

Analiza szeregów czasowych:

5. Liniowe modele stochastyczne

P. F. Góra

<http://th-www.if.uj.edu.pl/zfs/gora/>

semestr letni 2006/07

Dwa rodzaje modelowania

1. *Modelowanie “z pierwszych zasad”*. Znamy prawa rządzące jakimś zjawiskiem (fizycznym, biologicznym, procesem społecznym), na ich podstawie, dokonując odpowiednich idealizacji, tworzymy model szczegółowy. Często uwzględniamy zaburzenie stochastyczne.

2. *Modelowanie stochastyczne*. Nie znamy praw rządzących jakimś procesem, znamy tylko szereg czasowy będący wynikiem tego procesu. Wiemy lub zakładamy przy tym, iż w procesie uczestniczy bardzo wielu “agentów”, którzy dokonują przypadkowych decyzji, ale jakiś mechanizm sprawia, że wynikowy, uśredniony proces wykazuje pewne regularności. Obserwując owe regularności w szeregu czasowym, chcemy poznać pewne charakterystyki mechanizmu odpowiedzialnego za jego wygenerowanie.

Liniowe modele stochastyczne


Niech $\{y_n\}_{n=1}^N$ będzie pewnym ciągiem danych “pomiarowych”. Nie znamy mechanizmu, który wygenerował ten szereg. Przypuszczamy, że jest on mocno zaszumiony. Jeżeli szereg $\{y_n\}_{n=1}^N$ jest *stacjonarny*, próbujemy przedstawić go w postaci

$$y_n = \beta_1 y_{n-1} + \beta_2 y_{n-2} + \cdots + \beta_p y_{n-p} + \alpha_0 \eta_n + \alpha_1 \eta_{n-1} + \cdots + \alpha_q \eta_{n-q}, \quad (1)$$

gdzie $\{\eta_k\}$ jest białym szumem. Model (1) próbuje przedstawić rzeczywisty szereg czasowy w postaci odfiltrowanego białego szumu.

Proces (1) nazywam procesem $ARMA(p, q)$ (AutoRegresywny Moving Average — autoregresywny proces średniej ruchomej). W ogólności zamiast białego szumu, szereg $\{\eta_k\}$ mógłby być dowolnym stacjonarnym sygnałem o znanych własnościach.

Przykład procesu ARMA(3,2)



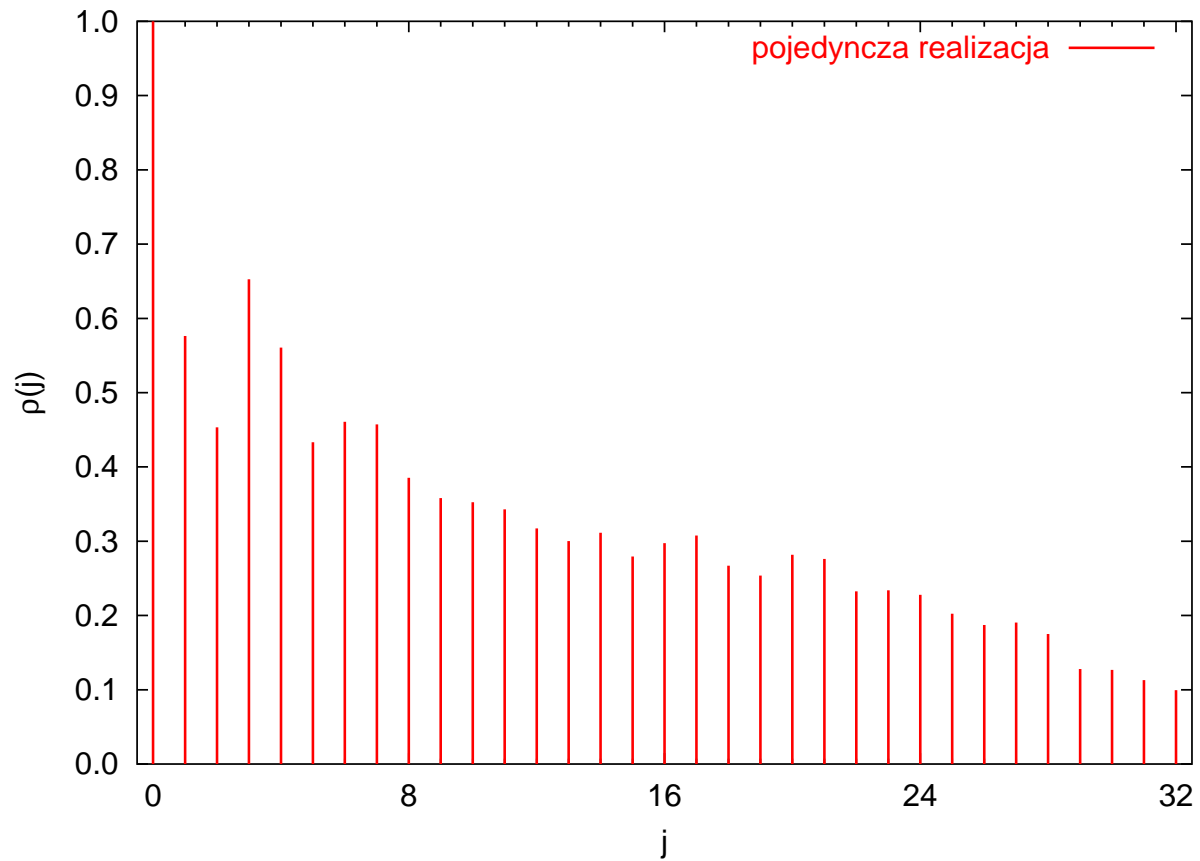
Funkcja korelacji

W teorii funkcję korelacji wylicza się **średniując po realizacjach** procesu stochastycznego, który “odpowiada” za wygenerowanie tego szeregu:

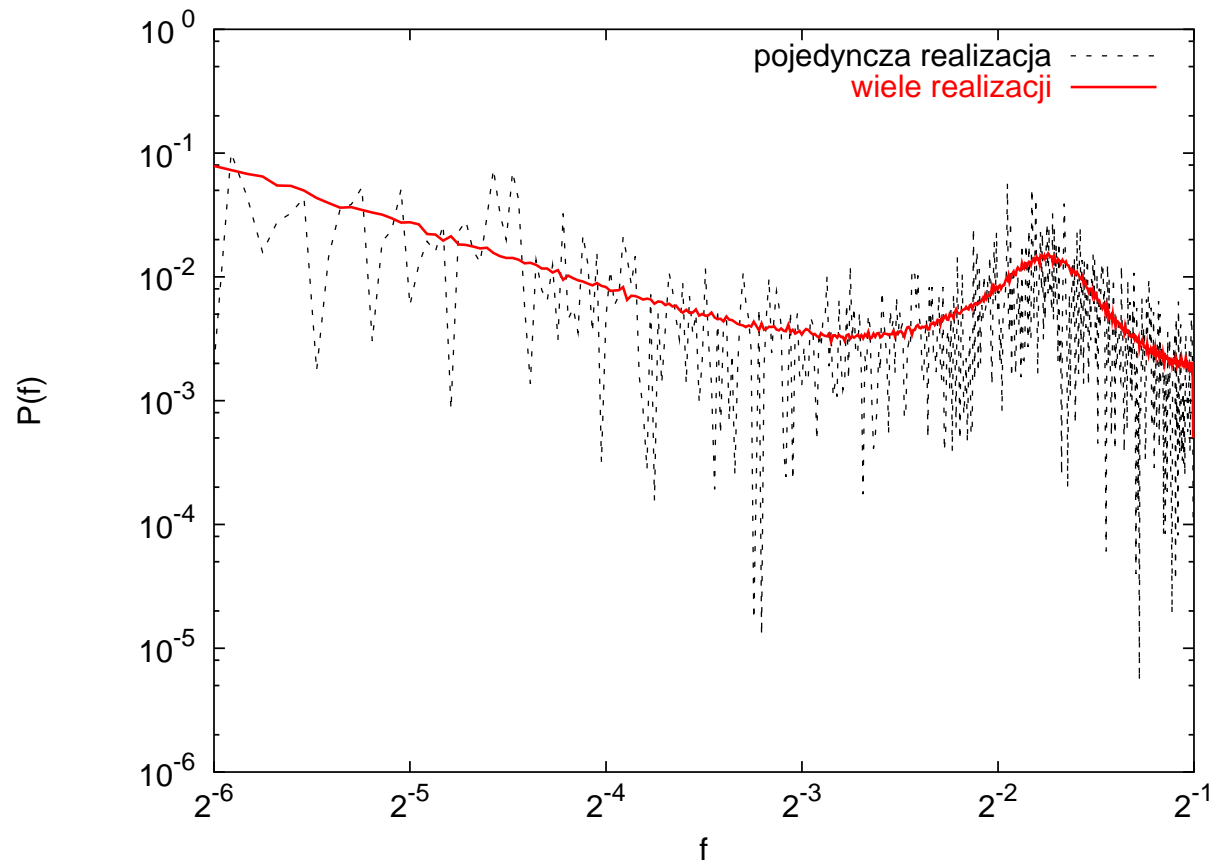
$$\rho(i) = \left\langle \left(\frac{1}{N-i} \sum_{j=i+1}^N y_{j-i} y_j \right) / \left(\frac{1}{N} \sum_{j=1}^N y_j^2 \right) \right\rangle \quad (2)$$

W praktyce mamy daną **tylko jedną realizację** naszego szeregu i dlatego obliczona funkcja korelacji może się różnić od wartości teoretycznej.

Funkcja korelacji powyższego procesu



Widmo mocy powyższego procesu



Warunek stacjonarności procesu ARMA

Proces (1) ma postać filtru IIR, a zatem

Proces (1) jest stacjonarny wtedy i tylko wtedy gdy pierwiastki równania

$$\lambda^p - \beta_1 \lambda^{p-1} - \beta_2 \lambda^{p-2} - \dots - \beta_p = 0 \quad (3)$$

leżą wewnątrz okręgu jednostkowego.

Procesy autoregresywne — $AR(p)$

Jeżeli proces $ARMA$ nie ma średniowania szumu, nazywamy go procesem autoregresywnym:

$$y_n = \beta_1 y_{n-1} + \beta_2 y_{n-2} + \cdots + \beta_p y_{n-p} + \alpha_0 \eta_n. \quad (4)$$

Aby obliczyć jego funkcję autokorelacji, mnożę (4) przez y_{n-m} i średniuję po realizacjach szumu:

$$\langle y_{n-m} y_n \rangle = \beta_1 \langle y_{n-m} y_{n-1} \rangle + \cdots + \beta_p \langle y_{n-m} y_{n-p} \rangle + \alpha_0 \langle y_{n-m} \eta_n \rangle. \quad (5)$$

Ostatni człon w (5) znika, gdyż y_{n-m} nie może zależeć od *późniejszego od siebie* szumu.

Dzieląc (5) przez wariancję $\langle y_n^2 \rangle$, dostajemy równanie na *funkcję korelacji procesu AR(p)*:

$$\rho_m = \beta_1 \rho_{m-1} + \beta_2 \rho_{m-2} + \cdots + \beta_p \rho_{m-p} \quad (6)$$

Z teorii równań różnicowych wiemy, że rozwiązanie równania różnicowego (6) ma postać

$$\rho_m = \sum_{j=1}^p A_j \lambda_j^m, \quad (7)$$

gdzie λ_j są rozwiązaniami równania (3). Z uwagi na wymaganie stabilności, $\forall j : |\lambda_j| < 1$, a zatem możemy napisać $\lambda_j = e^{-\tau_j} e^{2\pi i f_j}$, gdzie $\forall j : \tau_j > 0$.

Funkcja korelacji procesu autoregresywnego

Ponieważ równanie (3) ma współczynniki rzeczywiste, jego pierwiastki są albo rzeczywiste, albo parami sprzężone. Wobec tego stałe A_j można dobrać tak, aby ρ_m było rzeczywiste. Ostatecznie stwierdzamy, że

Funkcja korelacji procesu autoregresywnego ma postać kombinacji liniowej zanikających eksponent i tłumionych sinusoid:

$$\rho_m = \sum A_j e^{-m\tau_j} + \sum' A_{j'} e^{-m\tau_{j'}} \sin(2\pi f_{j'} m + \phi_{j'}). \quad (8)$$

Widmo procesu autoregresywnego

Widmo procesu autoregresywnego otrzymujemy natychmiast z funkcji przejścia odpowiedniego filtru:

$$P(f) = \frac{\alpha_0^2}{\left| 1 - \sum_{n=1}^p \beta_n e^{2\pi i n f} \right|^2}, \quad 0 \leq f \leq \frac{1}{2}, \quad (9)$$

Równania Yule'a-Walkera

W równaniu (6) podstawmy $m = 1$. Dostaniemy

$$\rho_1 = \beta_1 \rho_{1-1} + \beta_2 \rho_{1-2} + \dots + \beta_p \rho_{1-p} = \beta_1 + \beta_2 \rho_1 + \dots + \beta_p \rho_{p-1}, \quad (10)$$

gdź na mocy stacjonarności $\rho_j = \rho_{-j}$. Jeżeli zrobimy tak dla $m = 1, \dots, p$, dostaniemy *równania Yule'a-Walkera*:

$$\begin{bmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{p-1} \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{p-2} \\ \vdots & \vdots & \vdots & & \vdots \\ \rho_{p-1} & \rho_{p-2} & \rho_{p-3} & \cdots & 1 \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_p \end{bmatrix} = \begin{bmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_p \end{bmatrix}. \quad (11)$$

Teoretycznie, znając funkcję korelacji ρ_m , możemy stąd obliczyć parametry procesu β_j . **W praktyce** nie znamy funkcji korelacji ρ_m , możemy tylko używać korelacji “doświadczalnej”, wyliczonej z jedynej znanej nam realizacji procesu:

$$r_m = \left(\frac{1}{N-m} \sum_{i=m+1}^N y_{i-m} y_i \right) / \left(\frac{1}{N} \sum_{i=1}^N y_i^2 \right). \quad (12)$$

r_m podstawiamy do równania Yule’a-Walkera (11), skąd wyliczamy **przybliżone** wartości współczynników β_i . Jest jednak poważny problem: **Skąd mamy wiedzieć jaki jest rząd procesu, czyli jaki jest rozmiar układu równań (11)?**


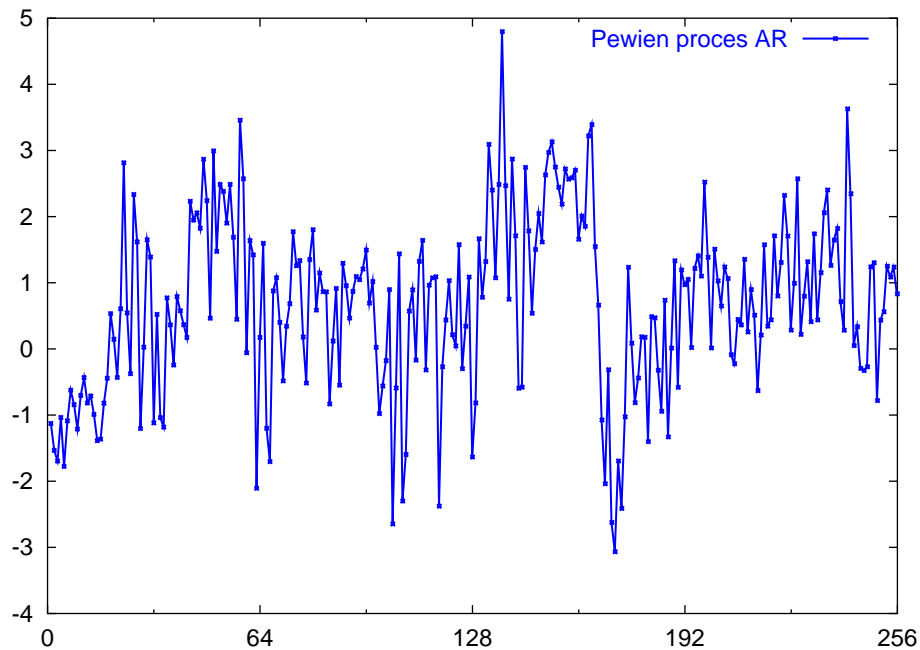
Funkcja autokorelacji cząstkowej

Funkcja autokorelacji procesu $AR(p)$ ma rozwinięcie nieskończone, zależy jednak od p liniowo niezależnych funkcji. Załóżmy, że proces jest rzędu k . Wówczas równania Yule'a-Walkera mają postać

$$\begin{bmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{k-2} \\ \vdots & \vdots & \vdots & & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & 1 \end{bmatrix} \begin{bmatrix} \varphi_{k1} \\ \varphi_{k2} \\ \vdots \\ \varphi_{kk} \end{bmatrix} = \begin{bmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_k \end{bmatrix}. \quad (13)$$

φ_{kk} nazywam funkcją autokorelacji cząstkowej. Dla procesu AR rzędu p , $\varphi_{kk} \neq 0$ dla $k \leq p$ i $\varphi_{kk} \equiv 0$ dla $k > p$. W praktyce zamiast ρ_m używamy r_m , co oczywiście utrudnia podjęcie decyzji o rzędzie procesu ☹

Przykład



Parametry wyestymowane: $p = 3: \beta_1 = 0.415, \beta_2 = 0.003, \beta_3 = 0.470$
 $p = 4: \beta_1 = 0.474, \beta_2 = -0.149, \beta_3 = 0.530, \beta_4 = 0.015$
Parametry "prawdziwe": $p = 3: \beta_1 = 0.500, \beta_2 = -0.125, \beta_3 = 0.500$

Proces AR(1)

$$y_n = \beta_1 y_{n-1} + \alpha_0 \eta_n \quad (14)$$


$-1 < \beta_1 < 1$. Funkcja korelacji ($m > 0$):


$$\langle y_n y_{n-m} \rangle = \beta_1 \langle y_{n-1} y_{n-m} \rangle + \alpha_0 \langle \eta_n y_{n-m} \rangle \quad (15)$$

$$\rho_m = \beta_1 \rho_{m-1} \quad (16)$$


$$\rho_m = \beta_1^m = (\text{sgn}(\beta_1))^m e^{-m \ln |\beta_1|} \quad (17)$$


$$y_n = 0.75y_{n-1} + \eta_n$$





$$y_n = -0.75y_{n-1} + \eta_n$$





Proces AR(2)


$$y_n = \beta_1 y_{n-1} + \beta_2 y_{n-2} + \alpha_0 \eta_n \quad (18)$$


Postępując jak poprzednio

$$\rho_i = \beta_1 \rho_{i-1} + \beta_2 \rho_{i-2} \quad (19)$$


Rozwiązaniem jest albo suma dwu członów zanikających potęgowo (“dwie eksponenty”), albo pewne zanikające rozwiązanie znakozmienne (“drgania tłumione”). To, że korelacja **zanika**, jest zagwarantowane przez warunki stacjonarności.


$$y_n = 0.75y_{n-1} - 0.05y_{n-2} + \eta_n$$





$$y_n = 0.75y_{n-1} - 0.5y_{n-2} + \eta_n$$





Procesy średniej ruchomej $MA(q)$

Dla procesu

$$y_n = \alpha_0 \eta_n + \alpha_1 \eta_{n-1} + \dots + \alpha_q \eta_{n-q} \quad (20)$$

otrzymujemy


$$\langle y_n y_{n-i} \rangle = \sum_{j=0}^q \alpha_j \langle \eta_{n-j} y_{n-i} \rangle \quad (21)$$


Funkcja korelacji **urywa się** dla $i > q$:

$$\rho_i = \begin{cases} \frac{-\alpha_i + \alpha_1 \alpha_{i-1} + \dots + \alpha_{q-i} \alpha_q}{1 + \alpha_1^2 + \dots + \alpha_q^2} & i = 1, 2, \dots, q \\ 0 & i > q \end{cases} \quad (22)$$


Funkcja autokorelacji cząstkowej **zanika**.


$$y_n = 0.25\eta_n + 0.5\eta_{n-1} + 0.25\eta_{n-2}$$





$$y_n = -0.25\eta_n + 0.5\eta_{n-1} + -0.25\eta_{n-2}$$






Procesy $ARMA(p, q)$


Warunkiem stacjonarności procesu $ARMA$ jest stacjonarność części autoregresywnej.

Widmo procesu $ARMA$ otrzymujemy z funkcji przejścia odpowiedniego filtra IIR :

$$P(f) = \left| \frac{\sum_{n=0}^q \alpha_n e^{2\pi i n f}}{1 - \sum_{n=1}^p \beta_n e^{2\pi i n f}} \right|^2, \quad 0 \leq f \leq \frac{1}{2}. \quad (23)$$

$$y_n = 0.75y_{n-1} + 0.25\eta_n + 0.5\eta_{n-1} + 0.25\eta_{n-2}$$





Kryteria identyfikacji rzędu procesu

Rodzaj procesu	Fukcja autokorelacji	Funkcja autokorelacji cząstkowej
$AR(p)$	zanika (nieskończona)	urywa się (skończona)
$MA(q)$	urywa się (skończona)	zanika (nieskończona)
$ARMA(p,q)$	zanika (nieskończona)	zanika (nieskończona)