

SZEREGI CZASOWE

Przekształcenia szeregu czasowego Zagadnienie stacjonarności Modele ARMA

Marzena Nowakowska

**Wydział Zarządzania i Modelowania Komputerowego
Politechnika Świętokrzyska**

Budynek C, p. 3.21

spimn@tu.kielce.pl

Przekształcenia wstępne

Cel

Mają więc na celu taką transformację szeregu wejściowego, aby wynik był szeregiem stacjonarnym.

Do podstawowych przekształceń zalicza się:

- transformacje potęgowe, w szczególności Boxa-Coxa, w celu eliminowania niejednorodności wariancji,
- eliminację trendu i sezonowości poprzez różnicowanie, jednokrotne lub wielokrotne z opóźnieniem 1 lub opóźnieniem sezonowym,
- eliminację trendu i sezonowości poprzez dekompozycję w celu uzyskania składnika losowego (*to już było*)

Transformacja Boxa-Coxa

$$f_{\lambda}(x) = \begin{cases} \frac{x^{\lambda} - 1}{\lambda} & \text{dla } \lambda \neq 0 \\ \ln(x) & \text{dla } \lambda = 0 \end{cases}$$

Transformację można stosować tylko w przypadku szeregu, którego wszystkie wartości są większe od zera.

Przesłanki stosowania transformacji:

- występowanie wzrostu lub spadku amplitudy wahań sezonowych (rosnąca lub malejąca amplituda wraz z poziomem szeregu)
- niejednorodna zmienność danych w kolejnych wartościach szeregu,
- duży wpływ obserwacji odstających
- dążenie do uzyskania rozkładów zbliżonych do normalnego, aby działały metody wymagające normalności

Jeżeli zastosuje się transformację Boxa-Coxa, to prognozy i odpowiadające im przedziały predykcyjne są tworzone dla danych przekształconych. Aby uzyskać dla danych pierwotnych, należy zastosować transformację odwrotną:

$$\tilde{f}_{\lambda}(x) = \begin{cases} (x \cdot \lambda + 1)^{1/\lambda} & \text{dla } \lambda \neq 0 \\ \exp(x) & \text{dla } \lambda = 0 \end{cases}$$

Różnicowanie

Różnicowanie z opóźnieniem 1 szeregu X_t definiuje się jako różnicę:

$$\nabla X_t = X_t - X_{t-1} = (1 - B)X_t$$

gdzie B jest operatorem przesunięcia wstecz zdefiniowanym jako: $BX_t = X_{t-1}$

Różnicowanie d -krotne szeregu X_t z opóźnieniem 1 definiuje się jako różnicę (różnicowanie rzędu d):

$$\nabla^d X_t = \nabla(\nabla^{d-1} X_t) = \nabla^{d-1} X_t - \nabla^{d-1} X_{t-1} \quad \text{dla } d \geq 1 \quad \text{oraz} \quad \nabla^0 X_t = X_t$$

Operator d -krotnego różnicowania z opóźnieniem 1 zapisuje jako:

$$\nabla^d = (1 - B)^d$$

Jeżeli po d -krotnym różnicowaniu z opóźnieniem 1 szeregu niestacjonarnego otrzymuje się szereg stacjonarny, to szereg pierwotny jest szeregiem zintegrowanym w stopniu d , co zapisuje się jako: $X_t \sim I(d)$, przy czym d jest najmniejszą liczbą całkowitą, dla której jest stacjonarnie.

Różnicowanie z opóźnieniem (sezonowym) s szeregu X_t definiuje się jako różnicę:

$$\nabla_s X_t = X_t - X_{t-s} = (1 - B^s)X_t$$

gdzie $B^s X_t = B(B^{s-1} X_t) = X_{t-s}$ jest operatorem różnicowania z opóźnieniem s (operator różnicowania sezonowego).

Własności różnicowania

- Różnicowanie z opóźnieniem 1 usuwa z szeregu trend liniowy, jeżeli taki występuje.
- Wykonanie d -krotnego różnicowania z opóźnieniem 1 powoduje, że z danych zostaje wyeliminowany wielomian stopnia d , jeżeli taki występuje.
- Różnicowanie z opóźnieniem s usuwa z szeregu sezonowość o okresie s , jeżeli taki występował. Dodatkowo usunięty jest też liniowy, jeżeli taki istniał.
- Niekiedy należy zastosować więcej niż jedną operację różnicowania aby uzyskać postać stacjonarną szeregu.
- Operację różnicowania z opóźnieniem s można stosować kilkakrotnie (d -krotnie). Można też stosować kolejno operacje różnicowania dla różnych opóźnień.
- Operatory różnicowania są przemienne. To oznacza, że można najpierw wykonać operację różnicowania sezonowego a następnie różnicować z opóźnieniem 1 lub odwrotnie.

Funkcja **BoxCox(x, lambda) # forecast**

Zwraca transformację zmiennej wejściowej przy użyciu transformacji Boxa-Coxa. *InvBoxCox()* odwraca transformację. Wartości ujemne funkcja przekształca zgodnie z zależnością:

$$f_{\lambda}(x) = \begin{cases} \frac{\text{sign}(x)|x|^{\lambda} - 1}{\lambda} & \text{dla } \lambda \neq 0 \\ \ln(x) & \text{dla } \lambda = 0 \end{cases}$$

x Wektor numeryczny lub szereg czasowy klasy *ts*.

lambda Parametr transformacji.

Funkcja `BoxCox.lambda(x, method = c("guerrero", "loglik"), lower = -1, upper = 2)` zwraca liczbę wskazującą parametr transformacji Boxa-Coxa.

Funkcja **diff(x, ...)**

Zwraca zróżnicowany szereg wielokrotnie z podanym opóźnieniem.

x Wektor numeryczny lub szereg czasowy klasy *ts*.

lag Wartość całkowita określająca wartość opóźnienia, domyślnie: 1.

differences Krotność (rzęd) różnicowania; domyślnie: 1.

Transformacje w R - przykład

```
# Szereg pbk to produkt krajowy brutto Polski

# Można również wczytać plik tekstowy z menu Import Dataset
# pod tytułem zakładki Environment
# uwaga przy czytaniu za pomocą instrukcji read.csv trzeba dać znać,
# czy pierwszy wiersz zawiera nazwy kolumn (domyślnie jest przyjmowane, że zawiera)

pkb <- ts(read.csv("c:/R/SzeregiCzasowe/Dane/pkb.txt", header=FALSE), start=1995, frequency=4)

# Transformacja Boxa-Coxa
pkb.sqrt<- BoxCox(pkb, lambda = 0.5)
pkb.log<- BoxCox(pkb, lambda = 0)
par(mfrow=c(3,1))
plot(pkb, main="Dane oryginalne")
plot(pkb.sqrt, main="Box-Cox, lambda=0.5")
plot(pkb.log, main="Box-Cox, lambda=0")
library(forecast)
lambda <- BoxCox.lambda(pkb, method = "loglike") # wyznaczenie wartości lambda, por. opis funkcji
pkb.est<- BoxCox(pkb, lambda = BoxCox.lambda(pkb, method = "loglik"))
plot(pkb.log, main="Box-Cox, lambda=est")

# Różnicowanie z opóźnieniem prostym (domyślna wartość d=1)
library(expsmooth) # dane usgdp
library(forecast)
data(usgdp)
tsdisplay(usgdp)
usgdp.diff <- diff(usgdp)
tsdisplay(usgdp.diff)

# Różnicowanie z opóźnieniem sezonowym, d=12 (s=12)
library(forecast)
AirPass.diff12 <- diff(AirPassengers, lag=12, differences=1)
tsdisplay(AirPassengers)
tsdisplay(AirPass.diff12)
par(mfcol=c(1,2))
plot(AirPassengers); plot(AirPass.diff12)
AirPass.diff12.diff_x <- diff(AirPass.diff12, lag=1, differences=3) # demo różnic dla rzędów: 1-3
tsdisplay(AirPass.diff12.diff_x)
```

Stacjonarność szeregu

W szeregu niestacjonarnym mogą wystąpić zjawiska (łącznie lub pojedynczo):

- średnia zamiast utrzymywać się na stałym poziomie, rośnie wraz z czasem,
- z roku na rok wzrasta różnica między rocznymi minimami i maksimami
- proces wykazuje silną sezonowość.

Stosowanie testów sprawdzających, czy dany proces jest stacjonarny nazywa się weryfikacją hipotezy stacjonarności szeregu.

Test pierwiastka jednorodnego (*unit root test*):

Jeżeli pierwiastkiem równania (wielomianu) charakterystycznego opisującego proces stochastyczny, zapisanego w postaci autoregresyjnej, jest jedynka, to proces nie jest to stacjonarny (i zintegrowany w stopniu pierwszym). W przypadku, gdy pierwiastki są do modułu różne od 1, to proces jest stacjonarny.

Hipoteza zerowa zakłada obecność pierwiastka jednostkowego - niestacjonarność procesu:

H₀: Szereg czasowy jest niestacjonarny

Najpopularniejszym narzędziem do badania stacjonarności szeregu (na podstawie testu pierwiastka jednorodnego) jest test (raczej rzadko) DF lub **rozszerzony test Dickeya-Fullera (ADF) (najczęściej)**.

Uwagi nt. testu ADF

Istnieją trzy typy szeregów czasowych, według których można obliczyć statystyki testowe testu Dickey-Fullera.

- 1) zerowa średnia — brak przecięcia. Szereg czasowy jest błędzeniem losowym bez trendu i bez dryfu
- 2) pojedyncza średnia — obejmuje wyraz wolny. Szereg czasowy jest błędzeniem losowym bez trendu i z dryfem
- 3) punkt przecięcia i trend. Szereg czasowy jest błędzeniem losowym z trendem i z dryfem

Testy stacjonarności nie rozwiązują definitywnie zagadnienia stacjonarności:

- występują problemy z odróżnieniem pierwiastka jednostkowego od pierwiastków niewiele różniących się od jedynki,
- w przypadku małej próby, wnioski mogą być fałszywe,
- większość testów nie sprawdza wszystkich czynników mogących mieć wpływ na niestacjonarność.

Test stacjonarności DF/ADF szeregu czasowego sprowadza się do sprawdzenia jego stopnia zintegrowania.

Funkcja `adf.test(x, ...)` biblioteka `aTSA`

Funkcja dla zwraca wyniki testu ADF trzech typów szeregów (jak podano wcześniej).

- `x` Wektor numeryczny lub szereg czasowy klasy `ts`.
- `nlag` Wielkość maksymalnego opóźnienia, do którego jest wykonane testowanie.
- `output` Flaga informująca, czy wyniki mają być wyprowadzone do konsoli.

Przykład

```
library(aTSA) # test Dickeya-Fullera
library(forecast) # funkcje autokorelacji

x <- as.ts(rnorm(200)) # biały szum, stacjonarny; H0 odrzucone
par(mfrow=c(3,1))
plot(x)
Acf(x, lag.max=30)
Pacf(x, lag.max=30)
adf.test(x, nlag = 4)

y <- as.ts(cumsum(x)) # błądzenie losowe, niestacjonarny; H0 nieodrzucone
par(mfrow=c(3,1))
plot(y)
Acf(y, lag.max=30)
Pacf(y, lag.max=30)
adf.test(y, nlag = 4)
```

Model AR(p)

Model autoregresyjny rzędu p jest modelem szeregu czasowego X_t danym zależnością:

$$X_t = \phi_0 + \phi_1 \cdot X_{t-1} + \phi_2 \cdot X_{t-2} + \dots + \phi_p \cdot X_{t-p} + Z_t$$

gdzie:

ϕ_0 – stała, dla uproszczenia często pomijana,

ϕ_1, \dots, ϕ_p – parametry modelu,

Z_t – szereg typu biały szum $WN(0, \sigma^2)$.

Model AR(p) jest zapisywany z wykorzystaniem operatora autoregresji $\phi(B)$ rzędu p jako:

$$\phi(B)X_t = \phi_0 + Z_t$$

gdzie:

$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$ jest operatorem autoregresji rzędu p ,

B jest operatorem przesunięcia wstecz.

Model autoregresji jest słabostacjonarny, jeżeli wszystkie pierwiastki równania charakterystycznego (wielomianu autoregresyjnego stopnia p):

$$1 - \phi_1 \cdot y^1 - \phi_2 \cdot y^2 - \dots - \phi_p \cdot y^p = 0$$

leżą poza okręgiem jednostkowym, tzn. spełniają nierówność $|y| > 1$. To oznacza, że jeżeli parametry ww. równania zapewniają wspomniane rozwiązanie, to proces AR(p) o tych parametrach jest stacjonarny.

Model jest wykorzystywany do identyfikacji procesów stacjonarnych

Identyfikacja modelu AR(p)

Reguła identyfikacji modelu autoregresji AR(p) jest oparta na postaci teoretycznej funkcji autokorelacji cząstkowej $\alpha(k)$ dla przesunięcia (opóźnienia) k . Jeżeli szereg $\{X_t\}$ jest procesem AR(p), to funkcja autokorelacji cząstkowej tego szeregu znika dla opóźnień większych niż rząd p procesu, tzn.

$$\alpha(k) \neq 0 \text{ jeżeli } k \leq p$$

$$\alpha(k) = 0 \text{ jeżeli } k > p$$

W praktyce stosuje się ww. właściwość do cząstkowej autokorelacji próbkowej.

Jeżeli cząstkowa autokorelacja próbkowa PACF(k) znajduje się pomiędzy przedziałami ufności $(-1,95/\sqrt{n}, 1,95/\sqrt{n})$ dla $k > p$, to można oczekiwać, że dane realizują proces AR(p).

Identyfikacja modelu AR(p) - przykład

```
library(forecast)
plot(AirPassengers)

# Transformacja Boxa-Coxa; poszukiwanie stałej lambda
lamb <- BoxCox.lambda(AirPassengers, method = "loglik")
par(mfrow=c(2,1))
for (lamb in seq(from=-1,to=0.9,by=0.1))
{
  AirPass.B_C<- BoxCox(AirPassengers, lambda = lamb)
  plot(AirPass.B_C, main=paste("Box-Cox, lambda=", as.character(lamb)))
  Pacf(AirPass.B_C, lag.max=52)
}

# grid(nx=12)
par(mfrow=c(2,1))
# Transformacja: różnicowanie sezonowe z opóźnieniem 12 i proste rzędu: od 1 do 5
AirPass.diff12 <- diff(AirPassengers, lag=12, differences=1)
plot(AirPass.diff12)
for (d in seq(from=1,to=5,by=1))
{
  AirPass.diff12.diff_x <- diff(AirPass.diff12, lag=1, differences=d)
  plot(AirPass.diff12.diff_x, main=paste("Roznicowanie; 1 x 12 sezonowe, proste ",
                                         paste(as.character(d), "x 1")))
  Pacf(AirPass.diff12.diff_x, lag.max=52)
}

# to samo można przeprowadzić dla szeregu usgdp
```

Model MA(q)

Model średniej ruchomej rzędu q jest modelem szeregu czasowego X_t danym zależnością:

$$X_t = \mu + Z_t + \theta_1 \cdot Z_{t-1} + \theta_2 \cdot Z_{t-2} + \dots + \theta_q \cdot Z_{t-q}$$

gdzie:

μ – wyraz wolny jest wartością oczekiwaną szeregu czasowego opisanego modelem MA(q), często zakładana jako równa zero i dlatego pomijana,

$\theta_1, \dots, \theta_q$ – parametry modelu,

Z_t – szereg typu biały szum $WN(0, \sigma^2)$.

Model MA(q) jest zapisywany z wykorzystaniem operatora średniej ruchomej $\theta(B)$ rzędu q jako:

$$X_t = \mu + \theta(B)Z_t$$

gdzie:

$\theta(B) = 1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q$ jest operatorem średniej ruchomej rzędu q ,

B jest operatorem przesunięcia wstecz.

Założeniem modelu MA(p) było uznanie, że wartość bieżąca szeregu zależy od wartości białego szumu lub nieprzewidywalnych szoków, co można przedstawić w postaci liniowej. Model MA obrazuje procesy będące skończoną sumą ważoną białego szumu z bieżącego oraz q poprzednich okresów

Każdy proces średniej ruchomej MA jest stacjonarny.

Model jest wykorzystywany do identyfikacji procesów stacjonarnych

Identyfikacja modelu MA(q)

Reguła identyfikacji modelu autoregresji MA(q) jest oparta na postaci teoretycznej funkcji autokorelacji $\rho(k)$ dla przesunięcia (opóźnienia) k . Jeżeli szereg $\{X_t\}$ jest procesem MA(q), to funkcja autokorelacji tego szeregu znika dla opóźnień większych niż rząd q procesu, tzn.

$$\rho(k) \neq 0 \text{ jeżeli } k \leq q$$

$$\rho(k) = 0 \text{ jeżeli } k > q$$

Każdy model stacjonarny o tej własności ma reprezentację w postaci odpowiedniego modelu MA(q). W praktyce stosuje się ww. właściwość do autokorelacji próbkowej sprawdzając, czy dla opóźnień k większych niż q można uznać ją za statystycznie nieistotną.

Jeżeli autokorelacja próbkowa ACF(k) znajduje się pomiędzy przedziałami ufności $(-1,95/\sqrt{n}, 1,95/\sqrt{n})$ dla $k > q$, to można oczekiwać, że dane realizują proces MA(q).

Identyfikacja modelu MA(q) - przykład

```
#  
library(forecast)  
plot(AirPassengers)  
  
# Transformacja Boxa-Coxa; poszukiwanie stałej lambda  
lamb <- BoxCox.lambda(AirPassengers, method = "loglik")  
par(mfrow=c(2,1))  
for (lamb in seq(from=-5,to=5,by=0.2))  
{  
  AirPass.B_C<- BoxCox(AirPassengers, lambda = lamb)  
  plot(AirPass.B_C, main=paste("Box-Cox, lambda=", as.character(lamb)))  
  Acf(AirPass.B_C, lag.max=52)  
}  
  
# grid(nx=12)  
  
# Transformacja: różnicowanie sezonowe z opóźnieniem 12 i proste rzędu: od 1 do 5  
AirPass.diff12 <- diff(AirPassengers, lag=12, differences=1)  
plot(AirPass.diff12)  
par(mfrow=c(2,1))  
for (d in seq(from=1,to=5,by=1))  
{  
  AirPass.diff12.diff_x <- diff(AirPass.diff12, lag=1, differences=d)  
  plot(AirPass.diff12.diff_x, main=paste("Różnicowanie; 1 x 12 sezonowe, proste ",  
                                         paste(as.character(d), "x 1")))  
  Acf(AirPass.diff12.diff_x, lag.max=52)  
}
```


Model ARMA(p, q)

Modele autoregresji i średniej ruchomej (ARMA) dostarczają oszczędny opis (słabo) stacjonarnego procesu stochastycznego za pomocą dwóch wielomianów, jednego dla autoregresji (AR), a drugiego dla średniej ruchomej (MAMA).

Model ARMA(p, q) jest modelem szeregu czasowego X_t danym zależnością:

$$X_t = \phi_1 \cdot X_{t-1} + \phi_2 \cdot X_{t-2} + \dots + \phi_p \cdot X_{t-p} + Z_t + \theta_1 \cdot Z_{t-1} + \theta_2 \cdot Z_{t-2} + \dots + \theta_q \cdot Z_{t-q}$$

lub w postaci skróconej:

$$X_t = \sum_{i=1}^p \phi_i X_{t-i} + Z_t + \sum_{i=1}^q \theta_i Z_{t-i}$$

gdzie

Z_t – szereg typu biały szum $WN(0, \sigma^2)$.

ϕ_1, \dots, ϕ_p – parametry części modelu przypisane do AR,

$\theta_1, \dots, \theta_q$ – parametry części modelu przypisane do MA.

Aby zapewnić jednoznaczność reprezentacji w ww. zależności zakłada się, że wielomiany odpowiednio stopnia p i q :

$$\phi(y) = 1 - \phi_1 \cdot y^1 - \phi_2 \cdot y^2 - \dots - \phi_p \cdot y^p$$

$$\theta(y) = 1 + \theta_1 y^1 + \theta_2 y^2 + \dots + \theta_q y^q$$

nie mają wspólnych czynników, tzn. nie mogą być zredukowane do wielomianów mniejszych stopni.

Model jest wykorzystywany do identyfikacji procesów stacjonarnych

Model ARMA(p, q) - cd

Model ARMA(p, q) jest zapisywany z wykorzystaniem operatora autoregresji $\phi(B)$ rzędu p i operatora średniej ruchomej rzędu q $\theta(B)$ jako:

$$\phi(B)X_t = \theta(B)Z_t \quad \text{gdzie } B \text{ jest operatorem przesunięcia wstecz.}$$

Przykład postaci modelu ARMA(1, 1): $X_t = \phi_1 X_{t-1} + Z_t + \theta_1 Z_{t-1}$

Modele AR(p) i MA(Q) są szczególnymi przypadkami modelu ARMA(p, q):

- AR(p) = ARMA(p, 0)
- MA(q) = ARMA(0, q)

Aby model ARMA(p, q) był stacjonarny wystarczy, aby jego część odpowiadająca modelowi AR(p) była stacjonarna, ponieważ modele MA(q) są zawsze stacjonarne. To oznacza, że model jest słabostacjonarny, jeżeli wszystkie pierwiastki równania charakterystycznego definiowanego dla modelu AR(p) (wielomianu autoregresyjnego stopnia p):

$$1 - \phi_1 \cdot y^1 - \phi_2 \cdot y^2 - \dots - \phi_p \cdot y^p = 0$$

leżą poza okręgiem jednostkowym, tzn. spełniają nierówność $|y| > 1$.

Własności modelu ARMA(p, q) Chwilowo pominięte

Odwracalność (*invertability*) oznacza możliwość przedstawienia wartości zakłócenia szeregu w chwili t jako kombinacji liniowej bieżącej i wcześniejszych wartości szeregu. ARMA(p, q) jest procesem odwracalnym, gdy istnieje ciąg stałych $\{\pi_j\}$, takich że zachodzi możliwość przedstawienia modelu ARMA(p, q) w postaci szeregu AR(∞):

$$Z_t = \sum_{i=0}^{\infty} \pi_i Z_{t-i} \quad \text{oraz} \quad \sum_{i=1}^{\infty} |\pi_i| < \infty$$

Odwracalność procesu ARMA jest równoważna warunkowi nałożonemu na współczynniki $\{\theta_j\}$:

$$\theta(y) = 1 + \theta_1 y^1 + \theta_2 y^2 + \dots + \theta_q y^q \neq 0 \quad \text{dla wszystkich } |y| \leq 1$$

co oznacza, że odpowiadający ww. równaniu proces AR(q) jest stacjonarny.

Współczynniki θ_i są określone przez rozwinięcie szeregu potęgowego, określonego zależnością od θ i ϕ .

Przyczynowość (*casuality*) oznacza możliwość przedstawienia wartości szeregu w chwili t jako kombinacji liniowej bieżącego i wcześniejszych zakłóceń. ARMA(p, q) jest procesem przyczynowym, gdy istnieje ciąg stałych $\{\psi_j\}$, takich że zachodzi możliwość przedstawienia modelu ARMA(p, q) w postaci szeregu MA(∞):

$$X_t = \sum_{i=0}^{\infty} \psi_i Z_{t-i} \quad \text{oraz} \quad \sum_{i=1}^{\infty} |\psi_i| < \infty$$

Przyczynowość procesu ARMA jest równoważna (udowodnione twierdzenie) warunkowi nałożonemu na współczynniki $\{\phi_i\}$:

$$\phi(y) = 1 - \phi_1 \cdot y^1 - \phi_2 \cdot y^2 - \dots - \phi_p \cdot y^p \neq 0 \quad \text{dla wszystkich } |y| \leq 1$$

Współczynniki ψ_i są określone przez rozwinięcie szeregu potęgowego, określonego zależnością od θ i ϕ .

Modele sezonowe: $AR(P)_s$, $MA(Q)_s$, $ARMA(P, Q)_s$

- Model sezonowy $AR(P)_s$

$$\Phi(B^s)X_t = Z_t$$

- Model sezonowy $MA(Q)_s$

$$X_t = \Theta(B^s)Z_t$$

- Model sezonowy $ARMA(P, Q)_s$

$$\Phi(B^s)X_t = \Theta(B^s)Z_t$$

gdzie:

B^s – operator różnicowania z opóźnieniem s (operator różnicowania sezonowego),

$\Phi(B^s)$ – operator sezonowej autoregresji rzędu P : $\Phi(B^s) = 1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_P B^{Ps}$

$\Theta(B^s)$ – operator sezonowej średniej ruchomej rzędu Q : $\Theta(B^s) = 1 + \Theta_1 B^s + \Theta_2 B^{2s} + \dots + \Theta_Q B^{Qs}$

Z_t – szereg typu biały szum $WN(0, \sigma^2)$.

Analogicznie do $ARMA(p, q)$, model $ARMA(P, Q)$ jest odwracalny gdy pierwiastki wielomianów $\Phi(y^s)$ i $\Theta(y^s)$ leżą poza kołem jednostkowym (tzn. wartości wielomianów dla argumentów leżących w obrębie koła są różne od zera).

Model mieszany: $ARMA(p, q) (P, Q)_s$

Jest połączeniem operatorów autoregresji i średniej ruchomej sezonowych i niesezonowych:

$$\Phi(B^s)\phi(B)X_t = \Theta(B^s)\theta(B)Z_t$$

Zachowanie ACF i PACF dla takich modeli jest kombinacją zachowania sezonowych i niesezonowych części modelu.

ARMA(p, q)(P, Q)_s - przykłady

Przykłady (z dokładnością do stałej):

$$\text{AR}(1): X_t = \phi_1 \cdot X_{t-1} + Z_t$$

$$\text{AR}(1)_{12}: X_t = \Phi_1 \cdot X_{t-12} + Z_t$$

$$\text{MA}(1): X_t = Z_t + \theta_1 \cdot Z_{t-1}$$

$$\text{MA}(1)_{12}: X_t = Z_t + \Theta_1 \cdot Z_{t-12}$$

$$\text{ARMA}(1, 1): X_t = \phi_1 X_{t-1} + Z_t + \theta_1 Z_{t-1}$$

$$\text{ARMA}(1, 1)_{12}: X_t = \Phi_1 X_{t-12} + Z_t + \Theta_1 Z_{t-12}$$

Przykłady (z dokładnością do stałej):

$$\text{ARMA}(0,1) \times (1,0)_{12}: X_t = \Phi_1 \cdot X_{t-12} + Z_t + \theta_1 Z_{t-1}$$

Skąd się wzięło:

$$\text{ARMA}(p, q) \times (P, Q)_{12}: \text{ARMA}(0,1) \times (1,0)_{12} \rightarrow p=0, q=1, P=1, Q=0, s=12$$

$$\begin{aligned} \Phi(B^{12}) \phi(B) X_t &= \Theta(B^{12}) \theta(B) Z_t \rightarrow \Phi(B^{12}) X_t = \theta(B) Z_t \rightarrow (1 - \Phi_1 B^{12}) X_t = (1 + \theta_1 B) Z_t \rightarrow \\ &\rightarrow X_t - \Phi_1 B^{12} X_t = Z_t + \theta_1 B Z_t \rightarrow X_t - \Phi_1 X_{t-12} = Z_t + \theta_1 Z_{t-1} \rightarrow X_t = \Phi_1 X_{t-12} + Z_t + \theta_1 Z_{t-1} \end{aligned}$$

Modele ARMA(p, q)(P, Q)_s są wykorzystywane do identyfikacji procesów stacjonarnych.

Cechy funkcji korelacyjnych dla modeli ARMA wykorzystywane w identyfikacji modelu ARMA

Modele zwykłe – identyfikacja rzędów zwykłych p i q			
	AR(p)	MA(q)	ARMA(p, q)
ACF	Zanika stopniowo	Znika dla $k > q$	Zanika stopniowo
PACF	Znika dla $k > p$	Znika stopniowo	Zanika stopniowo
Modele sezonowe – identyfikacja rzędów sezonowych P i Q			
	AR(P) _{s}	MA(Q) _{s}	ARMA(P, Q) _{s}
ACF	Zanika stopniowo dla $k = hs$ (wielokrotności okresu)	Znika dla $k > Qs$	Zanika stopniowo dla $k = hs$ (wielokrotności okresu)
PACF	Znika dla $k > Ps$	Znika stopniowo dla $k = hs$ (wielokrotności okresu)	Zanika stopniowo dla $k = hs$ (wielokrotności okresu)
$h = 1, 2, 3, \dots$			

W przypadku modeli sezonowych analizuje się zachowanie funkcji ACF i PACF dla opóźnień będących wielokrotnościami okresu s , tzn. $k = s, 2s, 3s, \dots$. Należy pamiętać, że dla modeli sezonowych wartości funkcji ACF i PACF dla opóźnień $k \neq s, 2s, 3s, \dots$ są równe zero.

Zaleca się, aby w pierwszej kolejności wykonać identyfikację P i Q , a dopiero później p i q .

Ogólne uwagi nt. dopasowania modeli ARMA

1.

Dla danych rzeczywistych analizuje się funkcje ACF i PACF próbkowe, co oznacza, że charakterystyczne własności modelu mogą być spełnione w przybliżeniu.

2.

Dla analizowanych danych różne modele (AR, MA, ARMA) będą równie dobrze lub równie niedobrze opisywały zjawisko. Zazwyczaj buduje się kilak modeli i z nich wybiera najlepszy stosując określone narzędzia oceny.

3.

W przypadku modeli ARMA typowe zachowania funkcji ACF i PACF to kombinacja zaników wykładniczych i sinusoid tłumionych. Nie ma prostej reguły na określenie rzędów.

4.

Reguły identyfikacji modelu ARMA można stosować, gdy analizowane dane uzna się za realizację procesu stacjonarnego. Ponieważ w praktyce występują szeregi niestacjonarne, dopasowanie modeli stacjonarnych wymaga odpowiedniego przekształcenia danych oryginalnych, np. poprzez różnicowanie, co w ogólnym przypadku prowadzi do dopasowania modelu $SARIMA(p, d, q) \times (P, D, Q)_s$.

5.

W porównaniu do modeli $AR(p)$ i $MA(q)$, model $ARMA(p, q)$ zwykle wymaga dużo mniejszej liczby parametrów (czyli mniejszej liczby rzędów p i q) aby uzyskać dobre dopasowanie do danych.

Szeregi niestacjonarne – modele ARIMA i SARIMA

Model ARIMA(p, d, q) (model zintegrowany autoregresji i średniej ruchomej) jest modelem szeregu czasowego X_t , gdy szereg czasowy $(1-B)^d X_t$, gdzie parametr $d \geq 0$ określa poziom zintegrowania, jest modelem ARMA(p, q). Model ARIMA(p, d, q) dla szeregu X_t spełnia równanie różnicowe postaci:

$$\phi(B)(1-B)^d X_t = \theta(B)Z_t$$

gdzie:

$\phi(B)$ – operator autoregresji rzędu p ,

$\theta(B)$ – operatora średniej ruchomej rzędu q ,

d – stopień integracji szeregu X_t

Model ARIMA jest składową trzech modeli szeregów:

- AR(p), gdzie p określa rząd autoregresji (poszczególne wartości szeregu czasowego można opisać za pomocą modelu jego na podstawie wcześniejszych obserwacji),
- I(d), gdzie d jest rzędem różnicowania (liczba krotności różnicowania danych, aby stały się stacjonarne),
- MA(q), gdzie q określa rząd średniej ruchomej (liczba opóźnień dla błędów prognozy w równaniu predykcji). Przy szacowaniu wartości następnego szeregu czasowego uwzględniane są błędy oszacowań lub prognoz z przeszłości. Różnica między oszacowaniem X_t a faktycznie zaobserwowaną wartością X_t jest oznaczona jako Z_t .

Parametry $\{\phi_i\}$ modelu są takie, że $\phi(z) \neq 0$ dla $|z| \leq 1$.

Dla $d = 0$ model ARIMA redukuje się do modelu ARMA.

Rozbudowanie modelu ARIMA o sezonowość z okresem s dostarcza model SARIMA(p,d,q)(P,D,Q) $_s$ w którym trójka (p, d, q) reprezentuje niesezonową część modelu a (P, D, Q) część sezonową.



$$\phi(B) \Phi(B^s) (1-B)^d (1-B)^D X_t = \theta(B) \Theta(B^s) Z_t$$

gdzie operatorom rzędu prostego p i q oraz integracji stopnia d odpowiadają operatory sezonowe oznaczone wielkimi literami alfabetu.

Stabilizowanie szeregu czasowego

1. Transformacja B-C ma na celu ustabilizowanie wariancji. Dane przekształcano dla stałej $\lambda = 0$, co oznacza transformację logarymiczną.

```
library(stats)
data(AirPassengers)
# 1. Transformacja B-C w celu ustabilizowania wariancji
AirPass.B_C<- BoxCox(AirPassengers, lambda = 0)
par(mfrow=c(2,1))
plot(AirPassengers)
plot(AirPass.B_C) # jest trend ale ustabilizowana wariancja
adf.test(AirPass.B_C, nlag = 4)
Acf(AirPass.B_C, lag.max=24)
```



Augmented Dickey-Fuller Test
alternative: stationary

Type	lag	ADF	p.value
Type 1: no drift no trend			
[1,]	0	0.913	0.902
[2,]	1	0.674	0.836
[3,]	2	0.796	0.871
[4,]	3	0.936	0.905
Type 2: with drift no trend			
[1,]	0	-1.82	0.400
[2,]	1	-2.02	0.321
[3,]	2	-1.65	0.465
[4,]	3	-1.61	0.481
Type 3: with drift and trend			
[1,]	0	-4.85	0.01
[2,]	1	-7.00	0.01
[3,]	2	-6.71	0.01
[4,]	3	-7.13	0.01

Stabilizowanie szeregu czasowego - cd

- Proces różnicowania służy do ustabilizowania szeregu. Patrząc na autokorelację szeregu *AirPassengers*, można zdecydować o rzędzie różnicowania.

2. Transformacje różnicowe: sezonowa i prosta w celu wyeliminowania sezonowości i trendu
`pom <- diff(AirPass.B_C, lag=12) # różnicowanie sezonowe; jednokrotne z opóźnieniem 12`
`AirPass.B_C_diff_12_1 <- diff(pom, lag=1) # różnicowanie proste; jednokrotne z opóźnieniem 1`

- Po wykonaniu ww. trzech przekształceń następuje sprawdzenie szeregu wynikowego na okoliczność stacjonarności.

3. Sprawdzenie stacjonarności wyników różnicowania


```
adf.test(AirPass.B_C_diff_12_1, nlag = 4)
```

```
par(mfrow=c(3,1))
```

```
plot(AirPass.B_C_diff_12_1)
```

```
Acf(AirPass.B_C_diff_12_1, lag.max=52)
```

```
Pacf(AirPass.B_C_diff_12_1, lag.max=52)
```




Augmented Dickey-Fuller Test
alternative: stationary


Type	lag	ADF	p.value
Type 1: no drift no trend	0	-16.25	0.01
[1,]	1	-9.34	0.01
[2,]	2	-8.65	0.01
[3,]	3	-7.70	0.01
[4,]			
Type 2: with drift no trend	0	-16.19	0.01
[1,]	1	-9.30	0.01
[2,]	2	-8.61	0.01
[3,]	3	-7.67	0.01
[4,]			
Type 3: with drift and trend	0	-16.16	0.01
[1,]	1	-9.29	0.01
[2,]	2	-8.62	0.01
[3,]	3	-7.70	0.01
[4,]			

Note: in fact, p.value = 0.01 means p.value <= 0.01


Analiza szeregu ustabilizowanego w celu identyfikacji postaci modelu



Series AirPass.B_C_diff_12_1



Series AirPass.B_C_diff_12_1



- autokorelacje dla opóźnień sezonowych
- autokorelacje dla opóźnień niesezonowych

Identyfikacja modelu SARIMA

Działania pozwalające określić parametry dla modelu szeregu czasowego po **zlogarytmowaniu** jego wartości:

- Składnik sezonowości: $s=12$
- Jednokrotne różnicowanie proste: $d=1$, jednokrotne różnicowane sezonowe: $D=1$
- Analizuje się zachowanie dla ACF i PACF dla opóźnień będących wielokrotnościami okresu. Dla modeli sezonowych wartości tych funkcji dla opóźnień niebędących wielokrotnościami okresu są równe zero. W ww. szeregu:

- P w składniku AR: ACF zanika stopniowo dla wielokrotności okresu i PACF znika dla $k > P \cdot s = 1 \cdot 12$
- Q w składniku MA: ACF znika dla $k > Q \cdot s = 1 \cdot 12$ i PACF znika stopniowo dla wielokrotności okresu

Propozycje dla parametrów sezonowych: $P=1, Q=1$

- Zachowania ACF i PACF to kombinacja zaników wykładniczych i sinusoid tłumionych. Trudno wskazać prostą regułę pozwalającą na zidentyfikowanie p i q . Po zidentyfikowaniu parametrów sezonowych P i Q analizuje się przebiegi ACF i PACF dla opóźnień niebędących wielokrotnościami okresu ($h = 1, 2, 3, \dots, s-1$).

W ww. szeregu:

- p w składniku AR: ACF zanika stopniowo i PACF znika dla $k > p = 23$ (ew. sprawdzić 3)
- q w składniku MA: ACF znika dla $k > 9$ i PACF znika stopniowo

Propozycje dla parametrów sezonowych: $(p=23, q=9)$ lub $(p=3, q=9)$

SARIMA(p, d, q)(P, D, Q)_s

d – rząd zróżnicowania prostego

D – rząd zróżnicowania sezonowego

s – częstotliwość (sezonowość)

P – rząd sezonowy składnika AR

Q – rząd sezonowy składnika MA

p – rząd prosty składnika AR

q – rząd prosty składnika MA

Uwzględniając identyfikację składników AR i MA:

SARIMA(23, 1, 0)(1, 1, 0)₁₂

SARIMA(3, 1, 0)(1, 1, 0)₁₂

SARIMA(0, 1, 9)(0, 1, 1)₁₂

Rozważając modele rozbudowane:

SARIMA(23, 1, 9)(1, 1, 1)₁₂

SARIMA(3, 1, 9)(1, 1, 1)₁₂

Eksperyment z modelem pełniejszym ale mniej rozbudowanym:

SARIMA(1, 1, 1)(1, 1, 1)₁₂