

EKONOMICKÁ UNIVERZITA V BRATISLAVE
FAKULTA HOSPODÁRSKEJ INFORMATIKY

Evidenčné číslo: 103003/I/2020/421000013850

**Modelovanie regionálnych disparít vo vybraných európskych
regiónoch na báze nástrojov priestorovej ekonometrie**

(Diplomová práca)

2020

Bc. Denisa Kováčová

EKONOMICKÁ UNIVERZITA V BRATISLAVE
FAKULTA HOSPODÁRSKEJ INFORMATIKY

**Modelovanie regionálnych disparít vo vybraných európskych
regiónoch na báze nástrojov priestorovej ekonometrie**

(Diplomová práca)

Študijný program: Operačný výskum a ekonometria

Študijný odbor: Ekonómia a manažment

Školiace pracovisko: Katedra operačného výskumu a ekonometrie

Vedúci záverečnej práce: doc. Ing. Michaela Chocholatá, PhD.

Bratislava 2020

Bc. Denisa Kováčová



Ekonomická univerzita v Bratislave
Fakulta hospodárskej informatiky

ZADANIE ZÁVEREČNEJ PRÁCE

Meno a priezvisko študenta: Bc. Denisa Kováčová
Študijný program: operačný výskum a ekonometria (Jednoodborové štúdium, inžiniersky II. st., denná forma)
Študijný odbor: ekonómia a manažment
Typ záverečnej práce: Inžinierska záverečná práca
Jazyk záverečnej práce: slovenský
Sekundárny jazyk: anglický

Názov: Modelovanie regionálnych disparít vo vybraných európskych regiónoch na báze nástrojov priestorovej ekonometrie

Anotácia: Analýza regionálnych disparít predstavuje zaujímavú a vysoko aktuálnu problematiku. Regionálne disparity vo všeobecnosti možno špecifikovať pre báze rôznych indikátorov pre regióny na rôznych úrovniach členenia. Súčasná regionálna politika Európskej únie (EÚ) je zameraná na postupnú elimináciu regionálnych disparít najmä v oblastiach ekonomického rastu, vzdelávania, výskumu a inovácií, zamestnanosti, sociálneho začlenenia a znižovania chudoby. Pri analýze regionálnych disparít a navrhovaní riešení na ich odstránenie je možné využiť rôzne prístupy. Jednou z možností, ktorá je v poslednom období pri analýze disparít veľmi populárna, je využitie nástrojov priestorovej analýzy dát a priestorovej ekonometrie, ktoré umožňujú zohľadniť aj existenciu prípadných priestorových závislostí medzi regiónmi.

Vedúci: doc. Ing. Michaela Chocholatá, PhD.
Katedra: KOVE FHI - Katedra operačného výskumu a ekonometrie FHI
Vedúci katedry: prof. Mgr. Juraj Pekár, PhD.
Dátum zadania: 22.10.2018

Dátum schválenia: 05.11.2018
prof. Mgr. Juraj Pekár, PhD.
vedúci katedry

Čestné vyhlásenie

Čestne vyhlasujem, že som záverečnú prácu vypracovala samostatne a uviedla som všetku použitú literatúru.

Dátum:

.....

Pod'akovanie

Vyslovujem pod'akovanie pani doc. Ing. Michaelae CHOCHOLATEJ, PhD. za jej pripomienky, neocenitel'né rady, podporu a metodickú pomoc pri písaní diplomovej práce.

ABSTRAKT

Kováčová, Denisa: Modelovanie regionálnych disparít vo vybraných európskych regiónoch na báze nástrojov priestorovej ekonometrie. – Ekonomická univerzita v Bratislave. Fakulta hospodárskej informatiky; Katedra operačného výskumu a ekonometrie. – Vedúci záverečnej práce: doc. Ing. Michaela Chocholatá, PhD. – Bratislava: FHI EU, 2019/2020, počet strán 80.

Cieľom záverečnej práce je analyzovanie a posúdenie regionálnych disparít v európskych regiónoch na báze nástrojov priestorovej ekonometrie. Práca je rozdelená do 4 hlavných kapitol. Obsahuje 7 grafov, 10 tabuliek, 7 máp, 18 obrázkov, 5 výstupov z programu GeoDa a prílohy A, B, C. Prvá kapitola obsahuje teoretický pohľad na súčasný stav riešenej problematiky doma aj v zahraničí. Objasňuje terminológiu použitých odborných pojmov prostredníctvom pohľadu odborných autorov. Charakterizuje pojmy, priestorové ukazovatele a ich vplyv na regionálne disparity v Európe na úrovni jednotlivých regiónov. Popisuje priestorovú ekonometriu, priestorovú štatistiku a ekonometrické SAR a SEM modely. A v neposlednom rade opisuje Európsku úniu, jej princípy, zásady i ciele, ktoré sa snaží dosiahnuť pri znižovaní regionálnych disparít v Európskej únii. V ďalšej časti sa popisuje cieľ, metódy a metodika práce, ktoré charakterizujú predmet a postupy, ktoré sa použili na dosiahnutie riešenia. Opisujú sa nástroje priestorovej štatistiky, ktoré sa využili na analýzu dát. Bližšie sa špecifikuje rozdelenie európskych regiónov na základe NUTS II a softvérový program GeoDa. Záverečná kapitola sa zaoberá analýzou vybraných ukazovateľov s využitím programu GeoDa, pomocou ktorého sme vykonali priestorové analýzy, na základe ktorých bolo možné sledovať regionálne disparity v Európe. Výsledkom riešenia danej problematiky je celkové zhodnotenie regionálnych disparít v Európskej únii.

Kľúčové slová: disparita, priestorová ekonometria, softvér GeoDa, nezamestnanosť, hrubý domáci produkt, úroveň vzdelania, Európska únia, priestorová autokorelácia, Moranov koeficient, SAR model, SEM model

ABSTRACT

Kováčová, Denisa: Modelling of regional disparities in selected European regions based on tools of spatial econometrics - University of Economics in Bratislava. Faculty of Economic Informatics; Department of Operations Research and Econometrics. –Thesis supervisor: doc. Ing. Michaela Chocholatá, PhD. - Bratislava: FHI EU, 2019/2020, number of pages 80.

The aim of the thesis is to analyse and assess regional disparities in European regions based on the tools of spatial econometrics. The work is divided into 4 main chapters. It contains 7 graphs, 10 tables, 7 maps, 18 pictures, 5 outputs from the GeoDa program, and 3 appendices A, B, C. The first chapter contains a theoretical view of the current state of the problem at home and at abroad. It clarifies the terminology of the technical terms used through the perspective of the professional authors. It characterizes concepts, spatial indicators, and their impact on the regional disparities in Europe at the level of individual regions, defining both the spatial econometrics and the spatial statistics. Further, it explains the econometric SAR and SEM models in more detail. Finally, it describes the European Union, its principles, values and objectives, which it seeks to achieve in reducing the regional disparities in the European Union. The next part specifies the goal, methods, and methodology of the work that characterize the subject and procedures used to achieve the solution. Spatial statistics tools used to analyse the data are also described. The division of European regions based on NUTS II and the GeoDa software program are specified in detail. The final chapter deals with the analysis of selected indicators using the GeoDa, which performed the spatial analysis based on which it was possible to monitor regional disparities in Europe. The result of solving this problem is an overall assessment of regional disparities in the European Union.

Key words: disparity, spatial econometrics, GeoDa software, unemployment, gross domestic product, level of education, European Union, spatial autocorrelation, Moran coefficient, SAR model, SEM model

Obsah

Zoznam grafov, tabuliek, máp, obrázkov a výstupov	9
Úvod	11
1. Súčasný stav riešenej problematiky doma aj v zahraničí	13
1.1. Disparita	13
1.2. Európska únia	22
1.3. Priestorová ekonometria a priestorová štatistika	26
2. Cieľ práce	29
3. Metodika práce a metódy skúmania	30
3.1. Priestorové ukazovatele	30
3.1.1. <i>Ekonometrické modely v priestorovej ekonometrii</i>	34
3.1.2. <i>Exploračná priestorová analýza dát</i>	37
3.2. Softvér GeoDa	37
3.3. Regióny v Európskej Únii podľa NUTS II	39
4. Výsledky práce	42
4.1. Práca s programom GeoDa pri analyzovaní dát	42
4.1.1. <i>Vybrané deskriptívne štatistiky</i>	43
4.1.2. <i>Mapové zobrazenie jednotlivých indikátorov</i>	45
4.1.2.1. Zobrazenie HDP v paritách kúpnej sily v percentilovej mape	45
4.1.2.2. Zobrazenie úrovne vzdelania v percentilovej mape	46
4.1.2.3. Zobrazenie nezamestnanosti v percentilovej mape	48
4.1.3. <i>Zostrojenie matice susednosti</i>	49
4.1.3.1. Skúmanie charakteristík váh pomocou histogramu	49
4.1.4. <i>Zistenie priestorovej autokorelácie v analyzovaných dátach</i>	51
4.1.5. <i>Klastrové mapy a mapa významnosti</i>	53
4.1.6. <i>Odhad ekonometrických modelov</i>	58
4.1.6.1. Odhad klasického lineárneho regresného modelu	59
4.1.6.2. Regresia SAR a SEM modelu	60
4.1.7. <i>Porovnanie klasického ekonomického modelu oproti SAR modelu</i>	61
Záver	63
Zoznam použitej literatúry	66
Prílohy	72
Príloha A	72
Príloha B	73
Príloha C	76

Zoznam grafov, tabuliek, máp, obrázkov a výstupov

Zoznam grafov

Graf 1: Nezamestnanosť vo vybraných krajinách	15
Graf 2: Pokles nezamestnanosti mladých ľudí v Bruseli	16
Graf 3: Najhoršie regióny z celkového hodnotenia kvality života	20
Graf 4: Najlepšie regióny z celkového hodnotenia kvality života	21
Graf 5: Histogram na základe matice kráľovná	49
Graf 6: Histogram na základe matice veža	50
Graf 7: Histogram na základe matice vzdialeností	51

Zoznam tabuliek

Tabuľka 1: Rozdelenie oblastí a indikátorov na základe kvality života a bývania.....	19
Tabuľka 2: Najhoršie regióny z celkového hodnotenia kvality života	20
Tabuľka 3: Najlepšie regióny z celkového hodnotenia kvality života	21
Tabuľka 4: Aktuálne členské štáty EÚ a rok ich vstupu do EÚ	22
Tabuľka 5: Hierarchizácia NUTS	40
Tabuľka 6: Počet obyvateľov podľa delenia NUTS	40
Tabuľka 7: Regióny podľa členenia NUTS II	41
Tabuľka 8: Rozdelenie úrovní vzdelania podľa ISCED	43
Tabuľka 9: Deskriptívne štatistiky premenných.....	44
Tabuľka 10: Odhad modelu SAR, metódou maximálnej vierohodnosti s maticou kráľovná a s maticou vzdialenosť	60

Zoznam máp

Mapa 1: Vzdelanie na základe NUTS II vo vybraných európskych regiónoch.....	17
Mapa 2: Zobrazenie HDP v PPS v percentilovej mape.....	46
Mapa 3: Vyznačené krajiny z prvej distribúcií HDP v PPS	46
Mapa 4: Percentilová mapa 3 - 8 úrovne vzdelania.....	47
Mapa 5: Percentilová mapa 0 – 2 úrovne vzdelania.....	47
Mapa 6: Percentilové zobrazenie nezamestnanosti NEZ.....	48
Mapa 7: Percentilové zobrazenie NEZ2.....	48

Zoznam obrázkov

Obrázok 1: Typy priestorovej autokorelácie	31
Obrázok 2: Moranov rozptylový diagram	32
Obrázok 3: Príklad ponúkaných mapových vykreslení v GeoDe.....	38
Obrázok 4: Zobrazenie počtu susedov po použití matice kráľovná.....	50
Obrázok 5: Moranova I štatistika indikátorov pri matici kráľovná	52
Obrázok 6: Grafy globálneho Moranovho I koeficienta, matica vzdialenosť.	52
Obrázok 7: LISA Klastrová mapa, matica kráľovná - A.) mapa NEZ, B.) mapa NEZ2.....	53
Obrázok 8: Mapy významnosti LISA, matica kráľovná.....	54
Obrázok 9: Klastrová mapa a mapa významnosti G štatistika s indikátorom NEZ	55
Obrázok 10: Klastrová mapa a mapa významnosti G štatistika s indikátorom NEZ 2	55
Obrázok 11: Klastrová mapa pre nezamestnanosť, matica vzdialenosti	56
Obrázok 12: Mapa významnosti pre nezamestnanosť, matica vzdialenosť	57
Obrázok 13: Výsledky odhadov klasického modelu a SAR modelu.....	61
Obrázok 14: Výsledky odhadov klasického modelu, SAR a SEM modelu s maticou váh vzdialenosť.....	62
Obrázok 15: Box ploty s deskriptívnymi štatistikami pre každú premennú.....	72
Obrázok 16: Klastrová mapa a mapa významnosti pre obidva typy matíc pre HDP	73
Obrázok 17: Klastrová mapa a mapa významnosti pre obidva typy matíc pre VZD	74
Obrázok 18: Klastrové mapy a mapy významnosti pre obidva typy matíc pre VZD2.....	75

Zoznam výstupov:

Výstup 1: Výstup modelu metódou MNŠ.....	76
Výstup 2: Výstup modelu metódou MNŠ, váha kráľovná	77
Výstup 3: Výstup modelu metódou MNŠ, váha vzdialenosť	78
Výstup 4: Výstup modelov SAR. 1.výstup matica kráľovná, 2.výstup matica vzdialenosť	79
Výstup 5: : Výstup modelov SEM s maticou váh vzdialenosť.....	80

Úvod

V dnešnom svete sa prehlbuje nevyváženosť rozvoja regiónov. Značné rozdiely v sociálno-ekonomických úrovniach sú typickým problémom veľkej časti Európskej únie (ďalej len EÚ). Najväčšie európske regionálne rozdiely boli viditeľné už pri porovnávaní miest a vidieckych oblastí. Rozdiely krajov sú determinované na základe ich odlišných podmienok, ako napríklad (ďalej len napr.) historický vývoj, koloniálna závislosť, prírodné bohatstvo, politická nestabilita, geografická poloha, infraštruktúrna vybavenosť. Všetky tieto faktory majú zásadný vplyv na rozvoj regiónov.

Ďalším značným rozdielom v mnohých krajinách je existencia chudobnejších oblastí. Môže za to aj fakt, že veľa krajov sa sústreďuje hlavne na jednu ekonomickú aktivitu, ktorá zabezpečuje najväčší prínos v regióne, ako napr. poľnohospodárska činnosť, ktorá je sústredená najmä v južných oblastiach regiónov. Nízka úroveň spôsobuje nevyhovujúcu vzdelávaciu, zdravotnú i dopravnú infraštruktúru. Je veľmi dôležité tieto schodky znižovať, aby nedošlo k ešte väčším rozdielom, čo by malo za následok prehlbovanie nerovností v hospodárskych i sociálnych oblastiach, ako zvyšovanie regionálnej nezamestnanosti alebo v rôznej vzdelanostnej úrovni obyvateľstva alebo vo finančných príjmoch ľudí.

Problematika regionálnych disparít je veľmi zaujímavá téma, ktorá poskytuje veľa možností na preskúmanie, analyzovanie ekonomických faktorov i sociálnych ukazovateľov s využitím nástrojov priestorovej analýzy dát a priestorovej ekonometrie. Preto sa stala témou našej záverečnej práce.

Cieľom našej záverečnej práce je analyzovanie a posúdenie regionálnych disparít v európskych regiónoch na báze nástrojov priestorovej ekonometrie. Zistiť, či existuje priestorová závislosť, do akej miery sú jednotlivé regióny diverzifikované a či je možné ich postupné znižovanie.

V prvej kapitole sa budeme venovať teoretickým pohľadom na súčasný stav riešenej problematiky doma aj v zahraničí. Objasníme terminológiu použitých odborných pojmov prostredníctvom pohľadu odborných autorov. Budeme charakterizovať pojmy, priestorové ukazovatele a ich vplyv na regionálne disparity v Európe na úrovni jednotlivých regiónov.

Ďalej budeme opisovať cieľ, metódy a metodiku práce, ktoré charakterizujú predmet a postupy a použijeme ich na dosiahnutie riešenia. Opíšeme nástroje priestorovej štatistiky, ktoré využijeme na analýzu dát. Bližšie budeme špecifikovať rozdelenie európskych regiónov na základe normalizovanej klasifikácie (ďalej len NUTS II) a softvér GeoDa.

V záverečnej kapitole sa budeme zaoberať analýzou vybraných ukazovateľov s využitím programu GeoDa, pomocou ktorého vykonáme priestorové analýzy, na základe ktorých môžeme sledovať regionálne disparity v Európe. Výsledkom riešenia danej problematiky bude celkové zhodnotenie regionálnych disparít v EÚ.

1. Súčasný stav riešenej problematiky doma aj v zahraničí

V prvej kapitole sme sa venovali teoretickým poznatkom a podrobnejšiemu vysvetleniu, na základe ktorého sa odvíjala praktická časť. Vysvetľovali sme pojmy, ktoré súvisia s danou problematikou ako disparita, priestorová ekonometria a štatistika. Snažili sme sa objasniť postoj a kroky EÚ, ktorá sa snaží regionálne disparity znižovať.

1.1. Disparita

Pri všetkých odborných prácach sa používajú adekvátne slovné spojenia, ktoré sú vo väčšine prípadov nezrozumiteľné pre laickú verejnosť. Preto je veľmi dôležité si na začiatku postupne vysvetliť jednotlivé pojmy.

Disparita pochádza z latinského slova dis - parita(us). V preklade to znamená rozdelenie, rozdielnosť, rôznorodosť, nerovnomernosť, diferenciacia, nerovnosť.

Existuje celá rada odborných slovníkov a encyklopédií, ktoré toto slovo zaraďujú spravidla do dvoch skupín. V prvej skupine ide o všeobecnú charakteristiku slova, ktorá pomáha pochopiť jeho význam, na rozdiel od odbornej literatúry, ktorá disparity vysvetľuje z územného hľadiska.

Galvasová a kol. (2007) vysvetľujú disparitu ako „štruktúrovaný jav, tvorený systémom prvkov, väzieb a vzťahov, ktorý sa prejavuje kumuláciou (ne-)priaznivých javov, ktoré ovplyvňujú rozvoj určitej oblasti v danom priestore“ (Galvasová a kol. 2007, s. 104). Sú považované mnohokrát za príčiny nestability v spoločnosti a sociálneho napätia v krajine. Ale na druhej strane umožňujú každej krajine postupne sa zlepšovať.

Dôležité je rozlišovať disparity, ktoré sú chápané zo všeobecného hľadiska. Regionálne disparity viacej napomáhajú pri hľadaní rozdielov medzi ekonomickým výkonom a blahobytom porovnávajúcich krajín. Diferencie medzi jednotlivými krajinami sú prirodzené lebo sa odlišujú svojou polohou, rozlohou, inými prírodnými podmienkami. Na objasnenie tohto pojmu sa veľakrát uvádza napr. porovnanie veľkomesta a dediny.

Regionálne rozdiely interpretujú rozdielnosť procesov, javov na základe racionálneho porovnania. Sú to odchýlky s priestorovou lokalizáciou minimálne v dvoch entitách územnej štruktúry.

Disparity ovplyvňujú štandardy celého územia, životné a ekonomické podmienky obyvateľstva. V mnohých prípadoch sa nedajú eliminovať. Zabúda sa, že niektoré aspekty disparít majú pozitívny dopad. Ako príklad môžeme uviesť krajinu s dvoma regiónmi, ktoré

majú rôznu teplotu vzduchu. Región s nižšou teplotou má vybudované zimné strediská a s vyššou teplotou aquaparky. Tým má zabezpečenú celoročnú návštevnosť turistov.

EÚ sa snaží zabráňovať vzniku väčších disparít, a to aplikovaním procesov a projektov, ktoré by zvýšili súdržnosť krajín takzvaná (ďalej len tzv.) koncepcia súdržnosti.

Zmenšiť rozdiely v jednotlivých krajinách na minimum je politický cieľ, ktorý sa snažia krajiny dosiahnuť za pomoci sociálno-ekonomickej konvergencie. Znamená to, že keď chcú štáty znížiť disparity v jednotlivých regiónoch, tak ich musia obmedziť v troch dimenziách: v ekonomickej, sociálnej a územnej.

Ďalej sa budeme venovať bližšiemu priblíženiu sociálnych disparít, ktoré budú analyzované aj v praktickej časti.

Sociálne disparity sú v krajinách najviac pociťované, keďže sú úzko spojené s obyvateľstvom. Zasahujú priamo do ich príjmov, čo sa odráža aj v celkovej úrovni obyvateľov v krajine. Čím je viac chudobnejších regiónov, tým väčší to má dopad na rozdielnosť vo výškach príjmu a životnej úrovni obyvateľov v krajine.

Nerovnosti medzi príjmami sú najviac viditeľné pri porovnávaní vyspelých krajín a krajín tretieho sveta. Rozdiely sú spôsobené napr. koloniálnou závislosťou, politickou nestabilitou spojenou s vojenskými konfliktmi a geografickou polohou. Ekonomia krajín tretieho sveta je orientovaná hlavne na poľnohospodárstvo a jednoduché produkty. Nízka úroveň spôsobuje nevyhovujúcu vzdelávaciu, zdravotnú i dopravnú infraštruktúru. Tieto problémy majú aj krajiny Európy. Ako príklad by sme uviedli konflikty na Ukrajine, ktoré spôsobili značné rozdiely medzi jednotlivými regiónmi a bude dlho trvať, kým sa opäť spamätajú. Politickú nestabilitu na Cypre, ktorá do značnej miery ovplyvňuje aj jeho regióny, keďže sa rozdelil na dve časti.


Diferencie je možné zaznamenať aj v jednotlivých krajských regiónoch. Každý región je zameraný na iné ekonomické aktivity, čo sa odrazí na príjmoch ľudí. Premerateľnosť sociálnych disparít sa používa nezamestnanosť, migrácia, úroveň vzdelania a mnohé iné ukazovatele.

Nezamestnanosť „je sociálno-ekonomický jav spojený s trhom práce. Definícia nezamestnanosti je založená na tom, že osoba schopná práce je z možnosti pracovať v platenom zamestnaní vyradená. Je to vážny ekonomický a zároveň i sociálny problém. Spojená je s takými spoločenskými javmi ako napríklad zlé mentálne a fyzické zdravie, zvýšená rozvodovosť, zločinnosť a podobne“ (Euroekonóm, 2016).

Nezamestnanosť vzniká na základe neochoty ľudí pracovať, štrukturálnymi zmenami, zánikom firiem, lacnejšej pracovnej sily zo zahraničia alebo nenájdением adekvátnej pracovnej pozície. Všetky tieto aspekty sa odrážajú v ekonomike štátu, čo má za následok prehlbovanie nerovností, zväčšovanie dlhu, migráciu obyvateľstva za lepšími pracovnými podmienkami. Prvým krokom je prilákať zamestnávateľov a poskytnúť im atraktívne podmienky.

Graf 1 predstavuje nezamestnanosť vo vybraných krajinách EÚ za rok 2019, kde najnižšiu nezamestnanosť dosiahla Česká republika. Naopak Grécko zaznamenalo najvyššiu nezamestnanosť, a to na úrovni 17 %. Na druhom mieste sa umiestnilo Španielsko so 14,2 %.

Graf 1: Nezamestnanosť vo vybraných krajinách



Zdroj: vlastné spracovanie údajov zo Štatistického úradu, 2020

Jednou z možných príčin, ktoré majú vplyv na nezamestnanosť je aj globálne otepľovanie, ktoré spôsobuje teplú a suchú klímu, ktorá má negatívne následky na ekonomiku, hlavne v prímorských krajinách.

V boji proti nezamestnanosti sa v EÚ vytvorili viaceré opatrenia, ktoré majú zaručiť nájdenie si vhodného zamestnania. Jedným z týchto opatrení je ponuka práce mladým ľuďom do 25 rokov, poprípade preškolenie, či iná forma doplnkového vzdelania do štyroch mesiacov po skončení štúdia alebo po strate zamestnania.

Opatrenia pre mladých ľudí, ktoré prijala Rada EÚ majú svoje opodstatnenie pri znižovaní nezamestnanosti. Fungovanie týchto opatrení je kľúčové a pomáha k celkovému znižovaniu v jednotlivých oblastiach. Mladí ľudia tak majú vyššiu šancu nájsť si uplatnenie v krajine.

Graf 2 slúži na ilustráciu, ktorá poukazuje ako sa nezamestnanosť mladých ľudí v Bruseli začala výrazne znižovať po stanovení záruk pre mladých ľudí. V roku 2013 bola miera nezamestnanosti 30,8 %. Postupne začala klesať až v júli 2019, kedy klesla o 50,2 %.

Graf 2: Pokles nezamestnanosti mladých ľudí v Bruseli



Zdroj: <https://press.actiris.be/youth-unemployment-at-record-low-in-brussels-after-six-year-continuous-drop>, Apríl 2020

V regióne hlavného mesta Belgicka sa výrazne zlepšila výkonnosť trhu práce. Podporou Európskeho sociálneho fondu a iniciatívy na podporu zamestnanosti mladých ľudí zintenzívil bruselský úrad práce úsilie zamerané na riešenie nezamestnanosti mladých ľudí tým, že zaviedol niekoľko reorganizácií (zriadenie špecializovanej služby, ktorá spája mladých ľudí so zamestnávateľmi, individuálne poradenstvo).

Ďalšou možnosťou ako zvyšovať rast zamestnanosti v krajinách je podpora pri hľadaní zamestnania, zaistenie právnych a sociálnych istôt a vyššia úroveň vzdelania.

Úroveň vzdelania je jeden z aspektov pri tvorbe disparít v krajinách. Vzdelaný človek má lepšie pracovné možnosti presadiť sa v medzinárodnej konkurencii a pomáha tak ekonomike rýchlejšie rásť.

Vzdelávanie je neustály proces, ktorý ovplyvňuje rozvoj celej spoločnosti. Je to prostriedok inovácií, ktorých kvalita má vplyv na konkurencieschopnosť krajín. Preto sa čoraz viac poskytujú stimuly na zlepšenie a zefektívnenie školského vzdelávania.

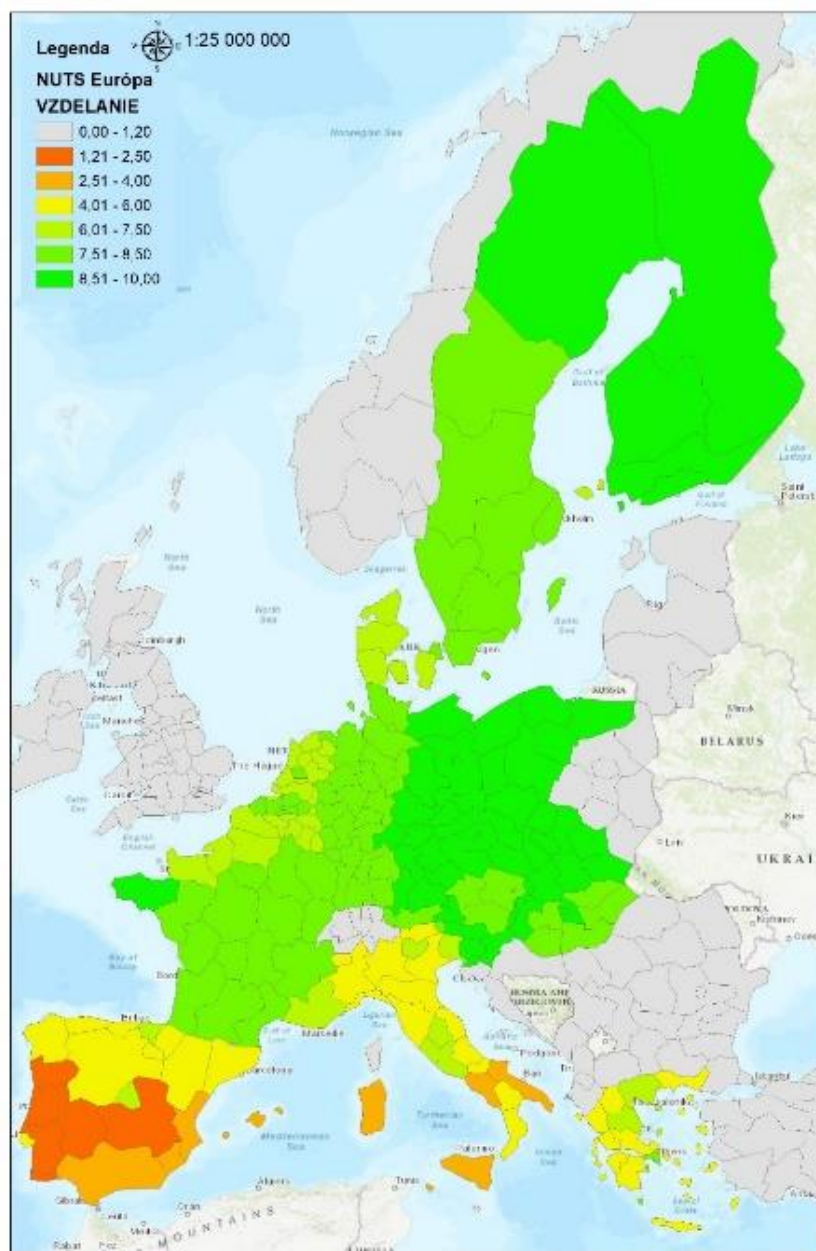
Organizácia pre hospodársku spoluprácu a rozvoj (ďalej len OECD) každoročne vydáva dokument s názvom Vzdelávanie. Dokument obsahuje analýzy kvantitatívnych ukazovateľov, ktoré vytvárajú celkový obraz o vzdelávaní v jednotlivých štátoch a umožňujú tak ich porovnávanie medzi sebou. Na základe tohto dokumentu dokážu krajiny efektívnejšie prerozdeliť svoje finančné prostriedky a lepšie sa zamerať na medzery v ich vzdelávacom systéme.

Ako hovorí OECD, tak: „Rozvoj a uznávanie vedomostí, zručností a kompetencií občanov sú kľúčové pre individuálny rast, konkurencieschopnosť, zamestnanosť a sociálnu

súdržnosť v spoločnosti. Takýto rozvoj a uznávanie by mali pracujúcim a študujúcim uľahčiť nadnárodnú mobilitu a mali by prispieť k splneniu požiadaviek dopytu a ponuky na európskom trhu práce. Prístup k celoživotnému vzdelávaniu a účasť na ňom pre všetkých vrátane znevýhodnených osôb a využívanie kvalifikácií by sa preto na národnej úrovni a na úrovni Spoločenstva mali podporovať a zlepšovať“ (OECD iLibrary, 2019).

Z webovej stránky OECD sme za pomoci programu ArcMap vygenerovali mapu európskych regiónov podľa výšky dosiahnutého bodového ohodnotenia z oblasti vzdelania obyvateľov (Mapa 1).

Mapa 1: Vzdelanie na základe NUTS II vo vybraných európskych regiónoch



Zdroj: vlastné spracovanie dát z <https://www.oecdregionalwellbeing.org/assets/downloads/OECD-Regional-Well-Being-Data-File.xlsx> za pomoci programu ArcMap

Krajiny vyznačené na mape sivou farbou neboli porovnávané. Regióny označené žltou farbou sa potýkajú s menšou nespokojnosťou obyvateľstva v kvalite vzdelania ako štáty vyznačené červenou farbou. V oblastiach so zeleným sfarbením sú obyvatelia spokojní s danou úrovňou vzdelania.

Porovnanie európskych regiónov z Mapy 1 nám slúži na lepšie pochopenie disparít z oblasti vzdelania v Európe. Ako môžeme vidieť, Európa má medzi sebou viditeľné odlišnosti hlavne v jednotlivých regiónoch, ktoré sa snaží postupne zmenšovať.

Dôsledkom disparít je aj rôznorodá kvalita života v regiónoch. Občania v oblastiach, ktoré nie sú zaostalé, poskytujú svojim obyvateľom všetky štandardy. Majú oveľa vyššiu kvalitu života ako ľudia z chudobnejších krajov, ktorí musia vynaložiť viac úsilia na kvalitnejší život.

Kvalita života kvantifikuje životné štandardy, a to na základe cien výrobkov a služieb, ktoré sa porovnávajú s relatívnymi príjmami v každej krajine s využitím spoločnej imaginárnej porovnávacej jednotky nazývanej Štandard kúpnej sily (ďalej iba „PPS“).

Porovnanie hrubého domáceho produktu (ďalej len HDP) na obyvateľa vyjadreného v PPS poskytuje prehľad o životných štandardoch v rámci Európy. Usiluje sa o zvyšovanie životných štandardov, ochranu životného prostredia, podporu tvorby pracovných miest, znižovanie rozdielov medzi regiónmi a spájanie izolovaných oblastí budovaním cezhraničnej infraštruktúry (European Union, 2020).

OECD zverejnila dôležité faktory pri meraní blahobytu (Tabuľka 1). Zaradila tam materiálne podmienky bývania a kvalitu života. V kvalite života sa priradilo 8 okruhov s indikátormi, ktoré majú rovnakú váhu v danej oblasti.

Tabuľka 1: Rozdelenie oblastí a indikátorov na základe kvality života a bývania

Téma	Oblasť	Indikátory
Materiálne podmienky bývania	Bývanie	Byty bez základného vybavenia Výdavky na bývanie Počet osôb na jednu izbu
	Príjmy	Celkový disponibilný príjem domácnosti Finančné aktíva domácnosti
	Zamestnanosť	Miera zamestnanosti Dostupnosť zamestnania Miera dlhodobej nezamestnanosti Osobné príjmy
Kvalita života	Občianska angažovanosť	Kvalita sociálnych služieb
	Vzdelanie	Dosiahnuté vzdelanie Zručnosti študentov Priemerný počet rokov školskej dochádzky
	Životné prostredie	Znečistenie ovzdušia Kvalita vody
	Občianska angažovanosť	Účasť na príprave zákonov Volebná účasť
	Zdravie	Priemerná dĺžka života pri narodení Spokojnosť so zdravím
	Spokojnosť so životom	Spokojnosť so životom
	Osobná bezpečnosť	Miera fyzických napadnutí Miera vražd
	Zosúladenie rodinného a pracovného života	Pracovné nadčasy Čas venovaný osobným záujmom

Zdroj: <https://www.enviroportal.sk/pokrok-spolocnosti/index-lepsieho-zivota>

Na webovej stránke OECD (<https://www.oecdregionalwellbeing.org/SK02.html>) sú zobrazené jednotlivé regióny porovnávané na základe kvality života v oblastiach: osobných príjmov, zdravia, bezpečnosti, zamestnanosti, vzdelania, bývania, dostupnosti verejných služieb, občianskej angažovanosti, komunity, životného prostredia, spokojnosti občanov. Cieľom je poskytnúť celkový obraz rozdielov medzi jednotlivými regiónmi.

„Pre meranie subjektívnej dimenzie kvality života sa používajú primárne dáta, získané v dotazníkových prieskumoch. Kvalitu svojho života ľudia hodnotia najčastejšie v Cantrilovej škále od 0 do 10. Nula predstavuje najhoršiu kvalitu života oproti desiatke“ (Murgaš, 2016 s. 338-339).

V nasledujúcej časti sme porovnávali vybrané regióny z Európy na základe jednotlivých ukazovateľov z OECD Regional Well-Being, ktoré dosahovali najlepšie a najhoršie výsledky v meraní kvality života. Celkovo sme porovnali 22 európskych krajín, z toho 196 európskych regiónov, z ktorých sme vybrali 5 najhorších a 5 najlepších regiónov. Územné celky mohli získať v jednotlivých oblastiach najviac 10 bodov, ale žiadna krajina nedosiahla vo všetkých oblastiach plný počet bodov.

Niektoré územné časti nedisponovali potrebnými údajmi. Najväčšia absencia dát sa ukázala hlavne v Pobaltských štátoch, a to v Lotyšsku i v Litve. Na základe nedostatočného množstva dát sa s nimi nepracovalo, lebo v celkovom hodnotení by sa umiestnili na posledných priečkach.

Tabuľka 2 hovorí o piatich najhorších regiónoch, u ktorých je kvalita života na veľmi nízkej úrovni. Patria sem regióny z Grécka a z Estónska.

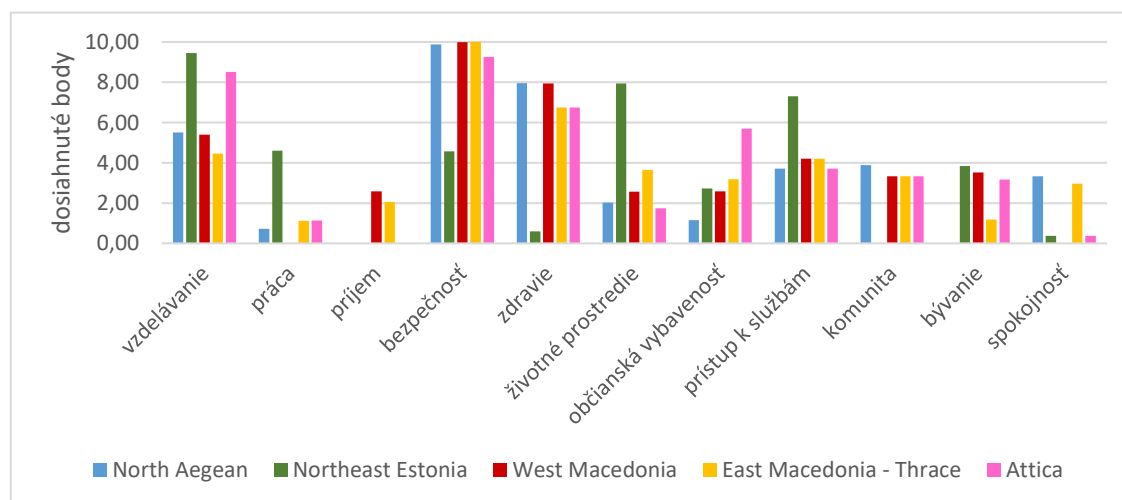
Tabuľka 2: Najhoršie regióny z celkového hodnotenia kvality života

5 Najhorších regiónov z celkového hodnotenia kvality života					
názov regiónu	North Aegean	Northeast Estonia	West Macedonia	East Macedonia - Thrace	Attica
vzdelávanie	5,51	9,45	5,40	4,45	8,52
práca	0,72	4,59	0,01	1,12	1,14
príjem	0,00	X	2,59	2,06	0,00
bezpečnosť	9,88	4,57	10,00	10,00	9,26
zdravie	7,96	0,60	7,94	6,75	6,75
životné prostredie	2,02	7,95	2,57	3,65	1,75
občianska vybavenosť	1,14	2,72	2,58	3,19	5,70
prístup k službám	3,71	7,30	4,20	4,20	3,71
komunita	3,89	X	3,33	3,33	3,33
bývanie	0,00	3,85	3,53	1,18	3,17
spokojnosť	3,33	0,37	0,00	2,96	0,37
celkový počet dosiahnutých bodov zo 110	38,16	41,40	42,15	42,90	43,69

Zdroj: vlastné spracovanie dát z <https://www.oecdregionalwellbeing.org/assets/downloads/OECD-Regional-Well-Being-Data-File.xlsx>

Regióny z Tabuľky 2 výrazne zaostávajú v oblastiach príjmu, spokojnosti obyvateľstva a v bývaní. Medzi sebou nemajú veľké bodové rozostupy. Väčšina regiónov sa územne zaraďuje do Grécka (North Aegean, West Macedonia, East Macedonia – Thrace, Attica). V gréckych regiónoch treba vyzdvihnúť vysokú úroveň bezpečnosti na rozdiel od estónskeho regiónu Northeast Estonia.

Graf 3: Najhoršie regióny z celkového hodnotenia kvality života



Zdroj: vlastné spracovanie dát z <https://www.oecdregionalwellbeing.org/assets/downloads/OECD-Regional-Well-Being-Data-File.xlsx>

V Grafe 3 estónsky región Northeast Estonia vykazuje vysokú úroveň vzdelania oproti regiónom z Grécka. Celkovo sa Estónsko pripája ku krajinám s vysokou úrovňou vzdelávania. Školstvo prešlo rozsiahlou reformou, ktorá mala pozitívny dopad. Dominuje aj v oblastiach životného prostredia a v dostupnosti služieb pre obyvateľov.

Kvalita života v Európskej únii je najvyššia vo Švédsku, ako uvádza Tabuľka 3. Bodovalo najmä v relatívne vysokej schopnosti zvládať nečakané výdavky zo svojich príjmov, v nízkej dlhodobej nezamestnanosti, v celkovej bezpečnosti v krajine a v dostupnosti služieb pre obyvateľov.

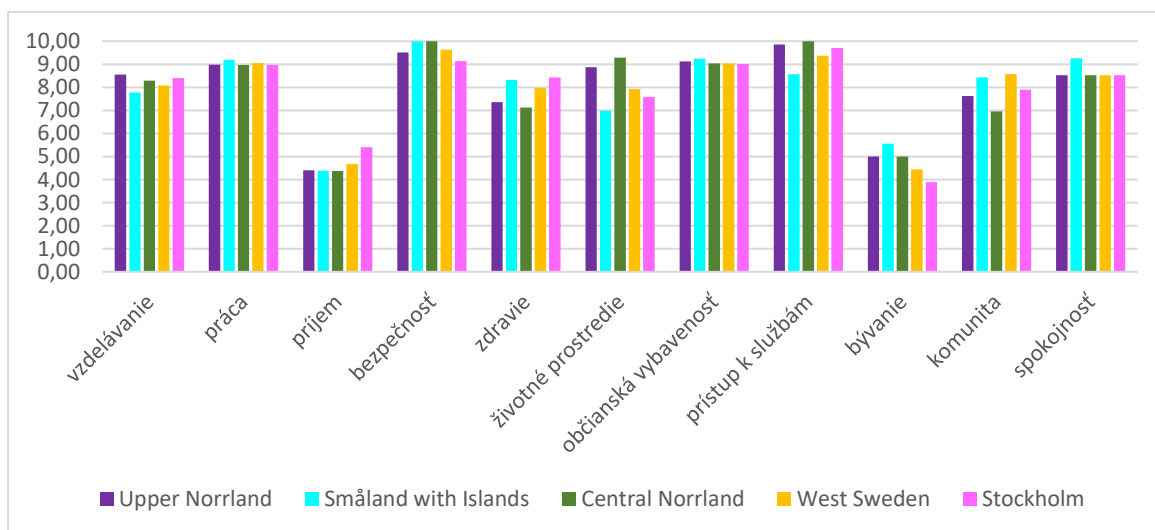
Tabuľka 3: Najlepšie regióny z celkového hodnotenia kvality života

5 najlepších regiónov z celkového hodnotenia kvality života					
názov regiónu	Upper Norrland	Småland with Islands	Central Norrland	West Sweden	Stockholm
vzdelávanie	8,55	7,78	8,29	8,08	8,39
práca	8,98	9,19	8,97	9,05	8,97
príjem	4,40	4,39	4,37	4,68	5,41
bezpečnosť	9,51	10,00	10,00	9,63	9,14
zdravie	7,36	8,32	7,12	7,97	8,43
životné prostredie	8,87	6,98	9,29	7,93	7,58
občianska vybavenosť	9,12	9,24	9,04	9,04	9,02
prístup k službám	9,86	8,57	10,00	9,38	9,70
bývanie	5,00	5,56	5,00	4,44	3,89
komunita	7,63	8,42	6,95	8,58	7,90
spokojnosť	8,52	9,26	8,52	8,52	8,52
celkový počet dosiahnutých bodov zo 110	87,80	87,70	87,54	87,30	86,95

Zdroj: vlastné spracovanie dát z <https://www.oecdregionalwellbeing.org/assets/downloads/OECD-Regional-Well-Being-Data-File.xlsx>

Graf 4 ukazuje, že vybrané územia nevykazujú značné disparity v jednotlivých oblastiach, čo dopomáha k celkovému znižovaniu regionálnych nerovností v krajine a zároveň zvyšuje hospodársky rast štátu.

Graf 4: Najlepšie regióny z celkového hodnotenia kvality života



Zdroj: vlastné spracovanie dát z <https://www.oecdregionalwellbeing.org/assets/downloads/OECD-Regional-Well-Being-Data-File.xlsx>

Európske regióny nevykazujú medzi sebou značné rozdiely, ako by sa očakávalo. Sú oblasti, v ktorých je každý región lepší alebo horší od iných. Je to spôsobené rôznymi faktormi, ktoré ich v priebehu rokov ovplyvňovali, ako poloha krajiny, spôsob myslenia obyvateľov, hospodárenie štátu, politická situácia, historický vývoj územia a mnoho ďalších faktorov, ktoré spôsobili disparity medzi jednotlivými krajinami.

1.2. Európska únia

Od 1. mája 2004 sa Slovenská republika (ďalej len SR) stala súčasťou EÚ. Zaradila sa tak ku krajinám, ktoré zdieľajú spoločné hodnoty a spolupracujú pri zachovaní mieru v Európe.

Cieľom spoločenstva je presadzovať mier i blahobyt občanov. Zaisťovať slobodu, bezpečnosť bez vnútorných hraníc. Bojovať proti diskriminácii a rodovej nerovnosti, zabezpečiť ochranu kultúrnych pamiatok a jazykovej rozmanitosti vo svete. Vytvoriť koalíciu na základe rovnakej hospodárskej a menovej únie (euro).

Hodnotami krajín EÚ sú: tolerancia, solidarita, spravodlivosť a nediskriminácia. Európa sa opiera o zásadu právneho štátu. Svoju najvyššiu právomoc odovzdali štáty Európskemu súdnemu dvoru, pričom sa zaviazali dodržiavať platné dohody a podmienky, s ktorými súhlasili pri vstupe do únie.

Súčasnú EÚ tvorí 27 štátov (Tabuľka 4). Od 31. januára 2020 z nej vystúpila Veľká Británia.

Tabuľka 4: Aktuálne členské štáty EÚ a rok ich vstupu do EÚ

Belgicko (1952)	Bulharsko (2007)	Česko (2004)	Chorvátsko (2013)	Cyprus (2004)
Dánsko (1973)	Estónsko (2004)	Fínsko (1995)	Francúzsko (1952)	Grécko (1981)
Holandsko (1952)	Írsko (1973)	Litva (2004)	Lotyšsko (2004)	Luxembursko (1952)
Maďarsko (2004)	Malta (2004)	Nemecko (1952)	Poľsko (2004)	Portugalsko (1986)
Rakúsko (1995)	Rumunsko (2007)	Slovensko (2004)	Slovinsko (2004)	Španielsko (1986)
Švédsko (1995)	Talianko (1952)			

Zdroj: https://www.slovensko.sk/sk/agendy/agenda/_zakladne-informacie-o-eu-co-j, vlastné spracovanie, 2020

Po rozšírení spoločenstva o ďalšie krajiny v roku 2004 sa zmenilo sociálno-ekonomické zoskupenie. Únia sa obohatila o nové obyvateľstvo, čo sa malo preukázať na raste ekonomiky. Lenže ekonomický rozdiel sa zvýšil iba nepatrne. Malo to za následok aj pričlenenie chudobnejších krajín. Ako príklad môžeme uviesť členstvo krajín zo socialistického bloku (Lotyšsko, Estónsko, Litva). Z tohto dôvodu sa EÚ snaží znižovať rozdiely jednotlivých krajín, na základe finančných príspevkov alebo európskych nariadení, ako je politika súdržnosti, Lisabonská stratégia, Európa 2020 a iné dokumenty.

Politika súdržnosti sa zaraďuje k najstarším politikám v Európe. Po prvýkrát sa objavila už v roku 1957 pri riešení rozdielov medzi regiónmi v členských štátoch EÚ. Vznikla ako produkt vstupov z Európskeho spoločenstva na čele národných vlád, expertov a oblastných subjektov. Poskytovala odpoveď na možnosť uskutočniť jednotný spoločný trh s menej rozvinutými oblasťami.

Koncepcia umožňuje dôležité štrukturálne zmeny, ktoré by sa inak nerealizovali. Poskytuje oveľa väčšiu podporu menej rozvinutým regiónom, ktoré dokážu dohnať ostatné vyspelejšie krajiny za menší časový rámec. Dochádza k znižovaniu rozdielov a k napomáhaniu štátom napredovať. Vyrovnávanie rozdielov sa odráža aj vo zvyšovaní kvality života obyvateľov.

V rámci tejto politiky sa investuje do inovácií a vzdelávania, podporujú sa menší podnikatelia. Kládne sa dôraz na spoluprácu medzi jednotlivými regiónmi a využívanie obnoviteľných zdrojov tak, aby si aj zaostávajúce regióny mohli zabezpečiť svoj ekonomický rozvoj.

Na začiatku sa pozornosť EÚ zamerala na vyrovnávanie rozdielov hlavne medzi sociálnymi skupinami, ako napr. diferenciu miezd, odpracovaný čas medzi zamestnancami v poľnohospodárstve oproti pracovníkom v priemysle. Predpoklad, že spoločný trh dokáže zvýšiť ekonomiku, sa po pridružení chudobnejších krajín, teda štátov, ktoré majú hlbšie regionálne rozdiely v jednotlivých krajinách, nezdaľ až taký istý. Nakoľko sa začali objavovať nepokoje, či tieto krajiny nebudú mať vplyv aj na efektivitu celkového spoločenstva. Aby sa eliminovali regionálne rozdiely boli navrhnuté zásahy na reštrukturalizáciu chudobnejších regiónov, ktoré by tak prerozdělili finančné prostriedky medzi krajinami na základe ich finančnej situácie.

Európska únia má celkovo 3 fondy: Európsky fond regionálneho rozvoja, Európsky sociálny fond plus a Kohézny fond. Prvé dva sú štrukturálne fondy a ich úlohou je podporovať hospodársky rast a zamestnanosť v štáte.

Eurofondy sa priradujú na základe berlínskej metódy, ktorá vznikla v roku 1999. Hlavným kritériom je relatívne bohatstvo regiónov a výška HDP. Bohatšie územia dostanú menej peňažných prostriedkov na rozdiel od chudobnejších.

„Prepojenie politiky súdržnosti so stratégiou Európa 2020¹, poskytuje príležitosť pokračovať v pomoci chudobnejším regiónom EÚ vyrovnávaním rozdielov, umožnením koordinácie politík EÚ a využívania fondov, rozvinúť politiku súdržnosti i z hľadiska kvality a pritom zohľadňovať spoločenské problémy, ako je demografický vývoj, zmena klímy a tak ďalej“ (Košický samosprávny kraj, 2012, s. 5).

Odstránenie vývojových rozdielov je rozhodujúci faktor pre konkurenčnú pozíciu Európy na celosvetovej úrovni.

K ďalším základným dokumentom, ktoré riešili problém disparít bola Lisabonská stratégia, prijatá v roku 2000 v Lisabone. Jedným z jej hlavných dôvodov jej vzniku bola snaha vyrovnať regionálne disparity.

Cieľom Lisabonskej stratégie bolo, aby sa z Európy do roku 2010 stala najkonkurencieschopnejšia a najdynamickejšia poznatkovo orientovaná ekonomika sveta, schopná trvalo udržateľného rastu, s väčším množstvom pracovných miest a sociálnou súdržnosťou. Mala pripraviť podmienky pre plnú zamestnanosť a posilniť tak regionálnu súdržnosť v Európe. Vidinou tohto dokumentu bolo, aby sa európska ekonomika, ktorá dohánala najlepšie ekonomiky, stala najlepšou ekonomikou na svete (Eu2020.gov.sk.).

Obsahovala sériu reforiem, ktoré sa zamerali hlavne na:

- vnútorný trh,
- vedu, inovácie a výskum,
- ochranu životného prostredia,
- oblasť trhu,
- vzdelávanie.²

¹ Stratégia Európa 2020 bude podrobnejšie spracovaná v nasledujúcich stranách diplomovej práce

² Hlavné oblasti reforiem z online dokumentu Benč a kolektív, 2007, (Kohézna politika EÚ na roky 2007 - 2013 a Lisabonská stratégia - Aktuálne reformy EÚ v kontexte lisabonskej stratégie)

Riadila sa na základe poznatkov o spolupráci, že konanie jedného členského štátu by bolo efektívnejšie, ak by ostatné štáty pracovali rovnako.

Neskôr bola revidovaná pod názvom Stratégia rastu a zamestnanosti. Dôvodom jej pozmenenia bolo, že nenapĺňovala dlhodobé ciele, dosahovala neuspokojivé výsledky kvôli náročnému programu, slabej koordinácii a sporným prioritám. Taktiež bolo nedostatočné zapájanie regionálnych a miestnych orgánov do formulovaní, vyhodnocovaní stratégií, čo malo za následok, že nezohľadňovala územné rozdiely krajín a to viedlo k strate jej účinnosti (Európa 2020). Vo všeobecnosti možno povedať, že nenaplnila svoje ciele a zlyhala.

V roku 2010 bola schválená Európskou komisiou v Bruseli stratégia Európa 2020, ktorá sa stala nástupcom Lisabonskej stratégie.

Európa 2020 je zameraná na konkrétne oblasti a opatrenia ako na európskej tak aj na národnej úrovni. Cieľom stratégie je aby sa Európa stala vedúcou ekonomickou, inovačnou mocnosťou sveta. Dosiahnuť vyššiu mieru nezamestnanosti, produktivity a sociálnej súdržnosti.

Zameriava sa na 7 iniciatív, ktoré podporujú pokroky v každej prioritnej oblasti, snaží sa tak postupne znižovať jednotlivé disparity (Európa 2020):

- ***Inovácie v únii*** – majú zlepšiť a zaistiť, aby inovatívne myšlienky vytvorili produkty a služby na zabezpečenie rastu ekonomiky a nových pracovných miest.
- ***Mládež v pohybe*** – snaží sa o skvalitnenie systémov vzdelávania a pomoci mladým ľuďom na trhu práce.
- ***Digitálny program pre Európu*** – pomáha zrealizovať jednotný digitálny trh pre všetky domácnosti a podniky v Európe.
- ***Európa efektívne využívajúca zdroje*** – vznikla na podporu využívania obnoviteľných zdrojov, modernizácií energetickej účinnosti a dopravy.
- ***Priemyselná politika vo veku globalizácie*** – zlepšuje podnikateľské prostredie pre menšie podniky a podporuje rozvoj udržateľnej priemyselnej základne, ktorá bude konkurencieschopná vo svetovom rozsahu.
- ***Program pre nové zručnosti a pracovné miesta*** – modernizuje trh práce a rozvíja zručnosti obyvateľov počas celého ich života, zosúladzuje ponuku a dopyt na trhu práce, vrátane pracovnej mobility.

- ***Európska platforma na boj proti chudobe*** – zabezpečuje sociálnu a územnú súdržnosť. Znamená to, aby ľudia, ktorí žijú v chudobe a sú sociálne vylúčení mali, možnosť žiť dôstojný život a mohli sa aktívne podieľať na rozvoji v spoločnosti.

Po skončení platnosti Stratégie Európy 2020 v roku 2030, bude na ňu následne nadväzovať Stratégia Európy 2030, ktorá bude obsahovať zanalyzované výzvy a problémy, ktorým môže čeliť Európa v budúcnosti.

Ďalšie základné myšlienky územného rozvoja a tiež snahu predísť vzniku disparít obsahoval nový dokument s názvom Európska perspektíva územného rozvoja (ďalej len „ESDP“). Bol podpísaný v roku 1999 v Nemecku. Má charakter nezáväzného dokumentu. Bol prijatý výborom ministrov zodpovedných za priestorové plánovanie v členských štátoch EÚ a členov Európskej komisie. Prijatím tohto dokumentu sa štáty dohodli na spoločných záujmoch a konceptoch pre budúci rozvoj územia Európy, ktorý by mal byť dosiahnutý v každom regióne Európy, a to najmä s dôrazom na hospodársku a sociálnu kohéziu, udržateľný rozvoj a konkurencieschopnosť v európskom priestore, integráciu dopravného plánovania, zachovanie i rozvoj prírodného dedičstva. Zdôrazňuje prijatie integrovaných územných stratégií hlavne na regionálnej úrovni ako je partnerstvo medzi mestom a dedinou.

Problémom ESDP je, že sa vynechali sporné veci ako aj politické opcie i fakt, že sa bude Európa ďalej rozširovať a tým nastanú problémy i s priepustnosťou na hraniciach. Neobsahoval územné zaväzujúce konkrétne rozvojových smerov. (Hrdina a kol., 2019).

„Priame účinky ESDP na jednotlivé štáty boli viac-menej protichodné, avšak nepriame dôsledky pre politiku územného rozvoja Európy s posilňovaním transnárodnej spolupráce, najmä prostredníctvom stratégie na udržateľný rast (Interreg) boli značné. To v konečnom dôsledku vyústilo aj do vytvorenia európskej observatórnej siete ESPON (European Spatial Observatory Network), ktorej výsledky pre územný rozvoj v rôznych častiach Európy pre územnú spoluprácu medzi susediacimi i spolupracujúcimi štátmi sú podstatne významné“ (Hrdina a kol., 2019, s. 11).

1.3. Priestorová ekonometria a priestorová štatistika

Prvá zmienka o priestorovej ekonometrii sa datuje od 19. storočia. Vznikla s vidinou zohľadnenia priestorovej závislosti, asymetrií vo vzťahoch, ktoré sa používajú v regionálnom modelovaní. Snaží sa odstrániť problémy, ktoré vznikali pri regionálnom modelovaní, ako sú priestorové interakcie a štruktúry, s ktorými si nedokáže poradiť

klasická ekonometria. Pracuje s dátami, ktoré boli zhromaždené s ohľadom na ich výskyt v priestore. Za jej hlavné znaky sa považuje smer, relatívna poloha a vzdialenosť.

Mnohé skúmané javy, ktoré existujú v priestore, sú ovplyvňované svojím okolím. Neexistuje jav, ktorý by bol celkom izolovaný od svojho okolia. Preto je potrebné pre priestorové javy použiť také metódy, analýzy a postupy, ktoré zohľadňujú, že skúmané javy môžu byť ovplyvnené svojimi susedmi. Práve tým sa zaoberá priestorová štatistika.

„Štatistickou analýzou priestorových javov sa zaoberá priestorová štatistika. Priestorové štatistiky sa líšia od klasickej štatistiky predovšetkým tým, že priestorové štatistiky pracujú so závislými premennými. Tým sa modely stávajú oveľa realistickejšími“ (Stehlíková, 2002, s. 8).

Ak by sa zanedbala informácia o priestorovej charakteristike, mohlo by to viesť k nepochopeniu, k strate ďalších dát, čo v konečnom dôsledku môže viesť k chybným výsledkom.

Priestorové údaje sa delia na plošné, bodové, sieťové a smerové. Plošné údaje sa vyznačujú údajmi z pozorovaní na plošných častiach regiónu. Bodové dáta predstavujú určitú relatívnu polohu na zemi, ako napr. rastliny, stromy, domy, obchod, obce. Sieť predstavuje objekt, cez ktorý prúdia zdroje. Je dôležité, aby sa vyznačovali dĺžkou a smerom. Musia mať minimálne dva body, ako napr. prúdenie vody, pohyb lodí. Smer je jeden z parametrov, ktorý sa dokáže vyčítať z máp. Ako príklad smerových údajov je šírenie choroby v území. Údaje, s ktorými sme pracovali v praktickej časti boli plošné (Markechová a kol., 2011).

V dnešnej dobe má priestorová ekonometria široké uplatnenie, a to nielen na ekonomickej úrovni. Uplatniť sa dokáže aj v biológii, v sociológii a mnohých iných oblastiach vedy a výskumu.

V tejto oblasti sa analytik skôr zameriava na závislosti medzi regiónmi, teda ako udalosti v inom regióne ovplyvnia samotný pozorovaný región a opačne. Mnoho analytikov sa zaoberalo problémom regionálnych disparít z oblasti analýzy nezamestnanosti v regiónoch EÚ.

Jedným z nich boli Marelli a Signorelli (2015), ktorí sa venovali podrobnejšiemu analyzovaniu konvergenie, vplyvu globálnej finančnej krízy a globálnej recesie, ktoré zmenili situáciu v eurozóne, nezamestnanosti v EÚ a potrebe inovačných politík, ktoré by dokázali zmierniť vplyv disparít. Pričom rozlišovali obdobie pred krízou (1999 – 2007) a po

kríze (2008 – 2013). Ich analýzy boli založené na sigma a beta konvergenciách pre rôzne makroekonomické premenné. Ďalej sa zamerali na potrebu inovačných politík. Ako sú dôležité pre prekonanie recesií v nezamestnanosti, najmä v boji proti nezamestnanosti mladých ľudí, ktorá je v dnešnej dobe problémom. Poukazovali aj na dôležitosť zmien v makroekonomických politikách, ktoré by ukončili súčasnú stagnáciu nezamestnanosti (Marelli a Signorelli, 2015).

Analytik Villaverde (2003) sa snažil s použitím rôznych techník odpovedať na problémy, s ktorými sa zaoberala aj EÚ. Medzi nimi bola veľká diverzifikácia regiónov, mobilita i polarizovanosť osobných príjmov v jednotlivých regiónoch v časovom horizonte od 1980 až do roku 1996. Výsledkom jeho práce bolo zistenie, že sa samotné disparity pomaly znižovali a mobilita v EÚ dosiahla pomerne vysoký stupeň, čo by mohlo spôsobiť značné problémy do budúcnosti (Villaverde, 2003).

LeGallo (2004) od roku 1980 až po rok 1995 skúmal medzi 138 územnými oblasťami vývoj regionálnych disparít v EÚ na základe hrubého domáceho produktu. Výsledkom bolo zistenie, že regionálne disparity naďalej pretrvávajú a pri ich procese následného znižovania je veľmi dôležitý geografický faktor (LeGallo, 2004).

Viacero autorov vo svojich prácach potvrdilo, že regionálne disparity v EÚ aj napriek snahe štátov o ich znižovanie naďalej pretrvávajú, v niektorých prácach sa rozdiely dokonca značne prehĺbovali. Španielsky analytik Diego Puga (Puga, 2001) napísal prácu, v ktorej poukázal na nárast disparít hlavne medzi regiónmi. Zameril sa pritom na regionálnu nezamestnanosť a jej polarizáciu. Nasledoval ho aj Gianetty v roku 2002, kde sa snažil bližšie vysvetliť príčiny vzniku diferencií medzi regiónmi (Gianetty, 2002).

Potvrdil sa aj fakt, že susediace krajiny sa navzájom ovplyvňujú. Toto tvrdenie overil vo svojej práci v roku 1996 analytik Quah, ktorý sa snažil prísť na to, ktoré ukazovatele najviac ovplyvňujú rozdielnosť regionálnych príjmov, keďže v celej EÚ sú veľmi rozdielne. Zaujímavosťou bolo zistenie, že najväčší vplyv na príjem majú geografické ukazovatele (Quah, 1996).

Priestorová ekonometria a jej značné využitie hlavne v problematike regionálnych disparít vedie už dlhú dobu k myšlienkam, či je vôbec možné, aby disparity za niekoľko rokov zanikli, alebo bude tento problém i naďalej pretrvávať.

2. Cieľ práce

Hlavným cieľom našej práce je preskúmať a poukázať na existenciu regionálnych disparít v európskych regiónoch. Zistiť, či existuje prepojenie medzi hlavnými ukazovateľmi ako je nezamestnanosť, dosiahnutá vzdelanosť obyvateľstva i HDP v krajine. Všetky údaje boli získané z Európskeho štatistického úradu (ďalej len EUROSTAT).

S ukazovateľmi sme ďalej pracovali v rámci skúmaných regiónov, na základe európskeho rozdelenia krajín NUTS II. Pri členení NUTS II sa každá krajina rozdelí na jednotlivé regionálne celky, pričom každý európsky štát má iný počet regiónov.

Údaje, ktoré sme získali z EUROSTATU vložíme do programu GeoDa, s pomocou ktorého dané dáta môžeme preskúmať, vykresliť ich na mapách ako aj odhadnúť priestorové modely. Na analyzovanie údajov na názornom grafickom vyobrazení dát s podkladovou mapou využijeme exploračnú priestorovú analýzu dát, ktorá slúži hlavne na vizualizáciu a prieskum, pritom využíva rôzne špecifické prostriedky ako mapy a histogramy, ktoré zakomponujeme do analýz.

Vzhľadom na vysokú prepojenosť ekonomík krajín EÚ využijeme nástroje priestorovej štatistiky a priestorovej ekonometrie. Pre vybrané ukazovatele (premenné) overíme existenciu priestorovej autokorelácie pomocou globálnych i lokálnych štatistík. Kým globálne štatistiky nám poskytujú informáciu o priestorovej autokorelácii z globálneho hľadiska (jedna hodnota pre celý súbor), lokálne štatistiky vypovedajú o priestorovej autokorelácii v jednotlivých regiónoch. V ďalšom kroku odhadneme ekonometrický model závislosti miery nezamestnanosti od dosiahnutého vzdelania a HDP. Vzhľadom na predpokladané potvrdenie prítomnosti priestorovej autokorelácie následne odhadneme vhodný priestorový ekonometrický model (model s priestorovým oneskorením - SAR model, model s priestorovými chybami - SEM model). Pri modelovaní využijeme poznatky z priestorovej štatistiky ako aj z priestorovej ekonometrie.

Cieľom práce je jednak poukázať na existenciu značných regionálnych disparít v oblasti nezamestnanosti, vzdelania a HDP a potvrdiť, že vývoj vyššie uvedených ukazovateľov v určitom regióne je v interakcii s vývojom daného ukazovateľa v geograficky blízkych regiónoch. Zistené priestorové interakcie možno následne využiť pri prijímaní opatrení a zákonov v oblasti podpory menej rozvinutých regiónov.

3. Metodika práce a metody skúmania

V tejto kapitole sme sa venovali metódam a metodike, ktoré boli potrebné pri práci a spracovávaní výsledkov danej problematiky. Všetky údaje, ktoré sme použili pri analýze, boli získané z databázy EUROSTATU, ktorých formát sme upravili podľa potreby a analyzovali pomocou softvéru GeoDa. Pri spracovaní danej témy sme vychádzali z odborných kníh, vedeckých časopisov i článkov, ktoré sa zaoberali danou problematikou.

Ukazovatele, ktoré boli potrebné pri analýze získaných údajov, a s ktorými pracoval aj samotný softvér GeoDa, boli nástrojmi priestorovej ekonometrie a štatistiky.

3.1. Priestorové ukazovatele


Priestorová ekonometria na rozdiel od klasickej ekonometrie sa rozširuje o priestorovú závislosť, priestorovú heterogenitu ako i o kvantifikáciu regiónov, ktorú sme následne vysvetlili.

Pri kvantifikácii regiónov sme regióny vyjadrili na základe získaných číselných hodnôt a následne zostavili ekonometrický model v matematickej podobe, kde sme získané parametre premenných štatisticky odhadovali (kvantifikovali). Po otestovaní významnosti odhadovaných závislostí bolo možné model využiť na ďalšiu analýzu. Tento proces je základnou metódou pri budovaní ďalších ekonometrických modelov (Mikolaj, Vančo, 2004).

V ekonomických sférach sme sa stretli s pojmom priestorová autokorelácia, ktorá predstavovala priestorovú závislosť. Vyskytovala sa vtedy, ak boli hodnoty pozorovanej premennej pre obidva regióny korelované. V prípade nekorelovaných hodnôt sa priestorová autokorelácia zamietla (Stehlíková, 2002).

Obrázok 1 ilustruje dva typy priestorovej závislosti, pozitívnu a negatívnu. Pri pozitívnej závislosti sú susedné hodnoty podobné. To znamená, že regióny medzi sebou vykazujú známky podobnosti. Hodnoty v priestore sa zhlukujú, ako napr. biele políčka sú zoskupené pri bielych a čierne políčka pri čiernych. Pri negatívnej autokorelácií sú hodnoty rozdielne a nezhlukujú sa rovnaké hodnoty premenných v priestore, napr. šachovnica (Stehlíková, 2002).

Obrázok 1: Typy priestorovej autokorelácie



Zdroj: Stehlíková, 2002, s. 51

Pri meraní priestorovej autokorelácie sa rozlišujú globálne miery a lokálne miery. Globálne miery sa vypočítajú na základe všetkých hodnôt súboru. Zaraďuje sa sem Moranov koeficient, Gearyho koeficient ako i Getisova-Ordova štatistika. V lokálnych mierach sa využíva štatistika Local Indicators of Spatial Association (ďalej len LISA), pričom sa sem zaraďuje Moranov koeficient, Gearyho štatistika ako aj lokálna Getis – Ordova štatistika.

Globálny Moranov koeficient vyjadruje mieru a aj stupeň priestorovej autokorelácie, pri ktorom platí (Stehlíková, 2002):

$$I = \frac{n \sum_{i=1}^n \sum_{j=1}^n w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{(\sum_{i=1}^n (x_i - \bar{x})^2) (\sum_{i=1}^n \sum_{j=1}^n w_{ij})} \quad 3.1$$


- ❖ n predstavuje počet priestorových jednotiek;
- ❖ x_i je hodnota skúmaného javu v priestorovej jednotke i , pričom i nadobúda hodnoty $i = 1, 2, 3, \dots, n$;
- ❖ x_j je hodnota skúmaného javu v priestorovej jednotke j , pričom j nadobúda hodnoty $j = 1, 2, 3, \dots, n$;
- ❖ \bar{x} určuje priemernú hodnotu skúmaného znaku;
- ❖ w_{ij} je váha pre priestrovú jednotku i a j

Ak je výsledná hodnota Moranovho koeficientu I (Grác a kol., 2011):

- záporná hodnota, ide o negatívnu autokoreláciu.
- kladná hodnota, tak identifikuje pozitívnu autokoreláciu.
- ak nadobudne hodnoty, ktoré sa pohybujú okolo 0, vtedy môže nastať situácia, kedy nie je možné identifikovať údajovú štruktúru.

Stupeň autokorelácie sa testuje na základe Moranovho rozptylového diagramu. Diagram predstavuje bodový graf, pričom sklon priamky zodpovedá Moranovmu I koeficientu (Obrázok 2). Ukazuje na závislosť jednotlivých faktorov medzi analyzovanými regiónmi v priestore. Vodorovná os predstavuje normalizovanú premennú x a na osy y sú normalizované priestorové oneskorenia tejto premennej Wx . Moranov rozptylový diagram umožňuje vytvárať priestorové zoskupenia štatistických jednotiek.

Obrázok 2: Moranov rozptylový diagram



Zdroj: Barreca, Curto, Rolando, 2017

V Obrázku 2 je uvedený Moranov rozptylový diagram, ktorý je rozdelený na štyri kvadranty. Negatívna priestorová autokorelácia nastáva v prvom kvadrante, ktorý obsahuje nízke hodnoty obklopené vysokými hodnotami. Pozitívna priestorová autokorelácia v druhom kvadrante má nízke hodnoty obklopené nízkymi hodnotami. Pri negatívnej priestorovej autokoreláci v treťom kvadrante sú vysoké hodnoty obklopené nízkymi. V štvrtom kvadrante je pozitívna priestorová autokorelácia, ktorá vykazuje vysoké hodnoty obklopené vysokými hodnotami.

Gearyho koeficient skúma druh autokorelácie na základe hodnoty c , ktorú sme vyjadrili vzorcom 3.2:

$$c = \frac{n-1}{2 \sum_{i=1}^n \sum_{j=1}^n w_{ij}} \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij} (x_i - x_j)^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad 3.2$$

Všetky symboly pre vzťah 3.2 sme vysvetlili pri globálnom Moranovom koeficiente.

Ak je hodnota Gearyho koeficienta 0, skúmaný jav je silne pozitívne autokorelovaný. Ak je 1, skúmaný jav je v priestore rozložený náhodne a pri hodnote 2 je jav silne negatívne autokorelovaný (Stehlíková, 2002).

Medzi novšie metódy počítania patrí Getisova – Ordova štatistika. Inak označovaná ako koeficient G. Vznikla v roku 1992. Označenie d predstavuje kritickú vzdialenosť. Znak n znázorňuje počet oblastí. W_{ij} predstavuje váhy (Stehlíková, 2002):

$$G(d) = \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij}(d) x_i x_j}{\sum_{i=1}^n \sum_{j=1}^n x_i x_j} \quad 3.3$$

„G koeficient je mierou celkovej priestorovej asociácie hodnôt vo vnútri kritickej vzdialenosti. Kladné hodnoty indikujú priestorové zhľukovanie vysokých hodnôt a negatívne hodnoty indikujú zhľukovanie nízkych hodnôt na skúmanom území (Stehlíková, 2002, s. 55).“

Lokálne indikátory na rozdiel od globálnych vyjadrujú premenlivosť priestorovej autokorelácie v lokálnej oblasti. V tomto prípade je Moranov a Gearyho index modifikovaný.

$$\text{Lokálny Moranov index: } I_i = z_i \sum_j w_{ij} z_j \quad 3.4$$

Pri modifikácii Moranovho indexu reprezentujú z_i a z_j priestorové odchýlky od priemeru. Ak vykazujú indexy nízke hodnoty, znamená to, že sa kumulujú odlišné hodnoty premenných. Pri vysokých hodnotách ide o opačný efekt. Zhľukujú sa podobné hodnoty, ktoré sa následne porovnajú s očakávanými hodnotami a zistí sa ich významnosť (Stehlíková, 2002).

$$\text{Lokálny Gearyho koeficient: } c_i = \sum_j w_{ij} (z_i - z_j)^2 \quad 3.5$$

Interpretácia lokálneho modifikovaného Gearyho koeficientu je taká istá ako pri globálnom procese. Ak sa kumulujú odlišné hodnoty, dochádza k vysokým hodnotám v samotnom indexe (Stehlíková, 2002).

Pri analýze disparít v jednotlivých regiónoch sa musia brať do úvahy aj susedia pozorovaného regiónu. Na základe tohto faktoru sa zostrojí priestorová matica susednosti s priestorovými váhami alebo sa použije metóda najbližšieho suseda, pričom sa berie do úvahy vzdialenosť a spoločné hranice regiónov. Čím je sused ďalej, tým je jeho vplyv na pozorovaný región menší. Výsledkom matice je 1 alebo 0. Prvky s hodnotami 1 napovedajú, že regióny majú susedské vzťahy. V opačnom prípade sa dostane výsledná hodnota 0, a teda medzi regiónmi neexistujú susedské vzťahy.

Pri hľadaní najbližšieho suseda pomocou matice susednosti, ktorá sa zostaví na základe vzdialenosti medzi regiónmi, je dôležité si dopredu zadefinovať počet najbližších susedov. Hľadá sa minimálna vzdialenosť k iným regiónom alebo sa určí celkové rozpätie vzdialenosti, do ktorého by sa mal nájsť daný sused.

Pri zadefinovaní vhodnej vzdialenosti je dôležité nastaviť také rozmedzie, aby nebolo príliš veľké alebo malé, čo by malo za následok nepomer počtu susedov pri jednotlivých regiónoch.

3.1.1. Ekonometrické modely v priestorovej ekonometrii

V niektorých prípadoch je veľmi ťažké jednoznačne určiť, či všetky dáta boli zozbierané v danom regióne, alebo či sa jednotlivé regióny navzájom neovplyvňujú. Ako napr. na trhu práce, keď zamestnanec pracujúci v inom regióne alebo štáte dostane výpoveď a nahlási sa na úrade práce v mieste trvalého bydliska. Vtedy dochádza k štatistickej chybe, ktorá môže mať vplyv na konečný výsledok.

Priestorové ekonometrické modely vychádzajú z klasických modelov, ktoré sa ďalej transformujú a prispôbujú danej problematike.

Klasický lineárny model sa zapisuje ako:

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon} \quad 3.6$$

Matica nezávislých premenných je \mathbf{X} a $\boldsymbol{\varepsilon}$ je označením vektora náhodných chýb. Nasledujúca podkapitola je viacej zameraná na teoretické opísanie priestorových modelov, ktoré sa najčastejšie využívajú v priestorovej ekonometrii.

V lineárnom priestorovom modeli je priestorová závislosť obsiahnutá ako regresor. To znamená, že plní funkciu doplňujúcej vysvetľujúcej premennej vo forme priestorovo posunutej závislej premennej, označuje sa ako $\mathbf{W}\mathbf{y}$. Celkový model, v ktorom je zahrnutá táto premenná sa nazýva model s posunom. Tento model je vhodný vtedy, ak sa hľadá existencia endogénnych priestorových interakcií a sila jej pôsobenia.

Zapisuje sa ako:

$$\mathbf{y} = \rho\mathbf{W}\mathbf{y} + \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon} \quad 3.7$$

Pri tomto zápise ρ predstavuje koeficient priestorovej autoregresie, ktorý ak sa rovná nule, tak v daných pozorovaniach y sa nenachádza priestorová závislosť. Priestorový posun sa označuje $\mathbf{W}\mathbf{y} = \sum_j w_{ij}y_j$, pričom vyjadruje závislosť vysvetľovanej premennej pri

danom pozorovaní od hodnôt iných pozorovaní. \mathbf{X} je matica exogénnych premenných. Odhad regresných parametrov je zastúpený v podobe znaku β (Anselin, 1995).

Člen \mathbf{W} je matica priestorových váh, ktorá je prezentovaná v tvare:

$$\mathbf{W} = \begin{pmatrix} 0 & b_{12} & b_{1j} \\ b_{21} & 0 & b_{i-1,j} \\ b_{i,1} & b_{i,j-1} & 0 \end{pmatrix}, \quad 3.8$$

príčom index b označuje relatívnu vzdialenosť vybraných regiónov i, j . Platí, že matica \mathbf{W} je symetrická, pozitívne definitná a na jej diagonále sa vyskytujú nulové prvky, ako je to ukázané vo vzorci 3.8. Znamená to, že región i je susedom regiónu j a platí to aj opačne. Región j je priľahlým regiónom pre región i , pričom samotný región i nemôže susediť so samým sebou.

Konštrukcia matice váh \mathbf{W} je založená buď na prístupe vzájomnej vzdialenosti, vzájomnej polohy priestorových jednotiek alebo na prístupoch, ktoré sú ich kombináciou. Matica váh \mathbf{W} je nevyhnutná k uskutočneniu priestorovej analýzy, pretože zachytáva priestorovú závislosť medzi sledovanými jednotkami, a tak výrazne ovplyvňuje celý proces analýzy (Furková, 2015).

Matica váh na základe vzdialenosti vychádza z centrálnych vzdialeností d_{ij} medzi dvojicou priestorových jednotiek i, j . Ťažiskom môže byť napr. hlavné mesto štátu. Do tejto skupiny sa zaraďuje matica váh k (najbližších susedov), matica váh radiálnych vzdialeností, matica váh mocninových vzdialeností i matica váh exponenciálnych vzdialeností. Bližšie preskúmame maticu váh k (najbližších susedov) (Furková, 2015).

Matica váh k najbližších susedov „nech ťažiská vzdialeností každej priestorovej jednotky i ku všetkým ostatným jednotkám $j \neq i$ sú usporiadané ako $d_{ij(1)} \leq d_{ij(2)} \leq \dots \leq d_{ij(n-1)}$. Potom pre každú jednotku $k = 1, \dots, n - 1$, množina $N_k(i) = \{j(1), j(2), \dots, j(k)\}$ obsahuje k najbližších jednotiek k jednotke i (Furková, 2015, s.47).“

Pre každé zadané k , matica váh \mathbf{W} k – najbližších susedov má nasledujúci tvar:

$$w_{ij} = \begin{cases} 1, & j \in N_k(i) \\ 0, & \text{inak} \end{cases} \quad 3.9$$

Výhodou konštrukcie matice váh na základe hraníc je matematická nenáročnosť. Zaraďuje sa sem matica váh priestorového susedstva a matica váh spoločných hraníc. Bližšie preskúmame maticu váh priestorového susedstva (Furková, 2015).

Pri matici priestorového susedstva sa zistia či priestorové jednotky vykazujú spoločné hranice. „Ak označíme množinu hraničných bodov priestorovej jednotky i ako $bnd(i)$, potom môžeme váhy priestorového susedstva typu „kráľovná“ zdefinovať takto:

$$w_{ij} = \begin{cases} 1, & bnd(i) \cap bnd(j) \neq \emptyset \\ 0, & bnd(i) \cap bnd(j) = \emptyset \end{cases} \quad 3.10$$

V tomto prípade váh sa predpokladá, že priestorové jednotky sú „susedia“ v prípade, ak majú spoločnú akúkoľvek časť hranice (Furková, 2015, s.47).“

Výber vhodnej matice váh nie je jednoznačný a mnohokrát si vyžaduje podrobnejšiu analýzu údajov. Avšak na druhej strane existujú rôzne programy, ktoré sú zamerané na takúto analýzu dát.

Ďalej si podrobnejšie vysvetlíme priestorový model, ktorý je korelovaný s chybami, čo odhaľuje aj redukovaná forma tohto modelu:

$$\mathbf{y} = (\mathbf{I} - \rho\mathbf{W})^{-1} \mathbf{X}\boldsymbol{\beta} + (\mathbf{I} - \rho\mathbf{W})^{-1} \boldsymbol{\varepsilon} \quad 3.11$$

Inverzie sa v tomto prípade dokážu rozpisovať na nekonečný rad s vysvetľujúcimi premennými a aj s chybovou zložkou pri všetkých regiónoch. Preto sa posun zaraďuje ako endogénna zložka. Na základe tohto faktu sa na odhad SAR modelu využíva metóda maximálnej vierohodnosti, čo má za následok transformáciu modelu do tvaru:

$$\mathbf{y} - \rho\mathbf{W}\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon} \quad 3.12$$

V druhom prípade sa priestorová závislosť vyskytuje vo forme chybového člena $E[\varepsilon_i \varepsilon_j] \neq 0$. Ide o model s priestorovými chybami, kde sa do modelu dostáva priestorová rôznorodosť. Využíva sa pri predpoklade výskytu eventuálnych chýb odhadu s účinkom priestorovej autokorelácie. Inak povedané, tento jav sa častokrát prejavuje pri použití geografických dát, ktoré sa môžu navzájom výrazne ovplyvňovať. Takýto typ modelu sa nazýva model s priestorovými chybami - model SEM (Anselin, 1995).

SEM model sa skladá z chybového procesu SAR a štandardného regresného vzťahu:

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{e} \quad 3.13$$

$$\mathbf{e} = \boldsymbol{\varphi}\mathbf{W}\mathbf{e} + \mathbf{u} \quad 3.14$$

pričom \mathbf{u} je z normálneho rozdelenia, ktorého stredná hodnota je nulová a variácia má tvar $\sigma^2\mathbf{I}$. Následne sa dostane tvar: $\mathbf{e} = (\mathbf{I} - \boldsymbol{\varphi}\mathbf{W})^{-1} \mathbf{u}$. Ostatné symboly sme popisovali vyššie.

Výsledný model má tvar (Anselin, 1995):

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + (\mathbf{I} - \varphi\mathbf{W})^{-1} \mathbf{u} \quad 3.15$$

V modeli je prítomná heteroskedasticita chýb, ktorá naznačuje, že na odhad modelu je vhodné využiť metódu maximálnej vierohodnosti tak, ako pri SAR modeli.

Po zhrnutí teoretických poznatkov u oboch modeloch sa dá s určitosťou povedať, že SAR model využíva priestorovú závislosť vo forme posunu člena $\mathbf{W}\mathbf{y}$. Inak povedané, správne vybraný región závisí od svojich susedných regiónoch, pričom sa nezabúda ani na vplyvy z vonkajšieho prostredia. Na rozdiel od SEM modelu, ktorý predpokladá silnú priestorovú závislosť medzi rezíduami.

3.1.2. Exploračná priestorová analýza dát

Exploračná analýza sa snaží identifikovať vlastnosti údajov. To znamená, že odvodzuje hypotézy, hľadá vzorce v údajoch. Overuje štatistické metódy, ktoré sú vhodné na použitie a v neposlednom rade poukazuje na výber správnych nástrojov a techník.

Nadstavbou exploračnej analýzy dát je priestorová exploračná analýza dát. V skratke označovaná ako ESDA. Hľadá konfigurácie a vzťahy medzi získanými údajmi. Umožňuje zhrnutie dát bez využitia modelov a hypotéz. Využíva sa na analyzovanie údajov na názornom grafickom vyobrazení dát s podkladovou mapou.

Slúži na vizualizáciu a prieskum. Využíva rôzne špecifické prostriedky ako box plot, histogramy, smoothing, identifikáciu trendov, gradienty a mapy, ktoré dokáže vykresliť aj softvérový nástroj GeoDa, v ktorom sa zozbierané dáta následne analyzujú, graficky vykresľujú a preskúmajú sa priestorové ukazovatele.

3.2. Softvér GeoDa

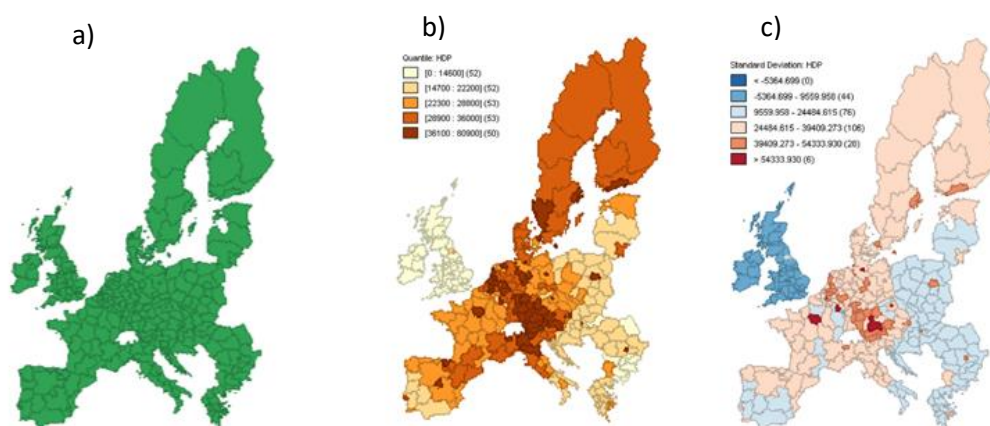
GeoDa je voľne dostupný program, ktorý analyzuje priestorové údaje, autokoreláciu a ponúka množstvo grafov, máp a priestorových regresných modelov, ktoré dokážu zachytiť závislosti medzi regiónmi. Implementuje geopriestorové analýzy, ktoré následne aplikuje v sociálnych i v environmentálnych vedách. Je vhodný na analyzovanie disparít v jednotlivých regiónoch.

Analýzy sme realizovali pomocou shape súborov (ďalej len shp.), ktoré sú v prostredí programu dynamicky prepojené. Ak používateľ potrebuje mať otvorených viacero okien v tom istom čase a zvýrazní jeden objekt na mape, program to vyhodnotí aj u ďalších

otvorených oknách. Prepojenie má tak vizuálne najst' hľadaný objekt na mape v rôznych stupňoch analýz.

Obrázok 3 ilustruje možnosti mapových vykreslení, ktoré ponúka samotný softvér po importovaní údajov do programu Geoda prostredníctvom shp. súborov. Mapa a) ukazuje prvotné vykreslenie Európy s jednotlivými regiónmi bez farebných rozdielov, pretože sa ešte nevybrala premenná na analýzu. Mapa b) ponúka kvantilové zobrazenie HDP ukazovateľa, pri ktorej sú regióny farebne vyznačené na základe kvantilov. Mapa c) ukazuje mapu, ktorej regióny sú vyznačené na základe štandardných odchýlok ukazovateľa HDP.

Obrázok 3: Príklad ponúkaných mapových vykreslení v GeoDe



Zdroj: vlastné spracovanie dát v GeoDe, mapa a) bez farebných rozdielov, kvantilova mapa b) s vykresleným ukazovateľom HDP, mapa c) so štandardnými odchýlkami ukazovateľa HDP.

Softvér ponúka aj množstvo iných mapových vykreslení ako napr.: mapu s percentilmi. Obsahuje okrem kvartilov aj extrémne hodnoty na základe medzikvartálového rozpätia, mapu prirodzených zlomov a mapu prirodzených intervalov.

Dôležitým poznatkom pri analýze je počet susediacich regiónov s pozorovaným územím. Skonstruuje sa matica susednosti s priestorovými váhami. Program umožňuje dva typy susednosti. Prvým typom je „veža“ a druhým „kráľovná“.

Veža definuje susedstvo vtedy ak majú spoločnú časť hranice. Dôležitá je dĺžka hranice. Zdefinuje sa kritická hodnota, ktorá charakterizuje kritérium susednosti. Na jeho základe môžu byť územné celky susedmi alebo nie. V prípade, ak je spoločná hranica menšia ako kritická hodnota, vybrané regióny nie sú susedmi. Pri definícii kráľovnej sa charakterizuje susednosť na základe už jedného spoločného bodu hranice s ťažiskami pre vybrané oblasti (Janotka, 2013).

Lokalizovaním najbližších susedov pomocou metódy vzdialenosti alebo k najbližším susedom sa získa priestorová matica susednosti. $n \times n$, Ak územné celky sú susedmi, matica obsahuje hodnotu 1, v opačnom prípade hodnotu 0 (Janotka, 2013).

Aby sa mohla využiť matica susednosti je potrebné ju transformovať s použitím riadkového normovania. „Princíp spočíva v tom, že každú hodnotu 1 alebo nula v riadku vydelíme celkovým súčtom hodnôt v riadku. Súčet v riadku sa bude rovnať 1 (Janotka, 2013, s. 7).“

3.3. Regióny v Európskej Únii podľa NUTS II

Na posudzovanie a hodnotenie potrieb regiónov EÚ ako aj na správne využitie nástrojov regionálnej politiky sa územné celky posudzujú podľa klasifikácie NUTS.

Región nemá ustálenú a rovnakú definíciu. I keď sa v dnešnej dobe používa takmer každodenne pri rozmanitých súvislostiach. Napriek tomu ho nemožno presne zdefinovať. Každý autor, vedná disciplína i oblasť, v ktorej sa používa, ho definuje inak. Preto definícia závisí od predmetu skúmania ako i od samotnej vednej oblasti, ktorej zodpovedá jej obsah.

Bašovský (1990) definuje región, ako „je zložitý dynamický priestorový systém, ktorý vznikol na zemskom povrchu na základe interakcie prírodných a socioekonomických javov (Bašovský, 1990, s. 118).“

Inak ho definuje Demek (1970), podľa ktorého ide o „územie, časť krajinej sféry, ktoré sa súborom vlastností, stavov a javov odlišuje od susedných prípadne ďalších oblastí, pričom táto jednota je objektívnou podmienkou a zákonným výsledkom vývoja daného územia (Demek, 1987, s.242).“

„Región ako nástroj novej štrukturálnej politiky Európskej Únie je nomenklatúrnou jednotkou pre územnú štatistiku NUTS. Má pôvod z francúzskeho slova Nomenclature des Unités Territoriales Statistiques. Cieľom takejto regionalizácie je dosiahnuť štruktúru, ktorá by zabezpečila porovnateľnosť regiónov v nomenklatúre NUTS na každej úrovni v celom Spoločenstve“ (Miškovičová, 2005).

NUTS vznikol na podnet Štatistického úradu Európskej Únie na základe celistvého územného delenia regiónov a jednoduchšej tvorbe regionálnej štatistiky.

Rozdelenie NUTS podľa skupín je vytvorené v rámci štrukturálnych fondov:

- **NUTS I** – sociálno-ekonomické regióny, spolkové krajiny, autonómne územia,
- **NUTS II** – provincie, administratívne územné celky,
- **NUTS III** – malé regióny s osobitnými diagnózami, časti krajov, okresy. (Miškovičová, 2005).

Tabuľka 5: Hierarchizácia NUTS

Úroveň	NUTS klasifikácia	Názov	Počet jednotiek
1	NUTS 0	štát	28
2	NUTS 1	územie	98
3	NUTS 2	región	273
4	NUTS 3	kraj	1,324
5	NUTS 4 (LAU 1)	okres	8,772
6	NUTS 5 (LAU 2)	obec	120,968

Zdroj: Lipková et al. 2011, vlastné spracovanie

Druhá úroveň klasifikácie NUTS (Tabuľka 5) rozčleňuje prvú úroveň, ktorá rozčleňuje krajiny. To isté platí aj pre tretiu úroveň. Nevýhodou klasifikácie je, že nepokrýva samosprávy a ak má štát v EÚ menší počet obyvateľov ako je v minimálnom prahu členení NUTS, tak sa krajina zaradí ako územná jednotka NUTS v danej úrovni. Administratívna úroveň sa určí na základe priemerného počtu obyvateľov a jej administratívnych jednotiek (Europa.eu, 2016).

Tabuľka 6 ukazuje administratívne členenie. Ak neexistuje administratívna úroveň vhodnej veľkosti, tak sa ohraničí na základe adekvátneho počtu menších susedných jednotiek. Výsledkom je neadministratívna úroveň, v ktorej sa musia dodržiavať uvedené populačné prahy, maximálny a minimálny počet obyvateľov.

Tabuľka 6: Počet obyvateľov podľa delenia NUTS

Úroveň	NUTS I.	NUTS II.	NUTS III.
Minimálny počet obyvateľov	3 000 000	800 000	150 000
Maximálny počet obyvateľov	7 000 000	3 000 000	800 000

Zdroj: http://publications.europa.eu/resource/cellar/3686a361-ae7-415d-8549-127ed6370bf0.0022.02/DOC_3

Diplomová práca bola zameraná na členenie podľa NUTS II. Tabuľka 7 ukazuje celkový počet regiónov v jednotlivých krajinách na základe členenia NUTS II, s ktorými

sme ďalej pracovali. Údaje pre regióny, ktoré sa nachádzajú na území Veľkej Británie sme neanalyzovali, keďže už nie je súčasťou EÚ. Slúžia iba na ilustráciu.

Tabuľka 7: Regióny podľa členenia NUTS II

Krajina	Počet regiónov podľa NUTS II	Krajina	Počet regiónov podľa NUTS II
Belgicko	11	Litva	2
Bulharsko	6	Luxembursko	1
Česká republika	8	Maďarsko	8
Dánsko	5	Holandsko	12
Nemecko	38	Poľsko	17
Estónsko	1	Portugalsko	5
Grécko	9	Rakúsko	9
Španielsko	15	Rumunsko	8
Francúzsko	21	Švédsko	8
Fínsko	4	Slovinsko	2
Chorvátsko	2	Slovensko	4
Taliansko	19	Írsko	3
Lotyšsko	1	Veľká Británie	41

Zdroj: vlastné spracovanie na základe Eurostatu

4. Výsledky práce

V nasledujúcej kapitole diplomovej práce sme poukazovali na ekonomicko-sociálne disparity. Bližšie sme analyzovali nezamestnanosť, HDP v PPS a úroveň vzdelania v jednotlivých regiónoch na základe členenia NUTS 2 v programe GeoDa. Využili sme nástroje priestorovej štatistiky.

Použili sme prístup ESDA, vykreslili sme si na mape jednotlivé ukazovatele, pomocou percentilových máp, kde sme porovnávali medzi územnými celkami ich rozdielnosti. Zaoberali sme sa prítomnosťou globálnej a lokálnej priestorovej autokorelácie, ktorú sme odhadli pomocou koeficientov priestorovej štatistiky. V neposlednom rade sme na základe ukazovateľov skonštruovali ekonometrické modely SAR a SEM, ktoré sme porovnávali s klasickým lineárnym modelom. Na rozpoznanie vhodného modelu sme spravili sériu testov, aby sme vybrali najlepšiu možnú voľbu.

4.1. Práca s programom GeoDa pri analyzovaní dát

Prvým krokom v riešení danej problematiky bolo stiahnutie správnych údajov, ktoré tvorili základ pri vytváraní modelu. Dáta, s ktorými sme pracovali pochádzali z webovej stránky EUROSTATU podľa členia NUTS II. Následne sme ich upravili tak, aby ich mohol program správne načítať. Bolo potrebné si z európskeho štatistického portálu stiahnuť aj mapu Európy v podobe shp. súboru. Po načítaní mapy do programu GeoDa sme do programu vložili aj získané údaje. Nepracovali sme so všetkými dátami, nakoľko niektoré obsahovali regióny, ktoré nemali susedov (ostrovy) alebo nedisponovali s potrebnými údajmi. Celkovo sme mali 260 údajov.

Mapa vykazovala aj územie Veľkej Británie ako súčasť európskeho zoskupenia. Ale na základe vývoja udalostí a po jej odstúpení z európskeho spoločenstva v roku 2020 sa pri riešení danej problematiky územie už ďalej nebralo do úvahy. Na základe tohto faktu sme následne pracovali s 219 údajmi, ktoré sme ďalej analyzovali pomocou programu GeoDa.

Dáta pochádzali z roku 2018. Boli to najnovšie údaje, ktoré poskytoval EUROSTAT. Hrubý domáci produkt bol vyjadrený v paritách kúpnej sily (ďalej len HDP v PPS). Nezamestnanosť a vzdelanie bolo poskytnuté v percentuálnom vyjadrení, rozdelené do dvoch kategórií. Nezamestnaných od 15 do 24 rokov (ďalej len NEZ 2) a od 20 do 64 rokov (ďalej len NEZ), aby sa pokryla čo najväčšia dĺžka obyvateľstva. Vzdelanie sa rozdelilo podľa výšky dosiahnutej úrovne na level 0-2 (ďalej len VZD) a level od 3 po 8 (ďalej len

VZD 2) podľa klasifikačnej úrovne International Standard Classification of Education (ďalej len ISCED), ktorú kvantifikovala Organizácia Spojených národov pre vzdelávanie, vedu a kultúru (ďalej len UNESCO) do 8 ucelených úrovní. Veková kategória pri obidvoch úrovniach vzdelania bola od 25 do 64 rokov.

V tabuľke 8 sme znázornili jednotlivé úrovne na základe dosiahnutého vzdelania podľa ISCED klasifikácie z roku 2011.

Tabuľka 8: Rozdelenie úrovní vzdelania podľa ISCED

úroveň	názov	charakteristika	doklad o získanom vzdelaní
0	vzdelávanie pre najmenšie deti	primárne dovednosti	-
1	primárne vzdelávanie	základné vzdelanie	vysvedčenie s doložkou
2	nižšie sekundárne vzdelávanie	nižšie stredné vzdelanie	vysvedčenie o záverečnej skúške
3	vyššie sekundárne vzdelávanie	stredné odborné vzdelanie	výučný list
4	postsekundárne neterciálne vzdelávanie	úplné stredné vzdelanie na stredných odborných školách a gymnáziách	vysvedčenie o maturitnej skúške
5	vyššie odborné vzdelávanie	absolútorium	vysvedčenie o absolventskej skúške
6	bakalárska úroveň vzdelávania	bakalárske vzdelanie	vysokoškolský diplom a dodatok k diplomu získaný po ukončení štúdia
7	magisterská úroveň vzdelávania	magisterské vzdelanie	vysokoškolský diplom a dodatok k diplomu získaný po ukončení štúdia
8	doktoranská úroveň vzdelávania	doktoranské vzdelanie	vysokoškolský diplom a dodatok k diplomu získaný po ukončení štúdia

Zdroj: vlastné spracovanie z online prezentácie Kobela, 2013

Ako vyplýva z Tabuľky 8 na úrovni 0 až 2 sa dosiahlo základné a nižšie stredné vzdelanie, ktorého dokladom o skončení prvej úrovni bolo vysvedčenie s doložkou. Po skončení druhej úrovne študenti dostali vysvedčenie o záverečnej skúške. Doklady o získanom vzdelaní pri úrovniach 3 až 8 boli výučný list, vysvedčenie o maturitnej skúške a vysokoškolský diplom.

Pri vizuálnom porovnaní všetkých indikátorov sme využili škatuľový graf, mapové zobrazenie, ktoré ponúkal softvér GeoDa.

4.1.1. Vybrané deskriptívne štatistiky

V prvom kroku sme odhadli pre každú premennú pomocou škatuľového grafu (box-plot), ktorý nám vykázal informácie o vybraných deskriptívnych štatistikách ako napr.

maximálna hodnota (ďalej len max), minimálna hodnota (ďalej len min), medián a štandardná odchýlka (ďalej len s.d.), ktoré sme spracovali do Tabuľky 9.

V prílohe A Obrázok 15 sme vyobrazili škatuľové grafy jednotlivých premenných. Box plot je typom grafu, ktorý sa často používa pri analýze vysvetľujúcich údajov na vizuálne znázornenie distribúcie číselných údajov a skreslenia pomocou zobrazenia dátových kvartilov. Poskytuje vizuálny súhrn údajov, ktorý analytikom umožňuje rýchlo identifikovať priemerné hodnoty, rozptyl súboru údajov a príznaky skreslenia. Skladá sa z obdĺžnika a z dvoch úsečiek. Dolný kvartil sa nachádza na spodnej časti obdĺžnika a horný kvartil na vrchnej časti. Čiara, ktorá rozdeľuje obdĺžnik je medián. Distribúcia je symetrická ak sa medián nachádza v strede. Priemer predstavuje zelený bod v obdĺžniku. Variabilitu nám ukazuje rozsah obdĺžnika. Čím je užší, tým je variabilita menšia. Z oboch strán vedú úsečky, pričom začiatok spodnej úsečky ukazuje na minimálnu hodnotu a koniec vrchnej úsečky maximálnu hodnotu. Všetky údaje, s ktorými sme pracovali vykazovali odľahlé pozorovania, ktoré sa zakreslili ako body.

Box ploty, ktoré vykazujú premennú HDP, VZD 2, NEZ a NEZ 2 (Príloha A, Obrázok 15) majú rozdelenie kladne (pravostranne) asymetrické na rozdiel od box plotu s premennou VZD, ktorá je záporne zošikmená.

V Tabuľke 9 sme zobrazili vybrané deskriptívne štatistiky.

Tabuľka 9: Deskriptívne štatistiky premenných

Deskriptívna štatistika	HDP	VZD	VZD 2	NEZ	NEZ 2
min	10 300,00	44,40	2,70	1,30	0,00
max	80 900,00	97,30	55,60	27,00	62,00
median	28 300,00	82,50	17,50	5,10	12,90
s.d.	11 478,59	11,45	11,45	4,75	12,68

Zdroj: výstup z programu GeoDa

Najmenšiu hodnotu pri premennej HDP v PPS z Tabuľky 9 vykazuje región z Bulharska, ktorého hodnota je 10 300. Naopak najvyššia hodnota HDP v PPS je 80 900 v regióne Luxemburska. Polovica regiónov má hodnotu HDP do 28 300 a druhá polovica má hodnotu nad 28 300. Na základe štandardnej odchýlky sa hodnota HDP pohybuje $\pm 11 478,59$ od priemeru.

Najmenšiu hodnotu pri premennej VZD z Tabuľky 9 vykazuje región z Portugalska, ktorého hodnota je 44,40 %. Naopak najvyššia hodnota VZD je 97,30 % v regióne, ktorý sa

nachádza v Litve. Polovica regiónov má hodnotu VZD do 82,50 % a druhá polovica má hodnotu nad 82,50 %. Na základe štandardnej odchýlky sa hodnota VZD pohybuje $\pm 11,45$ % od priemeru.

Najmenšiu hodnotu pri premennej VZD 2 z Tabuľky 9 vykazuje región z Litvy, ktorého hodnota je 2,70 %. Naopak najvyššia hodnota VZD 2 je 55,60 % v regióne, ktorý sa nachádza v Portugalsku. Polovica regiónov má hodnotu VZD 2 do 17,50 % a druhá polovica má hodnotu nad 17,50 %. Na základe štandardnej odchýlky sa hodnota VZD 2 pohybuje $\pm 11,45$ % od priemeru.

Najmenšiu hodnotu pri premennej NEZ z Tabuľky 9 vykazuje región z Českej republiky, ktorého hodnota je 1,30 %. Naopak najvyššia hodnota NEZ je 27 % v regióne, ktorý sa nachádza v Grécku. Polovica regiónov má hodnotu NEZ do 5,10 % a druhá polovica má hodnotu nad 5,10 %. Na základe štandardnej odchýlky sa hodnota NEZ pohybuje $\pm 4,75$ % od priemeru.

Najmenšiu hodnotu pri premennej NEZ 2 z Tabuľky 9 vykazuje až 34 regiónov, ktorých hodnota je 0 %. Naopak najvyššia hodnota NEZ 2 je 62 % v regióne, ktorý sa nachádza v Grécku. Polovica regiónov má hodnotu NEZ 2 do 12,90 % a druhá polovica má hodnotu nad 12,90 %. Na základe štandardnej odchýlky sa hodnota NEZ 2 pohybuje $\pm 12,68$ % od priemeru.

Po zobrazení deskriptívnych štatistík sme následne vykreslili mapy, ktoré nám poskytnú prehľad o hodnotách premenných v jednotlivých regiónoch.

4.1.2. Mapové zobrazenie jednotlivých indikátorov

Program nám vykreslil mapové zobrazenie na základe poskytnutých údajov. Ako bolo spomenuté v predchádzajúcich kapitolách, ponúkal množstvo máp pre jednoduchšiu vizualizáciu ako napr. percentilové mapy i kvantilové mapy. Pre lepšie poukázanie a zjednotenie rozdielov v daných územiach sme vykreslili iba percentilové mapy.

4.1.2.1. Zobrazenie HDP v paritách kúpnej sily v percentilovej mape

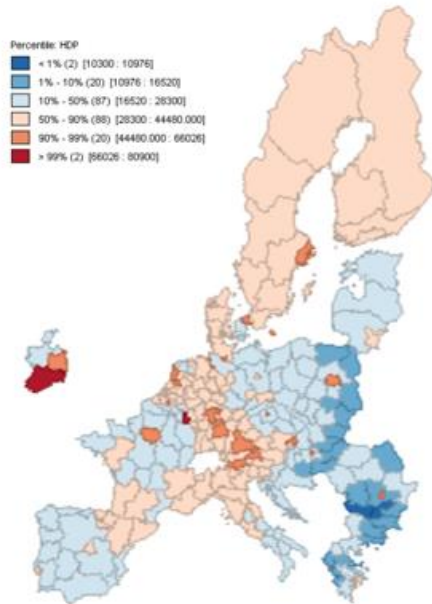
Percentilové mapy nám rozdeľovali všetky získané údaje do šiestich stanovených kategórií, ktoré zvyrazňovali extrémne hodnoty.

V percentilovej mape (Mapa 2) boli krajiny porovnávané na základe HDP v PPS za rok 2018. V prvej distribúcii do 1 % výšky HDP v PPS (tmavomodrá farba) spomedzi

všetkých regiónov mali dva regióny z Bulharska najmenšiu silu HDP v PPS oproti pozorovaným krajinám.

Na Mape 3 sme vybrali iba krajiny s najnižšou výškou HDP v PPS, ktoré sme označili tmavo modrou farbou. Boli to územné celky z Bulharska.

Mapa 2: Zobrazenie HDP v PPS v percentilovej mape



Zdroj: výstup z programu GeoDa

Mapa 3: Vyznačené krajiny z prvej distribúcií HDP v PPS



Zdroj: výstup z programu GeoDa

Mapa 2 nám ponúka ďalšie rozdelenie od 1 % do 10 %. Rozdelenie nám poukazuje na 20 regiónov, ktoré sú označené silno modrou farbou. Zaraďujú sa sem napr. kraje z Poľska, z Rumunska, zo Slovenska, z Bulharska, z Macedónska, ktorých HDP v PPS je v rozpätí od 10 976 až do 16 520. V distribúcií od 10 % do 50 % sa nachádza 87 regiónov, ktoré sú na mape vyfarbené bledomodrou farbou. Medzi najpočetnejšie patrí množstvo regiónov v rozpätí od 50 % do 90 %, pričom sa ich sem zaradilo až 88 krajov, ktoré sú vyznačené slabo oranžovou farbou. V rozmedzí od 90 % do 99 % je v distribúcií 20 regiónov. Najvyššiu výšku HDP v PPS majú iba 2 regióny zo všetkých porovnávaných regiónov. Ide o kraje z Írska a z Luxemburska.

4.1.2.2. Zobrazenie úrovne vzdelania v percentilovej mape

Disponovali sme dvoma typmi dát na základe dosiahnutého stupňa vzdelania 0 – 2 a 3 – 8, ktoré poukazovali na celkovú vzdelanosť obyvateľstva v regióne.

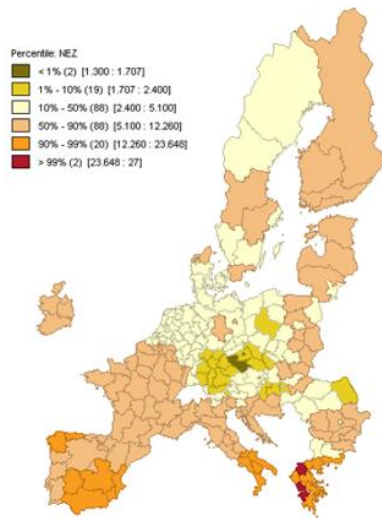
Percentilové mapy nám zobrazovali jednotlivé úrovne vzdelania. Mapa 4 obsahovala údaje z 3 až 8 úrovne a Mapa 5 zase z 0 – 2 úrovne vzdelania.

4.1.2.3. Zobrazenie nezamestnanosti v percentilovej mape

Pri vykreslení nezamestnanosti sme postupovali rovnako ako v predchádzajúcich mapových zobrazeniach. Tak isto ako pri vzdelaní, tak aj nezamestnanosť sme vykresľovali dvakrát. Pre obyvateľov od 20 do 64 rokov a pre obyvateľov od 15 do 24 rokov. Jednotlivé mapové zobrazenia sme následne medzi sebou porovnali.

Mapa 6 a Mapa 7 nám znázorňujú mapové zobrazenie nezamestnanosti pre jednotlivé skupiny obyvateľov v daných územných celkoch EÚ.

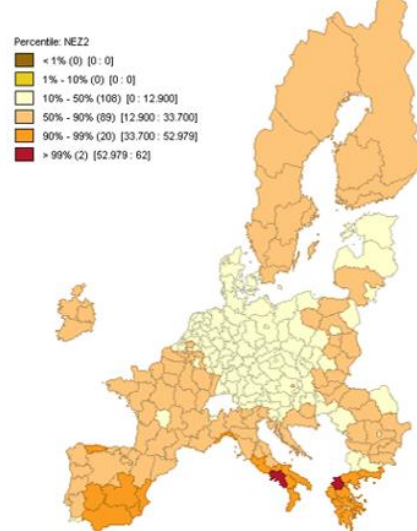
Mapa 6: Percentilové zobrazenie nezamestnanosti NEZ



Zdroj: výstup z programu GeoDa

Na Mape 6 je vidieť, že najvyššiu percentuálnu nezamestnanosť obyvateľov od 20 do 64 rokov majú regióny z Grécka, ktoré sú vyznačené červenou farbou. Naopak najmenšiu nezamestnanosťou v regióne si môžeme všimnúť u 2 regiónov v Českej republike.

Mapa 7: Percentilové zobrazenie NEZ2



Zdroj: výstup z programu GeoDa

Na Mape 7 je najvyššia výška nezamestnanosti obyvateľstva od 15 do 24 rokov v regionálnych oblastiach Talianska i Grécka. Najmenšiu mieru nezamestnanosti, ktorá vychádza z distribúcie 10 % až 50 %, nám mapa vykresľuje až v 108 európskych regiónoch. Väčšina z nich leží v strednej EÚ.

Zaujímavosťou je fakt, že najvyššia nezamestnanosť u mladej ako aj u staršej populácie obyvateľstva sa vyskytovala prevažne v rovnakých európskych regiónoch (Taliansko, Grécko).

Percentilové mapy boli užitočné pre celkovú vizualizáciu a vedeli poukázať na možnosť existencií priestorových zhlukov regiónov, ale neposkytovali nám žiadnu

štatistickú významnosť. Preto bolo potrebné využiť aj iné nástroje priestorovej analýzy, ktoré ponúkal samotný softvér GeoDa.


4.1.3. Zostrojenie matice susednosti

Pred analyzovaním samotnej priestorovej autokorelácie bolo dôležité si určiť, ktoré regióny budú susedné. Stanovili sme to na základe matice váh. Vzhľadom na priestorové efekty, ktoré pôsobili na regióny s jedným spoločným bodom, bola pre nás najlepšia možnosť typ „kráľovná“. Kráľovná považuje za susedov dva regióny s minimálne jedným spoločným bodom.

4.1.3.1. Skúmanie charakteristík váh pomocou histogramu

Histogram nám ukázal koľko krajov má koľko susedov po použití matice kráľovná. Graf 5 vykazuje histogram na základe matice kráľovná. V prvom stĺpci sa nám vykázalo 15 regiónov, ktoré mali iba jedného suseda. V piatom stĺpci sa nám vykázalo až 50 regiónov, ktoré mali piatich susedov.

Graf 5: Histogram na základe matice kráľovná

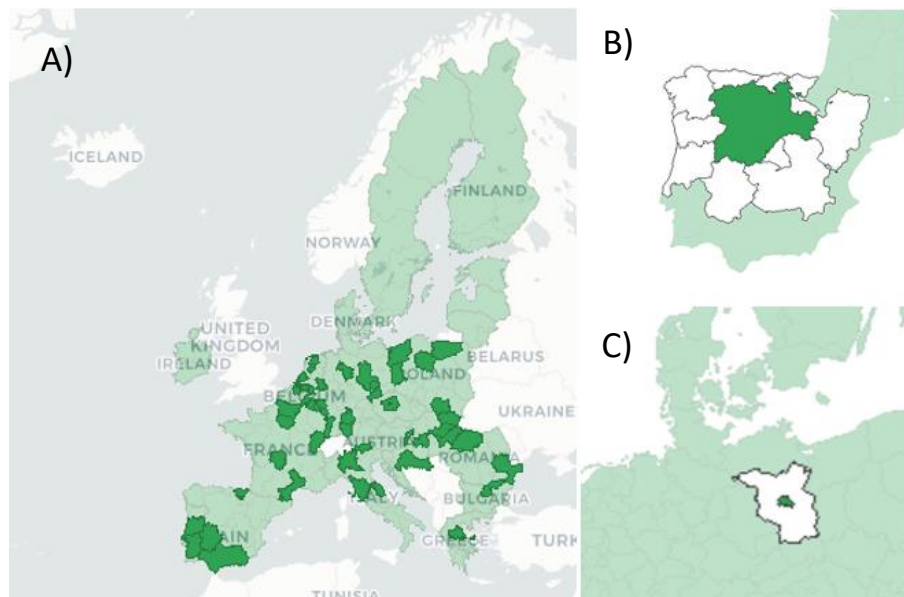


Zdroj: výstup z programu GeoDa,

Príklad jedného suseda nám znázorňuje Obrázok 4 v mape C. V Európe má 18 regiónov iba dvoch susedov, 27 troch susedov, 39 štyroch susedov. Piatimi susedmi disponuje až 50 regiónov (Obrázok 4 mapa A). Najvyšší počet susedných regiónov má iba

jeden kraj, ktorý je vyznačený na Obrázku 4 v mape B. Tento región sa nachádza na území Španielska.


Obrázok 4: Zobrazenie počtu susedov po použití matice kráľovná



Zdroj: výstup z programu GeoDa

Pri zmene typu kráľovná na vežu sa nám vyobrazí opäť histogram (Graf 6), ktorý sa o trochu menej diferencuje od Grafu 5.

Graf 6: Histogram na základe matice veža




Zdroj: výstup z programu GeoDa

Graf 6 poukazuje na počet regiónov v histograme, ktorý sa odlišuje iba pri počte susedov v stĺpcoch 2, 4, 5, keďže sa tu nezapočítavajú regióny za susedov, ak majú spoločnú

hranicu menšiu ako je stanovená kritická hranica. Histogram sme si vyobrazili na ilustráciu, ďalej s ním už nebudeme pracovať.

Zaujímavosťou pre nás bola analýza matice váh na báze Euklidovskej vzdialenosti. Prahová vzdialenosť bola 859 kilometrov. Graf 7 nám ilustruje histogram na základe matice vzdialenosti. Niektoré regióny majú až 97 susedov.

Graf 7: Histogram na základe matice vzdialeností



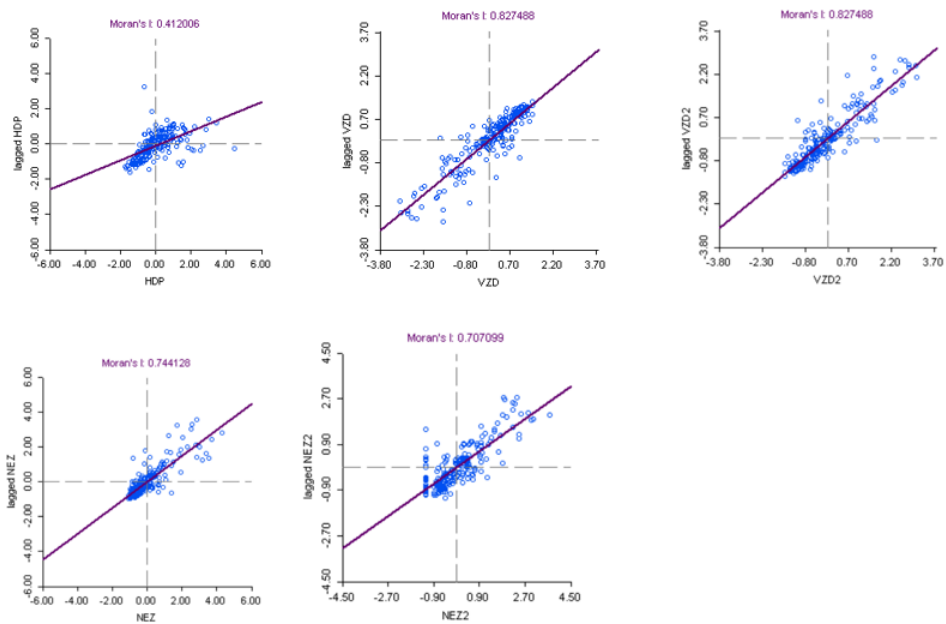
Zdroj: výstup z programu GeoDa

4.1.4. Zistenie priestorovej autokorelácie v analyzovaných dátach

Priestorová autokorelácia sa skúmala pomocou globálnej i lokálnej štatistiky priestorovej autokorelácie. Globálnu autokoreláciu sme vypočítali na základe Moranovej I štatistiky. Štatistika LISA a G koeficient sa využili na výpočet lokálnej autokorelácie, kde sa zistila prítomnosť negatívnej alebo pozitívnej priestorovej autokorelácie.

Globálnu priestorovú autokoreláciu sme graficky znázornili na Obrázku 5 pre každú jednu premennú na základe matice kráľovná. Hodnoty všetkých indikátorov boli kladné a pohybovali sa v rozmedzí od 0,3 do 0,8. Indikovalo nám to pozitívnu autokoreláciu, pretože hodnoty sa približovali k jednotke. Inak povedané, medzi regiónmi existovala vysoká nadväznosť.

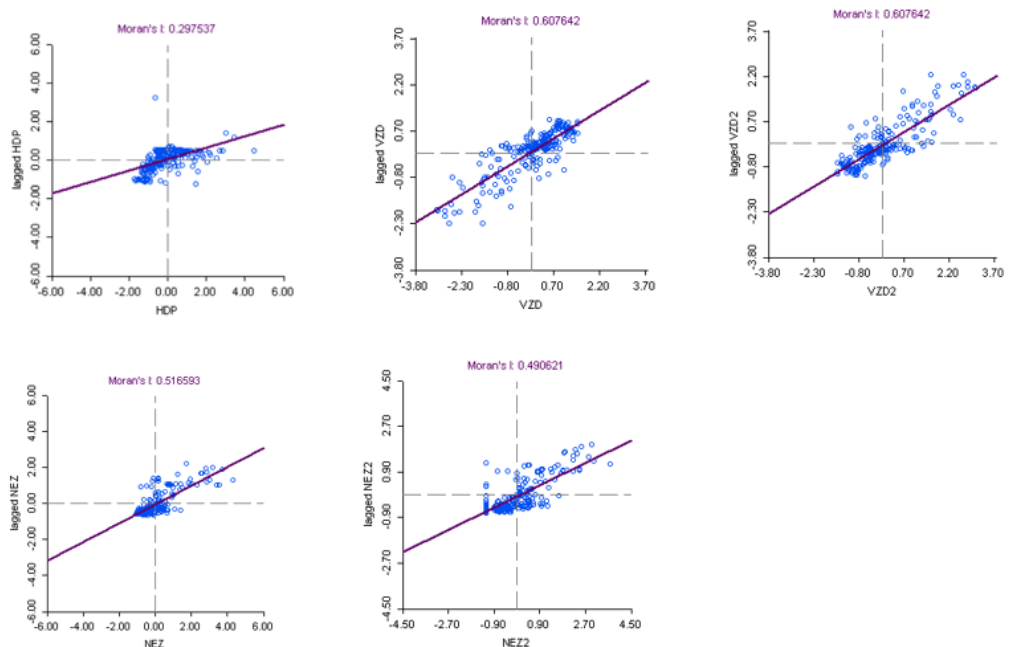
Obrázok 5: Moranova I štatistika indikátorov pri matici kráľovná



Zdroj: výstup z programu GeoDa

Globálnu priestorovú autokoreláciu sme graficky znázornili aj pre premenné na základe matice vzdialenosti (Obrázok 6). Hodnoty všetkých indikátorov boli kladné a pohybovali sa v rozmedzí od 0,29 do 0,61. Indikovalo nám to pozitívnu autokoreláciu, pričom existovala medzi regiónmi vysoká nadväznosť.

Obrázok 6: Grafy globálneho Moranovho I koeficienta, matica vzdialenost'



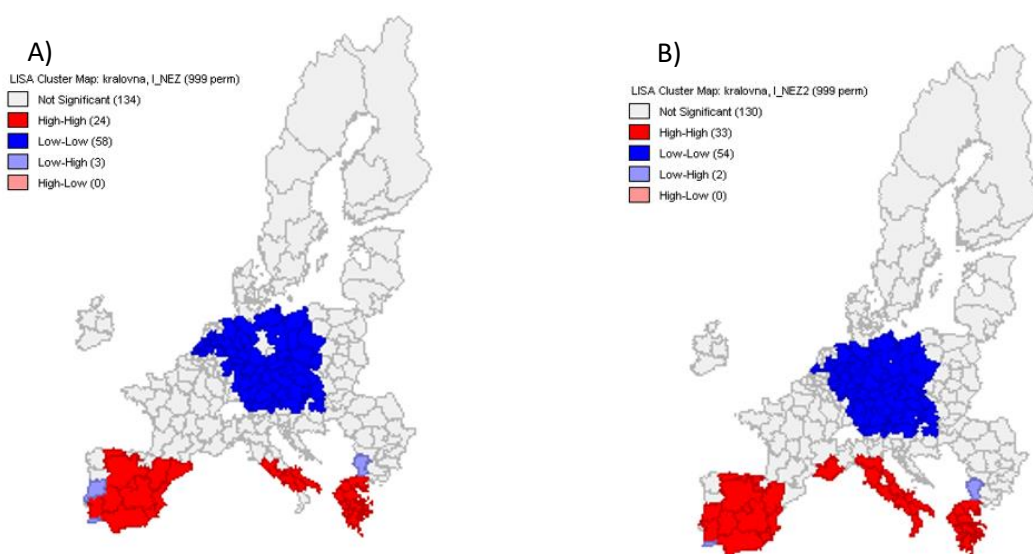
Zdroj: výstup z programu GeoDa

Ďalej sme preskúmali lokálnu priestorovú autokoreláciu, ktorú nám program vykreslil na základe klastrovej mapy a mapy významnosti LISA pre každú jednu analyzovanú maticu.

4.1.5. Klastrové mapy a mapa významnosti

Klastrové mapy LISA rozdelili regióny do kategórií: regióny bez štatistickej významnej korelácie, regióny s vysokými hodnotami so susedmi s vysokými hodnotami alebo s nízkymi susediacimi hodnotami, regióny s nízkymi hodnotami a s vysokými hodnotami susedov alebo s nízkymi susednými hodnotami (Obrázok 7).

Obrázok 7: LISA Klastrová mapa, matica kráľovná - A.) mapa NEZ, B.) mapa NEZ2



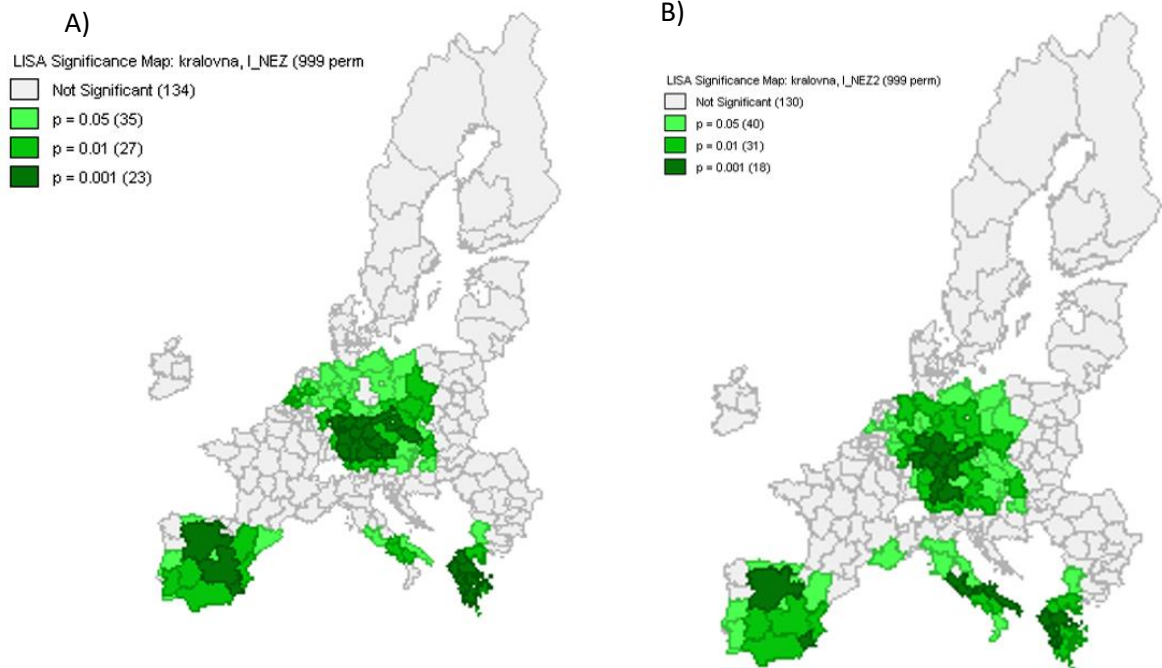
Zdroj: výstup z programu GeoDa

Lokálna priestorová autokorelácia sa rozdeľuje na pozitívnu a negatívnu autokoreláciu. Pozitívna autokorelácia indikuje zhľukovanie regiónov s podobnými hodnotami nezamestnanosti. Typ Low – Low (Obrázok 7) je v 112 (58, resp. v 54) regiónoch koncentrovaných najmä v strednej Európe. Typ High – High je v 57 (24, resp. v 33) regiónoch (Španielsko, Taliansko, Grécko). Negatívna autokorelácia naopak indikuje, v ktorých regiónoch je nezamestnanosť nižšia, resp. vyššia ako v regiónoch, ktoré ho obklopujú. Bledomodrou farbou je vyznačených 5 krajov, ktoré patria do kategórie Low – High.

Obidve mapy nám poukazovali na nezamestnanosť z rôznych vekových hľadísk obyvateľstva. Spoločne vykazovali vysokú nezamestnanosť u väčšiny regiónov Španielska, Talianska a Grécka ako i nízku nezamestnanosť v strednej Európe. Odlišovali sa v počte krajov v jednotlivých kategóriách.

Obrázok 8 znázorňuje mapy, ktoré vykresľujú iba regióny s významnou lokálnou štatistikou. Čím je zelená farba tmavšia, tým región dosahuje vyšší stupeň významnosti.

Obrázok 8: Mapy významnosti LISA, matica kráľovná



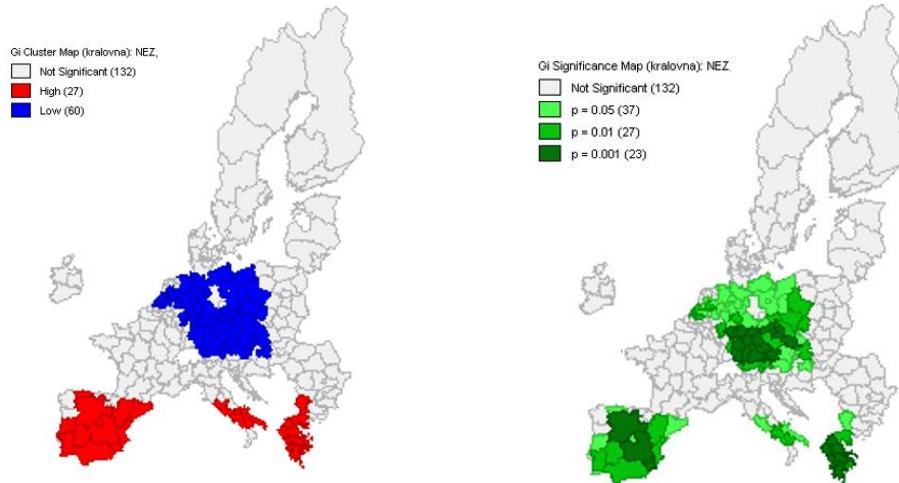
Zdroj: výstup z programu GeoDa, vlastné zdroje

Pri permutácii 999 (Obrázok 8) je najnižšia hodnota 0,001, ktorá predstavuje 23 regiónov pre mapu A nezamestnanosť od 20 do 64 rokov a 18 regiónov pre mapu B nezamestnanosť od 15 do 24 rokov.

Lokálna priestorová autokorelácia sa vykonala aj za pomoci G štatistiky. Ak bola hodnota pozitívna, poukazovala na vysoko – vysoké zoskupenie hodnôt. Pri negatívnych hodnotách boli zase nízko – nízke zoskupenia hodnôt.

Obrázok 9 nám ilustruje regióny za pomoci využitia G štatistiky, ktorá sa vyznačuje iba typmi Low, High a Not significant (nevýznamné).

Obrázok 9: Klastrová mapa a mapa významnosti G štatistika s indikátorom NEZ



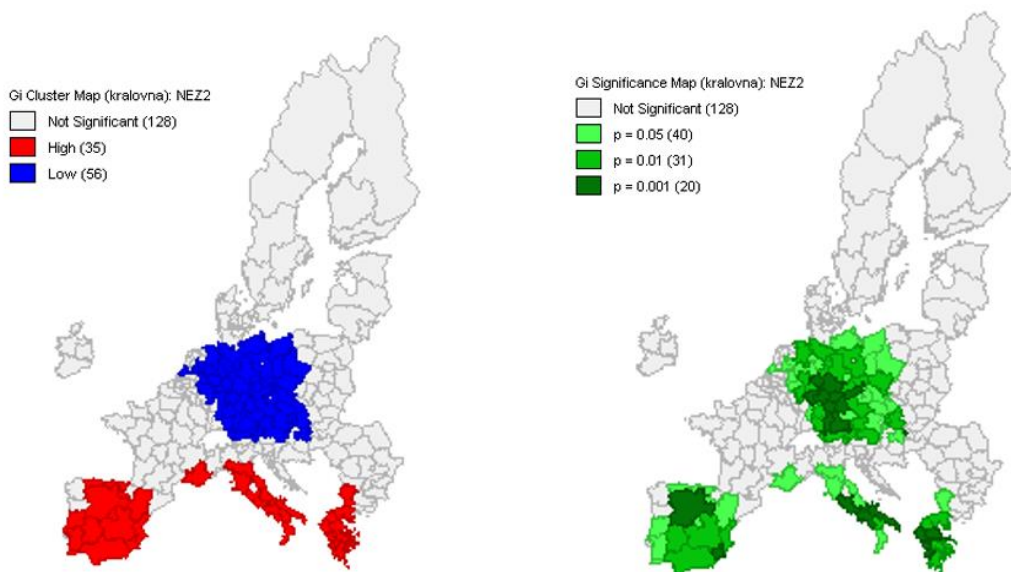
Zdroj: výstup z programu GeoDa

Lokálna priestorová autokorelácia (Obrázok 9) typu nízka je v 60 regiónoch koncentrovaná najmä v strednej Európe. Vysoká priestorová autokorelácia je v 27 regiónoch (Španielsko, Taliansko, Grécko).

Na hladine významnosti (Obrázok 9) 5 % je 37 regiónov významných. 27 regiónov je významných na hladine významnosti 1 % a 23 územných celkov je významných na 0,1 % hladine významnosti.

Na Obrázku 10 sme pomocou G štatistiky vykreslili aj nezamestnanosť pre obyvateľov od 15 do 24 rokov.

Obrázok 10: Klastrová mapa a mapa významnosti G štatistika s indikátorom NEZ 2



Zdroj: výstup z programu GeoDa

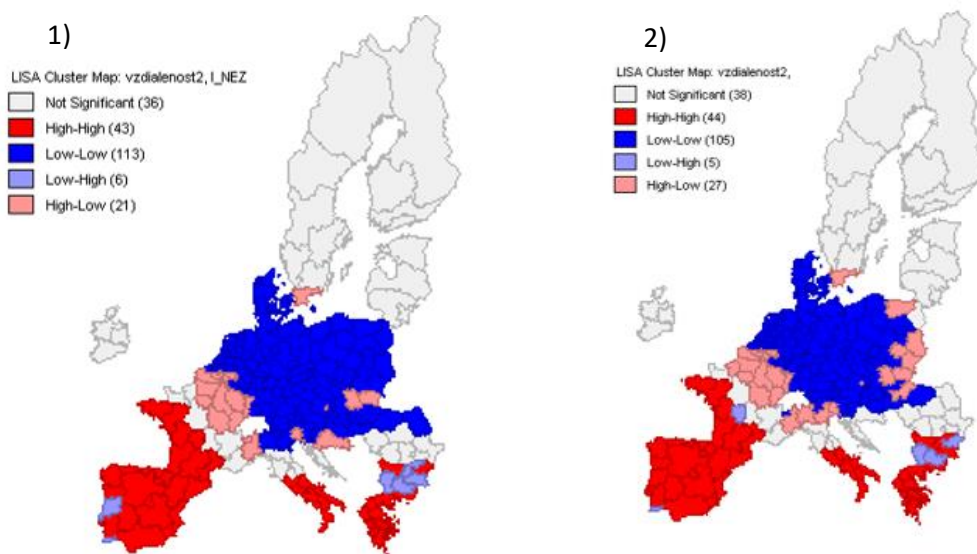
Nízka pozitívna lokálna priestorová autokorelácia (Obrázok 10) pri použití G štatistiky pre parameter nezamestnanosť od 15 do 24 rokov sa nachádza v 56 regiónov, ktoré sú vyznačené modrou farbou. Vysoká priestorová autokorelácia je v 35 regiónov vykreslená červenou farbou.

Na hladine významnosti 5 % je 40 regiónov významných, 31 regiónov je významných na hladine 1 % a pri 0,1 % je až 20 krajov významných.

Z výsledkov máp sme mohli konštatovať, že vysoká priestorová autokorelácia pre nezamestnanosť u oboch skupín bola sústredená najmä v južných oblastiach (Taliansko, Španielsko, Grécko). Naopak nízka autokorelácia pre nezamestnanosť pre obidve analyzované skupiny bola v strednej EÚ. Potvrdili nám to obidve štatistiky pre maticu kráľovná.

V nasledujúcom kroku sme vykreslili klastrové mapy (Obrázok 11) a mapy významnosti (Obrázok 12) pre obidve skupiny nezamestnanosti pre maticu vzdialenosť. Chceli sme zistiť, či pri matici vzdialenosť v nezamestnanosti vyjdú rovnaké mapové ukazovatele alebo sa budú výrazne odlišovať.

Obrázok 11: Klastrová mapa pre nezamestnanosť, matica vzdialenosti



Zdroj: výstup z programu GeoDa

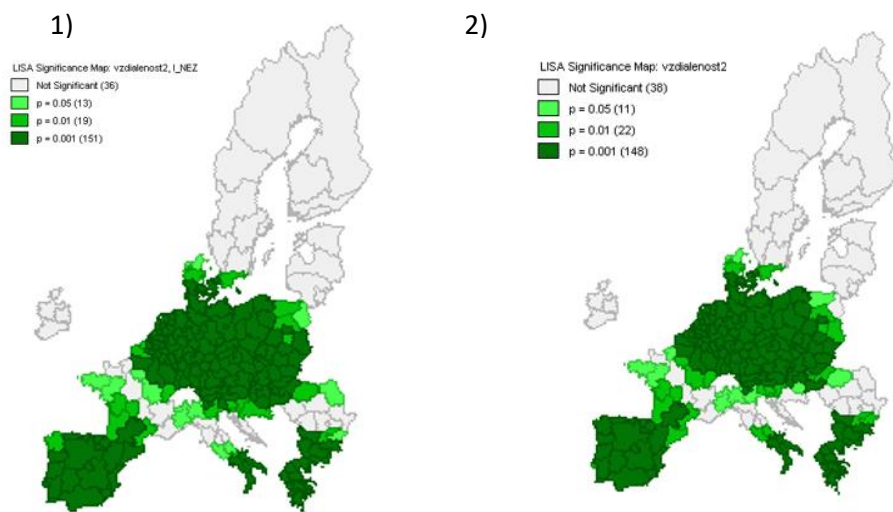
Prvá mapa (Obrázok 11) nám znázorňuje nezamestnanosť od 20 do 64 rokov. Druhá mapa nám poukazuje na nezamestnanosť od 15 do 24 rokov. Lokálna priestorová autokorelácia typu Low – Low (nízka) je v 113 regiónoch pre parameter NEZ a v 105 regiónoch pre parameter NEZ 2. Koncentrovaná je najmä v strednej Európe. Vysoká priestorová autokorelácia sa vyskytuje v 87 regiónoch, a to v Španielsku, v niektorých

regiónoch Portugalska, v južných častiach Talianska, v západných oblastiach Francúzska i v Grécku.

Bledomodrou farbou sú vyznačené kraje, ktoré patria do kategórie Low – High, ktorých je až 11 územných celkov. Ružovo zvýraznené krajiny patria do typu High a Low, v ktorej sa nachádza 48 regiónov.

Obrázok 12 nám vyznačuje mapy, ktoré nám vykresľujú regióny s významnou lokálnou štatistikou.

Obrázok 12: Mapa významnosti pre nezamestnanosť, matica vzdialenosť



Zdroj: výstup z programu GeoDa

Pri permutácii 999 (Obrázok 12) je najnižšia hodnota 0,001, ktorá predstavuje až 151 regiónov pre prvú mapu v nezamestnanosti od 20 do 64 rokov a 148 regiónov pre druhú mapu v nezamestnanosti od 15 do 24 rokov.

Mapy sa od seba celkovo moc nerozlišovali. Najväčší rozdiel spočíval v počte regiónov v jednotlivých sekciách. Všetky vykreslené mapy nám poukázali na približne rovnaké grafické vyobrazenia pre územné celky. Vysoká priestorová autokorelácia sa vyskytovala v južných oblastiach EÚ (napr. Španielsko, Taliansko) na rozdiel od strednej EÚ, kde bola zaznamenaná nízka priestorová autokorelácia pre parametre nezamestnanosti.

Pre ďalšie indikátory sme vykreslili mapy iba na základe lokálnej G štatistiky pre obidve matice, ktoré sme vyobrazili v kapitole Príloha v časti A.

Obrázok 16 v Prílohe B ilustruje HDP pre maticu kráľovná a maticu vzdialenosť v lokálnej G štatistike. Lokálna priestorová autokorelácia typu nízka je pri použití G štatistiky koncentrovaná v 46 regiónov (matica kráľovná) a v 53 regiónov (matica

vzdialenosť), ktoré sú znázornené modrou farbou. Typ vysokej priestorovej autokorelácie sa vyznačuje červenou farbou. Ide o 22 regiónov (matica kráľovná) a 96 regiónov (matica vzdialenosť). Na hladine významnosti 1 % je 22 regiónov (matica kráľovná), 17 regiónov (matica vzdialenosť) významných.

Obrázok 17 v Prílohe B vykazuje VZD pre maticu kráľovná a maticu vzdialenosť v lokálnej G štatistike. Lokálna priestorová autokorelácia typu nízka je pri použití G štatistiky sústredená v 37 (matica kráľovná) a 47 (matica vzdialenosť) regiónoch a sú vyznačené modrou farbou. Sú to napr. regióny zo Španielska, Talianska, Portugalska, Grécka. Typ vysokej priestorovej autokorelácie je vyznačený červenou farbou u 49 (matica kráľovná) a 109 (matica vzdialenosť) regiónov (napr. regióny zo strednej EÚ, Litva, Lotyšsko,..). Na hladine významnosti 1 % je 27 krajov (matica kráľovná) a 31 krajov (matica vzdialenosť) významných.

Obrázok 18 v Prílohe B poukazuje na VZD 2 pre maticu kráľovná a maticu vzdialenosť v lokálnej G štatistike. Lokálna priestorová autokorelácia typu nízka je pri použití G štatistiky v 49 (matica kráľovná) a 109 (matica vzdialenosť) regiónov, vyznačená modrou farbou. Typ vysokej priestorovej autokorelácie je zakreslený červenou farbou pre 37 (matica kráľovná) a 47 (matica vzdialenosť) regiónov. Na hladine významnosti 5 % je 40 regiónov významných, 31 regiónov je významných na hladine 1 % a pri 0,1 % je 20 krajov významných.

Pri globálnej priestorovej autokorelácie nám vyšla pozitívna autokorelácia, pričom existovala medzi regiónmi vysoká nadväznosť. Pri lokálnej priestorovej autokorelácie sme zistili existenciu pozitívnej aj negatívnej autokorelácie v európskych regiónoch. Jednotlivé premenné, ktoré sme analyzovali vykazovali zhľady regiónov s podobnými hodnotami ale vyskytli sa aj regióny, ktoré vykazovali negatívnu autokoreláciu. Po analýze priestorovej autokorelácie sme odhadli ekonometrické modely.

4.1.6. *Odhad ekonometrických modelov*

Cieľom štatistickej regresnej analýzy je vysvetlenie vzťahu medzi závislou a nezávislou premennou, pričom na závislú premennú pôsobia aj ďalšie javy a náhodné vplyvy. Snaží sa vysvetliť čo možno najväčšiu časť variability závislej premennej pomocou vzťahu s inou nezávislou premennou.

4.1.6.1. Odhad klasického lineárneho regresného modelu

Prvým krokom pri regresii bolo vybrať závislú a nezávislú premennú. Keďže sme odhadovali klasický lineárny model, tak závislou premennou bola nezamestnanosť od 20 do 64 rokov. Nezávislá premenná bola zastúpená v podobe HDP v PPS, VZD za rok 2018.

Po zadefinovaní všetkých premenných sme určili súbor s priestorovými váhami a odhadli sme lineárny model metódou najmenších štvorcov.

V prvom odhadnutom klasickom lineárnom modeli pri zadaní premennej HDP do modelu bol parameter v modeli štatisticky významný (Príloha C, Výstup 1). Model nevykazoval prítomnosť multikolinearity. Hodnota bola menšia ako 30, čo poukazovalo na jej neprítomnosť (Príloha C, Výstup 1).

Klasický lineárny model s využitím metódy najmenších štvorcov (ďalej len MNS) sme doplnili o priestorové váhy kráľovná (Príloha C, Výstup 2) a vzdialenosť (Príloha C, Výstup 3). Všetky parametre boli štatisticky významné pre obidva modely. Taktiež platilo, že Moranov I koeficient bol štatisticky významný v oboch prípadoch. Znamenalo to, že v modeloch bola prítomná autokorelácia.

Pri výbere vhodného priestorového modelu sme ďalej využili hodnoty Lagrangeových multiplikátorov, resp. ich robustných verzií a na ich základe sme vybrali model SAR (Príloha C, Výstup 2), ktorý bolo vhodné použiť aj pri odhadovaní druhého modelu s maticou váh vzdialenosť (Príloha C, Výstup 3).

Pri lineárnom klasickom modeli s využitím matice kráľovná (Príloha C, Výstup 2) boli silno významné LM lag aj LM error štatistiky. Preto sme brali do úvahy aj koeficienty z Robust LM lag a z Robust LM error. Vyššiu významnosť mal koeficient z Robust LM lag. Na základe tohto kritéria sa odhadoval SAR model.

Tento istý postup sme aplikovali aj pri lineárnom klasickom modeli s využitím matice vzdialenosti (Príloha C, Výstup 3). Potvrdili sa nám významné štatistické koeficienty LM lag a LM error. Vybrali sme model SAR, aj keď koeficienty v Robust lag a error sa medzi sebou výrazne neodlišovali, preto sme sa rozhodli, že odhadneme aj model SEM pre maticu váh vzdialenosť.

4.1.6.2. Regresia SAR a SEM modelu

Po odhadnutí klasického lineárneho modelu sme odhadli SAR a SEM model, kde sme skúmali, či majú premenné HDP, VZD vplyv na miery nezamestnanosti v európskych regiónoch, teda či je v modeloch prítomná priestorová autokorelácia. Následne sme napísali formuláciu SAR a SEM modelu.

Model SAR s využitím našich premenných má tvar:

$$NEZ_{20-64i} = \beta_0 + \rho \sum_{j=1}^n w_{ij} NEZ_{20-64j} + \beta_1 HDP_i + \beta_2 VZD_i + \varepsilon_i$$

SEM model pri využití našich premenných má tvar:

$$NEZ_{20-64i} = \beta_0 + \beta_1 HDP_i + \beta_2 VZD_i + u_i \quad u_i = \lambda \sum_{j=1}^n w_{ij} u_j + \varepsilon_i$$

Pre prehľadnejšie porovnanie výsledkov sme jednotlivé modely zoradili do Tabuľky 10, ktorá vykreslila SAR model regionálnej miery nezamestnanosti od 20 do 64 rokov na základe typu matíc.

Tabuľka 10: Odhad modelu SAR, metódou maximálnej vierohodnosti s maticou kráľovná a s maticou vzdialenosť

Odhad modelov na základe maximálnej vierohodnosti			
Parameter	SAR matica kráľovná	SAR matica vzdialenosť	SEM matica vzdialenosť
ρ	0,63764	0,75239	×
β_0	12,25710	12,31010	21,65370
β_1	-0,02214	-0,02912	-0,02216
β_2	-0,11103	-0,11585	-0,16418
λ	×	×	0,87407

Zdroj: vlastné spracovanie výsledkov z výstupu GeoDa, Príloha C Výstup 4 a 5

Vyššie uvedená Tabuľka 10 nám poukazovala na výsledky odhadov modelov SAR, ktorá vychádzala z matice kráľovná a z matice vzdialenosť a modelu SEM s maticou váh vzdialenosť. Modely priestorového oneskorenia poukazovali na priestorovú autokoreláciu so strednou silou. To isté opisoval koeficient lambda v modeli priestorovej chyby, ktorá detekovala silnú autokoreláciu, ktorá mala vplyv na chybové zložky regiónov. Lambda vykazovala hodnotu 0,87407.

4.1.7. Porovnanie klasického ekonomického modelu oproti SAR modelu

Všetky modely nezamestnanosti poukazovali na analýzu SAR modelu, ktorý by mal dosahovať lepšie výsledky na rozdiel od SEM modelu.

Pri rozhodnutí, ktorý model by bol pre nás najlepšou voľbou sme porovnali klasický model s modelom SAR pre obidva typy matic, ktoré sme ďalej porovnali pomocou 3 štatistík: Log likelihood, Akaikeho informačné kritérium a Schwarzovo kritérium. Výsledky štatistík ako aj výsledné hodnoty sú zobrazené na Obrázku 13.

Obrázok 13: Výsledky odhadov klasického modelu a SAR modelu

Log likelihood			
model	klasický model	SAR model (kráľovná)	SAR model (vzdialenosť)
1. model	-582,97	-526,90	-548,54

Akaikeho informačné kritérium			
model	klasický model	SAR model (kráľovná)	SAR model (vzdialenosť)
1. model	1 171,94	1 061,79	1 105,08

Schwarzovo kritérium			
model	klasický model	SAR model (kráľovná)	SAR model (vzdialenosť)
1. model	1 182,11	1 075,35	1 118,64

Zdroj: vlastné spracovanie výstupov z programu GeoDa

Na základe log likelihoodovho kritéria (Obrázok 13) bol pre nás najlepšou voľbou model s priestorovým oneskorením s maticou váh kráľovná, ktorý vykazoval najväčšiu hodnotu ukazovateľa spomedzi ostatných.

Swarzovho a Akaikeho informačné kritérium (Obrázok 13) nám poukazovali na SAR model s maticou váh kráľovná, pretože mal najmenšie hodnoty oproti ostatným modelom pri obidvoch prípadoch priestorových váh.

Obrázok 14: Výsledky odhadov klasického modelu, SAR a SEM modelu s maticou váh vzdialenosť

Log likelihood			
model	klasický model	SAR model (vzdialenosť)	SEM model (vzdialenosť)
1. model	-582,97	-548,54	-550,82

Akaikeho informačné kritérium			
model	klasický model	SAR model (vzdialenosť)	SEM model (vzdialenosť)
1. model	1 171,94	1 105,08	1 107,63

Schwarzovo kritérium			
model	klasický model	SAR model (vzdialenosť)	SEM model (vzdialenosť)
1. model	1 182,11	1 118,64	1 117,80

Zdroj: vlastné spracovanie výstupov z programu GeoDa

Rovnako sme porovnávali aj klasický model s modelmi SAR a SEM s maticou váh vzdialenosť (Obrázok 14). Pri log likelihoodovom kritériu a pri Akaikeho informačnom kritériu je lepšou voľbou model SAR s maticou váh vzdialenosť. Pri Swartzovom kritériu nám vyšiel model SEM s maticou váh vzdialenosť. Rozhodli sme sa pre model SAR s maticou váh vzdialenosť, pretože vyšiel vo viacerých kritériách a aj v predchádzajúcom porovnaní ako lepšia možnosť.

Z celkového hľadiska je najlepšou alternatívou model SAR s maticou váh kráľovná, ktorý vykazoval lepšie hodnoty oproti iným modelom a má rozsiahlejšie rozdiely v štatistikách oproti klasickému modelu a SAR modelu s maticou váh vzdialenosť.

Záver

V diplomovej práci sme sa zaoberali analyzovaním a porovnávaním regionálnych disparít v európskych regiónoch na báze nástrojov priestorovej ekonometrie na úrovni NUTS II.

V teoretickej časti sme vysvetľovali pojmy (disparita, priestorová ekonometria a štatistika) prostredníctvom odborných kníh. Poukazovali sme na rozdielnosť medzi použitím SAR a SEM modelov. Bližšie sme sa venovali aj Európskej únii, jej nariadeniam a cieľom, ako aj znižovaniu regionálnych disparít v jednotlivých európskych regiónoch, aby nevznikli ďalšie nerovnosti medzi krajinami a nedochádzalo tak k prehľbovaniu bohatších a chudobnejších regiónov v štáte, čo by sa následne odrazilo v ekonomike štátu. Ďalej sme charakterizovali postupy, spôsob získavania a spracovania údajov a metód, ktoré boli použité na celkové zanalyzovanie modelov. Dôležité bolo objasnenie využitia voľno dostupného softvéru GeoDa, ktorého výhodou bola jednoduchá orientácia v systémovom okne.

V praktickej časti sme sa zamerali na rôzne výstupy a mapy, ktoré ponúkal program GeoDa. Slúžili na posúdenie prítomnosti priestorovej autokorelácie, významnosti koeficientov a na poukázanie veľkosti disparít medzi jednotlivými regiónmi. Porovnávali sme ukazovatele nezamestnanosti, vzdelania i hrubého domáceho produktu za rok 2018. Nezamestnanosť i vzdelanie sme rozdelili do dvoch oblastí. Zisťovali sme rozdielnosť medzi dosiahnutými vzdelanostnými úrovňami, základným a vyšším vzdelaním a nezamestnanosťou medzi mladými a staršími obyvateľmi. Týmto spôsobom sme dokázali pokryť celkovú nezamestnanosť a dosiahnutú úroveň vzdelania.

Výsledky z box plotov nám poskytli všeobecné informácie pre celý súbor. Na základe percentilových máp sme získali lepšiu predstavu ako sú rozložené údaje v priestore. Najvyššia hodnota HDP na základe deskriptívnych štatistík bola zaznamenaná v Luxembursku. Naopak najvyššia hodnota HDP v PPS bola 80 900 v regióne Luxemburska. Polovica regiónov mala hodnotu HDP do 28 300 a druhá polovica mala hodnotu nad 28 300. Na základe štandardnej odchýlky sa hodnota HDP pohybovala $\pm 11\,478,59$ od priemeru.

Najvyšší level vzdelanosti na úrovni 3 – 8 bol v percentilových mapách vykreslený väčšinou u obyvateľov žijúcich v strednej Európe, ktorí boli viac vzdelaní a nepostačovala im iba základná úroveň. Mali tendenciu k vyššej úrovni vzdelania, s čím súvisel aj rozdiel

v životnej úrovni ľudí. Pričom najvyššia úroveň vzdelania 3 - 8 sa vykazovala v Litve a v Českej republike. Najmenej vzdelaných ľudí bolo v Portugalsku a v Španielsku. Najvyššia nezamestnanosť obyvateľstva sa ukázala v percentilových mapách v oblasti Talianska a Grécka.

Potvrdila sa nám silná závislosť, teda prítomnosť priestorovej autokorelácie pre každú z analyzovaných premenných. Následne sme použili testovacie štatistiky ako: Moranova I štatistika, Getisova - Ordova štatistika. Vytvorili sme dve priestorové matice váh, typ kráľovná, ktorá považuje za susedov dva regióny s minimálne jedným spoločným bodom a typ vzdialenosť, ktorú sme zostavili na základe vzdialenosti medzi regiónmi. Kladná hodnota pri priestorovej autokorelácii nám naznačovala, že medzi regiónmi existuje vysoká nadväznosť. Možno povedať, že medzi regiónmi, ktoré vykazujú približné hodnoty analyzovaných premenných sú viac priestorovo zhromaždené, než aby to bolo náhodné. Potvrdilo nám to aj vykreslenie z percentilových máp.

Pozitívna autokorelácia pri Moranovej I štatistike nám indikovala zhukovanie regiónov s podobnými hodnotami. Pri nezamestnanosti bol typ Low – Low v 112 (58, resp. v 54) regiónoch koncentrovaných najmä v strednej Európe. Typ High - High bol v 57 (24, resp. v 33) regiónoch (Španielsko, Taliansko, Grécko). Negatívna autokorelácia bola v piatich krajoch, ktoré patrili do kategórie Low – High.

Lokálna priestorová autokorelácia typu nízka bola v 60 regiónoch koncentrovaná najmä v strednej Európe. Priestorová autokorelácia typu vysoká bola v 27 regiónoch (Španielsko, Taliansko, Grécko).

Odhadli sme ekonometrický model závislosti miery nezamestnanosti od dosiahnutého vzdelania a HDP. Vzhľadom na predpokladané potvrdenie prítomnosti priestorovej autokorelácie sme následne odhadli vhodný priestorový ekonometrický model (SAR, SEM).

Pri testovaní klasického modelu metódou najmenších štvorcov sme si všimli, že sa vykazovali priestorové efekty. Odhadli sme iba premenné HDP a VZD. Vyšiel nám model bez multikolinearity a všetky parametre zostali významné.

Model priestorového oneskorenia nám poukazoval na priestorovú autokoreláciu so strednou silou. To isté opisovala lambda v modeloch priestorových chýb, ktorá ukazovala silnú autokoreláciu.

Na základe log likelihoodovho kritéria bol najlepšou voľbou model SAR s maticou váh kráľovná, ktorý vykazoval najväčšiu hodnotu ukazovateľa spomedzi ostatných.

Swarzovo a Akaikeho informačné kritéria nám potvrdili výber modelu SAR s maticou váh kráľovná, pretože mali najmenšie hodnoty oproti ostatným modelom pri oboch prípadoch závislej premennej nezamestnanosti. Aj pri klasickom modeli nám Langrangeove multiplikátory poukazovali na SAR model.

Pri porovnávaní klasického modelu s modelom SAR s maticou váh vzdialenosť a s modelom SEM s maticou váh vzdialenosť sme usúdili, že najlepšou voľbou z týchto možností je SAR model s maticou váh vzdialenosť. SEM model mal skôr ilustračný charakter.

Z celkového hľadiska bol pre nás najlepšou alternatívou model s priestorovým posunom s maticou váh kráľovná, ktorý vykazoval lepšie hodnoty oproti iným modelom a mal rozsiahlejšie rozdiely v štatistikách oproti klasickému modelu, SAR modelu s maticou váh vzdialenosť a SEM modelu s maticou váh vzdialenosť.

Cieľom práce bolo poukázať na existenciu značných regionálnych disparít v oblasti nezamestnanosti, vzdelania a HDP, ktoré sme potvrdili, keďže regióny nedosahovali rovnakú úroveň na globálnej ani na lokálnej úrovni. Taktiež sa nám podarilo dokázať, že vývoj vyššie uvedených ukazovateľov v určitom regióne pôsobí na vývoj daného ukazovateľa v geograficky blízkych regiónoch. Väčšinou sa medzi sebou zhluovali krajiny, ktoré vykazovali podobné hodnoty faktorov v daných oblastiach.

Nerovnosť medzi európskymi regiónmi je dlhodobá záležitosť, ktorú nie je ľahké eliminovať. EÚ ako aj samotné štáty sa dlhodobo snažia tieto rozdiely znižovať ako napr. v prijímaní rôznych zákonov a nariadení. Ide o komplexný problém, ktorého riešenie nie je jednoduché. Veľký vplyv v nerovnostiach zohráva aj charakter krajiny (priemyselná výroba, poľnohospodárska výroba,..), jeho politická situácia a mnohé iné vplyvy, ktoré sa odrážajú v ekonomike.

Zoznam použitej literatúry

- ANSELIN, Luc.** *Spatial Econometrics*. University of Texas at Dallas. 1999. [elektronický zdroj]. Texas. 1999. Dostupné na internete: <http://www.csiss.org/aboutus/presentations/files/baltchap.pdf>
- BARRECA, Alice. – CURTO, Rocco. – ROLANDO, Diana.** *Assessing Social and Territorial Vulnerability on Real Estate Submarkets*. [elektronický zdroj]. London. 1996. Dostupné na internete https://www.researchgate.net/figure/Anselins-Moran-scatter-plot-interpretation-guide-Source-Authors-elaboration-on-51_fig2_320599347
- BARIČ, Ondrej.** *Kohézna politika Slovenskej republiky po vstupe do Európskej Únie*. Bratislava : NCEGŠ, 2019. ISBN: 978-80-972508-3-6.
- BELOVIČ, Vladimír.** *Hlavné dokumenty EÚ v oblasti vzdelávania [elektronický zdroj]*. Bratislava. Ministerstvo školstva Slovenskej republiky. Dostupné na internete <http://www.education.gov.sk>
- BENČ, Vladimír. - KLAMÁR, Radoslav. a kol.** *Kohézna politika EÚ na roky 2007 - 2013 a Lisabonská stratégia - Aktuálne reformy EÚ v kontexte lisabonskej stratégie* [elektronický zdroj]. Bratislava. Výskumné centrum Slovenskej spoločnosti pre zahraničnú politiku, n.o. 2007. Dostupné na internete <https://www.unipo.sk/public/media/13200/Koh%C3%A9zna%20politika%20E%C3%9A%20na%20roky%202007%20E2%80%93%202013%20a%20Lisabonsk%C3%A1%20strat%C3%A9gia.pdf>
- BAŠOVSKÝ, Oliver. - LAUKO, Viliam.** *Úvod do regionálnej geografie*. Bratislava: Slovenské pedagogické nakladateľstvo, 1990. s.118. ISBN: 80-08-00278-6.
- DEMEK, Jaromír.** *Úvod do štúdia teoretickej geografie*. Bratislava: Slovenské pedagogické nakladateľstvo. 1987. s.248.
- DŽUNGANOVÁ, Božena.** *Terminológia ako vedná disciplína*. [elektronický zdroj]. Bratislava. 2000. Dostupné na: <https://www.juls.savba.sk/ediela/ks/2002/3/ks2002-3.pdf>. Dostupné na: <https://www.juls.savba.sk/ediela/ks/2002/3/ks2002-3.pdf>.
- EURÓPA 2020.** *Európa 2020*. [elektronický zdroj]. 2010. Dostupné na: <https://eur-lex.europa.eu/LexUriServ/LexUriServ.do?uri=COM:2010:2020:FIN:SK:PDF>

EURÓPSKA KOMISIA. *Biela kniha o budúcnosti Európy: Úvahy a scenáre pre štáty EÚ - 27 k vývoju do roku 2025.* [elektronický zdroj]. Brusel. 2017. ISBN: 978-92-79-67631-4. Dostupná na: https://ec.europa.eu/commission/sites/beta-political/files/biela_kniha_o_buducnosti_europy_sk.pdf.

EURÓPSKA ÚNIA. *Politika súdržnosti sa pozerá do budúcnosti.* In *Panorama* [elektronický zdroj] Luxemburg. 2017, č.61, s.52. Dostupné na: https://ec.europa.eu/regional_policy/sources/docgener/panorama/pdf/mag61/mag61_sk.pdf

FURKOVÁ, Andrea. *Konštrukcia matice priestorových váh: Spatial weight matrice construction. Využitie kvantitatívnych metód vo vedecko-výskumnej činnosti a v praxi XI: zborník príspevkov z [11.] seminára: 27. – 29. máj 2015, Makov - Kysuce.* Bratislava: Vydavateľstvo EKONÓM, 2015, , [1-4]. ISBN 978-80-225-4084-1.

GALVASOVÁ, Iva. a kol. *Spolupráce obcí jako faktor rozvoje.* Brno: vydavateľstvo Georgetown, 2007. 140 s. ISBN 80-251-20-9.

GIANNETTI. *The effects of integration on regional disparities: Convergence, divergence or both? In European Economic Review.* 2002, vol. 46, no. 3, p. 539-567. ISSN 0014-2921.

GRÁC, Róbert. - KLOBUČNÍK, Michal - SLÁVIK, Vladimír. *Priestorová autokorelácia - metódy vymedzovania a klasifikácie regiónov v kontexte sociálno-ekonomickej regionalizácie Slovenskej republiky.* [elektronický zdroj]. Bratislava. 2011. Dostupné na: http://www.humannageografia.sk/clanky/slavik_grac_klobucnik_2011.pdf

HÁJEK, Oldřich. *Regionální disparity a regionální politika.* Žilina : GEORG, 2011. ISBN 978-80-89401-50-5.

HRDINA, Vojtech. a kol. *Stratégia územného rozvoja Slovenska - Aktuálne zmeny v oblasti územného rozvoja Slovenskej republiky.*[elektronický zdroj] Bratislava: AUREX spol. s r.o. 2019. s. 79. Dostupné na: <https://www.mindop.sk/ministerstvo-1/vystavba-5/uzemne-planovanie/dokumenty/aktualne-zmeny-v-oblasti-uzemneho-rozvoja-slovenskej-republiky>.

CHVÁLOVÁ, Jindra. *Minislovník ekonomických výrazů.* In HN Focus. [elektronický zdroj]. 2018. Dostupné na: http://osz-stare.cmkos.cz/CZ/Z_tisku/Bulletin/06_2002/members_minislovník.html.

IVANIČOVÁ, Stanislava. *Čo všetko berie do úvahy index ľudského rozvoja?* [online článok]. [Dátum prístupu: 2017]. Dostupné na: <https://focus.hnonline.sk/ekonomika/clanok/1036113-co-vsetko-berie-do-uvahy-index-ludskeho-rozvoja>.

JANOTKA, Martin. *Ekonomické spektrum: Priestorová analýza s využitím softvéru OpenGeoDa*. [elektronický zdroj] Vrana nad Topľou: CAESaR - Centrum vzdelávania, vedy a výskumu, 2/2013. Dostupné na: <http://www.spektrum.caesar.sk/?download=casopis%2002-2013.pdf>.

Jednotka pre európsky regionálny, obchodný a hospodársky rozvoj a Centrum pre rozvoj miest a environmentálne riadenie. *Možnosti úspechu prístupu trvalo udržateľných spoločenstiev a jeho uplatnenia*. [elektronická štúdia] Brusel. 2007. Dostupné na: http://www.europarl.europa.eu/meetdocs/2004_2009/documents/dv/summarysustainablecommunities_/summarysustainablecommunities_sk.pdf

KAČÍRKOVÁ, Mária. *Zhlukovanie potenciál v regiónoch nových členských krajín Európskej Únie*. Bratislava : SAV, 2008. ISSN 1337–5598.

KAŇÚK, Ján. *Priestorové analýzy a modelovanie*. Košice : Univerzita Pavla Jozefa Šafárika v Košiciach, 2015. ISBN 978-80-8152-290-1.

KEREKEŠ, Juraj. *Regionálne disparity a ich vyrovnávanie*. [elektronická správa na diskusiu] Bratislava : s.n., 2007. Dostupné na: http://www.avv.sk/wp-content/uploads/2018/08/1Regionalne_disparity_a_ich_vyrovnovanie.pdf

KOBELA, Juraj. *Medzinárodná štandardná klasifikácia vzdelania ISCED 2011 a jej prepojenie s Národným kvalifikačným rámcom*. [elektronická prezentácia] Bratislava. 2013. Dostupné na: http://www.kin-ball.sk/downloads/media/2014/20141027_04_prepojenie_NKR_ISCED_2011.pdf

KOREC, Pavol - ONDOŠ, Slavomír - RUSNÁK, Jaroslav. *Regionálne disparity na Slovensku; Niekoľko poznámok k ich bádaniu*. [elektronický dokument] Bratislava, 2016. Dostupné na: http://actageographica.sk/stiahnutie/60_2_07_Korec_et_al.pdf

KOTULIČ, Rastislav. *Ekonomický normál a jeho využitie v manažmente firmy*. [elektronický dokument] Prešov, Slovenská republika. Dostupné na: <http://www.pulib.sk/web/kniznica/elpub/dokument/Kotulic7/subor/kotulic.pdf>.

Legallo, J. *Space-Time Analysis of GDP Disparities among European Regions: A Markov Chains Approach*. In International Regional Science Review. 2004, ISSN 1552-6925, 2004, vol. 27, no. 2, p. 138-163.

LIPKOVÁ, Ľudmila. *Európska únia*. Bratislava : Sprint dva, 2011. s. 446 . ISBN: 978-8089393-33-6.

MARELLI, Enrico. - SIGNORELLI, Marcello. *Convergence, Crisis and Unemployment in Europe: The need for innovative policies.* [elektronický dokument] Italy. 2015. Dostupné na: <http://hrcak.srce.hr/file/223164>

MARKECHOVÁ, Dagmar. - STEHLÍKOVÁ, Beáta - TRIPÁKOVÁ, Anna. *Základné štatistiky.- Priestorová štatistika*, Nitra, 2011. ISBN: 978-80-8094-899-3.

MATLOVIČ, René. - MATLOVIČOVÁ, Kvetoslava. *Regionálne disparity a ich riešenie na Slovensku v rozličných kontextoch.* Prešov : Vydavateľstvo prešovskej univerzity, 2011. ISSN: 1336-6149.

MICHÁLEK, Anton. - PODOLÁK, Peter. *Regionálne a priestorové disparity na Slovensku, ich vývoj v ostatných desaťročí, súčasný stav a konzekvencie.* Bratislava : SAV, 2014. ISB 978-80-89580-088.

MIKOLA, Ján. - VANČO, Branislav. *Štatistika pre manažérov.* Žilina : Fakulta špeciálneho inžinierstva Žilinskej univerzity, 2000. s. 222. ISBN: 978-8088829-63-8.

MIKOLA, Ján. - VANČO, Branislav. *Ekonometria.* [elektronický zdroj] Žilina: Fakulta špeciálneho inžinierstva Žilinskej univerzity, 2004. Dostupné na http://fsi.uniza.sk/kkm/files/publikacie/ek/ek_kap_1.pdf

Ministri európskych krajín zodpovední za územné plánovanie a územný rozvoj. *Územná agenda Európskej Únie.* [elektronický zdroj]. Maďarsko. 2011. Dostupné na: <https://www.mindop.sk/ministerstvo-1/vystavba-5/uzemne-planovanie/medzinarodna-spolupraca/uzemna-agenda-europskej-unie-2020-pdf-539-kb>

MIŠKOVIČOVÁ, Dana. *Regionálna politika Európskej únie, Jej opodstatnenosť a výzvy pre nové programovacie obdobie.* Slovenská politická revue. [elektronický zdroj]. 2005. Dostupné na: http://sjps.fsvucm.sk/Articles/05_2_3.pdf.

Nariadenie Európskeho parlamentu a Rady (ES) č. 1059/2003. Zhrnutie: *Spoločná nomenklatúra územných jednotiek na štatistické účely (NUTS).* [Online]. 2016. Dostupné na: http://publications.europa.eu/resource/cellar/3686a361-ae7-415d-8549-127ed6370bf0.0022.02/DOC_3.

Odbor prierezových priorít ÚV SR. *Systém implementácie horizontálneho princípu, Udržateľný rozvoj na roky 2014-2015.* [elektronický zdroj] Bratislava : s.n., 2018. Dostupné na: https://www.vicempremier.gov.sk/wp-content/uploads/2018/10/6279_system-implementacie-horizontalneho-principu-udrzatelny-rozvoj-na-roky-2014-%E2%80%93-2020-ver-20.pdf.

PUGA, Diego. *European Regional Policies in Light of Recent Location Theories* [elektronický zdroj]. 2001. CEPR Discussion Paper 2767, Dostupné na: <http://www.iadb.org/intal/intalcdi/PE/2009/03778.pdf>

QUAH, D. *Regional convergence clusters across Europe.* In *European Economic Review*. 1996, vol. 40, no. 3-5, p. 951-958. ISSN 0014-2921.

RADVANSKÝ, Marek. *Možnosti analyzovania vplyvu kohéznej politiky na regióny a trh práce SR.* Bratislava : Ekonomický ústav Slovenskej akadémie vied, 2014. ISBN: 978-80-7144-218-9.

RAJČÁKOVÁ, Eva. - ŠVECOVÁ, Angelika. *Regionálne disparity v kontexte regionálnej politiky SR.* [elektronický zdroj] Bratislava. Dostupné na: https://www.econ.muni.cz/do/1456/soubory/katedry/kres/4884317/14318877/Rajcakova_Svecova.pdf

RUMANOVSÁ, Ľubica. a kol. *Základy politiky súdržnosti v EÚ a SR.* Nitra : SPU, 2017. ISBN 978-80-552-1777-2.

STEHLÍKOVÁ, Beáta. *Priestorová štatistika.* Nitra : Slovenská poľnohospodárska univerzita v Nitre, 2002., s. 129. ISBN: 80-8069-046-4.

ŠUJANOVÁ, Jana. - MOLNÁROVÁ, Dagmar. *Päť rokov Lisabonskej stratégie.* [elektronický zdroj] Trnava : STU. 2005. Dostupné na: https://www.mtf.stuba.sk/buxus/docs/internetovy_casopis/2005/4/sujanova.pdf.

VANTUCH, Juraj. a kol. *Analýza Európskeho kvalifikačného rámca a národných kvalifikačných rámcov vo vybraných krajinách EÚ.* Bratislava : Štátny inštitút odborného vzdelávania, 2014. Dostupné na https://www.kvalifikacie.sk/sites/nsk/files/images/Dokumenty/analiza_ekr_nkr_eu.pdf

VILLAVERDE, Castro. *Regional convergence, polarisation and mobility in the European Union 1980-1996.* In *Journal of European Integration*. ISSN 1477-2280, 2003, vol. 25, no. 1, p. 73-86

Odkazy na použité internetové stránky:

Enviroportál.sk *Index lepšieho života*. [Online]. [Dátum prístupu: 2004]. Dostupné na: <https://www.enviroportal.sk/pokrok-spolocnosti/index-lepsieho-zivota>

Eu2020.gov.sk *Lisabonská stratégia*. [Online]. [Dátum prístupu: 2011]. Dostupné na: <https://www.eu2020.gov.sk/lisabonska-strategia/>

Euroekonóm.sk: *Nezamestnanosť*. [Online]. [Dátum prístupu: 2016]. Dostupné na: <https://www.euroekonom.sk/ekonomika/vseobecna-ekonomicka-teoria/nezamestnanost/>.

Europa.eu. *Európska Únia*. [Online]. [Dátum prístupu: 2020]. Dostupné na: https://europa.eu/european-union/about-eu/figures/living_sk.

Európsky parlament. *Znižovanie nezamestnanosti: o čom je politika EÚ*. [Online]. [Dátum prístupu: 2019]. Dostupné na: <https://www.europarl.europa.eu/news/sk/headlines/society/20190612STO54312/znizovani-e-nezamestnanosti-o-com-je-politika-eu>.

EUROSTAT. *Quality of life*. [Online]. [Dátum prístupu 2019]. Dostupné na: https://ec.europa.eu/eurostat/cache/infographs/qol/index_en.html.

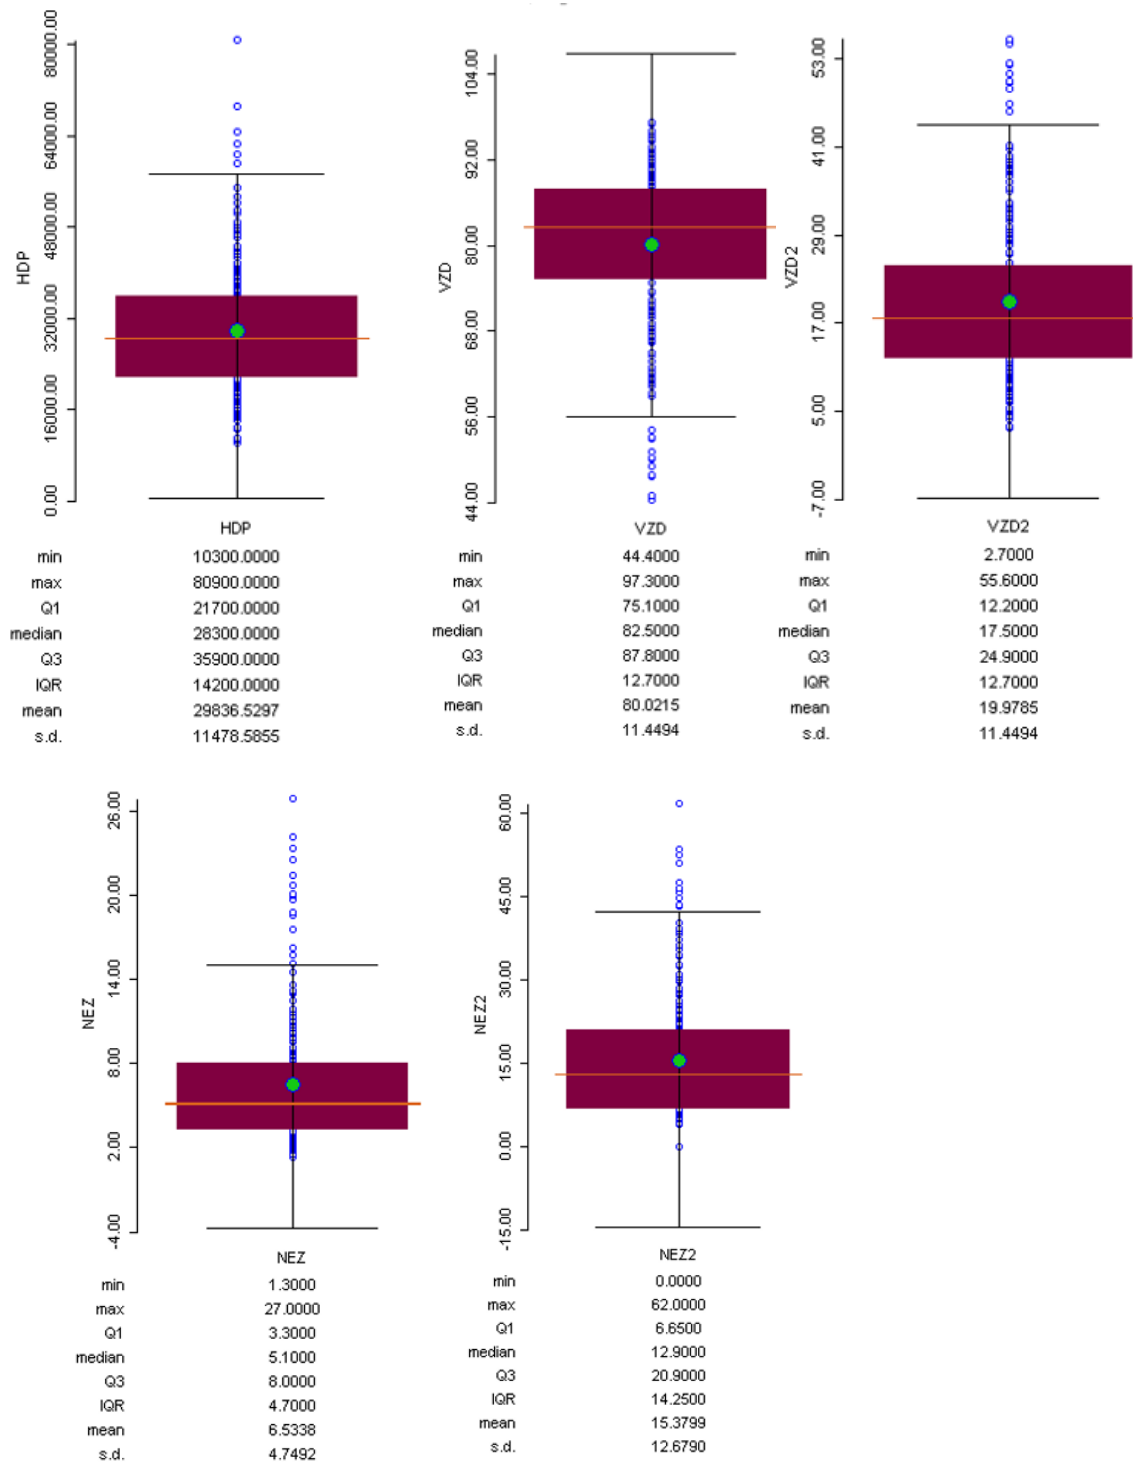
GATZ, Jan. *Brussels' youth unemployment halved after six-year continuous drop*. [Online]. [Dátum prístupu 2020]. Dostupné na: <https://press.actiris.be/youth-unemployment-at-record-low-in-brussels-after-six-year-continuous-drop>

OECD iLibrary. *Education at a Glance*. [Online] [Dátum prístupu 2019]. Dostupné na: <https://www.oecd-ilibrary.org/sites/f8d7880d-en/index.html?itemId=/content/publication/f8d7880d-en>.

Prílohy

Príloha A

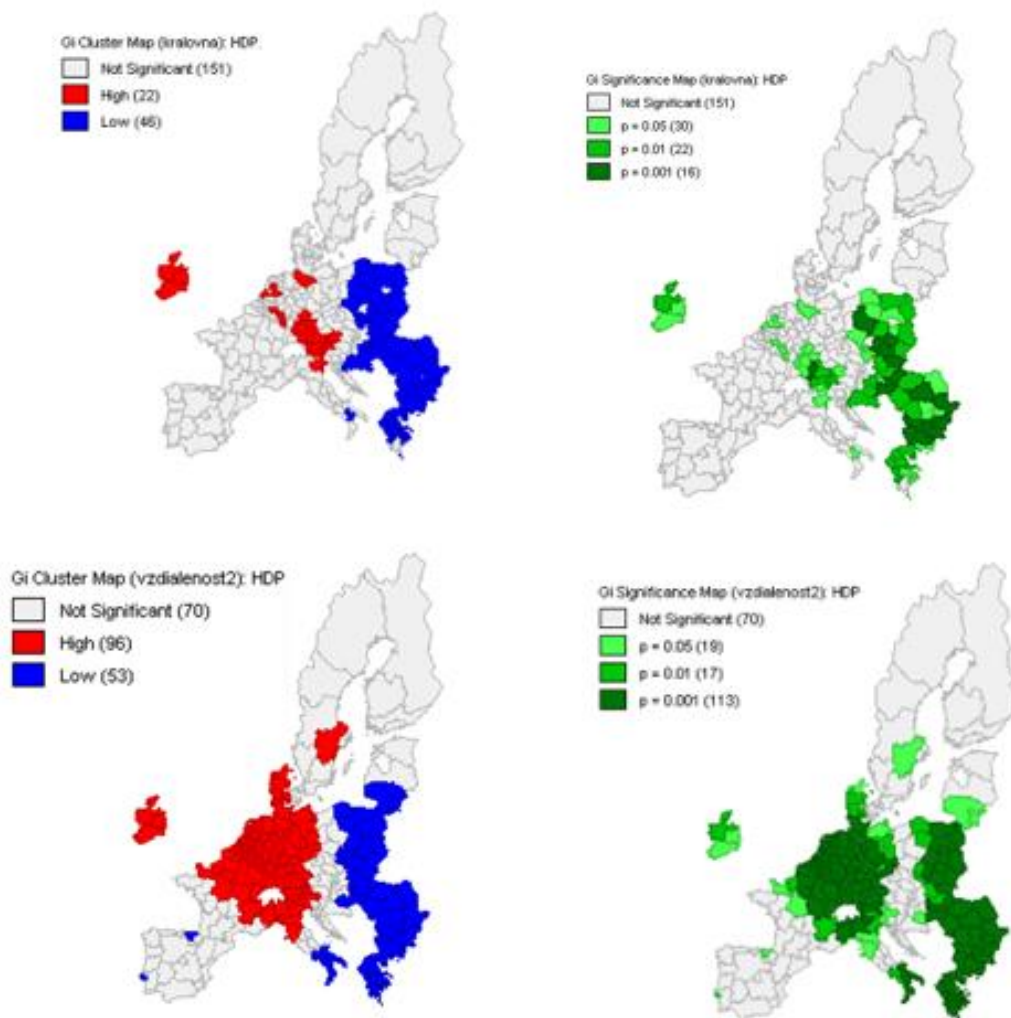
Obrázok 15: Box ploty s deskriptívnymi štatistikami pre každú premennú



Zdroj: výstup z programu GeoDa

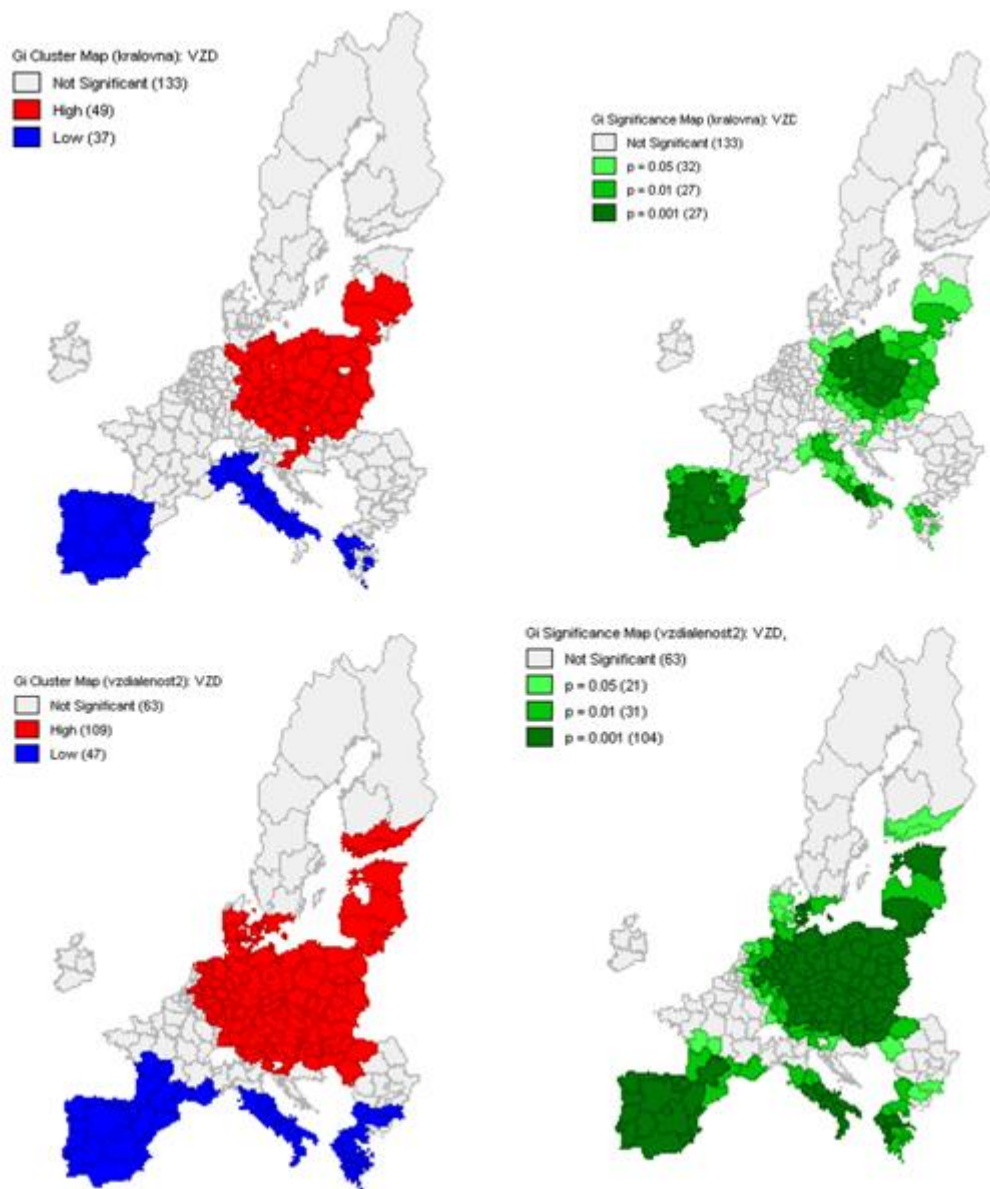
Príloha B

Obrázok 16: Klastrová mapa a mapa významnosti pre obidva typy matíc pre HDP



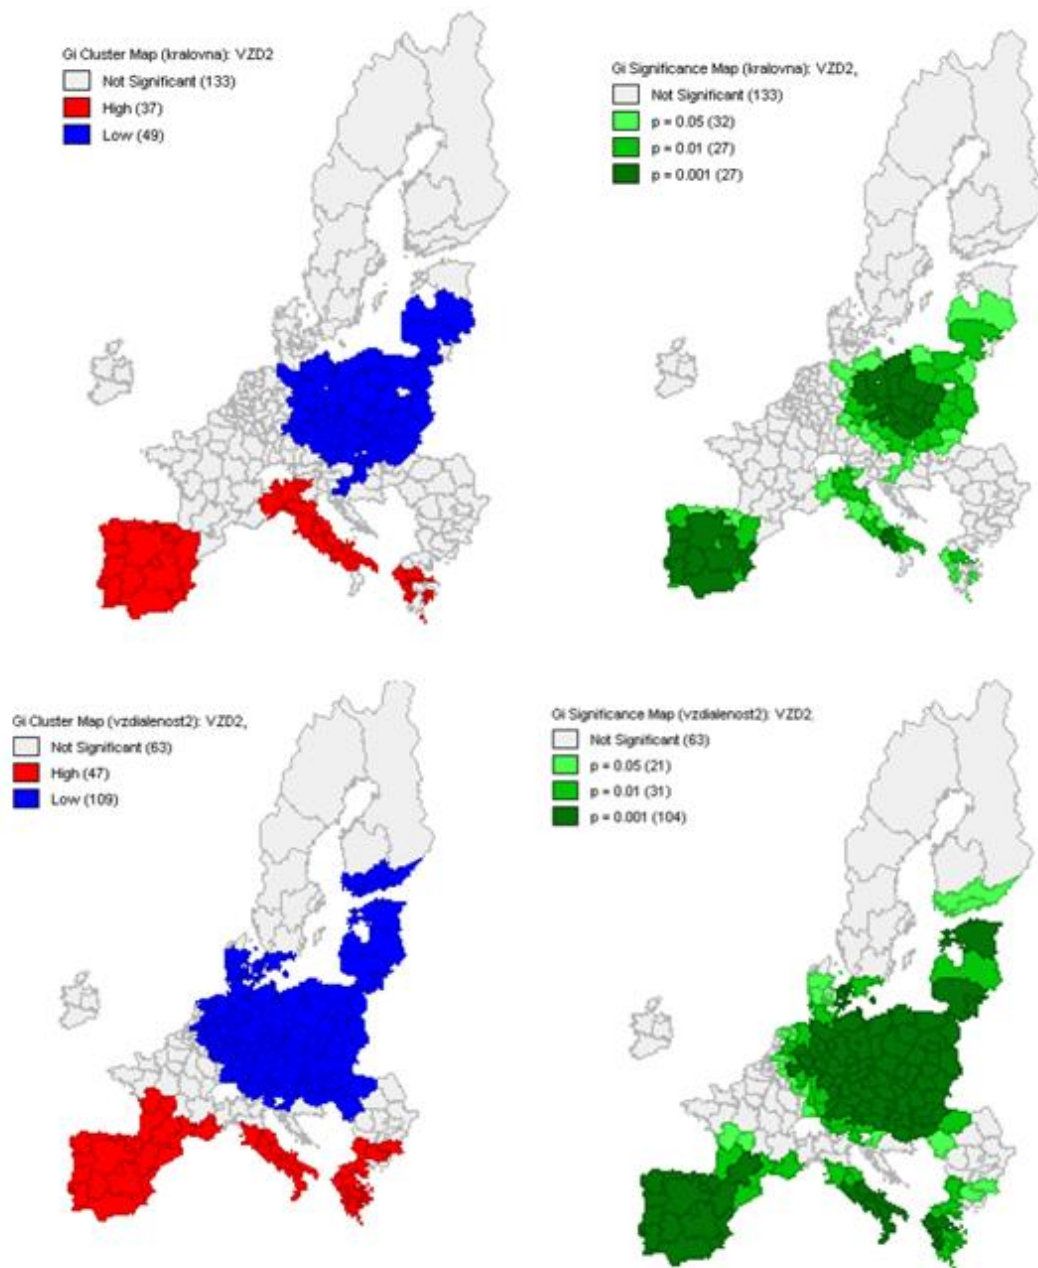
Zdroj: výstup z programu GeoDa

Obrázok 17: Klastrová mapa a mapa významnosti pre obidva typy matíc pre VZD



Zdroj: výstup z programu GeoDa

Obrázok 18: Klastrové mapy a mapy významnosti pre obidva typy matíc pre VZD2



Zdroj: výstup z programu GeoDa

Príloha C

Výstup 1: Výstup modelu metódou MNS

SUMMARY OF OUTPUT: ORDINARY LEAST SQUARES ESTIMATION

```
Data set      : subor bez vb (1)
Dependent Variable : NEZ   Number of Observations: 219
Mean dependent var : 6.53379   Number of Variables : 3
S.D. dependent var : 4.73838   Degrees of Freedom : 216

R-squared      : 0.464912   F-statistic      : 93.836
Adjusted R-squared : 0.459958   Prob(F-statistic) : 4.67632e-030
Sum squared residual: 2631.05   Log likelihood   : -582.972
Sigma-square    : 12.1808   Akaike info criterion : 1171.94
S.E. of regression : 3.4901   Schwarz criterion : 1182.11
Sigma-square ML  : 12.0139
S.E of regression ML: 3.46611
```

Variable	Coefficient	Std. Error	t-Statistic	Probability
CONSTANT	29.5364	1.70281	17.3457	0.00000
HDP	-8.32721e-005	2.08974e-005	-3.98481	0.00009
VZD	-0.256406	0.0209506	-12.2386	0.00000

REGRESSION DIAGNOSTICS

MULTICOLLINEARITY CONDITION NUMBER 17.014249

TEST ON NORMALITY OF ERRORS

TEST	DF	VALUE	PROB
Jarque-Bera	2	176.0031	0.00000

DIAGNOSTICS FOR HETEROSKEDASTICITY

RANDOM COEFFICIENTS

TEST	DF	VALUE	PROB
Breusch-Pagan test	2	86.7177	0.00000
Koenker-Bassett test	2	29.6530	0.00000

===== END OF REPORT =====

Zdroj: výstup z programu GeoDa

Výstup 2: Výstup modelu metodou MNŠ, váha královná

REGRESSION

SUMMARY OF OUTPUT: ORDINARY LEAST SQUARES ESTIMATION

```

Data set      : subor bez vb (1)
Dependent Variable : NEZ      Number of Observations: 219
Mean dependent var : 6.53379  Number of Variables : 3
S.D. dependent var : 4.73838  Degrees of Freedom : 216

R-squared      : 0.464912  F-statistic      : 93.836
Adjusted R-squared : 0.459958  Prob(F-statistic) : 4.67632e-030
Sum squared residual: 2631.05  Log likelihood   : -582.972
Sigma-square    : 12.1808  Akaike info criterion : 1171.94
S.E. of regression : 3.4901  Schwarz criterion : 1182.11
Sigma-square ML  : 12.0139
S.E of regression ML: 3.46611
    
```

Variable	Coefficient	Std. Error	t-Statistic	Probability
CONSTANT	29.5364	1.70281	17.3457	0.00000
HDP	-8.32721e-005	2.08974e-005	-3.98481	0.00009
VZD	-0.256406	0.0209506	-12.2386	0.00000

REGRESSION DIAGNOSTICS

MULTICOLLINEARITY CONDITION NUMBER 17.014249

TEST ON NORMALITY OF ERRORS

TEST	DF	VALUE	PROB
Jarque-Bera	2	176.0031	0.00000

DIAGNOSTICS FOR HETEROSKEDASTICITY

RANDOM COEFFICIENTS

TEST	DF	VALUE	PROB
Breusch-Pagan test	2	86.7177	0.00000
Koenker-Bassett test	2	29.6530	0.00000

DIAGNOSTICS FOR SPATIAL DEPENDENCE

FOR WEIGHT MATRIX : kralovna

(row-standardized weights)

TEST	MI/DF	VALUE	PROB
Moran's I (error)	0.5150	10.9505	0.00000
Lagrange Multiplier (lag)	1	118.8988	0.00000
Robust LM (lag)	1	12.3336	0.00044
Lagrange Multiplier (error)	1	110.8722	0.00000
Robust LM (error)	1	4.3070	0.03796
Lagrange Multiplier (SARMA)	2	123.2058	0.00000

===== END OF REPORT =====

Zdroj: výstup z programu GeoDa

Výstup 3: Výstup modelu metódou MNS, váha vzdialenosť

REGRESSION

SUMMARY OF OUTPUT: ORDINARY LEAST SQUARES ESTIMATION

```

Data set      : subor bez vb (1)
Dependent Variable : NEZ      Number of Observations: 219
Mean dependent var : 6.53379  Number of Variables : 3
S.D. dependent var : 4.73838  Degrees of Freedom : 216

R-squared      : 0.464912  F-statistic      : 93.836
Adjusted R-squared : 0.459958  Prob(F-statistic) : 4.67632e-030
Sum squared residual: 2631.05  Log likelihood   : -582.972
Sigma-square    : 12.1808  Akaike info criterion : 1171.94
S.E. of regression : 3.4901  Schwarz criterion : 1182.11
Sigma-square ML  : 12.0139
S.E of regression ML: 3.46611
    
```

Variable	Coefficient	Std. Error	t-Statistic	Probability
CONSTANT	29.5364	1.70281	17.3457	0.00000
HDP	-8.32721e-005	2.08974e-005	-3.98481	0.00009
VZD	-0.256406	0.0209506	-12.2386	0.00000

REGRESSION DIAGNOSTICS

MULTICOLLINEARITY CONDITION NUMBER 17.014249

TEST ON NORMALITY OF ERRORS

TEST	DF	VALUE	PROB
Jarque-Bera	2	176.0031	0.00000

DIAGNOSTICS FOR HETEROSKEDASTICITY

RANDOM COEFFICIENTS

TEST	DF	VALUE	PROB
Breusch-Pagan test	2	86.7177	0.00000
Koenker-Bassett test	2	29.6530	0.00000

DIAGNOSTICS FOR SPATIAL DEPENDENCE

FOR WEIGHT MATRIX : vzdialenosť2

(row-standardized weights)

TEST	MI/DF	VALUE	PROB
Moran's I (error)	0.2151	11.4599	0.00000
Lagrange Multiplier (lag)	1	98.0985	0.00000
Robust LM (lag)	1	23.0755	0.00000
Lagrange Multiplier (error)	1	91.8813	0.00000
Robust LM (error)	1	16.8583	0.00004
Lagrange Multiplier (SARMA)	2	114.9568	0.00000

===== END OF REPORT =====

Zdroj: výstup z programu GeoDa

Výstup 4: Výstup modelov SAR. 1.výstup matica kráľovná, 2.výstup matica vzdialenosť

SUMMARY OF OUTPUT: SPATIAL LAG MODEL - MAXIMUM LIKELIHOOD ESTIMATION

Data set : subor bez vb (1)
 Spatial Weight : kralovna
 Dependent Variable : NEZ Number of Observations: 219
 Mean dependent var : 6.53379 Number of Variables : 4
 S.D. dependent var : 4.73838 Degrees of Freedom : 215
 Lag coeff. (Rho) : 0.637642

R-squared : 0.716332 Log likelihood : -526.897
 Sq. Correlation : - Akaike info criterion : 1061.79
 Sigma-square : 6.369 Schwarz criterion : 1075.35
 S.E of regression : 2.52369

Variable	Coefficient	Std. Error	z-value	Probability
W_NEZ	0.637642	0.0506433	12.5908	0.00000
CONSTANT	12.2571	1.84683	6.63685	0.00000
VZD	-0.111025	0.0195743	-5.67199	0.00000
HDP	-3.28591e-005	1.51862e-005	-2.16374	0.03048

REGRESSION DIAGNOSTICS
 DIAGNOSTICS FOR HETEROSKEDASTICITY
 RANDOM COEFFICIENTS

TEST DF VALUE PROB
 Breusch-Pagan test 2 120.4563 0.00000

DIAGNOSTICS FOR SPATIAL DEPENDENCE

SPATIAL LAG DEPENDENCE FOR WEIGHT MATRIX : kralovna
 TEST DF VALUE PROB
 Likelihood Ratio Test 1 112.1502 0.00000

===== END OF REPORT =====

SUMMARY OF OUTPUT: SPATIAL LAG MODEL - MAXIMUM LIKELIHOOD ESTIMATION

Data set : subor bez vb (1)
 Spatial Weight : vzdialenost2
 Dependent Variable : NEZ Number of Observations: 219
 Mean dependent var : 6.53379 Number of Variables : 4
 S.D. dependent var : 4.73838 Degrees of Freedom : 215
 Lag coeff. (Rho) : 0.752394

R-squared : 0.625909 Log likelihood : -548.542
 Sq. Correlation : - Akaike info criterion : 1105.08
 Sigma-square : 8.3992 Schwarz criterion : 1118.64
 S.E of regression : 2.89814

Variable	Coefficient	Std. Error	z-value	Probability
W_NEZ	0.752394	0.0621491	12.1063	0.00000
CONSTANT	12.3101	2.08556	5.90252	0.00000
VZD	-0.115085	0.0217328	-5.29542	0.00000
HDP	-4.32164e-005	1.75593e-005	-2.46117	0.01385

REGRESSION DIAGNOSTICS
 DIAGNOSTICS FOR HETEROSKEDASTICITY
 RANDOM COEFFICIENTS

TEST DF VALUE PROB
 Breusch-Pagan test 2 107.1587 0.00000

DIAGNOSTICS FOR SPATIAL DEPENDENCE

SPATIAL LAG DEPENDENCE FOR WEIGHT MATRIX : vzdialenost2
 TEST DF VALUE PROB
 Likelihood Ratio Test 1 68.8593 0.00000

===== END OF REPORT =====

Zdroj: výstup z programu GeoDa

Výstup 5: : Výstup modelov SEM s maticou váh vzdialenosť

SUMMARY OF OUTPUT: SPATIAL ERROR MODEL - MAXIMUM LIKELIHOOD ESTIMATION
 Data set : subor bez vb (1)
 Spatial Weight : vzdialenost2
 Dependent Variable : NEZ Number of Observations: 219
 Mean dependent var : 6.533790 Number of Variables : 3
 S.D. dependent var : 4.738384 Degrees of Freedom : 216
 Lag coeff. (Lambda) : 0.874072

 R-squared : 0.628772 R-squared (BUSE) : -
 Sq. Correlation : - Log likelihood : -550.815216
 Sigma-square : 8.33493 Akaike info criterion : 1107.63
 S.E of regression : 2.88703 Schwarz criterion : 1117.8

Variable	Coefficient	Std. Error	z-value	Probability
CONSTANT	21.6537	2.72447	7.94788	0.00000
VZD	-0.164181	0.0297896	-5.51135	0.00000
HDP	-3.28898e-005	2.03345e-005	-1.61744	0.10578
LAMBDA	0.874072	0.0449481	19.4462	0.00000

REGRESSION DIAGNOSTICS

DIAGNOSTICS FOR HETEROSKEDASTICITY

RANDOM COEFFICIENTS

TEST	DF	VALUE	PROB
Breusch-Pagan test	2	107.1646	0.00000

DIAGNOSTICS FOR SPATIAL DEPENDENCE

SPATIAL ERROR DEPENDENCE FOR WEIGHT MATRIX : vzdialenost2

TEST	DF	VALUE	PROB
Likelihood Ratio Test	1	64.3135	0.00000

===== END OF REPORT =====

Zdroj: výstup z programu GeoDa