

**UNIVERZITA KOMENSKÉHO V BRATISLAVE
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY**

**EKONOMETRICKÁ ANALÝZA DETERMINANTOV
ZLYHANIA KRAJÍN EU**

DIPLOMOVÁ PRÁCA

UNIVERZITA KOMENSKÉHO V BRATISLAVE
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY

**EKONOMETRICKÁ ANALÝZA DETERMINANTOV
ZLYHANIA KRAJÍN EU**

DIPLOMOVÁ PRÁCA

Študijný program: Ekonomicko-finančná matematika a modelovanie
Študijný odbor: 1114 Aplikovaná matematika
Školiace pracovisko: Katedra aplikovanej matematiky a štatistiky
Vedúci práce: Ing. Tomáš Domonkos, PhD.



Univerzita Komenského v Bratislave
Fakulta matematiky, fyziky a informatiky

ZADANIE ZÁVEREČNEJ PRÁCE

Meno a priezvisko študenta: Bc. Jakub Getta
Študijný program: ekonomicko-finančná matematika a modelovanie
(Jednoodborové štúdium, magisterský II. st., denná forma)
Študijný odbor: aplikovaná matematika
Typ záverečnej práce: diplomová
Jazyk záverečnej práce: slovenský
Sekundárny jazyk: anglický

Názov: Ekonometrická analýza determinantov zlyhania krajín EU.
Analyzing the determinants of default of EU countries.

Cieľ: Práca má ambície identifikovať determinanty, ktoré by vedeli predpovedať zlyhanie krajín v krízových časoch v EU.

Vedúci: Ing. Tomáš Domonkos, PhD.
Katedra: FMFI.KAMŠ - Katedra aplikovanej matematiky a štatistiky
Vedúci katedry: prof. RNDr. Daniel Ševčovič, CSc.
Dátum zadania: 25.01.2017

Dátum schválenia: 27.01.2017
prof. RNDr. Daniel Ševčovič, CSc.
garant študijného programu

študent

vedúci práce

Podakovanie Chcel by som sa poďakovať za cenné rady a odbornú pomoc môjmu školiťovi Ing. Tomášovi Domonkosovi, PhD., ktorými ma počas písania tejto diplomovej práce viedol. Ďalej sa chcem poďakovať spolužiakovi Mgr. Michalovi Daniškovi, PhD. za čas, ktorý mi obetoval a za názory, ktoré mi pomohli pri písaní práce. Poďakovať sa chcem taktiež mojej rodine a priateľke za podporu počas písania práce.

Abstrakt v štátnom jazyku

GETTA, Jakub: Ekonometrická analýza determinantov zlyhania krajín EU [Diplomová práca], Univerzita Komenského v Bratislave, Fakulta matematiky, fyziky a informatiky, Katedra aplikovanej matematiky a štatistiky; školiteľ: Ing. Tomáš Domonkos, PhD., Bratislava, 2018, 60 s.

V práci sa zaoberáme hrozbou finančnej krízy a spôsobom, ako sa jej vyhnúť. Zameriavame sa na krajiny Európskej únie. Využitím znalostí zo štatistiky sa snažíme vytvoriť model, ktorý by vedel predpovedať blížiacu sa krízu na základe historických dát, ktoré máme k dispozícii. V prvom kroku rozdelíme krajiny do niekoľkých skupín. Krajiny danej skupiny vytvoria ekonomický celok, ktorý chápeme ako jednu krajinu. Následne pre každú skupinu analyzujeme determinanty, ktoré v práci vystupujú. Analyzovať budeme najmä to, do akej miery a s akým časovým oneskorením ovplyvňujú krízu krajiny.

Kľúčové slová: Finančná kríza, EWS, Ekonomika, Krajiny Európskej únie

Abstract

GETTA, Jakub: Analyzing the determinants of default of EU countries [Master Thesis], Comenius University in Bratislava, Faculty of Mathematics, Physics and Informatics, Department of Applied Mathematics and Statistics; Supervisor: Ing. Tomáš Domonkos, PhD., Bratislava, 2018, 60 p.

In this thesis we are dealing with the threat of the financial crisis and how to avoid it. We focus on the countries of the European Union. Using knowledge from statistics, we are trying to create a model that would predict a coming crisis based on the historical data we have at our disposal. In the first step, we divide the countries into several groups. The countries of one group create an economic entity that we understand as one country. Subsequently, we analyze the determinants, which are included in the thesis, for each group. In particular, we will analyze to what extent and with what time-lag they affect the country's crisis.

Keywords: Financial crisis, EWS, Economy, Countries of the European union

Obsah

Zoznam obrázkov	9
Zoznam tabuliek	10
Úvod	12
1 Finančná kríza	14
1.1 Dáta krízy	14
1.2 Ukazovatele krízy	16
2 Rozdelenie krajín	18
2.1 Bayesov zovšeobecnený lineárny model	18
2.1.1 Rozdelenie krajín	19
2.1.2 Vytvorenie modelov	21
2.2 Zovšeobecnený lineárny model obsahujúci reštrikciu	23
2.2.1 Rozdelenie krajín	24
2.2.2 Vytvorenie modelov	25
2.3 Rozdelenie podľa dát	27
2.3.1 Rozdelenie krajín	27
2.3.2 Vytvorenie modelov	29
2.4 Vyhodnotenie zhlukovania	31
3 Signifikantnosť premenných	32
3.1 1. Skupina	34
3.1.1 Bežný účet platobnej bilancie	35
3.1.2 Reálny efektívny výmenný kurz	36
3.1.3 Miera nezamestnanosti	37
3.1.4 Verejný dlh	38
3.1.5 Nominálne jednotkové náklady práce	39
3.2 2. skupina	40
3.3 3. skupina	41
3.4 4. skupina	42

4 Najlepšie predikujúci model	43
Záver	48
Zoznam použitej literatúry	50
Príloha A	52

Zoznam obrázkov

1	Bayesovské informačné kritérium pre bayesglm	20
2	Bayesovské informačné kritérium pre glmnet	25
3	Vykreslenie matice odlišností	28
4	Rozdeľovanie podľa dát - Bayesovské informačné kritérium	29

Zoznam tabuliek

1	Zoznam krajín a ich skratky	15
2	Rozsah dát každej krajiny	17
3	<i>bayesglm</i> - Testovanie modelu pre 1. skupinu	21
4	<i>bayesglm</i> - Testovanie modelu pre 2. skupinu	21
5	<i>bayesglm</i> - Testovanie modelu pre 3. skupinu	22
6	<i>bayesglm</i> - Testovanie modelu pre 4. skupinu	22
7	Výpočet ANtSR	23
8	<i>glmnet</i> - Testovanie modelu pre 1. skupinu	26
9	<i>glmnet</i> - Testovanie modelu pre 2. skupinu	26
10	<i>glmnet</i> - Testovanie modelu pre 3. skupinu	26
11	<i>glmnet</i> - Testovanie modelu pre 4. skupinu	26
12	Rozdelenie podľa dát - testovanie modelu pre 1. skupinu	30
13	Rozdelenie podľa dát - testovanie modelu pre 2. skupinu	30
14	Rozdelenie podľa dát - testovanie modelu pre 3. skupinu	30
15	Rozdelenie podľa dát - testovanie modelu pre 4. skupinu	30
16	Signifikantnosť bežného účtu platobnej bilancie pre 1. skupinu	35
17	Signifikantnosť reálneho efektívneho výmenného kurzu pre 1. skupinu	36
18	Signifikantnosť nezamestnanosti pre 1. skupinu	37
19	Signifikantnosť verejného dlhu pre 1. skupinu	39
20	Signifikantnosť nominálnych jednotkových nákladov práce pre 1. skupinu	40
21	Najlepšie modely 1. skupiny	44
22	Najlepšie modely 2. skupiny	45
23	Najlepšie modely 3. skupiny	46
24	Najlepšie modely 4. skupiny	46
25	Rozdelenie krajín v jednotlivých kvartáloch	52
26	Signifikantnosť bežného účtu platobnej bilancie pre 2. skupinu	53
27	Signifikantnosť reálneho efektívneho výmenného kurzu pre 2. skupinu	53
28	Signifikantnosť nezamestnanosti pre 2. skupinu	54
29	Signifikantnosť verejného dlhu pre 2. skupinu	54
30	Signifikantnosť nominálnych jednotkových nákladov práce pre 2. skupinu	55

31	Signifikantnosť bežného účtu platobnej bilancie pre 3. skupinu	55
32	Signifikantnosť reálneho efektívneho výmenného kurzu pre 3. skupinu .	56
33	Signifikantnosť nezamestnanosti pre 3. skupinu	56
34	Signifikantnosť verejného dlhu pre 3. skupinu	57
35	Signifikantnosť nominálnych jednotkových nákladov práce pre 3. skupinu	57
36	Signifikantnosť bežného účtu platobnej bilancie pre 4. skupinu	58
37	Signifikantnosť reálneho efektívneho výmenného kurzu pre 4. skupinu .	58
38	Signifikantnosť nezamestnanosti pre 4. skupinu	59
39	Signifikantnosť verejného dlhu pre 4. skupinu	59
40	Signifikantnosť nominálnych jednotkových nákladov práce pre 4. skupinu	60

Úvod

Kríza je neoddeliteľnou súčasťou ekonomiky každej krajiny. Prvé záznamy o výskyte krízy pochádzajú z dávnej minulosti. Na druhej strane, keď sa pozrieme do budúcnosti, je nám zrejmé, že kríza sa aj naďalej bude objavovať. Neexistuje spôsob, ktorým by sa dalo vyvarovať každej blížiacej sa kríze. Existujú však metódy, ktorými sa krízové udalosti dajú predpovedať a tým sa lepšie pripraviť na túto udalosť. Schopnosť predpovedania krízy v krajine má vplyv na lepšie zabezpečenie sa proti jej následkom. Práve na tieto metódy je zameraná naša diplomová práca.

Existuje viacero typov kríz. V našej práci sa zameriame na finančnú krízu. Je možné takúto krízu predikovať a následne jej istými opatreniami predísť? Touto otázkou sa budeme zaoberať v našej práci.

Identifikovanie kríz sa výrazne opiera o určenie a jasné definovanie minulých krízových udalostí. Bez vedomostí o priebehu skončených kríz sa len veľmi ťažko určuje, kedy ďalšia kríza nastane. Čím presnejšiu chronológiu týchto udalostí máme, tým presnejšie sú modely určené na analýzu ekonomického stavu krajiny a následné odhalenie blížiacej sa krízy. Naopak, nepresná analýza minulých udalostí môže viesť k vychýleným modelom. Tie môžu mať za následok neoptimálne politické rozhodnutia alebo v horšom prípade nepripravenosť krajín na blížiacu sa krízu.

Na predikovanie krízy slúžia systémy včasného varovania (EWS - z anglického Early Warning Systems). Pri študovaní literatúry sme narazili na rôzne varianty týchto systémov od rôznych autorov. Všetky sa odrážajú od historických udalostí krajín, tých krízových, ako aj ekonomických. My sa zameriame na modely založené na logistickej regresii. Priblíženie týchto systémov včasného varovania, ako aj oboznámenie čitateľa s historickými dátami bude tvoriť prvú kapitolu práce.

Našu prácu by sme mohli rozdeliť na dve časti. V prvej časti sa sústredíme na rôznorodosť krajín. Každá krajina má odlišnú ekonomiku a každá krajina zažíva krízu pri rôznych hodnotách ekonomických ukazovateľov. Práve preto sa bude náš prístup k jednotlivým krajinám líšiť. Roztriedime krajiny do niekoľkých skupín podľa ich ekonomiky, pričom analýza krajín v rámci jednej skupiny bude rovnaká. Toto bude témou druhej kapitoly.

V druhej časti práce sa sústredíme na analýzu determinantov, s ktorými pracujeme.

Pozorovať budeme vplyv každého determinantu samostatne. Našu pozornosť upriamime na časové oneskorenie, s ktorým determinanty vplývajú na krízu. Týmto sa budeme zaoberať v tretej kapitole. Súčasťou druhej časti bude aj hľadanie najlepšie predikujúceho modelu, čo bude obsahom poslednej, štvrtej kapitoly. Úlohou bude nájsť takú kombináciu lagovaných premenných, s ktorými dokáže model najlepšie odhaliť blížiacu sa krízu.

1 Finančná kríza

Systémy včasného varovania alebo taktiež “Early Warning Systems“ predstavujú metódy postavené na ekonomickej situácii krajiny a historických dátach krízy. Úlohou týchto systémov je naučiť sa predpovedať nebezpečenstvo krízy na základe minulých udalostí. Využívané sú najmä politikmi pri rozhodovaní sa o stratégiách použitých na riadenie štátu. Existuje široká trieda týchto varovných systémov. Ide o rôzne druhy štatistických modelov, najčastejšie sú to známe “logit“ alebo “probit“ modely. Témou *systémy včasného varovania* sa vo svojich prácach zaoberali napríklad [1], [2], [3], [4]. Jednou z najznámejších osobností v danej oblasti je G. Kaminski, ktorej práce sú [10] alebo [11].

V tejto prvej kapitole priblížime čitateľovi dáta, s ktorými budeme pracovať. Najskôr sa zameriame na dáta samotnej finančnej krízy, ich zdroj a spôsob, akým vznikli. Následne predstavíme ekonomické indikátory krajín, na základe ktorých budeme predpovedať krízu. V skratke opíšeme ich význam.

1.1 Dáta krízy

Prvým krokom k vytvoreniu modelu je získanie dát. Ako už názov diplomovej práce napovedá, vytvorenie modelu budeme realizovať na krajinách Európskej únie. V nasledujúcej tabuľke je zoznam všetkých krajín, ktoré zahrnieme do našej analýzy. Taktiež sa v tejto tabuľke nachádzajú skratky krajín, ktoré budeme ďalej v práci používať. Hoci sa čoraz viac rokuje o zákone o brexite, v čase písania tejto práce Spojené Kráľovstvo ešte patrilo do Európskej únie a preto ho ponecháme v zozname krajín.

Databázu kríz týchto krajín sme získali z [5], kde sa zaoberajú finančnou krízou. Každé obdobie krízy rozdeľujú na dve štádiá. Prvé štádium je obdobie samotnej krízy, ktoré začína prijatím politiky krízového manažmentu a končí posledným krokom krízového manažmentu. Druhé štádium je pokrízové obdobie, ktoré začína ukončením krízy a končí v momente, kedy sa ekonomika krajiny vráti späť do pôvodného stavu. Nas bude zaujímať len obdobie krízy.

Na určenie krízy využívajú v [5] nasledovný postup. V prvom kroku analyzujú historické udalosti krajiny s cieľom odhaliť finančný stres spojený s úpadkom ekonomiky.

Skratka	Krajina	Skratka	Krajina
AUT	Rakúsko	HUN	Maďarsko
BEL	Belgicko	IRL	Írsko
BLG	Bulharsko	ITA	Taliansko
CRO	Chorvátsko	LTU	Litva
CYP	Cyprus	LUX	Luxembursko
CZE	Česká republika	LVA	Lotyšsko
DEU	Nemecko	MLT	Malta
DNK	Dánsko	NLD	Holandsko
ESP	Španielsko	POL	Poľsko
EST	Estónsko	PRT	Portugalsko
FIN	Fínsko	ROM	Rumunsko
FRA	Francúzsko	SVK	Slovensko
GRB	Spojené Kráľovstvo	SVN	Slovinsko
GRC	Grécko	SWE	Švédsko

Tabuľka 1: Zoznam krajín a ich skratky

Tým sa vytvorí zoznam potenciálnych období kríz. V druhom kroku poverené orgány prechádzajú vytvorený zoznam, pričom sa snažia odhaliť chyby prvého druhu, teda prípady, kedy kríza nebola, avšak obdobie je zaradené do zoznamu. Taktiež sa snažia identifikovať chyby druhého druhu, čiže obdobia nezaradené do zoznamu, počas ktorých ale kríza bola. Na záver ešte porovnajú vzniknutý zoznam s databázami kríz od iných autorov za účelom analýzy nezhôd medzi dátami. Týmto spôsobom sa vytvorí konečný zoznam kríz.

Súbor dát teda obsahuje informáciu o tom, v akom období bola daná krajina v kríze. Nachádza sa tu zoznam všetkých kríz od roku 1970 až po rok 2016 a ide o mesačné dáta. My ale potrebujeme kvartálne dáta, o čom sa presvedčíme v podkapitole 1.2. Upravíme teda získané dáta, a to takým spôsobom, že pokiaľ sa kríza vyskytovala aspoň jeden mesiac v danom kvartáli, celý kvartál budeme označovať ako obdobie krízy. Na základe týchto dát si vytvoríme umelú premennú, často označovanú ako "dummy" premenná, ktorá bude nadobúdať hodnotu 1, ak sa kríza vyskytovala v danom kvartáli a hodnotu

0, ak kríza nebola zaznamenaná v uvedenom kvartáli. Táto premenná bude tvoriť závislú premennú v našom modeli a budeme ju označovať *Kríza*.

1.2 Ukazovatele krízy

V tejto časti sa zameriame na ukazovatele krízy, ktoré budú tvoriť množinu nezávislých premenných v modeli. Ako zdroj sme použili [6], kde sa nachádza 14 indikátorov označovaných ako MIP indikátory. Tieto ukazovatele sa využívajú pri identifikovaní makroekonomických nerovnováh v krajine. Keďže databáza obsahuje malé množstvo dát jednotlivých indikátorov, rozhodli sme sa použiť kvartálne dáta, čím sa výrazne zvýši ich počet. Taktiež sme presvedčení, že vytvorený model bude citlivejšie reagovať na zmeny v krízových obdobiach v porovnaní s ročnými dátami. Ako sme už spomenuli v 1.1, kvôli tomuto faktu sme museli databázu kríz prerobiť na kvartálne dáta. Z dôvodu použitia kvartálnych dát, ako aj z dôvodu malého množstva dát sme si vybrali nasledujúcich 5 indikátorov :

- bežný účet platobnej bilancie (Cab)
- reálny efektívny výmenný kurz (Reer)
- miera nezamestnanosti (Unempl)
- nominálne jednotkové náklady práce (Nulc)
- verejný dlh (Gdebt).

V zátvorke za názvom sa nachádza skratka indikátora, ktorou ho budeme v modeli označovať. Bežný účet platobnej bilancie a verejný dlh sú vyjadrené ako percento z hrubého domáceho produktu danej krajiny. Reálny efektívny výmenný kurz tvorí index, pričom rok 2005 je daný hodnotou 100. Miera nezamestnanosti je vypočítaná ako percento z aktívnej populácie krajiny. Nominálne jednotkové náklady práce sú definované ako percentuálna zmena v porovnaní s rovnakým obdobím predchádzajúci rok.

Pre každú krajinu sme získali iný počet dát. Rozsah období jednotlivých krajín, ktoré dáta opisujú, je uvedený v tabuľke 2.

Krajina	Začiatok	Koniec	Krajina	Začiatok	Koniec
AUT	Q1 2000	Q4 2016	HUN	Q1 1996	Q4 2016
BEL	Q1 2003	Q4 2016	IRL	Q1 2002	Q4 2016
BLG	Q1 2007	Q4 2016	ITA	Q1 2000	Q4 2016
CRO	Q1 2001	Q4 2016	LTU	Q1 2004	Q4 2016
CYP	Q1 2008	Q4 2016	LUX	Q1 2000	Q4 2016
CZE	Q1 2000	Q4 2016	LVA	Q1 2000	Q4 2016
DEU	Q1 2000	Q4 2016	MLT	Q1 2004	Q4 2016
DNK	Q1 2005	Q4 2016	NLD	Q2 2003	Q4 2016
ESP	Q1 1996	Q4 2016	POL	Q1 2004	Q4 2016
EST	Q1 2000	Q4 2016	PRT	Q1 2000	Q4 2016
FIN	Q1 2000	Q4 2016	ROM	Q1 2000	Q4 2016
FRA	Q1 2000	Q4 2016	SVK	Q1 2004	Q4 2016
GRB	Q1 2000	Q4 2016	SVN	Q1 2000	Q4 2016
GRC	Q1 2002	Q4 2016	SWE	Q1 1996	Q4 2016

Tabuľka 2: Rozsah dát každej krajiny

2 Rozdelenie krajín

Ďalším krokom po získaní dát je vytvorenie modelu. Nechceme však vytvárať model pre každú krajinu samostatne, pretože by sme získali 28 modelov pre 28 krajín. Každý z nich by sme potom museli samostatne analyzovať. Problémom by taktiež bolo, že na vytvorenie modelu by sme mali malý počet dát. Napríklad pre Cyprus by bol model veľmi nepresný, keďže máme len 36 dát. Podobne nechceme vytvoriť jeden model pre všetky krajiny, keďže krajiny sú heterogénne a takýto model by bol nepresný.

Krajiny preto rozdelíme do niekoľkých skupín. Na rozdeľovanie sme zvolili dva rôzne prístupy. Prvým prístupom je rozdeľovanie založené na modeli, ktorý vytvoríme pre každú krajinu samostatne (na vytvorenie modelov použijeme dve rôzne funkcie, čiže pôjde o dva rôzne zhľukovania). Druhý prístup tvorí rozdeľovanie na základe dát krajín. Dokopy teda budeme mať tri spôsoby zhľukovania krajín.

Pre každú skupinu potom vytvoríme zovšeobecnený lineárny model. Na základe výsledkov týchto modelov budeme porovnávať zhľukovania a vyberieme to, ktoré má najlepšie výsledky. Z dôvodu malého počtu dát budeme zhľukovanie krajín a následné vytváranie modelov pre každú skupinu realizovať na tých istých dátach. To môže spôsobiť, že modely budú vychýlené.

2.1 Bayesov zovšeobecnený lineárny model

Ako sme už v kapitole 2 naznačili, prvým typom bude rozdeľovanie podľa modelov jednotlivých krajín. Pre každú krajinu vytvoríme samostatný model. Závislú premennú bude tvoriť *Kriza* z podkapitoly 1.1. Ako nezávislé premenné použijeme všetkých 5 ukazovateľov z podkapitoly 1.2. Rovnica, ktorú v modeli použijeme, bude vyzeráť nasledovne:

$$Kriza \sim 1 + Cab + Reer + Unempl + Gdebt + Nulc.$$

Na vytvorenie modelu použijeme Bayesovský zovšeobecnený lineárny model (funkcia *bayesglm* v programe R). Dôvod, prečo nepoužijeme klasický zovšeobecnený lineárny model (funkcia *glm* v programe R), je taký, že funkcia nekonverguje pre všetky krajiny. V prípade použitia zovšeobecneného lineárneho modelu sa pre niektoré krajiny vytvorí tzv. dokonalá separácia. To znamená, že model vie jednoznačne určiť, kedy

kríza nastane a kedy nie. Inak povedané, pokiaľ sú hodnoty parametrov pod určitými hraničnými hodnotami, kríza nenastane, ale ak tieto hraničné hodnoty prekročia, kríza nastane. Koeficienty týchto modelov vyskočia do extrémnych čísel v porovnaní s ostatnými modelmi. Príslušné krajiny sú potom svojimi modelmi výrazne odlišné od ostatných, čo by sa odzrkadlilo na rozdelení krajín do skupín.

Funkcia *bayesglm* sa od funkcie *glm* odlišuje tým, že využíva apriórne informácie. Sú to nastavenia funkcie, na základe ktorých vytvorí odhad. Až po vytvorení tohto odhadu funkcia analyzuje dáta, čím odhad pozmení. Na druhej strane pri použití zovšeobecneného lineárneho modelu sa odhad vytvára čisto na základe dát.

Je veľa spôsobov, ako zvoliť tieto apriórne informácie. Ako uvádza [8], keďže nemáme veľa informácií o dátach a nevieme odhadnúť výstup z modelu, použijeme tzv. slabé apriórne informácie, ktoré sa v tomto prípade používajú. Konkrétne použijeme Cauchyho apriórne rozdelenie s nastavením *prior.mean* = 0 a *prior.scale* = 2.5.


Pre každú krajinu sme teda vytvorili Bayesovský zovšeobecnený lineárny model. Tým sme získali 6 hodnôt (intercept a 5 koeficientov) pre každú krajinu, na základe ktorých ich budeme zhlukovať.

2.1.1 Rozdelenie krajín

Na vytvorenie skupín použijeme zhlukovanie založené na modeli. Ide o nehierarchickú analýzu zhlukov, ktorá je založená na maximalizácii funkcie vierohodnosti. Túto metódu sme si zvolili, pretože na rozdiel od ostatných dokáže rozpoznať zhluk umiestnený v rámci iného zhluky. Podobne dokáže nájsť eliptický zhluk (iné nehierarchické analýzy zhlukov ako napríklad k-means alebo k-medoids pracujú len so sférickými zhlukmi). Ďalšou výhodou je, že nezáleží na rozmere premennej a teda nie je potrebná štandardizácia premenných.

Konkrétny model, ktorý použijeme, ako aj počet zhlukov pre krajiny zistíme pomocou Bayesovského informačného kritéria (BIC). Berúc do úvahy možný počet skupín 1 až 15, vypočítali sme BIC hodnotu pre každý typ modelu. Všetky hodnoty sú zobrazené na obrázku 1.

Najlepšou voľbou pre zhlukovanie založenom na modeli je použitie "VEV" modelu a rozdelenie krajín do 4 skupín. Aplikujeme teda toto zhlukovanie na koeficienty modelov



Obr. 1: Bayesovské informačné kritérium pre bayesglm

z 2.1. Výsledné rozdelenie krajín bude teda vyzeráť nasledovne:

- **Skupina 1:** AUT, FRA, GRB, HUN, NLD, PRT
- **Skupina 2:** CZE, DEU, LTU, LVA, ROM, SWE
- **Skupina 3:** BEL, BLG, CRO, CYP, ESP, EST, FIN, GRC, IRL, LUX, MLT, POL, SVK
- **Skupina 4:** DNK, ITA, SVN.

2.1.2 Vytvorenie modelov

Dáta krajín v každej skupine spojíme dokopy a usporiadame ich podľa času. Rozdelíme ich na tréningovú a testovaciu vzorku, pričom tréningovú vzorku bude tvoriť prvých 78% dát. Pri rozdeľovaní dát sme sa snažili využiť čo najväčší ich počet práve na natréningovanie modelu, keďže aj napriek ich sčítaniu máme relatívne malý počet. Na druhej strane sme uvažovali, aby testovacia vzorka mala aspoň 1 kvartál, počas ktorého bola kríza. Inak povedané, nechceli sme, aby závislá premenná v testovacích dátach obsahovala iba nulové hodnoty. Práve preto sme ich rozdelili na 78% a 22% dát.

Pre každú skupinu sme vytvorili zovšeobecnený lineárny model. Dáta použité na natréningovanie modelu sú tie isté, ako dáta použité na zhľukovanie krajín. To môže mať za následok vychýlenosť modelov, ako sme už spomenuli v úvode 2. kapitoly. Výsledky testovania modelov sú v nasledujúcich 4 tabuľkách. N v tabuľke označuje počet prípadov, v ktorých model nepredpovedal krízu. A naopak znamená počet období, v ktorých model predpovedal krízu, pričom hraničnú hodnotu sme stanovili na 0.5. To znamená, že všetky pravdepodobnosti v testovaní modelov, ktoré vyšli z intervalu $(0.5, 1)$, sme považovali za varovný signál. S touto hodnotou sme pracovali v celej práci. V riadkoch je zaznamenaný počet prípadov, kedy kríza nebola (označenie 0) a počet prípadov, kedy kríza nastala (označenie 1).

0.7878788	N	A	Σ
0	14	52	66
1	0	25	25
Σ	14	77	91

Tabuľka 3: *bayesglm* - Testovanie modelu pre 1. skupinu

0.1573034	N	A	Σ
0	75	14	89
1	0	1	1
Σ	75	15	90

Tabuľka 4: *bayesglm* - Testovanie modelu pre 2. skupinu

0.2097902	N	A	Σ
0	113	30	143
1	0	25	25
Σ	113	55	168

Tabuľka 5: *bayesglm* - Testovanie modelu pre 3. skupinu

1	N	A	Σ
0	0	32	32
1	0	9	9
Σ	0	41	41

Tabuľka 6: *bayesglm* - Testovanie modelu pre 4. skupinu

Hodnota v ľavom hornom rohu tabuliek vyjadruje schopnosť modelu predpovedať krízu. Budeme ju označovať ANtSR (z anglického Adjusted noise to signal ratio), ako uvádzajú v [10]. Ako vypočítať ANtSR, ukážeme pomocou tabuľky 7. Najskôr vypočítame pravdepodobnosť, že model predpovie krízu, hoci kríza v danom kvartáli nenastala:

$$\frac{B}{A+B}.$$

Podobne vypočítame úspešnosť modelu predpovedania krízy:

$$\frac{D}{C+D}.$$

Výsledné ANtSR dostaneme predelením týchto dvoch hodnôt :

$$\frac{\frac{B}{A+B}}{\frac{D}{C+D}}.$$

Ide teda o pomer falošných signálov, čiže prípadov, kedy kríza nenastala, avšak model ju predpovedal, k úspešným predikciám krízy. Čím nižšia táto hodnota je, tým lepšie model predpovedá krízu. Model je schopný predpovedať krízu, ak ANtSR patrí do intervalu (0, 1). Pokiaľ má model hodnotu menšiu ako 0.3, považuje sa za veľmi dobrý. Model, ktorého ANtSR je rovné 1, sa dá nahradiť generátorom, ktorý náhodne generuje výsledky testovania a preto nemá žiadnu výpovednú hodnotu.

ANtSR	Model nepredpovedal krízu	Model predpovedal krízu
Nebola kríza	A	B
Bola kríza	C	D

Tabuľka 7: Výpočet ANtSR

Čo sa týka našich modelov, vidíme, že druhý a tretí model sa považujú za veľmi dobré v predpovedaní krízy. Posledný, štvrtý model, má ANtSR rovné 1 a preto sa nedá použiť na predpovedanie krízy. Usudzujeme, že to je dôsledkom malého počtu dát, z ktorých bol štvrtý model natrénovaný. Nakoľko v prislúchajúcej skupine sú len tri krajiny, obsahuje menej ako 200 dát, z ktorých len 3/4 boli použité v tréningovej vzorke.

2.2 Zovšeobecnený lineárny model obsahujúci reštrikciu

Podobný postup z podkapitoly 2.1 zopakujeme aj tu. V tomto prípade funkciu *glm* nahradíme funkciou *glmnet*. Je to takisto zovšeobecnený lineárny model, ktorý ale obsahuje reštrikciu. Konkrétne ide o "Ridge" reštrikciu a "LASSO" reštrikciu. Je to penalizácia modelu za príliš vysokú chybovosť niektorých parametrov. Inak povedané, vplyv parametrov, ktoré najviac prispievajú chybovosti modelu, je znížený na minimum. "Ridge" reštrikcia sa tieto koeficienty s vysokou chybovosťou snaží znížiť na malé hodnoty, zatiaľ čo "LASSO" reštrikcia nastaví tieto koeficienty rovné nule. Účelová funkcia, ktorú minimalizujeme, bude vyzeráť nasledovne:

$$\min_{(\beta_0, \beta) \in \mathbb{R}^{p+1}} - \left[\frac{1}{N} \sum_{i=1}^N y_i (\beta_0 + x_i^T \beta) - \log(1 + e^{\beta_0 + x_i^T \beta}) \right] + \lambda \left[(1 - \alpha) \frac{\|\beta\|_2^2}{2} + \alpha \|\beta\|_1 \right].$$

Prvá hranatá zátvorka znázorňuje funkciu vierohodnosti zovšeobecneného lineárneho modelu. Druhá hranatá zátvorka obsahuje túto reštrikciu, kde λ a α sú vopred zadané koeficienty. "Ridge" reštrikcia je rovná $\frac{\|\beta\|_2^2}{2}$ a "LASSO" reštrikcia je rovná $\|\beta\|_1$.

Keďže v našom modeli máme len 5 parametrov, rozhodli sme sa použiť "Ridge" reštrikciu. Použitím "LASSO" reštrikcie by sa niektoré koeficienty vynulovali, čím by sa ich počet ešte zmenšil. Preto koeficient

$$\alpha = 0.$$

Koeficient λ nájdeme pomocou kros-validácie, pričom vezmeme tú λ , ktorá vytvára najmenšiu chybu kros-validácie.

V našich dátach sa ale nachádzajú aj krajiny, ktoré za celé pozorované obdobie nezažili krízu. Sú to krajiny Bulharsko, Estónsko, Fínsko, Malta, Poľsko, Slovensko. Všetky závislé premenné týchto krajín sú rovné nule. To spôsobuje, že koeficienty premenných sú veľmi malé hodnoty a naopak intercept nadobúda vysoké hodnoty. Z toho dôvodu sa pre tieto krajiny nedá použiť funkcia *glmnet*, preto použijeme pôvodný zovšeobecnený lineárny model.

Špecifická je taktiež Česká republika, ktorá mala krízu len na začiatku pozorovaného obdobia, a to v prvom a druhom kvartáli v roku 2000. Preto sa nedá použiť kros-validácia na nájdanie optimálnej λ . Preto použijeme defaultnú hodnotu λ .


Pre každú krajinu vytvoríme model podľa vyššie opísaného postupu, čím dostaneme 28 rôznych modelov. Podobne ako pri Bayesovom zovšeobecnenom lineárnom modeli ich budeme zhľukovať.

2.2.1 Rozdelenie krajín

Rovnako, ako v časti 2.1.1 budeme krajiny rozdeľovať podľa zhľukovania založenom na modeli. Aby sme výsledky mohli porovnávať s tými v kapitole 2.1, krajiny rozdelíme takisto do 4 skupín. Keďže pri modeli využívajúcom "Ridge" reštrikciu hľadáme optimálnu λ pomocou kros-validácie, pri opätovnom spustení programu dostaneme odlišné výsledky, pretože zakaždým je optimálna λ iná. Vytvárame teda modely stále nanovo a kontrolujeme hodnoty BIC, pričom hľadáme takú kombináciu modelov, pre ktorú je zhľukovanie do 4 skupín najlepšou voľbou. Po niekoľkých pokusoch sa nám to podarilo. Výsledok môžeme vidieť na obrázku 2.

Vidíme, že zhľukovanie do 4 skupín v takomto prípade je najlepšou voľbou. Model, ktorý pri zhľukovaní použijeme, sa volá "VEV". Podľa toho krajiny rozdelíme do týchto 4 skupín:

- **Skupina 1:** AUT, BEL, CYP, CZE, DEU, GRC, HUN, IRL, LTU, LVA, ROM, SWE
- **Skupina 2:** BLG, CRO, ESP, EST, FIN, LUX, MLT, POL, SVK



Obr. 2: Bayesovské informačné kritérium pre glmnet

- Skupina 3: FRA, GRB, NLD, PRT
- Skupina 4: DNK, ITA, SVN.

2.2.2 Vytvorenie modelov

Dáta v každej skupine spojíme dokopy a usporiadame podľa času. Aby boli rovnaké podmienky na testovanie modelov, dáta rozdelíme na 78%, ktoré budú tvoriť tréningovú vzorku a 22%, ktoré slúžia na testovanie kvality modelov. Pre každú skupinu vytvoríme zovšeobecnený lineárny model. Výsledky testovania modelov sa nachádzajú v nasledujúcich 4 tabuľkách.

Vidíme, že rovnako ako v podkapitole 2.1, aj tu poslednú skupinu tvoria krajiny Dánsko, Taliansko a Slovinsko, čo je pomerne málo dát. Práve preto je hodnota ANtSR rovná 1, čo značí nekvalitný model, ktorý nedokáže predpovedať nebezpečenstvo krízy. Ostatné modely sú výrazne kvalitnejšie. Až 2 zo 4 modelov majú ANtSR menšie ako

0.3, čím sa považujú za veľmi dobré modely.

0.2977099	N	A	Σ
0	104	27	131
1	12	27	39
Σ	116	54	170

Tabuľka 8: *glmnet* - Testovanie modelu pre 1. skupinu

0.1083333	N	A	Σ
0	107	13	120
1	0	1	1
Σ	107	14	121

Tabuľka 9: *glmnet* - Testovanie modelu pre 2. skupinu

0.5869565	N	A	Σ
0	19	27	46
1	0	11	11
Σ	19	38	57

Tabuľka 10: *glmnet* - Testovanie modelu pre 3. skupinu

1	N	A	Σ
0	0	32	32
1	0	9	9
Σ	0	41	41

Tabuľka 11: *glmnet* - Testovanie modelu pre 4. skupinu

2.3 Rozdelenie podľa dát

Tretie, posledné zhľukovanie, sa od prvých dvoch odlišuje tým, že nebudeme vytvárať modely pre jednotlivé krajiny. Rozdelenie krajín budeme realizovať na samotných dátach. Aby boli rovnaké podmienky, pre každú krajinu použijeme rovnaký počet dát. Konkrétne budeme pracovať s obdobím od prvého kvartálu v roku 2008 až po štvrtý kvartál v roku 2016. Toto rozpätie sme si určili kvôli krajine Cyprus, ktorá má najmenší počet dát.


V každom kvartáli zhľukujeme krajiny podľa piatich indikátorov z 1.2. podkalitoly: Cab, Reer, Unempl, Nulc, Gdebt. Použijeme zhľukovanie založené na modeli, pričom konkrétny typ modelu ako aj počet zhľukov nastavíme na defaultné hodnoty. Vznikne 28×36 matica, ktorá v riadkoch obsahuje krajiny a v stĺpcoch výsledok zhľukovania pre každý kvartál. Časť tejto matice je zobrazená v tabuľke 16 v prílohe.

Následne použijeme klasické mnohorozmerné škálovanie. Vytvoríme 28×28 maticu rozdielov D , ktorá bude vyjadrovať odlišnosť jednotlivých krajín. Hodnota D_{ij} označuje počet prípadov, kedy krajina i bola v inom zhľuku ako krajina j . Na diagonále bude mať matica D samé nuly, preto $D_{ii} = 0 \quad \forall i = 1, \dots, 28$. Na túto maticu aplikujeme mnohorozmerné škálovanie. Výsledkom bude matica P , ktorá v riadkoch obsahuje súradnice bodov zvolených tak, aby vyjadrovali rozdiely medzi krajinami. Aby sme mohli zobraziť odlišnosti krajín, museli by sme použiť 16-rozmerný priestor, keďže matica P je rozmeru 28×16 . Môžeme ale zobraziť približné odlišnosti krajín v 2D priestore využitím prvých dvoch stĺpcov matice (Obrázok 3). V ďalšej časti budeme ale zhľukovať krajiny podľa celej matice P .

2.3.1 Rozdelenie krajín

Na analýzu zhľukov použijeme zhľukovanie založené na modeli. Podobne ako v predchádzajúcich prípadoch, konkrétny model vyberieme podľa Bayesovho informačného kritéria. BIC pre všetky možné modely a pre počty zhľukov 1 až 15 je zobrazené na obrázku 4. Zvolíme si počet zhľukov 4, aby sa nám výsledky lepšie porovnávali s predchádzajúcimi zhľukovaniami. Najvhodnejší model v tomto prípade je "VII".


Konečné rozdelenie krajín bude:



Obr. 3: Vykreslenie matice odlišností

- **Skupina 1:** AUT, DEU, DNK, FIN, FRA, GRB, HUN, LUX, MLT, NLD, POL, ROM, SVN, SWE
- **Skupina 2:** BEL, CRO, CYP, ESP, GRC, IRL, ITA, PRT
- **Skupina 3:** BLG, EST
- **Skupina 4:** CZE, LTU, LVA, SVK.

Ako môžeme vidieť, v tretej aj štvrtej skupine sa nachádza malý počet krajín. Preto predpokladáme, že modely vytvorené pre tieto skupiny budú nepresné v predikovaní



Obr. 4: Rozdeľovanie podľa dát - Bayesovské informačné kritérium

krízy. Na základe toho usudzujeme, že zhlukovanie podľa dát krajín bude dávať najhoršie výsledky spomedzi všetkých troch. O tom sa ale presvedčíme až po testovaní modelov.

2.3.2 Vytvorenie modelov

Aplikujeme rovnaký postup na vytvorené skupiny. Dáta krajín tej istej skupiny spojíme dokopy a usporiadame podľa času. Rozdelíme ich na 78% dát, ktoré použijeme ako tréningovú vzorku a 22% dát, na ktorých vzniknuté modely otestujeme. Vytvoríme zo všeobecných lineárnych modelov pre každú skupinu, ktoré potom otestujeme na testovacej

vzorke dát. Výsledky sú v tabuľkách 12 až 15.

0.7788462	N	A	Σ
0	155	27	182
1	17	4	21
Σ	172	31	203

Tabuľka 12: Rozdelenie podľa dát - testovanie modelu pre 1. skupinu

0.8600305	N	A	Σ
0	14	55	69
1	3	38	41
Σ	17	93	110

Tabuľka 13: Rozdelenie podľa dát - testovanie modelu pre 2. skupinu

	N	A	Σ
0	24	0	24
1	0	0	0
Σ	24	0	24

Tabuľka 14: Rozdelenie podľa dát - testovanie modelu pre 3. skupinu

	N	A	Σ
0	52	1	53
1	0	0	0
Σ	52	1	53

Tabuľka 15: Rozdelenie podľa dát - testovanie modelu pre 4. skupinu

Modely vytvorené pre prvú a druhú skupinu nie sú veľmi kvalitné v predikovaní krízy, pretože hodnoty ANtSR sú pomerne vysoké. V tretej a štvrtej skupine, kde máme malý počet dát, sa v testovacej vzorke nenachádzajú informácie z obdobia krízy. To má za následok, že nevieme vypočítať ANtSR a tým pádom nedokážeme porovnať modely s ostatnými.

2.4 Vyhodnotenie zhľukovania

Posledným krokom v tejto fáze je výber toho zhľukovania, ktoré dáva najlepšie výsledky. Už na prvý pohľad je zrejmé, že to nebude tretie zhľukovanie, teda rozdelenie podľa dát. Hodnoty ANtSR pre prvú a druhú skupinu tohto zhľukovania sú výrazne väčšie v porovnaní s ostatnými dvomi zhľukovaniami. Ďalším dôvodom, prečo toto zhľukovanie nepovažujeme za najlepšie je fakt, že roztriedenie krajín do skupín je veľmi nerovnomerné. Tretia skupina obsahuje iba dve krajiny a štvrtá skupina obsahuje štyri krajiny. V týchto skupinách máme malý počet dát, čo by mohlo spôsobiť nepresnosti v ďalších analýzach. Preto toto zhľukovanie vylúčime.

Ostali nám zhľukovanie využívajúce Bayesov zovšeobecnený lineárny model a zhľukovanie využívajúce zovšeobecnený lineárny model s reštrikciou. Ako prvé si všimneme, že obidva zhľukovania majú poslednú, štvrtú skupinu, rovnakú. Pri vyberaní najlepšieho zhľukovania je preto táto štvrtá skupina irelevantná. Podľa hodnôt ANtSR, ktoré sú vo všeobecnosti nižšie v druhom prípade, zvolíme druhé zhľukovanie za najlepšie. Ide o nasledovné rozdelenie krajín:

- **Skupina 1:** AUT, BEL, CYP, CZE, DEU, GRC, HUN, IRL, LTU, LVA, ROM, SWE
- **Skupina 2:** BLG, CRO, ESP, EST, FIN, LUX, MLT, POL, SVK
- **Skupina 3:** FRA, GRB, NLD, PRT
- **Skupina 4:** DNK, ITA, SVN.

Toto rozdelenie krajín budeme využívať v zvyšnej časti diplomovej práce.

3 Signifikantnosť premenných

Hlavným prínosom druhej kapitoly pre túto prácu bolo rozdelenie krajín. Okrem toho sme ale taktiež vytvorili modely pre tieto rozdelenia, ktoré sme následne oklasifikovali. Hodnotili sme ich na základe schopnosti predpovedať nebezpečenstvo krízy. Napriek problémom spôsobeným nedostatkom dát vykazovali modely pomerne dobré výsledky. Výnimku tvorí posledný model, ktorého mieru nekvality sme odôvodnili malým počtom dát. Zo zvyšných troch modelov sú až dva modely považované za veľmi dobré. Analýzou premenných, ktoré v modeloch vystupujú, sa pokúsime túto mieru kvality zvýšiť.

Konkrétne v tretej kapitole sa budeme venovať signifikantnosti jednotlivých indikátorov finančnej krízy. Z historických udalostí vieme, že každý ekonomický ukazovateľ krízy má vplyv s iným časovým oneskorením. Poznáme také, ktoré v danom momente indikujú prítomnosť krízy, a teda sú bez časového oneskorenia. Naopak, existujú aj také, ktorých výrazná zmena sa prejaví v podobe krízy až o pár rokov neskôr. Našou úlohou bude sa zamerať na päť indikátorov, ktoré v našej práci vystupujú. Každý indikátor budeme posúvať v čase, pričom budeme hľadať taký časový posun T , pri ktorom má indikátor najväčší vplyv na krízu.

K dispozícii máme kvartálne dáta, indikátory budeme preto posúvať po kvartáloch. Najmenšia hodnota T bude rovná nule, čo znamená bez časového posunu. Najväčší časový posun bude $T = 16$ kvartálov, čiže štyri roky. Maximálne posunutie štyri roky sme zvolili s ohľadom na obdobie, pre ktoré máme dáta. Analyzovať budeme každý indikátor samostatne. Keďže ale medzi indikátormi existuje istá korelácia, pri danom indikátore nás bude zaujímať časové posunutie aj ostatných indikátorov. Hľadáme teda takú kombináciu časových posunov, pri ktorých má pozorovaná premenná najväčšiu signifikantnosť.

Signifikantnosť budeme porovnávať nasledovne. Funkcia logistickej regresie má v našom prípade tvar

$$p(x) = \frac{1}{1 + e^{-(\beta_0 + \beta_C x_C + \beta_R x_R + \beta_U x_U + \beta_G x_G + \beta_N x_N)}}, \quad (1)$$

kde jednotlivé koeficienty sú:

- β_C - koeficient bežného účtu platobnej bilancie

- β_R - koeficient reálneho efektívneho výmenného kurzu
- β_U - koeficient miery nezamestnanosti
- β_G - koeficient verejného dlhu
- β_N - koeficient nominálnych jednotkových nákladov práce.

Pre tieto koeficienty existuje hypotéza o nulovosti, ktorá testuje, či daný parameter je signifikantný v modeli:

$$H_0 : \beta_i = 0 \quad vs. \quad H_1 : \beta_i \neq 0.$$

Túto hypotézu zamietneme, pokiaľ je p-hodnota nižšia ako 5%. Čím je p-hodnota nižšia, tým skorej zamietneme hypotézu o nulovosti a teda platí, že premenná x_i je v našom modeli signifikantná. Hľadáme teda minimálnu p-hodnotu. Konkrétny indikátor budeme posúvať v čase vždy o jeden kvartál, pričom zakaždým vypočítame p-hodnotu, ktorú si zapíšeme. Výsledný časový posun T bude ten, pri ktorom je p-hodnota najnižšia.

V našej práci máme 5 indikátorov a každý môžeme posunúť o 0 až 16 kvartálov, čiže dokopy máme 17^5 kombinácií, ako môžeme premenné nastaviť. Kvôli časovej náročnosti výpočtov neprejdeme všetkými možnosťami. Signifikantnosť premenných budeme hľadať iteratívne, čo objasníme na nižšie uvedenom príklade. Keďže neprejdeme všetkých 17^5 kombinácií, nemôžeme zaručiť, že nájdené optimum bude globálne. Je pravdepodobné, že náš nižšie opísaný postup konvergoval len k lokálnemu optimu a globálne optimum sa nám nepodarilo nájsť.

Povedzme, že chceme zistiť signifikantnosť bežného účtu platobnej bilancie. Na začiatku si zvolíme štartovací bod, časový posun T_0 pre každú premennú. Všetky premenné posunieme v čase podľa tohto počiatočného bodu. Zoberieme bežný účet platobnej bilancie a posunieme ho postupne vždy o jeden kvartál, pričom v každom časovom okamihu vypočítame prislúchajúcu p-hodnotu. Získame 17 hodnôt. Tieto p-hodnoty hovoria o signifikantnosti Cab v modeli s danými posunutými premennými. Nájdeme, pri akom časovom posunutí je p-hodnota najnižšia. Časový posun T^C bežného účtu platobnej bilancie zmeníme na získanú hodnotu. Berúc do úvahy túto informáciu prejdeme na ďalší indikátor, reálny efektívny výmenný kurz. Podobne aj tento postupne

posúvame v čase. Avšak aj v tomto prípade pozorujeme, ako sa mení signifikantnosť bežného účtu platobnej bilancie. Inými slovami, zapisujeme si p-hodnotu prislúchajúcu hypotéze o nulovosti koeficientu bežného účtu platobnej bilancie. Týmto spôsobom nájdeme časový posun T^R reálneho efektívneho výmenného kurzu, pri ktorom má Cab najväčšiu signifikantnosť. Takto prejdeme všetky premenné a vrátíme sa k bežnému účtu platobnej bilancie. Tento postup opakujeme, až pokým nezačne konvergovať. V našich výpočtoch sme cyklus nastavili na 10 opakovaní. Takmer vo všetkých prípadoch konvergencia nastala už pri 2-3 opakovaní.

Podobne ako v 2. kapitole, budeme vytvárať zovšeobecnený lineárny model. Dáta rozdelíme na trénovaciu a testovaciu vzorku. Z dôvodu malého počtu dát validačnú vzorku dát nevytvoríme.

Posunutie jednotlivých indikátorov v čase realizujeme pre každú krajinu samostatne. Až následne na to spojíme dáta krajín z rovnakej skupiny. Z nich potom vytvoríme model logistickej regresie, v ktorom pozorujeme signifikantnosť parametrov. Týmto spôsobom predídeme tomu, aby sa zmiešali dáta dvoch rôznych krajín. Signifikantnosť parametrov budeme analyzovať pre každú skupinu samostatne. Podrobnejšie sa budeme venovať prvej skupine, ktorá obsahuje najväčší počet krajín a teda má najlepšiu výpovednú hodnotu. Uvedieme aj naše výsledky. Výsledky z druhej, tretej a štvrtej kapitoly sa nachádzajú v Prílohe A.

3.1 1. Skupina

Pre zopakovanie túto skupinu tvoria krajiny Rakúsko, Belgicko, Cyprus, Česká republika, Nemecko, Grécko, Maďarsko, Írsko, Litva, Lotyšsko, Rumunsko a Švédsko. Pre každú premennú zvolíme 10 štartovacích bodov, ktoré budú konvergovať buď k lokálnemu, alebo globálnemu minimu. V tabuľkách zobrazujeme štartovacie body, teda začiatkové posunutia jednotlivých premenných. Ďalej sa tu nachádzajú výsledné časové posuny, pri ktorých dosahujú modely najväčšiu signifikantnosť pozorovanej premennej. Tiež sa tu nachádzajú p-hodnoty hypotéz o nulovosti koeficientov modelov. Posledným údajom je samotný koeficient, ktorého hypotézu o nulovosti testujeme.

Štartovací bod					Výsledné posunutie					P-value	β_C
T_0^C	T_0^R	T_0^U	T_0^G	T_0^N	T^C	T^R	T^U	T^G	T^N		
5	6	2	12	13	0	16	0	0	4	1.52E-07	0.109
2	4	16	7	14	10	0	16	15	16	0.0003	-0.063
9	13	6	0	8	0	16	0	0	4	1.52E-07	0.109
1	16	9	14	12	0	16	0	0	4	1.52E-07	0.109
7	9	11	7	3	0	16	0	0	4	1.52E-07	0.109
14	9	2	16	15	0	16	0	0	4	1.52E-07	0.109
2	9	12	12	5	0	16	0	0	4	1.52E-07	0.109
8	1	5	8	3	10	0	16	15	16	0.0003	-0.063
1	14	6	10	3	10	0	16	15	16	0.0003	-0.063
3	3	11	0	14	0	16	0	0	4	1.52E-07	0.109

Tabuľka 16: Signifikantnosť bežného účtu platobnej bilancie pre 1. skupinu

3.1.1 Bežný účet platobnej bilancie

Bežný účet sa podľa [7] skladá z obchodu s tovarom a službami krajiny s ostatnými krajinami sveta. Ďalej je tvorený ziskom krajiny zo zahraničných investícií a taktiež hotovostnými prevodmi. Bežný účet platobnej bilancie vyjadruje vzťah medzi exportom a importom krajiny. V prípade kladnej bilancie má krajina väčší export ako import. V prípade zápornej je to naopak, teda krajina viacej vyváža ako dováža. Táto hodnota, či už kladná alebo záporná, je vyjadrená ako percento z hrubého domáceho produktu.

Indikátor teda vyjadruje konkurencieschopnosť krajiny. Výrazne vyšší export v porovnaní s importom prospieva ekonomike. Kladná hodnota preto znamená dobré ekonomické postavenie krajiny v rámci ostatných krajín. Očakávame teda, že so zvyšujúcou sa hodnotou bežného účtu platobnej bilancie pravdepodobnosť krízy klesá. Tento predpoklad platí iba v prípade, že berieme do úvahy len jednu krajinu, v našom prípade jednu skupinu. Pokiaľ by išlo o viaceré krajiny, prípadne celú eurozónu, nemusí to byť také jednoznačné. Keďže krajiny eurozóny majú spoločnú menu, sú navzájom previazané. Kladné hodnoty bežného účtu platobnej bilancie vo vyspelejších krajinách môžu spôsobiť pokles Cab v tých menej vyspelých, čo môže byť brané ako negatívum pre

ekonomiku európskych krajín.

V našom modeli nám ale vyšiel presný opak predpokladu, ktorý sme uviedli vyššie. Za najsignifikantnejšiu vyšla taká kombinácia časových posunov, v ktorých je Cab bez časového oneskorenia. V tomto prípade je koeficient $\beta_C = 0.109$ kladný, čo znamená, že so zvyšujúcou sa hodnotou platobnej bilancie stúpa pravdepodobnosť krízy. To je ale podľa ekonomickej teórie nelogické.

Preto by sme dali radšej do pozornosti v poradí druhý výsledok. Ide o lokálne minimum, ktorého p-hodnota je síce výrazne vyššia ako v prípade prvého výsledku, avšak stále je menšia ako 5%, a teda premenná je signifikantná. Koeficient dosahuje zápornú hodnotu $\beta_C = -0.063$, čo hovorí, že so zvyšujúcim sa bežným účtom platobnej bilancie pravdepodobnosť krízy klesá.

Berúc do úvahy správnosť predpokladu o zápornej hodnote koeficientu, bežný účet platobnej bilancie najvýraznejšie ovplyvňuje krízu s 2,5-ročným oneskorením. To nám hovorí, že veľké zmeny tohto indikátora sa prejavujú v ekonomike o 2,5 roka.

3.1.2 Reálny efektívny výmenný kurz

Štartovací bod					Výsledné posunutie					P-value	β_R
T_0^C	T_0^R	T_0^U	T_0^G	T_0^N	T^C	T^R	T^U	T^G	T^N		
9	13	16	0	9	15	7	6	0	11	0.0093	0.037
4	15	5	8	6	7	0	0	12	16	2.45E-05	-0.067
10	10	7	16	15	7	0	0	12	16	2.45E-05	-0.067
13	6	0	7	6	7	0	0	12	16	2.45E-05	-0.067
3	11	14	5	9	15	7	6	0	11	0.0093	0.037
10	7	0	6	6	7	0	0	12	16	2.45E-05	-0.067
11	4	1	15	10	7	0	0	12	16	2.45E-05	-0.067
8	9	8	14	9	7	0	0	12	16	2.45E-05	-0.067
1	9	16	12	12	7	0	0	12	16	2.45E-05	-0.067
15	5	13	6	5	16	7	14	1	5	0.0120	0.036

Tabuľka 17: Signifikantnosť reálneho efektívneho výmenného kurzu pre 1. skupinu

Druhým indikátorom je reálny efektívny výmenný kurz. V [9] ho definujú ako hod-

notu domácej meny v porovnaní s váženým priemerom niekoľkých hlavných medzinárodných mien, upravený o vplyv inflácie. Dopad tohto indikátora na finančnú krízu je neurčitý.

Na jednej strane zvýšenie hodnoty *Reer* spôsobí, že export sa stane drahším a import lacnejším, čo má za následok stratu konkurencieschopnosti obchodu, ako uvádzajú v [9]. Podľa toho zvýšenie reálneho efektívneho výmenného kurzu zapríčiňuje zvýšenie pravdepodobnosti výskytu krízy. Na druhej strane tým, že sa zvýši *Reer*, a teda sa export stane drahším a import lacnejším, krajina z obchodu viac profituje. Vyšší profit má opačný efekt na krízu, čiže pravdepodobnosť výskytu krízy sa znižuje.

Z našich dát sme získali dva rôzne výsledky pre β_R , jeden s kladným a druhý so záporným znamienkom. V prípade toho záporného je p-hodnota výrazne nižšia, preto vezmeme túto hodnotu ako výslednú. To nám hovorí, že zvyšujúca sa hodnota *Reer* má negatívny účinok na vznik krízy. Podľa toho sa reálny efektívny výmenný kurz ukazuje ako indikátor bez časového oneskorenia vplyvu na krízu.

3.1.3 Miera nezamestnanosti

Štartovací bod					Výsledné posunutie					P-value	β_U
T_0^C	T_0^R	T_0^U	T_0^G	T_0^N	T^C	T^R	T^U	T^G	T^N		
2	16	1	3	4	16	0	0	16	5	1.02E-10	0.259
4	13	11	6	13	7	8	9	0	2	2.34E-06	-0.224
11	14	1	13	11	16	0	0	16	5	1.02E-10	0.259
10	16	5	1	9	7	8	9	0	2	2.34E-06	-0.224
1	7	14	7	15	7	8	9	0	2	2.34E-06	-0.224
2	4	9	13	1	16	0	0	16	5	1.02E-10	0.259
6	5	7	8	4	16	0	0	16	5	1.02E-10	0.259
5	2	15	8	5	16	0	0	16	5	1.02E-10	0.259
8	15	3	6	8	16	0	0	16	5	1.02E-10	0.259
0	7	8	13	9	16	0	0	16	5	1.02E-10	0.259

Tabuľka 18: Signifikantnosť nezamestnanosti pre 1. skupinu

Mieru nezamestnanosti, ktorá je v poradí tretí indikátor, nemusíme zvlášť opisovať.

Ako sme už spomenuli v 1.2, je vyjadrená percentom z aktívnej populácie krajiny. Je zrejmé, že vysoká nezamestnanosť negatívne vplýva na ekonomiku a preto usudzujeme, že zvýšenie nezamestnanosti prispieva k riziku vzniku krízy.

Avšak Eurostat ([6]) sa v poslednej dobe zaoberá názorom, že nezamestnanosť nie je príčinou krízy, ale je jej dôsledkom. Porovnaním nášho modelu s modelom, v ktorom nevystupuje nezamestnanosť, by sme mohli overiť túto teóriu. My to však v našej práci nebudeme analyzovať. Pozrieme sa len na signifikantnosť tohto indikátora v modeli.

V tabuľke 18 sú zaznamenané výsledky pre hľadanie optima miery nezamestnanosti. Dosiahli sme dva rôzne výsledky. Ekonomicky interpretovateľný je ten, v ktorom $\beta_U = 0.259$. Kladná hodnota podporuje teóriu, ktorá hovorí, že pri vyššej miere nezamestnanosti sú šance na vznik krízy vyššie. Pre toto optimum je vplyv nezamestnanosti bez časového oneskorenia, podobne ako reálny efektívny výmenný kurz.

P-hodnota je veľmi malá, čo signalizuje signifikantnosť premennej. Preto by sme ju neodporúčali vynechať v našom modeli. Neskôr sa pozrieme aj na ostatné skupiny a presvedčíme sa, či je tomu naozaj tak. To však neznamená, že model s *Unempl* dosahuje najlepšie možné výsledky. Je možné, že by model bez tejto premennej vykazoval lepšiu predikciu. V takom prípade by bolo lepšie ju vylúčiť. To by potvrdilo teóriu o tom, že nezamestnanosť je dôsledkom krízy.

3.1.4 Verejný dlh

Verejný dlh, rovnako ako aj nezamestnanosť, negatívne vplýva na ekonomiku krajiny. Otázkou je, či verejný dlh spôsobuje finančnú krízu. Niektoré zdroje, ako napríklad [6], uvádzajú, že je pravdepodobné, že tento ekonomický ukazovateľ nespôsobuje krízu, ale predstavuje schopnosť krajiny reagovať na už vzniknutú krízu. Krajiny s nízkym verejným dlhom majú možnosť začať expanzívnu fiškálnu politiku, čo im pomôže lepšie znášať dôsledky krízy. Na druhej strane, v krajinách s vysokým dlhom by ešte väčšie zadĺženie prehĺbilo krízu a krajina by sa dostala do ešte väčších problémov. Nakoľko sú tieto myšlienky pravdivé, je otázne a bude potrebných ešte veľa analýz na to, aby sa potvrdili, respektíve vyvrátili.

My sme sa rozhodli zohľadniť verejný dlh v našom modeli a použiť ho na predikciu krízy. Dáta, ktoré máme k dispozícii, predstavujú verejný dlh ako percento z hrubého

Štartovací bod					Výsledné posunutie					P-value	β_G
T_0^C	T_0^R	T_0^U	T_0^G	T_0^N	T^C	T^R	T^U	T^G	T^N		
14	9	4	7	11	5	8	8	0	5	4.22E-19	0.0411
8	14	13	2	4	15	8	10	0	5	4.24E-19	0.0410
6	0	7	0	15	5	8	8	0	5	4.22E-19	0.0411
13	1	1	0	13	5	8	8	0	5	4.22E-19	0.0411
15	6	10	12	4	15	8	10	0	5	4.24E-19	0.0410
11	10	0	2	7	5	8	8	0	5	4.22E-19	0.0411
9	14	1	10	2	15	8	10	0	5	4.24E-19	0.0410
1	9	6	7	14	5	8	8	0	5	4.22E-19	0.0411
3	1	15	12	3	15	8	10	0	5	4.24E-19	0.0410
1	14	1	7	12	5	8	8	0	5	4.22E-19	0.0411

Tabuľka 19: Signifikantnosť verejného dlhu pre 1. skupinu

domáceho produktu krajiny. Výsledky v tabuľke 19 vyšli pomerne jednoznačne. Vo všetkých desiatich prípadoch vyšiel koeficient β_G kladný. Tým sa verejný dlh zaradil medzi indikátory, ktoré svojím nárastom prispievajú k vzniku krízy. P-hodnota vyšla takmer nulová. Môžeme preto tvrdiť, že ide o dôležitú premennú v modeli. Najväčší vplyv na vznik krízy sme zaznamenali bez časového posunu. Inými slovami, náhle zmeny vo verejnom dlhu sa okamžite premietnu do ekonomickej situácie krajiny.

3.1.5 Nominálne jednotkové náklady práce

Nominálne jednotkové náklady práce sú v [12] definované ako priemerné náklady práce za jednotku vyprodukovaného výstupu. Často sa používajú ako merítko konkurencieschopnosti krajín. Dáta, ktoré sme použili na analýzu, sú vyjadrené ako percentuálna zmena v porovnaní s tým istým obdobím predchádzajúceho roku. Tento ukazovateľ, rovnako ako aj miera nezamestnanosti a verejný dlh, nepriaznivo vplýva na ekonomiku a preto sa každá krajina snaží o čo najnižšie náklady práce. Očakávame teda, že nárast nákladov práce bude priamo úmerný nárastu pravdepodobnosti vzniku krízy.

Podľa tabuľky 20 môžeme vidieť, že nám vyšli dva protichodné výsledky. Pre najnižšiu p-hodnotu vyšiel koeficient $\beta_N = 0.131$. Kladné znamienko koeficientu potvrdzuje

Štartovací bod					Výsledné posunutie					P-value	β_N
T_0^C	T_0^R	T_0^U	T_0^G	T_0^N	T^C	T^R	T^U	T^G	T^N		
5	0	3	13	11	0	8	16	0	5	6.89E-08	0.131
5	15	9	11	2	5	0	6	16	0	4.07E-06	-0.102
8	3	8	1	13	0	8	16	0	5	6.89E-08	0.131
13	5	6	13	14	0	8	16	0	5	6.89E-08	0.131
7	8	16	8	16	5	0	6	16	0	4.07E-06	-0.102
6	4	15	9	2	0	8	16	0	5	6.89E-08	0.131
4	6	9	16	15	5	0	6	16	0	4.07E-06	-0.102
5	9	13	15	1	5	0	6	16	0	4.07E-06	-0.102
6	7	6	14	10	0	8	16	0	5	6.89E-08	0.131
16	14	5	3	7	0	8	16	0	5	6.89E-08	0.131

Tabuľka 20: Signifikantnosť nominálnych jednotkových nákladov práce pre 1. skupinu

teóriu ekonómie, čo nás utvrdzuje o správnosti výsledku. Najvýznamnejší nám vyšiel tento parameter pri časovom posunutí o 5 kvartálov.

3.2 2. skupina

Druhú skupinu tvoria krajiny Bulharsko, Chorvátsko, Španielsko, Estónsko, Fínsko, Luxembursko, Malta, Poľsko a Slovensko. Hoci ide o relatívne veľkú vzorku dát, až 6 z týchto 9 krajín nemajú v dátach záznam o kríze. Možno aj práve kvôli tomu boli tieto krajiny zaradené do spoločnej skupiny. To nám spôsobovalo isté problémy pri analyzovaní ukazovateľov, ako aj pri vytváraní modelov, o čom sa presvedčíme v kapitole 4. Výsledky pre druhú skupinu sa nachádzajú v tabuľkách 26 - 30 v prílohe. Tu ich len v krátkosti opíšeme.

P-hodnoty bežného účtu platobnej bilancie vyšli výrazne vyššie ako pre prvú skupinu. Väčšina hodnôt sa blíži k hraničným 5%. Našli sme iba jednu kombináciu časových posunov, pre ktoré je koeficient β_C záporný, čo je v súlade s teóriou ekonómie. Avšak pre tento koeficient vyšla p-hodnota väčšia ako 5%, preto hypotézu o nulovosti koeficientu nezamietame. Všetky ostatné koeficienty vyšli kladné. Časové posunutie premennej sa pohybovalo medzi 0-1 kvartálom, no v prípade najsignifikantnejšej premennej (pre-

mennej s najnižšou p-hodnotou) vyšlo maximálne možné posunutie, teda 4 roky. Tieto nezrovnalosti pripisujeme už spomínanému problému s dátami.

Reálny efektívny výmenný kurz vyšiel rovnako pre všetkých 10 štartovacích bodov. Záporný koeficient $\beta_R = -0.108$ naznačuje, že rast tohto ukazovateľa bude znižovať nebezpečenstvo krízy, podobne ako pre prvú skupinu. Miera nezamestnanosti s hodnotou $\beta_U = 0.256$ predstavuje najvplyvnejší ukazovateľ v našom modeli. Ako sme už spomenuli, verejný dlh zaraďujeme medzi tie indikátory, ktoré nepriaznivo vplývajú na ekonomiku krajiny a preto požadujeme, aby jeho koeficient bol kladný. Taký sa nachádza v tabuľke 29 iba jeden a hoci je príslušná p-hodnota výrazne vyššia ako ostatné, stále je menšia ako 5%. Všetky tri indikátory najvýraznejšie ovplyvňujú krízu bez časového posunu. Posledný indikátor sú nominálne jednotkové náklady práce. Výsledné optimum s p-hodnotou rovnou 0.0073 a koeficientom $\beta_N = 0.129$ sme dosiahli pri posunutí premennej o 5 kvartálov v čase.

Ako si môžeme všimnúť, zatiaľ čo časový posun pre bežný účet platobnej bilancie vyšiel odlišne pre prvú a druhú skupinu, všetky ostatné posuny vyšli úplne rovnako. Koeficienty tých istých indikátorov sa síce nerovnajú, väčšina z nich však dosahuje približne rovnaké hodnoty. To nám hovorí, že v oboch skupinách existujú podobné závislosti medzi indikátormi a samotnou finančnou krízou.

3.3 3. skupina

V tretej skupine sú začlenené krajiny Francúzsko, Veľká Británia, Holandsko a Portugalsko. Výsledky tretej skupiny sú zobrazené v tabuľkách 31 - 35 v prílohe. Malý počet krajín avizuje, že tieto výsledky môžu byť vychýlené. Budeme preto porovnávať, nakoľko sú zhodné s tými v prvej a druhej skupine.

Rovnaké výsledky dosiahli indikátory bežný účet platobnej bilancie, miera nezamestnanosti a verejný dlh. Hovoríme pritom o výsledkoch, ktoré nie sú tie najsignifikantnejšie, ale sú v súlade s teóriou a samozrejme ich p-hodnota nepresiahla 5%. Miera nezamestnanosti a verejný dlh sú bez časového posunutia, čo je identické s prvou skupinou. Časové posunutie pre bežný účet platobnej bilancie pre $\beta_C = -0.152$ je rovné 12 kvartálov. Pre porovnanie v prvej skupine to bolo 10 kvartálov.

Na druhej strane reálny efektívny výmenný kurz a nominálne jednotkové náklady

práce vyšli presne naopak než sme očakávali. Kladné hodnoty koeficientov pre *Reer* znamenajú, že tento indikátor nepriaznivo vplyva na ekonomiku krajiny. Podobne záporný koeficient *Nulc* hovorí, že zvyšovanie jednotkových nákladov práce znižuje pravdepodobnosť krízy. Zatiaľ čo pre reálny efektívny výmenný kurz nevieme určiť záver, výsledok nominálnych jednotkových nákladov práce považujeme za nelogické a teda nesprávne. Úplne odlišné vyšli aj ich posunutia v čase.

3.4 4. skupina

V štvrtej skupine sa nachádzajú krajiny Dánsko, Taliansko a Slovinsko. Ide o najmenšiu skupinu dát a tým pádom sú výsledky značne vychýlené oproti ostatným skupinám. O tom sme sa už presvedčili v 2.2.2. kapitole, kde model vytvorený z týchto dát bol nekvalitný a nemal žiadnu výpovednú hodnotu. Chybou však nebol postup použitý pri analýzach, ale to, že sa nám nepodarilo získať väčšiu vzorku dát. Sme presvedčení, že pri väčšom počte dát by výsledky boli rovnako dobré, ako napríklad v prípade prvej skupiny.

Čo sa týka samotných indikátorov, bežný účet platobnej bilancie vyšiel najsignifikantnejší pri polročnom posune. Očakávali sme ale, že koeficient bude dosahovať záporné hodnoty. Podobne aj reálny efektívny výmenný kurz, ktorý tiež dosahuje len kladné hodnoty. Obidva indikátory pritom zaraďujeme do skupiny indikátorov, ktoré svojím zvyšovaním znižujú pravdepodobnosť krízy. Miera nezamestnanosti a verejný dlh vyšli podľa očakávaní, avšak nejedná sa o najsignifikantnejšie výsledky. Časový posun 0 kvartálov pre $\beta_U = 1.395$ a 1 kvartál pre $\beta_G = 0.061$ sa takmer zhodujú s výsledkami predchádzajúcich skupín. Nominálne jednotkové náklady práce, podobne ako prvé dva indikátory, nevyšli podľa predpokladu, ktorý hovorí o kladnom koeficiente. Prislúchajúce tabuľky 36 - 40 sa nachádzajú v prílohe.

4 Najlepšie predikujúci model

Ako už z názvu vyplýva, štvrtá kapitola sa zaoberá hľadaním najlepšie predikujúceho modelu pre krajiny Európskej únie. Tento model sa pokúsime nájsť využitím myšlienky, ktorú sme opísali v úvode tretej kapitoly. Budeme hľadať takú kombináciu časových posunutí parametrov, pri ktorých model najlepšie predikuje krízu. Budeme teda hľadať model s najnižšou hodnotou ANtSR.

Okrem ANtSR použijeme na porovnanie modelov aj CPR (z angl. Correct Prediction Rate). CPR vyjadruje úspešnosť varovných signálov modelu. Vypočíta sa ako pomer úspešných predpovedaní krízy ku všetkým varovným signálom, čiže podľa tabuľky 7 v kapitole 2.1.2:

$$\frac{D}{B + D}.$$

Correct prediction rate použili napríklad v [4], odkiaľ sme ho získali.

Rozdiel oproti 3. kapitole je v tom, že v jednotlivých iteráciách nebudeme zapisovať p-hodnoty. Vytvorený model použijeme priamo na testovaciu sadu dát a zistíme jeho schopnosť predikcie. P-hodnotu v tomto prípade nahradí ANtSR. Rozdelenie dát na trénovaciu a testovaciu vzorku je odlišné pre každú skupinu. Dáta sme sa snažili rozdeliť tak, aby v testovacej sade bolo relatívne dosť dát z obdobia krízy. Zároveň sme sa snažili, aby čo najviac dát bolo použitých na natréňovanie.

Ďalšou odlišnosťou v porovnaní s 3. kapitolou je fakt, že pri výbere najlepšie predikujúceho modelu použijeme výrazne viac štartovacích bodov. Aj v tomto prípade máme 17^5 kombinácií, ako vytvoriť model. Z časových dôvodov neprejdeme všetkými kombináciami. K výberu budeme pristupovať iteračne pomocou náhodne zvolených štartovacích bodov. Tých bude presne 100. Väčší počet ako v tretej kapitole sme zvolili preto, lebo očakávame, že rôzne výsledné posunutia parametrov dospejú k rovnakému výsledku ANtSR. Pri väčšom počte optimálnych riešení môžeme výsledky navzájom porovnať. V nasledujúcich štyroch tabuľkách sú zobrazené rôzne časové posunutia, pri ktorých modely dosahujú najlepšie výsledky.

Výsledky prvej skupiny sú znázornené v tabuľke 21. ANtSR vyšlo rovné 0.11765, čo je považované za veľmi dobrý model. Došlo k výraznému zlepšeniu oproti modelu v 2.2.2, kde $ANtSR = 0.29771$. Podobne Correct prediction rate, ktoré vyšlo takmer 70%, indikuje dobrý model.

Posunutie premenných					<i>ANtSR</i>	<i>CPR</i>
T^C	T^R	T^U	T^G	T^N		
13	4	16	0	3	0.117647058823529	0.684
5	7	14	0	12	0.117647058823529	0.684
6	4	15	0	11	0.117647058823529	0.684
5	4	15	0	12	0.117647058823529	0.684
7	3	15	0	11	0.117647058823529	0.684
6	3	15	0	12	0.117647058823529	0.684
14	7	16	0	2	0.117647058823529	0.684
13	6	16	0	2	0.117647058823529	0.684

Tabuľka 21: Najlepšie modely 1. skupiny

Tieto výsledky sme dosiahli pre 8 rôznych nastavení parametrov modelu. Hoci ide o rozdielne posunutia jednotlivých premenných, dá sa z tabuľky vyčítať istá podobnosť medzi nimi. Najjednoduchší je verejný dlh, ktorý vo všetkých 8 prípadoch bol bez časového posunutia. Reálny efektívny výmenný kurz vyšiel v rozmedzí 3-7 kvartálov. Jeho vplyv na krízu je približne s ročným časovým oneskorením. S trochu menším rozptylom vyšla nezamestnanosť, ktorej posunutie sa pohybovalo medzi 14-16 kvartálmi. Bežný účet platobnej bilancie a nominálne jednotkové náklady práce už nebolo také ľahké určiť. Tieto dva parametre rozdelili modely na dve skupiny. V prvej skupine má bežný účet platobnej bilancie viac ako 3-ročné časové posunutie, zatiaľ čo nominálne jednotkové náklady práce majú vplyv na krízu s približne polročným časovým oneskorením. Druhú skupinu tvoria modely, v ktorých je to naopak. Bežný účet platobnej bilancie má časové posunutie v rozmedzí 5-7 kvartálov a nominálne jednotkové náklady práce majú približne 3-ročné časové posunutie.

Pri výbere ktorejkoľvek možnosti dostaneme rovnako dobre predikujúci model. Pri vyššom počte dát by sa ale zrejme tieto modely začali jemne líšiť v predikcii, čím by sa vybral najvhodnejší z nich. Podľa signifikantnosti by sme zvolili predposledný model. Pri danom časovom posunutí majú jeho premenné najväčšiu signifikantnosť spomedzi všetkých. No aj napriek tomu považujeme všetky modely za dobré, keďže až 70% signálov sú úspešné varovania pred krízou.

Posunutie premenných					$ANtSR$	CPR
T^C	T^R	T^U	T^G	T^N		
7	5	7	9	1	0.0330578512396694	0.2
4	0	8	9	1	0.0330578512396694	0.2

Tabuľka 22: Najlepšie modely 2. skupiny

V prípade druhej skupiny sú výsledky značne skreslené. Hoci $ANtSR = 0.03306$ (pre porovnanie v 2.2.2. kapitole vyšlo $ANtSR = 0.10833$) značí kvalitný model, correct prediction rate vyšlo iba 20%, čo hovorí o opaku. Dôvodom toho je nedostatok krízových dát v testovacej vzorke. Model potom nemá problém zaradiť všetky krízové obdobia do tej správnej skupiny. To sa prejaví na dobrom výsledku $ANtSR$, ktoré nevie zohľadniť počet varovných signálov, ktoré model potreboval na správne určenie krízy. Inými slovami, model síce predpovie všetky krízy, avšak varovných signálov má oveľa viac. Na druhej strane Correct prediction rate sa pozerá práve na túto vlastnosť modelu. Obidva modely, ktoré nám vyšli ako najlepšie, potrebovali až 5-násobne viac varovných signálov, ako bolo dát krízy.

Spomedzi dvojice modelov sa nám zdá byť vhodnejší ten druhý, práve kvôli signifikantnosti parametrov. V prípade druhého modelu sú nesignifikantné dva parametre, a to bežný účet platobnej bilancie a nominálne jednotkové náklady práce. Zatiaľ čo v prvom modeli vyšiel nesignifikantný aj verejný dlh.

Čo sa týka parametrov, tri z piatich vyšli približne rovnako v oboch modeloch. Nominálne jednotkové náklady práce s časovým posunom 1 štvrtrok, verejný dlh s posunom 9 kvartálov a miera nezamestnanosti posunutá približne o 2 roky. Bežný účet platobnej bilancie vyšiel v rozpätí 1-2 rokov. Avšak v oboch prípadoch bol tento indikátor nesignifikantný a pri ďalšej práci s modelom by sa mohol vylúčiť. Reálny efektívny výmenný kurz mal oveľa vyššiu signifikantnosť v druhom modeli, teda bez časového posunutia.

V tretej skupine máme výrazne menší počet dát ako v prvej či druhej skupine. No aj napriek tomu dosahuje pomerne dobré výsledky. Keďže sme našli iba jedno optimálne riešenie, pre porovnanie sme priložili druhý najlepší model. Došlo k výraznému zlepšeniu predikcie oproti modelu v 2.2.2, kde $ANtSR = 0.58696$. Práve kvôli

Posunutie premenných					$ANtSR$	CPR
T^C	T^R	T^U	T^G	T^N		
9	5	0	16	16	0.1875	0.55
11	4	0	15	16	0.2083333333333333	0.5238

Tabuľka 23: Najlepšie modely 3. skupiny

$ANtSR = 0.1875$ sa model začlenil medzi dobré modely, ktorých hodnota je menšia ako 0.3.

Correct prediction rate vyšlo mierne nad 50%. Teda pri použití tohto modelu v praxi by približne polovica varovných signálov bola správnych. Vo zvyšných prípadoch by opatrenia proti kríze boli zbytočné. Berúc ale do úvahy podmienky, za ktorých bol model vytvorený, považujeme výsledky predikcie za dobré. V tabuľke 23 môžeme vidieť časový posun indikátorov, pri ktorých má model najlepšie výsledky.

Posunutie premenných					$ANtSR$	CPR
T^C	T^R	T^U	T^G	T^N		
14	0	14	10	9	0	1
14	0	14	8	11	0	1
13	2	16	14	10	0	1
14	0	14	11	8	0	1
13	1	14	12	10	0	1
12	0	16	0	9	0	1

Tabuľka 24: Najlepšie modely 4. skupiny

Časové posunutia indikátorov štvrtej skupiny, rovnako ako aj výsledky predikcie sú znázornené v tabuľke 24. Ako môžeme vidieť, pre túto skupinu krajín sa nám podarilo vytvoriť dokonalý model. Model jednoznačne odhalil všetky krízové obdobia a potreboval na to rovnaký počet varovných signálov. To znamená, že $ANtSR = 0$ a $CPR = 1$. Tento úspech však pripisujeme vo veľkej miere malému počtu dát a čiastočne aj náhode.

Model rozhodne nepovažujeme za dôveryhodný a nemal by sa použiť by vytváraní politických stratégií.

Podobne ako v 3. kapitole, ani tu sme neprechádzali všetkými kombináciami mo-

delov, ale k hľadaniu sme pristupovali iteračne. Získané výsledky preto nemusia predstavovať globálne optima. Je pravdepodobné, že z niektorého štartovacieho bodu to konvergovalo do lokálneho optima. V takom prípade by existovala kombinácia časových posunov, ktorá by vytvorila ešte kvalitnejší model. O tom, či ide o globálne optimum, by sme si boli istí len v prípade, pokiaľ by sme prešli všetkými 17⁵ kombináciami.

Medzi jednotlivými skupinami môžeme vidieť značné rozdiely. V každej skupine je odlišný časový posun premenných pre najlepšie predikujúce modely. Neexistujú dve skupiny, ktoré by mali čo i len podobné posunutie. Napríklad verejný dlh v prvej skupine je bez časového posunu. V zvyšných troch skupinách je verejný dlh posunutý minimálne o dva roky. To odlišuje prvú skupinu od ostatných. Dôvodom toho je rozdielnosť v dátach. Považujeme preto za dobrý krok rozdelenie krajín do skupín. V prípade vytvorenia jednej skupiny by bol model natrénovaný na dátach pravdepodobne vychýlený.

Čo sa týka samotných modelov, modely pre druhú a štvrtú skupinu považujeme za nedôveryhodné a preto ich neodporúčame použiť pri vytváraní stratégií predchádzajúcich krízu. Postup použitý pri vytvorení modelov bol rovnaký vo všetkých prípadoch. Avšak v druhej skupine bol problém nedostatok dát obsahujúcich informáciu o kríze. V štvrtej skupine bol nedostatok dát celkovo. Model vytvorený pre tretiu skupinu mal pomerne málo dát, no výsledky boli celkom priaznivé. Hodnota ANtSR indikovala dobrý model a taktiež CPR ukázalo, že viac ako polovica varovných signálov skutočne varuje pred krízou. Jednoznačne najlepším modelom je model prvej skupiny. Dostatočný počet dát sa tu odzrkadlil na kvalite modelu, ktorý až v 70% prípadov varovných signálov úspešne predpovedá krízu. Model považujeme za schopný použitia pri riadení ekonomiky krajín a analýze hrozby blížiacich sa finančných kríz.

Záver

V tejto diplomovej práci sme sa zaoberali témou finančnej krízy v európskych krajinách a spôsobom, ako ich predikovať, aby tvorcovia hospodárskej politiky mali dostatok priestoru na korekcie nepriaznivého ekonomického vývoja. Existuje mnoho systémov včasného varovania, s ktorými ekonómovia dennodenne pracujú. My sme sa rozhodli použiť logistickú regresiu na vytvorenie takéhoto systému. Väčšinou je však vytvorený jeden systém včasného varovania pre všetky pozorované krajiny, čím vzniká istá nepresnosť práve kvôli heterogenite krajín. To sme sa pokúsili odstrániť metódou nehierarchickej analýzy zhlukov.

V prvej časti práce sme oboznámili čitateľa s pojmom systém včasného varovania a načrtli sme niekoľko typov týchto systémov od rôznych autorov. Taktiež sme tu opísali dáta, s ktorými sme pracovali a priblížili čitateľovi ich zdroj. Následne sme roztriedili krajiny do skupín. Použili sme zhlučovanie založené na modeli, pričom krajiny sme sa snažili roztriediť do optimálneho počtu skupín, aby sme mali dostatok dát v každej skupine a taktiež aby nebolo vytvorených príliš veľa skupín. Zhlučovali sme tromi rôznymi spôsobmi. Vo všetkých troch prípadoch sme krajiny roztriedili do štyroch skupín. Pre každú skupinu sme vytvorili systém včasného varovania v podobe logistickej regrese a otestovali sme schopnosť jeho predikcie. Na základe výsledkov týchto systémov sme vybrali najlepší spôsob zhlučovania. S týmto rozdelením sme pokračovali v ďalších analýzach.

V druhej časti, ktorú tvorí tretia a štvrtá kapitola, sme sa zaoberali už samotnými štyrmi systémami včasného varovania vytvorených pre štyri skupiny krajín výsledného rozdelenia. Analyzovali sme signifikantnosť ekonomických indikátorov vystupujúcich v modeloch. Pozorovali sme, aký vplyv na krízu majú indikátory s rôznymi časovými posunmi a hľadali sme také posuny, s ktorými sú premenné najsignifikantnejšie. Jednotlivé skupiny sa svojimi výsledkami mierne odlišovali a preto ich tu nebudeme všetky uvádzať. Výsledky spolu s príslušnými tabuľkami sa nachádzajú v 3. kapitole a Prílohe A.

Súčasťou druhej časti je aj vytvorenie najlepších modelov pre všetky skupiny, a to hľadaním takej kombinácie lagovaných premenných, pri ktorých má model najlepšiu schopnosť predikcie krízy. Zo štyroch vytvorených modelov považujeme dva za apli-

kovateľné v praxi. Prvý je model vytvorený pre prvú skupinu krajín, ktorý dosiahol $ANtSR = 0.11765$ a $CPR = 0.684$. V tomto prípade mal bežný účet platobnej bilancie vplyv na krízu s jeden a pol ročným oneskorením, reálny efektívny výmenný kurz s ročným oneskorením, nezamestnanosť so štvorročným oneskorením. Verejný dlh bol bez časového oneskorenia a nominálne jednotkové náklady práce s trojročným oneskorením. Druhý aplikovateľný model je model tretej skupiny. V tomto modeli vyšlo $ANtSR = 0.1875$ a $CPR = 0.55$, čo na daný počet dát značí kvalitný model. Indikátory vyšli podobne ako pre prvý model. Bežný účet platobnej bilancie mal dvojročné oneskorenie, reálny efektívny výmenný kurz ročné oneskorenie a nominálne jednotkové náklady práce štvorročné oneskorenie. Miera nezamestnanosti a verejný dlh sú presne naopak, nezamestnanosť je bez časového oneskorenia a verejný dlh so štvorročným oneskorením. Modely pre druhú a štvrtú skupinu nepovažujeme za vhodné aplikácie v praxi vzhľadom na ich nepriaznivé výsledky.

Najväčším problémom, s ktorým sme sa pri písaní stretli, je už viackrát spomínaný nedostatok dát. Väčšina európskych krajín je pomerne mladá, preto je počet dát malý. Pri väčšom počte dát by modely boli výrazne presnejšie. Takisto by sme nemuseli robiť viaceré analýzy na tých istých dátach, kvôli čomu vznikla možná vychýlenosť modelov.

Zoznam použitej literatúry

- [1] Alessi, L., Antunes, A., Babecký, J., Baltussen, S., Behn, M., Bonfim, D., Bush, O., Detken, C., Frost, J., Guimaraes, R., Havránek, T., Joy, M., Kauko, K., Matěju, J., Monteiro, N., Neudorfer, B., Peltonen, T., Rodrigues, P.M.M., Rusnák, M., Schudel, W., Sigmund, M., Stremmel, H., Šmídková, K., Van Tilburg, R., Vašíček, B., Žigraiová, D. : Comparing different early warning systems: Result from a horse race competition among members of the Macro-prudential Research Network, University Library of Munich, Germany, 2015
- [2] Antunes, A., Bonfim, D., Monteiro, N., Rodrigues P.M.M. : Early warning indicators of banking crises: exploring new data and tools, Economic Bulletin and Financial Stability Report Articles, Banco de Portugal, Economics and Research Department, 2014
- [3] Csontos, O., Szalai, Z. : Assessment of macroeconomic imbalance indicators, MNB Bulletin, 2013, dostupné na internete (15.4.2018): <http://www.mnb.hu/letoltes/mnb-szemle-2013-okt-eng-final.pdf#page=16>
- [4] Domonkos, T., Ostrihoň, F., Šikulová, I., Širaňová, M. : Analysing the Relevance of the MIP Scoreboard's Indicators, National Institute of Economic and Social Research, vol. 239(1) (2017), 32-52
- [5] European Systemic Risk Board, dostupné na internete (28.11.2017): <https://www.esrb.europa.eu/pub/financial-crises/html/index.en.html>
- [6] Eurostat, dostupné na internete (28.11.2017): <http://ec.europa.eu/eurostat/web/macroeconomic-imbalances-procedure/indicators>
- [7] Focuseconomics - Economic Forecasts from the World's Leading Economists, dostupné na internete (4.4.2018): <https://www.focus-economics.com/economic-indicator/current-account-balance>
- [8] Gelman, A., Jakulin, A., Pittau, M. G., Su, Y. : A weakly informative default prior distribution for logistic and other regression models, Ann.

- Appl. Stat. Vol. 2 (2008), No. 4, 2008, dostupné na internete(16.12.2017):
https://projecteuclid.org/download/pdfview_1/euclid.aoas/1231424214
- [9] International Monetary Fund, dostupné na internete (6.4.2018):
<http://datahelp.imf.org/knowledgebase/articles/537472-what-is-real-effective-exchange-rate-reer>
- [10] Kaminski, G., Lizondo, S., Reinhart, C. M. : Leading Indicators of Currency Crises, Staff Papers, Vol. 45, No. 1, International Monetary Fund, 1998
- [11] Kaminski, G., Reinhart, C. M. : The Twin Crises: The Causes of Banking and Balance-of-Payments Problems, The American Economic Review, Vol. 89, No. 3, American Economic Association, 1999
- [12] Organisation for Economic Co-operation and Development, dostupné na internete(8.4.2018): <https://data.oecd.org/lprdy/unit-labour-costs.htm>

Príloha A

	Q1 2008	Q2 2008	Q3 2008	Q4 2008	...	Q1 2016	Q2 2016	Q3 2016	Q4 2016
AUT	1	1	1	1	...	1	1	1	1
BEL	2	1	1	2	...	1	2	1	2
BLG	3	1	2	3	...	2	3	3	3
CRO	1	2	1	4	...	2	4	2	4
CYP	2	2	1	2	...	1	5	1	4
CZE	3	1	2	3	...	2	6	3	5
DEU	4	1	1	5	...	1	1	1	1
DNK	5	1	1	6	...	1	7	1	6
ESP	2	2	1	2	...	2	5	2	6
EST	5	1	2	6	...	2	3	3	3
FIN	4	1	1	5	...	1	7	1	6
FRA	2	2	1	4	...	1	1	1	1
GRB	2	1	1	4	...	2	5	3	7
GRC	2	2	1	4	...	1	2	2	2
HUN	1	1	1	1	...	1	1	2	1
IRL	1	1	1	1	...	1	5	3	6
ITA	2	2	1	2	...	1	2	1	2
LTU	3	1	2	3	...	2	3	3	3
LUX	5	1	1	6	...	2	7	3	5
LVA	3	1	2	3	...	2	3	3	3
MLT	4	1	1	5	...	1	1	1	1
NLD	4	1	1	5	...	1	4	1	7
POL	4	1	1	6	...	2	6	2	4
PRT	2	2	1	2	...	1	1	1	1
ROM	5	1	2	6	...	2	3	3	3
SVK	3	1	2	3	...	2	6	2	5
SVN	1	1	1	1	...	2	7	3	6
SWE	5	1	1	6	...	2	4	1	7

Tabuľka 25: Rozdelenie krajín v jednotlivých kvartáloch

Štartovací bod					Výsledné posunutie					P-value	β_C
T_0^C	T_0^R	T_0^U	T_0^G	T_0^N	T^C	T^R	T^U	T^G	T^N		
6	10	11	8	4	1	13	6	6	5	0.0459	0.039
9	13	16	0	9	1	13	6	6	5	0.0459	0.039
4	15	5	8	6	1	13	6	6	5	0.0459	0.039
10	10	7	16	15	1	13	6	6	5	0.0459	0.039
13	6	0	7	6	0	16	5	5	4	0.0400	0.041
3	11	14	5	9	1	13	6	6	5	0.0459	0.039
10	7	0	6	6	16	16	0	10	0	0.0104	0.049
11	4	1	15	10	16	16	0	10	0	0.0104	0.049
8	9	8	14	9	1	13	6	6	5	0.0459	0.039
1	9	16	12	12	15	0	16	16	14	0.0523	-0.039

Tabuľka 26: Signifikantnosť bežného účtu platobnej bilancie pre 2. skupinu

Štartovací bod					Výsledné posunutie					P-value	β_R
T_0^C	T_0^R	T_0^U	T_0^G	T_0^N	T^C	T^R	T^U	T^G	T^N		
15	5	13	6	5	0	0	0	9	11	0.00016	-0.108
2	16	1	3	4	0	0	0	9	11	0.00016	-0.108
4	13	11	6	13	0	0	0	9	11	0.00016	-0.108
11	14	1	13	11	0	0	0	9	11	0.00016	-0.108
10	16	5	1	9	0	0	0	9	11	0.00016	-0.108
1	7	14	7	15	0	0	0	9	11	0.00016	-0.108
2	4	9	13	1	0	0	0	9	11	0.00016	-0.108
6	5	7	8	4	0	0	0	9	11	0.00016	-0.108
5	2	15	8	5	0	0	0	9	11	0.00016	-0.108
8	15	3	6	8	0	0	0	9	11	0.00016	-0.108

Tabuľka 27: Signifikantnosť reálneho efektívneho výmenného kurzu pre 2. skupinu

Štartovací bod					Výsledné posunutie					P-value	β_U
T_0^C	T_0^R	T_0^U	T_0^G	T_0^N	T^C	T^R	T^U	T^G	T^N		
0	7	8	13	9	0	0	0	11	16	3.23E-11	0.253
14	9	4	7	11	0	0	0	11	16	3.23E-11	0.253
8	14	13	2	4	6	6	0	11	5	3.63E-11	0.256
6	0	7	0	15	0	0	0	11	16	3.23E-11	0.253
13	1	1	0	13	0	0	0	11	16	3.23E-11	0.253
15	6	10	12	4	0	0	0	11	16	3.23E-11	0.253
11	10	0	2	7	0	0	0	11	16	3.23E-11	0.253
9	14	1	10	2	0	0	0	11	16	3.23E-11	0.253
1	9	6	7	14	0	0	0	11	16	3.23E-11	0.253
3	1	15	12	3	0	0	0	11	16	3.23E-11	0.253

Tabuľka 28: Signifikantnosť nezamestnanosti pre 2. skupinu

Štartovací bod					Výsledné posunutie					P-value	β_G
T_0^C	T_0^R	T_0^U	T_0^G	T_0^N	T^C	T^R	T^U	T^G	T^N		
1	14	1	7	12	7	0	0	12	12	3.46E-05	-0.048
5	0	3	13	11	7	0	0	12	12	3.46E-05	-0.048
5	15	9	11	2	7	0	0	12	12	3.46E-05	-0.048
8	3	8	1	13	0	16	16	0	7	0.00016	0.029
13	5	6	13	14	7	0	0	12	12	3.46E-05	-0.048
7	8	16	8	16	7	0	0	12	12	3.46E-05	-0.048
6	4	15	9	2	7	0	0	12	12	3.46E-05	-0.048
4	6	9	16	15	7	0	0	12	12	3.46E-05	-0.048
5	9	13	15	1	7	0	0	12	12	3.46E-05	-0.048
6	7	6	14	10	7	0	0	12	12	3.46E-05	-0.048

Tabuľka 29: Signifikantnosť verejného dlhu pre 2. skupinu

Štartovací bod					Výsledné posunutie					P-value	β_N
T_0^C	T_0^R	T_0^U	T_0^G	T_0^N	T^C	T^R	T^U	T^G	T^N		
16	14	5	3	7	5	6	4	0	5	0.0073	0.129
14	12	16	7	15	3	16	0	12	12	0.0108	-0.117
10	11	2	5	13	3	16	0	12	12	0.0108	-0.117
4	12	12	10	9	3	16	0	12	12	0.0108	-0.117
11	13	3	14	4	5	6	4	0	5	0.0073	0.129
6	12	12	11	10	3	16	0	12	12	0.0108	-0.117
5	13	4	4	5	5	6	4	0	5	0.0073	0.129
7	7	9	7	1	7	6	13	14	0	0.0157	-0.108
12	3	12	2	8	5	6	4	0	5	0.0073	0.129
13	16	12	12	8	5	6	4	0	5	0.0073	0.129

Tabuľka 30: Signifikantnosť nominálnych jednotkových nákladov práce pre 2. skupinu

Štartovací bod					Výsledné posunutie					P-value	β_C
T_0^C	T_0^R	T_0^U	T_0^G	T_0^N	T^C	T^R	T^U	T^G	T^N		
0	8	3	13	6	0	16	0	5	16	3.90E-06	0.206
1	15	7	1	13	12	6	5	1	16	0.0036	-0.152
13	11	1	10	8	0	16	0	5	16	3.90E-06	0.206
2	11	13	5	15	0	16	0	5	16	3.90E-06	0.206
12	12	13	5	1	0	16	0	5	16	3.90E-06	0.206
2	13	6	10	9	0	16	0	5	16	3.90E-06	0.206
2	11	15	14	9	0	16	0	5	16	3.90E-06	0.206
9	7	15	6	13	0	16	0	5	16	3.90E-06	0.206
1	15	5	7	13	0	16	0	5	16	3.90E-06	0.206
13	12	7	0	3	12	6	5	1	16	0.0036	-0.152

Tabuľka 31: Signifikantnosť bežného účtu platobnej bilancie pre 3. skupinu

Štartovací bod					Výsledné posunutie					P-value	β_R
T_0^C	T_0^R	T_0^U	T_0^G	T_0^N	T^C	T^R	T^U	T^G	T^N		
4	9	10	8	5	11	9	3	0	11	8.16E-07	0.277
3	11	14	13	13	11	9	3	0	11	8.16E-07	0.277
2	3	9	11	12	11	9	3	0	11	8.16E-07	0.277
4	10	15	13	16	11	9	3	0	11	8.16E-07	0.277
6	4	4	14	2	11	9	3	0	11	8.16E-07	0.277
3	15	10	16	14	11	9	3	0	11	8.16E-07	0.277
3	14	14	9	2	11	9	3	0	11	8.16E-07	0.277
7	6	9	12	1	11	9	3	0	11	8.16E-07	0.277
12	14	4	9	4	11	9	3	0	11	8.16E-07	0.277
13	14	5	10	12	11	9	3	0	11	8.16E-07	0.277

Tabuľka 32: Signifikantnosť reálneho efektívneho výmenného kurzu pre 3. skupinu

Štartovací bod					Výsledné posunutie					P-value	β_U
T_0^C	T_0^R	T_0^U	T_0^G	T_0^N	T^C	T^R	T^U	T^G	T^N		
8	10	4	3	14	4	8	5	0	9	5.49E-08	-1.334
11	16	12	14	1	1	16	0	6	16	6.43E-06	0.899
15	11	11	4	11	4	8	5	0	9	5.49E-08	-1.334
10	9	4	4	3	4	8	5	0	9	5.49E-08	-1.334
9	7	12	10	2	4	8	5	0	9	5.49E-08	-1.334
16	11	9	1	6	12	7	5	0	16	6.66E-08	-1.615
8	13	12	9	8	4	8	5	0	9	5.49E-08	-1.334
8	13	15	9	6	1	16	0	6	16	6.43E-06	0.899
14	7	15	3	16	4	8	5	0	9	5.49E-08	-1.334
3	7	3	1	4	4	8	5	0	9	5.49E-08	-1.334

Tabuľka 33: Signifikantnosť nezamestnanosti pre 3. skupinu

Štartovací bod					Výsledné posunutie					P-value	β_G
T_0^C	T_0^R	T_0^U	T_0^G	T_0^N	T^C	T^R	T^U	T^G	T^N		
5	12	6	8	3	6	9	5	0	12	2.24E-09	0.166
10	13	0	15	8	1	16	0	6	16	6.01E-05	-0.127
15	2	10	2	13	6	8	5	0	0	2.18E-09	0.168
9	12	8	10	7	6	8	5	0	0	2.18E-09	0.168
13	15	4	7	9	6	9	5	0	12	2.24E-09	0.166
2	13	4	12	14	6	9	5	0	12	2.24E-09	0.166
3	7	1	8	5	1	16	0	6	16	6.01E-05	-0.127
9	3	10	14	8	6	8	5	0	0	2.18E-09	0.168
6	14	4	8	16	6	8	5	0	0	2.18E-09	0.168
7	1	6	14	11	6	9	4	0	1	2.25E-09	0.182

Tabuľka 34: Signifikantnosť verejného dlhu pre 3. skupinu

Štartovací bod					Výsledné posunutie					P-value	β_N
T_0^C	T_0^R	T_0^U	T_0^G	T_0^N	T^C	T^R	T^U	T^G	T^N		
4	8	8	4	15	14	13	4	2	16	0.00015	-0.452
6	3	1	7	11	14	13	4	2	16	0.00015	-0.452
9	13	8	1	0	3	13	16	0	16	0.00022	-0.442
6	9	3	12	11	3	13	16	0	16	0.00022	-0.442
10	2	4	16	6	12	0	15	15	16	0.00033	-0.418
8	11	15	12	10	14	0	12	13	16	0.00038	-0.411
6	12	15	6	8	1	0	0	5	16	0.00042	-0.421
4	4	4	4	1	14	13	4	2	16	0.00015	-0.452
10	13	5	1	9	14	13	4	2	16	0.00015	-0.452
14	12	15	14	15	3	13	16	0	16	0.00022	-0.442

Tabuľka 35: Signifikantnosť nominálnych jednotkových nákladov práce pre 3. skupinu

Štartovací bod					Výsledné posunutie					P-value	β_C
T_0^C	T_0^R	T_0^U	T_0^G	T_0^N	T^C	T^R	T^U	T^G	T^N		
0	15	8	16	5	2	0	7	0	9	1.51E-07	0.670
4	10	6	13	13	2	0	7	0	9	1.51E-07	0.670
13	6	7	11	7	2	0	7	0	9	1.51E-07	0.670
11	11	14	1	7	2	0	7	0	9	1.51E-07	0.670
13	8	0	15	7	2	0	7	0	9	1.51E-07	0.670
14	8	11	11	7	3	0	7	1	10	1.68E-07	0.760
11	4	9	14	12	3	0	7	1	10	1.68E-07	0.760
7	5	10	0	11	3	0	7	1	10	1.68E-07	0.760
14	2	8	0	15	3	0	5	0	15	2.58E-07	0.938
16	11	12	9	5	5	0	8	9	16	3.66E-07	0.741

Tabuľka 36: Signifikantnosť bežného účtu platobnej bilancie pre 4. skupinu

Štartovací bod					Výsledné posunutie					P-value	β_R
T_0^C	T_0^R	T_0^U	T_0^G	T_0^N	T^C	T^R	T^U	T^G	T^N		
15	1	9	7	8	15	5	10	4	15	4.14E-07	1.479
6	10	9	9	4	15	5	10	4	15	4.14E-07	1.479
6	1	10	6	2	8	2	10	9	16	4.53E-07	1.293
5	11	16	0	9	14	4	10	3	14	4.57E-07	1.364
2	4	12	3	5	8	2	9	3	16	4.58E-07	1.237
12	2	16	14	2	16	6	10	5	16	4.63E-07	1.512
13	4	5	2	13	15	5	8	2	14	4.68E-07	1.403
15	14	4	11	16	12	2	10	4	16	4.82E-07	1.284
8	9	12	3	16	12	2	10	4	16	4.82E-07	1.284
9	4	3	12	10	16	6	9	5	15	4.95E-07	1.486

Tabuľka 37: Signifikantnosť reálneho efektívneho výmenného kurzu pre 4. skupinu

Štartovací bod					Výsledné posunutie					P-value	β_U
T_0^C	T_0^R	T_0^U	T_0^G	T_0^N	T^C	T^R	T^U	T^G	T^N		
0	5	15	9	6	13	0	0	15	11	5.02E-07	1.395
0	4	9	15	7	13	0	0	15	11	5.02E-07	1.395
15	13	2	15	2	13	0	0	15	11	5.02E-07	1.395
14	2	14	10	5	13	0	0	15	11	5.02E-07	1.395
16	11	15	6	7	13	0	0	15	11	5.02E-07	1.395
13	8	8	8	14	12	8	14	1	12	7.93E-07	-1.812
13	3	11	5	15	12	8	14	1	12	7.93E-07	-1.812
3	2	10	13	6	12	8	14	1	12	7.93E-07	-1.812
9	13	5	1	16	12	8	14	1	12	7.93E-07	-1.812
13	9	5	13	1	14	8	15	12	14	8.30E-07	-2.200

Tabuľka 38: Signifikantnosť nezamestnanosti pre 4. skupinu

Štartovací bod					Výsledné posunutie					P-value	β_G
T_0^C	T_0^R	T_0^U	T_0^G	T_0^N	T^C	T^R	T^U	T^G	T^N		
5	13	4	8	6	14	16	0	11	3	1.55E-05	-0.060
14	16	1	9	12	14	16	0	11	3	1.55E-05	-0.060
10	15	0	14	3	14	16	0	11	3	1.55E-05	-0.060
0	8	1	2	2	14	16	0	11	3	1.55E-05	-0.060
10	4	14	10	0	12	1	14	1	16	2.67E-05	0.061
11	1	12	15	9	12	1	14	1	16	2.67E-05	0.061
16	14	9	14	12	12	1	14	1	16	2.67E-05	0.061
2	3	5	15	8	16	1	13	0	16	2.93E-05	0.055
3	14	10	8	3	15	0	13	1	16	3.19E-05	0.059
11	9	14	6	10	15	0	13	1	16	3.19E-05	0.059

Tabuľka 39: Signifikantnosť verejného dlhu pre 4. skupinu

Štartovací bod					Výsledné posunutie					P-value	β_N
T_0^C	T_0^R	T_0^U	T_0^G	T_0^N	T^C	T^R	T^U	T^G	T^N		
1	3	11	13	6	15	2	9	10	0	1.77E-05	-0.589
8	6	3	3	5	15	2	9	10	0	1.77E-05	-0.589
2	5	2	10	5	15	2	9	10	0	1.77E-05	-0.589
9	13	4	1	14	15	2	9	10	0	1.77E-05	-0.589
10	13	15	16	0	11	2	8	10	0	1.81E-05	-0.573
16	10	8	10	4	11	2	8	10	0	1.81E-05	-0.573
2	2	13	9	4	11	2	8	10	0	1.81E-05	-0.573
7	0	5	14	2	11	2	8	10	0	1.81E-05	-0.573
15	11	7	9	1	12	1	9	11	1	4.66E-05	-0.521
9	3	11	10	7	15	5	12	14	7	0.0010	-0.586

Tabuľka 40: Signifikantnosť nominálnych jednotkových nákladov práce pre 4. skupinu