

GARCH modely

Beáta Stehlíková, FMFI UK, Cvičenie z časových rado

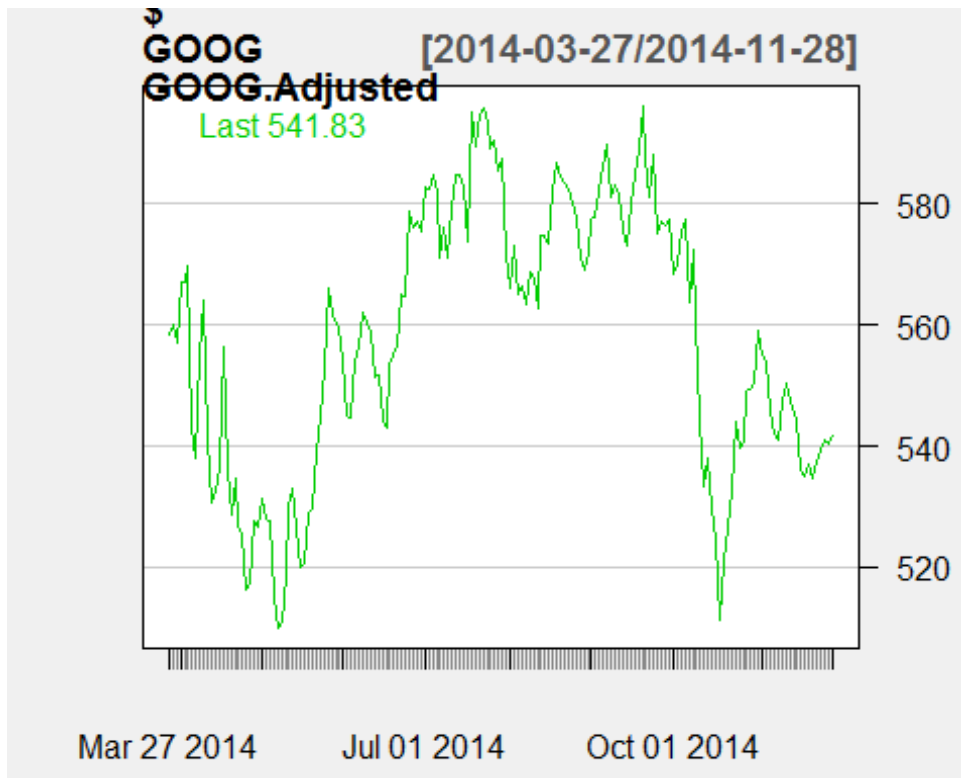
Príklad 1: Volatilita cien akcií – analogicky ako na prednáške

Najskôr načítame knižnice:

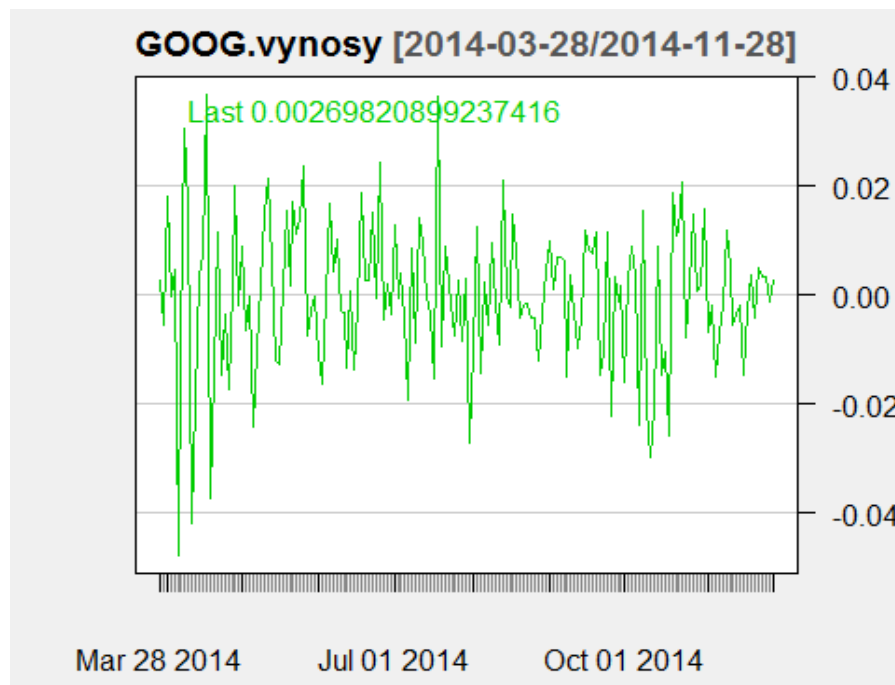
```
library(quantmod) # získanie cien akcií  
library(astsa)    # sarima modely  
library(fGarch)   # garch modely
```

Dáta:

```
getSymbols("GOOG", from="2012-01-01", to="2014-11-30")  
chartSeries(GOOG$GOOG.Adjusted, theme="white")
```

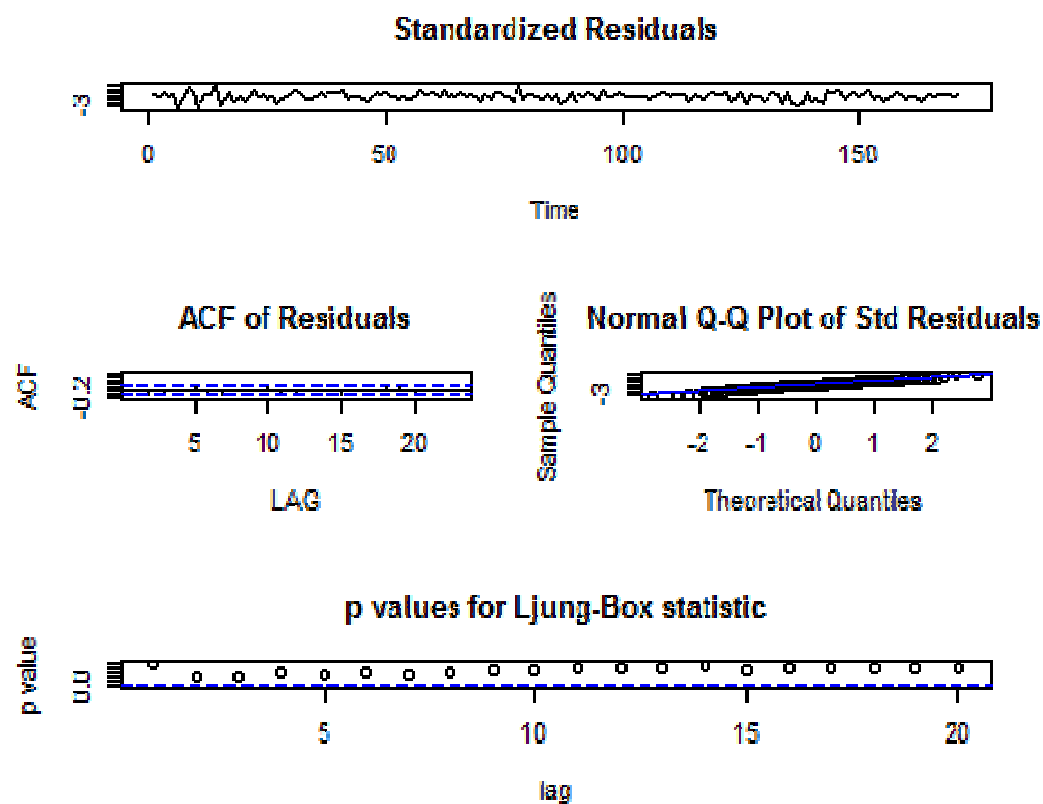


```
GOOG.vynosy <- diff(log(GOOG$GOOG.Adjusted))  
chartSeries(GOOG.vynosy, theme="white")
```



```
vynosy <- G00G.vynosy[!is.na(G00G.vynosy)] # prva hodnota je NA
```

Pre vynosy odhadnite model „konštanta + biely šum“. Na kontrolu výsledok:

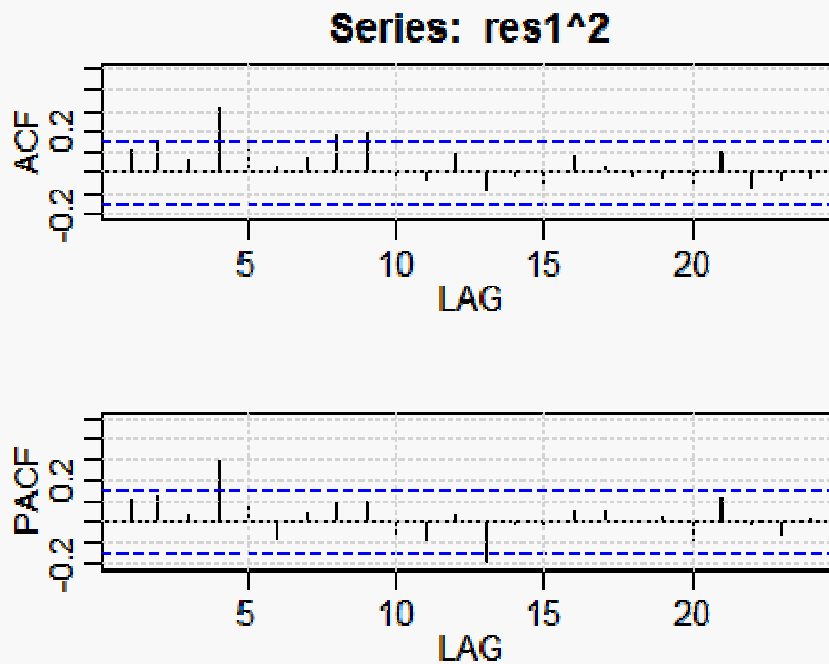


```

## $fit
##
## Call:
## stats::arima(x = xdata, order = c(p, d, q), seasonal = list(order = c(P,
##      0), period = S), xreg = xmean, include.mean = FALSE, optim.control =
##      list(trace = trc,
##        REPORT = 1, reltol = tol))
##
## Coefficients:
##      xmean
##      -2e-04
## s.e.    1e-03
##
## sigma^2 estimated as 0.0001735:  log likelihood = 497.76,  aic = -991.51
##
## $AIC
## [1] -7.647878
##
## $AICc
## [1] -7.635765
##
## $BIC
## [1] -8.629506

```

Zobrazte ACF druhých mocnín rezíduí :



Pomocou funkcií z prednášky:

- odhadnite model tak, že odchýlka od konštanty nebude biely šum, ale vhodný GARCH proces
- overte podmienky stacionarity odhadnutého GARCH procesu
- zobrazte ACF štandardizovaných rezíduí aj ich druhých mocnín
- zobrazte priebeh odhadnutej štandardnej odchýlky
- spravte predikcie

Ďalej: zobrazte summary modelu - vysvetlime si testy, ktoré obsahuje. Pre určitý model napríklad dostaneme:

```
## Standardised Residuals Tests:
##
## Jarque-Bera Test      R      Chi ^2   13.75095   0.001032809
## Shapiro-Wilk Test    R      W        0.9835653  0.04119268
## Ljung-Box Test       R      Q(10)    4.904431   0.8974699
## Ljung-Box Test       R      Q(15)    9.036078   0.8756235
## Ljung-Box Test       R      Q(20)    12.44751   0.8998126
## Ljung-Box Test       R^2    Q(10)    32.61096   0.0003165607
## Ljung-Box Test       R^2    Q(15)    36.00869   0.001762707
## Ljung-Box Test       R^2    Q(20)    38.5378    0.007606715
## LM Arch Test         R      TR^2     29.68414   0.003114792
```

Príklad 2: Výpočet Value at Risk

Postup bol uvedený na prednáške

(<http://www.iam.fmph.uniba.sk/institute/stehlikova/cr14/prednasky/garch.pdf>, slajd 27), jediný rozdiel je, že teraz máme denne data.

Postupujte teda podľa jednotlivých bodov z prednášky:

Aplikácia: Value at risk (VaR)


- NA NEPOVINNOM CVIČENÍ:
 - ◊ Začnime po N hodnotách výnosov
 - ◊ Odhadneme GARCH model.
 - ◊ Spravíme predikciu pre štandardnú odchýlku a pomocou nej zostrojíme VaR pre výnos na nasledujúci týždeň
 - ◊ Každý týždeň pridáme nové pozorovanie, odhadneme znovu GARCH a vypočítame nové VaR

Príklad 3: GARCH náhodná zložka v ARIMA modeloch

Doteraz sme pri rezíduách z modelu testovali len to, či v nich nie je autokorelácia. Teraz sa pozrieme aj na autokoreláciu druhých mocnín rezíduí, teda či nemusíme ešte modelovať aj disperziu náhodnej zložky.

Ako príklad zoberieme spotrebu kávy z cvičenia o ARIMA modelovaní:

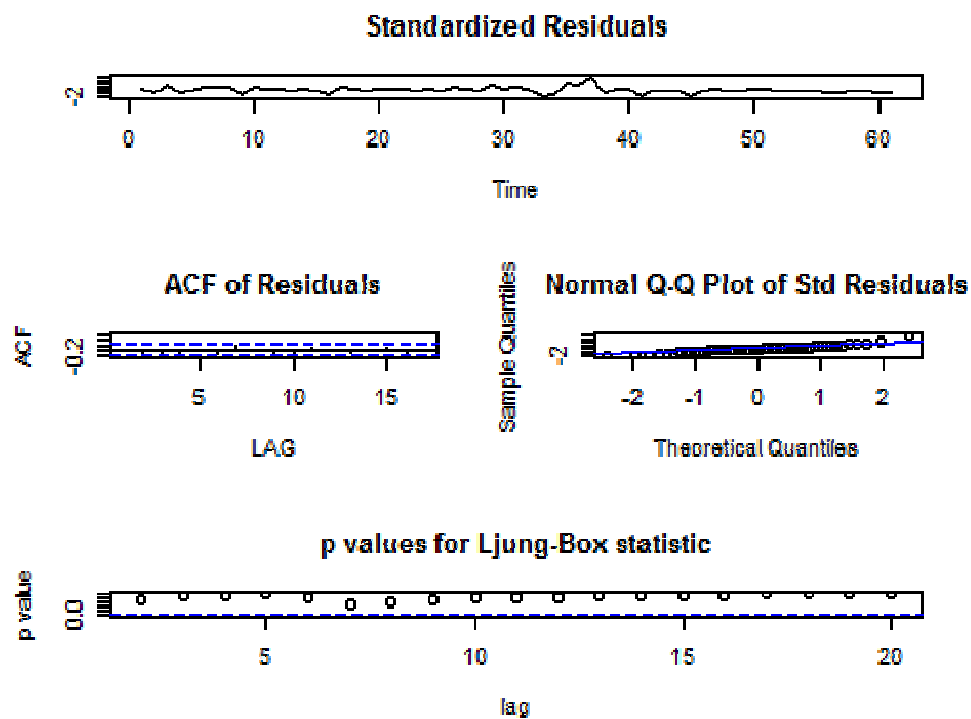
```
y<-  
read.table("http://www.i.am.fmph.uni.ba.sk/institute/stehliva/cr14/data/kava.  
txt")  
y=ts(y)  
plot(y)
```



Pracujeme s diferenciami, odhadneme pre ne MA(1) model:

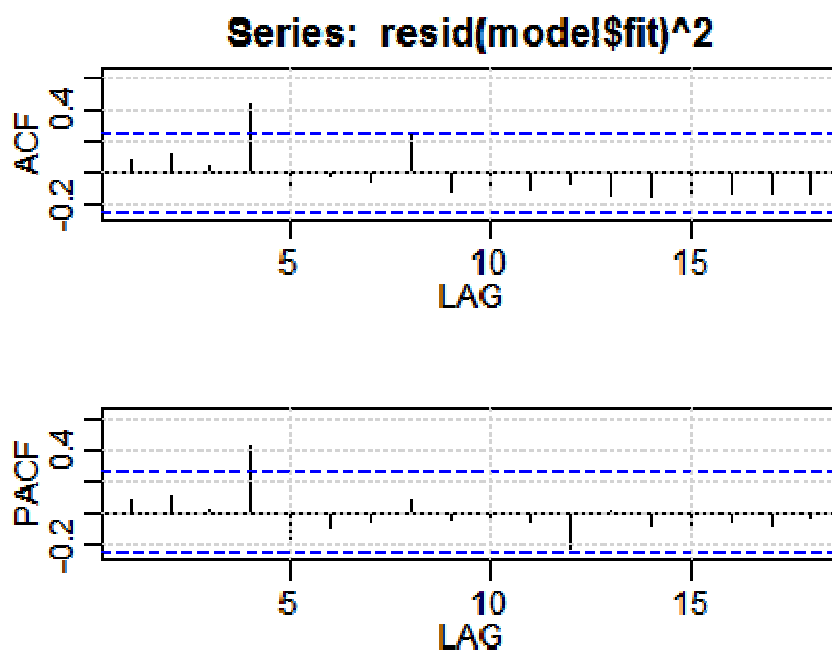
```
model <- sarima(y, 0, 1, 1, details=FALSE)
```

Rezíduá sa z pohľadu autokorelácie vyzerajú dobre:



ACF druhých mocnín rezíduí však ukazuje, že rezíduá nie sú bielym šumom, ale treba modelovať ich disperziu.

```
acf2(resid(model$fit)^2)
```



Nájdite vhodný ARIMA+GARCH model pre tieto dáta. Môžete:

- meniť počet ARCH a GARCH členov
- modelovať logaritmy namiesto pôvodných dát

Štandardizované rezíduá a rezíduá druhých mocnín nemôžu obsahovať autokoreláciu, model musí prejsť testami pre štandardizované rezíduá zo summary (Ljung-Box pre rezíduá a ich druhé mocniny, ARCH LM test)

Poznámky:

- Ako vyzerá použitie funkcie garchFit v prípade AR a MA členov: napríklad `garchFit(~arma(0, 1)+garch(1, 0), data=nase. data)`
- Prvá zložka musí byť ARMA, nie ARIMA. Ak robíme s diferencovanými dátami, treba napr. `garchFit(~arma(1, 0)+garch(1, 0), data=diff(nedi ferencovane. data))`