

Ćwiczenie nr 11 – model ARIMA

1. Wczytaj dane z pliku *recruit.txt*. Dane te zawierają ilość nowych ryb w Pacyfiku z 453 miesięcy w latach 1950–1987. Narysuj wykres danych.
Na podstawie rysunków funkcji autokorelacji oraz autokorelacji cząstkowej (acf i pacf) zaproponuj model dla tych danych?

Dopasuj metodą najmniejszych kwadratów model AR(2).

```
ols=ar(recruit,aic=F,order.max=2,demean=F,intercept=T,method="ols");  
ols  
ols$asy.se # błędy standardowe
```

Dopasuj model AR(2) metodą Yule’a-Walkera. Porównaj wyniki.

```
yw = ar(recruit, order=2,method="yw")  
sqrt(diag(yw$asy.var.coef)) # błędy standardowe
```

Przeprowadź prognozę na następne 24 miesiące. Zobrazuj wynik wraz z 90-procentowymi przedziałami ufności.

```
pred = predict(yw, n.ahead=24)  
plot(recruit,xlim=c(1980,1990))  
lines(pred$pred,col="red")  
lines(pred$pred+1.64*pred$se,col="red",lty="dashed")  
lines(pred$pred-1.64*pred$se,col="red",lty="dashed")
```

Dopasuj model AR(2) metodą największej wiarygodności oraz metodą Burga. Porównaj z poprzednimi wynikami.

```
burg<-ar(recruit,order=2,method="burg")  
mle<-ar(recruit,order=2,method="mle")  
mle$var.pred # wariancja predykcji
```

2. Wczytaj dane z pliku *gnp96.txt* zawierające kwartalny dochód narodowy brutto Stanów Zjednoczonych (druga kolumna) z lat 1947-2002 (daty w pierwszej kolumnie). Narysuj wykres tego szeregu oraz wykresy autokorelacji i autokorelacji cząstkowej. Czy ten szereg jest stacjonarny?

Spróbuj zestacjonaryzować szereg poprzez różnicowanie.

Zlogarytmuj oryginalne dane i ponownie spróbuj zestacjonaryzować szereg poprzez różnicowanie.

Na podstawie wykresów autokorelacji i autokorelacji cząstkowej zaproponuj możliwy model dla danych.

Dopasuj model ARMA(1,0).

```
gnp.ar<-arima(dlgnp,order=c(1,0,0))
```

Dopasuj model ARMA(0,2).

```
gnp.ma<-arima(dlgnp,order=c(0,0,2))
```

Porównaj otrzymane modele.

Znajdź współczynniki rozwinięcia modelu AR(1) w model MA(∞).

```
ARMAtoMA(ar=0.3467,ma=0,10)
```

Zbadaj reszty w modelu. (test białoszumowości oraz testy normalności).

```
acf(gnp.ar$res,100)
```

```
Box.test(gnp.ar$res,type="Ljung")
```

```
qqnorm(gnp.ar$res); qqline(gnp.ar$res)
```

```
tsdiag(gnp.ar)
```

Dopasuj model ARMA(1,1)

```
gnp.arma<-arima(dlgnp,order=c(1,0,1))
```

Porównaj modele poprzez kryterium AIC (kryt. Akaike).

```
AIC(gnp.ar); AIC(gnp.ma); AIC(gnp.arma);
```

Porównaj modele poprzez kryterium AICC (kryt. Akaike z poprawką na obciążenie).

```
log(gnp.ma$sigma2)+(222+3)/(222-3-2)
```

```
log(gnp.ar$sigma2)+(222+2)/(222-2-2)
```

```
log(gnpgr.arma$sigma2)+(222+3)/(222-3-2)
```

Porównaj modele poprzez kryterium bayesowskie BIC (kryt. Schwartza).

```
log(gnp.ma$sigma2)+(2*log(222)/222)
```

```
log(gnp.ar$sigma2)+(1*log(222)/222)
```

```
log(gnpgr.arma$sigma2)+(2*log(222)/222)
```

Dopasuj model ARIMA(1,1,1) do zlogarytmowanych danych (nie różnicowanych).

```
gnp.arima<-arima(lgnp,order=c(1,1,1),xreg=(1:length(lgnp)))
```

(Dodatkowy regresor αt został dodany by po zróżnicowaniu pozostała stała α – domyślnie R nie dodaje stałej do modelu różnicowanego). Wykonaj prognozę na

następnych 10 kwartałów.

```
predict(gnp.arima,n.ahead=10,newxreg=224:233)
```

3. Wczytaj dane z pliku *prod.txt*. Dane te przedstawiają miesięczny wskaźnik produkcji w Stanach Zjednoczonych w latach 1948-1978. Narysuj wykres. Co można powiedzieć o tym szeregu?

Zróznicuj model tak by pozbyć się trendu i sezonowości. Zbadaj autokorelację i autokorelację cząstkową. Jaki model można dopasować do tych danych?

Dopasuj modele $ARIMA(1, 1, 1)(0, 1, 1)_{12}$, $ARIMA(1, 1, 1)(2, 1, 0)_{12}$, $ARIMA(1, 1, 1)(2, 1, 1)_{12}$.

```
prod1=arima(prod,order=c(1,1,1),seasonal=list(order=c(0,1,1),period=12))
```

Przeprowadź prognozę na następny rok za pomocą najlepszego z modeli.