

Jihočeská univerzita v Českých Budějovicích
Ekonomická fakulta
Katedra účetnictví a financí

Teze bakalářské práce

Analýza finančních časových řad v době krize

Vypracoval: Lukáš Průdek

Vedoucí práce: Mgr. Michal Houda, Ph. D

České Budějovice

2023

Klíčová slova: časové řady, burzovní indexy, Boxova-Jenkinsova metodologie, období krize

Anotace: V rámci této práce se budeme zabývat analýzou finančních časových řad v době krize a před. Tyto řady budou analyzovány za pomoci Boxovi-Jenkinsovi metodiky. Cílem je pochopení této metody a její následná aplikace na ceny burzovních indexů DAX a PX. Hodnoty burzovního indexu DAX byly sestaveny Frankfurtskou burzou cenných papírů a hodnoty index PX byly sestaveny Burzou cenných papírů Praha. Pokusím se o tvorbu modelů, které dokážou dané řady spolehlivě pospat pro následnou tvorbu predikcí v rámci dílčích období. Tyto modely a z nich vytvořené predikce budou následně využity při porovnání změn v chování časových řad.

Úvod a přehled literatury

Jelikož jsou ekonomiky České republiky a Spolkové republiky Německo relativně silně provázány (pro Českou republiku je Spolková republika Německo jedním z nejdůležitějších obchodních partnerů), usoudil jsem, že bych mohl dosáhnout zajímavých závěrů srovnáním finančních trhů těchto dvou zemí a převážně dopad a reakce na krizi.

Cíl práce

Bakalářská práce Analýza finančních časových řad v době krize se zabývá problematikou modelování úrovnových ARIMA modelů ve finančních časových řadách. Teoretická část pojednává o hospodářském cyklu, jeho fázích a výkyvech. Dále přibližuje problematiku finančních krizí a v poslední řadě definuje základní předpoklady a postup při konstrukci úrovnových ARIMA modelů.

V praktické části je snaha o vybudování vhodných úrovnových ARIMA modelů, které nejlépe vystihují sledované ceny burzovních indexů DAX a PX. Pro práci jsou stanoveny dva předpoklady. Prvním předpokladem jsou změny v úrovnových ARIMA modelech, způsobené působením krizových šoků na vývoj burzovních indexů DAX a PX. Druhým předpokladem je, že úrovnové ARIMA modely popisující vývoj burzovních indexů budou na základě předem stanovených kritérií přesněji odpovídat časovým řadám indexů v období před krizí než v období krize. Nalezené modely budou využity k předpovědím budoucího chování trhu a k vyhodnocení jejich spolehlivosti.

Metodika

Při konstrukci ARIMA modelů jsem postupoval na základě sestavených ACF a PACF pozorovaných časových řad.

Stacionaritu jsem v praktické části hodnotil:

- Dle průběhu časové řady

Je-li z grafu vykreslující vývoj časové řady zřetelné, že řada obsahuje výrazný trend, konkrétní časová řada nemůže být stacionární, jelikož trend způsobuje, že časová řada nekonverguje ke konstantní nepodmíněné střední hodnotě.

- Dle autokorelační a parciálně autokorelační funkce

Jestli že se hodnoty autokorelační a parciálně autokorelační funkce blíží k nule pouze velmi pomalu, daná časová řada není stacionární.

- Dle testu jednotkových kořenů

Testy jednotkových kořenů slouží k odstranění subjektivního charakteru určování řádu diferencování. V tomto případě bude využit Dickey-Fullerův test (dále jen DF-test) a Kwiatkowski–Phillips–Schmidt–Shin test (dále jen KPSS-test)

DF-test je založen na testování nulové hypotézy o stacionaritě časové řady reprezentované procesem náhodné procházky H_0 : o existenci nulového kořene proti alternativě H_A : není H_0 .

Pokud má řada podobu striktně bílého lze pro ni použít DF-test. Když tomu tak není, je vhodné použít rozšířený DF-test, jehož testová statistika a kritické hodnoty zůstávají stejné, ale testem ověřujeme nulovou hypotézu, kde časová řada je tvaru $AR(p)$ s obsahem jednotkového kořene, oproti alternativě, že přítomen není.

KPSS-test řeší občasnou slabou vypovídací schopnost ADF-testu. KPSS-test má proto nulovou hypotézu v podobě alternativní hypotézy ADF-testu a je testovaná proti alternativní hypotéze reprezentující nestacionaritu časové řady.

Časovou řadu jsem považoval za stacionární pouze v případě, že ADF-test nulovou hypotézu zamítne a KPSS-test nulovou hypotézu nezamítne. Pokud předpoklad stacionární časové řady není splněn, transformuje se řada pomocí prvních či vyšších diferencí a takto upravená řada se pak nazývá integrovaná a řád d její integrace se v ARIMA modelu značí pomocí $I(d)$.

Po splnění podmínek stacionarity byla úroveň autoregresního modelu $AR(p)$ závislá na počtu statisticky významných koeficientů výběrové PACF a stejně tak úroveň modelu klouzavých průměrů $MA(q)$ byla odvozena od počtu statisticky významných koeficientů výběrové ACF. Z těchto vybraných modelů se zvolí ty nejvhodnější na základě hodnot informačních kritérií. Tato informační kritéria slouží k nalezení nejvhodnějšího úrovnového modelu $ARMA(p, q)$, pro které se posuzuje jejich hodnota reziduálního součtu čtverců a zároveň penalizují model s příliš velkým počtem regresorů..

Mezi nepoužívanější se řadí Akaikeho a Bayesovské informační kritérium, mezi kterými si lze vybrat v závislosti na požadavku konzistentnosti modelu pro BIC nebo vydatnosti modelu pro AIC.

Věřohodnost získaných modelů jsem poté kontroloval:

- Na základě výběrové ACF a PACF funkce.

Nulová hypotéza vypovídá o nepřítomnosti autokorelace mezi rezidui $\hat{\varepsilon}_t$ a $\hat{\varepsilon}_{t-k}$ na 95% intervalu spolehlivosti zamítnuta ve prospěch alternativní hypotézy o přítomnosti autokorelace.

- Na základě hodnoty Q statistiky: Ljung-Boxův test

L-B test testuje nulovou hypotézu o nevýznamnosti prvních K autokorelací reziduí ve tvaru $H_0: \rho_1 = \rho_2 = \dots = \rho_K = 0$ oproti alternativní hypotéze $H_1: \text{non } H_0$.


- Na základě inverzního jednotkového kruhu kořenů

Podmínky stacionarity pro model jsou že komplexní kořeny $\varphi(B)$ leží mimo jednotkový kruh a podmínky invertibility pro model jsou že komplexní kořeny $\theta(B)$ leží mimo jednotkový kruh. Tímto je možné vidět, jak blízko je model k invertibilitě nebo stacionaritě pomocí vykreslení jeho kořenů ve vztahu s komplexním jednotkovým kruhem. Je však jednodušší vykreslit podobu inverzních kořenů, které by naopak měli ležet uvnitř jednotkového kruhu, pro které však platí, že kořeny nalézající se poblíž středu jednotkového kruhu mohou být numericky nestabilní a jejich modely jsou tedy nevhodné pro tvorbu predikcí.

Nakonec se tyto otestované modely použili pro tvorbu predikcí a predikčních intervalů a celý tento proces byl porovnán mezi jednotlivými obdobími.

Výsledky

Graf 1: Ceny burzovních indexů DAX a PX




Zdroj: vlastní zpracování dle www.investing.com

Při pohledu na obě řady bylo patrné, že jsou tyto dvě řady na sebe silně vázány, což potvrzuje silný korelační koeficient 0,825. Může se zde nacházet vnější proměnná, která na obě řady působí velice podobným způsobem. Pro oba modely je možné říci, že rozdílnost v chování těchto řad v období před krizí a během krize značně ovlivní úspěšnost vytvořených modelů. Přesto je tedy možné říci, že podle předem stanovených kritérií sledovanou řadu indexu DAX v rámci celého období nejlépe vystihoval model $ARIMA(0, 1, 2)$, jehož hodnota AICc vycházela o pouhou 1 setinu jednotky lépe oproti následujícímu, tedy jsou téměř srovnatelné. Pro sledovanou řadu PX v rámci celého období jsem za nevhodnější model usoudil $ARIMA(2, 1, 2)$, pro který hodnota AICc vyšla o více než 2 celé jednotky méně a z hledaných modelů se považoval za jednoznačně nejvhodnější.

Tato skutečnost je ještě více viditelná při tvorbě predikcí. Pro vybrané modely jsem vytvořil predikce jdoucí 20 pozic do budoucnosti, což by v našem případě představovalo 20 dní, a tedy téměř jeden pracovní měsíc. Zde je vidět, jak velice podobné a až téměř totožné jsou nalezené modely popisující řadu indexu DAX. Z predikčních grafů vytvořených na základě modelů řady DAX bylo viditelné, že jsou naprosto totožné a tuto skutečnost potvrdila i tabulka obsahující výpis hodnot z těchto predikcí, viditelný v tabulce Příloha 1. V této tabulce bylo zřetelné, že odhadnuté hodnoty předpovědí z modelů indexu DAX byly identické, a to samé platilo pro jejich predikční intervaly na hladině 80 %, které jsem v práci uvedl jako procentní vzdálenost od hodnot časové řady.

Z těchto poměrů predikčních intervalů bylo zřejmé, že nalezený úrovnový model vysvětlující řadu indexu PX byl pro potřeby predikcí spolehlivější a především vhodnější. O tom vypovídal značně pomalejší růst tohoto intervalu, který byl tedy užší.

Graf 2: Ceny burzovních indexů DAX a PX v období před krizí




Zdroj: vlastní zpracování dle www.investing.com

Při analýze těchto řad bylo patrné, jak moc se během krize změnilo jejich chování. Tato skutečnost byla prokazatelně viditelná při nalézání vhodných modelů za pomoci hodnot AICc. Pro oba indexy platilo, že vypočtené hodnoty se pohybovaly v mnohem nižších hladinách a v obou případech se snížili téměř na polovinu. Oproti řadě sledované v rámci celého období se pro cenovou řadu indexu DAX v období před krizí změnil na základě stanovených kritérií z úrovnového modelu $ARIMA(0, 1, 2)$ na model $ARIMA(2, 1, 2)$ s konstantou $c = 4,675$. Oproti tomu si úrovnový model cenové řady indexu PX v předkrizovém období zachoval svou podobu $ARIMA(2, 1, 2)$ a vykazuje tím i vyzorovanou podobnost těchto dvou řad v tomto období.

Na základě všech stanovených kritérií byl pro řadu DAX v tomto období jako nejvhodnější model vyhodnocen $ARIMA(2, 1, 2)$ s konstantou $c = 4,675$, avšak z tabulky Příloha 2 bylo patrné, že predikční interval na úrovni 80% spolehlivosti se od osmé predikce začíná rozšiřovat pomaleji. Z toho by bylo možné vyvodit, že navzdory míram AICc a BIC by model $ARIMA(5, 1, 0)$ mohl být pro tvorbu predikcí spolehlivější.

Graf 3: Ceny burzovních indexů DAX a PX v období během krize



Zdroj: vlastní zpracování dle www.investing.com

Jak je vidět na Grafu 3 ceny indexu DAX po začátku krize velice rychle vzrostly a před druhým krizovým šokem se byly schopny necelý rok držet na stálé výši mezi 15 a 16 tisíci. Oproti tomu cenám indexu PX trvalo téměř dva roky dosáhnout srovnatelného nárůstu, než po svém maximu opět začal padat vinou krizového šoku.

Ačkoli se zde nachází tyto nepředvídatelné šoky, které drasticky ovlivnily chování těchto řad, výše hodnot AICc a BIC by svou velikostí (respektive poklesem) nasvědčovaly, že nalezené úrovně modely dokáží řady v tomto období popsat mnohem lépe. Přesněji řečeno model ARIMA(3, 1, 3), který jsem vyhodnotil za nejvhodnější pro vysvětlení cen indexu DAX v období krize, je podle AICc o 41 % úspěšnější. To samé lze říci pro model ARIMA(2, 1, 0), který popisuje chování řady cen indexu PX v období krize a je podle AICc o 30 % úspěšnější než nejvhodnější model v klidné době před krizí.

Avšak z pohledu na tabulku Příloha 3 bylo patrné, že ze všech sledovaných období byly predikční modely během krize nejméně spolehlivé a z nich vytvořené predikční intervaly dosahují nejvyšších hodnot.

Závěr

Bakalářská práce Analýza finančních časových řad v době krize se zabývala analýzou časových řad burzovních indexů DAX a PX v období od roku 2015 do května 2023. Na základě Boxovy-Jenkinsovy metodologie byly vytvořeny úroňové ARIMA modely se snahou sestavení modelů s nejlepší vypovídací schopností. Dopad ekonomické krize se v rámci této práce projevil změnou v jejich vypovídací schopnosti, což bylo viditelné za pomoci změn hodnot AICc. Vypovídací schopnost úroňových modelů se při pohledu na dílčí časové řady téměř zdvojnásobila, což vykazuje o prokazatelné změně chování burzovních indexů v období krize. Tomu nasvědčuje i vývoj predikčních intervalů vytvořených na základě těchto úroňových modelů. Rozpětí jejich predikčních intervalů se měnila v závislosti na sledovaném období.

Nejvhodnějšími modely v rámci celého sledované období se pro burzovní index DAX ukázal být úroňový model $ARIMA(0, 1, 2)$ a pro burzovní index PX vystihl model $ARIMA(2, 1, 2)$. Z tvorby predikčních intervalů bylo viditelné, že přesnost vytvořených modelů byla znatelně vyšší pro model burzovního indexu PX, jehož predikční interval se rozšiřoval pomaleji.

Dopad krize na změnu chování sledovaných indexů v rámci celé řady se projevil již při jejich analýze v období před krizí. Pro oba tyto indexy byl nalezený model stejného řádu a to $ARIMA(2, 1, 2)$, který se lišil pouze v existenci konstanty v modelu indexu DAX. Tato skutečnost dokládá provázanost těchto indexů a celkové ekonomiky České republiky a Spolkové republiky Německo. Jelikož se úroňový model řady PX v období před krizí oproti celému období nezměnil, dokládá to o slabším působení krizových šoků na chování indexu PX oproti indexu DAX. Toto období bylo charakteristické nejpřesnějšími predikcemi, jejichž predikční intervaly se jeví jako nejužší.

Ačkoli se v období krize nacházejí nepředvídatelné šoky, které drasticky ovlivnily chování časových řad pozorovaných indexů, výše hodnot informačních kritérií nasvědčují, že nalezené úroňové modely dokáží řady v tomto období popsat ze všech období nejlépe. Model $ARIMA(3, 1, 3)$, který náleží burzovnímu indexu DAX v období krize, byl na základě informačních kritérií o 41% přesnější než úroňový model v období před krizí. Stejná situace nastala i pro úroňový model indexu PX, a to pro model $ARIMA(2, 1, 0)$, který vykazoval o 30% lepší výsledky, než dokázal úroňový model v období před krizí. Přesnost při tvorbě predikcí za pomoci těchto modelů však oproti ostatním obdobím značně poklesla, o čemž

vypovídá rozsah vytvořených predikčních intervalů, který byl oproti ostatním obdobím nejvzdálenější od sledované řady.

Seznam literatury použité v tezích

Cipra, T. (2013). *Finanční ekonomie* (2. upravené vyd.). Ekopress.

Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: principles and preactices*. 3rd edition OTexts: Melbourne, Australia. OTexts.com/fpp3. Accessed on May 2023.

Wooldridge, J. (2012). *Introductory econometrics: a modern approach*. Fifth edition, student edition. Boston: Cengage Learning.

Investing.com (2023, květen). *PX Historical data*. <https://www.investing.com/indices/px-historical-data>

Další bibliografické údaje

Type of thesis: bachelor

Author: Lukáš PRŮDEK

Academic Year: 2022/2023

Department: Faculty of Economics, University of South Bohemia in Ceske Budejovice, Czech Republic

Thesis supervisor: Mgr. Michal HOUDA, Ph. D

Number of pages:

Language of thesis: CZ

Title of Thesis: Financial time series analysis in times of crisis

Annotation: In this thesis, we will analyze financial time series during and before the crisis. These series will be analyzed using the Box-Jenkins methodology. The aim is to understand this method and then apply it to the prices of the DAX and PX stock indices. The DAX stock index values were compiled by the Frankfurt Stock Exchange and the PX index values were compiled by the Prague Stock Exchange. I will attempt to build models that can reliably describe the series in question for subsequent forecasting over sub-periods. These models and the predictions made from them will then be used to compare changes in time series behaviour.

Key words: time series, stock market indices, Box-Jenkins methodology, crisis period

Přílohy vázané v práci:

**Příloha 1: Predikční intervaly vhodných modelů pro celé období na 80% úrovni
spolehlivosti**

h	DAX ARIMA(2, 1, 0)				DAX ARIMA(0, 1, 2)				PX ARIMA(2, 1, 2)			
	mean	horní	dolní	% interval	mean	horní	dolní	% interval	mean	horní	dolní	% interval
1	16 051	16 247,6	15 854,8	1,2%	16 051	16 247,5	15 854,6	1,2%	1 316	1 329,2	1 302,9	1,0%
2	16 055	16 330,1	15 779,3	1,7%	16 055	16 330,2	15 779,4	1,7%	1 318	1 336,5	1 299,2	1,4%
3	16 055	16 393,0	15 716,3	2,1%	16 055	16 393,2	15 716,5	2,1%	1 319	1 342,4	1 295,7	1,8%
4	16 055	16 446,0	15 663,5	2,4%	16 055	16 446,1	15 663,5	2,4%	1 319	1 346,1	1 291,1	2,1%
5	16 055	16 492,6	15 616,9	2,7%	16 055	16 492,7	15 616,9	2,7%	1 317	1 348,5	1 286,3	2,4%
6	16 055	16 534,7	15 574,8	3,0%	16 055	16 534,8	15 574,8	3,0%	1 317	1 350,8	1 282,6	2,6%
7	16 055	16 573,4	15 536,1	3,2%	16 055	16 573,5	15 536,1	3,2%	1 317	1 353,7	1 280,3	2,8%
8	16 055	16 609,4	15 500,1	3,5%	16 055	16 609,5	15 500,1	3,5%	1 318	1 357,0	1 278,7	3,0%
9	16 055	16 643,1	15 466,3	3,7%	16 055	16 643,3	15 466,3	3,7%	1 318	1 359,9	1 276,7	3,2%
10	16 055	16 675,1	15 434,4	3,9%	16 055	16 675,3	15 434,3	3,9%	1 318	1 362,0	1 274,1	3,3%
11	16 055	16 705,5	15 404,0	4,1%	16 055	16 705,7	15 403,9	4,1%	1 317	1 363,7	1 271,3	3,5%
12	16 055	16 734,5	15 374,9	4,2%	16 055	16 734,8	15 374,9	4,2%	1 317	1 365,5	1 269,0	3,7%
13	16 055	16 762,4	15 347,1	4,4%	16 055	16 762,6	15 347,0	4,4%	1 317	1 367,6	1 267,2	3,8%
14	16 055	16 789,1	15 320,3	4,6%	16 055	16 789,4	15 320,2	4,6%	1 318	1 369,8	1 265,7	3,9%
15	16 055	16 815,0	15 294,5	4,7%	16 055	16 815,3	15 294,4	4,7%	1 318	1 371,8	1 264,0	4,1%
16	16 055	16 840,0	15 269,5	4,9%	16 055	16 840,3	15 269,4	4,9%	1 318	1 373,5	1 262,0	4,2%
17	16 055	16 864,2	15 245,3	5,0%	16 055	16 864,5	15 245,1	5,0%	1 318	1 375,0	1 260,1	4,3%
18	16 055	16 887,7	15 221,7	5,2%	16 055	16 888,0	15 221,6	5,2%	1 317	1 376,6	1 258,3	4,5%
19	16 055	16 910,6	15 198,9	5,3%	16 055	16 910,9	15 198,7	5,3%	1 318	1 378,3	1 256,8	4,6%
20	16 055	16 932,9	15 176,6	5,5%	16 055	16 933,2	15 176,5	5,5%	1 318	1 380,1	1 255,3	4,7%

Zdroj: vlastní zpracování

**Příloha 2: Predikční intervaly vhodných modelů pro období před krizí na 80% úrovni
spolehlivosti**

h	DAX ARIMA(2, 1, 2)				DAX ARIMA(5, 1, 0)				PX ARIMA(2, 1, 2)			
	mean	horní	dolní	% interval	mean	horní	dolní	% interval	mean	horní	dolní	% interval
1	13 000	13 157,7	12 841,7	1,2%	12 996	13 153,9	12 837,9	1,2%	1 074	1 083,4	1 063,9	0,9%
2	12 992	13 214,4	12 769,6	1,7%	12 986	13 208,9	12 763,5	1,7%	1 073	1 086,5	1 058,8	1,3%
3	12 989	13 258,4	12 718,7	2,1%	12 989	13 259,8	12 717,4	2,1%	1 073	1 089,8	1 056,2	1,6%
4	13 003	13 315,2	12 690,4	2,4%	13 005	13 320,3	12 690,5	2,4%	1 073	1 092,8	1 053,8	1,8%
5	12 998	13 347,1	12 648,4	2,7%	13 011	13 361,2	12 661,7	2,7%	1 073	1 094,3	1 050,8	2,0%
6	12 995	13 376,4	12 613,3	2,9%	13 011	13 390,1	12 632,3	2,9%	1 073	1 097,1	1 049,5	2,2%
7	13 006	13 418,9	12 593,8	3,2%	13 012	13 418,1	12 605,8	3,1%	1 073	1 098,7	1 047,2	2,4%
8	13 003	13 444,5	12 562,1	3,4%	13 011	13 442,7	12 579,7	3,3%	1 073	1 100,3	1 045,3	2,5%
9	13 001	13 468,3	12 533,7	3,6%	13 010	13 465,7	12 554,7	3,5%	1 073	1 102,5	1 044,1	2,7%
10	13 010	13 503,1	12 517,5	3,8%	13 010	13 488,5	12 531,5	3,7%	1 073	1 103,6	1 042,0	2,8%
11	13 009	13 525,7	12 491,7	4,0%	13 010	13 510,4	12 509,5	3,8%	1 073	1 105,3	1 040,8	3,0%
12	13 007	13 546,5	12 467,5	4,1%	13 010	13 531,5	12 488,4	4,0%	1 073	1 106,8	1 039,4	3,2%
13	13 015	13 576,2	12 452,8	4,3%	13 010	13 551,8	12 468,3	4,2%	1 073	1 107,9	1 037,7	3,3%
14	13 014	13 596,9	12 431,0	4,5%	13 010	13 571,3	12 448,8	4,3%	1 073	1 109,5	1 036,8	3,4%
15	13 013	13 615,9	12 409,6	4,6%	13 010	13 590,2	12 430,0	4,5%	1 073	1 110,6	1 035,3	3,5%
16	13 019	13 641,9	12 396,0	4,8%	13 010	13 608,5	12 411,7	4,6%	1 073	1 111,8	1 034,0	3,6%
17	13 019	13 661,4	12 376,9	4,9%	13 010	13 626,2	12 394,0	4,7%	1 073	1 113,2	1 033,0	3,7%
18	13 018	13 679,1	12 357,8	5,1%	13 010	13 643,4	12 376,8	4,9%	1 073	1 114,2	1 031,6	3,8%
19	13 024	13 702,4	12 344,8	5,2%	13 010	13 660,1	12 360,0	5,0%	1 073	1 115,4	1 030,7	4,0%
20	13 024	13 720,8	12 327,8	5,4%	13 010	13 676,5	12 343,7	5,1%	1 073	1 116,5	1 029,6	4,1%

Zdroj: vlastní zpracování

**Příloha 3: Predikční intervaly vhodných modelů pro období během krize na 80%
úrovni spolehlivosti**

h	DAX ARIMA(3, 1, 2)				PX ARIMA(5, 1, 0)			
	mean	horní	dolní	% interval	mean	horní	dolní	% interval
1	16 049	16 291,0	15 808,0	1,5%	1 316	1 332,9	1 298,9	1,3%
2	16 067	16 406,1	15 727,5	2,1%	1 318	1 342,7	1 293,9	1,9%
3	16 047	16 468,9	15 624,9	2,6%	1 318	1 349,5	1 287,3	2,4%
4	16 054	16 538,4	15 570,0	3,0%	1 319	1 355,3	1 281,9	2,8%
5	16 064	16 604,8	15 522,5	3,4%	1 319	1 360,3	1 277,0	3,1%
6	16 046	16 642,0	15 450,6	3,7%	1 319	1 364,7	1 272,7	3,5%
7	16 058	16 698,8	15 416,7	4,0%	1 319	1 368,7	1 268,6	3,8%
8	16 060	16 746,1	15 374,2	4,3%	1 319	1 372,5	1 264,9	4,1%
9	16 047	16 776,0	15 318,2	4,5%	1 319	1 375,9	1 261,4	4,3%
10	16 060	16 826,5	15 293,3	4,8%	1 319	1 379,2	1 258,1	4,6%
11	16 057	16 861,9	15 251,9	5,0%	1 319	1 382,3	1 255,0	4,8%
12	16 049	16 890,1	15 207,6	5,2%	1 319	1 385,3	1 252,1	5,0%
13	16 061	16 935,2	15 186,4	5,4%	1 319	1 388,2	1 249,2	5,2%
14	16 054	16 962,8	15 145,9	5,7%	1 319	1 390,9	1 246,5	5,5%
15	16 051	16 991,3	15 110,8	5,9%	1 319	1 393,5	1 243,9	5,6%
16	16 061	17 031,0	15 090,2	6,0%	1 319	1 396,1	1 241,3	5,8%
17	16 053	17 053,8	15 051,4	6,2%	1 319	1 398,5	1 238,8	6,0%
18	16 053	17 083,1	15 023,4	6,4%	1 319	1 400,9	1 236,5	6,2%
19	16 060	17 117,4	15 001,9	6,6%	1 319	1 403,2	1 234,1	6,4%
20	16 052	17 137,7	14 965,8	6,8%	1 319	1 405,5	1 231,9	6,6%

Zdroj: vlastní zpracování