

# *Modelovanie volatility - ARCH a GARCH modely*

Beáta Stehlíková  
Časové rady, FMFI UK

# Ceny akcií

---

- Týždenné ceny akcií (knížnica `quantmod` z cvičení)
- Vypočítame spojité výnosy:


```
1 library(quantmod)
2 library(astsa)
3
4 getSymbols("EBAY", from="2010-01-01", to="2014-12-31", auto.assign=TRUE)
5 EBAY <- to.weekly(EBAY)
6 vynosy <- diff(log(EBAY$EBAY.Adjusted))[-1] # vynechame NA na zaciatku
7
8 chartSeries(vynosy, theme="white")
```

- Na cvičení na začiatku semestra sme analyzovali autokorelácie takýchto dát

# Výnosy

---

- Priebeh výnosov:



# Výnosy akcií: Black-Scholesov model

---

- Black-Scholesov model ( $\rightarrow$  finančná mat., PDR):

$$dS = \mu S dt + \sigma S dw,$$

kde  $w$  je Wienerov proces.

- Existuje explicitné vyjadrenie pre cenu akcie v čase  $t$  :

$$S_t = S_0 e^{(\mu - 1/2 \sigma^2)t + \sigma w_t}$$

- Výnosy v Black-Scholesovom modeli:

$$vynost_t = \ln \left( \frac{S_t}{S_{t+\Delta t}} \right) = (\mu - 1/2 \sigma^2) \Delta t + \sigma \Delta w$$

$\Rightarrow$  nezávislé s rozdelením  $N((\mu - 1/2 \sigma^2) \Delta t, \sigma^2 \Delta t)$

- Model pre časový rad výnosov:

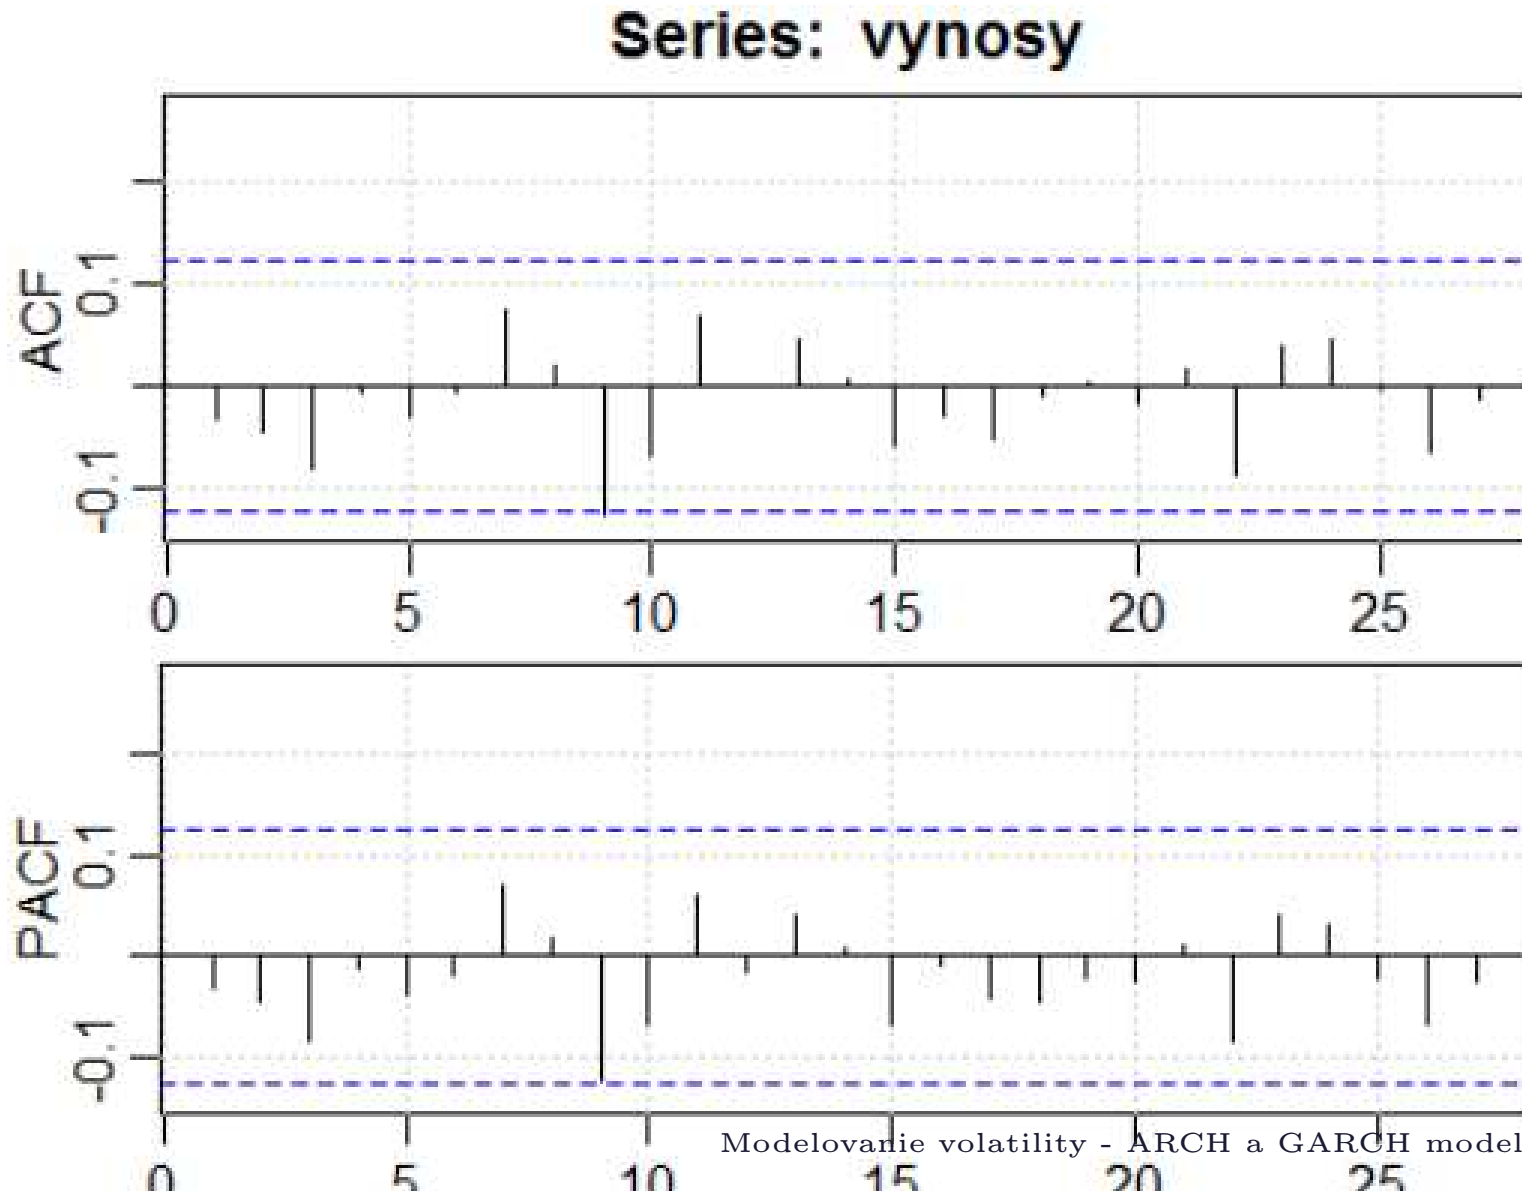
$$vynost_t = c + u_t,$$

kde  $u$  je biely šum

# Výnosy akcií: naše dáta

---

- Podľa ACF by to mohol byť biely šum



# Výnosy akcií: naše dáta

---

- Výnosy modelujeme bielym šumom:

```
12 model1<-sarima(vynosy,0,0,0, details=FALSE)
13 acf2(model1$fit$residuals) # to iste ako acf2(vynosy) -> ok
14 acf2(model1$fit$residuals^2) # -> PROBLEM
```


→ rezíduá sú výnosy posunuté o konštantu

- Ak je absolútna hodnota rezídua malá, tak väčšinou nasleduje rezíduum tiež s malou absolútnou hodnotou
- Podobne za rezíduom s veľkou absolútnou hodnotou nasleduje často rezíduum s veľkou absolútnou hodnotou - môže byť kladné aj záporné, preto sa táto vlastnosť na autokorelácii neprejavila
- **Druhé mocniny budú zrejme korelované** (pre biely šum to ale neplatí)

# Výnosy akcií: naše dáta

---

- Autokorelácia **druhých mocnín:**



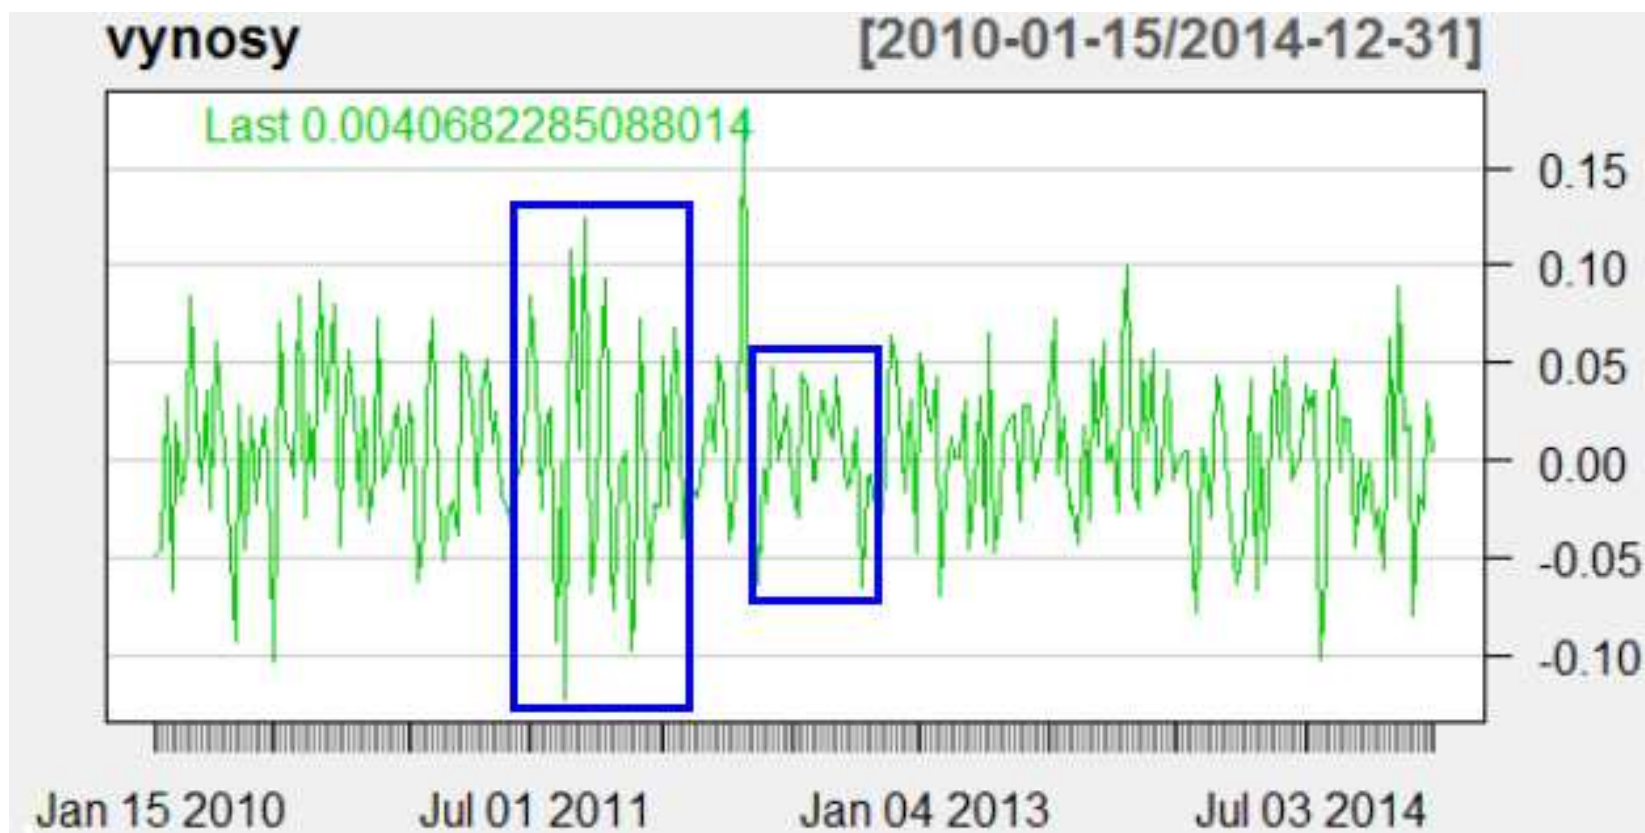
→ **signifikantná autokorelácia**

- OTÁZKA:  
**Aký model dokáže zachytiť takéto vlastnosti?**

# Výnosy akcií: naše dáta

---

- Možné vysvetlenie: **nekonštatná disperzia**





# ARCH a GARCH modely

---

- $u$  nie je biely šum, ale

$$u_t = \sqrt{\sigma_t^2} \eta_t,$$

kde  $\eta$  je biely šum s jednotkovou disperziou; teda

$$u_t \sim N(0, \sigma_t^2)$$

- **ARCH model** (autoregressive conditional heteroskedasticity) - rovnica pre disperziu  $\sigma_t^2$ :

$$\sigma_t^2 = \omega + \alpha_1 u_{t-1}^2 + \dots + \alpha_q u_{t-q}^2$$

- **Ohraničenia na parametre:**

- ◇ na zabezpečenie kladnosti disperzie:

$$\omega > 0, \alpha_1, \dots, \alpha_{q-1} \geq 0, \alpha_q > 0$$

- ◇ kvôli stacionarite:

$$\alpha_1 + \dots + \alpha_q < 1$$

# ARCH a GARCH modely

---

- Nevýhody ARCH modelov:
  - ◇ malý počet členov  $u_{t-i}^2$  často nestačí - vo štvorcoch rezíduí je stále autokorelácia
  - ◇ pri väčšom počte členov sú koeficienty často nesignifikantné alebo nespĺňajú uvedené ohraničenia na parametre
- Zovšeobecnenie: **GARCH modely** - odstraňujú tieto problémy

# ARCH a GARCH modely

---

- **GARCH(p,q) model** (generalized autoregressive conditional heteroskedasticity) rovnica pre disperziu  $\sigma_t^2$ :

$$\sigma_t^2 = \omega + \alpha_1 u_{t-1}^2 + \dots + \alpha_q u_{t-q}^2 + \beta_1 \sigma_{t-1}^2 + \dots + \beta_p \sigma_{t-p}^2$$

- **Ohraničenia na parametre:**
  - ◇ na zabezpečenie kladnosti disperzie:

$$\omega > 0, \alpha_1, \dots, \alpha_{q-1} \geq 0, \alpha_q > 0$$

$$\beta_1, \dots, \beta_{p-1} \geq 0, \beta_p > 0$$

- ◇ kvôli stacionarite:

$$(\alpha_1 + \dots + \alpha_q) + (\beta_1 + \dots + \beta_p) < 1$$

- Často sa používa **GARCH(1,1)**

# *GARCH modely v R-ku*

---

- Modelovanie výnosov YHOO - pokračovanie
- V R-ku:
  - ◇ knižnica `fGarch`
  - ◇ funkcia `garchFit`, model sa píše v tvare napr.  
`arma(1,1)+garch(1,1)`
  - ◇ parametrom `trace=FALSE` zrušíme vypisovanie podrobností ohľadom konvergenencie optimalizačného procesu
- Odhadujeme model **konštanta + šum**; na modelovanie šumu skúsime **ARCH/GARCH modely**

# ARCH(1)

---

- Odhadovanie ARCH(1) modelu:

```
16 # arch(1) = garch(1,0)
17 model10 <- garchFit(~garch(1,0), data=vynosy, trace=FALSE)
18 stand.rez <- model10@residuals/model10@sigma.t # standardizovane rezidua
19 acf2(stand.rez)
20 acf2(stand.rez^2)
21 summary(model10)
```

- Zobrazíme teda:
  1. ACF štandardizovaných rezíduí
  2. ACF štandardizovaných druhých mocnín rezíduí
  3. `summary` s testami o štandardizovaných rezíduách a ich druhých mocninách

# *GARCH modely v R-ku*


---

- Prístup k užitočným hodnotám:
  - ◇ `@fitted` - fitované hodnoty
  - ◇ `@residuals` - rezíduá
  - ◇ `@h.t` - odhadnutá variancia
  - ◇ `@sigma.t` - odhadnutá štandardná odchýlka
- Štandardizované rezíduá - rezíduá vydelené ich štandardnou odchýlkou - majú byť bielym šumom
- Takisto ich druhé mocniny majú byť bielym šumom

# ARCH(1)

---


- Rezíduá:



# ARCH(1)

---

- Druhé mocniny:





# Testovanie rezíduí

---

- Testy:

## Standardised Residuals Tests:

			Statistic	p-Value
Jarque-Bera Test	R	Chi <sup>2</sup>	29.18907	4.588523e-07
Shapiro-Wilk Test	R	W	0.9821336	0.002392983
Ljung-Box Test	R	Q(10)	12.29485	0.2658079
Ljung-Box Test	R	Q(15)	21.08263	0.1342099
Ljung-Box Test	R	Q(20)	28.34245	0.1015375
Ljung-Box Test	R <sup>2</sup>	Q(10)	27.55866	0.002123322
Ljung-Box Test	R <sup>2</sup>	Q(15)	44.23218	0.0001011277
Ljung-Box Test	R <sup>2</sup>	Q(20)	46.02944	0.0007985573
LM Arch Test	R	TR <sup>2</sup>	25.98164	0.01079828

- Je tu: testovanie normality, Ljung-Box pre štandardizované rezíduá a ich druhé mocniny
- Čo je nové: testovanie homoskedasticity v týchto rezíduách

# ARCH(2)

---

- Skúsime ARCH(2) - výsledky testov:

## Standardised Residuals Tests:

			Statistic	p-Value
Jarque-Bera Test	R	Chi <sup>2</sup>	34.65834	2.978778e-08
Shapiro-Wilk Test	R	W	0.9814854	0.001841151
Ljung-Box Test	R	Q(10)	10.75724	0.3767411
Ljung-Box Test	R	Q(15)	19.54396	0.1901334
Ljung-Box Test	R	Q(20)	26.93409	0.1371285
Ljung-Box Test	R <sup>2</sup>	Q(10)	14.11704	0.1677196
Ljung-Box Test	R <sup>2</sup>	Q(15)	27.9337	0.02198778
Ljung-Box Test	R <sup>2</sup>	Q(20)	30.13048	0.06776678
LM Arch Test	R	TR <sup>2</sup>	20.09535	0.06530357

# ARCH(3)

---

- ARCH(3) - výsledky testov:

## Standardised Residuals Tests:

			Statistic	p-Value
Jarque-Bera Test	R	Chi <sup>2</sup>	33.88186	4.391851e-08
Shapiro-Wilk Test	R	W	0.9816512	0.001968254
Ljung-Box Test	R	Q(10)	10.70552	0.3809165
Ljung-Box Test	R	Q(15)	19.44674	0.1941989
Ljung-Box Test	R	Q(20)	26.77638	0.1416733
Ljung-Box Test	R <sup>2</sup>	Q(10)	14.01256	0.1724194
Ljung-Box Test	R <sup>2</sup>	Q(15)	27.74511	0.02322011
Ljung-Box Test	R <sup>2</sup>	Q(20)	29.97015	0.07033882
LM Arch Test	R	TR <sup>2</sup>	20.00903	0.06691536

# ARCH(4)

---

- ARCH(4) - výsledky testov:

## Standardised Residuals Tests:


			Statistic	p-Value
Jarque-Bera Test	R	Chi <sup>2</sup>	12.79082	0.001669201
Shapiro-Wilk Test	R	W	0.9880808	0.0302226
Ljung-Box Test	R	Q(10)	10.54746	0.3938435
Ljung-Box Test	R	Q(15)	18.98255	0.2145258
Ljung-Box Test	R	Q(20)	26.02379	0.1650277
Ljung-Box Test	R <sup>2</sup>	Q(10)	14.41393	0.1549343
Ljung-Box Test	R <sup>2</sup>	Q(15)	21.97894	0.1083574
Ljung-Box Test	R <sup>2</sup>	Q(20)	23.88737	0.2473466
LM Arch Test	R	TR <sup>2</sup>	18.14053	0.1114896

- V rezíduách ani ich druhých mocninách už nie je autokorelácia.

# ARCH(4)

---

- ACF druhých mocnín:



→ bez signifikantnej autokorelácie

# ARCH(4)

---

- Ale ARCH koeficienty  $\alpha_i$  nie sú signifikantné:

Error Analysis:

	Estimate	Std. Error	t value	Pr(> t )	
mu	4.022e-03	2.433e-03	1.653	0.0983	.
omega	1.170e-03	2.003e-04	5.842	5.16e-09	***
alpha1	3.839e-02	1.250e-01	0.307	0.7587	
alpha2	1.259e-01	8.058e-02	1.563	0.1181	
alpha3	1.000e-08	1.475e-01	0.000	1.0000	
alpha4	1.098e-01	8.052e-02	1.364	0.1726	

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

# GARCH(1,1)

---

- Skúsme GARCH(1,1):

```
44 # garch(1,1)
45 model11 <- garchFit(~garch(1,1), data=vynosy, trace=FALSE)
46 stand.rez <- model11@residuals/model11@sigma.t # standardizovane rezidua
47 acf2(stand.rez)
48 acf2(stand.rez^2)
49 summary(model11)
50
```

- Testy:

## Standardised Residuals Tests:

			Statistic	p-Value
Jarque-Bera Test	R	Chi <sup>2</sup>	11.47005	0.003230806
Shapiro-Wilk Test	R	W	0.987312	0.02152423
Ljung-Box Test	R	Q(10)	10.26988	0.4171434
Ljung-Box Test	R	Q(15)	17.86043	0.2700744
Ljung-Box Test	R	Q(20)	23.83093	0.2498554
Ljung-Box Test	R <sup>2</sup>	Q(10)	9.549341	0.4808792
Ljung-Box Test	R <sup>2</sup>	Q(15)	17.0167	0.3178669
Ljung-Box Test	R <sup>2</sup>	Q(20)	19.01346	0.5209512
LM Arch Test	R	TR <sup>2</sup>	12.16882	0.4322184

# GARCH(1,1)

---

- Odhadnuté koeficienty:

Error Analysis:

	Estimate	Std. Error	t value	Pr(> t )
mu	3.262e-03	2.351e-03	1.388	0.1652
omega	2.428e-05	3.596e-05	0.675	0.4994
alpha1	4.334e-02	2.401e-02	1.805	0.0711 .
beta1	9.396e-01	3.923e-02	23.954	<2e-16 ***

---


Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1



# Odhadnutá štandardná odchýlka

---

- Vieme ju získať pomocou `@sigma.t` :



# Odhadnutá štandardná odchýlka

---

- Iný prístup k niektorým grafom - `plot(model11)`:

```
> plot(model11)
```

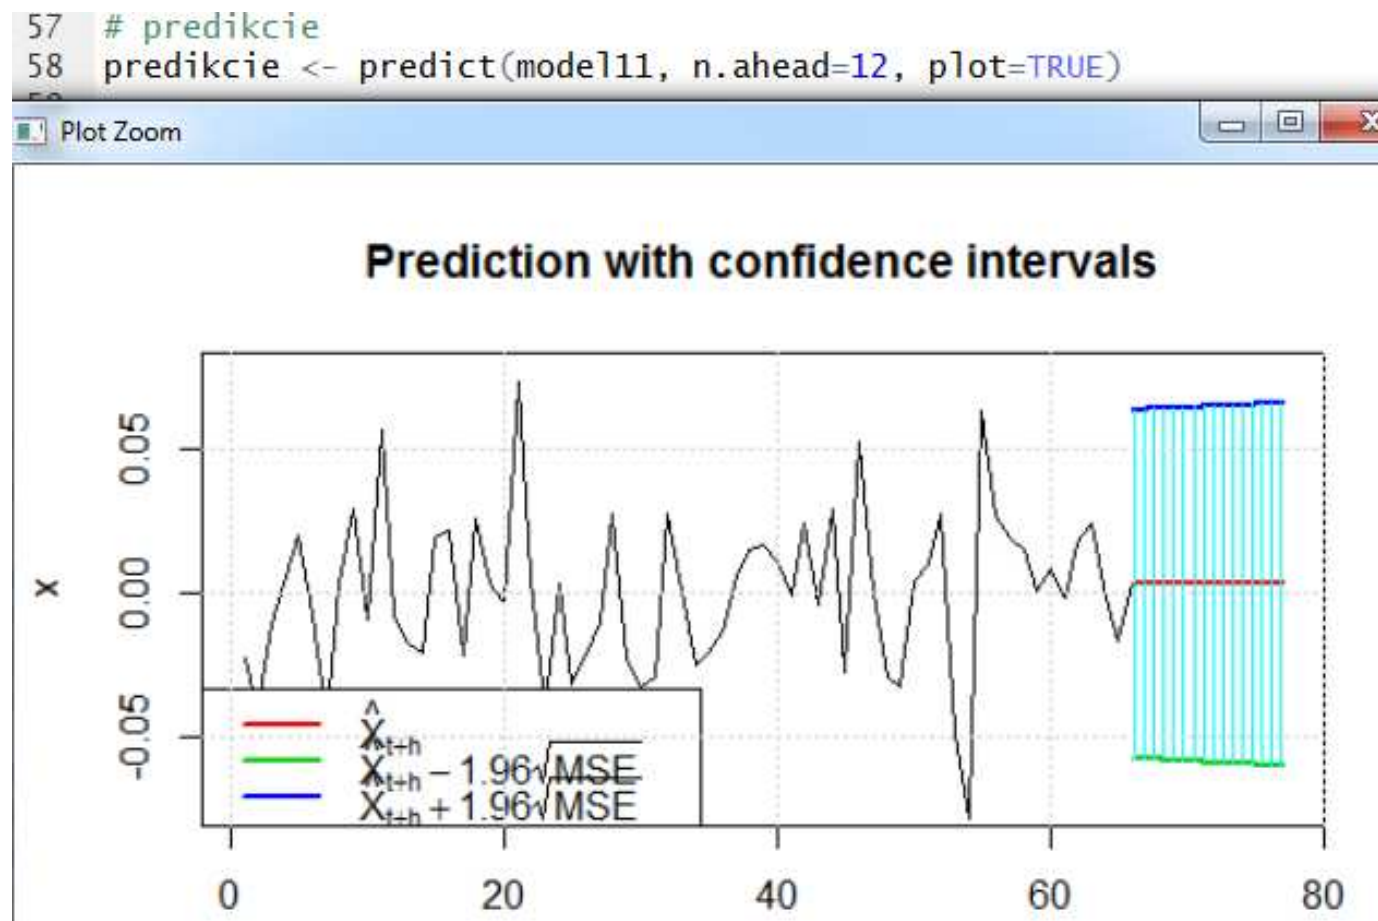
```
Make a plot selection (or 0 to exit):
```

```
1:  Time Series
2:  Conditional SD
3:  Series with 2 Conditional SD Superimposed
4:  ACF of Observations
5:  ACF of Squared Observations
6:  Cross Correlation
7:  Residuals
8:  Conditional SDs
9:  Standardized Residuals
10: ACF of Standardized Residuals
11: ACF of Squared Standardized Residuals
12: Cross Correlation between  $r^2$  and  $r$ 
13: QQ-Plot of Standardized Residuals
```

```
Selection: |
```

# Predikcie

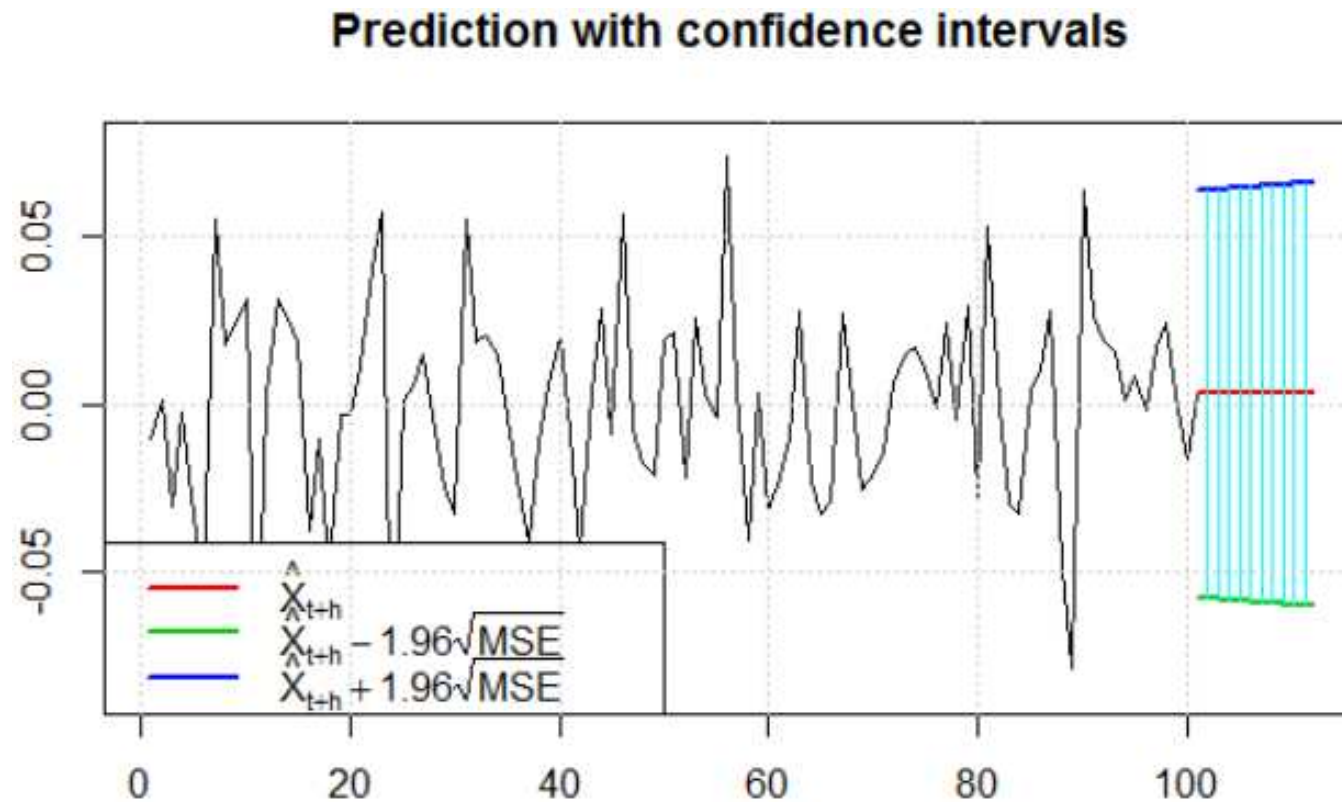
- Predikcie pomocou funkcie `predict`; parameter `n.ahead` určuje počet períód



# Predikcie

---


- Parameterom  $nx$  vieme zmeniť počet periód z dát, ktoré sa vykreslia (teraz  $nx=100$ ):



# Predikcie

---


- Predikovaný vývoj štandardnej odchýlky:



# Predikcie

---

- Predikovaný vývoj štandardnej odchýlky pre dlhšie obdobie - čomu sa rovná limita?



# Aplikácia: Value at risk (VaR)

---

- Value at risk (VaR) je vlastne kvantil
- Nech  $X$  je hodnota portfólia; potom

$$\mathcal{P}(X \leq VaR) = \alpha,$$

napr. pre  $\alpha = 0.05$

- Štandardne GARCH predpokladá normálne rozdelenie (dajú sa odhadovať aj iné rozdelenia) - vieme počítat kvantily
- Nedostatky:
  - ◇ predpoklad normality
  - ◇ sú aj lepšie miery rizika ako VaR

# *Aplikácia: Value at risk (VaR)*

---

- NA CVIČENÍ:
  - ◇ Začneme po  $N$  hodnotách výnosov
  - ◇ Odhadneme GARCH model.
  - ◇ Spravíme predikciu pre štandardnú odchýlku a pomocou nej zostrojíme  $VaR$  pre výnos na nasledujúci týždeň
  - ◇ Každý týždeň posunieme okno s dátami (máme nové pozorovanie) odhadneme znovu GARCH a vypočítame nové  $VaR$



# Iné modely pre volatilitu

---

- **Threshold GARCH:**
  - ◇  $u_t > 0$  - "good news",  $u_t < 0$  - "bad news"
  - ◇ TARARCH umožňuje, aby mali na volatilitu rôzny vplyv
  - ◇ *leverage effect*: väčší vplyv na volatilitu majú *bad news*
- Nemodelujeme disperziu (ako v ARCH/GARCH modeloch), ale
  - ◇ jej logaritmus → **exponential GARCH**
  - ◇ ľubovoľnú mocninu štandardnej odchýlky → **power GARCH**
- a ďalšie...