

Modele ARMA

- Ważną klasę modeli dynamicznych stanowią modele $ARMA(p, q)$

- Ważną klasę modeli dynamicznych stanowią modele $ARMA(p, q)$
- Modele tej klasy są modelami ateoretycznymi

- Ważną klasę modeli dynamicznych stanowią modele $ARMA(p, q)$
- Modele tej klasy są modelami ateoretycznymi
- Model zjawiska budowany jest w oparciu o statystyczne właściwości danych

- Ważną klasę modeli dynamicznych stanowią modele $ARMA(p, q)$
- Modele tej klasy są modelami ateoretycznymi
- Model zjawiska budowany jest w oparciu o statystyczne właściwości danych
- Modele ARMA są użytecznym narzędziem prognostycznym

- Model ARMA składa się z dwóch części:

$$y_t = \underbrace{\alpha_1 y_{t-1} + \dots + \alpha_p y_{t-p}}_{AR} + \underbrace{\mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}}_{MA}$$

- model autoregresyjny

$$y_t = \mu + \alpha_1 y_{t-1} + \alpha_2 y_{t-2} + \dots + \alpha_p y_{t-p}$$

- model autoregresyjny

$$y_t = \mu + \alpha_1 y_{t-1} + \alpha_2 y_{t-2} + \dots + \alpha_p y_{t-p}$$

- model średniej ruchomej

$$y_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}$$

$$E(\varepsilon_t) = 0 \quad \text{var}(\varepsilon_t) = \sigma^2 \quad E(\varepsilon_t, \varepsilon_s) = 0 \quad \forall t \neq s$$

- składniki ε_t nazywa się innowacjami

- składniki ε_t nazywa się innowacjami
- część MA można traktować jako składnik losowy o rozbudowanej strukturze

$$u_t = \varepsilon_t + \theta_1\varepsilon_{t-1} + \theta_2\varepsilon_{t-2} + \dots + \theta_q\varepsilon_{t-q}$$

- składniki ε_t nazywa się innowacjami
- część MA można traktować jako składnik losowy o rozbudowanej strukturze

$$u_t = \varepsilon_t + \theta_1\varepsilon_{t-1} + \theta_2\varepsilon_{t-2} + \dots + \theta_q\varepsilon_{t-q}$$

- w takim przypadku podlega on zjawisku autokorelacji

- składniki ε_t nazywa się innowacjami
- część MA można traktować jako składnik losowy o rozbudowanej strukturze

$$u_t = \varepsilon_t + \theta_1\varepsilon_{t-1} + \theta_2\varepsilon_{t-2} + \dots + \theta_q\varepsilon_{t-q}$$

- w takim przypadku podlega on zjawisku autokorelacji
- model ARMA można wówczas przedstawić jako

$$y_t = \mu + \alpha_1y_{t-1} + \alpha_2y_{t-2} + \dots + \alpha_p y_{t-p} + u_t \quad (1)$$

- Jeśli model nie ma części autoregresyjnej to można jego parametry oszacować MNK

- Jeśli model nie ma części autoregresyjnej to można jego parametry oszacować MNK
- Model (1) nie spełnia założeń KRML

- Jeśli model nie ma części autoregresyjnej to można jego parametry oszacować MNK
- Model (1) nie spełnia założeń KRML
- Estymatory MNK nie są zgodne

- Jeśli model nie ma części autoregresyjnej to można jego parametry oszacować MNK
- Model (1) nie spełnia założeń KRML
- Estymatory MNK nie są zgodne
- Oszacowania uzyskuje się wykorzystując MNW lub Nieliniową MNK

- Jeśli model nie ma części autoregresyjnej to można jego parametry oszacować MNK
- Model (1) nie spełnia założeń KRML
- Estymatory MNK nie są zgodne
- Oszacowania uzyskuje się wykorzystując MNW lub Nieliniową MNK
- W przypadku rozbudowanej postaci modelu obliczenia są czasochłonne i źle numerycznie uwarunkowane

- Jeśli model nie ma części autoregresyjnej to można jego parametry oszacować MNK
- Model (1) nie spełnia założeń KRML
- Estymatory MNK nie są zgodne
- Oszacowania uzyskuje się wykorzystując MNW lub Nieliniową MNK
- W przypadku rozbudowanej postaci modelu obliczenia są czasochłonne i źle numerycznie uwarunkowane
- Jest to szczególnie duży problem dla krótkich szeregów

- Jeśli model nie ma części autoregresyjnej to można jego parametry oszacować MNK
- Model (1) nie spełnia założeń KRML
- Estymatory MNK nie są zgodne
- Oszacowania uzyskuje się wykorzystując MNW lub Nieliniową MNK
- W przypadku rozbudowanej postaci modelu obliczenia są czasochłonne i źle numerycznie uwarunkowane
- Jest to szczególnie duży problem dla krótkich szeregów
- Do testowania hipotez można użyć testów W, LR, LM

- Przed estymacją parametrów należy ustalić rząd procesów

- Przed estymacją parametrów należy ustalić rząd procesów
- Metoda Boxa-Jenkinsa

- Przed estymacją parametrów należy ustalić rząd procesów
- Metoda Boxa-Jenkinsa
- Metoda od ogólnego do szczegółowego

- Przed estymacją parametrów należy ustalić rząd procesów
- Metoda Boxa-Jenkinsa
- Metoda od ogólnego do szczegółowego
- Kryteria informacyjne

- Jeżeli procesy są prawidłowo ustalone to reszty są białym szumem

- Jeżeli procesy są prawidłowo ustalone to reszty są białym szumem
- testem niezależności reszt jest statystyka Ljung-Boxa

$$Q = n(n+2) \sum_{k=1}^m \frac{\hat{\rho}_k}{T-k} \xrightarrow{D} \chi_{m-p-q}^2$$

gdzie

$$\hat{\rho}_k = \frac{(T-k) \sum (y - \bar{y}) \sum (y_{t-k} - \bar{y})}{T^{-1} \sum (y - \bar{y})^2}$$

- Funkcja autokowariancji pokazuje zależność między y_t a poprzednimi wartościami

- Funkcja autokowariancji pokazuje zależność między y_t a poprzednimi wartościami
- Dla szeregu stacjonarnego wartości zależą wyłącznie od odległości między obserwacjami

$$E(y_t - E(y_t))(y_{t-k} - E(y_{t-k})) = \gamma_k \quad k = 0, 1, 2, \dots$$

- Funkcja autokowariancji pokazuje zależność między y_t a poprzednimi wartościami
- Dla szeregu stacjonarnego wartości zależą wyłącznie od odległości między obserwacjami

$$E(y_t - E(y_t))(y_{t-k} - E(y_{t-k})) = \gamma_k \quad k = 0, 1, 2, \dots$$

- autokowariancje są nieunormowane

- Funkcja autokowariancji pokazuje zależność między y_t a poprzednimi wartościami
- Dla szeregu stacjonarnego wartości zależą wyłącznie od odległości między obserwacjami

$$E(y_t - E(y_t))(y_{t-k} - E(y_{t-k})) = \gamma_k \quad k = 0, 1, 2, \dots$$

- autokowariancje są nieunormowane
- Funkcja autokorelacji (ACF) (**A**utocorrelation **F**unction)

$$\rho_k = \frac{\text{cov}(y_t, y_{t-k})}{\text{var}(y_t)}$$

- Funkcja autokowariancji pokazuje zależność między y_t a poprzednimi wartościami
- Dla szeregu stacjonarnego wartości zależą wyłącznie od odległości między obserwacjami

$$E(y_t - E(y_t))(y_{t-k} - E(y_{t-k})) = \gamma_k \quad k = 0, 1, 2, \dots$$

- autokowariancje są nieunormowane
- Funkcja autokorelacji (ACF) (**A**utocorrelation **F**unction)

$$\rho_k = \frac{\text{cov}(y_t, y_{t-k})}{\text{var}(y_t)}$$

- $\rho_k \in [-1, 1]$


- Funkcja autokowariancji pokazuje zależność między y_t a poprzednimi wartościami
- Dla szeregu stacjonarnego wartości zależą wyłącznie od odległości między obserwacjami

$$E(y_t - E(y_t))(y_{t-k} - E(y_{t-k})) = \gamma_k \quad k = 0, 1, 2, \dots$$

- autokowariancje są nieunormowane
- Funkcja autokorelacji (ACF) (**A**utocorrelation **F**unction)

$$\rho_k = \frac{\text{cov}(y_t, y_{t-k})}{\text{var}(y_t)}$$

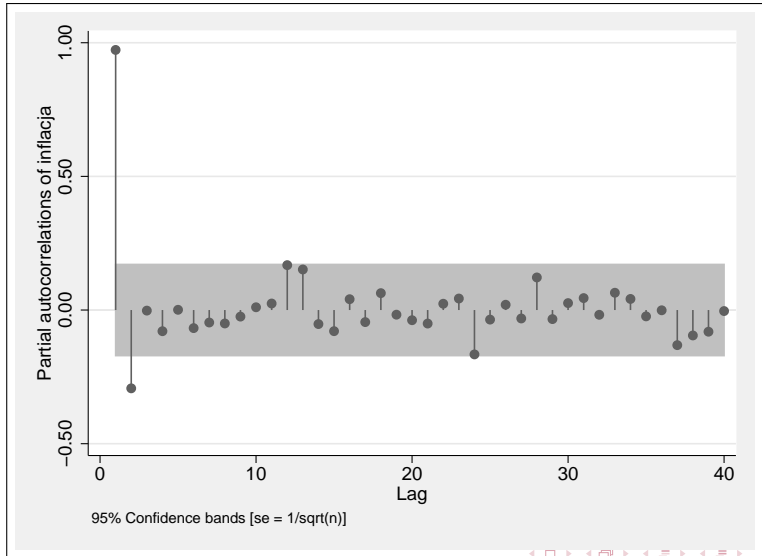
- $\rho_k \in [-1, 1]$
- $\rho_k = \rho_{-k}$



- Funkcja cząstkowej autokorelacji (**P**artial **A**utocorrelation **F**unction) pokazuje zależność między y_t a poprzednimi wartościami, pomijając wpływ pośrednich opóźnień

- Funkcja cząstkowej autokorelacji (**P**artial **A**utocorrelation **F**unction) pokazuje zależność między y_t a poprzednimi wartościami, pomijając wpływ pośrednich opóźnień
- Liczbowo jest równa oszacowaniu współczynnika ρ_k w modelu:

$$y_t = \mu + \rho_1 y_{t-1} + \dots + \rho_k y_{t-k} + \varepsilon_t$$



LAG	AC	PAC	Q	Prob>Q	-1	0	1	-1	0	1
					[Autocorrelation]			[Partial Autocor]		
1	0.9731	0.9731	127.85	0.0000	-----			-----		
2	0.9395	-0.2928	247.95	0.0000	-----			--		
3	0.9062	-0.0021	360.56	0.0000	-----					
4	0.8727	-0.0791	465.8	0.0000	-----					
5	0.8383	0.0009	563.66	0.0000	-----					
6	0.8041	-0.0675	654.44	0.0000	-----					
7	0.7708	-0.0466	738.5	0.0000	-----					
8	0.7365	-0.0502	815.87	0.0000	-----					
9	0.7041	-0.0245	887.16	0.0000	-----					
10	0.6721	0.0104	952.64	0.0000	-----					
11	0.6416	0.0245	1012.8	0.0000	-----					
12	0.6129	0.1681	1068.2	0.0000	-----					-

- Polega na graficznej analizie przebiegu funkcji ACF i PACF



- Polega na graficznej analizie przebiegu funkcji ACF i PACF
- Wielkość p oraz q można oszacować na podstawie przebiegu funkcji ACF i PACF

- Polega na graficznej analizie przebiegu funkcji ACF i PACF
- Wielkość p oraz q można oszacować na podstawie przebiegu funkcji ACF i PACF
- Urywająca się funkcja ACF wskazuje na rząd procesu MA

- Polega na graficznej analizie przebiegu funkcji ACF i PACF
- Wielkość p oraz q można oszacować na podstawie przebiegu funkcji ACF i PACF
- Urywająca się funkcja ACF wskazuje na rząd procesu MA
- Urywająca się funkcja PACF wskazuje na rząd procesu AR

- Polega na graficznej analizie przebiegu funkcji ACF i PACF
- Wielkość p oraz q można oszacować na podstawie przebiegu funkcji ACF i PACF
- Urywająca się funkcja ACF wskazuje na rząd procesu MA
- Urywająca się funkcja PACF wskazuje na rząd procesu AR
- Jeżeli obie funkcje maleją bardzo powoli należy szereg zróżnicować

- Polega na graficznej analizie przebiegu funkcji ACF i PACF
- Wielkość p oraz q można oszacować na podstawie przebiegu funkcji ACF i PACF
- Urywająca się funkcja ACF wskazuje na rząd procesu MA
- Urywająca się funkcja PACF wskazuje na rząd procesu AR
- Jeżeli obie funkcje maleją bardzo powoli należy szereg zróżnicować
- Regularne skoki mogą wskazywać na obecność sezonowości



- W praktyce wykresy są trudne do jednoznacznej interpretacji

- W praktyce wykresy są trudne do jednoznacznej interpretacji
- Dodatkowy problemem jest brak zgodności oszacowań PACF

- W praktyce wykresy są trudne do jednoznacznej interpretacji
- Dodatkowy problemem jest brak zgodności oszacowań PACF
- Wskazane jest posłużenie się formalnymi metodami

- W praktyce wykresy są trudne do jednoznacznej interpretacji
- Dodatkowy problemem jest brak zgodności oszacowań PACF
- Wskazane jest posłużenie się formalnymi metodami
- Celem jest wybór modelu o małej liczbie parametrów

Przykład

Porównanie statystyk różnych modeli

Kryterium	ARMA(2,0)	ARMA(2,1)	ARMA(1,1)	ARMA(2,2)
AIC	102.2005	127.7031	105.7842	107.6906
BIC	113.7317	142.1171	117.3154	122.1046
LL	-47.10025	-58.85155	-48.89209	-48.84532

- Powszechność sezonowości

- Powszechność sezonowości
- Brak jej uwzględnienia może powodować autokorelację

- Powszechność sezonowości
- Brak jej uwzględnienia może powodować autokorelację
- Zmienne zero-jedynkowe

- Powszechność sezonowości
- Brak jej uwzględnienia może powodować autokorelację
- Zmienne zero-jedynkowe
- Sezonowe wyrównywanie szeregów (X11, TRAMO-SEATS)

- Powszechność sezonowości
- Brak jej uwzględnienia może powodować autokorelację
- Zmienne zero-jedynkowe
- Sezonowe wyrównywanie szeregów (X11, TRAMO-SEATS)
- Różnicowanie sezonowe

Przykład

Porównanie statystyk różnych modeli

Kryterium	SARMA(2,0)	SARMA(1,1)	SARMA(1,0)
AIC	182.0381	182.9793	189.6979
BIC	193.1881	194.1292	198.0603
LL	-87.01905	-87.48964	-91.84893

- Model ARMA może być wykorzystany jako narzędzie prognostyczne

- Model ARMA może być wykorzystany jako narzędzie prognostyczne
- Wartość w kolejnym okresie zależy wyłącznie od znanych wartości

$$y_{T+1} = \mu + \alpha_1 y_T + \dots + \alpha_p y_{T-p+1} + \varepsilon_{T+1} + \theta_1 \varepsilon_T + \dots + \theta_q \varepsilon_{T-q+1}$$

gdzie T oznacza ostatnią obserwację w próbie

- Model ARMA może być wykorzystany jako narzędzie prognostyczne
- Wartość w kolejnym okresie zależy wyłącznie od znanych wartości

$$y_{T+1} = \mu + \alpha_1 y_T + \dots + \alpha_p y_{T-p+1} + \varepsilon_{T+1} + \theta_1 \varepsilon_T + \dots + \theta_q \varepsilon_{T-q+1}$$

gdzie T oznacza ostatnią obserwację w próbie

- Zakłada się że reszty dla przyszłych okresów są równe 0

- Model ARMA może być wykorzystany jako narzędzie prognostyczne
- Wartość w kolejnym okresie zależy wyłącznie od znanych wartości

$$y_{T+1} = \mu + \alpha_1 y_T + \dots + \alpha_p y_{T-p+1} + \varepsilon_{T+1} + \theta_1 \varepsilon_T + \dots + \theta_q \varepsilon_{T-q+1}$$

gdzie T oznacza ostatnią obserwację w próbie

- Zakłada się że reszty dla przyszłych okresów są równe 0
- Prognoza y_{T+1} jest równa

$$y_{\hat{T}+1} = \hat{\mu} + \alpha_1 \hat{y}_T + \dots + \alpha_p y_{\hat{T}-p+1} + \theta_1 e_T + \dots + \theta_q e_{T-q+1}$$

- Model ARMA może być wykorzystany jako narzędzie prognostyczne
- Wartość w kolejnym okresie zależy wyłącznie od znanych wartości

$$y_{T+1} = \mu + \alpha_1 y_T + \dots + \alpha_p y_{T-p+1} + \varepsilon_{T+1} + \theta_1 \varepsilon_T + \dots + \theta_q \varepsilon_{T-q+1}$$

gdzie T oznacza ostatnią obserwację w próbie

- Zakłada się że reszty dla przyszłych okresów są równe 0
- Prognoza y_{T+1} jest równa

$$y_{\hat{T}+1} = \hat{\mu} + \alpha_1 \hat{y}_T + \dots + \alpha_p y_{\hat{T}-p+1} + \theta_1 e_T + \dots + \theta_q e_{T-q+1}$$

- prognozy oblicza się rekurencyjnie

- sensowne prognozy z modelu ARMA najwyżej na $\max\{p, q\}$ okresów

- sensowne prognozy z modelu ARMA najwyżej na $\max\{p, q\}$ okresów
- dla kolejnych okresów przyjmują wartość

$$y^* = \frac{\mu}{1 - \sum \alpha_j}$$

ARIMA regression

Sample: 1998m1 - 2008m12

Number of obs = 132

Wald chi2(2) = 25062.40

Log likelihood = -47.10025

Prob > chi2 = 0.0000

```

-----
            |               OPG
inflacja |      Coef.  Std. Err.      z    P>|z|    [95% Conf. Interval]
-----+-----
inflacja |
   _cons | 8.235239   4.280912    1.92  0.054   - .155194    16.62567
-----+-----
ARMA      |
   ar    |
   L1.   | 1.409584   .0487239   28.93  0.000   1.314087    1.505081
   L2.   | -.4130118   .04851    -8.51  0.000  - .5080896   -.317934
-----+-----
   /sigma | .338333   .0105082   32.20  0.000   .3177374    .3589287
-----
  
```

- Prognoza na 1 okres naprzód

$$y_{T+1} = \alpha_1 y_T + \alpha_2 y_{T-1} = 1.41 * 4.53 - 0.41 * 4.67 = 4.47$$

- Prognoza na 1 okres naprzód

$$y_{T+1} = \alpha_1 y_T + \alpha_2 y_{T-1} = 1.41 * 4.53 - 0.41 * 4.67 = 4.47$$

- Prognoza na 2 okresy naprzód

$$y_{T+2} = \alpha_1 y_{\hat{T}+1} + \alpha_2 y_T = 1.41 * 4.47 - 0.41 * 4.53 = 4.45$$

- Prognoza na 1 okres naprzód

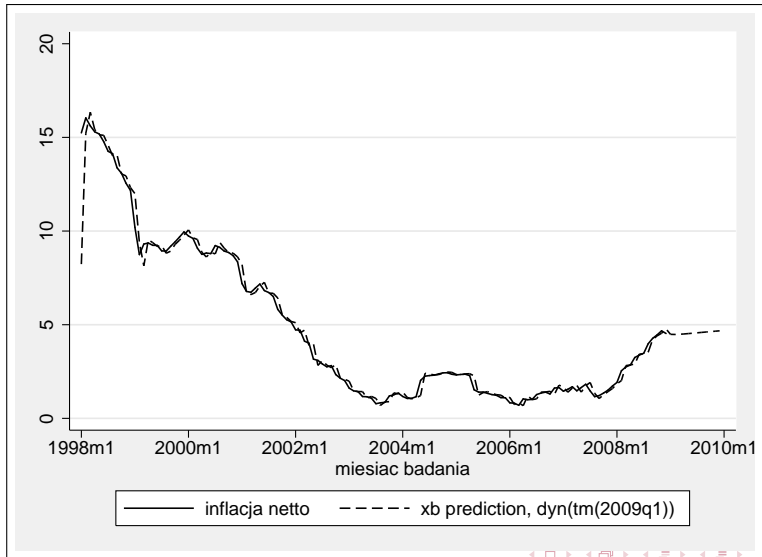
$$y_{T+1} = \alpha_1 y_T + \alpha_2 y_{T-1} = 1.41 * 4.53 - 0.41 * 4.67 = 4.47$$

- Prognoza na 2 okresy naprzód

$$y_{T+2} = \alpha_1 y_{\hat{T}+1} + \alpha_2 y_T = 1.41 * 4.47 - 0.41 * 4.53 = 4.45$$

- Prognoza na 3 okresy naprzód

$$y_{T+3} = \alpha_1 y_{\hat{T}+2} + \alpha_2 y_{\hat{T}+1} = 1.41 * 4.45 - 0.41 * 4.47 = 4.44$$



- Ze względu na ateoretyczną naturę procesu ARMA, czasem wykorzystuje się go w połączeniu z innym modelem

- Ze względu na ateoretyczną naturę procesu ARMA, czasem wykorzystuje się go w połączeniu z innym modelem
- Wówczas ma on postać

$$y_t = X_t\beta + u \quad u_t \sim ARMA(p, q)$$

```
ARIMA regression           Number of obs       =       131
Sample: 1998m2 - 2008m12   Wald chi2(4)        =    19031.20
Log likelihood = -38.16698  Prob > chi2         =       0.0000
```

```
-----+-----
            |                OPG
inflacja |      Coef.   Std. Err.   z   P>|z|   [95% Conf. Interval]
-----+-----
stopa |
  --. |  -.2230583   .1066216  -2.09  0.036   -.4320329   -.0140838
  L1. |  -.1902509   .1413774  -1.35  0.178   -.4673454   .0868436
  _cons |   14.29238   5.359286   2.67  0.008    3.78837   24.79638
-----+-----
```

```
ARMA  ar |
  L1. |   1.386976   .06362   21.80  0.000    1.262284   1.511669
  L2. |  -.3891893   .0640723  -6.07  0.000   -.5147686   -.26361
-----+-----
```

```
/sigma |   .3163894   .0122967  25.73  0.000    .2922883   .3404905
=====+=====
```

```
Model |  Obs   ll(null)  ll(model)   df       AIC       BIC
-----+-----
ARMA  |   131      .  -38.16698    6    88.33396   105.5851
-----+-----
```