-1} + \varepsilon_t = (x_{t-2} + \varepsilon_{t-1}) + \varepsilon_t = x_0 + \varepsilon_t + \cdots + \varepsilon_1$ となる .

従って x_0 が与えられているときの条件付き分散は , $V[x_t | x_0] = V\left[\sum_{s=1}^t \varepsilon_s\right] = \sum_{s=1}^t V[\varepsilon_s] = t\sigma^2$.

$$V_{x_t}[x_t] = E_{x_0}[V[x_t | x_0]] + V_{x_0}[E[x_t | x_0]] = E_{x_0}[t\sigma^2] + V_{x_0}[x_0] = t\sigma^2 + V_{x_0}[x_0]$$

定常性を仮定すると , $\gamma(0) = V_{x_0}[x_0] = V_{x_t}[x_t]$ となるが , $\gamma(0) = t\sigma^2 + \gamma(0)$ となるが , 矛盾

する . よって定常ではない .

[MA 過程]

$$x_t = \varepsilon_t + \theta \varepsilon_{t-1}$$

$$x_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \cdots + \theta_q \varepsilon_{t-q}$$

[MA 過程と ACF]

$$x_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \cdots + \theta_q \varepsilon_{t-q}$$

$$x_{t-k} = \varepsilon_{t-k} + \theta_1 \varepsilon_{t-k-1} + \cdots + \theta_q \varepsilon_{t-k-q}$$

$\theta_0 = 1$ とする

$$\begin{aligned} \gamma(k) &= E[x_t x_{t-k}] = E[(\varepsilon_t + \theta_1 \varepsilon_{t-1} + \cdots + \theta_q \varepsilon_{t-q})(\varepsilon_{t-k} + \theta_1 \varepsilon_{t-k-1} + \cdots + \theta_q \varepsilon_{t-k-q})] \\ &= E[\theta_k \varepsilon_{t-k}^2] + E[\theta_{k+1} \theta_1 \varepsilon_{t-k-1}^2] + \cdots + E[\theta_q \theta_{q-k} \varepsilon_{t-q}^2] \\ &= \sigma^2 (\theta_k \theta_0 + \theta_{k+1} \theta_1 + \cdots + \theta_q \theta_{q-k}) \\ &= \sigma^2 \sum_{j=0}^{q-k} \theta_{k+j} \theta_j \end{aligned}$$

$$\rho(k) = \frac{\sum_{j=0}^{q-k} \theta_{k+j} \theta_j}{\sum_{j=0}^q \theta_j^2}$$

$$\rho(q) = \frac{\sum_{j=0}^0 \theta_{q+j} \theta_j}{\sum_{j=0}^q \theta_j^2} = \frac{\theta_q}{\sum_{j=0}^q \theta_j^2} (\neq 0)$$

$$\rho(q+1) = \frac{\sum_{j=0}^{q-(q+1)} \theta_{q+1+j} \theta_j}{\sum_{j=0}^q \theta_j^2} = 0$$

[SACF, SPACF を使った AR, MA 過程の同定]

AR(p) の場合

PACF(p) $\neq 0$, PACF(p+1) = 0 から, SPACF(p+1) が 0 に近い値をとる. さらに,

s.e.(SPACF(p+m)) $\approx 1/\sqrt{n}$ (m ≥ 1) なので, PACF(p+m) = 0 という帰無仮

説の下で棄却域は $|\text{SPACF}(p+m)| > 1.96/\sqrt{n}$ となる。逆に $|\text{SPACF}(p+m)| \leq 1.96/\sqrt{n}$ なら、 $\text{PACF}(p+m) = 0$ という帰無仮説が支持されるので、AR 次数は p となる。

MA(q)の場合

$\rho(q) \neq 0, \rho(q+1) = 0, \rho(q+2) = 0, \dots$ なので、 $\hat{\rho}(q+m)$ が 0 に近い値をとるはず。
 $\text{s.e.}(\hat{\gamma}(p+m)) \approx 1/\sqrt{n}$ ($m \geq 1$) なので、 $\gamma(p+m) = 0$ という帰無仮説の下で棄却域は $|\hat{\gamma}(p+m)| > 1.96/\sqrt{n}$ となる。逆に $|\hat{\gamma}(p+m)| \leq 1.96/\sqrt{n}$ なら、 $\gamma(p+m) = 0$ という帰無仮説が支持されるので、MA 次数は p となる。

[AR 過程のパラメータ推定]

いったん AR(p)とわかったなら、 $x_t = \mu + \phi_1 x_{t-1} + \dots + \phi_p x_{t-p} + \varepsilon_t$ より、この回帰を最小二乗法で行えばよい。

[MA 過程のパラメータ推定]

推定の問題点は、 ε_t がわからないこと。だから、まず ε_t を決定する漸化式を求める。

$\varepsilon_t = x_t - \mu - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q}$, 初期条件 $\varepsilon_0 = \varepsilon_{-1} = \dots = 0$ で考える。もし、 $\mu, \theta_1, \dots, \theta_q$ を

なんらかの値に固定してあげれば、上記の漸化式で ε_t を計算できる。 $\sum_{t=1}^T \varepsilon_t^2$ を最小にする

$\mu, \theta_1, \dots, \theta_q$ を探せばよい。

探し方、Excel なら、ソルバーを使える。

R の例

[ARMA 過程]

AR と MA 過程の混合モデル

$$x_t = \mu + \phi_1 x_{t-1} + \dots + \phi_p x_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}$$

ACF の計算

$k > q$ のとき、

$$x_t x_{t-k} = \phi_1 x_{t-1} x_{t-k} + \dots + \phi_p x_{t-p} x_{t-k} + \varepsilon_t x_{t-k} + \theta_1 \varepsilon_{t-1} x_{t-k} + \dots + \theta_q \varepsilon_{t-q} x_{t-k}$$

$$E[x_t x_{t-k}] = \phi_1 E[x_{t-1} x_{t-k}] + \cdots + \phi_p E[x_{t-p} x_{t-k}] + E[\varepsilon_t x_{t-k}] + \theta_1 E[\varepsilon_{t-1} x_{t-k}] + \cdots + \theta_q E[\varepsilon_{t-q} x_{t-k}]$$

$$\gamma(k) = \phi_1 \gamma(k-1) + \cdots + \gamma_p \gamma(k-p)$$

$k \leq q$ のとき ,

$$x_t \varepsilon_t = \phi_1 x_{t-1} \varepsilon_t + \cdots + \phi_p x_{t-p} \varepsilon_t + \varepsilon_t^2 + \theta_1 \varepsilon_{t-1} \varepsilon_t + \cdots + \theta_q \varepsilon_{t-q} \varepsilon_t$$

$$E[x_t \varepsilon_t] = \phi_1 E[x_{t-1} \varepsilon_t] + \cdots + \phi_p E[x_{t-p} \varepsilon_t] + E[\varepsilon_t^2] + \theta_1 E[\varepsilon_{t-1} \varepsilon_t] + \cdots + \theta_q E[\varepsilon_{t-q} \varepsilon_t] = \sigma^2$$

$$x_t \varepsilon_{t-1} = \phi_1 x_{t-1} \varepsilon_{t-1} + \cdots + \phi_p x_{t-p} \varepsilon_{t-1} + \varepsilon_t \varepsilon_{t-1} + \theta_1 \varepsilon_{t-1} \varepsilon_{t-1} + \cdots + \theta_q \varepsilon_{t-q} \varepsilon_{t-1}$$

$$\begin{aligned} E[x_t \varepsilon_{t-1}] &= \phi_1 E[x_{t-1} \varepsilon_{t-1}] + \cdots + \phi_p E[x_{t-p} \varepsilon_{t-1}] + E[\varepsilon_t \varepsilon_{t-1}] + \theta_1 E[\varepsilon_{t-1} \varepsilon_{t-1}] + \cdots + \theta_q E[\varepsilon_{t-q} \varepsilon_{t-1}] \\ &= \phi_1 E[x_t \varepsilon_t] + \theta_1 \sigma^2 \end{aligned}$$

$$\begin{aligned} E[x_t \varepsilon_{t-2}] &= \phi_1 E[x_{t-1} \varepsilon_{t-2}] + \phi_2 E[x_{t-2} \varepsilon_{t-2}] + \cdots + \phi_p E[x_{t-p} \varepsilon_{t-2}] \\ &\quad + E[\varepsilon_t \varepsilon_{t-2}] + \theta_1 E[\varepsilon_{t-1} \varepsilon_{t-2}] + \theta_2 E[\varepsilon_{t-2} \varepsilon_{t-2}] + \cdots + \theta_q E[\varepsilon_{t-q} \varepsilon_{t-2}] \\ &= \phi_1 E[x_t \varepsilon_{t-1}] + \phi_2 E[x_t \varepsilon_t] + \theta_2 \sigma^2 \end{aligned}$$

一般的な漸化式

$$E[x_t \varepsilon_t] = \sigma^2$$

$$E[x_t x_{t-k}] = \phi_k E[x_t \varepsilon_t] + \cdots + \phi_1 E[x_t \varepsilon_{t-k+1}] + \theta_k \sigma^2 \quad (k \geq 1)$$

$$\begin{bmatrix} E[x_t \varepsilon_t] \\ E[x_t \varepsilon_{t-1}] \\ E[x_t \varepsilon_{t-2}] \\ \vdots \\ E[x_t \varepsilon_{t-k}] \end{bmatrix} = \begin{bmatrix} 0 & 0 & \cdots & 0 & 0 \\ \phi_1 & 0 & \cdots & 0 & 0 \\ \phi_2 & \phi_1 & \ddots & 0 & 0 \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ \phi_k & \phi_{k-1} & \cdots & \phi_1 & 0 \end{bmatrix} \begin{bmatrix} E[x_t \varepsilon_t] \\ E[x_t \varepsilon_{t-1}] \\ \vdots \\ E[x_t \varepsilon_{t-k+1}] \\ E[x_t \varepsilon_{t-k}] \end{bmatrix} + \begin{bmatrix} 1 \\ \theta_1 \\ \vdots \\ \theta_{k-1} \\ \theta_k \end{bmatrix} \sigma^2$$

$$\begin{bmatrix} 1 & 0 & \cdots & 0 & 0 \\ -\phi_1 & 1 & \cdots & 0 & 0 \\ -\phi_2 & -\phi_1 & \ddots & 0 & 0 \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ -\phi_k & -\phi_{k-1} & \cdots & -\phi_1 & 1 \end{bmatrix} \begin{bmatrix} E[x_t \varepsilon_t] \\ E[x_t \varepsilon_{t-1}] \\ E[x_t \varepsilon_{t-2}] \\ \vdots \\ E[x_t \varepsilon_{t-k}] \end{bmatrix} = \begin{bmatrix} 1 \\ \theta_1 \\ \vdots \\ \theta_{k-1} \\ \theta_k \end{bmatrix} \sigma^2$$

$$\begin{bmatrix} 1 & 0 & \cdots & 0 & 0 \\ -\phi_1 & 1 & \cdots & 0 & 0 \\ -\phi_2 & -\phi_1 & \ddots & 0 & 0 \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ -\phi_k & -\phi_{k-1} & \cdots & -\phi_1 & 1 \end{bmatrix}^{-1} = \begin{bmatrix} 1 & 0 & \cdots & 0 & 0 \\ f_1 & 1 & \cdots & 0 & 0 \\ f_2 & f_1 & \ddots & 0 & 0 \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ f_k & f_{k-1} & \cdots & f_1 & 1 \end{bmatrix} \text{とおくと,}$$

$f_k = \phi_k + f_{k-1}\phi_{k-1} + \cdots + f_1\phi_1$ であることがわかる .

$$\begin{bmatrix} E[x_t \varepsilon_t] \\ E[x_t \varepsilon_{t-1}] \\ E[x_t \varepsilon_{t-2}] \\ \vdots \\ E[x_t \varepsilon_{t-k}] \end{bmatrix} = \begin{bmatrix} 1 & 0 & \cdots & 0 & 0 \\ f_1 & 1 & \cdots & 0 & 0 \\ f_2 & f_1 & \ddots & 0 & 0 \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ f_k & f_{k-1} & \cdots & f_1 & 1 \end{bmatrix} \begin{bmatrix} 1 \\ \theta_1 \\ \vdots \\ \theta_{k-1} \\ \theta_k \end{bmatrix} \sigma^2$$

$$x_t^2 = \phi_1 x_{t-1} x_t + \cdots + \phi_p x_{t-p} x_t + \varepsilon_t x_t + \theta_1 \varepsilon_{t-1} x_t + \cdots + \theta_q \varepsilon_{t-q} x_t$$

$$E[x_t^2] = \phi_1 E[x_{t-1} x_t] + \cdots + \phi_p E[x_{t-p} x_t] + E[\varepsilon_t x_t] + \theta_1 E[\varepsilon_{t-1} x_t] + \cdots + \theta_q E[\varepsilon_{t-q} x_t]$$

$$\begin{aligned} E[x_t x_{t-1}] &= \phi_1 E[x_{t-1} x_{t-1}] + \cdots + \phi_p E[x_{t-p} x_{t-1}] + E[\varepsilon_t x_{t-1}] + \theta_1 E[\varepsilon_{t-1} x_{t-1}] + \cdots + \theta_q E[\varepsilon_{t-q} x_{t-1}] \\ &= \phi_1 E[x_t x_t] + \phi_2 E[x_{t-1}^2] + \cdots + \phi_p E[x_t x_{t-(p-1)}] \\ &\quad + E[\varepsilon_{t+1} x_t] + \theta_1 E[\varepsilon_t x_t] + \cdots + \theta_q E[\varepsilon_{t-(q-1)} x_t] \end{aligned}$$

$$p \geq q$$

$$\left\{ \begin{bmatrix} 0 & -\phi_1 & \cdots & -\phi_{p-1} & -\phi_p \\ 0 & -\phi_2 & \ddots & -\phi_p & 0 \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ 0 & -\phi_p & \ddots & 0 & 0 \\ 0 & 0 & \cdots & 0 & 0 \end{bmatrix} + \begin{bmatrix} 1 & 0 & \cdots & 0 & 0 \\ -\phi_1 & 1 & \cdots & 0 & 0 \\ \vdots & \ddots & \ddots & & \vdots \\ -\phi_{p-1} & -\phi_{p-2} & \ddots & 1 & 0 \\ -\phi_p & -\phi_{p-1} & \cdots & -\phi_1 & 1 \end{bmatrix} \right\} \begin{bmatrix} \gamma(0) \\ \gamma(1) \\ \vdots \\ \gamma(p-1) \\ \gamma(p) \end{bmatrix}$$

$$= \begin{bmatrix} 1 & \theta_1 & \cdots & \theta_{p-1} & \theta_q \\ \theta_1 & \theta_2 & \ddots & \theta_q & 0 \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ \theta_{q-1} & \theta_q & \ddots & 0 & 0 \\ \theta_q & 0 & \cdots & 0 & 0 \\ & & & & O_{p-q, q+1} \end{bmatrix} \begin{bmatrix} E[x_t \varepsilon_t] \\ E[x_t \varepsilon_{t-1}] \\ \vdots \\ E[x_t \varepsilon_{t-q+1}] \\ E[x_t \varepsilon_{t-q}] \end{bmatrix}$$

$$= \begin{bmatrix} 1 & \theta_1 & \cdots & \theta_{p-1} & \theta_q \\ \theta_1 & \theta_2 & \ddots & \theta_q & 0 \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ \theta_{q-1} & \theta_q & \ddots & 0 & 0 \\ \theta_q & 0 & \cdots & 0 & 0 \\ & & & & O_{p-q, q+1} \end{bmatrix} \begin{bmatrix} 1 & 0 & \cdots & 0 & 0 \\ f_1 & 1 & \cdots & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ f_2 & f_1 & \ddots & 0 & 0 \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ f_q & f_{q-1} & \cdots & f_1 & 1 \end{bmatrix} \begin{bmatrix} 1 \\ \theta_1 \\ \vdots \\ \theta_{q-1} \\ \theta_q \end{bmatrix} \sigma^2$$

$p < q$

$$\left\{ \begin{bmatrix} 0 & -\phi_1 & \cdots & -\phi_{p-1} & -\phi_p \\ 0 & -\phi_2 & \ddots & -\phi_p & 0 \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ 0 & -\phi_p & \ddots & 0 & 0 \\ 0 & 0 & \cdots & 0 & 0 \end{bmatrix} + \begin{bmatrix} 1 & 0 & \cdots & 0 & 0 \\ -\phi_1 & 1 & \cdots & 0 & 0 \\ \vdots & \ddots & \ddots & & \vdots \\ -\phi_{p-1} & -\phi_{p-2} & \ddots & 1 & 0 \\ -\phi_p & -\phi_{p-1} & \cdots & -\phi_1 & 1 \end{bmatrix} \right\} \begin{bmatrix} \gamma(0) \\ \gamma(1) \\ \vdots \\ \gamma(p-1) \\ \gamma(p) \end{bmatrix}$$

$$= \begin{bmatrix} 1 & \theta_1 & \cdots & \theta_p & \cdots & \cdots & \cdots & \cdots & \theta_q \\ \theta_1 & \theta_2 & \ddots & \theta_{p+1} & \ddots & \ddots & \ddots & \ddots & 0 \\ \vdots & \ddots & \ddots & \ddots & \ddots & \ddots & \ddots & \ddots & \vdots \\ \theta_p & \theta_{p+1} & \cdots & \cdots & \cdots & \theta_q & 0 & \cdots & 0 \end{bmatrix} \begin{bmatrix} 1 & 0 & \cdots & 0 & 0 \\ f_1 & 1 & \cdots & 0 & 0 \\ f_2 & f_1 & \ddots & 0 & 0 \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ f_q & f_{q-1} & \cdots & f_1 & 1 \end{bmatrix} \begin{bmatrix} 1 \\ \theta_1 \\ \vdots \\ \theta_{q-1} \\ \theta_q \end{bmatrix} \sigma^2$$

[ARMA 過程の推定]

MA 過程と同様

[AIC による ARMA 過程の決定]

$$AIC = \log \hat{\sigma}^2 + 2 \frac{p+q+1}{T} \quad (\text{定数項ありの場合})$$

$$AIC = \log \hat{\sigma}^2 + 2 \frac{p+q}{T} \quad (\text{定数項なしの場合})$$

AIC が最小のモデルを選ぶ .

(例) 日経 2 2 5 日次複利収益率

```
arorder<- -1;
maorder <- -1;
aicmin<-10000000;
for(i in 0:5)
  for(j in 0:5) {
    result <- arima(retnikkei, order=c(i,0,j));
    if (result$aic < aicmin){
      aicmin<- result$aic;
      arorder<- i; maorder<- j
    }
  };
print(c(arorder, maorder, aicmin))
```

```
[1]      3.00      5.00 -46468.43
```

```
> result <- arima(retnikkei, order=c(arorder,0,maorder));
```

警告メッセージ :

収束に関する問題の可能性: optim は以下のコードを与えました : 1 in: arima(retnikkei, order = c(arorder, 0, maorder))

```
> result
```

Call:

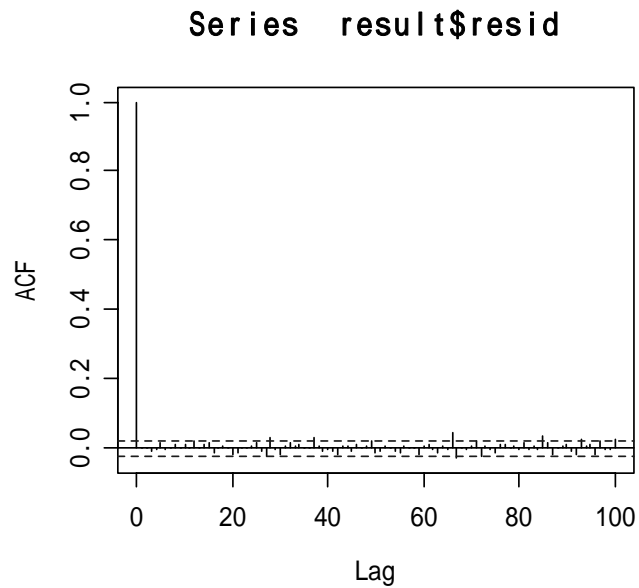
```
arima(x = retnikkei, order = c(arorder, 0, maorder))
```

Coefficients:

	ar1	ar2	ar3	ma1	ma2	ma3	ma4	ma5
	0.5722	-0.0344	-0.6289	-0.5641	-0.0301	0.6907	-0.0161	-0.0464
s.e.	0.0114	0.0131	0.0152	0.0210	0.0162	0.2087	0.0232	0.0162

```
intercept
      1e-04
s.e.    1e-04
```

sigma^2 estimated as 0.000136: log likelihood = 23244.21, aic = -46468.43




```
> Box.test(result$resid, lag=100, type=c("Ljung-Box"))
```

Box-Ljung test

```
data: result$resid
X-squared = 133.1595, df = 100, p-value = 0.01491
```


```
> predictdata<- retnikkei - result$resid
> plotdata<- cbind(retnikkei, predictdata)
> matplot(plotdata, type="l")
```



[Long Memory 過程]


```
> acf(abs(retnikkei), lag=2000)
```

Series abs(retnikkei)



```
> pacf(abs(retnikkei), lag=500)
```

Series abs(retnikkei)



```
> aggvarFit(retnikkei)
```

Title:

Hurst Exponent from Aggregated Variances

Call:

```
aggvarFit(x = retnikkei)
```

Method:

Aggregated Variance Method

Hurst Exponent:

H	beta
0.5319445	-0.9361109

Hurst Exponent Diagnostic:

Estimate	Std.Err	t-value	Pr(> t)
X 0.5319445	0.02373784	22.40913	4.52827e-27

Parameter Settings:

n	levels	minnpts	cut.off1	cut.off2
7665	50	3	5	316

Description:

Fri Jun 03 10:20:26 2005

0.5 以上なら長期記憶あり 境界線上


[分散不均一性の処理]

(日次収益率の分布)

実線：収益率 / 標準偏差 (収益率) の推定された密度関数，分散 1 に標準化

点線：N(0,1)の密度関数

```
> den<-density(retnikkei/sd(retnikkei))
> dendata<-cbind(den$y,dnorm(den$x))
> matplot(den$x, dendata, type="l")
```



(非正規性)

Q-Q プロット

経験分布関数とは，(横軸座標，縦軸座標)として $\left(t, \frac{t\text{以下のデータ数}}{\text{標本数}}\right)$ をプロットしたも

のである．しかし，これでは正規分布との違いがよくわからない．そのために，Q-Qプロットといわれるものを描く． $\Phi(t)$ を標準正規分布の確率分布関数とする．よって， X が正規分布に従い，その平均が μ ，標準偏差が σ とすれば，

$$\Pr\left(\frac{X-\mu}{\sigma} \leq t\right) = \Phi(t)$$

である．よって，

$$\Pr(X \leq \mu + t\sigma) = \Phi(t)$$

である．標準正規分布の q パーセンタイルを z_q とすると，

$$\Pr(X \leq \mu + z_q\sigma) = \Phi(z_q) = q$$

となり， $\Phi(z_q) = q$ より $z_q = \Phi^{-1}(q)$ となるので， $\Pr(X \leq \mu + \sigma\Phi^{-1}(q)) = q$ ．

つまり， X の q パーセンタイル X_q は $\mu + \sigma\Phi^{-1}(q)$ である．従って， $(X_q, \Phi^{-1}(q))$ をプロットす


ると線形になるはずである． q は $\frac{\text{データ値以下のデータ数}}{\text{標本数}}$ でわかるので，結局，データが

正規分布に従っていれば， $\left(\text{データ値}, \Phi^{-1}\left(\frac{\text{データ値以下のデータ数}}{\text{標本数}} \right) \right)$ の全てのデータ

値に対するプロットは直線に近くなるはずである．これをQ-Qプロットと呼ぶ．

```
> qqnorm(retnikkei)
```

```
> qqline(retnikkei)
```



なぜおこるか？

(1) 分布がもともと非正規だから． 安定分布

しかし，先ほどの Long Memory の推定では，Hurst Exponent は 0.5 と有意に異ならなかった．もし，収益率が正規分布以外の安定分布なら，Hurst Exponent は 0.5 と異なるはずである．


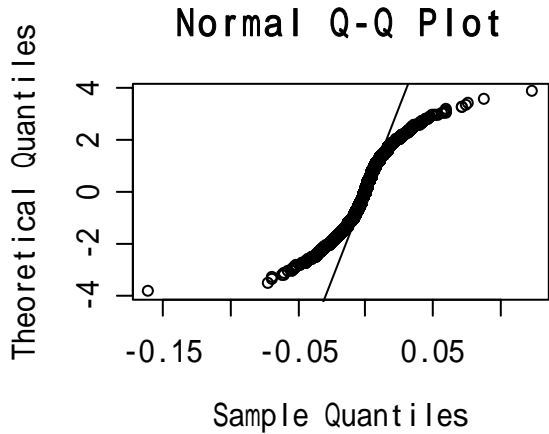
(2) 正規分布の混合プロセスだから

(混合正規分布)

日経225日次収益率と確率0.5でN(0,1), 確率0.5でN(0,10)の場合のQ-Qプロット

```
> qqnorm(retnikkei, datax=TRUE)
```

```
> qqline(retnikkei, datax=TRUE)
```



(ARCHの仲間たち)

<Volatility>


$\mu_t = E[x_t | F_{t-1}]$ < F_{t-1} は $t - 1$ 期までの情報 >

$\sigma_t^2 = V(x_t | F_{t-1}) = E[(x_t - \mu_t)^2 | F_{t-1}]$ (条件付き分散)

$\mu_t = 0$ だから, 近似的に $\sigma_t^2 = V(x_t | F_{t-1}) = E[x_t^2 | F_{t-1}]$.

日経225月次収益率

変動の激しい時期とそうでない時期



・ Volatility の特徴


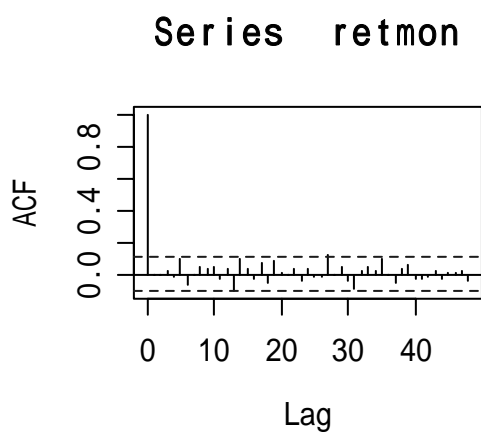
Volatility Clustering(収益率変動の激しい時期がかたまる)

Volatility jump はほとんどない Volatility は連続



Volatility は特定の範囲内でのみ変化する Volatility は定常

Leverage Effect Volatility は価格変化と負の相関を持つ



< 月次収益率 >



月次には相関はない。



絶対値には 2 , 3 月の範囲で相関がある。



2乗値には2, 3月の範囲で相関がある。

$\mu_t = E[x_t | F_{t-1}]$ の計算 .

```
> arorder<- -1;
> maorder <- -1;
> aicmin<-10000000;
> for(i in 0:6)
+ for(j in 0:6) {
+ result <- arima(retmon, order=c(i,0,j));
+ if (result$aic < aicmin){
+ aicmin<- result$aic;
+ arorder<- i; maorder<- j
+ }
+ };
> print(c(arorder, maorder, aicmin))
[1] 0.000 0.000 -1024.185
```

```
result<- arima(retmon, order=c(0,0,0));
> print(result)
```

Call:

```
arima(x = retmon, order = c(0, 0, 0))
```

Coefficients:

intercept
 0.0029
 s.e. 0.0030

sigma^2 estimated as 0.003025: log likelihood = 514.09, aic = -1024.18

$$\mu_t = E[x_t | F_{t-1}] = 0$$

$$x_t = \varepsilon_t$$

しかし, volatility 変化をモデル化する.

<ARCH(m)>

$$r_t = \mu + \sum_{i=1}^p \phi_i r_{t-i} + \sum_{i=1}^q \phi_i a_{t-i} + a_t$$

a_t をショック, mean-corrected return とよぶ

$$a_t = \sigma_t \varepsilon_t$$


$$\varepsilon_t \sim \text{IID}(0,1)$$

$$\sigma_t^2 = \alpha_0 + \alpha_1 a_{t-1}^2 + \dots + \alpha_m a_{t-m}^2 \quad (\alpha_i > 0)$$


一般的には ε_t は $N(0,1)$, または, $t(\text{df})/\text{s.e.}(t(\text{df}))$ と考えられる.

過去の大きなショックは大きな Volatility をもたらしやすい. Volatility Clustering


$$\sigma_t^2 = 1e(-6) + \frac{1}{\sqrt{3}} a_{t-1}^2 \text{ のとき}$$



Series data



Series data^2



性質(ARCH(1)の場合)

$$a_t = \varepsilon_t \sqrt{\alpha_0 + \alpha_1 a_{t-1}^2}$$


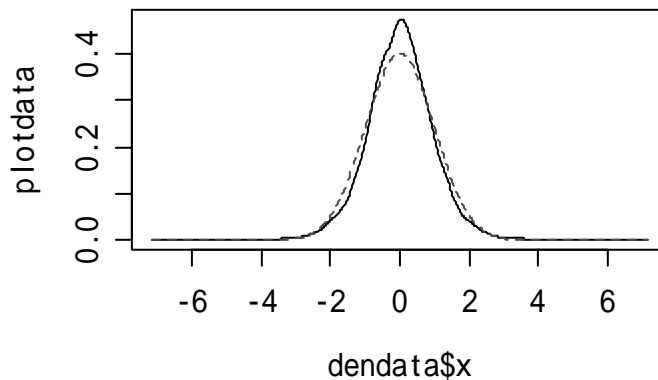
$$\begin{aligned} E[a_t] &= E_{a_{t-1}} E[a_t | a_{t-1}] = E_{a_{t-1}} E[\varepsilon_t \sqrt{\alpha_0 + \alpha_1 a_{t-1}^2} | a_{t-1}] = E_{a_{t-1}} [\sqrt{\alpha_0 + \alpha_1 a_{t-1}^2} E[\varepsilon_t]] = E_{a_{t-1}} [0] \\ &= 0 \end{aligned}$$

$$\begin{aligned} V[a_t] &= V_{a_{t-1}} [E[a_t | a_{t-1}]] + E_{a_{t-1}} [V[a_t | a_{t-1}]] \\ &= V_{a_{t-1}} [E[\varepsilon_t \sqrt{\alpha_0 + \alpha_1 a_{t-1}^2} | a_{t-1}]] + E_{a_{t-1}} [V[\sqrt{\alpha_0 + \alpha_1 a_{t-1}^2} \varepsilon_t | a_{t-1}]] \\ &= V_{a_{t-1}} [0] + E_{a_{t-1}} [(\alpha_0 + \alpha_1 a_{t-1}^2) V[\varepsilon_t]] \\ &= \alpha_0 + \alpha_1 E[a_{t-1}^2] = \alpha_0 + \alpha_1 V[a_{t-1}] \end{aligned}$$

定常性から, $V[a_t] = V[a_{t-1}]$ なので, $V[a_t] = \frac{\alpha_0}{1-\alpha_1}$. ことから, 定常性のためには, $1-\alpha_1 > 0$

が必要なこともわかる.

- ・ 正規分布よりも大きい裾をもつ. (点線標準正規)



< ARCH の欠点 >

- ・ プラスのショックもマイナスのショックも volatility に同一のショックをもたらす.
- ・ 4次モーメント $E[a_t^4]$ を持つためには, ARCH(1)の場合 $0 \leq \alpha_1^2 \leq 1/3$ でなければならない.

高次の ARCH ではこの条件は複雑になる.

- ・ 大きな孤立したのショックに対してゆっくり反応していくので, volatility を大きめに予測

< ARCH 推定の手順 >

1. 線形時系列モデルからの乖離を考える. ARMA 推定のやり方を使う.(特に日次)
2. その残差系列, $\hat{\varepsilon}_t$ を対象とする.
3. この系列に条件付き分散不均一性があるかを調べる

(ア) $\hat{\varepsilon}_t^2$ の系列相関を Ljung-Box テストで検定

(イ) $\hat{\varepsilon}_t^2 = \alpha_0 + \alpha_1 \hat{\varepsilon}_{t-1}^2 + \dots + \alpha_m \hat{\varepsilon}_{t-m}^2 + \varepsilon_t$ の回帰において, 全係数の有意性検定である F

テストを行う.(LM検定)

4. 分散不均一性の次数を決める

$\hat{\varepsilon}_t^2$ の SPAC で次数を決める.

5. 推定を行う

6. モデルのチェック

$\tilde{a}_t = \hat{\varepsilon}_t / \sigma_t$ を標準化ショックと呼ぶ

(ア) $\tilde{a}_t = \hat{\varepsilon}_t / \sigma_t$ に対して Ljung-Box テスト

(イ) $\tilde{a}_t = \hat{\varepsilon}_t / \sigma_t$ に対して Q-Q プロット

(ウ) $\tilde{a}_t = \hat{\varepsilon}_t / \sigma_t$ の基本統計量を調べる

< 例 >

日経 2 2 5 月次収益率

1. 線形時系列モデルからの乖離を考える. ARMA 推定のやり方を使う.
すでにみたとおり ARMA(0, 0), つまり, Random Walk
そのままの系列を使用.

2. 省略

3. この系列に条件付き分散不均一性があるかを調べる

(ア) Ljung-Box テスト

```
> for(i in 1:5) print(Box.test(ret.mon^2, lag=i))
```

Box-Pierce test

```
data: ret.mon^2
```

```
X-squared = 31.2103, df = 1, p-value = 2.315e-08
```

Box-Pierce test


```
data: ret.mon^2
X-squared = 53.8953, df = 2, p-value = 1.981e-12
```

Box-Pierce test

```
data: ret.mon^2
X-squared = 56.7467, df = 3, p-value = 2.911e-12
```

Box-Pierce test

```
data: ret.mon^2
X-squared = 59.3207, df = 4, p-value = 4.029e-12
```

Box-Pierce test

```
data: ret.mon^2
X-squared = 66.1834, df = 5, p-value = 6.367e-13
```

ということで、確かに分散不均一性はある。

(イ) LM検定

```
x<- (ret.mon[6:length(ret.mon)])^2
lag1<-(ret.mon[5:(length(ret.mon)-1)])^2
lag2<-(ret.mon[4:(length(ret.mon)-2)])^2
lag3<-(ret.mon[3:(length(ret.mon)-3)])^2
lag4<-(ret.mon[2:(length(ret.mon)-4)])^2
lag5<-(ret.mon[1:(length(ret.mon)-5)])^2
r<-lm(x~lag1+lag2+lag3+lag4+lag5)
summary(r)
```

Call:

```
lm(formula = x ~ lag1 + lag2 + lag3 + lag4 + lag5)
```

Residuals:

Min	1Q	Median	3Q	Max
-0.0092388	-0.0022304	-0.0013865	0.0003802	0.0361517

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	0.0015467	0.0003729	4.147	4.26e-05	***
lag1	0.2475140	0.0541703	4.569	6.89e-06	***
lag2	0.1894369	0.0558214	3.394	0.000772	***
lag3	-0.0585674	0.0566672	-1.034	0.302098	
lag4	-0.0023138	0.0558402	-0.041	0.966972	
lag5	0.1180351	0.0541764	2.179	0.030047	*

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.005075 on 336 degrees of freedom


Multiple R-Squared: 0.1338, Adjusted R-squared: 0.1209

F-statistic: 10.38 on 5 and 336 DF, p-value: 2.855e-09

(イ)の方法でもやはり、分散不均一性はある。

4. 分散不均一性の次数を決める

Series retmon^2



5次くらいか(2次もあり)

5. 推定

```
> library(tseries)
> r.arch<- garch(ret.mon, order=c(0,5))
> summary(r.arch)
Call:
garch(x = ret.mon, order = c(0, 5))
```

Model:

GARCH(0,5)

Residuals:

(残差)

Min	1Q	Median	3Q	Max
(最小値)	(第1四分位)	(中央値)	(第3四分位)	(最大値)
-3.9797	-0.4719	0.1530	0.7141	3.6800

Coefficient(s):

(係数)

	Estimate	Std. Error	t value	Pr(> t)
	(推定値)	(標準誤差)	(t値)	(p値)
a0	0.0011892	0.0002034	5.846	5.02e-09 ***
a1	0.1732990	0.0732212	2.367	0.0179 *
a2	0.1660008	0.0905517	1.833	0.0668 .
a3	0.0814976	0.0863993	0.943	0.3455
a4	0.1103221	0.0727329	1.517	0.1293
a5	0.1179515	0.0790294	1.493	0.1356

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Diagnostic Tests:

(診断テスト)

Jarque Bera Test

(ベラ - ハルケ検定 ~ 帰無仮説: 正規分布, 正規分布のとき小さい値, カイ2乗分布)

data: Residuals

X-squared = 35.2969, df = 2, p-value = 2.165e-08

(統計量値) (自由度)(p値)

(統計量値が大きく, p値が小さいので, 帰無仮説: 正規分布が棄却され, 残差は正規ではない)

Box-Ljung test

data: Squared.Residuals

X-squared = 0.0099, df = 1, p-value = 0.9206


(統計量値) (自由度) (p値)

(統計量値が小さく, p値が大きい. 帰無仮説: 残差の2乗に系列相関はないは棄却され, 系列相関はない)


```
> res<- r.arch$resid
```

```
> plot(res, type="l")
```

標準化ショックのプロット




Series res[6:length(res)]^2



実際の収益率²(実線)とVolatility $E[r_t^2]$ (点線)のプロット

2乗値（実線）とボラティリティ値（点線）をプロットする


```
> plotdata<- cbind(ret.mon[6:length(ret.mon)]^2,  
  r.arch$fitted.values[6:length(ret.mon),1]^2)  
>matplot(plotdata, type="l")
```




6 . チェック

```
> r.arch<- garchFit(ret.mon, order=c(0,5))  
> opar<-par(mfrow=c(2,2))  
> plot(r.arch)  
> par(opar)
```

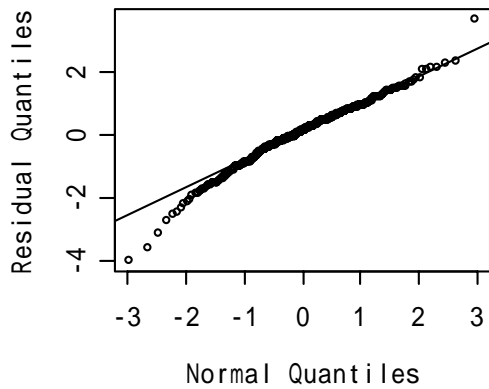
Standardized Residuals




ACF of |Residuals|



QQ-Plot of Residuals



Ljung-Box p-values



Test on absolute Values of Residual

自己相関は消えている .

```
> basicStats(res)
```

	Value
nobs	347.00000000
NAs	5.00000000
Minimum	-3.97971168
Maximum	3.67999316
1. Quartile	-0.47193653
3. Quartile	0.71407865
Mean	0.06073388
Median	0.15295071
Sum	20.77098702
SE Mean	0.05405309

LCL Mean	-0.04558558
UCL Mean	0.16705334
Variance	0.99923389
Stdev	0.99961687
Skewness	-0.47375137
Kurtosis	1.22867549

標準化ショックは依然として Fat tail を持っている .

< GARCH(m,s) >

$$r_t = \mu + \sum_{i=1}^p \phi_i r_{t-i} + \sum_{i=1}^q \phi_i a_{t-i} + a_t$$

a_t をショック , mean-corrected return とよぶ

$$a_t = \sigma_t \varepsilon_t$$

$$\varepsilon_t \sim \text{IID}(0,1)$$

$$\sigma_t^2 = \alpha_0 + \alpha_1 a_{t-1}^2 + \dots + \alpha_m a_{t-m}^2 + \beta_1 \sigma_{t-1}^2 + \dots + \beta_s \sigma_{t-s}^2 \quad (\alpha_i > 0, \beta_i > 0)$$

ARCH だと観測可能なデータからボラティリティが確定的にわかる . しかし , GARCH は観測できない (推定はできる) σ_{t-k}^2 が入っているので , ボラティリティを確定的に知ることはできない . しかし , 潜在的にはボラティリティの確定的漸化式が存在する .

次数の決定

まず , library(tseries) , library(fSeries)を実行 .

(最小の A I C のモデルを選ぶ)

```
data=ret.mon
```

```
result.arma<- arima(data, order=c(3, 0, 5));
```

```
z<-result.arma$res;
```

```
aroder<- -1;
```

```
maorder <- -1;
```

```
aicmin<-Inf;
```

```
for(i in 0:9)
```



```
  for(j in 1:9) {
```

```
    result <- garch(z, order=c(i,j), itmax=20000, grad="numerical");
```


```

aic<- result$n.likeli+(i+j+1)
print(c(i,j,aic));
if (aic < aicmin){
    aicmin<- aic;
    arorder<- i; maorder<- j
}
};
print(c(arorder, maorder, aicmin));
result<- garch(z, order=c(arorder,maorder), itmax=20000);
summary(result)
plot(result)
x11()
kurtosis(res, na.rm=T)
skewness(res, na.rm=T)
plotdata<- cbind(ret.mon[2:length(ret.mon)]^2,
    result$fitted.values[2:length(ret.mon),1]^2)
matplot(plotdata, type="l")


```




Histogram of z



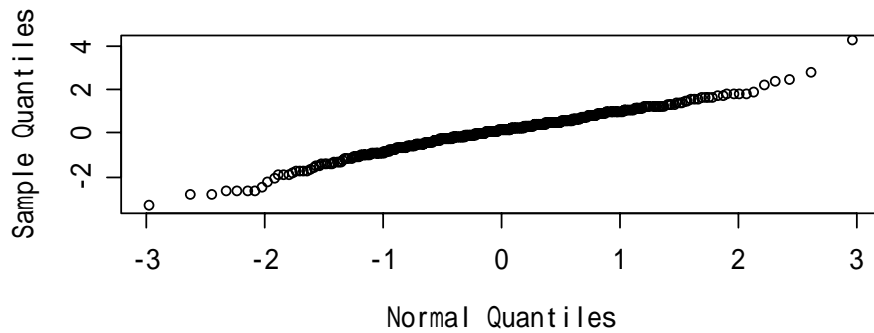
Histogram of Residuals




Q-Q Plot of z





Q-Q Plot of Residuals



ACF of Squared z



ACF of Squared Residuals



(結果の出力)

```
> print(c(arorder, maorder, aicmin));
```

```
[1] 1.0000 1.0000 -861.1997
```

Call:

```
garch(x = z, order = c(arorder, maorder), itmax = 20000)
```

Model:
GARCH(1,1)

Residuals:

Min	1Q	Median	3Q	Max
-3.37052	-0.55846	0.08133	0.60820	4.18912

Coefficient(s):

	Estimate	Std. Error	t value	Pr(> t)
a0	3.565e-05	2.183e-05	1.633	0.102379
a1	8.930e-02	2.342e-02	3.813	0.000137 ***
b1	9.031e-01	2.356e-02	38.328	< 2e-16 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Diagnostic Tests:

Jarque Bera Test

data: Residuals

X-squared = 25.685, df = 2, p-value = 2.646e-06

Box-Ljung test

data: Squared.Residuals

X-squared = 1.0163, df = 1, p-value = 0.3134

> kurtosis(res, na.rm=T)

[1] 1.228675

> skewness(res, na.rm=T)

[1] -0.4737514

rgarch<-garchFit(ret.mon, order=c(1,1); summary(rgarch)

(結果)

Call:

garchFit(x = ret.mon, order = c(1, 1))

Model:
GARCH(1,1)

Residuals:

Min	1Q	Median	3Q	Max
-3.1286	-0.4701	0.1473	0.6935	4.1204

Coefficient(s):

	Estimate	Std. Error	t value	Pr(> t)
omega	3.046e-05	2.204e-05	1.382	0.167007
a1	8.948e-02	2.473e-02	3.619	0.000296 ***
b1	9.049e-01	2.358e-02	38.371	< 2e-16 ***


Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Fit:


sigma^2 estimated as: 0.9733
AIC Criterion: 981.35

```
> opar<-par(mfrow=c(2,2))  
> plot(rgarch)
```


Standardized Residuals




ACF of |Residuals|




QQ-Plot of Residuals




Ljung-Box p-values




```
> res<-rgarch$res
> kurtosis(res, na.rm=T)
[1] 1.064439
> skewness(res, na.rm=T)
[1] -0.2720261
> plotdata<- cbind(ret.mon[2:length(ret.mon)]^2,
+                 result$fitted.values[2:length(ret.mon),1]^2)
> matplot(plotdata, type="l")
```



ARCH(2)と GARCH(2,1)との volatility の比率



GARCH(2,3)と GARCH(2,1)の volatility の比率



`stdFit(rgarch$resid[3:length(rgarch$resid)])`

\$minimum

[1] 469.7923

\$estimate

[1] 0.1146346 0.9647381 6.9252765

\$gradient

[1] 4.973799e-05 -1.541594e-04 2.290062e-06

\$code

[1] 1

\$iterations

[1] 17

GARCH(2,1)の標準化ショックは自由度7程度のt分布に近い

(なぜ GARCH モデルがかくも反映するのか)

Volatility Clustering をとらえる

端以外はほとんど正規分布となる .

< IGARCH >

$$\sigma_t^2 = \alpha_0 + \alpha_1 a_{t-1}^2 + \cdots + \alpha_m a_{t-m}^2 + \beta_1 \sigma_{t-1}^2 + \cdots + \beta_s \sigma_{t-s}^2 \quad (\alpha_i > 0)$$

で推定された $\hat{\beta}_1 + \cdots + \hat{\beta}_s \approx 1$ でありがちである . 上記の例でもそう . この場合 Volatility 自身がランダムウォークしているということ .

$$\sigma_t^2 = \alpha_0 + \alpha_1 a_{t-1}^2 + \cdots + \alpha_m a_{t-m}^2 + \beta_1 \sigma_{t-1}^2 + \cdots + \beta_s \sigma_{t-s}^2 \quad (\alpha_i > 0)$$

$$\beta_1 + \cdots + \beta_s \approx 1$$

商品 , 為替

< GARCH-M >

$$r_t = \mu + c\sigma_t^2 + a_t$$

$$a_t = \sigma_t \varepsilon_t$$

$$\varepsilon_t \sim \text{IID}(0,1)$$

$$\sigma_t^2 = \alpha_0 + \alpha_1 a_{t-1}^2 + \cdots + \alpha_m a_{t-m}^2 + \beta_1 \sigma_{t-1}^2 + \cdots + \beta_s \sigma_{t-s}^2 \quad (\alpha_i > 0)$$

c がリスクプレミアムをしめす

SP500 では GARCH(1,1) - M で c が有意に正になるらしい .

<E-GARCH>

正の収益と負の収益に対する非対称効果

$$\text{ショック} : g(\varepsilon_t) = \theta \varepsilon_t + \gamma (|\varepsilon_t| - E(|\varepsilon_t|))$$

$$g(\varepsilon_t) = \begin{cases} (\theta + \gamma)\varepsilon_t - \gamma E(|\varepsilon_t|) & \varepsilon_t \geq 0 \\ (\theta - \gamma)\varepsilon_t - \gamma E(|\varepsilon_t|) & \varepsilon_t < 0 \end{cases}$$

一般には正規分布を仮定して $E(|\varepsilon_t|) = \sqrt{2/\pi}$ とする .

$$a_t = \sigma_t \varepsilon_t$$

$$\varepsilon_t \sim \text{IID}(0,1)$$

$$\log(\sigma_t^2) = \alpha_0 + \alpha_1 \log(\sigma_{t-1}^2) + \cdots + \alpha_m \log(\sigma_{t-m}^2) + g(\varepsilon_{t-1}) + \beta_1 g(\varepsilon_{t-2}) + \cdots + \beta_s g(\varepsilon_{t-s-1})$$

< Asymmetric Volatility Models: APARCH(p,q) >

$$u_t | \Omega_{t-1} = \sigma_t \xi_t, \quad \xi_t \sim \mathcal{N}(0, 1),$$

$$\sigma_t^\delta = \omega + \sum_{i=1}^p \alpha_i (|u_{t-i}| - \gamma_i u_{t-i})^\delta + \sum_{j=1}^q \beta_j \sigma_{t-j}^\delta,$$

$$\omega > 0, \delta \geq 0, -1 < \gamma_i < 1,$$

$$\alpha_i \geq 0, i = 1, \dots, p \quad \beta_j \geq 0, j = 1, \dots, q.$$

- Engle's ARCH(p):
 $\delta = 2$ and $\gamma_i = 0; \beta_j = 0$.
- Bollerslev's GARCH(p,q):
 $\delta = 2$ and $\gamma_i = 0$.
- Taylor/Schwert's GARCH(p,q):
 $\delta = 1$ and $\gamma_i = 0$.

Bollerslev の GARCH が普通の GARCH

月次収益率

$$\sigma_t^2 = 0.0001562 + 0.0949281 \left(|u_{t-1}| - 0.4260921 u_{t-1} \right)^2 + 0.8430144 \sigma_{t-1}^2$$

$$u_{t-1} > 0 \text{ なら } , \sigma_t^2 = 0.0001562 + 0.0949281 (1 - 0.4260921)^2 u_{t-1}^2 + 0.8430144 \sigma_{t-1}^2$$

$$u_{t-1} \leq 0 \text{ なら } , \sigma_t^2 = 0.0001562 + 0.0949281 (1 + 0.4260921)^2 u_{t-1}^2 + 0.8430144 \sigma_{t-1}^2$$

Leverage Effect

```
> raparch<- aparchFit(ret.mon,
+ order=list(alpha.lags=1, beta.lags=1, delta=2),
+ opt=list(gamma = T, delta = FALSE, disparm = FALSE),
+ doprint=FALSE)
> summary(raparch)
```

Call:

```
aparchFit(x = ret.mon, order = list(alpha.lags = 1, beta.lags = 1,
delta = 2), opt = list(gamma = T, delta = FALSE, disparm = FALSE),
doprint = FALSE)
```

Coefficient(s):

```
[1] 0.0001562 0.0949281 0.4260921 0.8430144 2.0000000 1.0000000
```

<SV>

$$r_t = \sigma_t \varepsilon_t$$

$$\log(\sigma_t^2) = \alpha_0 + \sum_{k=1}^p \alpha_p \log(\sigma_{t-k}^2) + v_t$$

ε_t, v_t は独立