
The autocorrelation and autocovariance functions - helpful tools in the modeling problem

Joanna Nowicka-Zagrajek

Agnieszka Wyłomańska

Institute of Mathematics and Computer

Science

Hugo-Steinhaus Center for Stochastic

Processes

Wrocław University of Technology


Poland

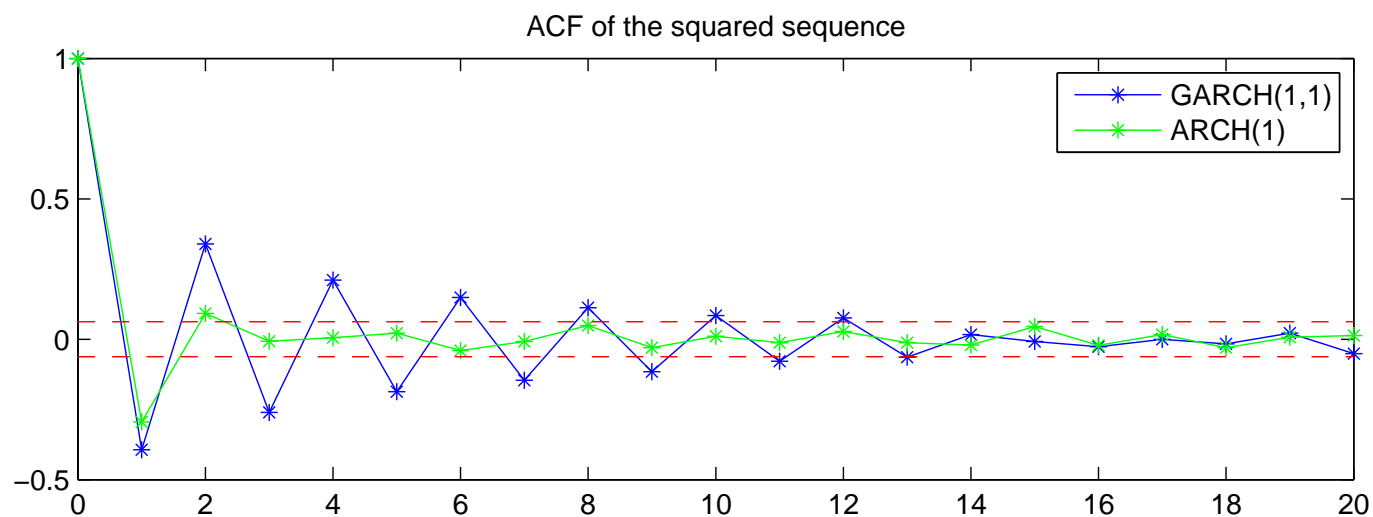
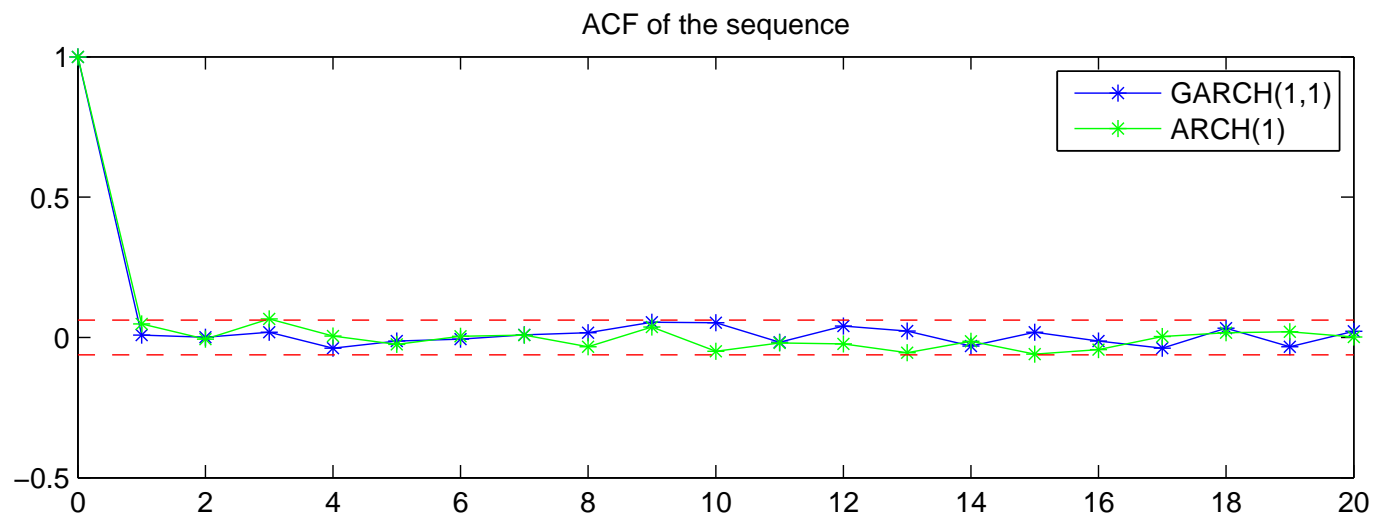


Spis treści

1. Motywacja
2. Podstawowe definicje i założenia
3. Niezależne zmienne losowe o jednakowym rozkładzie
4. Stacjonarne modele ARMA
 - (a) Model AR(1)
 - (b) Model MA(1)
5. Modele ARCH(p)
 - (a) Model ARCH(2)
6. Modele GARCH(p,q)
 - (a) Model GARCH(1,1)
7. Podsumowanie i Literatura.

Funkcja autokorelacji dwóch zbiorów obserwacji





Podstawowe definicje i założenia

- X, Y - zmienne losowe o skończonych wartościach oczekiwanych $\mathbb{E}X, \mathbb{E}Y$ i skończonych wariancjach $\text{Var}(X), \text{Var}(Y)$
- Najbardziej popularną miarą zależności X i Y jest kowariancja:

$$\text{cov}(X, Y) = \mathbb{E}(XY) - \mathbb{E}X\mathbb{E}Y$$

- W wielu zastosowaniach zamiast kowariancji używa się tzw. przeskalowanej kowariancji (korelacji):

$$\text{corr}(X, Y) = \frac{\text{cov}(X, Y)}{\sqrt{\text{Var}(X)}\sqrt{\text{Var}(Y)}}$$

- Obydwie miary są symetryczne.

- Przy studiowaniu struktury zależności szeregu czasowego $\{X_n\}$ wykorzystuje się tzw. funkcję autokowariancji

$$\text{cov}(X_n, X_m) = \mathbb{E}(X_n X_m) - \mathbb{E}X_n \mathbb{E}X_m$$

oraz funkcję autokorelacji (ACF)

$$\text{corr}(X_n, Y_m) = \frac{\text{cov}(X_n, X_m)}{\sqrt{\text{Var}(X_n)} \sqrt{\text{Var}(X_m)}}$$

- Dla stacjonarnego szeregu czasowego funkcje te przybierają postać

$$\text{cov}(X_n, X_m) = \text{cov}(X_0 X_{m-n}) = \mathbb{E}(X_0 X_{m-n}) - (\mathbb{E}X_0)^2 = \text{cov}_X(m-n),$$

$$\text{corr}(X_n, Y_m) = \text{corr}(X_0 X_{m-n}) = \frac{\text{cov}_X(m-n)}{\text{Var}(X_0)} = \text{corr}_X(m-n).$$

- Estymatorami tych funkcji są autokowariancja i autokorelacja próbkowa

$$\widehat{\text{cov}}_X(h) = \widehat{\text{cov}}(X_0, X_h) = \frac{1}{n} \sum_{i=1}^{n-h} (x_i - \bar{x})(x_{i+h} - \bar{x}),$$

$$\widehat{\text{corr}}_X(h) = \frac{\widehat{\text{cov}}_X(h)}{\widehat{\text{cov}}_X(0)},$$

gdzie $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$ oraz x_1, x_2, \dots, x_n są zaobserwowanymi wartościami szeregu $\{X_n\}$.

- W pracy studiujemy nie tylko strukturę zależności obserwowanego szeregu czasowego $\{X_n\}$, ale również szeregu utworzonego z kwadratów wyjściowych danych

$$Y_n = X_n^2$$

- Zakładamy, że $\mathbb{E}X_n^4 = \mathbb{E}Y_n^2$ istnieje dla każdego n
- Szereg $\{\xi_n\}$ - niezależne zmienne losowe o jednakowym rozkładzie (i.i.d.) o średniej zero i skończonym czwartym momencie z następującymi parametrami

$$\sigma^2 = \mathbb{E}\xi_n^2, \quad \gamma = \mathbb{E}\xi_n^4.$$

Niezależne zmienne losowe o jednakowym rozkładzie

Rozpatrujemy szereg czasowy o średniej zero niezależnych zmiennych losowych o jednakowym rozkładzie o skończonym czwartym momencie, tzn. $X_n = \xi_n$.

- Szereg ten jest stacjonarny
- Funkcja autokowariancji

$$\text{cov}_X(k) = \text{cov}(X_n, X_{n+k}) = \sigma^2 \mathbb{I}_{k=0}$$

- Funkcja autokorelacji

$$\text{corr}_X(k) = \mathbb{I}_{k=0}.$$





- Funkcja autokowariancji dla szeregu kwadratów $Y_n = X_n^2$

$$\text{cov}_Y(k) = (\gamma - \sigma^4)\mathbb{I}_{k=0},$$

- Funkcja autokorelacji dla szeregu kwadratów

$$\text{corr}_Y(k) = \mathbb{I}_{k=0}.$$

- Jedynie dla $k = 0$ rozpatrywane miary zależności są niezerowe dla $\{X_n\}$ oraz $\{Y_n\}$.



Stacjonarne modele ARMA

DEFINICJA 1 *Proces $\{X_n\} = \{X_n, n = 0, \pm 1, \pm 2, \dots\}$ jest szeregiem ARMA(p, q) ($p, q \in N$), jeśli $\{X_n\}$ jest stacjonarny oraz dla każdego $n \in N$ zachodzi*

$$X_n - b_1 X_{n-1} - \dots - b_p X_{n-p} = \xi_n + a_1 \xi_{n-1} + \dots + a_q \xi_{n-q}, \quad (1.1)$$

gdzie innowacje ξ_n są i.i.d. ze średnią zero oraz $E\xi_n^2 = \sigma^2$.

Równanie (1.1) może być zapisane następująco

$$B(L)X_n = A(L)\xi_n, \quad n = 0, \pm 1, \pm 2, \dots,$$

gdzie $A(z)$ i $B(z)$ są wielomianami odpowiednio stopni q i p

$$A(z) = 1 + a_1z + \dots + a_qz^q,$$

$$B(z) = 1 - b_1z - \dots - b_pz^p,$$

oraz L jest operatorem przesunięcia

$$L^j X_n = X_{n-j}, \quad j = 0, \pm 1, \pm 2, \dots \ .$$

Jeśli wielomiany $A(z)$ i $B(z)$ nie mają wspólnych pierwiastków oraz pierwiastki $B(z)$ są poza dyskiem jednostkowym $\{z : |z| \leq 1\}$, wtedy $\{X_n\}$ jest szeregiem przyczynowym (causal) oraz

$$X_n = \sum_{j=0}^{\infty} \phi_j \xi_{n-j}, \quad \text{a.s.} \quad n = 0, \pm 1, \pm 2, \dots,$$

gdzie

$$\sum_{j=0}^{\infty} \phi_j z^j = \frac{A(z)}{B(z)}.$$

Dla przyczynowego modelu ARMA(p,q) otrzymujemy

$$\text{cov}_X(k) = \text{cov}(X_{n+k}, X_n) = \sigma^2 \sum_{j=0}^{\infty} \phi_j \phi_{j+|k|},$$

$$\text{corr}_X(k) = \text{corr}(X_{n+k}, X_n) = \frac{\sum_{j=0}^{\infty} \phi_j \phi_{j+|k|}}{\sum_{j=0}^{\infty} \phi_j^2},$$

$$\text{cov}_Y(k) = \gamma \sum_{j=0}^{\infty} (\phi_j \phi_{j+|k|})^2 + \sigma^4 \left(\sum_{j=0}^{\infty} \phi_j \phi_{j+|k|} \right)^2$$

$$\text{corr}_Y(k) = \frac{\gamma \sum_{j=0}^{\infty} (\phi_j \phi_{j+|k|})^2 + \sigma^4 \left(\sum_{j=0}^{\infty} \phi_j \phi_{j+|k|} \right)^2}{\gamma \sum_{j=0}^{\infty} \phi_j^4 + \sigma^4 \left(\sum_{j=0}^{\infty} \phi_j^2 \right)^2}.$$

Model AR(1)

AR(1) model (model autoregressji rzędu 1) dany jest wzorem

$$X_n - bX_{n-1} = \xi_n,$$

gdzie ξ_n i.i.d. ze średnią zero. Przy założeniu $0 < |b| < 1$ model AR(1) jest przyczynowy $X_n = \sum_{j=0}^{\infty} b^j \xi_{n-j}$.

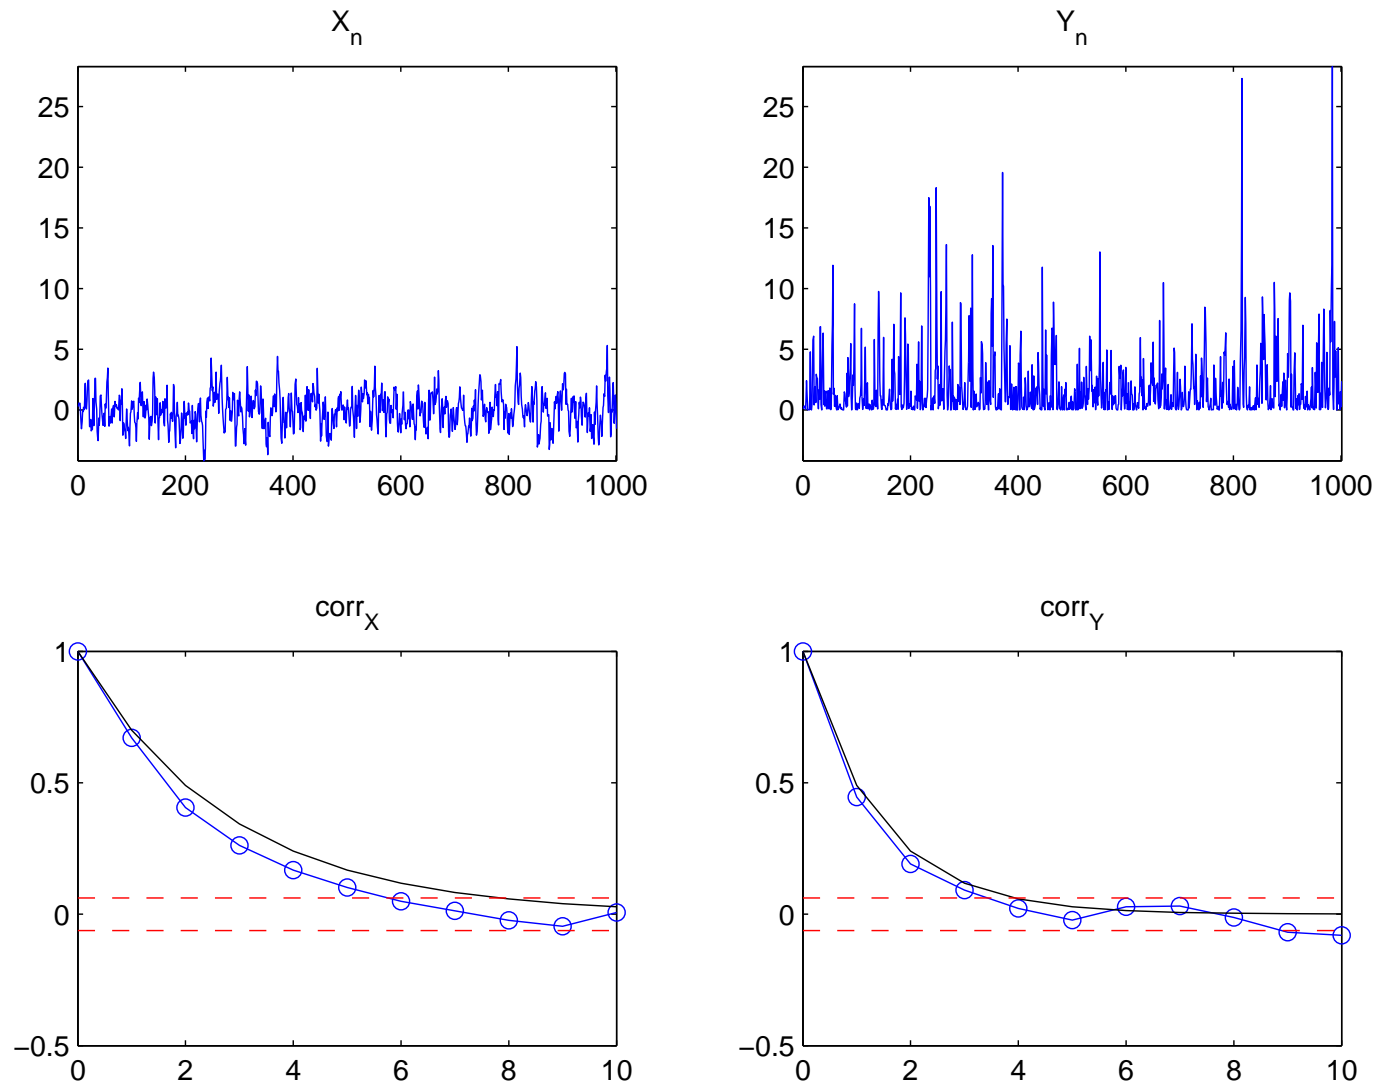
Dla modelu AR(1) otrzymujemy

$$\begin{aligned}\text{cov}_X(k) &= \text{cov}(X_{n+k}, X_n) = \frac{b^k \sigma^2}{1 - b^2}, \\ \text{corr}_X(k) &= \text{corr}(X_{n+k}, X_n) = b^k.\end{aligned}$$

Obie miary eksponencjalnie dążą do zera dla wzrastających wielkości k .

Ponadto

$$\begin{aligned}\text{cov}_Y(k) &= \text{cov}(Y_{n+k}, Y_n) = b^{2k} \left(\frac{\gamma}{1 - b^4} + \frac{\sigma^4}{(1 - b^2)^2} \right), \\ \text{corr}_Y(k) &= \text{corr}(Y_{n+k}, Y_n) = b^{2k}.\end{aligned}$$



Model MA(1)





Model MA(1) (moving average) dany jest wzorem:

$$X_n = \xi_n + a\xi_{n-1},$$

gdzie innowacje ξ_n są i.i.d. ze średnią zero.

Dla modelu MA(1) otrzymujemy

$$\begin{aligned} \text{cov}_X(k) = \text{cov}(X_{n+k}, X_n) &= \sigma^2(\mathbb{I}_{k=0} + a^2\mathbb{I}_{k=0} + a\mathbb{I}_{k=1}) \\ \text{corr}_X(k) = \text{corr}(X_{n+k}, X_n) &= \frac{\mathbb{I}_{k=0} + a^2\mathbb{I}_{k=0} + a\mathbb{I}_{k=1}}{1 + a^2} \\ \text{cov}_Y(k) = \text{cov}(Y_{n+k}, Y_n) &= \begin{cases} \gamma(1 + a^4) + \sigma^4(4a^2 - 1 - a^4) & \text{dla } k = 0, \\ a^2\gamma - \sigma^4a^2 & \text{dla } k = 1, \\ 0 & \text{dla } k > 1. \end{cases} \\ \text{corr}_Y(k) = \text{corr}(Y_{n+k}, Y_n) &= \begin{cases} 1 & \text{dla } k = 0, \\ \frac{a^2\gamma - \sigma^4a^2}{\gamma(1+a^4) + \sigma^4(4a^2 - 1 - a^4)} & \text{dla } k = 1, \\ 0 & \text{dla } k > 1. \end{cases} \end{aligned}$$



Modele ARCH(p)

DEFINICJA 2 *Proces ARCH(q) ($q \in \mathbb{N}$) z gaussowskimi innowacjami jest zdefiniowany następującym równaniem*

$$X_n = \sqrt{h_n} \xi_n, \quad n = 0, 1, 2, \dots, \quad (1.2)$$

$$h_n = \theta + \sum_{j=1}^q \psi_j X_{n-j}^2, \quad (1.3)$$

gdzie innowacje ξ_n są i.i.d. o standardowym rozkładzie normalnym oraz $\theta, \psi_q > 0$, $\psi_j \geq 0$, $j = 1, \dots, q - 1$.

Model ARCH(2)

Model ARCH(2) z gaussowskimi innowacjami dany jest wzorem

$$X_n = \sqrt{h_n} \xi_n$$

$$h_n = \theta + \psi_1 X_{n-1}^2 + \psi_2 X_{n-2}^2.$$

W modelu tym warunkiem gwarantującym istnienie czwartego momentu jest

$$\psi_2 + 3\psi_1^2 + 3\psi_2^2 + 3\psi_1^2\psi_2 - 3\psi_2^3 < 1.$$





Dla modelu ARCH(2) z gaussowskimi innowacjami otrzymujemy

$$\begin{aligned} \text{cov}_X(k) = \text{cov}(X_{n+k}, X_n) &= \frac{\sigma^2 \theta}{1 - \sigma^2(\psi_1 + \psi_2)} \mathbb{I}_{k=0} \\ \text{corr}_X(k) = \text{corr}(X_{n+k}, X_n) &= \mathbb{I}_{k=0} \\ \text{corr}_Y(k) = \text{corr}(Y_{n+k}, Y_n) &= \begin{cases} 1 & \text{dla } k = 0, \\ \frac{\psi_1}{1 - \psi_2} & \text{dla } k = 1, \\ \frac{\psi_2 + \psi_1^2 - \psi_2^2}{1 - \psi_2} & \text{dla } k = 2, \\ \psi_1 \text{corr}(k - 1) + \psi_2 \text{corr}(k - 2) & \text{dla } k > 2. \end{cases} \end{aligned}$$

W ogólnym przypadku

$$\text{corr}_Y(k) = \sum_{i=1}^{\max(p,q)} (\psi_i + \phi_i) \text{corr}(k - 1), \quad k > p,$$

gdzie $\psi_i = 0$ for $i > q$ oraz $\phi_i = 0$ dla $j > p$.



Modele GARCH(p,q)

DEFINICJA 3 *Proces GARCH(p,q) ($p, q \in N$) z gaussowskimi innowacjami zdefiniowany jest następująco*

$$\begin{aligned} X_n &= \sqrt{h_n} \xi_n, \quad n = 0, 1, 2, \dots, \\ h_n &= \theta + \sum_{j=1}^p \phi_j h_{n-j} + \sum_{j=1}^q \psi_j X_{n-j}^2, \end{aligned}$$

gdzie innowacje ξ_n są i.i.d. o standardowym rozkładzie normalnym oraz $\theta, \phi_p, \psi_q > 0$, $\phi_j \geq 0$, $j = 1, \dots, p-1$, $\psi_j \geq 0$, $j = 1, \dots, q-1$.

Model GARCH(1,1)

Model GARCH(1,1) z gaussowskimi innowacjami dany jest wzorem

$$X_n = \sqrt{h_n} \xi_n, \quad n = 0, 1, 2, \dots,$$

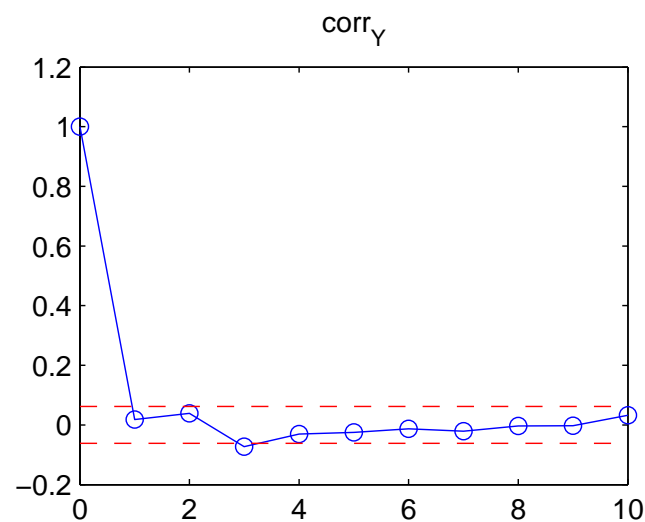



$$h_n = \theta + \phi h_{n-1} + \psi X_{n-1}^2.$$

W modelu tym warunkiem gwarantującym istnienie czwartego momentu jest

$$3\psi^2 + 2\psi\phi + \phi^2 < 1.$$

Dla modelu GARCH(1,1) z gaussowskimi innowacjami otrzymujemy

$$\begin{aligned}\text{cov}_X(k) = \text{cov}(X_{n+k}, X_n) &= \frac{\sigma^2\theta}{1 - \phi - \sigma^2\psi} \mathbb{I}_{k=0} \\ \text{corr}_X(k) = \text{corr}(X_{n+k}, X_n) &= \mathbb{I}_{k=0} \\ \text{corr}_Y(k) = \text{corr}(Y_{n+k}, Y_n) &= \begin{cases} 1 & \text{dla } k = 0, \\ \frac{\psi(1-\psi\phi-\pi^2)}{1-2\psi\phi-\phi^2} & \text{dla } k = 1, \\ (\psi + \phi)^{k-1} \text{corr}(1) & \text{dla } k > 1. \end{cases}\end{aligned}$$



Podsumowanie

- Funkcje autokowariancji i autokorelacji są dobrymi narzędziami wykorzystywanymi w analizie danych rzeczywistych
- Ich w miarę prosta postać powoduje że są to narzędzia powszechnie wykorzystywane w praktyce
- Przy ich użyciu można zweryfikować hipotezę odnośnie wyboru odpowiedniego modelu
- Konieczne jest jednak badanie nie tylko miar zależności danego szeregu, ale również szeregu utworzonego z kwadratów obserwowanych wartości.

Literatura

- [1]T. Bollerslev ”On the correlation structure for the generalized autoregressive conditional heteroskedastic process” Journal of Time Series Analysis, Vol. 9, No 2, 1988.
- [2]P.J. Brockwell and R.A. Davis ”Introduction to Time Series and Forecasting”, Springer-Verlag, New York,second edition, 2002.
- [3]A. Milhoj ”The Moment Structure of ARCH processes” Scandinavian Journal of Statistics 12, 281-292, 1985.