

EKONOMICKÁ UNIVERZITA V BRATISLAVE
FAKULTA HOSPODÁRSKEJ INFORMATIKY

103003/I/2021/421000285118

PRIESTOROVÁ ANALÝZA VZDELANIA
VO VYBRANÝCH EURÓPSKÝCH REGIÓNOCH

Diplomová práca

2021

Bc. Barbora Šebová

EKONOMICKÁ UNIVERZITA V BRATISLAVE
FAKULTA HOSPODÁRSKEJ INFORMATIKY

PRIESTOROVÁ ANALÝZA VZDELANIA VO VYBRANÝCH
EURÓPSKYCH REGIÓNOCH

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 2021

Bc. Barbora Šebová



Ekonomická univerzita v Bratislave
Fakulta hospodárskej informatiky

ZADANIE ZÁVEREČNEJ PRÁCE

Meno a priezvisko študenta: Bc. Barbora Šebová

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: Priestorová analýza vzdelania vo vybraných európskych regiónoch

Anotácia: Predmetom diplomovej práce je analýza vzdelania vo vybraných európskych regiónoch s identifikáciou regionálnych disparít na báze nástrojov priestorovej analýzy dát. Súčasťou práce je tiež konštrukcia priestorových ekonometrických modelov skúmajúcich vplyv vybraných sociálno-ekonomických premenných na analyzovanú premennú "vzdelanie".

Vedúci: doc. Ing. Michaela Chocholatá, PhD.

Katedra: KOVE FHI - Katedra operačného výskumu a ekonometrie FHI

Vedúci katedry: prof. Mgr. Juraj Pekár, PhD.

Dátum zadania: 22.10.2019

Dátum schválenia: 31.10.2019

prof. Mgr. Juraj Pekár, PhD.

vedúci katedry

Čestné vyhlásenie

Vyhlasujem, že predloženú záverečnú prácu som vypracovala samostatne. Všetky použité literárne zdroje som uviedla v zozname použitej literatúry.

V Bratislave 6.mája 2021

.....

podpis študenta (autora)

Pod'akovanie

Touto cestou sa chcem pod'akovať svojej školiteľke doc. Ing. Michaelae Chocholatej, PhD. za odborné vedenie, cenné rady a za jej pedagogické usmernenie pri písaní diplomovej práce.

Abstrakt

ŠEBOVÁ, Barbora: *Priestorová analýza vzdelania vo vybraných európskych regiónoch*. – Ekonomická univerzita v Bratislave. Fakulta hospodárskej informatiky; Katedra operačného výskumu a ekonometrie. – Vedúci záverečnej práce: doc. Ing. Michaela Chocholatá, PhD. – Bratislava: FHI, 2021, 87s.

Vzhľadom na cieľ stratégie Európa 2020 dosiahnuť aspoň 40% populácie vo veku 30-34 rokov absolvujúcich terciárne vzdelanie sa táto práca venuje analýze regionálnych rozdielov v dosiahnutom terciárnom vzdelaní v rámci 251 regiónov NUTS 2 Európskej únie v období rokov 2012 – 2019 za pomoci nástrojov priestorovej analýzy. Taktiež skúmame oneskorený vplyv regionálneho HDP a hustoty zaľudnenia na úroveň dosiahnutého terciárneho vzdelania v roku 2019 pomocou modelov priestorovej ekonometrie. Práca je rozdelená do 4 kapitol. Prvá kapitola zdôrazňuje význam vzdelania, s ktorým je spojená dôležitosť priestorovej interakcie a geografickej polohy, nakoľko jednotlivé regióny EÚ nemožno považovať za izolované. V ďalšej časti umožnila analýza priestorových údajov (ESDA) odhaliť veľké rozdiely medzi analyzovanými regiónmi na národnej aj nadnárodnej úrovni, a taktiež identifikovala niektoré regióny s už dosiahnutým cieľom stratégie Európa 2020, ako aj regióny pod hranicou 40%. Globálna a regionálna Moranova I štatistika navyše umožnila identifikovať priestorové vzorce v analyzovanej oblasti. Na základe výsledkov ekonometrickej analýzy zisťujeme, že úroveň regionálneho HDP a hustoty zaľudnenia má očakávaný pozitívny vplyv na úroveň dosiahnutého terciárneho vzdelania, ako aj nevyhnutnosť začleniť do modelu priestorovú dimenziu.

Kľúčové slová:

Európa 2020, terciárne vzdelanie, úroveň dosiahnutého vzdelania, nerovnosť, priestorová analýza, priestorová ekonometria

Abstract

ŠEBOVÁ, Barbora: *Spatial analysis of the education in the selected European regions*. – University of Economics in Bratislava. Faculty of Economic Informatics; Department of Operations Research and Econometrics. – Supervisor: doc. Ing. Michaela Chocholatá, PhD. – Bratislava: FEI, 2021, 87s.

Considering the goal of the Europe 2020 strategy, to reach a 40% level of tertiary education among the population with age between 30-34, this work focuses on the analysis of regional disparities in tertiary education achievement within 251 NUTS 2 regions of the European Union in the period of years between 2012 - 2019 using spatial analysis tools. We also examine the delayed impact of regional GDP and population density on the level of tertiary education attained in 2019 using spatial econometrics models. The work is divided into 4 chapters. The first chapter emphasizes the importance of education, to which spatial interaction and geographical location is associated, as individual EU regions cannot be considered as isolated. In the next section, the Exploratory Spatial Data Analysis (ESDA) has revealed large differences between the analyzed regions at national and subnational level, and also identified some regions with the Europe 2020 strategy's target already achieved, as well as regions below 40%. In addition, global and regional Moran I statistics made it possible to identify spatial patterns in the analyzed area. Based on the results of the econometric analysis, we detect that the level of regional GDP and population density has the expected positive impact on the level of tertiary education achieved, as well as the need to include a spatial dimension in the model.

Key words:

Europe 2020, tertiary education, education attainment level, disparity, spatial analysis, spatial econometrics

Obsah

Zoznam tabuliek.....	8
Zoznam ilustrácií	9
Zoznam skratiek.....	11
Úvod	12
1 Súčasný stav riešenej problematiky doma a v zahraničí.....	14
1.1 Vymedzenie a funkcia vzdelania	15
1.2 Charakteristika úrovni vzdelania ISCED	18
1.3 Vzdelávací systém na Slovensku.....	19
1.3.1 OECD a agenda rezortu školstva, vedy a výskumu SR	23
1.4 Terciárne vzdelanie v Európe	25
1.4.1 Možnosti terciárneho vzdelania - Univerzity v Európe	29
1.4.2 Terciárne vzdelanie na Slovensku a jeho nedostatky	31
1.5 Hlavné trendy v oblasti vzdelávania.....	37
1.6 Prehľad vybraných výskumných štúdií analyzujúcich vzdelanie.....	39
2 Cieľ práce.....	43
3 Metodika práce a metódy skúmania	44
3.1 Analýza priestorových údajov ESDA.....	44
3.2 Ekonometrická analýza.....	48
4 Výsledky práce.....	52
4.1 Priestorová analýza terciárneho vzdelania	52
4.1.1 Mapovanie terciárneho vzdelania v EÚ.....	55
4.1.2 Priestorová autokorelácia	58
4.2 Regresná analýza	64
4.2.1 Lineárny model OLS.....	65
4.2.2 Priestorový autoregresný model SAR.....	67
4.2.3 Model priestorovej chyby SEM	69
4.2.4 Durbinov priestorový model SDM	70
4.2.5 Váhy kráľovnej verzus euklidovská vzdialenosť	71
4.3 Diskusia	75
Záver	77
Zoznam použitej literatúry	79
Prílohy.....	87

Zoznam tabuliek

Tabuľka 1: Výsledky odhadu lineárneho regresného modelu, modelu SAR, modelu SEM a modelu SDM, váhy: kráľovná.....	72
Tabuľka 2: Výsledky odhadu lineárneho regresného modelu, modelu SAR, modelu SEM a modelu SDM, váhy: euklidovská vzdialenosť.....	74

Zoznam ilustrácií

Obrázok 1: Populácia s vysokoškolským vzdelaním (% , 25-64 rokov, 2003).....	21
Obrázok 2: Podiel populácie 30-34 s VŠ vzdelaním (v % , 2005 a 2016).....	21
Obrázok 3: Verejné výdavky na vzdelávanie (% HDP, 2006 - 2020).....	22
Obrázok 4: Podiel osôb vo veku 30-34 rokov s terciárnym vzdelaním (ISCED úrovne 5-8), podľa regiónov NUTS 2, (% , 2015).....	27
Obrázok 5: Štruktúra populácie 25-34 ročných podľa dosiahnutého terciárneho vzdelávania v SR a krajinách V5 v roku 2016.....	32
Obrázok 6: Pracovné miesta vs. počet ekonomicky aktívnych vysokoškolákov v odboroch – sociálne vedy a inžinierstvo.....	33
Obrázok 7: Podiel ekonomicky aktívnych vysokoškolákov 25-30 rokov, OECD, 2016.....	35
Obrázok 8: Vysokoškolské pracovné miesta a absolventi technických odborov.....	36
Obrázok 9: Definovanie susedstiev.....	45
Obrázok 10: Moranov bodový diagram.....	47
Obrázok 11: Prístup zdola-nahor (bottom-up).....	48
Obrázok 12: Škatuľový graf pre dosiahnuté terciárne vzdelanie (v %), veková skupina 30-34 rokov, 2012 - 2019.....	52
Obrázok 13: Dosiahnuté terciárne vzdelanie (v % , veková skupina 30-34 rokov) v členských štátoch EÚ-26, 2012 - 2019.....	53
Obrázok 14: Dosiahnuté nižšie ako základné, základné a nižšie stredoškolské vzdelávanie (v % , veková skupina 30-34 rokov) v členských štátoch EÚ-26, 2012 - 2019.....	54
Obrázok 15: Kvantilová mapa dosiahnutého terciárneho vzdelania (v % , veková skupina 30-34 rokov), 2012	55
Obrázok 16: Kvantilová mapa dosiahnutého terciárneho vzdelania (v % , veková skupina 30-34 rokov), 2019	56
Obrázok 17: Škatuľová mapa pre uvažovanú úroveň dosiahnutého vzdelania v roku 2012.....	57
Obrázok 18: Škatuľová mapa pre uvažovanú úroveň dosiahnutého vzdelania v roku 2019.....	57
Obrázok 19: Histogram matice typu „kráľovná“.....	58

Obrázok 20: Histogram matice typu „euklidovská vzdialenosť“.....	59
Obrázok 21: Dynamika globálneho Moranovho I v rokoch 2012 - 2019 pre rôzne špecifikácie váhových matíc.....	60
Obrázok 22: Moranov bodový diagram pre maticu váh typu kráľovná v roku 2019.....	61
Obrázok 23: Klastrové mapy LISA dosiahnutého vzdelania pre maticu váh typu kráľovná v rokoch 2012 a 2019.....	61
Obrázok 24: Klastrové mapy LISA dosiahnutého vzdelania pre maticu váh typu 4 najbližší susedia v rokoch 2012 a 2019.....	62
Obrázok 25: Klastrové mapy LISA dosiahnutého vzdelania pre váhovú maticu euklidovskej vzdialenosti v rokoch 2012 a 2019.....	63
Obrázok 26: Odhad lineárneho modelu OLS – štatistické ukazovatele.....	66
Obrázok 27: Odhad lineárneho modelu OLS – charakteristiky priestorovej závislosti.....	67
Obrázok 28: Odhad modelu SAR.....	68
Obrázok 29: Odhad modelu SEM.....	69
Obrázok 30: Odhad modelu SDM.....	70

Zoznam skratiek

EÚ	Európska únia
NUTS	Nomenklatúra jednotiek pre územnú štatistiku
HH	Vysoký-vysoký
LL	Nízky-nízky
LH	Nízky-vysoký
HL	Vysoký-nízky
OLS	Metóda najmenších štvorcov
SAR	Priestorový autoregresný model
SEM	Model priestorovej chyby
SDM	Durbinov priestorový model
LM	Lagrangeove multiplikátory
ML	Metóda maximálnej vierohodnosti
ESDA	Prieskumná analýza priestorových údajov (Exploratory spatial data analysis)
HDP	Hrubý domáci produkt
ISCED	Medzinárodná klasifikácia štandardov vzdelávania
OECD	Organizácia pre hospodársku spoluprácu a rozvoj
STEM	Veda, technológie, inžinierstvo a matematika
RÚZ	Republiková únia zamestnávateľov
V5	Krajiny Vyšehradskej skupiny (vrátane Ukrajiny)
PIAAC	Program medzinárodného hodnotenia dospelých
TALIS	Medzinárodná štúdia o vyučovaní a vzdelávaní
PISA	Program medzinárodného hodnotenia žiakov
EHEA	Európsky priestor vysokoškolského vzdelávania
SR	Slovenská republika

Úvod

Jednou z priorít stratégie Európa 2020 bol inteligentný rast, ktorý znamená rozvoj hospodárstva založeného na znalostiach a inováciách. Otázka vzdelania tak zohrávala jednu z kľúčových úloh v stratégii Európa 2020 s cieľom zvýšiť podiel ľudí s vysokoškolským vzdelaním. Päť cieľov Európskej únie na rok 2020 sa zameriavalo na zamestnanosť, výskum a inovácie, zmenu podnebia a energie, vzdelávanie a boj proti chudobe. Je zrejmé, že všetky tieto ciele navzájom súvisia (Chocholatá a Furková, 2017). Jadrom intelektuálneho kapitálu sú však vedomosti. Dôležitý je rozvoj a prenos vedomostí prostredníctvom vysokoškolského vzdelávania, ktoré zohráva dôležitú úlohu pri pomoci ľuďom vyrovnáť sa s neustálymi zmenami. Je však zrejmé, že vysokoškolské vzdelanie je do veľkej miery ovplyvnené hustotou zaľudnenia, nakoľko krajiny s veľkým počtom obyvateľov na 1 km² majú aj vysoký podiel detí v školskom veku a čelia väčšiemu dopytu po vzdelávacích službách. Vysoká hustota obyvateľstva preto môže zefektívniť podporu širšieho spektra možností špecializovaného vzdelávania a odbornej prípravy. Je potrebné tiež pripomenúť, že miera uplatniteľnosti dospelých s terciárnym vzdelaním je vyššia, ako pri tých, ktorí majú najvyššie ukončené stredoškolské vzdelanie. Vysokoškolsky vzdelaní ľudia tiež disponujú ďalšími výhodami, ako napríklad vyšší zárobok, ich zdravotný stav je lepší, viac sa zúčastňujú na verejnom živote. Tieto výhody sa však môžu líšiť v závislosti od veku, pohlavia, úrovne terciárneho vzdelania a študijného odboru. Uvedené výhody naznačujú, že jednotlivci by mali mať motiváciu k vyššiemu vzdelaniu a tiež vlády majú motiváciu podporovať svojich občanov v snahe dosiahnuť takéto vzdelanie.

Pokiaľ však ide o základné sociálno-ekonomické ukazovatele (napr. HDP na obyvateľa, vzdelanostná úroveň, migrácia, miera nezamestnanosti), v rámci regiónov EÚ je možné identifikovať pomerne veľké regionálne rozdiely. Nakoľko regióny jednotlivých členských štátov EÚ sú navzájom prepojené a nemožno ich považovať za izolované, priestorový aspekt sa javí ako významný faktor k hlbšej analýze. Stojí za zmienku, že v tejto súvislosti sú veľmi populárne rôzne nástroje zaoberajúce sa problémami konvergenzie. Vhodnými nástrojmi pre takúto analýzu je priestorová analýza a priestorová ekonometria. Napriek tomu, že pojem „priestorová ekonometria“ bol prvýkrát použitý v 70. rokoch 20. storočia a niektoré techniky boli popísané už v polovici minulého storočia, ich použitie sa začalo na prelome nového tisícročia (Arbia, 2006). Priestorová ekonometria vznikla s motiváciou zohľadňovať priestorovú závislosť, asymetriu vo vzťahoch, vzájomné ovplyvňovanie sa a interakciu, kritické aspekty dát používaných v regionálnom

modelovaní. V súčasnosti už existujú rôzne geografické informačné systémy (GIS) a špeciálne softvéry, ktoré umožňujú vykonávať priestorovú analýzu a odhadovať priestorové ekonometrické modely.

Námetom skúmanej problematiky bol príspevok Chocholatej (2018) na medzinárodnej vedeckej konferencii o efektívnosti a zodpovednosti vo vzdelávaní (ERIE), ktorý pojednáva o stratégii Európa 2020. Jedným z cieľov stratégie Európa 2020 je dosiahnuť aspoň 40% podiel obyvateľstva vo veku 30–34 rokov absolvujúcich terciárne vzdelávanie. Autorka v tomto príspevku analyzuje regionálne rozdiely v dosiahnutom terciárnom vzdelaní v 251 regiónoch NUTS 2 v Európskej únii v období rokov 2010–2016 pomocou nástrojov priestorovej analýzy. Pretože jednotlivé regióny EÚ nepôsobia ako samostatné subjekty, dokument zdôrazňuje dôležitosť priestorovej interakcie a geografickej polohy. Prieskumná analýza priestorových údajov (ESDA) umožnila odhaliť veľké rozdiely medzi analyzovanými regiónmi na národnej aj nadnárodnej úrovni, čo naznačuje niektoré regióny s už dosiahnutým cieľom, ako aj regióny pod hranicou 40%. Globálne a regionálne Moranove I štatistiky umožnili identifikovať priestorové vzorce v analyzovanej oblasti, ako aj existenciu a pretrvávajúce regionálnych rozdielov.

Cieľ predkladanej diplomovej práce je dvojaký. Jednak sa sústreďuje na hodnotenie pretrvávania regionálnych rozdielov medzi regiónmi EÚ v úrovni dosiahnutého terciárneho vzdelania obyvateľov vo veku 30–34 rokov na základe priestorovej analýzy v 251 regiónoch NUTS 2 krajín Európskej únie v období rokov 2012 – 2019. Druhým, nie menej podstatným cieľom je analyzovanie vplyvu oneskoreného regionálneho HDP a hustoty zaľudnenia na úroveň dosiahnutého vzdelania v roku 2019, na základe odhadovaných priestorových ekonometrických modelov. Využitie priestorovej analýzy umožňuje zachytiť a pochopiť dynamiku vývoja úrovne dosiahnutého terciárneho vzdelania v regiónoch EÚ v analyzovanom období rokov 2012 - 2019, ako aj vyhodnotiť pretrvávajúce regionálnych rozdielov.

V prvej časti práce popisujeme sociálno-ekonomické súvislosti odrážajúce vzdelanie v skúmaných regiónoch Európskej únie a tiež stav poznanej problematiky. Druhá kapitola zahŕňa ciele práce, jej hypotézu, hlavné a vedľajšie výskumné otázky. Následne tretia kapitola popisuje použitú metodiku a metódy skúmania problematiky priestorovej ekonometrie, použité modely a dátovú štruktúru. V poslednej, štvrtej kapitole sú zhrnuté výsledky analýz a diskusia k danej téme, kde porovnávame dosiahnuté výstupy s výsledkami iných autorov zaoberajúcimi sa podobnou otázkou. V závere zhŕňame hlavnú podstatu a dôležité zistenia diplomovej práce.

1 Súčasný stav riešenej problematiky doma a v zahraničí

Vzdelanie má v dnešnej spoločnosti neopomenuteľný význam a je naň kladený veľký dôraz. S postupným ekonomickým a sociálnym rozvojom krajín po druhej svetovej vojne sa pozornosť vládnych politík uprela na základné princípy v spoločnosti: ekonomickú prosperitu, sociálne istoty a životné príležitosti. Ekonomický vývoj v spoločnosti ovplyvňoval dopyt po kvalitnej pracovnej sile s vyšším vzdelaním v oblasti ľudských zdrojov. Na druhú stranu ekonomický rast ovplyvnil zvyšujúcu sa spotrebu obyvateľov a životný štýl ľudí, ktorý sa počas niekoľkých rokov výrazne zmenil (Čerych, 1999). V dnešnej rozvíjajúcej sa modernej spoločnosti s mnohými novými hospodárskymi odvetvami je preto nesmierne dôležité vzdelanie ľudí, aby dokázali obstať na vysoko konkurenčnom celosvetovom trhu práce. Práve vzdelanie je považované za prostriedok, ktorým možno dosiahnuť ekonomickú prosperitu a zároveň i sociálnu spravodlivosť. Vzdelanie možno považovať za efektívnu investíciu, ktorá sa človeku v budúcnosti vráti v podobe perspektívneho zamestnania a kvalitnejšej životnej úrovne.

Podľa OECD360 (2015) získali ľudia vo veku 25 až 34 rokov príležitosť dosiahnuť vyššiu úroveň vzdelania ako ich rodičia vďaka rozšíreniu vzdelávacích systémov na úrovni vyššieho sekundárneho alebo postsekundárneho neterciárneho a terciárneho vzdelávania v mnohých krajinách OECD (Organizácia pre hospodársku spoluprácu a rozvoj). V krajinách OECD, ktoré sa zúčastnili Prieskumu zručností dospelých 2012 (produkt programu medzinárodného hodnotenia schopností dospelých OECD – PIAAC), v priemere 32 % mladých ľudí dosiahlo vyššiu úroveň vzdelania ako ich rodičia, zatiaľ čo iba 16 % nedosiahlo úroveň vzdelania svojich rodičov. Rozširovanie vzdelávania bolo obzvlášť zreteľné vo Francúzsku, Írsku, Taliansku, Kórei, Španielsku a v Ruskej federácii, kde rozdiel medzi stúpajúcou a klesajúcou mobilitou v oblasti vzdelávania predstavuje 30 percentuálnych bodov alebo viac.

„Vysokoškolské vzdelanie dosiahlo takmer 40 % súčasných dospelých vo veku 25 až 34 rokov, čo je o 15 percentuálnych bodov vyšší podiel ako v kategórii dospelých vo veku 55 až 64 rokov. V súčasnosti sa vo väčšine krajín OECD vzdelávanie väčšiny detí začína skôr, než dosiahnu vek 5 rokov. Viac ako tri štvrtiny 4-ročných detí (84 %) v krajinách OECD sa zúčastňujú predškolských vzdelávacích programov a programov primárneho vzdelávania; v krajinách OECD, ktoré sú zároveň súčasťou Európskej únie, je to až 89 % všetkých 4-ročných detí. Približne 72 % študentov v krajinách OECD, ktorí nastúpia do inštitúcií vyššieho stredoškolského vzdelávania, dokončí štúdium v rámci predpokladaného obdobia študijného programu. V roku 2012 sa vzdelávacieho procesu v krajinách OECD

zúčastňovalo v priemere 49 % mladých ľudí vo veku 15 až 29 rokov. 36 % zo zostávajúcich 51 % malo prácu, 7 % bolo nezamestnaných a 8 % nepracujúcich“ (OECD360, 2015, s.38).

Vysokoškolské inštitúcie a v menšej miere aj inštitúcie predškolského vzdelávania získavajú najväčšie podiely finančných prostriedkov zo súkromných zdrojov. Verejné financovanie vzdelávacích inštitúcií, súhrnne za všetky úrovne vzdelávania, sa v období od roku 2000 do roku 2011 zvýšilo vo všetkých krajinách (s výnimkou Talianska). Vzhľadom na vyšší počet domácností, ktoré sa podieľajú na nákladoch na vzdelávanie, však súkromné financovanie narástlo ešte výraznejšie vo viac ako troch štvrtinách krajín. Zatiaľ čo v dvoch tretinách krajín sa podiel verejných výdavkov určených na vzdelávanie v období od roku 2005 do roku 2011 znížil, počas kratšieho obdobia 2008 až 2011, keď hospodárska kríza vrcholila, rástli verejné výdavky na vzdelávanie rýchlejšie (resp. klesali pomalšie) ako verejné výdavky na všetky ostatné sektory služieb v 16 z 31 krajín s dostupnými údajmi (OECD360, 2015).

OECD360 (2015) tiež zdôrazňuje, že len v štyroch z 35 krajín s dostupnými údajmi sa od učiteľov v predškolských zariadeniach vyžaduje magisterský titul, zatiaľ čo v prípade učiteľov všeobecných predmetov na úrovni vyššieho stredoškolského vzdelávania sa vyžaduje v 22 z 36 krajín s dostupnými údajmi. „Profesionálny vývoj je v prípade učiteľov povinný na všetkých úrovniach vzdelávania v približne troch štvrtinách krajín OECD a partnerských krajín s dostupnými údajmi. Zatiaľ čo v 17 krajinách sa profesionálny vývoj vyžaduje od všetkých učiteľov na úrovni nižšieho stredoškolského vzdelávania a v 8 krajinách sa vyžaduje v súvislosti s možnosťou povýšenia alebo zvýšenia mzdy, v 6 krajinách sa nevyžaduje vôbec. V roku 2012 bolo viac ako 4,5 milióna študentov zapísaných na vysokoškolské štúdium mimo krajiny svojho občianstva. Austrália, Rakúsko, Luxembursko, Nový Zéland, Švajčiarsko a Veľká Británia mali najvyšší percentuálny podiel zahraničných študentov z celkového počtu zapísaných vysokoškolských študentov“ (OECD360, 2015, s.38).

1.1 Vymedzenie a funkcia vzdelania

Všeobecne sa vzdelanie charakterizuje ako "sústava vedeckých a technických vedomostí, intelektuálnych a praktických zručností vrátane utvárania morálnych rysov a záujmov, ktoré je výsledkom procesu vzdelávania." (Tvrдый, 2007, s.8)

Krebs (2007) chápe vzdelanie ako výsledok dvoch vzájomne prepojených procesov - výchovy a vzdelávania. Výchova je dôležitá pre človeka najmä z toho dôvodu, že rozvíja

kultúrne a občianske kvality človeka, ktoré potom majú vplyv na celú spoločnosť. Vzdelávanie vníma ako proces, kde si ľudia osvojujú poznatky a zručnosti, ktoré potom vedú človeka k poznaniu a všeobecnej kultivácii. Krebs hovorí o vzdelaní ako o klasickom príklade nehmotného tovaru. Palán (2002) upozorňuje na to, že vzdelanie je výsledkom procesov, ktoré sú zamerané na utváranie osobnosti. Vzdelanie chápe ako sústavu vedeckých a technických vedomostí, intelektuálnych a praktických zručností, utvorenie morálnych rysov a osobitých záujmov. Dewey (1998) vníma vzdelanie ako súbor informácií a schopností, ktoré boli vypracované v minulosti a je potrebné ich ďalej odovzdať novým generáciám. Vzdelanie je podľa neho procesom rozvoja zvnútra človeka. Vzdelanie rozlišuje na tradičné a progresívne. Za hlavný cieľ tradičného vzdelania považuje prípravu mladých ľudí na budúce zodpovednosti a úspechy v ich živote. Progresívne vzdelanie predstavuje kritiku tradičného vzdelania. V súvislosti s progresívnym vzdelaním upozorňuje na existujúce normy a metódy, ku ktorým by sa mali mladí ľudia priblížiť.

Prečo vlastne ľudia študujú, je otázka, ktorú si kladú Keller a Tvrďý (2010). Podľa nich ľudia študujú z toho dôvodu, že vo vzdelaní vidia výhodnú investíciu a v pracovnom uplatnení vidia v prvom rade príležitosť, ako túto dlhodobú investíciu finančne čo najvýnosnejšie zúročia. Motiváciou k vzdelaniu ale nemusí byť iba finančný prínos, ľudia môžu študovať aj na základe tradície, pretože už ich rodičia študovali alebo preto, že chcú získať vzdelanie v odbore, ktorý ich zaujíma a ktorému sa chcú ďalej venovať.

Odborná literatúra vymedzuje štyri základné funkcie vzdelania, ktoré popisuje Krebs (2007). Jedná sa o funkciu preventívnu, poučnú, ekonomickú a sociálno-kultúrnu. Preventívna funkcia vzdelania je chápaná ako prevencia k nájdeniu si budúceho povolania a k uplatneniu ďalších rolí v spoločnosti, predovšetkým v rodine, obci a pod. Za poučnú funkciu vzdelania je považované vzdelanie "ex post", kedy so vzdelaním začneme až po uskutočnení určitej udalosti. Na ekonomickú funkciu vzdelania sa nahliada ako na výrobný faktor, pretože nám umožňuje získať nové vedomosti, zručnosti a kvalifikáciu. Vzdelanie umožňuje získať ekonomický profit a vyššiu rast produktivity práce. Sociálno-kultúrnu funkciu vzdelania je veľmi ťažké vymedziť, pretože vzdelanie ovplyvňuje veľa vlastností a hodnôt každého človeka, ako je napríklad tolerancia alebo komunikácia a úcta k druhým. Sociálno-kultúrnu funkciu vzdelania možno chápať aj ako takú, ktorá formuje vzťah ľudí k spotrebe, spolu vytvára diferenciáciu v príjmoch aj v životnej úrovni obyvateľstva.

Vzdelanie teda plní mnoho funkcií, ktoré sú významné pre človeka i celú spoločnosť. Dosiahnutá úroveň vzdelania jednak pomáha pri uplatnení sa na trhu práce, pozitívne

ovplyvňuje mieru nezamestnanosti, má ale tiež vplyv na kvalitu života obyvateľstva. Vyššia úroveň vzdelania totiž môže prispievať k zdravému životnému štýlu, k spokojnosti človeka, k formovaniu si vlastných názorov, k rozvoju osobnosti či k osobnej samostatnosti a nezávislosti (Mertl a Výchová, 2009). Nemožno zabudnúť ani finančnú stránku vzdelaného obyvateľstva, kedy ľudia s vyšším dosiahnutým vzdelaním majú lepšiu možnosť uplatniť sa na trhu práce. O úzkom vzťahu medzi dosiahnutým vzdelaním a príjmami tiež hovorí Mertl a Výchová (2009). Upozorňujú na to, že vyššie príjmy nutne nemusia ľudia poberať iba na základe najvyššieho dosiahnutého vzdelania. Existuje aj veľa ďalších faktorov, ktoré k získaniu vysokých príjmov prispievajú. Môžu to byť napríklad schopnosti, ktoré má človek vrodené, ako napríklad zdravé sebavedomie a prezentovanie sa, ale aj rozdiely v ponuke vzdelávacích odborov alebo prekážky brániace vstupu do ponúkaných vzdelávacích odborov. Práve vzdelávacích odborov existuje v súčasnej dobe široké spektrum a ľudia teda majú možnosť si na základe vlastných preferencií z týchto odborov vybrať.

Údaje o mzdách takisto poukazujú na prehĺbovanie rozdielov medzi tými, ktorí vzdelanie majú, a tými, ktorí ho nemajú. „V krajinách OECD zarábajú dospelí s ukončeným vysokoškolským vzdelaním v priemere o približne 70 % viac ako dospelí s vyšším stredoškolským vzdelaním. Rozdielna úroveň zručností má tiež vplyv na mzdu, a to dokonca aj medzi ľuďmi s rovnakou úrovňou dosiahnutého vzdelania: podľa údajov zaznamenaných počas prieskumu zručností dospelých zarába vysokoškolsky vzdelaný dospelý, ktorý dosahuje najvyššiu úroveň schopnosti spracovávať textové informácie, v priemere o približne 45 % viac ako dospelý s podobným vzdelaním, ktorý dosahuje najnižšiu úroveň schopnosti spracovávať textové informácie“ (OECD360, 2015, s.35).

OECD360 (2015) uvádza, že vzdelanie je nevyhnutne dôležité aj z ekonomického hľadiska. Mnohé medzinárodné štúdie ukazujú, že vyššia úroveň dosiahnutého vzdelania pozitívne ovplyvňuje dobu, po ktorú je človek počas produktívneho veku zamestnaný. V čase globálnej ekonomickej krízy stratilo zamestnanie v krajinách OECD oveľa viac obyvateľov s dosiahnutým stredným vzdelaním než ľudia so vzdelaním vysokoškolským. Je teda zrejmé, že dosiahnutá úroveň vzdelania ovplyvňuje hospodársky a sociálny rozvoj daných štátov. V roku 2012 bola miera nezamestnanosti vysokoškolsky vzdelaných obyvateľov krajín OECD v kategórii dospelých vo veku 25 až 34 rokov v priemere 7,4%, kdežto miera nezamestnanosti dospelých vo veku 25 až 34 rokov bez vyššieho stredoškolského vzdelania dosiahla v roku 2012 v priemere hodnotu 19,8 % (v mnohých krajinách dokonca vyššiu), čo predstavuje zvýšenie oproti 13,6 % v roku 2008.

Vzdelanie pôsobí pozitívne aj na vyrovnanie sa s budúcimi zmenami v spoločnosti, predovšetkým s tými, ku ktorým v posledných rokoch najviac dochádza, konkrétne technologické zmeny a vedecko-technologický pokrok. Vzdelanie tým, že napomáha človeku samostatne myslieť, sa stáva dôležitým komponentom pre rozvoj spoločnosti jednotlivých zemí (Krebs, 2007).

Vzdelaní občania sa lepšie dokážu orientovať v dnešnom chaotickom a zložitom svete. Vzdelaní ľudia môžu mať určitú výhodu z hľadiska spokojnosti v živote, vzdelanie je pre nich hodnotou samo o sebe. Vzdelanie sa považuje za veľmi dôležité aj v súvislosti s tým, že vzdelaní ľudia môžu mať lepšiu pracovnú pozíciu, nie sú nároční na sociálne dávky a nezaťažujú tak štátne výdavky (Čerych, 1999).

1.2 Charakteristika úrovni vzdelania ISCED

Medzinárodná klasifikácia štandardov vzdelávania (ISCED) patrí do medzinárodnej rodiny ekonomických a sociálnych klasifikácií Spojených národov, ktoré sa aplikujú v celosvetovej štatistike s cieľom zostavovať, zhromažďovať a analyzovať medzinárodne porovnateľné údaje. ISCED je referenčná klasifikácia pre organizovanie vzdelávacích programov a príslušných kvalifikácií podľa úrovni vzdelávania a odborov (MŠVVaŠ SR, 2018). ISCED je produktom medzinárodného odsúhlasenia od začiatku 70-tych rokov minulého storočia a je prijatá členskými štátmi formálne na Generálnej konferencii UNESCO. V súčasnosti platná klasifikácia ISCED 1997, bola schválená 29. zasadaním Generálnej konferencie UNESCO v novembri 1997. Revidovaná klasifikácia ISCED 2011, ktorá bola prijatá na 36. zasadnutí Generálnej konferencie UNESCO v novembri 2011, sa prijatím nariadenia komisie EÚ č. 317/2013 stáva od 1.1.2014 záväznou normou pre členské štáty a inštitúcie Únie v oblasti klasifikácie vzdelania. Klasifikácia ISCED 97 je rozdelená do siedmich kategórií podľa úrovni vzdelania na ISCED 0 - ISCED 6. Každá kategória je pridelená úroveň vzdelania nasledovne (Kobela, 2013):

ISCED 0 - Predškolské vzdelávanie

ISCED 1 - Primárne vzdelávanie alebo prvý stupeň základného vzdelávania

ISCED 2 - Nižšie stredné vzdelávanie alebo druhý stupeň základného vzdelávania

ISCED 3 - Stredné vzdelávanie

ISCED 4 - Pomaturitné neterciárne vzdelávanie

ISCED 5 - Prvý stupeň terciárneho vzdelávania

ISCED 6 - Druhý stupeň terciárneho vzdelávania

Klasifikácia ISCED 2011 je pozmenená na nasledovné kategórie dosiahnutej úrovne vzdelania (Kobela, 2013):

ISCED 0 – vzdelávanie pre najmenšie deti

ISCED 1 – primárne vzdelávanie

ISCED 2 – nižšie sekundárne vzdelávanie

ISCED 3 – vyššie sekundárne vzdelávanie

ISCED 4 – postsekundárne neterciárne vzdelávanie

ISCED 5 – vyššie odborné vzdelávanie

ISCED 6 – bakalárska úroveň vzdelávania

ISCED 7 – magisterská úroveň vzdelávania

ISCED 8 – doktorandská úroveň vzdelávania

Podľa Ministerstva školstva, vedy, výskumu a športu Slovenskej republiky (MŠVVaŠ SR, 2018) vysoké školy v Slovenskej republike môžu poskytovať vysokoškolské vzdelanie iba v študijných odboroch uvedených v Sústave študijných odborov Slovenskej republiky. Základnou jednotkou klasifikácie v ISCED je vzdelávací program. Vzdelávacie programy a príslušné kvalifikácie v rámci úrovni ISCED 2011 sú rozlíšené do štyroch podkategórií (Kobela, 2013):

1. bez ukončenia úrovne bez priameho prístupu k vyššej úrovni ISCED,
2. čiastočné ukončenie úrovne bez priameho prístupu k vyššej úrovni ISCED,
3. ukončenie úrovne bez priameho prístupu k vyššej úrovni ISCED,
4. ukončenie úrovne s priamym prístupom k vyššej úrovni ISCED.

1.3 Vzdelávací systém na Slovensku

Počiatky organizovaného vzdelávania na území Slovenska sú spojené s príchodom vierozvestcov Konštantína a Metoda do Veľkomoravskej ríše v 9. storočí, ďalej formované Máriou Teréziou a jej školskými reformami v 18. storočí, pričom významným aktom vo vývoji školstva na Slovensku bolo poštátne školenie v roku 1944, založené na princípe monopolu jednej strany, spoločného vlastníctva s výlučnou orientáciou na sovietske modely vytvárania jednotlivých oblastí hospodárskeho a spoločenského života, ktorý s niekoľkými pokusmi o revíziu systému pretrval štyridsať rokov. V novembri 1989 v Československu padol komunistický režim a celá spoločnosť vrátane školstva nastúpila na proces transformácie. Princípy demokratizácie a humanizácie vytvorili vhodné východiská

pre diferenciáciu a decentralizáciu výchovno-vzdelávacej sústavy, vytváranie nového obsahu výchovy a vzdelávania zodpovedajúceho potrebám konca 20. storočia (Európska komisia, 2020).

„Vzdelanostnú úroveň obyvateľstva môžeme zjednodušene rozdeliť na dve časti – predvysokoškolské a vysokoškolské vzdelanie. Slovenská populácia dosahovala po roku 1989 veľmi vysokú úroveň stredoškolského vzdelania. Až 87 % malo v tomto roku ukončenú strednú školu, čo je ďaleko viac ako v okolitých štátoch (konkurovala iba Česká republika s 87 %) a takisto nad priemerom krajín OECD so 66 %. Podobne je to aj so základným vzdelaním, respektíve gramotnosťou, ktorá je základným predpokladom integrácie do spoločnosti“ (Kišš a Šiškovič, 2006, s.29).

Pre ekonomiku na našom stupni rozvoja boli maturanti dôležití, ale pre budovanie znalostnej ekonomiky sú podstatne kľúčovejší vysokoškolsky vzdelaní ľudia, nakoľko je známe, že vysokoškooláci sa v najväčšej miere podieľajú na raste miezd obyvateľstva. Slovenské vysoké školstvo bolo vzhľadom na veľkosť a populáciu Slovenska v minulosti budované na princípoch špecializácie vysokých škôl. Vzhľadom na nízky počet vysokoškolských študentov sa vysokoškolské vzdelanie v mnohých oblastiach dalo získať iba na jednej alebo na malom počte vysokých škôl. Masifikácia vysokoškolského vzdelávania, ktorá na Slovensku nastúpila oneskorene – až v súvislosti so spoločenskými zmenami priniesla po roku 1989 zmenu štruktúry vysokých škôl. Mnohé existujúce vysoké školy zaznamenali dynamický kvantitatívny a časom aj kvalitatívny rozvoj a boli založené nové štátne (verejné), ako aj súkromné vysoké školy (Burjan a kol., 2017).

Podľa Kišša a Šiškoviča (2006) sa počet vysokoškolákov okrem roku 1991 zvyšoval pomerne solídny tempom. Kým v roku 1989 navštevovalo vysokú školu 58 862 študentov, v roku 2004 ich bolo už 163 075, čo predstavuje nárast o 177 %. Keďže sme ešte stále mali výrazne nižší podiel vysokoškolsky vzdelanej populácie ako v najvyspelejších krajinách, je zrejmé, že počas socialistického režimu ukončilo vysokú školu menej študentov. Vtedajšia hospodárska politika ani štruktúra zamestnanosti nevyžadovali posilnenie najvyššieho stupňa vzdelania. Aj keď sa presadzovala politika plnej zamestnanosti, teda každý mal prácu, dôraz sa vôbec nekládol na sofistikovanosť pracovníkov, ktorá je najvyššia práve u vysokoškolsky vzdelaných ľudí.


Oproti najvyspelejším krajinám bolo na Slovensku stále relatívne málo vysokoškolsky vzdelaných ľudí. Kým v krajinách OECD malo 24 % populácie ukončenú vysokú školu, u nás to bolo iba 12 %, pričom podobne na tom boli aj okolité krajiny v Európe (Obrázok 1). Vzhľadom na pozitívny vývoj v uplynulých rokoch sa očakával nárast vysokoškolských

absolventov, keď súčasní vysokoškoláci vyjdú zo školských lavíc. Tento trend bol iba nepatrne oslabovaný narastajúcim priemerným vekom obyvateľstva (Kišš a Šiškovič, 2006).

Slovensko	12	Maďarsko	15
Česká republika	12	Nemecko	24
Poľsko	14	USA	38
Rakúsko	15	Priemer OECD	24

Obrázok 1: Populácia s vysokoškolským vzdelaním (% , 25-64 rokov, 2003) (zdroj: Kišš a Šiškovič, 2006)

Na prelome 20. a 21. storočia stav síce hovoril stále v náš neprospech, ale v uplynulých rokoch bolo badať na Slovensku výrazný nárast vzdelanostnej úrovne (Obrázok 2). „Podiel vysokoškolsky vzdelaného obyvateľstva na Slovensku je oproti krajinám OECD stále nízky, medzi 30-34 ročnými sa však za posledných 10 rokov zdvojnásobil“ (MFSR, 2017, s.18).




Obrázok 2: Podiel populácie 30-34 s VŠ vzdelaním (v %, 2005 a 2016) (zdroj: MFSR, 2017)

Školstvo patrí medzi najvýznamnejšie verejné služby, ktorého stav do značnej miery determinuje ekonomický rast a životnú úroveň obyvateľstva. Najvýznamnejším dlhodobým ukazovateľom pre hodnotenie jeho relatívneho významu pre spoločnosť je objem peňazí určených na jeho financovanie, ktorého relatívne vyjadrenie, teda k hrubému domácomu produktu (HDP) na obyvateľa poskytuje priestor aj pre medzinárodné porovnanie. V oblasti školstva sa analýza zaoberá vzdelanostnou úrovňou obyvateľstva,

kde najpodstatnejšiu časť tvoria vysokoškolsky vzdelaní ľudia (Kišš a Šiškovič, 2006, s.25).

Podľa Kišša a Šiškoviča (2006) výška zdrojov určených na školstvo v absolútnom vyjadrení narastá so zvyšujúcou sa ekonomickou prosperitou krajiny. To isté ale platí aj pri relatívnom vyjadrení, teda ekonomicky najvyspelejšie krajiny dávajú na vzdelávanie v pomere k HDP prípadne na jedného študenta či obyvateľa viac ako menej vyspelé krajiny. Presnejšie povedané, príjmová elasticita na úrovni jednotlivcov v krajinách OECD bola okolo 0,16, teda zo zvýšeného príjmu o 1 % minie človek na školstvo o 0,16 % viac. Elasticita na agregátnej úrovni bola ale vyššia ako 1, čo pri zvýšenej produkcii štátu o 1 % znamená rast výdavkov o viac ako 1 %. Keďže občan neznáša celú časť nákladov na tieto služby, jeho citlivosť na cenu je podstatne nižšia.

Mierne zaostávanie Slovenska vo financovaní školstva je evidentné. Podľa odhadov tvorili výdavky na školstvo v roku 1990 5,8 % HDP, v nasledujúcich rokoch mierne klesli, keď v roku 2001 dosiahli 4,0 %. Od roku 2001 postupne narastali a v roku 2005 už boli na úrovni 4,8 % HDP. Rozdiel medzi krajinami OECD a Slovenskom sa pritom za posledných 20 rokov nijako výrazne nezmenil. Je teda zrejmé, že hospodárska politika jednotlivých vlád od začiatku 90. rokov nevenovala pozornosť zlepšeniu finančnej situácie v školstve, keď finančné prostriedky smerovali do iných oblastí vyžadujúcich akútnejšie riešenie. Keď sa pozrieme len na verejné výdavky na vzdelávanie, Slovensko dávalo v roku 2017 na vzdelávanie 4 % HDP verejných výdavkov, čo je približne o 1 % HDP menej v porovnaní s priemerom EÚ. V uplynulých rokoch sa rozdiel znižoval a v roku 2019 sa predpokladal nárast na 4,2 % HDP s následným poklesom na 4 % HDP (MFSR, 2017).



Obrázok 3: Verejné výdavky na vzdelávanie (% HDP, 2006 - 2020) (zdroj: MFSR, 2017)

„V uplynulých rokoch sa hospodárska politika začala intenzívnejšie zameriavať na budovanie vedomostného potenciálu krajiny – znalostnej ekonomiky, čo reflektovalo aj objem prostriedkov venovaných školstvu. Verejné výdavky narastali rýchlejšie ako HDP, čo sa malo prejaviť vo vyššom podiele výdavkov na HDP. Navyše spolu s klesajúcim počtom žiakov na základných a stredných školách sa zvyšoval aj podiel financií na jedného žiaka“ (Kišš a Šiškovič, 2006, s.29).

V prvej dekáde 21. storočia rástol počet študentov na vysokých školách, a to v priemere len o niečo pomalšie ako objem verejných prostriedkov, aj tu sa preto mal zvyšovať objem prostriedkov v prepočte na jedného študenta. Avšak, nielen na vysokých školách ale aj v celom školskom systéme bolo zámerom vlády presadiť zvýšenie podielu súkromných zdrojov financovania (MFSR, 2017).

1.3.1 OECD a agenda rezortu školstva, vedy a výskumu SR

OECD (Organization for Economic Cooperation and Development) vznikla 30. septembra 1961, pričom nahradila pôvodnú Organizáciu pre európsku ekonomickú spoluprácu, ktorá vznikla v roku 1948 v súvislosti s Marshallovým plánom. Je to medzivládna organizácia združujúca 34 najvyspelejších štátov sveta. Slovensko je členom od 14. decembra 2000. Hlavným cieľom organizácie je podpora dlhodobého udržateľného hospodárskeho rastu, zamestnanosti a zvyšovania životnej úrovne v členských krajinách pri súčasnom zachovaní vnútornej a vonkajšej finančnej rovnováhy, napomáhať aj nečlenským krajinám pri ich hospodárskom rozvoji a prispievať k rastu svetového obchodu. Záujmy SR (Slovenskej republiky) zastupuje Stála misia SR pri OECD. OECD je multisektorovou organizáciou. Slovensko na jej činnosti participuje prostredníctvom zapojenia jednotlivých ministerstiev a ostatných inštitúcií štátnej správy Slovenskej republiky (MH SR, 2021).

„Trvalým úsilím Slovenskej republiky je koncentrovať ťažisko spolupráce s OECD na oblasti relevantné pre formulovanie a realizáciu politík potrebných pre udržateľný a inkluzívny hospodársky rozvoj a zvyšovanie konkurenčnej schopnosti Slovenskej republiky. Konkrétne ide o snahu byť príspevkom pri hľadaní ciest k fiškálnej konsolidácii verejných financií a možnostiam pre vytváranie pracovných príležitostí, podpore budovania znalostnej ekonomiky (systému vzdelávania, zlepšovania podnikateľského prostredia, rozvíjania inovačnej kapacity)“ (MH SR, 2021, s.1).

Slovenská republika sa už ako členská krajina OECD prvýkrát zúčastnila štúdie PISA - Program medzinárodného hodnotenia žiakov (čitateľská, matematická a prírodovedná

gramotnosť 15-ročných žiakov základných a stredných škôl) v roku 2003, keď bola hlavnou sledovanou oblasťou matematická gramotnosť. Cieľom štúdie PISA nie je hodnotiť výkony jednotlivých žiakov alebo škôl, ale sledovať výsledky vzdelávacích systémov zúčastnených krajín, ich zmeny v čase a prinášať námety na zlepšenie vzdelávacej politiky. Slovenská republika tiež participuje na štúdii TALIS - Medzinárodná štúdia o vyučovaní a vzdelávaní (Teaching and Learning International Survey) od jej prvej realizácie v roku 2008. Cieľom je monitorovať pracovné prostredie a podmienky učiteľov a riaditeľov škôl, vplyv vzdelávacej politiky na prácu učiteľov a vyučovanie (napr. hodnotenie práce učiteľov, kvalifikačné požiadavky a pracovné povinnosti učiteľov, metódy vyučovania, postoje učiteľov, a pod.). Základnú výskumnú vzorku tvoria všetky osoby pravidelne a samostatne vyučujúce žiakov 2. stupňa základných škôl a zodpovedajúcich ročníkov osemročných gymnázií, teda nielen učelia. Výskumným nástrojom štúdie TALIS sú dotazníky pre učiteľov a riaditeľov škôl (MŠVVaŠ SR, 2021).

MŠVVaŠ SR (2021) zdôrazňuje tiež významnosť výskumu PIAAC - Program medzinárodného hodnotenia dospelých (Programme for the International Assessment of Adult Competencies). Cieľom tohto výskumu je získať objektívnu spätnú väzbu o úrovni kognitívnych a nekognitívnych zručností majstrov odbornej výchovy, učiteľov všeobecnovzdelávacích alebo odborných predmetov na stredných školách, vysokoškolských pedagógov vo veku do 65 rokov ako aj študentov študujúcich akademické predmety v učiteľských odboroch. SR sa zúčastnila doteraz zrealizovaného historicky 1. cyklu výskumu v období rokov 2008 – 2014 na základe deklarácie o účasti podpísanej ministrom školstva a následne aj v zmysle uznesenia vlády SR.

V roku 2019 sa zapojilo do spoločného projektu MŠVVaŠ SR a OECD - Národná stratégia zručností pre Slovenskú republiku. Cieľom projektu je identifikovať a podporiť medzi-sektorový dialóg, ktorý povedie k efektívnejšiemu nastaveniu odporúčaní na zlepšenie systému zručností SR v 4 oblastiach:

- posilňovanie zručností mladých ľudí vrátane znevýhodnenej populácie,
- znižovanie nesúladu zručností na trhu práce,
- podpora účasti na celoživotnom vzdelávaní,
- posilňovanie zručností na pracovisku.

Finálna stratégia bola verejne predstavená dňa 27. januára 2020 za účasti ministerky školstva a zástupcu generálneho sekretára OECD (MŠVVaŠ SR, 2021).

„V roku 2019 sa tiež konala v spolupráci MŠVVaŠ SR, OECD, organizácie Teach for All a Metodicko – pedagogického centra medzinárodná konferencia pod názvom Európsky učiteľ 21. storočia, ktorej sa zúčastnilo viac ako 300 učiteľov z celého Slovenska. Cieľom konferencie bolo prezentovať inovácie v edukačnom procese a možnosti uplatnenia najlepších zahraničných skúseností v podmienkach slovenských škôl vo viacerých oblastiach. Na konferencii vystúpili analytici OECD a súčasne aj samotný riaditeľ OECD pre oblasť vzdelávania - Andreas Schleicher“ (MŠVVaŠ SR, 2021, s.1).

1.4 Terciárne vzdelanie v Európe

Ako sa trh nekvalifikovanej pracovnej sily znižuje, čoraz viac ľudí si uvedomuje, že ukončené stredoškolské vzdelanie im už nedáva pri hľadaní zamestnania žiadny náskok a väčšina mladých ľudí sa po ukončení strednej školy snaží dosiahnuť vyššiu kvalifikáciu (Marian, 2015). „Hlavné mestá si veľké organizácie (vo verejnom aj súkromnom sektore) často vyberajú za svoje sídla z dôvodov prestíže alebo výhod vyplývajúcich z úspor z rozsahu, ktoré sa im v niektorých najväčších mestách EÚ ponúkajú. Táto relatívne vysoká koncentrácia ekonomickej činnosti (a s ňou súvisiacich pracovných príležitostí) môže, aspoň čiastočne, vysvetliť podstatné množstvo absolventov, ktorí sa sťahujú do regiónov hlavných miest“ (Eurostat, 2017, s.1) .

„Terciárne vzdelávanie je úroveň vzdelávania, ktorú ponúkajú univerzity, odborné vysoké školy, technologické inštitúty a ďalšie inštitúcie udeľujúce akademické tituly alebo diplomy osvedčujúce vyššie odborné vzdelanie. Členské štáty EÚ sú postavené pred štyri veľké výzvy: rozšírenie prístupu k vysokoškolskému vzdelávaniu zvýšením účasti (najmä znevýhodnených skupín); zníženie počtu študentov, ktorí predčasne ukončia terciárne vzdelávanie bez kvalifikácie; skrátenie času, ktorý niektorí jednotlivci potrebujú na dokončenie štúdia; zlepšenie kvality vysokoškolského vzdelávania tým, že sa zvýši relevantnosť študijných odborov pre svet práce“ (Eurostat, 2017, s.1).

Podľa Európskej komisie (2017) má každá krajina svoj vlastný individuálny systém vysokoškolského vzdelávania - všetky sú však súčasťou Európskeho priestoru vysokoškolského vzdelávania (EHEA). Systém EHEA pomáha zabezpečiť kompatibilitu systémov vysokoškolského vzdelávania v celej Európe. Študenti, vedci a akademici v Európe môžu ľahšie spolupracovať, a taktiež študovať alebo pracovať v zahraničí. Kvalifikácie v celej Európe sú porovnateľné prostredníctvom európskeho kvalifikačného rámca. Väčšina študijných programov zahŕňa prednášky a kurzy s hodnotením prostredníctvom esejí, skúšok a kurzov. Mnohé z nich zahŕňajú aj čas strávený prácou v


priemysle alebo prácou na odvetvových projektoch. Väčšina vysokoškolských študijných programov má „modulárnu“ štruktúru. To znamená, že si študent môže vytvoriť osobný program výberom niekoľkých rôznych modulov alebo študijných jednotiek každý rok zo širokej ponuky. V celej Európe je možné nájsť obrovskú škálu vysokoškolských študijných programov - astrofyzika, biotechnológia, obchod, chemické inžinierstvo, geografia, manažment zelenej energie, história, informačné technológie, medzinárodné vzťahy, jazyky, právo, literatúra, medicína, sociológia, učiteľstvo, cestovný ruch, zoológia a oveľa viac.

Eurostat (2017) uvádza, že podiel osôb s dosiahnutým terciárnym vzdelaním sa v krajinách EÚ-28 rýchlo zvyšoval z úrovne 23,6 % v roku 2002, pričom každý rok došlo k nárastu podielu. Do roku 2015 dosiahlo terciárne vzdelanie približne 38,7 % obyvateľov vo veku 30-34 rokov, čo bolo o 0,8 percentuálneho bodu viac ako v roku 2014. Keďže väčšina osôb vo veku 30-34 rokov dosiahne terciárne vzdelanie do veku 30 rokov, tento ukazovateľ sa môže použiť na posúdenie atraktívnosti alebo „efektu príťažlivosti“ regiónov s ohľadom na možnosti absolventov nájsť si zamestnanie. Na nasledujúcom obrázku (Obrázok 4) je zobrazená dosiahnutá úroveň terciárneho vzdelania podľa regiónov NUTS 2 za rok 2015: najtmavším odtieňom oranžovej sú zvýraznené regióny, v ktorých minimálne polovica obyvateľov vo veku 30-34 rokov dosiahla vzdelanie na terciárnej úrovni. Zďaleka najvyšší podiel bol zaznamenaný v jednom z dvoch regiónov hlavného mesta Spojeného kráľovstva, a to v regióne Inner London – West, v ktorom mali viac než štyri pätiny (80,8 %) obyvateľov vo veku 30-34 rokov dosiahnuté terciárne vzdelanie. Druhý, tretí a štvrtý najvyšší podiel bol tiež zaznamenaný v Spojenom kráľovstve, a to konkrétne v týchto regiónoch: Outer London – South (69,3 %), ďalší región hlavného mesta Inner London – East (68,2 %) a North Eastern Scotland (66,1 %). Je potrebné poznamenať, že všetky štyri regióny Škótska zaznamenali podiely na úrovni viac ako 50 %.

„Veľký podiel zostávajúcich regiónov v EÚ s relatívne vysokou úrovňou dosiahnutého terciárneho vzdelania tvorili regióny hlavných miest, a to: Hovedstaden (Dánsko), Southern and Eastern (Írsko), Île de France (Francúzsko), Noord-Holland (Holandsko), Mazowieckie (Poľsko), Helsinki-Uusimaa (Fínsko) a Stockholm (Švédsko), ako aj Cyprus, Litva a Luxembursko. Inde boli regióny s najvyšším podielom osôb vo veku 30-34 rokov, ktoré dosiahli terciárne vzdelanie, často charakterizované ako regióny spojené s výskumom a/alebo technológiami, napríklad: región Brabant Wallon a región Vlaams-Brabant v Belgicku, País Vasco v Španielsku, Rhône-Alpes vo Francúzsku, Utrecht v Holandsku,

Västsverige vo Švédsku alebo Berkshire, Buckinghamshire a Oxfordshire v Spojenom kráľovstve“ (Eurostat, 2017, s.1).

Podiel osôb s dosiahnutým terciárnym vzdelaním, ktorý klesol pod 20 % je zobrazený najsvetlejším odtieňom oranžovej (Obrázok 4). Takýto podiel bol dosiahnutý v ôsmich regiónoch, ktoré sa nachádzali v južných a východných častiach EÚ. V ekonomickej štruktúre je pre ne typická tradičná závislosť od primárnych činností – ťažkého priemyslu (napríklad baníctva alebo hutníctva železa a ocele) alebo poľnohospodárstva. Štyri z ôsmich regiónov sa nachádzali na juhu Talianska (Puglia, Sardegna, Campania a Sicilia), tri na východe Rumunska (Sud-Est, Sud – Muntenia a Nord-Est) a posledným bol región Severozápad na severozápade Českej republiky, v ktorom sa zaznamenal najnižší podiel osôb s dosiahnutým terciárnym vzdelaním, a to na úrovni 15,4 %. Ďalej sa 11 regiónov úrovne 2 nachádzalo v Turecku, kde dosiahla terciárne vzdelanie spomedzi osôb vo veku 30 – 34 rokov menej než jedna osoba z piatich.



Obrázok 4: Podiel osôb vo veku 30-34 rokov s terciárnym vzdelaním (ISCED úrovne 5-8), podľa regiónov NUTS 2, (% , 2015) (zdroj: Eurostat, 2017)

Okrem týchto regiónov bola úroveň dosiahnutého terciárneho vzdelania relatívne nízka aj v mnohých regiónoch Rakúska a Českej republiky. To možno, aspoň čiastočne,

pripísať osobitnému dôrazu kladenému na odborné vzdelávanie v týchto členských štátoch EÚ, keďže sa v nich viac zdôrazňujú odborné kvalifikácie než akademické. Jedným z prekvapení, ktoré je na mape zreteľne viditeľné, sú nemecké regióny Brandenburg, Mecklenburg-Vorpommern a Sasko-Anhaltsko vo východnom Nemecku, kde sú percentuálne podiely mladých ľudí s ukončeným terciárnym vzdelaním výrazne nižšie ako priemer. Tento dosť znepokojujúci trend je pravdepodobne spôsobený migráciou mladých kvalifikovaných pracovníkov do Berlína alebo západonemeckých štátov. Je tiež potrebné poznamenať, že aj keď sa zdá, že Nemecko vo všeobecnosti zaostáva vo vzdelaní za väčšinou ostatných európskych krajín (čo je v rozpore s jeho nízkou mierou nezamestnanosti a veľkým ekonomickým úspechom), rozdiely sú spôsobené relatívne jedinečným rozsiahlym systémom duálneho vzdelávania rozšírený hlavne v Nemecku. Duálne vzdelávanie je systém, v ktorom žiak vyššieho sekundárneho vzdelávania navštevuje špeciálny typ odbornej školy (zvyčajne) 2 dni v týždni a zvyšok týždňa trávi ako učeň v spoločnosti spolupracujúcej so školou. Žiaci tak získajú požadovanú kvalifikáciu priamo, bez toho, aby sa museli zúčastňovať terciárneho vzdelávania. Všeobecne je veľmi bežné, že nemecké spoločnosti ponúkajú potenciálnym pracovníkom špeciálne školiace programy, ktoré môžu pracovníka naučiť všetky potrebné zručnosti bez poskytnutia formálneho akademického vzdelania a akademického titulu (Marian, 2015).

Podľa Eurostatu (2017) bol v roku 2015 podiel mladých žien vo veku 30-34 rokov žijúcich v krajinách EÚ-28 s dosiahnutým terciárnym vzdelaním 43,4 %; bolo to podstatne viac ako zodpovedajúci podiel zaznamenaný medzi mladými mužmi rovnakého veku, ktorý bol iba mierne vyšší než tretinový (34,0 %). Za posledné desaťročie sa podiel žien vo veku 30-34 rokov s dosiahnutým terciárnym vzdelaním zvyšoval rýchlejším tempom než zodpovedajúci podiel mužov, takže rozdiel medzi pohlaviami sa v prípade tohto ukazovateľa prehlboval. Veľká väčšina (230 z 261) regiónov NUTS 2, vykazovala v roku 2015 vyšší podiel žien vo veku 30-34 rokov s dosiahnutým terciárnym vzdelaním. V 29 regiónoch bol vyšší podiel mladých mužov s terciárnym vzdelaním a v dvoch regiónoch – Münster v Nemecku a v regióne rakúskeho hlavného mesta Wien – nebol medzi pohlaviami žiadny rozdiel.

Najväčší rozdiel medzi pohlaviami v dosiahnutom terciárnom vzdelaní bol zaznamenaný v Lotyšsku, kde bol podiel žien o 29,7 percentuálneho bodu vyšší než v prípade mužov. Vo všeobecnosti boli niektoré z najväčších rozdielov medzi pohlaviami zaznamenané v pobaltských štátoch, v Belgicku, Dánsku, Španielsku, Taliansku, vo Švédsku a v Spojenom kráľovstve, pričom vo viacregionálnych členských štátoch EÚ boli

minimálne dva regióny, ktoré zaznamenali rozdiel medzi pohlaviami na úrovni minimálne 20,0 percentuálneho bodu v prospech žien. Niektoré z týchto regiónov boli charakterizované ako relatívne vidiecke alebo riedko obývané, pričom rozdiel medzi pohlaviami bol často skôr dôsledkom nižšieho podielu dosiahnutého terciárneho vzdelania medzi mladými mužmi než vyššieho podielu dosiahnutého terciárneho vzdelania medzi mladými ženami. K týmto relatívne vidieckym alebo riedko osídleným regiónom patria napríklad Limburg v Belgicku, Sjælland v Dánsku, Molise v Taliansku, Övre Norrland a Mellersta Norrland vo Švédsku a North Yorkshire alebo Highlands and Islands v Spojenom kráľovstve. Tento vývoj možno pripísať množstvu dôvodov, napríklad: častejšej tendencii mladých mužov s dosiahnutým terciárnym vzdelaním odchádzať z vidieckych regiónov a hľadať si prácu inde alebo vyššiemu podielu mužov, ktorí zo vzdelávacieho systému odchádzajú relatívne predčasne, pravdepodobne pre prácu v poľnohospodárstve (Eurostat, 2017).

„Z 29 regiónov, v ktorých bol podiel mladých mužov s dosiahnutým terciárnym vzdelaním vyšší ako podiel zaznamenaný v prípade mladých žien, sa 19 nachádzalo v Nemecku. Z nich najvyšší rozdiel medzi pohlaviami s podielom mužov vyšším ako podielom žien bol zaznamenaný vo východobavorskom regióne Oberpfalz. Polovica zo zostávajúcich 10 regiónov s vyšším podielom dosiahnutého terciárneho vzdelania medzi mladými mužmi sa nachádzala v Spojenom kráľovstve, dva v Holandsku a po jednom v Španielsku, vo Francúzsku a v Rumunsku“ (Eurostat, 2017, s.1).

1.4.1 Možnosti terciárneho vzdelania - Univerzity v Európe

Aké sú najobľúbenejšie univerzity v každej európskej krajine? UniRank (2020) sa snaží odpovedať na túto otázku zverejnením zoznamu európskych krajín a poskytnutím rebríčka ich vysokoškolských inštitúcií, ktoré spĺňajú nasledujúce výberové kritériá:

- Licencované alebo akreditované príslušnou organizáciou spojenou s vysokoškolským vzdelávaním v každej európskej krajine
- Ponúkať najmenej štvorročné vysokoškolské vzdelanie (bakalárske) alebo postgraduálne vzdelanie (magisterské alebo doktorandské)
- Poskytovanie kurzov predovšetkým v tradičnom formáte prezenčného vzdelávania bez dištančného vzdelávania

Podľa databázy UniRank (2020) v roku 2020 existovalo v Európe 2 725 oficiálne uznaných inštitúcií vysokoškolského vzdelávania. Vzhľadom na to, že databáza UniRank obsahuje celkový počet 13 723 oficiálne uznaných inštitúcií vysokoškolského vzdelávania

po celom svete, je podiel európskych univerzít na úrovni 19,9%. Keďže sa jedná o odhadovanú populáciu na európskom kontinente, ktorá predstavuje približne 10% z celkovej svetovej populácie, zdá sa, že európsky systém vysokoškolského vzdelávania a jeho ponuky sú vo svete silne nadmerne zastúpené, prinajmenšom z hľadiska počtu vysokých škôl. Z celkového počtu 2 725 uznaných vysokých škôl v Európe zahrnutých do databázy UniRank je 1 922 verejných (oficiálne pridružených alebo riadených národnými, štátnymi alebo miestnymi vládami) a 777 je súkromných. Pokiaľ ide o počet verejných a súkromných univerzít, UniRank (2020) vykazuje oveľa vyššiu prítomnosť verejných vysokých škôl na európskom kontinente ako celku. Okrem toho 194 z 200 najlepších univerzít v Európe (97%) sú verejné vysoké školy. V systéme vysokoškolského vzdelávania v každej európskej krajine môžu stále existovať rozdiely. Všeobecne tiež platí, že drvivá väčšina európskych verejných vysokých škôl nie sú neziskové organizácie, a to nie nevyhnutne z právneho hľadiska, ale určite z hľadiska povahy a inštitucionálnych účelov, ako sú úloha, rozsah a poslanie.

UniRank zverejňuje dvakrát ročne neakademické hodnotenie najlepších 200 univerzít v Európe na základe platných, nestranných a neovplyvniteľných metrík poskytovaných nezávislými zdrojmi. Podľa rebríčka univerzít UniRank 2020 je zoznam 10 najlepších univerzít v Európe (UniRank, 2020):

1. University of Oxford
2. University of Cambridge
3. University College London
4. Eidgenössische Technische Hochschule Zürich
5. The University of Edinburgh
6. Universitat de Barcelona
7. Universidad Complutense de Madrid
8. Universität Wien
9. The University of Manchester
10. The London School of Economics and Political Science

Aké sú hlavné výzvy, ktorým musí v súčasnosti čeliť vysokoškolské vzdelávanie v Európe? Podľa UniRank (2020) sú hlavnými problémami systému vysokoškolského vzdelávania v Európe implementácia politík harmonizácie systémov vysokoškolského

vzdelávania, ktorá sa začala Bolonským procesom, a výzvy vyplývajúce z odchodu britskej vysokoškolskej zložky z Európskej únie.

1.4.2 Terciárne vzdelanie na Slovensku a jeho nedostatky

„V ostatných rokoch bol na Slovensku zaznamenaný nárast počtu ľudí s absolvovaným vysokoškolským vzdelaním, avšak tento nárast je stále nižší ako vo väčšine štátov OECD. Väčšina vysokoškolsky vzdelaných ľudí na Slovensku (vo veku 25 až 64 rokov) disponuje druhostupňovým (Mgr., Ing. a pod.) vysokoškolským vzdelaním. Tento trend je podobný aj v okolitých štátoch, predovšetkým v Poľsku a Česku“ (Filčák, 2019, s.19).


Analýza Filčáka (2019) odhaľuje, že podiel vysokoškolsky vzdelaných osôb vo veku 25 až 34 rokov na Slovensku sa v rokoch 2008 až 2018 zvyšoval pomerne rýchlym tempom. Z hľadiska pohlavia sa zvýšil podiel mužov (zo 16 % v roku 2008 na 30 % v roku 2018) a výrazne aj podiel žien (z 21 % v roku 2008 na 45 % v roku 2018) disponujúcich vysokoškolským vzdelaním. Priemerný podiel vysokoškolsky vzdelaných osôb vo veku 25 až 34 rokov sa v štátoch OECD v rokoch 2008 až 2018 zvýšil o 9 percentuálnych bodov (p. b.). Na Slovensku je nárast výraznejší, celkovo o 19 p.b..

Môžeme preto konštatovať, že vzdelanostná úroveň slovenského obyvateľstva sa postupne zvyšuje. Pre porovnanie, v roku 2018 vo vekovej kategórii 65 rokov a viac bolo iba 13,11 % osôb s ukončeným vysokoškolským vzdelaním, avšak vo vekovej kategórii 25 až 29 rokov to bolo už 36,76 %. Podľa rodového hľadiska bol v kategóriách s vyšším vzdelaním (maturita a vyššie) stav relatívne rovnomerný, pričom mierna dominancia jedného alebo druhého pohlavia bola v princípe vysvetliteľná demografickou štruktúrou obyvateľstva. Zaujímavosťou je však výraznejšia dominancia žien s vysokoškolským vzdelaním vo vekových skupinách 20 až 24 a 25 až 29 rokov, kde ženské pohlavie prevyšuje nad mužským pohlavím vo vysokoškolskom vzdelaní približne o 26,5 p.b. (Blanár, 2019).

V slovenskej spoločnosti a tiež naprieč politickým spektrom však panuje zhoda, že školstvo, vrátane terciárneho vzdelávania, v porovnaní s inými rozvinutými krajinami zaostáva. Prestáva byť pridanou hodnotou v medzinárodnej konkurencieschopnosti a vyžaduje zásadné reformné kroky. Sústreďenie sa na parciálne riešenia jednotlivých symptómov však nie je prístup, ktorý by priniesol potrebnú zásadnú zmenu. Po systematickom posúdení súvislostí problematických oblastí slovenského terciárneho vzdelávania, využívajúc medzinárodné porovnania, Republiková únia zamestnávateľov

(RÚZ, 2019) dospela k záveru, že kľúčovým parametrom, ktorý má širokospektrálne dopady, je nevyhovujúca štruktúra študijných programov a teda aj štruktúra absolventov, ktorí prichádzajú na trh práce. S vysokou mierou pravdepodobnosti je odlišná štruktúra dôsledkom zlého nastavenia terciárneho vzdelávania. Jeho štruktúra je v plnej miere podriadená záujmu študentov, respektíve ich výberu z ponuky vysokých škôl a len veľmi slabo reflektuje potreby trhu práce, konkurencieschopnosti a trvalej udržateľnosti Slovenska.

„Slovensko sa v štruktúre terciárneho vzdelávania zásadne odlišuje od priemeru krajín OECD, od priemeru EÚ a dokonca aj od susediacich krajín, s ktorými zdieľa historickú skúsenosť. Naše vysoké školy opúšťa takmer dvojnásobok absolventov druhého stupňa ISCED 7 (titul magister, inžinier) ako je tomu v priemere krajín OECD. Naopak, máme veľmi malý podiel študentov končiacich štúdium po absolvovaní bakalárskeho stupňa ISCED 6 a prakticky žiadnych absolventov krátkych vysokoškolských programov (v zahraničí väčšinou dvojročných) ISCED 5“ (RÚZ, 2019, s.3). Štúdiá Kouckého a Obdržálka (2017) dokonca ukázala, že máme aktuálne celosvetovo vôbec jeden z najvyšších podielov populačného ročníka, ktorý získava magisterský či inžiniersky diplom (Obrázok 5).




Obrázok 5: Štruktúra populácie 25 – 34 ročných podľa dosiahnutého terciárneho vzdelávania v SR a krajinách V5 v roku 2016 (zdroj: RÚZ, 2019)

V praxi to napríklad znamená, že slovenskému študentovi trvá absolvovanie terciárneho vzdelania v priemere o viac ako rok dlhšie, než je tomu v priemere krajín OECD. To je aj vo fáze masifikovaného terciárneho vzdelania (dynamického kvantitatívneho rozvoja), ktoré je celosvetovým trendom, tak zásadná odchýlka, že jeho

dopady na fungovanie celého systému nemôžu byť zanedbateľné. Sú evidentné na mnohých úrovniach a majú veľmi negatívny vplyv na výkonnosť vysokoškolského systému, ktorý je, žiaľ, v súčasnosti na chvoste medzinárodných porovnaní (OECD, 2017).

RÚZ (2019) však pripomína, že dĺžka štúdia nie je jediný štrukturálny problém. Druhý je v zásadnom nesúlade odborovej štruktúry oproti potrebám trhu práce. Potvrdzujú to tak analýzy súčasného dopytu a ponuky pracovných miest, ako aj existujúce prognostické štúdie. Disproporcia je zrejmá v nadprodukcii absolventov spoločenskovedných odborov oproti nedostatkovým absolventom STEM odborov vedy, technológií, inžinierstva a matematiky, a naďalej sa prehľbuje (Obrázok 6).



Obrázok 6: Pracovné miesta vs. počet ekonomicky aktívnych vysokoškolákov v odboroch – sociálne vedy a inžinierstvo (zdroj: RÚZ, 2019)

„Vplyv uvedených štrukturálnych odchýlok na zlý stav vysokého školstva na Slovensku môžeme skúmať cez ich vplyv na konkrétne problémy. Medzi tie najvážnejšie patria:

1. Kvalita terciárneho vzdelávania
2. Kvalita pedagógov
3. Kvalita študentov
4. Únik mozgov do zahraničia
5. Kariérna orientácia a kvalita absolventov stredných škôl
6. Napĺňanie požiadaviek trhu práce a podpora konkurencieschopnosti
7. Nedostatočné zdroje na financovanie terciárneho vzdelávania“ (RÚZ, 2019, s.3)

Podľa RÚZ (2019) je diskusia o validných indikátoroch kvality vysokých škôl zložitá. Výkonnosť slovenských vysokých škôl v medzinárodnej súťaži podľa dostupných štatistík jasne zaostáva. Prejavuje sa to v celosvetovo etablovaných rankingoch (v rámci troch najprestížnejších sa vyskytuje v top 1 000 len jedna slovenská univerzita), rovnako ako v hodnotení úspešnosti vysokoškolského systému ako celku. V U21 - Ranking of National Higher Education Systems nám patrí 35. miesto, v rámci európskych krajín sú horšie iba Srbsko, Turecko, Chorvátsko, Rumunsko a Bulharsko (Williams, Leahy a Jesen, 2017). Intenzívnejšie rozlíšenie kvalitných vysokých škôl je preto vitálnou potrebou pre celý systém terciárneho vzdelávania na Slovensku.

Čo sa týka kvality pedagógov, tá je na Slovensku dotknutá v prvom rade nízkymi mzdami. Správa OECD (2015) pri porovnaní priemerných ročných platov vysokoškolských pedagógov v prepočte na paritu kúpnej sily uvádza Slovensko na poslednom mieste spomedzi skúmaných krajín. „Na spodných priečkach figurujú zostupne Poľsko, Island, Maďarsko, Česká republika a Slovensko. Avšak tri z piatich menovaných krajín (Poľsko, Maďarsko a Česká republika) zaznamenali najvyšší medziročný rast platov u profesorov. Inými slovami, spomenuté okolité krajiny, ktoré sú historicky v podobnej situácii ako Slovensko, na aktuálnu situáciu reagujú. To však neplatí pre Slovensko, ktoré sa tak v sledovanom období ešte viac prepadlo“ (RÚZ, 2019, s.13).


„Tým, že štrukturálny problém vyúsťuje na Slovensku do dlhšieho trvania terciárneho vzdelávania, je náročnejší okrem iného aj na mzdy pre pedagógov. Súčasný slovenský model musí rozdeliť rovnaký balík peňazí medzi väčší počet učiteľov ako je tomu v krajinách, kde štúdium začína obdobná časť populácie, ale určitý podiel z nej ho ukončuje skôr. Riešenie štrukturálneho problému by teda prinieslo možnosť zásadného zvýšenia platov pri zachovaní pomeru počtu študentov na učiteľa v študijných programoch s diverzifikovanou dĺžkou štúdia“ (RÚZ, 2019, s.5).

Podľa RÚZ (2019) na súčasnú úroveň kvality terciárneho vzdelávania tiež veľmi negatívne vplýva nedostatočná selekcia/výber študentov. Spôsob financovania vysokých škôl, silne zohľadňujúci počet študentov, ovplyvňuje ochotu prijímať na štúdium aj uchádzačov s podpriemernými výsledkami na strednej škole. Masifikácia ponuky vysokoškolských programov a počtu prijímaných študentov rástla na Slovensku v období rokov 2000 až 2008 nebývalým tempom oproti iným krajinám. Naviac, skoro všetci absolventi bakalárskeho štúdia pokračujú na druhom stupni. Absolventi magisterského štúdia na Slovensku majú výrazne nižšiu úroveň, než predstavuje priemer krajín OECD, EÚ alebo V5 (Slovensko, Česko, Maďarsko, Poľsko, Ukrajina), čím narastá devalvácia

hodnoty diplomov na tejto úrovni. Snaha konkurovať v kvalite študentov krajinám OECD, kde v druhom stupni pokračuje len polovica populačného ročníka vysokoškolákov voči Slovensku, je tak prakticky veľmi náročná.

Ďalším existujúcim problémom je, že odliv slovenských maturantov do zahraničia neustále narastá – v roku 2015 dosiahol 14,5 % študujúcich na vysokých školách. Ak odhliadneme od Luxemburska s veľmi špecifickými podmienkami, je to najvyššie číslo v rámci sledovaných krajín OECD (ďalšie krajiny sú na úrovni 8 % a menej). Prijímame však nepomerne menej zahraničných študentov. Rovnako je zrejmé, že menej ako polovica Slovákov študujúcich v zahraničí sa vracia späť na Slovensko (LEAF, 2016). Najväčšia časť tých, ktorí sa rozhodli neštudovať na Slovensku, smeruje do Českej republiky. Sú to vo vysokom percente maturanti s najlepšimi študijnými výsledkami. Podľa prieskumov očakávajú kvalitnejšie štúdium – uvádza to až 82 % slovenských uchádzačov o štúdium v Českej republike (Pudlák, 2015).


„Aktuálne analýzy (Obrázok 7) navyiac ukazujú, že priemerná náročnosť kvalifikácií pracovných miest na Slovensku paradoxne klesá – je stále menej miest ponúkaných pre vyššie kvalifikácie, čo je opäť trend nezlučiteľný s vývojom vo vyspelých ekonomikách. Podiel ekonomicky aktívnych magistrov/inžinierov vo veku 25 – 34 rokov je pre Slovensko medzi krajinami OECD jeden z najnižších a nedosahuje ani 80 %. Absolventi vysokých škôl teda nenachádzajú zodpovedajúce uplatnenie a často ostávajú mimo pracovný trh“ (RÚZ, 2019, s.8).



Obrázok 7: Podiel ekonomicky aktívnych vysokoškolákov 25-30 rokov, OECD, 2016
(zdroj: RÚZ, 2019)

Podľa RÚZ (2019) je závažnosť zistení o odborovom nesúlade štruktúry absolventov a potrieb trhu práce, najmä s ohľadom na nadprodukciu v spoločenských vedách a rastúci deficit v technických odboroch pre ekonomický rast a konkurencieschopnosť z pohľadu Slovenska oveľa intenzívnejšia ako pre iné krajiny s podobnými tendenciami. Patríme totiž v rámci EÚ práve ku krajinám s výrazne priemyslovo orientovanou ekonomikou (podobne ako Nemecko, Rakúsko či Česko) a podiel pracovných miest s technickou kvalifikáciou je u nás nadpriemerný.

Na nasledujúcom obrázku (Obrázok 8) môžeme vidieť, že postavenie Slovenska (podobne ako Českej republiky) je špecifické v tom, že na jednej strane má zo všetkých krajín tretí najvyšší podiel pracovných miest vhodných pre vysokoškolákov s technickou kvalifikáciou (21,8 %), avšak podiel absolventov technických odborov je medzi európskymi krajinami naopak podpriemerný (len 13,1 %). Je teda zrejmé, že Slovensko potrebuje výrazný zásah do štruktúry študovaných odborov, ak sa chce vyhnúť vážnym negatívnym ekonomickým dopadom (RÚZ, 2019).



Obrázok 8: Vysokoškolské pracovné miesta a absolventi technických odborov (zdroj: RÚZ, 2019)

Štruktúru študijných odborov a vývoj potrieb/ponuky na trhu práce je možné monitorovať a navzájom optimalizovať. Podľa RÚZ (2019) sa štrukturálne požiadavky musia premietnuť do mechanizmov financovania a musia byť široko komunikované a argumentované voči verejnosti, najmä uchádzačom o štúdium v terciárnom vzdelávaní či ich sociálnemu okoliu. Problémom je, že existujúce analýzy uplatniteľnosti absolventov

vysokých škôl a prognózy vývoja trhu práce pre pozície vyžadujúce terciárnu kvalifikáciu vznikajú na Slovensku skôr ad hoc ako systematicky. S infláciou titulov, ktoré na trhu nediferencujú kvalitu, prichádza aj problém prekvalifikovanosti, pretože na pozíciách, kde by postačovala kratšia praktickejšia kvalifikácia, pôsobia zamestnanci s absolvovaným druhým či tretím stupňom a silne teoretickou prípravou.

„Na základe medzinárodných porovnaní niet tiež pochyb o tom, že slovenské vysoké školstvo je stále výrazne podfinancované. Vyplýva to z hodnôt troch najvýznamnejších základných ukazovateľov, najbežnejšie pre tento účel používaných:

- výdavky na vysoké školstvo ako podiel z hrubého domáceho produktu (HDP);
- výdavky na vysokoškolského študenta v prevoditeľnej mene zohľadňujúc rozdielne cenové úrovne krajín;
- výdavky na vysokoškolského študenta v pomere k HDP na obyvateľa danej krajiny“ (RÚZ, 2019, s.8)

Podľa OECD (2017) sa vo vyššie uvedených údajoch slovenské vysoké školstvo jednoznačne nemôže porovnávať takmer so žiadnou inou krajinou OECD alebo EÚ. Na jeho úroveň, konkurencieschopnosť, atraktivitu, kvalitu aj efektívnosť, rovnako ako pre jeho potenciálny rozvoj, to má úplne zásadný vplyv. Potenciálne príjmy štátneho rozpočtu sú každoročne znižované nadmerným zotrvávaním študentov v procese vzdelávania. V súhrne to znamená, že priblížením sa štruktúrou terciárneho vzdelania k priemeru krajín OECD, by sa Slovensko zlepšilo na úroveň krajín OECD aj v ostatných, často sledovaných, ukazovateľoch, ako sú celkové výdavky na terciárne vzdelávanie, výdavky na žiaka/rok, mzda pedagógov v terciárnom vzdelávaní atď. Zmeny štruktúry by tiež mohli priniesť prelom v podfinancovanosti vysokého školstva.

RÚZ (2019) je presvedčené, že uvádzané fakty a medzinárodné porovnania jednoznačne podporujú tézu o nevyhnutnosti reformných krokov, nakoľko slovenský model je odklonom od súčasných trendov, v rámci ktorých drvivá väčšina rozvinutých krajín reaguje na vývoj vedy, technológií a spoločnosti.

1.5 Hlavné trendy v oblasti vzdelávania

Vzdelávanie hrá rozhodujúcu úlohu pri vylepšovaní potrebných zručností, znalostí a postojov populácie pre prosperitu v modernom osobnom a profesionálnom živote. Keď sa svet bude čoraz viac digitalizovať, vzdelávací systém sa musí prispôbovať a vyvíjať,

aby mohol využívať nástroje a silné stránky nových technológií, a súčasne riešiť obavy z možného zneužitia, ako sú podvody, krádeže identity alebo kyberšikana.

V súčasnosti existuje veľké množstvo štúdií, ktoré sa zaoberajú výskumom toho, akým smerom by sa mal systém vzdelávania v najbližších rokoch uberať a načo by sa mal zamerať. Jedným z nich je aj Program Trends Shaping Education (OECD, 2019), ktorý skúma hlavné ekonomické, politické, sociálne a technologické trendy ovplyvňujúce budúcnosť vzdelávania od raného detstva až po celoživotné vzdelávanie. Tento program pokrýva širokú škálu tém týkajúcich sa globalizácie, demokracie a občianstva, bezpečnosti, starnutia a moderných kultúr. V spojitosti s globalizáciou prichádzajú výzvy ako rastúca spotreba, neudržateľné využívanie zdrojov a pre niektorých pocit zaostávania.

Pri vybavovaní študentov zručnosťami potrebnými na úspech v globálnej budúcnosti zohráva dôležitú úlohu vzdelávanie. Vzdelanie má dôležitú úlohu rovnako pri zlepšovaní občianskej a sociálnej účasti a podpore demokratického občianstva. Vzdelávanie môže hrať tiež úlohu pri porozumení, prevencii a zmierňovaní bezpečnostných rizík. Môže tiež pomôcť študentom rozlišovať medzi vnímanými a skutočnými rizikami, budovať odolnosť a lepšie pripraviť občanov na nepriaznivé situácie. Digitalizácia môže pomôcť vyrovnať sa s mnohými rizikami spojenými so zvýšenou slabosťou a závislosťou, ale tiež otvára nové hrozby internetových podvodov zamerané špeciálne na starších ľudí. Tento program preto podnecuje tiež úvahy o tom, ako môže byť vzdelávanie, ktoré sa často spája predovšetkým s mladými ľuďmi, prospešné pre staršiu populáciu. Prepojenie týchto megatrendov so vzdelávaním je prostriedkom na rozšírenie našich obzorov a základných informácií pre dôležité rozhodovania (OECD, 2019).

V roku 2010 Európska únia prijala stratégiu na zabezpečenie inteligentného, udržateľného a inkluzívneho rastu: stratégia Európa 2020 (Európska komisia, 2010). Krátkodobou výzvou bolo dosiahnuť úspešné prekonanie krízy. S cieľom zabezpečiť udržateľnú budúcnosť a podporiť rast a zamestnanosť, stanovila Európska únia päť cieľov v oblasti: zamestnanosti, inovácií, vzdelávania, sociálneho začlenenia a klímy/energie, ktoré sa mali dosiahnuť do roku 2020. Všetky tieto ciele sú vzájomne prepojené, napr. v kontexte vzdelávania sa javí ako zrejmé, že lepšie vzdelaná populácia je ľahšie zamestnateľná, čo ďalej znamená znižovanie chudoby.

V roku 2018 Európska únia prijala novú stratégiu pre regionálny rozvoj a súdržnosť po roku 2020 (Európska komisia, 2018). Nový rámec politiky súdržnosti v rokoch 2021 - 2027 bude riadiť päť hlavných cieľov v oblastiach:

-
- modernejšia Európa prostredníctvom inovácií, digitalizácie, hospodárskej transformácie a podpory malých a stredných podnikov
 - ekologickejšia Európa bez uhlíka, implementácia Parížskej dohody a investície do prechodu na obnoviteľné zdroje energie a boj proti zmene podnebia
 - prepojenejšia Európa so strategickou dopravou a digitálnymi sieťami
 - sociálnejšia Európa, realizácia európskeho piliera sociálnych práv a podpora kvalitného zamestnania, vzdelávania, zručností, sociálneho začlenenia a jednotného prístupu k zdravotnej starostlivosti
 - Európa bližšie k občanom prostredníctvom podpory miestnych rozvojových stratégií a trvalo udržateľného rozvoja miest v celej EÚ

Aj keď sa v rámci regionálneho rozvoja kladie dôraz na prvý a druhý bod spomínaných cieľov, teda inovatívnejšia a ekologickejšia Európa (65% až 85% prostriedkov z Európskeho fondu regionálneho rozvoja a Kohézneho fondu), neustále skvalitňovanie vzdelávania, ktoré úzko súvisí s ďalšími cieľmi EÚ je naďalej víziou do roku 2027. Je však potrebné mať na pamäti, že medzi jednotlivými členskými štátmi existujú obrovské rozdiely na národnej aj vnútroštátnej úrovni. Na identifikáciu existujúcich rozdielov a navrhnutie riešení na ich odstránenie je možné použiť rôzne prístupy (Hančlová a Tvrdý, 2004). Jedným z prístupov, ktorý sa v posledných rokoch stal veľmi populárnym, je použitie nástrojov na analýzu priestorových údajov a priestorovej ekonometrie, ktoré tiež umožňujú možné priestorové závislosti medzi regiónmi. Z praktického hľadiska je potrebné vyriešiť problém regionálnych rozdielov, čo znamená, že podpora rozvoja jedného regiónu môže významne zasiahnuť nielen tento región, ale aj geograficky blízke regióny.

1.6 Prehľad vybraných výskumných štúdií analyzujúcich vzdelanie

Nakoľko univerzitné vzdelanie a akýkoľvek iný druh formálneho vzdelávania nám poskytuje vedomosti, ktoré po jeho ukončení využívame v konkrétnom špecializovanom odvetví, boli publikované viaceré štúdie využívajúce rôzne prístupy v rámci analýz vzdelanosti. Vzhľadom na zameranie diplomovej práce uvedieme prehľad niektorých z nich, zdôrazňujúcich priestorové hľadisko.

Pokiaľ ide o otázku dosiahnutia terciárneho vzdelávania v kontexte stratégie Európa 2020, existuje hodnotná štúdia, ktorú predložili Dragomirescu-Gaina, Elia a Weber (2015) a ktorí položili otázku, či je možné dosiahnuť cieľ stratégie Európa 2020 v oblasti

terciárneho vzdelávania. Na základe prístupu založeného na panelových údajoch dospeli k záveru, že Európa pravdepodobne dosiahne svoj cieľ, predstavili však aj určité pochybnosti o reálnej hospodárskej konvergencii. Ich štúdia poskytuje konzistentný celok v súlade s predikciami teoretických modelov, ktoré vnímajú vzdelávanie ako dobrú spotrebu aj investíciu. Rozhodnutia o školskej dochádzke však ukazujú vyššiu závislosť od očakávaného príjmu ako od rodinného zázemia, čo však nie je prekvapujúce v kontexte, v ktorom prevláda zvyšovanie návratnosti vzdelania a príjmová nerovnosť (Winchester a Greenaway, 2007).

Pagliacci (2014) analyzoval výzvy stratégie Európa 2020 a regionálne rozdiely s koncentráciou na dve zložky - inteligentný a inkluzívny rast, a úlohu terciárneho vzdelávania na základe analýzy základných komponentov a priestorovej analýzy. Preukázal obrovskú územnú nevyváženosť v celej EÚ a poukázal na skutočnosť, že geografia zohráva kľúčovú úlohu pri dosahovaní cieľov stratégie Európa 2020.

Podnetnou štúdiou sa zaoberá Chocholatá a Furková (2017), ktoré analyzovali úroveň dosiahnutého vzdelania v 252 regiónoch NUTS 2 Európskej únie (EÚ) s ohľadom na priestorový aspekt. Pretože jednotlivé regióny EÚ nemožno považovať za izolované, hlavným cieľom tohto článku bolo zhodnotiť vplyv umiestnenia na úroveň dosiahnutého vzdelania (percento populácie vo veku 25-64 rokov s minimálne vyšším stredoškolským vzdelaním) v období rokov 2007 - 2015, ako aj preskúmať vplyv regionálneho rastu 2014/2007 na úroveň dosiahnutého vzdelania v roku 2015. Priestorová analýza preukázala existenciu pozitívnej priestorovej autokorelácie a pretrvávania rozdielov v úrovni dosiahnutého vzdelania v regiónoch EÚ počas analyzovaného obdobia. Výsledky ekonometrickej analýzy potvrdili očakávaný pozitívny vplyv ekonomického rastu na úroveň dosiahnutého vzdelania ako aj potrebu začlenenia priestorovej dimenzie do modelu.

Ďalšou analýzou prispeli Rodríguez-Pose a Tselios (2007), pričom ich cieľom bolo skúmanie časopriestorovej dynamiky európskeho vzdelávania, meraného vzhľadom k ukončenej úrovni vzdelania a veku. Snažili sa opísať nerovnosti v dosiahnutom vzdelaní cez vizualizácie máp, a odhaliť vzorce pre globálnu a lokálnu priestorovú autokoreláciu pomocou panelových dát 102 európskych regiónov v období rokov 1995 – 2000. Z prieskumných analýz vyplýva, že bez zavedenia akýchkoľvek predchádzajúcich obmedzujúcich predpokladov, je vzdelávanie geograficky autokorelované, pričom pri priestorovej závislosti treba brať do úvahy aj inštitucionálne faktory. Analýza európskeho vzdelania tiež ilustruje systematické rozdiely medzi mestskými a vidieckymi oblasťami ako aj medzi severnými a južnými regiónmi. Ekonomiky v rámci klastra interagujú viac

ako s tými mimo klastra. Dosiahnuté vzdelanie je vyššie na severe a v mestských oblastiach, zatiaľ čo nerovnosť vo vzdelaní je v týchto oblastiach nižšia. Preto je priestorová závislosť a priestorová heterogenita skutočne požadovanými prvkami pri analýze európskeho vzdelania.

Priestorová ekonometria je vo veľkej miere využívaná k analýzam vzdelanosti v rôznych aj mimoeurópskych krajinách. Dôkazom je napríklad štúdia zaoberajúca sa priamymi a nepriamymi dopadmi vzdelávania (efekt prelievania) na ekonomický rast v 31 provinciách Číny (LV a kol., 2015). Súdiac podľa výsledkov odhadov za obdobie 1996 - 2010, vývoj základného a terciárneho vzdelania hrá ústrednú úlohu v ekonomickom raste. Tento príspevok poskytuje empirické dôkazy o argumentoch, opisujúcich dôležitosť výdavkov na vzdelanie a priemernej dĺžky školskej dochádzky na ekonomický rozvoj. Oba faktory majú vplyv na susedné regióny.

Medzi ďalšie zaujímavé štúdie zaoberajúce sa priestorovou nerovnosťou v oblasti vzdelávania patrí tiež štúdia od Touitou, Yacina a Ahmeda (2020), ktorí analyzovali väzby medzi priestorovým umiestnením a rozdielmi vo vzdelávaní v Alžírsku na vzorke 48 alžírskych provincií. V rámci tejto štúdie sa autori zamerali na vzdelávanie z troch hľadísk: kvalitu, kvantitu a nerovnosť vo vzdelávaní. Poukazujú nato, že napriek výraznému pokroku v školskej dochádzke sú v Alžírsku naďalej dôležité sociálne a priestorové nerovnosti v prístupe k vzdelaniu.

Taktiež môžeme spomenúť príspevok Ahmeda (2011), ktorý vo svojej práci zaoberajúcej sa regionálnym rastom a rozvojom v Pakistane zdôraznil, aké dôležité je analyzovať sociálno-ekonomické javy prostredníctvom priestorových konceptov, ako je hustota, vzdialenosť, susedstvo a aglomerácia. Jeho práca zdôrazňuje túto skutočnosť v troch vzájomne súvisiacich štúdiách, ktoré analyzovali priestorové aspekty nerovností príjmov a ľudského kapitálu v Pakistane. Prvá štúdia skúma vývoj a trend rozdelenia výnosov a príjmov v Pakistane medzi rokmi 1993 a 2006 - obdobím charakterizovaným makroekonomickými reformami a slušným priemerným tempom rastu HDP. Druhá štúdia využíva prieskumné techniky priestorových údajov na analýzu rozsahu priestorového zoskupovania ekonomických nerovností, rastu a rozvoja v pakistanských okresoch v rokoch 1998 až 2006. Záverečná štúdia potom po prvýkrát skúma konvergenciu príjmov v pakistanských okresoch v rokoch 1998 až 2005 pomocou priestorových ekonometrických techník. Hlavné empirické zistenia z prvej štúdie ukazujú, že výnosy z nízkych úrovní vzdelania klesli, zatiaľ čo výnosy z vysokoškolských úrovní sa zvýšili. Okrem toho sú tieto výnosy oveľa vyššie u žien ako u mužov. Ukázalo sa tiež, že nerovnosť v príjmoch v rámci

provincií neustále zostáva vyššia v porovnaní s nerovnosťou medzi nimi. Zistenia z druhej štúdie ukazujú, ako sa susedné okresy navzájom delia o úroveň rozvoja, čo potvrdzuje, že ekonomická geografia má význam pre regionálne nerovnosti, rast a rozvoj v Pakistane. A nakoniec, konvergenčná analýza uskutočnená v tretej štúdii ukazuje, že po zohľadnení priestorových účinkov možno v Pakistane pozorovať podmienenú konvergenciu. Stručne povedané, táto štúdia prispieva k politickej diskusii o ekonomických nerovnostiach a konvergencii v rozvojových ekonomikách, a najmä k výskumu na regionálnej úrovni v Pakistane, a to tak, že sa na pakistanské údaje po prvýkrát aplikovala kontrafaktuálna regresná analýza a priestorové ekonometrické techniky.

Aj keď o téme konvergenzie regionálnych príjmov existuje obrovská rada štúdií, oveľa menej pozornosti priťahovali iné aspekty sociálno-ekonomického blahobytu a rozvoja. Sociálne ukazovatele sú cenným doplnkom ekonomických ukazovateľov pri analýze priestorových vzorov v danom geografickom regióne a často môžu poskytnúť komplexnejší pohľad na regionálne sociálno-ekonomické správanie. V chudobnejších krajinách, v ktorých dominuje veľa oblastí s nízkym príjmom, ktoré vykazujú podobnú ekonomickú výkonnosť, môžu sociálne ukazovatele odhaliť ďalší pohľad na rozdiely medzi regiónmi. Príspevok Eliasa a Reya (2011) preto skúma problematiku konvergenzie vzdelávania v Peru v období rokov 1993 až 2005. S využitím prieskumných analýz priestorových údajov a priestorovej ekonometrie sa štúdia uskutočňuje na úrovni provincií s cieľom odhaliť potenciálne priestorové vzorce, ktoré pomáhajú vysvetliť rozdiely vo výsledkoch vzdelávania v priebehu času medzi regiónmi.

V neposlednom rade môžeme spomenúť tiež Suttona (2012), ktorý skúmal priestorové rozdelenie dosiahnutého vzdelania v USA alebo Wanga (2012), ktorý predstavil priestorovú analýzu nerovnosti vo vzdelávaní v čínskych provinciách. Taktiež Umar a kol. (2014) poskytli priestorovú ekonometrickú analýzu distribúcie vzdelania a regionálnych rozdielov v príjmoch v Nigérii. Dospeli k záveru, že „investície do spravodlivého rozdelenia vzdelávania budú veľmi účinnou politickou stratégiou na zlepšenie regionálnej hospodárskej výkonnosti aj regionálnej hospodárskej konvergenzie v Nigérii“(Umar a kol., 2014, s. 722).

2 Cieľ práce

Primárnym cieľom diplomovej práce je poukázanie na rozsah a dynamiku regionálnych rozdielov v podiele obyvateľstva vo veku 30-34 rokov s dosiahnutým terciárnym vzdelaním v 251 regiónoch NUTS 2 Európskej únie v období rokov 2012 - 2019 pomocou nástrojov priestorovej analýzy.

K dosiahnutiu tohto cieľa boli stanovené parciálne ciele:

1. Analýza globálnej a lokálnej priestorovej autokorelácie

Výskumné predpoklady:

- globálny nárast podielu obyvateľstva vo veku 30-34 rokov s ukončeným terciárnym vzdelaním počas sledovaného obdobia,
- pretrvávajúce rozdiely v úrovni dosiahnutého vzdelania naprieč regiónmi EÚ,
- problém nerovnomerného rozloženia dosiahnutého vzdelania v priestore,
- existencia horných a dolných odľahlých hodnôt,
- vytváranie zhlukov v rámci regiónov s podobnou výškou podielu dosiahnutého sledovaného vzdelania,
- citlivosť priestorovej analýzy na rôzne špecifikácie matice **W**.

2. Regresná analýza odrážajúca závislosť medzi dosiahnutým terciárnym vzdelaním a ďalšími socio-ekonomickými ukazovateľmi

Výskumné predpoklady:

- nevhodnosť použitia lineárneho modelu OLS pri analýze priestorových závislostí,
- potreba využitia špeciálnych priestorových modelov pre neskreslené opísanie sledovaných ukazovateľov,
- dosahované terciárne vzdelanie závisí od regionálneho HDP,
- analyzovaný podiel vzdelanosti asociuje s hustotou zaľudnenia v daných európskych regiónoch.

3 Metodika práce a metody skúmania

Analýza tejto práce sa uskutočňovala na základe údajov získaných zo všeobecných a regionálnych štatistík databázy Eurostat (2021a). Hlavné zameranie bolo na dosiahnuté vzdelanie charakterizované populáciou vo veku 30–34 rokov (v %) s terciárnym vzdelaním pre 251 regiónov NUTS 2 krajín EÚ v období rokov 2012 - 2019. Priestorová analýza sa uskutočňovala pomocou voľne dostupného softvéru GeoDa. Súbor .shp pre európske regióny bol stiahnutý z webovej stránky Eurostatu (2021b).

Na dosiahnutie stanovených cieľov sme v prvom kroku využili konvenčne používaný prístup k preskúmaniu priestorovej štruktúry regionálnych údajov, založený na analýze priestorových údajov (ESDA), ktorý okrem grafického znázornenia umožňuje aj výpočet rôznych mier nerovností s využitím niekoľkých typov máp. V diplomovej práci sme použili kvantilovú mapu, škatuľový graf či škatuľovú mapu. Zatiaľ čo na základe týchto máp je možné určiť niektoré priestorové vzorce a extrémne hodnoty alebo odľahlé hodnoty, neposkytujú však žiadne informácie o štatistickej významnosti zhľukovania regiónov. Ďalší krok ESDA bol preto založený na analýze priestorovej autokorelácie na globálnej aj lokálnej úrovni. Globálna štatistika Moranovo I a lokálna štatistika Moranovo I sú hlavnými nástrojmi pre túto časť práce.

Ďalej sme pracovali na ekonometrickom modelovaní terciárneho vzdelania vo vzťahu s inými socioekonomickými ukazovateľmi. V rámci regresnej analýzy sme použili prierezové údaje, pretože sa zaoberajú údajmi za jednotlivé regióny v stanovenom čase. S cieľom preskúmať vplyv hrubého domáceho produktu regiónov na dosiahnuté vzdelanie týchto regiónov v roku 2019 sme použili oneskorený vplyv ukazovateľa HDP za rok 2018, vyjadrený v eurách na obyvateľa. Skúmame tiež závislosť dosiahnutého terciárneho vzdelania v roku 2019 od hustoty zaľudnenia v danom regióne, ktoré bolo definované počtom obyvateľov na km². Tento ukazovateľ analyzujeme taktiež pre rok 2018, nakoľko predpokladáme, že hustota obyvateľstva sa v čase výrazne nemení.


3.1 Analýza priestorových údajov ESDA

Pre väčšinu priestorových modelov je dôležité vedieť, či má priestorová jednotka nejakých susedov, resp. ktoré regióny susedia so sledovaným regiónom. Na základe týchto skutočností sa konštruuje priestorová matica susednosti s priestorovými váhami. Definovať susednosť je v systéme GeoDa možné na základe dvoch kritérií – spoločných hraníc a vzdialenosti. „Pri spoločných hraniciach hovoríme o tzv. kontiguite (susedstve, mieste

dotyku). LeSage (1998) opísal niekoľko možností, ako skonštruovať danú maticu v závislosti od toho, ako susedstvo zadefinujeme:

1. Susedstvo typu „Veža“- susedstvo je definované na základe spoločnej časti hranice na ľubovoľnej strane. Dôležitú rolu v tomto zohráva dĺžka hranice. Definovaním kritickej hodnoty získavame kritérium susednosti. Regióny tak v tomto prípade susedia, ak je spoločná hranica väčšia ako daná kritická hodnota vzdialenosti.
2. Susedstvo typu „Kráľovná“- v tomto prípade kritickú hodnotu nešpecifikujeme a susednosť je definovaná aj jedným spoločným bodom hranice dvoch regiónov.
3. Susedstvo typu „Strelec“- v tomto prípade pre susedstvo platí podmienka spoločného bodu dvoch regiónov. V praxi sa však uvažuje o zdieľaní spoločnej hranice, ktorá je menšia ako vyššie spomenutá kritická hodnota vzdialenosti.“(Janotka, 2013, s.7)

Ako sme už uviedli, vzťahy susedstva sú konkrétne definované buď ako prípad veže, prípad strelca, alebo prípad kráľovnej. Pri týchto typoch susedstva vychádzame z hry Šach. Aj keď sú pomerne jednoduché a intuitívne, ako napovedajú už ich názvy, pre ilustráciu pripájame ich predpoklady na nasledujúcom obrázku (Obrázok 9). Susedstvo typu veža (Rooks case) je susedstvom 4 regiónov susediacich s každou bunkou, strelce (Bishops case) berie do úvahy iba uhlopriečky vzťahu a susedstvo typu kráľovná (Queen's case) považuje susedstvo okolitých ôsmich buniek. Toto sú najbežnejšie formy spojitosti používané v priestorovej autokorelácii. Podľa Sawadu (2009) je z týchto troch prípadov najčastejšie používaný typ veža, naopak susedstvo typu strelce sa používa len zriedka.



Obrázok 9: Definovanie susedstiev (zdroj: Sawada, 2009)

Na špecifikáciu priestorových interakcií naprieč analyzovanými regiónmi je však potrebné vytvoriť príslušnú maticu priestorových váh **W** dimenzie $(n \times n)$, kde n je počet regiónov v množine údajov. Špecifikácia matice **W** patrí k jedným z najproblematickejších tém, o ktorých sa v literatúre intenzívne diskutuje, pretože môže významne ovplyvniť

výsledky analýz (Anselin, 1988; Rodríguez-Pose Tselios, 2007). V tejto práci sme zvážili tri rôzne špecifikácie váhovej matice - matica susednosti typu kráľovná prvého rádu, váhová matica 4 najbližších susedov a matica prahovej vzdialenosti na základe metriky euklidovskej vzdialenosti. Najskôr bolo potrebné definovať, ktoré regióny sú susedmi, to znamená rozhodnúť, ktoré prvky matice **W** budú nenulové. V prípade matice kráľovnej možno regióny považovať za susedné, pokiaľ majú spoločnú časť hranice, vo váhovej matici 4 najbližších susedov má každý región presne 4 susedné regióny a v prípade euklidovskej matice vzdialeností je špecifikácia susedných regiónov založená na vzdialenostiach medzi regiónmi. Na vytvorenie matice **W** sme použili už spomínaný softvér GeoDa. Tento softvér umožňuje tiež vizualizáciu priestorových vzorov a priestorového zoskupenia na základe Moranovho bodového diagramu, ktorý zachytáva globálne aj lokálne štatistiky. Potvrdenie priestorovej autokorelácie znamená prítomnosť priestorových účinkov, čo znamená, že údaje z jedného regiónu môžu mať vplyv na údaje z iného regiónu. Lokálnu štatistiku Moranovho I pre jednotlivé regióny je možné vypočítať nasledovne (Anselin, 1995):

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


kde I_i označuje rozklad globálnych štatistík Moranovho I, x_i predstavuje analyzovanú premennú pre región i , $\bar{x}$ označuje priemer vzorky, n je počet regiónov v množine údajov a w_{ij} sú prvky priestorovej váhovej matice.

V Moranovom bodovom diagrame (Obrázok 10) je na osi x zobrazená štandardizovaná hodnota premennej, zatiaľ čo na osi y je znázornené štandardizované priestorové oneskorenie tej istej premennej. Moranov bodový diagram je rozdelený do štyroch kvadrantov a je v ňom možné identifikovať štyri rôzne priestorové asociácie:

- Kvadrant I: vysoké hodnoty y obklopené vysokými hodnotami (HH),
- Kvadrant II: nízke hodnoty y obklopené vysokými hodnotami (LH),
- Kvadrant III: nízke hodnoty y obklopené nízkymi hodnotami (LL),
- Kvadrant IV: vysoké hodnoty y obklopené nízkymi hodnotami (HL).

Asociácie HH a LL naznačujú pozitívnu priestorovú autokoreláciu, zatiaľ čo asociácie LH a HL negatívnu autokoreláciu. Potvrdenie pozitívnej priestorovej autokorelácie znamená, že regióny s vysokými (nízkymi) hodnotami sa nachádzajú v blízkosti iných regiónov s vysokými (nízkymi) hodnotami, zatiaľ čo negatívna priestorová autokorelácia

opisuje prítomnosť priestorových odľahlých hodnôt, to znamená regiónov s veľmi odlišnými hodnotami od svojich susedov (Elias Rey, 2011; Rodríguez-Pose Tselios, 2007).



Obrázok 10: Moranov bodový diagram (zdroj: Guţoiu, 2015)


Zatiaľ čo globálna Moranova štatistika I poskytuje meranie globálnej priestorovej autokorelácie, to znamená, ako silné je priestorové zhľukovanie naprieč susediacimi regiónmi, jeho lokálne verzie umožňujú hodnotenie priestorovej autokorelácie pre jednu konkrétnu priestorovú jednotku (región). Indikátory lokálnej priestorovej autokorelácie sú v literatúre často označované ako LISA štatistiky, ktoré boli vyvinuté Anselinom (1995). Lokálna priestorová štatistika nám identifikuje priestorovú autokoreláciu v každom regióne a jej výsledky môžu byť vizualizované v mapovej podobe. Výsledné klastrové mapy dokazujú rozdielny charakter priestorovej autokorelácie pri jednotlivých premenných a identifikujú zhľuky podpriemerných alebo nadpriemerných hodnôt vrátane miest s negatívnou autokoreláciou (Novák a Netrdová, 2011). LISA znázorňuje regióny so štatisticky významnou štatistikou Moranovo I, farebne odlíšené podľa typu priestorovej autokorelácie. Charakteristiky LISA tak možno znázorniť na nami zvolených územných jednotkách, teda regiónoch EÚ. Veľkým prínosom LISA štatistickej analýzy je zreteľnejšie zobrazenie oblastí s nadpriemernými a naopak podpriemernými hodnotami sledovaného ukazovateľa.

V tejto súvislosti tiež môžeme dodať, že existujú aj iné, často používané metódy pre analýzu priestorových údajov, ako napríklad Getisova-Ordova štatistika alebo Gearyho štatistika. Getisova-Ordova štatistika G_i , slúži na identifikáciu rozmiestnenia priestorových

zskupení vysokých hodnôt (hot spot) a priestorových zskupení nízkych hodnôt (cold spot) (Klícha, 2011). Getisova-Ordova štatistika G_i patrí do foriem lokálnej priestorovej autokorelácie, ale nemožno ju považovať za LISA v prenesenom slova zmysle, pretože súčet lokálnych štatistík nie je v proporčnom vzťahu k štatistike globálnej (Klufová, Rost, Klicnarová, 2012). Naopak Gearyho C_i štatistiku možno zaradiť medzi lokálne indikátory priestorovej asociácie (LISA), a podobne ako jej globálna verzia (Geary, 1954), vychádza zo štvorcových diferencií, resp. rozdielnosti. Nízke hodnoty tejto štatistiky teda indikujú pozitívnu priestorovú autokoreláciu (podobnosť), kým jej vysoké hodnoty svedčia v prospech negatívnej autokorelácie (rozdielnosti).

3.2 Ekonometrická analýza

V ďalšom kroku sa zameriame na ekonometrické modelovanie a s tým súvisiacu analýzu sledovaných socioekonomických ukazovateľov. Všeobecne existujú dva základné prístupy k odhadu modelov v rámci priestorovej regresie, a to prístup smerujúci od špecifikácií ku všeobecnosti (bottom-up), tiež známy ako klasický prístup (Obrázok 11) alebo prístup smerujúci od všeobecnosti k špecifikácií (top-down), tiež nazývaný Hendryho prístup (Florax a kol., 2003; Mitchell, 2013). V našom prípade budeme ďalej postupovať podľa klasického prístupu, ktorý spočíva v tom, že sa začína odhadom nepriestorového klasického lineárneho modelu OLS (Le Gallo, 2002).



Obrázok 11: Prístup zdola-nahor (bottom-up) (zdroj: Florax a kol., 2003)

Prvým krokom je odhad klasického lineárneho regresného modelu metódou najmenších štvorcov (OLS). Hlavným účelom lineárnej regresie je nájsť lineárny vzťah medzi závislou premennou a súborom vysvetľujúcich premenných. Metóda najmenších štvorcov (OLS) sa označuje ako najlepší lineárny nestranný odhad. Estimátor OLS získame

minimalizáciou súčtu štvorcových reziduí. Na získanie správnych štatistických záverov z odhadovaného modelu je potrebné brať do úvahy určité predpoklady o náhodnej chybe regresnej rovnice. V rámci analýzy odhadovaného modelu OLS sa zameriavame na niektoré z nich, ktoré sú z nášho pohľadu významné.

Požadujeme aby (Albert, 2021):

- a) náhodné chyby mali strednú hodnotu rovnú nule
- b) náhodné chyby mali konštantný rozptyl (homoskedasticita) a boli nekorelované
- c) náhodné chyby mali normálne rozdelenie

Formulácia lineárneho modelu OLS je nasledovná:

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

kde $\mathbf{y}$ je $(n \times 1)$ rozmerný vektor závislej premennej, $\mathbf{X}$ je matica nezávislých premenných rozmeru $(n \times (k + 1))$ a k je počet nezávislých premenných. $\boldsymbol{\beta}$ je $((k+1) \times 1)$ rozmerný vektor neznámych parametrov a $\boldsymbol{\varepsilon}$ je $(n \times 1)$ vektor nezávislých identicky rozdelených náhodných zložiek.

Na opísanie vzťahu medzi závislou premennou a nezávislými premennými je možné použiť model lineárnej regresie. Ak však v údajoch existuje priestorový efekt, musí sa použiť priestorový model. Je to preto, že priestorová rôznorodosť spôsobuje štruktúrnu nestabilitu modelovaného vzťahu. Pretože prítomnosť priestorových efektov môže mať významné dôsledky na kvalitu odhadov, ďalej sme pokračovali testovaním prítomnosti priestorovej závislosti s cieľom zvoliť vhodnú formu priestorového modelu. Všeobecne môžeme rozlišovať medzi dvoma typmi priestorovej závislosti - priestorovým oneskorením a priestorovou chybou, čo tiež zodpovedá dvom formám priestorových modelov - priestorový autoregresný model (SAR) alebo model priestorovej chyby (SEM) (Anselin, 1988).

Modely SAR aj SEM možno odhadnúť metódou maximálnej vierohodnosti (ML). Prostredníctvom testov Lagrangeových multiplikátorov (LM) alebo ich robustných modifikácií je možné zvoliť vhodnú formu priestorového modelu, to znamená SAR alebo SEM, prípadne klasický lineárny model najmenších štvorcov. Oba tieto testy používajú reziduály z modelu OLS na testovanie nulovej hypotézy o priestorovej nezávislosti proti alternatívnej hypotéze o priestorovej závislosti. Testy LM sú asymptotické a sledujú rozdelenie χ^2 s jedným stupňom voľnosti. Interpretácia týchto testovacích štatistík musí začať pri klasických Lagrangeových multiplikátoroch (LM). Ak nie sú štatisticky významné, je potrebné pokračovať v lineárnom nepriestorovom modeli. Ak je jedna z

týchto testovacích štatistík významná, rozhodnutie je jasné. Ak sú však obe štatistiky významné, je nutné skontrolovať ich robustnú verziu. V tomto prípade rozhoduje opäť štatistická významnosť. Ak by boli aj tie obe významné, rozhodujeme sa pre model, ktorý je určený LM s väčšou významnosťou. Robustné testy nám pomáhajú pochopiť, aký typ priestorovej závislosti môže najlepšie fungovať. Tento prístup je všeobecne veľmi obľúbený, pretože LM testy sú založené na reziduáloch lineárneho modelu a preto sú z výpočtového hľadiska nenáročné. Florax a kol. (2003) tiež pomocou simulácií ukázali, že tento postup je najefektívnejší.

Priestorový autoregresný (SAR) model možno použiť na opísanie vzťahu medzi závislou premennou a nezávislými premennými zvážením priestorového vplyvu. Pred odhadom modelu SAR však musí byť otestovaný priestorový efekt pomocou Moranovho I. Ako sme už spomínali, používa sa na zistenie prítomnosti priestorovej závislosti. Pretože ak neexistuje žiadny priestorový efekt, je možné použiť lineárny regresný model využívajúci OLS (Permai, 2019). Ak identifikujeme prítomnosť priestorovej závislosti, odhadneme model SAR metódou maximálnej vierohodnosti (ML).

Model SAR možno formulovať nasledovne:

$$\mathbf{y} = \rho \mathbf{W}\mathbf{y} + \mathbf{X}\boldsymbol{\beta} + \mathbf{u}$$

kde ρ je skalárny priestorový autoregresný parameter merajúci stupeň závislosti, $\mathbf{W}$ je matica priestorových váh rozmeru $(n \times n)$, $\mathbf{W}\mathbf{y}$ je $(n \times 1)$ rozmerný vektor priestorovo oneskorenej závislej premennej, $\mathbf{u}$ je $(n \times 1)$ rozmerný vektor náhodných zložiek, symboly $\mathbf{y}$ a $\boldsymbol{\beta}$ boli vysvetlené vyššie. Kým hodnota $\rho \neq 0$ implikuje existenciu priestorových efektov v susedných regiónoch, nulová hodnota označuje priestorovú nezávislosť medzi pozorovaniami uvažovanej závislej premennej.

Zatiaľ čo model priestorového oneskorenia vníma priestorovú závislosť ako vecne zmysluplnú, v tom zmysle, že závislá premenná y v danom regióne i je ovplyvnená tou istou premennou u jej susedov, model priestorovej chyby (SEM) zaobchádza s priestorovou závislosťou ako s nežiadúcou. Táto forma modelu sa používa v prípade, že nepredpokladáme podstatnú interakciu v rámci regiónov, avšak snažíme sa korigovať vplyv priestorovej autokorelácie, ktorá vzniká v dôsledku použitia priestorovo usporiadaných pozorovaní. Takže namiesto toho, aby sme predpokladali, že priestorové oneskorenie ovplyvňuje závislú premennú, odhadujeme model, ktorý zmierňuje predpoklad štandardného regresného modelu o potrebe nezávislosti chýb (Medina a Solymosi, 2019).

Model SEM je vyjadrený ako:

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}, \boldsymbol{\varepsilon} = \lambda \mathbf{W}\boldsymbol{\varepsilon} + \mathbf{u}$$

kde λ je parameter priestorovej chyby odrážajúci intenzitu priestorovej autokorelácie medzi regresnými reziduálmi a $\mathbf{W}\boldsymbol{\varepsilon}$ je $(n \times I)$ rozmerný vektor priestorovo oneskorených náhodných zložiek, pričom ostatné symboly boli vysvetlené vyššie.

Dodatočne sme k spomínaným priestorovým modelom odhadovali aj priestorový zmiešaný model, ktorý je rozšírením modelu SAR o priestorové oneskorenia vysvetľujúcich premenných, známy tiež ako priestorový model Durbin (SDM). Podobne ako pri modeloch SAR a SEM sme odhadli aj model SDM na základe metódy ML. Formulácia Durbinovho priestorového modelu (SDM) obsahujúceho aj priestorové oneskorenia vysvetľujúcich premenných je nasledovná:

$$\mathbf{y} = \rho \mathbf{W}\mathbf{y} + \mathbf{X}\boldsymbol{\beta} + \mathbf{W}\mathbf{X}\boldsymbol{\Theta} + \mathbf{u}$$


kde $\mathbf{W}\mathbf{X}$ označuje $(n \times k)$ rozmernú maticu priestorovo oneskorených vysvetľujúcich premenných a $\boldsymbol{\Theta}$ je $(k \times I)$ rozmerný vektor parametrov odrážajúci účinky exogénnej interakcie (Anselin, 2003). Durbinov model zaujíma v priestorovej ekonometrii kľúčovú pozíciu (Fischer a kol., 2010), nakoľko je z neho možné odvodiť v špeciálnych prípadoch množstvo ďalších modelov. Ak sa pozrieme na všeobecnú formuláciu modelu SDM, tak ak napríklad nie je možné zamietnuť nulovú hypotézu $\Theta = 0$, SDM sa stane modelom SAR, alebo ak nemožno zamietnuť nulovú hypotézu $\Theta = -\rho\beta$, dostaneme z modelu SDM model SEM. Pokiaľ však zavedieme obmedzenie $\rho = 0$ aj $\Theta = 0$, získame klasický lineárny regresný model (Chocholatá a Furková, 2017).

4 Výsledky práce

4.1 Priestorová analýza terciárneho vzdelania


V rámci stratégie EÚ pre rok 2020, v ktorej je zahrnutá aj oblasť vzdelania, v tejto časti diplomovej práce analyzujeme údaje o dosiahnutom terciárnom vzdelaní v 251 regiónoch Európskej únie NUTS 2 za obdobie 2012 - 2019, ktoré boli získané z databázy REGIO Eurostatu (2021a). Zo súboru obsahujúceho všetky regióny Európy (Eurostat, 2021b) bol v GeoDa extrahovaný súbor s 251 regiónmi NUTS 2 členských štátov EÚ. Pôvodný súbor údajov obsahujúci 272 regiónov NUTS 2 z 28 členských štátov EÚ bol zúžený vylúčením 20 ostrovných regiónov v krajinách Cyprus, Malta, Francúzsko, Fínsko, Španielsko, Grécko, Portugalsko a Taliansko, a tiež bol vylúčený jeden taliansky región kvôli chýbajúcim údajom.

Škatuľový graf dosiahnutého terciárneho vzdelania pre analyzované regióny NUTS 2 členských štátov EÚ za obdobie rokov 2012 - 2019 je znázornený na nasledujúcom obrázku (Obrázok 12). Priemerné hodnoty mali postupne rastúcu tendenciu z 34,96% na 39,89%. Pokles nerovností medzi analyzovanými regiónmi naznačujú klesajúce hodnoty medzikvartilového rozpätia (IQR) v období rokov 2012 - 2015, po ktorých nasledoval mierny nárast v roku 2016 a od roku 2017 znova mierne poklesol. Ďalej je potrebné spomenúť, že vo všetkých analyzovaných rokoch existuje minimálne jedna horná odľahlá hodnota, no žiadne spodné odľahlé hodnoty.



Obrázok 12: Škatuľový graf pre dosiahnuté terciárne vzdelanie (v%), veková skupina 30-34 rokov, 2012 - 2019 (zdroj: GeoDa, vlastné spracovanie)

Priemerné hodnoty analyzovaného ukazovateľa v období rokov 2012 - 2019 pre vybraných 26 členských štátov EÚ, počítané ako priemer všetkých regiónov na území daného štátu, sú uvedené na nasledujúcom grafe (Obrázok 13). Najvyšší podiel osôb vo veku 30-34 rokov s vysokoškolským vzdelaním je v Litve, najmenej v Rumunsku a v Taliansku. V priemere sa v EÚ-26 (nakoľko sme abstrahovali od ostrovných štátov Cyprus a Malta) zvýšil podiel ľudí vo veku 30-34 rokov, ktorí ukončili terciárne vzdelávanie, z 35,32% v roku 2012 na 41,65% v roku 2019. V deviatich členských štátoch (Belgicko, Írsko, Španielsko, Francúzsko, Litva, Luxembursko, Fínsko, Švédsko a Spojené kráľovstvo) bol cieľ 40% obyvateľov vo veku 30-34, ktorí ukončili terciárne vzdelanie splnený počas celého analyzovaného obdobia 2012 - 2019.




Obrázok 13: Dosiahnuté terciárne vzdelanie (v %, veková skupina 30-34 rokov) v členských štátoch EÚ-26, 2012 - 2019 (zdroj: Eurostat, vlastné spracovanie)

Je jasne viditeľné, že podiel ľudí vo veku 30-34 rokov s ukončeným terciárnym vzdelaním vykazuje rastúcu tendenciu takmer vo všetkých analyzovaných krajinách, s výnimkou Bulharska, Maďarska a Rumunska, kde môžeme pozorovať výkyvy smerom k zvýšeniu, no od určitého roku znova k zníženiu podielu terciárne vzdelaného obyvateľstva. V tejto súvislosti je tiež dôležité poznamenať, že najvyššiu tendenciu rastu počas skúmaných rokov môžeme sledovať napríklad v Grécku – z 27,11% v roku 2012 na 41,44% v roku 2019 ako aj na Slovensku, kde podiel terciárne vzdelaného obyvateľstva vzrástol z 27,13% v roku 2012 na 42,93% v roku 2019. Pokiaľ ide o cieľ stratégie Európa

2020, dosiahnuť najmenej 40% ľudí vo veku 30-34 rokov absolvujúcich terciárne vzdelanie, môžeme s vysokou pravdepodobnosťou predpokladať, že tento cieľ väčšina členských štátov do roku 2020 splnila, nakoľko 19 sledovaných štátov ho dosiahlo už v roku 2019.

Pre porovnanie sme na nasledujúcom grafe (Obrázok 14) znázornili priemerné hodnoty dosiahnutého nižšieho ako základného, základného a nižšieho stredoškolského vzdelania vo veku obyvateľstva medzi 30-34 v analyzovaných štátoch EÚ-26. Na rozdiel od dosiahnutého terciárneho vzdelania, pri tomto druhu vzdelania môžeme pozorovať klesajúcu tendenciu. Pokiaľ sa pozrieme na celkový priemer EÚ-26 v intervale rokov 2012 - 2019, môžeme vidieť, že tento podiel klesol zo 16,2% v roku 2012 na 13,6% v roku 2019, čo rovnako považujeme za zlepšenie vzdelanosti v analyzovaných rokoch pre EÚ-26 ako celok. Výnimku tvoria krajiny ako napríklad Bulharsko, Česko, Dánsko, Nemecko, Estónsko, Poľsko, či Slovinsko, kde sa podiel dosiahnutého nižšieho ako základného, základného a nižšieho stredoškolského vzdelania v priebehu rokov 2012 - 2019 výrazne nezmenil.




Obrázok 14: Dosiahnuté nižšie ako základné, základné a nižšie stredoškolské vzdelávanie (v %, veková skupina 30-34 rokov) v členských štátoch EÚ-26, 2012 - 2019 (zdroj: Eurostat, vlastné spracovanie)

Najnižšie hodnoty spomedzi sledovaných krajín môžeme vidieť v Česku, Poľsku či Slovinsku, kde sa podiel dosiahnutého spomínaného vzdelania pohybuje približne v okolí 5%, čo považujeme za pozitívny indikátor vzdelanosti pre tieto krajiny. Naopak vysoké podiely nižšieho dosiahnutého vzdelania zaznamenávame v Španielsku, Taliansku, Portugalsku a v Rumunsku. Tieto dosiahli podiel 25-45% v rámci sledovaného obdobia. Musíme však poznamenať, že pri Portugalsku zaznamenávame veľký pokles z 44,6% v roku 2012 na 29,2% v roku 2019, čo znamená, že zlepšili svoj podiel nižšieho ako základného, základného a nižšieho stredoškolského vzdelávania o viac ako 15 percentuálnych bodov v priebehu 7 rokov.

4.1.1 Mapovanie terciárneho vzdelania v EÚ


Ďalším krokom bolo znázornenie analyzovaných údajov pomocou kvantilových máp pre skúmané roky 2012 (Obrázok 15) a 2019 (Obrázok 16), kvôli ilustrovaniu nerovnomerného rozloženia dosiahnutého terciárneho vzdelania v priestore vrátane zachytenia existencie určitých rozdielov naprieč regiónmi vo vnútri analyzovaných krajín (Chocholatá a Furková, 2017). V roku 2012 sa regióny s najnižším podielom obyvateľov vo veku 30-34 rokov s ukončeným terciárnym vzdelaním nachádzali predovšetkým v Chorvátsku, Taliansku, Rumunsku a Slovensku. Do tejto kategórie však patria aj niektoré ďalšie regióny v strednej, východnej a južnej časti EÚ.



Obrázok 15: Kvantilová mapa dosiahnutého terciárneho vzdelania (v %, veková skupina 30-34 rokov), 2012 (zdroj: GeoDa, vlastné spracovanie)

V roku 2019 sa podiel osôb vo veku 30 až 34 rokov, ktoré ukončili vysokoškolské vzdelanie, zvýšil v porovnaní s rokom 2012, avšak stále veľmi nízke hodnoty boli zaznamenané pre regióny v Rumunsku a Bulharsku. Na druhej strane, najvyšší podiel

vysokoškolsky vzdelaných obyvateľov vo veku 30-34 rokov v roku 2012 bol zaznamenaný na celom území Litvy, ďalej vo francúzskom, britskom či fínskom regióne, ako aj v niektorých ďalších regiónoch nachádzajúcich sa hlavne v západnej a severnej Európe. V roku 2019 dominovali v najväčšej miere írské a švédske regióny, navyše s pretrvávajúcimi vysokými hodnotami v Litve. V porovnaní s rokom 2012 bolo možné do skupiny regiónov s najvyšším podielom vysokoškolsky vzdelanej populácie zahrnúť viac regiónov vo východnej a južnej Európe, ako napr. poľské a grécke regióny. Z tejto skupiny však na druhej strane ubudli niektoré regióny v Švédsku, Fínsku, či Španielsku.




Obrázok 16: Kvantilová mapa dosiahnutého terciárneho vzdelania (v %, veková skupina 30-34 rokov), 2019 (zdroj: GeoDa, vlastné spracovanie)

Škatuľové mapy umožňujú ďalšie zobrazovania rozdielov medzi regiónmi na národnej ako aj na nižšej úrovni. Tieto mapy sú špeciálnou formou kvartilovej mapy, no skladajú sa zo šiestich kategórií. Okrem štyroch kategórií zodpovedajúcich štyrom kvartilom sú špecifikované dve ďalšie kategórie pre horné a dolné odľahlé hodnoty. Ako môžeme vidieť na škatuľovej mape (Obrázok 17) a jej legende, prvý a posledný kvartil už nezodpovedajú presne jednej štvrtine pozorovaní, pretože dolné a horné odľahlé hodnoty sú zobrazené ako ďalšie kategórie (Anselin a kol., 2010).


V roku 2012 bola zistená jedna horná odľahlá hodnota (región Inner London) a rovnako tá istá horná odľahlá hodnota bola identifikovaná aj v roku 2019 (Obrázok 18). Pretože neboli zistené žiadne dolné odľahlé hodnoty, regiónmi s najnižšími hodnotami (okolo 25%) boli takmer všetky regióny Rumunska a Talianska. Obe mapy ukazujú, že regióny s vyšším (nižším) percentom populácie s uvažovanou úrovňou dosiahnutého vzdelania sa zvyčajne zoskupujú pri sebe, ale na druhej strane je tiež možné identifikovať

niektoré regióny s vyšším percentom „vzdelaného“ obyvateľstva v porovnaní so susednými regiónmi.



Obrázok 17: Škatuľová mapa pre uvažovanú úroveň dosiahnutého vzdelania v roku 2012
(zdroj: GeoDa, vlastné spracovanie)

V roku 2012 to boli napr. Bucuresti-Ilfov v Rumunsku, Bratislavský kraj na Slovensku, Praha v Českej republike alebo Berlín v Nemecku. V roku 2019 zasa Yugozađen v Bulharsku, Bucuresti-Ilfov v Rumunsku, Berlín v Nemecku alebo Wien v Rakúsku. To sa väčšinou týka regiónov hlavného mesta alebo regiónov s univerzitami či s vysokou koncentráciou aktivít spojených s výskumom a vývojom, pretože tieto regióny lákajú ľudí s vyššou kvalifikáciou a umožňujú im lepšie príležitosti na ďalšie vzdelávanie, lepšie kariérne vyhliadky a vyššie platy (Chocholatá a Furková, 2017).




Obrázok 18: Škatuľová mapa pre uvažovanú úroveň dosiahnutého vzdelania v roku 2019
(zdroj: GeoDa, vlastné spracovanie)

Aj keď vizualizácia pomocou kvantilových a škatuľových máp umožňuje analyzovať, či je dosiahnuté vzdelanie náhodne rozdelené medzi analyzované regióny alebo či existuje priestorové zoskupenie regiónov s podobným percentom ľudí s ukončeným terciárnym vzdelaním do veku 30-34 rokov, tieto prístupy neposkytujú žiadne informácie o štatistickej významnosti alebo nevýznamnosti zoskupovania jednotlivých regiónov (Rodríguez-Pose Tselios, 2007; Mitchell, 2013).

4.1.2 Priestorová autokorelácia


Aby sa potvrdilo, že poloha regiónu ovplyvňuje podiel ľudí s analyzovanou úrovňou dosiahnutého vzdelania, to znamená test priestorovej autokorelácie, je potrebné definovať priestorové susedstvá a priestorové váhy. Matica priestorových váh **W** bola definovaná tromi rôznymi spôsobmi, aby sa preukázala citlivosť jej špecifikácie na výsledky. Najskôr bola zadaná matica váh pre typ susedstva kráľovná (dva regióny sa považujú za susedov, ak majú spoločnú časť hranice), ďalej sme použili váhovú maticu 4 najbližších susedov a nakoniec matica **W** vychádzala z metriky euklidovskej vzdialenosti.

V prípade matice váh typu kráľovná mali regióny 1 až 11 susedov s najvyššou frekvenciou 5 susedov. Nasledujúci histogram (Obrázok 19) znázorňuje štruktúru susedstva typu „kráľovná“ pre sledované regióny EÚ-26. V celku je rozloženie susedstiev pre 251 regiónov EÚ symetricky rozdelené, s mediánom 5 susedov a priemerom 4,55. Minimálny počet susedov je 1, a maximum je 11 susedov. Ako si tiež môžeme všimnúť, najväčšia časť regiónov má 5 susedov, a tejto hodnote zodpovedá 58 regiónov. Okrem toho vidíme početnosť regiónov v každom intervale, ktorý predstavuje počet susedov.



Obrázok 19: Histogram matice typu „kráľovná“ (zdroj: GeoDa, vlastné spracovanie)

Na základe euklidovských váh vzdialenosti bol počet susedov podstatne vyšší, v intervale 1 až 69 susedov s najvyššou frekvenciou 38 susedov (Obrázok 20). Druhé najpočetnejšie frekvencie mali na rovnakej úrovni 54 a 57 susedov pri tomto druhu váh. Môžeme si tiež všimnúť, že v niektorých intervaloch susedstiev je početnosť nulová. To znamená, že žiaden z európskych regiónov nemá 3, 8, 34, 40, 53 ani 67 susedov.




Obrázok 20: Histogram matice typu „euklidovská vzdialenosť“ (zdroj: GeoDa, vlastné spracovanie)

Pokiaľ ide o rôzne špecifikácie matice $\mathbf{W}$, pomocou softvéru GeoDa sme vypočítali globálne Moranove I štatistiky pre každý rok analyzovaného obdobia. Dynamika Moranovho I počas obdobia 2012 - 2019 pre tri vyššie uvedené špecifikácie váhových matic je zachytená na nasledujúcom grafe (Obrázok 21). Je viditeľné, že globálne hodnoty Moranovho I v prípade matice váh typu kráľovná a váhovej matice typu 4 najbližších susedov boli podobné - pohybovali sa v intervale medzi 0,35 a 0,53. Avšak globálne hodnoty Moranovho I založené na euklidovskej matici váh vzdialenosti boli podstatne nižšie, medzi 0,2 a 0,4. Podobné výsledky získali tiež Chocholatá a Furková (2017).


V tejto súvislosti je dôležité spomenúť, že euklidovské váhové matice sa používajú v riadkovej štandardizovanej podobe, čo znamená, že súčtom prvkov každého riadku je 1 a každý sused konkrétneho regiónu má rovnakú váhu. Ako zdôraznil napríklad Mitchell (2013, s.16): „Váhy štandardizované podľa riadkov zvyšujú vplyv pravdepodobných presahov všade tam, kde má región málo susedov v porovnaní s vplyvom pravdepodobných presahov v regiónoch, kde dochádza k prelievaniu medzi mnohými susedmi.“ Ako bolo uvedené vyššie, počet susedov bol v použitých maticiach extrémne odlišný, čo môže slúžiť ako jedno z možných vysvetlení odlišných hodnôt globálnych Moranových I štatistík.

Vidíme tiež, že hodnoty globálnych Moranových I štatistík pre všetky druhy váhových matic sú väčšie ako očakávaná hodnota $E(I) = -1/(n-1) = -0,004$. Pomocou randomizačného prístupu založeného na 999 permutáciách sme preto preukázali štatisticky významnú pozitívnu priestorovú autokoreláciu počas celého analyzovaného obdobia. Je teda omnoho pravdepodobnejšie, že regióny s vysokým (nízkym) podielom obyvateľstva s uvažovanou úrovňou dosiahnutého vzdelania budú mať susedov s rovnako vysokým (nízkym) podielom obyvateľstva s vysokoškolským vzdelaním, ako je tomu v prípade čistej náhodnosti (Chocholatá a Furková, 2017).




Obrázok 21: Dynamika globálneho Moranovho I v rokoch 2012–2019 pre rôzne špecifikácie váhových matic (zdroj: vlastné spracovanie)

Vráťme sa ešte k matici váh pre susedstvo typu kráľovná, ktorej globálnu Moranovu I štatistiku pre rok 2019 znázorňuje nasledujúci bodový diagram (Obrázok 22). Z grafu môžeme pozorovať lineárny vzťah medzi sledovanými hodnotami terciárneho vzdelania pre rok 2019 a priestorovo oneskorenými hodnotami pre jednotlivé pozorovania. Sklon tejto priamky zodpovedá kladnej hodnote Moranovho I koeficienta a jeho hodnota 0,461 je uvedená v hornej časti grafu. Keďže je koeficient kladnej hodnoty, poukazuje na pozitívnu priestorovú autokoreláciu. Koeficient Moranovho I plní v tomto prípade funkciu regresného koeficienta. Podiely terciárne vzdelaného obyvateľstva sú znázornené na vodorovnej osi a ich priestorové oneskorenia na osi zvislej. Z grafu je tiež možné vidieť, že zhuk bodov je sprevádzaný prítomnosťou niekoľkých odľahlých hodnôt v 1. (high-high), 2. (low-high) a 4. (high-low) kvadrante. Nakoniec môžeme vybrať body v každom kvadrante a identifikovať miesta na mape spojené s každým zo štyroch typov priestorovej autokorelácie.




Obrázok 22: Moranov bodový diagram pre maticu váh typu kráľovná v roku 2019 (zdroj: GeoDa, vlastné spracovanie)

Na jednej strane globálna Moranova I štatistika poskytuje iba meranie globálnej priestorovej asociácie, pričom ignoruje podrobnosti špecifické pre daný región. Na druhej strane ukazovatele LISA umožňujú rozklad globálnych štatistík a určujú identifikáciu jednotlivých regionálnych pozorovaní (Anselin, 1995; Ahmed, 2011). Priestorové rozloženie a priestorové zoskupovanie založené na klastrových mapách LISA týkajúce sa rôznych váh (kráľovná, 4 najbližší susedia, euklidovská vzdialenosť) pre roky 2012 a 2019 sú znázornené na nasledujúcich mapách.



Obrázok 23: Klastrové mapy LISA dosiahnutého vzdelania pre maticu váh typu kráľovná v rokoch 2012 a 2019, (zdroj: GeoDa, vlastné spracovanie)

Podľa týchto máp existuje veľa regiónov vykazujúcich pozitívnu priestorovú autokoreláciu (HH, LL) a iba niekoľko regiónov s významnou negatívnou priestorovou autokoreláciou (HL, LH). Výsledky za jednotlivé roky sa však líšia v dôsledku použitej matice váh. Štatisticky významná pozitívna priestorová autokorelácia typu HH znamená, že regióny aj ich susedia dosahovali nadpriemerné hodnoty vo výške dosiahnutého terciárneho vzdelania. V roku 2012 bolo na základe váhovej matice typu kráľovná (Obrázok 23) a 4 najbližších susedov (Obrázok 24) identifikovaných 87 a 74 oblastí so štatisticky významnou pozitívnou autokoreláciou. Na základe váh euklidovskej vzdialenosti (Obrázok 25) sú znázornené rozšírenejšie klastre. Až pri 153 oblastiach bola preukázaná významná pozitívna autokorelácia. Výsledky za rok 2019 boli mierne odlišné. Zaznamenali sme 65 a 56 štatisticky významných oblastí s pozitívnou autokoreláciou na základe váhovej matice kráľovnej a 4 najbližších susedov. Euklidovská matica váh vzdialenosti identifikovala 114 oblastí so štatisticky významnou pozitívnou autokoreláciou. Významná pozitívna autokorelácia HH bola zistená pre regióny nachádzajúce sa hlavne v západných a severných krajinách Európy, zatiaľ čo významná pozitívna autokorelácia typu LL bola identifikovaná pre regióny nachádzajúce sa hlavne v Taliansku, Rumunsku, Grécku, ako aj v niektorých regiónoch strednej Európy. Umiestnenie regiónov sa v porovnaní s rokom 2012 významne nezmenilo.




Obrázok 24: Klastrové mapy LISA dosiahnutého vzdelania pre maticu váh typu 4 najbližší susedia v rokoch 2012 a 2019, (zdroj: GeoDa, vlastné spracovanie)

To isté platí pre priestorovo odľahlé hodnoty – t.j. regióny so štatisticky významnou negatívnou autokoreláciou LH a HL. Pri výskyte autokorelácie typu LH sú hodnoty v

analyzovanom regióne nižšie ako priemer, zatiaľ čo hodnoty v susedných regiónoch sú nad priemerom. V prípade matice váh typu kráľovná bolo identifikovaných 6 oblastí typu LH v roku 2012 (Sjælland v Dánsku, Flevoland a Zeeland v Holandsku, Prov. Hainaut v Belgicku, Basse-Normandie a Auvergne vo Francúzsku) a taktiež 6 oblastí v roku 2019 (Sjælland v Dánsku, Flevoland a Zeeland v Holandsku, Kent v Spojenom kráľovstve, Languedoc-Roussillon vo Francúzsku a La Rioja v Španielsku).

Štatisticky významná negatívna autokorelácia typu HL indikujúca nadpriemerné hodnoty v regióne obklopenom susedmi s podpriemernými hodnotami sa zistila zväčša v regiónoch niektorých hlavných miest alebo v regiónoch s univerzitami a výskumnými centrami. Je to hlavne preto, že tieto regióny priťahujú vysoko kvalifikovanú populáciu, umožňujú lepšie príležitosti pre ďalšie vzdelávanie a lepšie kariérne vyhliadky. Pri matici kráľovnej sme zaznamenali 8 oblastí tohto typu v roku 2012 (Leipzig a Oberbayern v Nemecku, Bratislavský kraj na Slovensku, Vzhodna Slovenija v Slovinsku, Közép-Magyarország v Maďarsku, Ilfov v Rumunsku, Yugozapaden v Bulharsku a Attiki v Grécku) a 6 takýchto oblastí v roku 2019 (Hamburg a Brandenburg v Nemecku, Jihovýchod v Českej republike, Közép-Magyarország v Maďarsku, Ilfov v Rumunsku a Yugozapaden v Bulharsku).



Obrázok 25: Klastrové mapy LISA dosiahnutého vzdelania pre váhovú maticu euklidovskej vzdialenosti v rokoch 2012 a 2019, (zdroj: GeoDa, vlastné spracovanie)

Pomocou špecifikácie váhovej matice 4 najbližších susedov sme identifikovali 4 regióny typu LH (Flevoland a Zeeland v Holandsku, Prov. Hainaut v Belgicku a Basse-Normandie vo Francúzsku) v roku 2012 a 5 regiónov v roku 2019 (Flevoland v Holandsku,

Prov. Hainaut v Belgicku, Kent v Spojenom kráľovstve, La Rioja v Španielsku a Niederösterreich v Rakúsku). Zaznamenali sme tiež 7 oblastí typu HL v roku 2012 (Leipzig v Nemecku, Praha v Českej republike, Bratislavský kraj na Slovensku, Közép-Magyarország v Maďarsku, Ilfov v Rumunsku, Yugozađen v Bulharsku a Attiki v Grécku) a 6 oblastí (Hamburg a Berlín v Nemecku, Praha v Českej republike, Közép-Magyarország v Maďarsku, Ilfov v Rumunsku a Yugozađen v Bulharsku) v roku 2019.

Najvyšší počet regiónov so štatisticky významnými negatívnymi priestorovými autokoreláciami bol špecifikovaný pre euklidovskú maticu váh vzdialenosti s 31 regiónmi v roku 2012 a 42 regiónmi v roku 2019 patriacimi do rôznych krajín EÚ (Obrázok 25). Môžeme si tiež všimnúť, že regióny typu LH sa sústreďovali skôr v severozápadnej časti EÚ a regióny typu HL zväčša v strednej a južnej časti EÚ. Výsledky priestorovej analýzy odhalili pretrvávajúce rozdiely na uvažovanej úrovni dosiahnutého vzdelania v regiónoch EÚ počas analyzovaného obdobia, podobne ako uviedol v svojej práci Rodríguez-Pose Tselios (2007). Avšak, ako vidíme na škatulových mapách (Obrázky 17-18), v dolných ale ani v horných odľahlých hodnotách nebol identifikovaný významný rozdiel v roku 2019 v porovnaní s rokom 2012.

Štatistická významnosť regiónov s priestorovými asociáciami HH a LL sa počas analyzovaného obdobia až na niekoľko výnimiek významne nezmenila (Obrázky 23-25), môže byť preto užitočná informácia a veľká výzva pre orgány EÚ, aby efektívnejšie distribuovali obmedzené zdroje na vytváranie atraktívnejších pracovných príležitostí, a tým povzbudzovali obyvateľstvo k dosiahnutiu vyššieho vzdelania, lepších vyhliadok na kariéru a vyššej životnej úrovne (Chocholatá a Furková, 2017).

4.2 Regresná analýza

V tejto časti sa zameriame na ekonometrickú analýzu – odhad regresných modelov OLS, SAR, SEM a SDM odrážajúcich závislosť medzi dosiahnutým terciárnym vzdelaním (závislá premenná) a dvoma ďalšími ukazovateľmi, ktorými sú regionálny HDP na obyvateľa a hustota zaľudnenia vybraných európskych regiónov. Spomínané priestorové modely odhadujeme najskôr na základe váh typu kráľovná a neskôr aj pre váhy euklidovskej vzdialenosti. Nakoľko pri testovaní priestorovej autokorelácie v prípade váhovej matice typu 4 najbližších susedov sme dosahovali nesymetrickosť, rozhodli sme sa ekonometrické modelovanie pre tento typ váh vynechať.

Ako už vieme, priestorové ekonometrické modely možno vo všeobecnosti rozdeliť podľa troch rôznych efektov interakcie. Jednou z nich je interakcia medzi endogénnymi

závislými premennými, druhou je interakcia medzi exogénnymi nezávislými premennými a treťou je interakcia medzi náhodnými chybami (Elhorst, 2014). Preto rôznym efektom interakcie zodpovedajú aj tri druhy priestorových ekonometrických modelov: model priestorovej autoregresie (SAR), ktorý sa skladá iba z výrazu priestorového oneskorenia závislej premennej, ďalej priestorový Durbinov model (SDM) obsahujúci priestorovo oneskorenú závislú premennú a tiež priestorovo oneskorené nezávislé premenné, a model priestorových chýb (SEM), ktorý obsahuje iba priestorové oneskorenie náhodnej chyby merania.

4.2.1 *Lineárny model OLS*

Proces priestorovej regresnej analýzy začneme odhadom klasického lineárneho modelu metódou najmenších štvorcov. Výsledky odhadnutého lineárneho modelu sú zobrazené na nasledujúcich obrázkoch (Obrázky 26-27). Na základe získaného odhadu môžeme vidieť, že výstup je rozdelený do troch častí. Prvá časť (Obrázok 26) znázorňuje klasické štatistické ukazovatele a charakteristiky regresného modelu, ako priemer, štandardná odchýlka, koeficient determinácie a podobne. Za kritérium kvality modelu sa používa podiel vysvetleného súčtu štvorcov k celkovému súčtu štvorcov. Túto mieru môžeme opísať koeficientom determinácie R^2 , ktorý vyjadruje, akú časť celkovej variability závislej premennej vysvetľuje model, teda aká časť celkovej variability je determinovaná kvantifikovaným ekonometrickým modelom. V modeli OLS je R^2 príliš nízka, len 10,55% celkovej variability je vysvetlená modelom. Tento model však potvrdzuje očakávaný pozitívny vzťah medzi dosiahnutým terciárnym vzdelaním v roku 2019 a HDP v roku 2018 ($p < 0.01$) ako aj medzi sledovaným vzdelaním a hustotou zaľudnenia v roku 2018 ($p < 0.05$). Oba sledované ukazovatele sú teda v rámci modelu OLS štatisticky významné.

Druhá časť obsahuje testovacie štatistiky na zistenie multikolinearity, normality rezíduí a heteroskedasticity (Obrázok 27). Ukazovateľ multikolinearity je menší ako 30 a preto nepredpokladáme problém s multikolinearitou. Test Jarque-Bera meria rozdiel medzi výberovou šikmosťou (3. moment) a špicatosťou (4. moment) rezíduí a šikmosťou a špicatosťou normálneho rozdelenia. V našom prípade údaj v stĺpci "probability" hovorí o tom, že náhodné chyby nemajú normálne rozdelenie, čo identifikuje ďalší problém s týmto druhom modelu. Pretože nasledujúce testy priestorovej závislosti sú podmienené normálnym rozdelením, je potrebné interpretovať výsledky testov veľmi opatrne.

REGRESSION				

SUMMARY OF OUTPUT: ORDINARY LEAST SQUARES ESTIMATION				
Data set	:	NUTS2EUbez21		
Dependent Variable	:	edu_2019	Number of Observations:	251
Mean dependent var	:	39.894	Number of Variables	: 3
S.D. dependent var	:	10.6064	Degrees of Freedom	: 248
R-squared	:	0.105453	F-statistic	: 14.6177
Adjusted R-squared	:	0.098239	Prob(F-statistic)	: 9.9718e-007
Sum squared residual	:	25258.8	Log likelihood	: -934.894
Sigma-square	:	101.85	Akaike info criterion	: 1875.79
S.E. of regression	:	10.0921	Schwarz criterion	: 1886.36
Sigma-square ML	:	100.633		
S.E. of regression ML	:	10.0316		

Variable	Coefficient	Std. Error	t-Statistic	Probability

CONSTANT	34.2833	1.38369	24.7767	0.00000
gdp_2018	0.000173125	4.59497e-005	3.76771	0.00021
pdens_2018	0.00216076	0.000942232	2.29324	0.02267

Obrázok 26: Odhad lineárneho modelu OLS – štatistické ukazovatele (zdroj: GeoDa, vlastné spracovanie)

Tretia séria testov špecifikuje, či v daných dátach existuje problém s heteroskedasticitou. V dvoch prípadoch, a to v Breusch-Paganovom a Koenker-Bassetovom teste prijímame nulovú hypotézu o homoskedasticite, teda konštantnosti rozptylov, avšak pri Whiteovom teste identifikujeme existenciu heteroskedasticity. Breusch-Paganov test nemusí dobre fungovať vtedy, keď náhodné chyby nemajú normálne rozdelenie. Pre takéto prípady je možné použiť Whiteov všeobecný test heteroskedasticity, čo je vlastne zvláštny prípad Breusch-Pagana (Williams, 2020). Zaznamenanie heteroskedasticity v modeli však nemusí byť nevyhnutne negatívny jav, pretože odchýlky náhodných porúch by mohli byť pozitívne ovplyvnené priestorovou závislosťou v analyzovaných dátach. Dôvodom je, že pri určení konkrétnej formy nestability (variability reziduí) je kľúčovou geografická poloha pozorovaní a tiež fakt, že heteroskedasticita môže byť ťažšie odlíšiteľná od priestorovej autokorelácie, kedy už štandardné metódy nestačia (napr. v prípade prítomnosti zhluku extrémnych hodnôt reziduí).

Tretia časť je z pohľadu priestorovej analýzy kľúčová. Na základe priestorových váh sú určené charakteristiky priestorovej závislosti. Na vyhodnotenie priestorovej závislosti modelu sa vykonáva viacero testov. Najdôležitejším testom je Moranovo I. Jeho hodnota 0,4997 potvrdzuje vysokú štatistickú významnosť a indikuje problém priestorovej autokorelácie v modeli. „Samotný koeficient je však dosť citlivý aj na abnormality v modeli. Preto je doplnený piatimi Langrangeovými multiplikátormi (LM). Dva sú pre identifikáciu modelu s priestorovým posunom (SAR), dva pre model s priestorovými chybami (SEM) a posledný pre určenie SARMA modelu, čo je vlastne kombinácia oboch predchádzajúcich.“ (Janotka, 2013, s.13)

```

REGRESSION DIAGNOSTICS
MULTICOLLINEARITY CONDITION NUMBER    4.595512
TEST ON NORMALITY OF ERRORS
TEST          DF          VALUE          PROB
Jarque-Bera      2          12.4315          0.00200

DIAGNOSTICS FOR HETEROSKEDASTICITY
RANDOM COEFFICIENTS
TEST          DF          VALUE          PROB
Breusch-Pagan test    2          3.9221          0.14071
Koenker-Bassett test  2          3.0924          0.21306
SPECIFICATION ROBUST TEST
TEST          DF          VALUE          PROB
White            5          42.1092          0.00000

DIAGNOSTICS FOR SPATIAL DEPENDENCE
FOR WEIGHT MATRIX : kralovna 1 radu
(row-standardized weights)
TEST          MI/DF          VALUE          PROB
Moran's I (error)      0.4997          11.1575          0.00000
Lagrange Multiplier (lag)    1          103.2345          0.00000
Robust LM (lag)          1          4.5826          0.03230
Lagrange Multiplier (error)  1          118.0576          0.00000
Robust LM (error)        1          19.4057          0.00001
Lagrange Multiplier (SARMA)  2          122.6401          0.00000
===== END OF REPORT =====

```

Obrázok 27: Odhad lineárneho modelu OLS – charakteristiky priestorovej závislosti
(zdroj: GeoDa, vlastné spracovanie)

V našom prípade sú oba klasické LM testy vysoko štatisticky významné. Rozhodnutie, aký model si vybrať, určuje preto robustná verzia LM. Tá je na 5% hladine významnosti štatisticky významná pre oba modely, ale na 1% hladine významnosti je štatisticky významná len pre model s priestorovými chybami SEM. Ak by sme teda počítali s 1% hladinou významnosti, robustná miera LM modelu priestorovej chyby SEM je stále významná, ale robustná miera LM modelu priestorového oneskorenia SAR sa stáva nevýznamnou. Nakoľko sú však obidva testy a ich robustné verzie na 5% hladine štatisticky významné, je ťažké poskytnúť jednoznačný záver o tom, ktorý z dvoch modelov, SAR alebo SEM, je vhodnejší. Preto sme sa ďalej rozhodli pre odhad oboch z nich.

4.2.2 Priestorový autoregresný model SAR

Na ďalšom obrázku (Obrázok 28) vidíme výsledky odhadu modelu priestorového oneskorenia SAR. Skladá sa opäť z viacerých častí, pričom začína všeobecnými informačnými testami. Všimnime si, že okrem informácií, ktoré sa objavili v predchádzajúcom výstupe regresie OLS, máme určený záznam priestorovej váhy: kráľovná 1. rádu. Ako ďalší indikátor sa objavila priestorovo oneskorená závislá premenná vzťahujúca sa k terciárnemu vzdelaniu v roku 2019.

Pre porovnanie klasického a priestorovo posunutého modelu využijeme tri ukazovatele z obidvoch výstupov. Nie je však vhodné porovnávať lineárny model OLS s priestorovými modelmi na základe R^2 , keďže pre priestorový model je koeficient determinácie iný, tzv.

pseudo R^2 (Anselin, 1988). Avšak, Log likelihood je pre model s priestorovým posunom väčší, čo hovorí v prospech priestorového modelu. Akaikeho informačné kritérium a Schwarzovo kritérium oproti štandardnému lineárnemu modelu klesli, čo znamená opäť potvrdenie priestorového modelu. Mierne zmeny sme zaznamenali vo významnosti jednotlivých vysvetľujúcich premenných. Nezaznamenali sme však takú zmenu, ktorá by zmenila pôvodne štatisticky významný vzťah na nevýznamný na definovanej hladine významnosti. Naopak, hustota zaľudnenia ako jedna z vysvetľujúcich premenných sa stala v tomto modeli významnou aj na 1% hladine významnosti. Ukázali sme však, že vysoko významný je priestorový autoregresný parameter Rho, ktorý meria závislosť sledovaných ukazovateľov. Tento parameter vysvetľuje, že hodnoty sledovaného terciárneho vzdelania sú korelované s hodnotami dosiahnutého terciárneho vzdelania v susedných regiónoch.

```

REGRESSION
-----
SUMMARY OF OUTPUT: SPATIAL LAG MODEL - MAXIMUM LIKELIHOOD ESTIMATION
Data set      : NUTS2EUbez21
Spatial Weight : kralovna 1 radu
Dependent Variable : edu_2019 Number of Observations: 251
Mean dependent var : 39.894 Number of Variables : 4
S.D. dependent var : 10.6064 Degrees of Freedom : 247
Lag coeff. (Rho) : 0.558501

R-squared      : 0.407302 Log likelihood : -894.629
Sq. Correlation : - Akaike info criterion : 1797.26
Sigma-square   : 66.6759 Schwarz criterion : 1811.36
S.E of regression : 8.16553

-----
Variable      Coefficient      Std. Error      z-value      Probability
-----
W_edu_2019    0.558501      0.056824      9.82862      0.00000
CONSTANT      13.8271      2.27341      6.08209      0.00000
gdp_2018      0.000119454    3.86661e-005    3.08938      0.00201
pdens_2018    0.00237814    0.000762407    3.11925      0.00181
-----

REGRESSION DIAGNOSTICS
DIAGNOSTICS FOR HETEROSKEDASTICITY
RANDOM COEFFICIENTS
TEST          DF      VALUE      PROB
Breusch-Pagan test      2      4.4889      0.10599

DIAGNOSTICS FOR SPATIAL DEPENDENCE
SPATIAL LAG DEPENDENCE FOR WEIGHT MATRIX : kralovna 1 radu
TEST          DF      VALUE      PROB
Likelihood Ratio Test    1      80.5302      0.00000
===== END OF REPORT =====

```

Obrázok 28: Odhad modelu SAR (zdroj: GeoDa, vlastné spracovanie)

Po úvodných štatistikách sú v nasledujúcich častiach uvedené testy na identifikáciu heteroskedasticity a priestorovej závislosti. Vidíme, že pravdepodobnosť 10,6% v Breusch-Paganovom teste naznačuje, že v modeli sa po zavedení priestorového oneskorenia stále zachováva homoskedasticita, čo predstavuje konštantnosť rozptylu náhodných porúch, a teda aj rezíduí. Taktiež hodnota Likelihood Ratio testu v modeli priestorového oneskorenia je stále významná. Môžeme teda prijať záver, že zavedenie priestorového oneskorenia

zlepšilo štatistické parametre modelu a bola potvrdená významnosť priestorového autoregresného parametra ρ .

4.2.3 Model priestorovej chyby SEM

Model priestorového oneskorenia SAR je pravdepodobne najbežnejšou špecifikáciou a možno najbežnejším spôsobom uvažovania o priestorovej závislosti. Máme však možnosť skúmať priestorovú závislosť aj spôsobom, že do regresnej rovnice zahrnieme regresný poruchový člen prostredníctvom modelu SEM. V porovnaní s výstupom priestorovo posunutého modelu SAR máme v rámci odhadu SEM (Obrázok 29) k dispozícii nový indikátor, a to koeficient priestorovo korelovaných chýb (Lambda). V tomto prípade má pozitívny efekt a je vysoko významný. V odhade SEM sa oproti modelu SAR zlepšila významnosť modelu, čo sa prejavilo pri vyšších hodnotách koeficienta determinácie (R^2) a Log likelihood. Rovnako ako v priestorovom modeli oneskorenia, vplyvy nezávislých premenných na závislú premennú zostávajú približne rovnaké. Pokiaľ sa pozrieme na doteraz odhadnuté modely, model SEM dosahuje najnižšie hodnoty v rámci Akaikeho a Schwarzovho kritéria, čo taktiež hovorí o kvalite a dobrej prispôbivosti tohto modelu.

```

REGRESSION
-----
SUMMARY OF OUTPUT: SPATIAL ERROR MODEL - MAXIMUM LIKELIHOOD ESTIMATION
Data set      : NUTS2EUbez21
Spatial Weight : kralovna 1 radu
Dependent Variable : edu_2019 Number of Observations: 251
Mean dependent var : 39.894024 Number of Variables : 3
S.D. dependent var : 10.606395 Degrees of Freedom : 248
Lag coeff. (Lambda) : 0.616808

R-squared      : 0.456600 R-squared (BUSE) : -
Sq. Correlation : - Log likelihood : -886.769482
Sigma-square    : 61.1301 Akaike info criterion : 1779.54
S.E of regression : 7.81857 Schwarz criterion : 1790.12

-----
Variable      Coefficient      Std.Error      z-value      Probability
-----
CONSTANT      32.5118      1.90304      17.0842      0.00000
gdp_2018      0.000249481  5.02492e-005  4.96487      0.00000
pdens_2018    0.00213886   0.000752947   2.84065      0.00450
LAMBDA        0.616808     0.0536143     11.5045      0.00000
-----

REGRESSION DIAGNOSTICS
DIAGNOSTICS FOR HETEROSKEDASTICITY
RANDOM COEFFICIENTS
TEST          DF      VALUE      PROB
Breusch-Pagan test      2      11.0592     0.00397

DIAGNOSTICS FOR SPATIAL DEPENDENCE
SPATIAL ERROR DEPENDENCE FOR WEIGHT MATRIX : kralovna 1 radu
TEST          DF      VALUE      PROB
Likelihood Ratio Test    1      96.2487     0.00000
===== END OF REPORT =====

```

Obrázok 29: Odhad modelu SEM (zdroj: GeoDa, vlastné spracovanie)

Nevýhodou tohto modelu v porovnaní s modelom SAR je identifikácia problému s heteroskedasticitou, ktorú potvrdil Breusch-Paganov test na 1% hladine významnosti a ktorej sa nám doteraz darilo vyhýbať. Významnú hodnotu však nadobúda test Likelihood Ratio, čo potvrdzuje silnú významnosť parametra λ . Preto môžeme prijať záver, že umožnenie korelovaného priestorového poruchového člena zlepšilo prispôbenie modelu.

4.2.4 Durbinov priestorový model SDM

V súvislosti s už spomínanými priestorovými modelmi stojí za zmienku, že niektorí autori (napr. LeSage a Fischer, 2008) kritizujú výber špecifikácie priestorového modelu iba na základe diagnostických testov SAR a SEM, a zdôrazňujú potrebu uvažovania zmiešaného priestorového modelu - model SAR rozšírený o priestorové oneskorenia vysvetľujúcich premenných, známy tiež ako Durbinov priestorový model, a to najmä v prípade vynechaných premenných. V rámci regresnej analýzy preto okrem vyššie uvedených modelov odhadujeme aj priestorový Durbinov model SDM (Obrázok 30).

```
SUMMARY OF OUTPUT: SPATIAL LAG MODEL - MAXIMUM LIKELIHOOD ESTIMATION
Data set      : NUTS2EUbez21
Spatial Weight : kralovna 1 radu
Dependent Variable : edu_2019 Number of Observations: 251
Mean dependent var : 39.894 Number of Variables : 6
S.D. dependent var : 10.6064 Degrees of Freedom : 245
Lag coeff. (Rho) : 0.609873

R-squared      : 0.466808 Log likelihood : -883.999
Sq. Correlation : - Akaike info criterion : 1780
Sigma-square   : 59.9817 Schwarz criterion : 1801.15
S.E of regression : 7.74479

-----
Variable      Coefficient    Std.Error    z-value    Probability
-----
W_edu_2019    0.609873    0.0539332    11.3079    0.00000
CONSTANT      14.9175    2.34874    6.35127    0.00000
gdp_2018      0.000285122    5.2964e-005    5.38331    0.00000
pdens_2018    0.00207073    0.000746836    2.77266    0.00556
LAGgdp2018    -0.000251741    6.67087e-005    -3.77374    0.00016
LAGpde2018    -0.00347003    0.00251028    -1.38233    0.16687
-----

REGRESSION DIAGNOSTICS
DIAGNOSTICS FOR HETEROSKEDASTICITY
RANDOM COEFFICIENTS
TEST
Breusch-Pagan test    DF    VALUE    PROB
                     4    12.0419    0.01704

DIAGNOSTICS FOR SPATIAL DEPENDENCE
SPATIAL LAG DEPENDENCE FOR WEIGHT MATRIX : kralovna 1 radu
TEST
Likelihood Ratio Test    DF    VALUE    PROB
                     1    97.0757    0.00000
===== END OF REPORT =====
```

Obrázok 30: Odhad modelu SDM (zdroj: GeoDa, vlastné spracovanie)

Môžeme si všimnúť, že štatistické ukazovatele tohto modelu dosahujú zatiaľ najlepšie hodnoty v porovnaní s predošlými modelmi pri koeficiente determinácie, ktorý vysvetľuje

46,68% modelu, čo je zatiaľ najvyššia dosiahnutá hodnota v rámci tohto ukazovateľa. Taktiež test Likelihood Ratio zostáva štatisticky významný. Problém v tomto modeli nastáva pri oneskorenej premennej hustota zaľudnenia, ktorý nie je významný ani na 5% hladine významnosti. Hodnota Akaikeho kritéria je porovnateľná s predchádzajúcim modelom SEM, takže pri tomto teste nezaznamenávame zlepšenie, ale ani zhoršenie. Avšak, čo sa týka homoskedasticity v modeli SDM, môžeme konštatovať, že na 1% hladine významnosti prijímame nulovú hypotézu o homoskedasticite.

Pri porovnaní Durbinovko priestorového modelu s modelmi priestorového oneskorenia (SAR) a priestorových chýb (SEM) môžeme vidieť, že sledované kritériá sú najuspokojivejšie práve pri modeli SDM, čo len potvrdilo, že je výhodné uvažovať aj s týmto priestorovým modelom. Môžeme si však všimnúť, že všetky tri priestorové modely SAR, SEM aj SDM prinášajú zlepšenie oproti pôvodnému lineárnemu modelu OLS. Preto sme dospeli k záveru, že zaradenie priestorovej zložky zlepší významnosť analyzovaného ekonometrického modelu.

4.2.5 *Váhy kráľovnej verzus euklidovská vzdialenosť*

V tejto časti si priblížime dôležitosť voľby váh pri odhade spomínaných ekonometrických modelov. Veľmi často sa pre odhad modelov používajú práve váhy kráľovnej, na základe ktorých sme odhadovali modely v predchádzajúcich častiach. Nezriedka sa pri odhadoch využívajú aj váhy na základe euklidovskej vzdialenosti. Ďalej preto uvedieme výsledky regresnej analýzy pre oba druhy váh, pokúsime sa ich porovnať a prijať čo možno najlepší záver pre skúmané ukazovatele - odhadovaný model odrážajúci závislosť medzi dosiahnutým terciárnym vzdelaním, oneskoreným hrubým domácim produktom a oneskorenou hustotou zaľudnenia. Výsledky sú uvedené osobitne pre váhy kráľovnej (Tabuľka 1) a váhy euklidovskej vzdialenosti (Tabuľka 2).¹

V prvom kroku bol na základe OLS odhadnutý klasický lineárny regresný model. Výsledky odhadov sú zhrnuté v tabuľkách 1 a 2 (stĺpec: Lineárny model). Všetky parametre β_0 , β_1 a β_2 boli štatisticky významné, bol potvrdený očakávaný pozitívny vzťah medzi dosiahnutým vzdelaním, regionálnym HDP a hustotou zaľudnenia v danom regióne. R^2 bola však veľmi nízka a diagnostické štatistiky - Moranova I analýza aplikovaná na regresné reziduály a Lagrangeove multiplikátory naznačovali, že môžeme jednoznačne

¹ Kým výstupy z GeoDa s využitím matice kráľovná sme uviedli v podkapitolách 4.2.1 až 4.2.4, výstupy s využitím matice euklidovskej vzdialenosti sú uvedené v prílohách 1-5

zamietnuť nulovú hypotézu o priestorovej nezávislosti, čo znamená, že by sa mal brať do úvahy priestorový aspekt.

	Lineárny model	SAR model	SEM model	SDM model
Odhad	OLS	ML	ML	ML
β_0	34.283**** ²	13.8271***	32.5118***	14.9175***
β_1	0.00017***	0.000119***	0.000249***	0.00029***
β_2	0.00216**	0.002378***	0.002139***	0.00207**
λ	-	-	0.616808***	-
ρ	-	0.5585***	-	0.60987***
Θ_1	-	-	-	-0.00025***
Θ_2	-	-	-	-0.00347
R^2	0.10545	0.40730	0.45660	0.46681
Log likelihood	-934.894	-894.629	-886.769	-883.999
AIC	1875.79	1797.26	1779.54	1780
Diagnostické testy				
Moran's I (error)	11.1575***	-	-	-
LM (lag)	103.2345***	-	-	-
Robust LM (lag)	4.5826**	-	-	-
LM (error)	118.0576***	-	-	-
Robust LM (error)	19.4057***	-	-	-
Moran's I (spatial residual)	-	-0.010	-0.046	-0.034

Tabuľka 1: Výsledky odhadu lineárneho regresného modelu, modelu SAR, modelu SEM a modelu SDM, váhy: kráľovná (zdroj: vlastné spracovanie)

Pretože oba testy LM aj ich robustné verzie na základe matice váh kráľovnej boli vysoko významné, bolo ťažké vyjadriť jednoznačný záver o tom, ktorý z dvoch modelov, či SAR alebo SEM je vhodnejší. V rámci odhadu lineárneho regresného modelu na základe euklidovskej vzdialenosti sme identifikovali nevýznamnosť robustnej verzie pre SAR model, čo naznačovalo model SEM za vhodnejší. Napriek tomu sme sa rozhodli odhadnúť všetky spomínané priestorové modely (teda aj SAR a SDM) s cieľom porovnať výsledky pre rôzne matice váh. Výsledky odhadu ML pre SAR a SEM modely sú tiež uvedené v

²

Symbole *** a ** označujú štatistickú významnosť pri hladine významnosti 1% a 5%

tabuľkách 1 a 2 (stĺpce: SAR model, SEM model). Pokiaľ sa pozrieme na váhy kráľovnej, všetky odhadované parametre boli štatisticky významné, hodnoty regresných parametrov β_1 a β_2 potvrdzujú pozitívny oneskorený vplyv HDP a hustoty zaľudnenia na dosiahnuté terciárne vzdelanie. Štatistická významnosť priestorových parametrov ρ a λ potvrdzuje silnú pozitívnu a významnú priestorovú autokoreláciu, to znamená prítomnosť priestorových efektov v susedných regiónoch. Preto vyššie percento „vzdelanej“ populácie v konkrétnom regióne bude mať tendenciu zvyšovať mieru vzdelanosti v susedných regiónoch. Štatistickú významnosť modelov SAR a SEM potvrdili nízke hodnoty Moranovej I štatistiky použitej na zodpovedajúce priestorové reziduá, čo indikuje neprítomnosť zvyškovej priestorovej autokorelácie. Zahrnutie priestorovej zložky sa tak javí ako nevyhnutné z hľadiska prekonania problému s pravdepodobne skreslenými výsledkami, a teda so zavádzajúcimi závermi z odhadu nepriestorových modelov.

Nakoniec bol pre oba druhy váh odhadnutý sa aj model SDM (stĺpce: SDM model). Ako vidíme z tabuľky 1 aj tabuľky 2, parametre β_1 a ρ boli v oboch prípadoch štatisticky významné na 1% hladine významnosti, avšak pri parametri β_0 sme zaznamenali pokles štatistickej významnosti z 1% hladiny významnosti pri váhach kráľovnej na 5% hladinu významnosti pri váhach euklidovskej vzdialenosti. Parameter β_2 si udržal významnosť pri oboch druhoch váhovej matice na 5% hladine významnosti. Podobná situácia nastáva v prípade parametra θ_1 , ktorý bol v prípade váh kráľovnej (Tabuľka 1) aj pri euklidovských váhach (Tabuľka 2) štatisticky významný pri 1% hladine významnosti, avšak parameter θ_2 , vzťahujúci sa na priestorovo posunutý vplyv hustoty zaľudnenia, nepreukázal štatistickú významnosť ani v jednom prípade. Negatívne hodnoty parametrov theta naznačujú, že vyšší hrubý domáci produkt, prípadne vyššia hustota zaľudnenia v susedných regiónoch, spojený okrem iného s lepšími kariérnymi príležitosťami a lepším ekonomickým blahobytom, priláka určitý podiel „vzdelanejšej“ populácie na prechod do týchto regiónov. Následkom toho je, že percentuálny podiel populácie s úrovňou dosiahnutého vzdelania v analyzovanom regióne poklesne (Chocholatá a Furková, 2017).

Pokiaľ ide o štatistickú významnosť parametrov a ďalšie charakteristiky modelov, najmä hodnoty AIC, v oboch prípadoch sme uprednostnili model SDM, pri váhach kráľovnej aj pri euklidovskej vzdialenosti. Robustné verzie pri odhade klasického lineárneho regresného modelu nám však naznačovali efektívnosť modelu SEM. Aj tento model dosahoval uspokojivé výsledky, dokonca hodnoty AIC boli porovnateľné s modelom SDM, avšak pri modeli SDM sme identifikovali nižšie záporné hodnoty Log likelihood v porovnaní s ostatnými modelmi, čo môže poskytovať štatistický základ pre

prijatie modelu SDM ako najlepšieho riešenia tejto analýzy. Môžeme tiež dospieť k záveru, že hoci sú výsledky citlivé na výber váhovej matice, ukázalo sa, že v obidvoch prípadoch je zohľadnenie priestoru pri ekonometrickom modelovaní nevyhnutnou súčasťou k tomu, aby sa dosiahli ekonometricky správne výsledky (Chocholatá a Furková, 2017).

	Lineárny model	SAR model	SEM model	SDM model
Odhad	OLS	ML	ML	ML
β_0	34.2833*** ³	5.15785	33.8635***	6.08656**
β_1	0.000173***	0.000119***	0.000224***	0.000267***
β_2	0.002161**	0.002305***	0.001713**	0.00204**
λ	-	-	0.81823***	-
ρ	-	0.769075***	-	0.814127***
Θ_1	-	-	-	-0.0002***
Θ_2	-	-	-	-0.003353
R^2	0.10545	0.324819	0.348829	0.368739
Log likelihood	-934.894	-905.003	-901.597	-897.596
AIC	1875.79	1818.01	1809.19	1807.19
Diagnostické testy				
Moran's I (error)	12.8170***	-	-	-
LM (lag)	102.1743***	-	-	-
Robust LM (lag)	0.0085	-	-	-
LM (error)	121.3390***	-	-	-
Robust LM (error)	19.1732***	-	-	-
Moran's I (spatial residual)	-	0.028	0.013	0.013

Tabuľka 2: Výsledky odhadu lineárneho regresného modelu, modelu SAR, modelu SEM a modelu SDM, váhy: euklidovská vzdialenosť (zdroj: vlastné spracovanie)

³ Symboly *** a ** označujú štatistickú významnosť pri hladine významnosti 1% a 5%

4.3 Diskusia

Táto práca, podobne ako niektoré ďalšie štúdie zaoberajúce sa dosiahnutým vzdelaním v európskych regiónoch (Pagliacci, 2014; Rodríguez-Pose a Tselios, 2007; Chocholatá a Furková, 2017), potvrdzuje, že pokiaľ ide o ciele stratégie Európa 2020, geografia zohráva zásadnú úlohu. Primárnym cieľom je zabezpečenie inteligentného, udržateľného a inkluzívneho rastu, v rámci ktorého je obsiahnutá aj oblasť vzdelania ako jedna z najdôležitejších častí k dosiahnutiu spomínaného rastu EÚ. Ak sa podrobnejšie pozrieme na cieľ EÚ v oblasti vzdelania, a to dosiahnuť najmenej 40% ľudí vo veku 30-34 rokov absolvujúcich terciárne vzdelanie, 19 zo sledovaných štátov ho naplnilo už v roku 2019. V rámci priemeru EÚ-26 je cieľ za rok 2019 splnený s podielom 41,65% terciárne vzdelaného obyvateľstva vo veku 30-34 rokov.

Na základe takzvaného Toblerovho prvého zákona geografie: „Všetko súvisí so všetkým ostatným, ale blízke veci spolu súvisia viac ako veci vzdialené“ (Tobler, 1970, s. 234), sme pri analýze brali do úvahy aj takzvané priestorové efekty, konkrétne priestorovú autokoreláciu. Pozitívna priestorová autokorelácia naznačuje, že regióny s vysokým (nízkym) podielom obyvateľov vo veku 30-34 rokov s ukončeným terciárnym vzdelaním majú tendenciu sa nachádzať v blízkosti a zoskupené s inými regiónmi, ktoré majú vysoký (nízky) podiel ukončeného terciárneho vzdelania vo veku 30-34 rokov (Chocholatá, 2018). Klastrové mapy navyše poskytovali rozčlenenejší pohľad na podstatu priestorovej autokorelácie. Naše výsledky sú v súlade s Pagliacci (2014), ktorý tvrdí, že je problematické považovať EÚ za homogénnu oblasť, pokiaľ ide o stratégiu Európa 2020. Táto diplomová práca, rovnako ako práce Chocholatá a Furková (2017) a Chocholatá (2018), preukázala, že napriek postupnému zlepšovaniu vzdelanosti v EÚ, na národnej i regionálnej úrovni sa musíme vyrovnávať s rozmanitými územnými rozdielmi. Taktiež sme dokázali, že územné rozdiely majú tendenciu v priebehu času pretrvávať a identifikovali sme niektoré regióny prevažne hlavných miest ako „dobré vzdelané“ a niektoré odľahlé regióny, ktoré vo vzdelanosti nedosahujú najlepšie výsledky. Problém hlavných miest a veľkých miest s centralizáciou rozličných služieb je však všeobecný problém spomínaný napr. Elias a Rey (2011) pri analýze peruánskych regiónov. Priestorová analýza preto môže slúžiť ako užitočná podpora pre tvorcov politik pri prijímaní správnych rozhodnutí vzhľadom na prítomnosť priestorových prelievaní medzi regiónmi.

V druhej časti práce sme sa zaoberali predpokladanou závislosťou medzi dosiahnutým terciárnym vzdelaním, regionálnym hrubým domácim produktom a hustotou zaľudnenia v sledovaných regiónoch pomocou priestorového aj nepriestorového prístupu. Výsledky

regresnej analýzy preukázali prítomnosť priestorovej asociácie medzi socioekonomickými ukazovateľmi. Analýza ďalej odhalila, že tradičný lineárny model (OLS) nebol korektne špecifikovaný kvôli prítomnosti silnej závislosti priestorovej náhodnej zložky a došlo by preto k nesprávnym interpretáciám. Pretože reziduály z klasického nepriestorového regresného modelu boli priestorovo autokorelované, po diagnostickej kontrole boli odhadnuté priestorové modely SAR, SEM a SDM na základe dvoch váhových matíc, kráľovná a euklidovská vzdialenosť, ktoré už neposkytovali skreslené hodnoty. Pokiaľ ide o štatistickú významnosť parametrov, ako aj hodnoty testu AIC, uprednostnili sme špecifikáciu SDM pre váhy kráľovnej aj pre euklidovskú vzdialenosť. Pozitívny vzťah medzi úrovňou terciárnej vzdelanosti a oneskorenou hodnotou HDP ako aj hustotou zaľudnenia v regiónoch EÚ sa jednoznačne potvrdil. Aj keď sú výsledky citlivé na výber váhovej matice, v oboch prípadoch štatistická významnosť priestorových parametrov potvrdzuje prítomnosť priestorových efektov v susedných regiónoch, čo naznačuje, že vyššie percento „vzdelanej“ populácie v konkrétnom regióne bude mať tendenciu zvyšovať mieru vzdelanosti v susedných regiónoch. Špecifikácia modelu SDM ďalej poukazovala na skutočnosť možného odlivu niektorých ľudí s uvažovanou úrovňou vzdelania do susedných regiónov s vyššou hodnotou HDP.

V prípade EÚ prinieslo sledovanie vzdelanostnej premennej, ako aj ďalších sociálno-ekonomických premenných zaujímavé výsledky týkajúce sa regionálneho rozvoja. V rámci analyzovaných cieľových bodov tejto diplomovej práce sme potvrdili všetky výskumné predpoklady. Keďže vplyv polohy regiónu na podiel vzdelaného obyvateľstva je preukázateľný, regresná analýza by sa mala obohatiť o začlenenie priestorovej dimenzie, aby sa zabránilo možným skresleným výsledkom, a teda zavádzajúcim záverom (Chocholatá a Furková, 2017).

Záver

V diplomovej práci sme pomocou metodiky priestorovej ekonometrie uskutočnili analýzy úrovne dosiahnutého vzdelania (percento populácie vo veku 30–34 rokov s terciárnym vzdelaním) v 251 regiónoch NUTS 2 krajín EÚ v období rokov 2012–2019 s cieľom posúdiť vplyv polohy regiónu na percentuálnom podiele populácie s vysokoškolským vzdelaním. Medzi splnené ciele tiež radíme preskúmanie vplyvu regionálneho HDP a hustoty zaľudnenia na podiel ľudí so stanovenou úrovňou dosiahnutého terciárneho vzdelania, a to na základe odhadu priestorových a nepriestorových ekonometrických modelov.

Za pozitívny poznatok tejto práce môžeme radiť postupne rastúcu tendenciu terciárnej vzdelanosti takmer vo všetkých analyzovaných krajinách EÚ, a naopak, klesajúcu tendenciu dosiahnutého nižšieho ako základného, základného a nižšieho stredoškolského vzdelávania v týchto krajinách. Preukázaný trend môžeme považovať za zvýšenie úrovne vzdelanosti v analyzovaných rokoch pre EÚ ako celok. Znázornený škatuľový graf dosiahnutého terciárneho vzdelania v jednotlivých rokoch (Obrázok 12) však naznačuje pretrvávajúce rozdiely naprieč regiónmi počas sledovaného obdobia.

Nástroje ESDA založené na grafickej vizualizácii a mapovaní údajov sprevádzaných výpočtom globálnej a regionálnej Moranovej I štatistiky nám umožnili posúdiť prítomnosť priestorovej závislosti v skúmaných regiónoch. Susedstvo regiónov bolo charakterizované tromi rôznymi typmi váhových matíc - matica váh typu kráľovná, matica váh 4 najbližších susedov a matica euklidovskej vzdialenosti. Výsledky preukázali silnú pozitívnu priestorovú autokoreláciu v prípade všetkých troch špecifikácií váhovej matice, pričom najsilnejšia autokorelácia bola potvrdená pri matici váh typu kráľovná, a naopak najslabšiu závislosť indikovala matica euklidovskej vzdialenosti. Potvrdenie priestorovej autokorelácie znamená, že regióny s vysokým (nízkym) percentom populácie s terciárnym vzdelaním majú tendenciu sa nachádzať v blízkosti iných regiónov, ktoré majú tiež vysoký (nízky) podiel obyvateľstva s uvažovanou úrovňou dosiahnutého vzdelania.

Na základe regionálnych štatistík Moranovho I a klastrových máp LISA bola zistená významná pozitívna autokorelácia HH pre regióny nachádzajúce sa hlavne v krajinách západnej a severnej Európy, zatiaľ čo významná pozitívna autokorelácia LL bola identifikovaná pre regióny nachádzajúce sa prevažne v Taliansku, Rumunsku, Grécku, ako aj v niektorých regiónoch strednej Európy. Taktiež je potrebné zdôrazniť, že výsledky štatistickej významnosti regiónov s priestorovými asociáciami HH a LL sa počas

posudzovaného obdobia významne nezmenili. Rozdiely medzi regiónmi majú teda tendenciu v priebehu času pretrvávať.

Dôležitosť priestorovej interakcie a geografickej blízkosti sme brali do úvahy aj pri regresnej analýze testujúcej závislosť medzi dosiahnutým vzdelaním, regionálnym HDP a hustotou zaľudnenia. Pretože reziduály z lineárneho (nepriestorového) regresného modelu boli priestorovo autokorelované, po diagnostickej kontrole boli odhadnuté priestorové modely SAR, SEM a SDM na základe váhových matíc kráľovná a euklidovská vzdialenosť. Po dôkladnom porovnaní odhadnutých priestorových modelov, berúc do úvahy štatistickú významnosť parametrov, hodnoty AIC, ako aj hodnoty Log likelihood, v oboch prípadoch sme uprednostnili model SDM, pre váhy kráľovnej aj pre euklidovské vzdialenosti.

Predpoklad o pozitívnom vplyve miery regionálneho HDP ako aj hustoty zaľudnenia na úroveň dosiahnutého terciárneho vzdelania sa jednoznačne potvrdil. Štatistická významnosť priestorových parametrov navyše potvrdzuje prítomnosť priestorových efektov v susedných regiónoch. To znamená, že vzdelanejšia populácia v konkrétnom regióne bude mať tendenciu zvyšovať vzdelanostnú úroveň v susedných regiónoch. Výsledky prezentované v tejto práci jasne preukázali vplyv polohy regiónu na podiel obyvateľstva s vysokoškolským vzdelaním. To je jasná signalizácia toho, že by sa regresná analýza mala obohatiť o začlenenie priestorovej dimenzie, aby sa zabránilo nepresným výsledkom a zavádzajúcim záverom.

Keďže štúdie zaoberajúce sa analýzou dosiahnutého vzdelania v regiónoch EÚ sú dosť obmedzené, analýza tohto typu môže slúžiť ako užitočný nástroj pre orgány EÚ, ako aj pre orgány jednotlivých krajín, na prijímanie dôležitých rozhodnutí (v súlade so stratégiou Európa 2020), s cieľom motivovať ľudí k dosiahnutiu vyššej úrovne vzdelania podporou vhodných regiónov. A to nie iba pomocou pre menej rozvinuté regióny, ale aj tie regióny, ktoré môžu slúžiť prostredníctvom priestorových účinkov prelievania k zvýšeniu podielu „vzdelanejšej“ populácie v blízkych regiónoch, nakoľko bola potvrdená pozitívna priestorová autokorelácia v sledovaných európskych regiónoch.

Zoznam použitej literatúry

AHMED, S. *Essays on Spatial Inequalities in Income and Education: Econometric Evidence from Pakistan* [online]. PhD dissertation, University of Trento. 2011. [cit. 2021-01-27] Dostupné na: http://eprints-phd.biblio.unitn.it/621/1/PHD_SOFIA_AHMED__oct_2611__.pdf

ALBERT, *Key Assumptions of OLS: Econometrics Review*. [online]. 2021. [cit. 2021-02-01]. Dostupné na: <https://www.albert.io/blog/key-assumptions-of-ols-econometrics-review/>

ANSELIN, L. *Spatial Econometrics: Methods and Models* [online]. Dordrecht: Kluwer. 1988. [cit. 2021-02-01] Dostupné na: <https://doi.org/10.1007/978-94-015-7799-1>

ANSELIN, L. *Local indicators of spatial association – LISA*. [online]. Geographical Analysis, vol. 27, no. 2, pp. 93–115. 1995. [cit. 2021-01-27] Dostupné na: <https://doi.org/10.1111/j.1538-4632.1995.tb00338.x>

ANSELIN, L. *Spatial externalities, spatial multipliers and spatial econometrics* [online]. International Regional Science Review, vol. 26, pp. 153–166. 2003. [cit. 2021-02-12] Dostupné na: <https://doi.org/10.1177/0160017602250972>

ANSELIN, L.; KIM, Y. W. & SYABRI, I. *Web-based analytical tools for the exploration of spatial data* [online]. in M. M. Fischer & A. Getis (eds.) Handbook of Applied Spatial Analysis: Software Tools, Methods and Applications, Berlin & Heidelberg: Springer-Verlag, pp. 151–173. 2010. [cit. 2021-01-25]. Dostupné na: https://doi.org/10.1007/978-3-642-03647-7_10

ARBIA, G. *Spatial Econometrics: Statistical Foundations and Applications to Regional Convergence*. Berlin & Heidelberg: Springer-Verlag. 2006. [cit. 2021-04-07]. ISBN: 978-3-540-32305-1

BLANÁR, F. *Ďalšie vzdelávanie a jeho miesto v procese celoživotného učenia sa* [online]. Časopis ACADEMIA. 2019. [cit. 2021-04-17]. Dostupné na: https://www.cvtisr.sk/buxus/docs//ACADEMIA/2019/4-2019_academia_web.pdf

BURJAN, V. a kol. *Učiace sa Slovensko* [online]. Ministerstvo školstva, vedy, výskumu a športu Slovenskej republiky: Národný program rozvoja výchovy a vzdelávania. 2017. [cit. 2021-04-03]. Dostupné na: https://www.minedu.sk/data/files/6987_uciace_sa_slovensko.pdf

ČERYCH, L. *České vzdělání a Evropa. Strategie rozvoje lidských zdrojů v ČR při vstupu do EU: Program Phare*, Praha: Sdružení pro vzdělávací politiku. 1999. 88 str., [cit. 2021-03-07]. ISBN: 80-211-0312-4

DEWEY, J. *Experience and education: The 60th Anniversary Edition*. Kappa Delta Pi. 1998. [cit. 2021-03-05]. ISBN 9780912099354

DRAGOMIRESCU-GAINA, C., ELIA, L. a WEBER, A. *A fast-forward look at tertiary education attainment in Europe 2020* [online]. Journal of Policy Modeling, vol. 37, no. 5, pp. 804-819. 2015. [cit. 2021-01-23]. Dostupné na: <https://doi.org/10.1016/j.jpolmod.2015.05.002>

ELHORST, J.P. *Matlab software for spatial panels*. Int. Reg. Sci. Rev., 37 (3), pp. 389-405. 2014. [cit. 2021-02-05]

ELIAS, M., REY, S.J. *Educational Performance and Spatial Convergence in Peru* [online]. Région et Développement, no. 33, pp. 107-135. 2011. [cit. 2021-02-10]. Dostupné na: <https://regionetdeveloppement.univ-tln.fr/wp-content/uploads/Elias.pdf>

EURÓPSKA KOMISIA. *Study in Europe: Higher education in Europe* [online]. 2017. [cit. 2021-04-06] Dostupné na: https://ec.europa.eu/education/study-in-europe/planning-studies/european-higher-education_en

EURÓPSKA KOMISIA. *Europe 2020: A European strategy for smart, sustainable and inclusive growth* [online]. 2010. [cit. 2021-01-23] Dostupné na: <http://eur-lex.europa.eu/LexUriServ/LexUriServ.do?uri=COM:2010:2020:FIN:EN:PDF>

EURÓPSKA KOMISIA. *Regional development and cohesion beyond 2020: the new framework at a glance*. European Union. 2018. [cit. 2021-03-04]. ISBN 978-92-79-86094-2

EURÓPSKA KOMISIA. *Slovensko, Historický vývoj* [online]. 2020. [cit. 2021-03-07] Dostupné na: https://eacea.ec.europa.eu/national-policies/eurydice/content/historical-development-72_sk

EUROSTAT. *Štatistika vzdelávania a odbornej prípravy na regionálnej úrovni* [online]. 2017. [cit. 2021-04-06]. Dostupné na: https://ec.europa.eu/eurostat/statistics-explained/index.php/Archive:%C5%A0tatistika_vzdel%C3%A1vania_a_odbornej_pr%C3%ADpravy_na_region%C3%A1lnej_%C3%BArovni

EUROSTAT. *Database – Eurostat* [online]. 2021a. [cit. 2021-01-24]. Dostupné na: <http://ec.europa.eu/eurostat/data/database>

EUROSTAT. *GISCO – Eurostat* [online]. 2021b. [cit. 2021-01-24]. Dostupné na: <http://ec.europa.eu/eurostat/web/gisco/geodata/reference-data/administrative-units-statistical-units>

FILČÁK, T. *Vybrané indikátory z Education at a Glance 2019: Vysokoškolské vzdelávanie na Slovensku a v stredoeurópskych štátoch OECD* [online]. Časopis ACADEMIA. 2019. [cit. 2021-04-17]. Dostupné na: https://www.cvtisr.sk/buxus/docs//ACADEMIA/2019/4-2019_academia_web.pdf

FISCHER, M. M.; BARTKOWSKA, M.; RIEDL, A.; SARDADVAR, S. & KUNNERT, A. *The impact of human capital on regional labor productivity in Europe* [online]. In M. M. Fischer & A. Getis (eds.) *Handbook of Applied Spatial Analysis: Software Tools, Methods and Applications*, Berlin & Heidelberg: Springer-Verlag, pp. 585–597. 2010. [cit. 2021-02-05]. Dostupné na: https://doi.org/10.1007/978-3-642-03647-7_28

FLORAX, R. J. G. M., FOLMER, H. & Rey, S. J. *Specification searches in spatial econometrics: the relevance of Hendry's methodology* [online]. *Regional Science and Urban Economics*, vol. 33, pp. 557–579. 2003. [cit. 2021-02-01]. Dostupné na: [https://doi.org/10.1016/S0166-0462\(03\)00002-4](https://doi.org/10.1016/S0166-0462(03)00002-4)

GEARY, R. *The contiguity ratio and statistical mapping* [online]. *The Incorporated Statistician*, 5, 115-145. 1954. [cit. 2021-02-27]. Dostupné na: http://www.stat.ucla.edu/~nchristo/statistics_c173_c273/geary_paper.pdf

GUȚOIU, G.-I., *Spatial polarization in Bucharest at the 2014 Presidential Election* [online]. *South-East European Journal of Political Science (SEEJPS)*, Vol. III, No. 2. 2015. [cit. 2021-02-25]. Dostupné na: https://www.researchgate.net/publication/294870442_Spatial_polarization_in_Bucharest_at_the_2014_Presidential_Election

HANČLOVÁ, J., TVRDÝ, L. *Classification of the Regions* [online]. Ostrava: Technical university of Ostrava. 2004. [cit. 2021-01-23]. Dostupné na: http://accendo.cz/wp-content/uploads/part_2-1_11_20041.pdf

CHOCHOLATÁ, M. *Spatial Analysis of the Tertiary Educational Attainment in European Union*. ERIE. University of Economics in Bratislava, pp. 96-103. 2018. [cit. 2021-03-03]

CHOCHOLATÁ, M., FURKOVÁ, A. *Regional Disparities in Education Attainment Level in the European Union: A Spatial Approach* [online]. *Baltic Journal of European*

Studies, vol. 7, no. 2, pp. 107-131. 2017. [cit. 2021-01-23]. Dostupné na: https://www.researchgate.net/publication/321014485_Regional_Disparities_in_Education_Attainment_Level_in_the_European_Union_A_Spatial_Approach

JANOTKA, M. *Priestorová analýza s využitím softvéru Opengeda*. Ekonomické spektrum. Bratislava: CAESaR-Centrum vzdelávania, vedy a výskumu. 2013. [cit. 2021-03-03]. 8(2), 4-14. ISSN 1336-9105.

KELLER, J., TVRDÝ, L. *Vzdělanostní společnost? Chrám, výtah a pojišťovna*. Sociologické nakladatelství SLON, Praha 2008. 2010. [cit. 2021-03-06]. ISBN 978-80-86429-78-6

KIŠŠ, Š., ŠIŠKOVIČ, M. *Porovnanie životnej úrovne na Slovensku v rokoch 1989 – 200* [online]. Inštitút finančnej politiky, Ministerstvo financií SR. 2006. [cit. 2021-03-14]. Dostupné na: <https://www.mfsr.sk/sk/financie/institut-financnej-politiky/publikacie-ifp/ekonomicke-analyzy/12-porovnanie-zivotnej-urovne-slovensku-rokoch-1989-2005-august-2006.html>

KLÍCHA, M. *Shluková analýza funkčních ploch pro sledování urbánního vývoje olomouckého regionu* [online]. Institut geoinformatiky. 2011. [cit. 2021-02-27]. Dostupné na: http://gis.vsb.cz/GISacek/GISacek_2011/papers/klicha.pdf

KLUFOVÁ, R., ROST M., KLICNAROVÁ J. *Modelování Regionálních procesů*. Praha: Alfa Nakladatelství, s.r.o., 2012. [cit. 2021-02-27]. ISBN 978-80-87197-53-0

KOBELA, J. *Medzinárodná štandardná klasifikácia vzdelania ISCED 2011 a jej prepojenie s Národným kvalifikačným rámcom* [online]. Ministerstvo školstva, vedy, výskumu a športu SR. 2013. [cit. 2021-03-08]. Dostupné na: http://www.kin-ball.sk/downloads/media/2014/20141027_04_prepojenie_NKR_ISCED_2011.pdf

KOUCKÝ, J., OBDRŽÁLEK, P. a kol., *Liečba, ktorú nikto nechce?* [online]. Reflexie a trendy pre riadenie a rozvoj vysokého školstva. Informačné listy 1/17, Centrum edukačného manažmentu, Univerzita Komenského v Bratislave, Fakulta managementu. 2017. [cit. 2021-03-17]. Dostupné na: https://www.fm.uniba.sk/fileadmin/fm/Veda/projekty/vystupy_CEM/liecbaktoruniktonechce_infolistycem1_17.pdf

KREBS, V. A kol. *Sociální politika*. 4. přepracované vydání, Praha: ASPI. 2007. [cit. 2021-03-06]. ISBN 978-80-7357-276-1

LEAF. *Prieskum medzi Slováckmi v zahraničí* [online]. 2016. [cit. 2021-03-19]. Dostupné na: <https://spap.leaf.sk/prieskum2016/>

LE GALLO, J. *Econométrie spatiale: l'autocorrélation spatiale dans les modèles de régression linéaire* ». *Economie & prévision* 4, pp. 139–157. 2002. [cit. 2021-02-04].

LESAGE J. P.: *Spatial econometrics* [online] University of Toledo. 1998. [cit. 2021-01-26]. Dostupné na: www.spatial-econometrics.com/html/wbook.pdf

LESAGE, J. P. & FISCHER, M. M. *Spatial growth regressions: model specification, estimation and interpretation* [online]. *Spatial Economic Analysis*, vol. 3, no. 3, pp. 275–304. 2008. Dostupné na: <http://dx.doi.org/10.1080/17421770802353758>

LV, K. a kol. *Impacts of educational factors on economic growth in regions of China: a spatial econometric approach* [online]. SILC Business School, Shanghai University, 20 Chengzhong RD. Jiading District, 201800 Shanghai, P.R. China. 2015. [cit. 2021-03-24]. Dostupné na: https://www.researchgate.net/publication/283868791_Impacts_of_educational_factors_on_economic_growth_in_regions_of_China_a_spatial_econometric_approach

MARIAN, J. *Percentage of population with completed tertiary education by region in Europe* [online]. *Language learning, science and art*. 2015. [cit. 2021-04-06]. Dostupné na: <https://jakubmarian.com/percentage-of-population-with-completed-tertiary-education-in-europe/>

MEDINA, J., SOLYMOSI, R., *Crime Mapping in R* [online]. 2019. [cit. 2021-02-04]. Dostupné na: https://maczokni.github.io/crimemapping_textbook_bookdown/

MERTL, J., VYCHOVÁ, H. *Vazby vzdělání a zdraví v kontextu ekonomického rozvoje* [online]. Praha, článek pro: *Politická ekonomie*, 1, 2009, str. 58 – 78. 2009. [cit. 2021-03-06]. Dostupné na: <http://www.vse.cz/polek/download.php?jnl=polek&pdf=670.pdf>

MFSR, *Revízia výdavkov na vzdelávanie* [online]. Ministerstvo financií Slovenskej republiky: Záverečná správa. 2017. [cit. 2021-04-03]. Dostupné na: <https://www.minedu.sk/21395-sk/revizia-vydavkov-na-vzdelavanie-2017/>

MITCHELL, W. *Introduction to spatial econometric modelling*. Centre of Full Employment and Equity Working Paper, no. 1–13. 2013. [cit. 2021-02-04].

MH SR, *Organizácia pre hospodársku spoluprácu a rozvoj – OECD* [online]. 2021. [cit. 2021-03-09]. Dostupné na: https://www.mhsr.sk/obchod/multilateralne-obchodne-vztahy/oecd/organizacia-pre-hospodarsku-spolupracu-a-rozvoj-oecd?fbclid=IwAR0E_0nL4Z5Jblzwn0jZhDpkUDZP30qSgknirx3zKct6k1Kiszxz4l9X3KA

MŠVVaŠ SR, *OECD a agenda rezortu školstva, vedy, výskumu a športu SR* [online]. 2021. [cit. 2021-03-09]. Dostupné na: <https://www.minedu.sk/oecd-a-agenda-rezortu-skolstva-vedy-vyskumu-a-sportu-sr/?fbclid=IwAR23kMeKr93EiV-mUSbNOoFiVm7Z2e6lkUuwlrZWLQvKeHFRRJkIfMkPv2M>

MŠVVaŠ SR, *Národná klasifikácia vzdelania* [online]. 2018. [cit. 2021-03-08]. Dostupné na: <https://www.minedu.sk/data/files/3772.pdf>

NOVÁK, J., NETRDOVÁ, P. *Prostorové vzorce sociálně-ekonomické diferenciace obcí v České republice* [online]. Sociologický časopis. Vol. 47, No. 4. 2011. [cit. 2021-02-28]. Dostupné na: <https://sreview.soc.cas.cz/pdfs/csr/2011/04/05.pdf>

OECD. *Education at a Glance 2015* [online]. OECD Indicators, OECD Publishing, Paris. 2015. [cit. 2021-03-19]. Dostupné na: https://www.oecd-ilibrary.org/education/education-at-a-glance-2015_eag-2015-en

OECD. *Education at a Glance 2017* [online]. OECD Indicators, OECD Publishing, Paris. 2017. [cit. 2021-03-17]. Dostupné na: <http://dx.doi.org/10.1787/eag-2017-en>

OECD. *Trends Shaping Education 2019* [online]. OECD Publishing, Paris. 2019. [cit. 2021-03-22]. Dostupné na: https://doi.org/10.1787/trends_edu-2019-en

OECD360. *Ako sa darí Slovensku?* [online]. OECD 360: Slovenská republika 2015. 2015. [cit. 2021-03-07]. Dostupné na: <https://www.oecd-ilibrary.org/docserver/9789264236714-sk.pdf?expires=1615069436&id=id&accname=guest&checksum=73BB7691B8CB8FCF424BCC322D26DE02>

PAGLIACCI, F. *Europe 2020 Challenges and Regional Imbalances. A Spatial Analysis* [online]. XXXV Conferenza Italiana di Science Regionali. 2014. [cit. 2021-01-23]. Dostupné na: https://www.aisre.it/images/old_papers/Pagliacci.pdf

PALÁN, Z. *Lidské zdroje, výkladový slovník*. 1. vydání, Praha, Akademie Věd České republiky. 2002. [cit. 2021-03-06]. ISBN 80-200-0950-7

PERMAI, S. D., JUARI, R., CHOWANDA, A. *Spatial autoregressive (SAR) model for average expenditure of Papua Province* [online]. 4th International Conference on Computer Science and Computational Intelligence 2019 (ICCSCI). 12–13 September 2019. [cit. 2021-02-03]. Dostupné na: <https://www.sciencedirect.com/science/article/pii/S187705091931169X>

PUDLÁK, Š. *Analýza výsledků testování obecných studijních předpokladů* [online]. SCIO. 2015. [cit. 2021-03-19]. Dostupné na: <https://www.scio.cz/download/TZOSP.pdf>

RODRÍGUEZ-POSE, A. & TSELIOS, V. *Analysis of Educational Distribution in Europe: Educational Attainment and Inequality within Regions*. in Papers DYNREG08, Economic and Social Research Institute (ESRI), No. 8/2007.

RÚZ, *Koncept reformy terciárneho vzdelávania na Slovensku z pohľadu RÚZ* [online]. Republiková únia zamestnávateľov. BusinessEurope. 2019. [cit. 2021-03-17]. Dostupné na:

https://ruzsr.sk/app/webroot/CmsPlugin/files/Koncept_reformy_tercialneho_vzdelavania_poda_RUZ.pdf?fbclid=IwAR20yqok091yCv9NQoLidtFVgWXRmo6ERGpnuAPR98oPlrdCgw-65HAnPBg

SAWADA, M. *Global Spatial Autocorrelation Indices - Moran's I, Geary's C and the General Cross-Product Statistic* [online]. University of Ottawa, 2009. [cit. 2021-02-28]. Dostupné na: <http://www.lpc.uottawa.ca/publications/moransi/moran.htm>

SUTTON, F. *The Nexus of Place and Finance in the Analysis of Educational Attainment: A Spatial Econometric Approach* [online]. The University of Arizona. 2012. [cit. 2021-04-07]. Dostupné na: https://repository.arizona.edu/bitstream/handle/10150/265348/azu_etd_12498_sip1_m.pdf;jsessionid=0D850B85811ECC4119197596100622D5?sequence=1

TOBLER, W. R. *A computer movie simulating urban growth in the Detroit region* [online]. Economic Geography, vol. 46, no. 2, pp. 234-240. 1970. [cit. 2021-02-10]. Dostupné na: <https://doi.org/10.2307/143141>

TOUITOU, M., YACINE, L., AHMED, B. *Spatial disparity and inequality of education domain in Algeria: a spatial econometric approach* [online]. International Journal of Social Economics. 2020. [cit. 2021-03-22]. ISSN 0306-8293. Dostupné na : https://www.researchgate.net/publication/343586949_Spatial_disparity_and_inequality_of_education_domain_in_Algeria_a_spatial_econometric_approach

TVRDÝ, L. a kol. *Trh práce a vzdělanost v regionálním kontextu* [online]. Vysoká škola Báňská, Katedra regionální a environmentální politiky. 2007. ISBN 978-80-248-1665-4, [cit. 2021-03-05]. Dostupné na :http://accendo.cz/wp-content/uploads/2007_VTP_regiony.pdf

UMAR, H. M., ISMAIL, R., EAM, L. H. *A Spatial Econometrics Analysis of Educational Distribution and Regional Income Disparities in Nigeria* [online]. Proceedings Book of ICETSR 2014, Malaysia Handbook on the Emerging Trends in

Scientific Research, pp. 722–731. 2014. [cit. 2021-04-07]. Dostupné na: <https://www.semanticscholar.org/paper/A-Spatial-Econometrics-Analysis-of-Educational-and-Umar-Ismail/e3b8aa9b11eb42293a148e31780b4c722f394fbf>

UNIRANK. *Universities in Europe. Higher Education in Europe* [online]. University Rankings. 2020. [cit. 2021-04-07]. Dostupné na: https://www.4icu.org/Europe/?fbclid=IwAR2eAIVtmC_UghXesZXb4crWsfSTlQv0JgOgAujlm3s9oxljhA_EE9vbXKM

WANG, Z. *A Spatial Analysis of Educational Inequality in Mainland China* [online]. Stats 499 Paper, Statistics Department, University of Michigan. 2012. [cit. 2021-04-07]. Dostupné na: <https://deepblue.lib.umich.edu/bitstream/handle/2027.42/91791/wangzh.pdf?sequence=1>

WILLIAMS, R. *Heteroskedasticity* [online]. University of Notre Dame. 2020. [cit. 2021-02-02]. Dostupné na: <https://www3.nd.edu/~rwilliam/stats2/l25.pdf>

WILLIAMS, R., LEAHY, A., JESEN, P. *U21 ranking of national higher Education systems 2017* [online]. Universitas 21 and Institute of Applied Economic and Social Research, University of Melbourne. 2017. [cit. 2021-03-19]. Dostupné na: <https://universitas21.com/what-we-do/u21-rankings/previous-u21-rankings-national-higher-education-systems/2017>

WINCHESTER, N., GREENAWAY, D. *Rising wage inequality and capital-skill complementarity* [online]. Journal of Policy Modeling, 29(1), 41–54. 2007. [cit. 2021-03-22]. Dostupné na: <https://www.sciencedirect.com/science/article/abs/pii/S0161893806000196>

Prílohy

Príloha č.1 Odhad lineárneho modelu OLS – štatistické ukazovatele pre maticu euklidovskej vzdialenosti

REGRESSION

SUMMARY OF OUTPUT: ORDINARY LEAST SQUARES ESTIMATION

Data set : NUTS2EUbez21
Dependent Variable : edu_2019 Number of Observations: 251
Mean dependent var : 39.894 Number of Variables : 3
S.D. dependent var : 10.6064 Degrees of Freedom : 248

R-squared : 0.105453 F-statistic : 14.6177
Adjusted R-squared : 0.098239 Prob(F-statistic) : 9.9718e-007
Sum squared residual: 25258.8 Log likelihood : -934.894
Sigma-square : 101.85 Akaike info criterion : 1875.79
S.E. of regression : 10.0921 Schwarz criterion : 1886.36
Sigma-square ML : 100.633
S.E of regression ML: 10.0316

Variable	Coefficient	Std.Error	t-Statistic	Probability
CONSTANT	34.2833	1.38369	24.7767	0.00000
gdp_2018	0.000173125	4.59497e-005	3.76771	0.00021
pdens_2018	0.00216076	0.000942232	2.29324	0.02267

**Príloha č.2 Odhad lineárneho modelu OLS – charakteristiky priestorovej závislosti
pre maticu euklidovskej vzdialenosti**

REGRESSION DIAGNOSTICS

MULTICOLLINEARITY CONDITION NUMBER 4.595512

TEST ON NORMALITY OF ERRORS

TEST	DF	VALUE	PROB
Jarque-Bera	2	12.4315	0.00200

DIAGNOSTICS FOR HETEROSKEDASTICITY

RANDOM COEFFICIENTS

TEST	DF	VALUE	PROB
Breusch-Pagan test	2	3.9221	0.14071
Koenker-Bassett test	2	3.0924	0.21306

SPECIFICATION ROBUST TEST

TEST	DF	VALUE	PROB
White	5	42.1092	0.00000

DIAGNOSTICS FOR SPATIAL DEPENDENCE

FOR WEIGHT MATRIX : euk dist

(row-standardized weights)

TEST	MI/DF	VALUE	PROB
Moran's I (error)	0.2267	12.8170	0.00000
Lagrange Multiplier (lag)	1	102.1743	0.00000
Robust LM (lag)	1	0.0085	0.92642
Lagrange Multiplier (error)	1	121.3390	0.00000
Robust LM (error)	1	19.1732	0.00001
Lagrange Multiplier (SARMA)	2	121.3475	0.00000

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

Príloha č.3 Odhad modelu SAR pre maticu euklidovskej vzdialenosti

REGRESSION

SUMMARY OF OUTPUT: SPATIAL LAG MODEL - MAXIMUM LIKELIHOOD ESTIMATION

Data set : NUTS2EUbez21
Spatial Weight : euk dist
Dependent Variable : edu_2019 Number of Observations: 251
Mean dependent var : 39.894 Number of Variables : 4
S.D. dependent var : 10.6064 Degrees of Freedom : 247
Lag coeff. (Rho) : 0.769075

R-squared : 0.324819 Log likelihood : -905.003
Sq. Correlation : - Akaike info criterion : 1818.01
Sigma-square : 75.9549 Schwarz criterion : 1832.11
S.E of regression : 8.71521

Variable	Coefficient	Std.Error	z-value	Probability
W_edu_2019	0.769075	0.0686232	11.2072	0.00000
CONSTANT	5.15785	2.68331	1.9222	0.05458
gdp_2018	0.000119735	4.23772e-005	2.82546	0.00472
pdens_2018	0.00230487	0.000814671	2.82921	0.00467

REGRESSION DIAGNOSTICS

DIAGNOSTICS FOR HETEROSKEDASTICITY

RANDOM COEFFICIENTS

TEST	DF	VALUE	PROB
Breusch-Pagan test	2	0.2256	0.89332

DIAGNOSTICS FOR SPATIAL DEPENDENCE

SPATIAL LAG DEPENDENCE FOR WEIGHT MATRIX : euk dist

TEST	DF	VALUE	PROB
Likelihood Ratio Test	1	59.7809	0.00000

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

Príloha č.4 Odhad modelu SEM pre maticu euklidovskej vzdialenosti

REGRESSION

SUMMARY OF OUTPUT: SPATIAL ERROR MODEL - MAXIMUM LIKELIHOOD ESTIMATION

Data set : NUTS2EUbez21
Spatial Weight : euk dist
Dependent Variable : edu_2019 Number of Observations: 251
Mean dependent var : 39.894024 Number of Variables : 3
S.D. dependent var : 10.606395 Degrees of Freedom : 248
Lag coeff. (Lambda) : 0.818226

R-squared : 0.348829 R-squared (BUSE) : -
Sq. Correlation : - Log likelihood : -901.597404
Sigma-square : 73.2539 Akaike info criterion : 1809.19
S.E of regression : 8.55885 Schwarz criterion : 1819.77

Variable	Coefficient	Std.Error	z-value	Probability
CONSTANT	33.8635	3.27278	10.347	0.00000
gdp_2018	0.000223785	5.36197e-005	4.17355	0.00003
pdens_2018	0.00171294	0.00081789	2.09433	0.03623
LAMBDA	0.818226	0.0644839	12.6888	0.00000

REGRESSION DIAGNOSTICS

DIAGNOSTICS FOR HETEROSKEDASTICITY

RANDOM COEFFICIENTS

TEST	DF	VALUE	PROB
Breusch-Pagan test	2	4.0759	0.13030

DIAGNOSTICS FOR SPATIAL DEPENDENCE

SPATIAL ERROR DEPENDENCE FOR WEIGHT MATRIX : euk dist

TEST	DF	VALUE	PROB
Likelihood Ratio Test	1	66.5928	0.00000

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

Príloha č.5 Odhad modelu SDM pre maticu euklidovskej vzdialenosti

SUMMARY OF OUTPUT: SPATIAL LAG MODEL - MAXIMUM LIKELIHOOD ESTIMATION

Data set : NUTS2EUbez21
Spatial Weight : euk dist
Dependent Variable : edu_2019 Number of Observations: 251
Mean dependent var : 39.894 Number of Variables : 6
S.D. dependent var : 10.6064 Degrees of Freedom : 245
Lag coeff. (Rho) : 0.814127

R-squared : 0.368739 Log likelihood : -897.596
Sq. Correlation : - Akaike info criterion : 1807.19
Sigma-square : 71.0141 Schwarz criterion : 1828.34
S.E of regression : 8.42699

Variable	Coefficient	Std.Error	z-value	Probability
W_edu_2019	0.814127	0.0648279	12.5583	0.00000
CONSTANT	6.08656	2.76924	2.19792	0.02795
gdp_2018	0.00026683	5.75787e-005	4.63418	0.00000
pdens_2018	0.00204014	0.000812551	2.51079	0.01205
LAGgdp2018	-0.000220046	7.24479e-005	-3.0373	0.00239
LAGpde2018	-0.00335347	0.00273195	-1.2275	0.21963

REGRESSION DIAGNOSTICS

DIAGNOSTICS FOR HETEROSKEDASTICITY

RANDOM COEFFICIENTS

TEST	DF	VALUE	PROB
Breusch-Pagan test	4	8.2412	0.08313

DIAGNOSTICS FOR SPATIAL DEPENDENCE

SPATIAL LAG DEPENDENCE FOR WEIGHT MATRIX : euk dist

TEST	DF	VALUE	PROB
Likelihood Ratio Test	1	69.8824	0.00000

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