

Česká zemědělská univerzita v Praze

Provozně ekonomická fakulta

Katedra statistiky



Disertační práce

**Rozvoj metod komplexního hodnocení hospodářsky
problémových regionů České republiky**

Autorka: Ing. Jitka Sirohi

Odborná školitelka: prof. Ing. Libuše Svatošová, CSc.

© 2022 ČZU v Praze

Poděkování

Ráda bych touto cestou poděkovala mé školitelce prof. Ing. Libuši Svatošové, CSc., za odborné vedení po celou dobu mého studia a za cenné rady a připomínky při zpracování disertační práce. Mé poděkování patří i mé rodině a kolegům na fakultě za neutuchající podporu.

Rozvoj metod komplexního hodnocení hospodářsky problémových regionů České republiky

Abstrakt

Disertační práce se zabývá metodikou konstrukce kompozitních indikátorů se zaměřením na hospodářsky problémové okresy (LAU 1) České republiky a způsob jejich vymezení dle vybraných ukazatelů. Hospodářské rozdíly mezi regiony stále přetrvávají a je nezbytné tyto disparity a posuny ve vývoji analyzovat jako podklad pro nastavení možných politických nástrojů, které by mohly pomoci disparity a znevýhodnění eliminovat. Hlavním cílem disertační práce je návrh metodologického aparátu k identifikaci hospodářsky problémových okresů ČR pomocí kompozitního indikátoru, podle kterého lze stanovit disparity mezi regiony. Dílčím cílem je nalezení nejvhodnější sady proměnných a komparace jednotlivých kombinací metod, např. normalizace, určování vah a agregace, neboť spolu tyto metody úzce souvisí. Disertační práce tak přispívá k rozvoji metodologie konstrukce kompozitních indikátorů celkově a finální kompozitní indikátor může sloužit regionům jako návrh metodického postupu. Uvažované proměnné byly stanoveny dle dokumentů Strategie regionálního rozvoje České republiky a metodik vybraných krajů. Metodiky výpočtů se řídí stěžejním dokumentem *Handbook on Constructing Composite Indicators: Methodology and User Guide, Brussels: OECD*, který byl vydán v roce 2008. Na základě provedených analýz bylo zkonstruováno celkem čtyřicet osm typů kompozitních indikátorů za použití kombinace výše uvedených metod. Následně po zvážení robustnosti a jednotlivých výhod a nevýhod kombinací metod byl zvolen vhodný kompozitní indikátor dovolující charakterizovat hospodářsky problémové okresy, jehož konstrukce je založena na lineární agregaci v prvním stupni za použití stejných vah na normalizovaných datech pomocí metody Min-Max a datové matici očištěné od odlehlých pozorování. V druhém stupni je pak provedena geometrická agregace pilířů.

KLÍČOVÁ SLOVA: Agregace, hospodářsky problémové okresy, kompozitní indikátor, metodologický aparát, normalizace, regionální rozdíly, stanovení vah, strategie regionálního rozvoje, vícerozměrná analýza.

Development of Methodology for Comprehensive Evaluation of Economically Weak Regions of the Czech Republic

Abstract

The dissertation thesis deals with the methodology of calculation of composite indicators focusing on economically weaker regions (LAU 1 level) of the Czech Republic, and the way their definition uses selected indicators. Economic disparities between regions persist and it is necessary to analyze these disparities and shifts in development as a basis for setting possible policy instruments that could help to eliminate disparities and disadvantages. The main aim of the thesis is to draft a methodological apparatus for identifying economically weak regions of the Czech Republic using a composite indicator, according to which disparities between regions can be determined. A partial goal is to find the most suitable set of variables and to compare individual combinations of methods of data e.g. normalization, weights setting and methods of aggregation, as these methods are closely related. The dissertation contributes to the development of a methodology for the calculation of composite indicators overall and the final composite indicator may serve as a proposal for a methodological procedure for regions. Considered variables were set according to the documents of the Regional Development Strategy of the Czech Republic and the methodologies of selected regions. Calculation methodologies follow the key document *Handbook on Constructing Composite Indicators: Methodology and User Guide, Brussels: OECD*, published in 2008. Based on the calculations made, a total of forty-eight types of composite indicators were calculated using a combination of the aforementioned methods. After considering the robustness and pros and cons of each combination of methods, a suitable composite indicator was chosen to characterize economically weak regions, whose calculation is based on a linear aggregate at the first level using the equal weights on normalized data using the Min-Max method and removed outliers from the data matrix. At the second level, there is a geometric aggregation of the pillars.

KEYWORDS: Aggregation, economically weak regions, a composite indicator, methodological apparatus, data normalization, regional disparities, weights setting, regional development strategy, multidimensional analysis

Obsah

1. ÚVOD	11
2. CÍL PRÁCE A METODIKA	12
2.1 CÍL PRÁCE.....	12
2.2 METODIKA.....	13
2.1.1 První krok – Sestavení teoretického rámce	15
2.1.2 Druhý krok – Výběr jednotlivých ukazatelů	16
2.1.3 Třetí krok – Nahrazení chybějících hodnot a detekce odlehlých pozorování.....	17
2.1.4 Čtvrtý krok – Vícerozměrná analýza	20
2.1.5 Pátý krok – Normalizace dat	23
2.1.6 Šestý krok – Stanovení vah a agregace	27
2.1.7 Sedmý krok – Analýza k posouzení robustnosti a citlivosti	31
2.1.8 Osmý krok – „Back to the details“	33
2.1.9 Devátý krok – Vztah s ostatními proměnnými	33
2.1.10 Desátý krok – Prezentace a vizualizace výsledků	34
3. TEORETICKÁ VÝCHODISKA	35
3.1 MĚŘENÍ REGIONÁLNÍCH DISPARIT ZA POUŽITÍ KOMPOZITNÍHO INDIKÁTORU	37
3.2 REGIONÁLNÍ POLITIKA A METODIKY VYMEZENÍ HOSPODÁŘSKY PROBLÉMOVÝCH REGIONŮ ČESKÉ REPUBLIKY	39
3.2.1 Metodika dle Strategie regionálního rozvoje	41
3.2.2 Metodika vymezení hospodářsky problémových regionů vybraných krajů.....	48
4. VLASTNÍ PRÁCE	65
4.1 TEORETICKÝ RÁMEC	67
4.2 VÝBĚR JEDNOTLIVÝCH INDIKÁTORŮ	68
4.3 DETEKCE CHYBĚJÍCÍCH HODNOT A OMLEHLÝCH POZOROVÁNÍ.....	70
4.4 NORMALIZACE DAT.....	72
4.5 VÍCEROZMĚRNÁ ANALÝZA	73
4.6 STANOVENÍ VAH A AGREGACE.....	81
4.6.1 Metoda stejných vah.....	83
4.6.2 Metoda analýzou hlavních komponent/faktorovou analýzou	84
4.7 ANALÝZA K POSOUZENÍ ROBUSTNOSTI A CITLIVOSTI.....	86
4.7.1 Techniky řešení nulových hodnot pro geometrickou agregaci a jejich posouzení měř robustnosti	89
4.7.2 Posouzení robustnosti na základě přístupu k odlehlým pozorováním.....	92
4.7.3 Posouzení robustnosti na základě metody normalizace	94
4.7.4 Posouzení robustnosti na základě stanovených vah.....	97
4.7.5 Posouzení robustnosti na základě metody agregace I a agregace II.....	100
4.7.6 Posouzení robustnosti na základě metod agregace.....	102
4.8 BACK TO DETAILS	104
4.8.1 Výhody a nevýhody zvolených metod	105
4.9 VZTAH S OSTATNÍMI PROMĚNNÝMI	107
4.10 PREZENTACE A VIZUALIZACE VÝSLEDKŮ.....	109
4.11 NÁVRH METODOLOGICKÉHO APARÁTU KONSTRUKCE KOMPOZITNÍHO INDIKÁTORU K IDENTIFIKACI HOSPODÁŘSKY PROBLÉMOVÝCH REGIONŮ ČR	113
5. VÝSLEDKY A DISKUSE	115
6. ZÁVĚR	119
7. SEZNAM POUŽITÝCH ZDROJŮ	124
PŘÍLOHY	132

Seznam obrázků

Obrázek 1	Hospodářsky problémové regiony dle Ministerstva pro místní rozvoj ČR .44
Obrázek 2	Sociálně znevýhodněné oblasti dle Ministerstva pro místní rozvoj ČR 45
Obrázek 3	Vymezení metropolí, aglomerací, regionálních center vyššího řádu a hospodářsky a sociálně ohrožených území pro účely SRR..... 48
Obrázek 4	Schéma postupu vlastní části disertační práce..... 66
Obrázek 5	Schéma postupu vymezení teoretického rámce 67
Obrázek 6	Hospodářsky problémové a rizikové okresy dle KI 11431 pro rok 2012.. 111
Obrázek 7	Hospodářsky problémové a rizikové okresy dle KI 11431 pro rok 2016.. 112
Obrázek 8	Návrh metodologického aparátu konstrukce kompozitního indikátoru k identifikaci hospodářsky problémových regionů ČR (KI 11431) 114

Seznam tabulek

Tabulka 1	Výběr z popisné statistiky 2016 (kompletní popisná statistika viz Příloha 38) 72
Tabulka 2	Anti-image matice pro rok 2012..... 77
Tabulka 3	Úprava anti-image matice pro rok 2012 78
Tabulka 4	KMO a Bartlettův test..... 79
Tabulka 5	Podíl vysvětleného rozptylu jednotlivými komponentami pro rok 2012 79
Tabulka 6	Podíl vysvětleného rozptylu jednotlivými komponentami pro rok 2016 80
Tabulka 7	Přehled vytvořených kompozitních indikátorů za kombinace použitých metod..... 82
Tabulka 8	Stanovené váhy bez použití pilířů a s pilíři..... 84
Tabulka 9	Tabulka komponentních zátěží pro výpočet vah pro rok 2016..... 85
Tabulka 10	Výpočet váhy pro rok 2016 85
Tabulka 11	Finální PCA váhy pro roky 2012 a 2016 86
Tabulka 12	Detekce extrémních a odlehlých pozorování u typu kompozitního indikátoru na základě hodnot z-skóre..... 87
Tabulka 13	Výpočet měr robustnosti pro porovnání KI dle technik řešení nulových hodnot pro geometrickou agregaci (2012 a 2016)..... 90
Tabulka 14	Výpočet měr robustnosti pro všechny uvažované typy KI (2012 a 2016)... 92
Tabulka 15	Výpočet měr robustnosti pro porovnání KI dle přístupu k odlehlým pozorováním (2012 a 2016)..... 93
Tabulka 16	Výpočet měr robustnosti pro porovnání KI dle typu vah (2012 a 2016)..... 98
Tabulka 17	Výpočet měr robustnosti pro porovnání KI dle typu agregace (2012 a 2016) 100
Tabulka 18	Spearmanův korelační koeficient pro jednotlivé typy KI a medián pořadí105
Tabulka 19	Souhrn metod normalizace 106
Tabulka 20	Vybrané typy KI jako nejvhodnější (2012 a 2016)..... 107
Tabulka 21	Výše koeficientu determinace v regresní analýze u nejvhodnějších typů KI (2012 a 2016)..... 108
Tabulka 22	Regresní koeficienty regresního modelu KI 11431 (2016) 109

Seznam grafů

Graf 1	Dendrogram – rok 2012.....	74
Graf 2	Dendrogram – rok 2016.....	75
Graf 3	Výstup z programu SPSS – Cattelův sutinový graf (Scree-Plot) pro rok 2012..	80
Graf 4	Výstup z programu SPSS – Cattelův sutinový graf (Scree-Plot) pro rok 2016..	81
Graf 5	Výběr okresů – odlehlá pozorování dle typu KI pro rok 2016.....	89
Graf 6	Výběr okresů – Box-Plot pro pořadí KI jednotlivých okresů – porovnání technik ošetření nulových hodnot pro geometrickou transformaci za rok 2016.....	91
Graf 7	Výběr okresů – Box-Plot pro pořadí KI jednotlivých okresů – porovnání dle přístupu k odlehlým pozorováním za rok 2016.....	94
Graf 8	Výběr okresů – Box-Plot pro pořadí KI jednotlivých okresů – porovnání metod normalizace za rok 2016.....	95
Graf 9	Výběr okresů – výsledné pořadí KI jednotlivých okresů – porovnání metod normalizace za rok 2016.....	96
Graf 10	Výběr okresů – výsledné pořadí KI jednotlivých okresů – porovnání mediánu metod normalizace za rok 2016.....	97
Graf 11	Výběr okresů – výsledné pořadí KI jednotlivých okresů – porovnání metod stanovení vah za rok 2016.....	99
Graf 12	Výběr okresů – výsledné pořadí KI jednotlivých okresů – porovnání mediánu metod stanovení vah za rok 2016.....	99
Graf 13	Výběr okresů – Box-Plot pro pořadí KI jednotlivých okresů – porovnání metod jednostupňové a dvoustupňové agregace za rok 2016.....	101
Graf 14	Výběr okresů – výsledné pořadí KI jednotlivých okresů – porovnání metod jednostupňové a dvoustupňové agregace za rok 2016.....	102
Graf 15	Výběr okresů – výsledné pořadí KI jednotlivých okresů – porovnání metod agregace I za rok 2016.....	103
Graf 16	Výběr okresů – výsledné pořadí KI jednotlivých okresů – porovnání mediánu metod lineární, geometrická agregace a součet pořadí za rok 2016.....	104

Seznam příloh

Příloha 1	Seznam všech uvažovaných indikátorů dle metodik jednotlivých krajů a SRR	132
Příloha 2	Výčet zvolených ukazatelů za hospodářskou oblast použitých pro další výpočty.....	133
Příloha 3	Výčet zvolených ukazatelů za sociální oblast použitých pro další výpočty ..	135
Příloha 4	Korelační matice pro rok 2012	138
Příloha 5	Korelační matice pro rok 2016	139
Příloha 6	Tabulka komponentních zátěží pro výpočet vah pro rok 2012.....	140
Příloha 7	Finální pořadí dle jednotlivých typů KI (bez outlierů) (2016-a)	141
Příloha 8	Finální pořadí dle jednotlivých typů KI (s outliery) (2016-b)	142
Příloha 9	Finální pořadí dle jednotlivých typů KI (bez outlierů) (2012-a).....	143
Příloha 10	Finální pořadí dle jednotlivých typů KI (s outliery) (2012-b)	144
Příloha 11	Box-Plot pro jednotlivé pořadí okresů s označením typu kompozitního indikátoru (2012)	145
Příloha 12	Box-Plot pro jednotlivé pořadí okresů označením typu kompozitního indikátoru (2016)	146
Příloha 13	Box-Plot pro pořadí KI jednotlivých okresů – porovnání technik ošetření nulových hodnot pro geometrickou transformaci (2012)	147
Příloha 14	Box-Plot pro pořadí KI jednotlivých okresů – porovnání technik ošetření nulových hodnot pro geometrickou transformaci (2016)	148
Příloha 15	Box-Plot pro pořadí KI jednotlivých okresů – porovnání dle přístupu k odlehlým pozorováním (2012).....	149
Příloha 16	Box-Plot pro pořadí KI jednotlivých okresů – porovnání dle přístupu k odlehlým pozorováním (2016).....	150
Příloha 17	Korelační matice (Spearmanův korelační koeficient) mezi jednotlivými typy KI (2016)	151
Příloha 18	Box-Plot pro pořadí KI jednotlivých okresů – porovnání metod normalizace (2012)	152
Příloha 19	Box-Plot pro pořadí KI jednotlivých okresů – porovnání metod normalizace (2016)	153
Příloha 20	Výsledné pořadí KI jednotlivých okresů – porovnání metod normalizace za rok 2012	154
Příloha 21	Výsledné pořadí KI jednotlivých okresů – porovnání metod normalizace za rok 2016	155
Příloha 22	Výsledné pořadí KI jednotlivých okresů – porovnání mediánu metod normalizace za rok 2012	156
Příloha 23	Výsledné pořadí KI jednotlivých okresů – porovnání mediánu metod normalizace za rok 2016	157
Příloha 24	Box-Plot pro pořadí KI jednotlivých okresů – porovnání metod stanovení vah (2012).....	158
Příloha 25	Box-Plot pro pořadí KI jednotlivých okresů – porovnání metod stanovení vah (2016).....	159
Příloha 26	Výsledné pořadí KI jednotlivých okresů – porovnání metod stanovení vah za rok 2012	160
Příloha 27	Výsledné pořadí KI jednotlivých okresů – porovnání metod stanovení vah za rok 2016	161

Příloha 28	Výsledné pořadí KI jednotlivých okresů – porovnání mediánu metod stanovení vah za rok 2012	162
Příloha 29	Výsledné pořadí KI jednotlivých okresů – porovnání mediánu metod stanovení vah za rok 2016	163
Příloha 30	Box-Plot pro pořadí KI jednotlivých okresů – porovnání metod jednostupňové a dvoustupňové agregace (2012)	164
Příloha 31	Box-Plot pro pořadí KI jednotlivých okresů – porovnání metod jednostupňové a dvoustupňové agregace (2016)	165
Příloha 32	Výsledného pořadí KI jednotlivých okresů – porovnání metod jednostupňové a dvoustupňové agregace za rok 2016	166
Příloha 33	Výsledného pořadí KI jednotlivých okresů – porovnání metod agregace I za rok 2012	167
Příloha 34	Výsledného pořadí KI jednotlivých okresů – porovnání metod agregace I za rok 2016	168
Příloha 35	Výsledného pořadí KI jednotlivých okresů – porovnání mediánu vybraných metod agregace I za rok 2012	169
Příloha 36	Výsledného pořadí KI jednotlivých okresů – porovnání mediánu vybraných metod agregace I za rok 2016	170
Příloha 37	Popisná statistika 2012	171
Příloha 38	Popisná statistika 2016	172

Seznam použitých zkratek

CLU	Cluster Analysis, shluková analýza
ČSÚ	Český statistický úřad
EU	Evropská unie
FA	Factor analysis, faktorová analýza
GJ	Generelové jednotky
IQR	Interquartile Range, interkvartilové rozpětí
KI	Kompozitní indikátor
KMO	Kaiser – Meyer – Olkin kritérium
LAU	Local Administrative Units, místní správní jednotky
OECD	The Organisation for Economic Co-operation and Development, Organizace pro hospodářskou spolupráci a rozvoj
PCA	Principle Component Analysis, analýza hlavních komponent
PRÚO	Programu rozvoje územního obvodu
RURÚ	Rozbor udržitelného rozvoje území obcí
SO POÚ	Správních obvodů obcí s pověřeným obecním úřadem
SRR	Strategie regionálního rozvoje
SRÚOK	Strategie rozvoje územního obvodu kraje
MAD	Median Absolute Deviation, mediánové absolutní odchylky
MAR	Missing at Random, náhodně chybějící hodnoty
MCAR	Missing Completely at Random, zcela náhodné chybějící hodnoty
MF	Ministerstvo financí
MMR	Ministerstvo pro místní rozvoj
MPSV	Ministerstvo práce a sociálních věcí
NMAR	Not Missing at Random, nenáhodné chybějící hodnoty
NUTS	Nomenclature of Territorial Units for Statistics, Nomenklatura územních statistických jednotek
ÚAP	Územně analytické podklady

1. Úvod

Každý region má svá specifika, jak v oblasti demografické, hospodářské, sociální, tak v oblasti životního prostředí, a v rámci těchto oblastí disponuje různými zdroji. Důsledkem rozdílů ve zdrojích jednotlivých regionů vznikají disparity, a tak mezi regiony může docházet k nerovnoměrnému rozvoji. Různé hospodářské úrovně mezi nimi nadále přetrvávají, a je tedy důležité tyto disparity a posuny ve vývoji analyzovat jako podklad pro nastavení možných politických nástrojů, které by mohly pomoci disparity a znevýhodnění zmírnit či eliminovat.

Pro lepší porozumění problematice je nutné disparity mezi regiony a jejich změny neustále monitorovat, přičemž pak lze nalézt vhodný kompozitní indikátor (KI), který pomůže problematiku snáze pochopit. V posledních letech narůstá zájem o vytvoření nástroje pro srovnání regionů za použití kompozitních indikátorů, vzhledem k vysokému počtu ekonomických, sociálních a environmentálních dat, která jsou k dispozici (Pavlík a kol., 2014). Konstrukce a využití kompozitních indikátorů není v České republice na úrovni krajů či okresů důsledně řešenou problematikou. Pro tvorbu kompozitních indikátorů jsou k dispozici metodologická doporučení v *Handbook on Constructing Composite Indicators: Methodology and User Guide, Brussels: OECD (2008)*. Ovšem veřejná správa nedisponuje dostatečným množstvím odborníků, kteří by se touto problematikou zabývali na úrovni krajů či okresů, a tvorba kompozitních indikátorů na této úrovni je spojena s řadou metodologických nejasností (Minařík a kol., 2013). Z tohoto důvodu jsou v disertační práci diskutovány různé metodiky konstrukce KI pro stanovení hospodářsky slabých oblastí podle Strategii regionálního rozvoje a Programů rozvoje vybraných krajů, protože na úrovni krajů či okresů pro ně jednotná metodika neexistuje. Dle zvolených proměnných na základě těchto dokumentů bude sestaveno celkem čtyřicet osm typů kompozitních indikátorů za použití kombinací postupů ošetření odlehlých pozorování, metod normalizace, určování vah, agregace a technik řešení nulových hodnot pro geometrickou agregaci, jejichž výsledky budou vyhodnocovány a porovnávány. Disertační práce tak může především celkově přispět k rozvoji metodologie konstrukcí kompozitních indikátorů a navrhovaný KI může sloužit regionům jako podklad pro metodický postup. Tento návrh pro tvorbu kompozitních indikátorů může být vhodný pro strategické rozhodování, plánování a nastavení politických nástrojů.

2. Cíl práce a metodika

Přetrvávající hospodářské rozdíly mezi regiony je nezbytné neustále monitorovat a vyhodnocovat, zda dochází k jejich prohlubování, či nikoliv. Mimo jiné je třeba pozorovat směr tohoto rozvoje regionů. K tomuto účelu velice dobře poslouží kompozitní indikátor, který umožňuje agregaci většího počtu individuálních faktorů (ukazatelů za hospodářskou a sociální oblast) v jeden ukazatel. Tímto ukazatelem (KI) lze komplexně sledovat a porovnávat regiony s jednoduchou interpretací výsledků. Navržené vstupní ukazatele budou zvoleny ve vzájemné souvztažnosti s ukazateli pro stanovení hospodářsky slabých regionů dle dokumentů Strategie regionálního rozvoje České republiky pro jednotlivá období a metodik vybraných krajů.

2.1 Cíl práce

Vytvoření kompozitního indikátoru bude představovat využití jednorozměrných a vícerozměrných statistických metod. Tvorba KI bude zahrnovat celou řadu kroků, v rámci nichž budou naplněny cíle práce. V těchto krocích dochází hned k několika rozhodnutím volby metody, např. metody normalizace, stanovení vah, metody agregace. Proto bude ve vlastní části disertační práce sestavena řada různých variant KI za použití kombinací metod. Stěžejním dokumentem pro konstrukci kompozitních indikátorů je publikace vydaná v roce 2008 *Handbook on Constructing Composite Indicators: Methodology and User Guide*, Brussels: OECD, která představuje metodologický základ disertační práce. Po posouzení robustnosti, vztahů s ostatními proměnnými a zvážení veškerých výhod a nevýhod jednotlivých metod bude výstupem jedna finální varianta konstrukce KI, která dovolí charakterizovat hospodářsky problémové regiony a může jim posloužit jako návrh metodologického aparátu.

Hlavním cílem disertační práce je návrh metodologického aparátu konstrukce kompozitního indikátoru k identifikaci hospodářsky problémových okresů ČR, dle kterého bude možné stanovit nerovnosti mezi regiony v oblasti hospodářské a sociální. Dílčím cílem je nalezení nejvhodnější sady proměnných, komparace jednotlivých kombinací postupů ošetření odlehlých pozorování, metod normalizace, určování vah, agregace a technik řešení nulových hodnot pro geometrickou agregaci prezentované na datové matici sestavené z ukazatelů

pro stanovení hospodářsky problémových okresů (LAU 1) ČR. Dále pak zpracování závěrů, které vyplynou z výše uvedených výpočtů. Základní zdroj dat budou tvořit údaje z Českého statistického úřadu (ČSÚ), databáze KROK (ČSÚ) a data z vybraných ministerstev, především Ministerstva financí (MF) a Ministerstva práce a sociálních věcí (MPSV) na úrovni LAU 1 (okres), kromě Hlavního města Prahy, za běžné standardní roky 2012 a 2016. Tyto roky byly ke komparaci v případové studii vlastní části práce zvoleny proto, že v posledních letech nebyla situace příliš stabilní a za standardních podmínek, když od roku 2019 sužuje svět pandemie COVID-19.

Důvod výpočtu k detekci hospodářsky problémových regionů udává zákon o podpoře regionálního rozvoje SRR, který vymezuje podmínky pro podporované regiony, a stanovením soustavy indikátorů je tento požadavek splněn. Mimo jiné je také cílem podpory regionálního rozvoje navyšování konkurenceschopnosti v regionech. (MMR, 2021)

2.2 Metodika

Pro konstrukci kompozitního indikátoru budou použity jak jednorozměrné, tak vícerozměrné statistické metody. V první řadě budou provedeny výpočty základních statistických charakteristik, které vypovídají o základních vlastnostech souboru, například o variabilitě či normalitě rozdělení. Na základě Shapiro-Wilkova testu, popřípadě Kolmogorov-Smirnovova testu bude posouzena normalita rozdělení souboru. Poté budou data podrobena explorační analýze a pomocí koeficientů šikmosti a špičatosti se odhalí odlehlé a extrémní hodnoty. Též grafické zobrazení dle krabicového diagramu (Box-Plot) prokáže odlehlá pozorování. V důsledku těchto hodnot mohou být silně ovlivněny výsledky statistické analýzy (Hebák, 2005). Ovšem podle Melouna (2002) bychom měli zvážit, zda odstraňovat proměnné s odlehlým pozorováním pro metodu hlavních komponent, i přestože se jedná o metodu na odlehlé hodnoty citlivou, a to z důvodu zachování cenných informací. Z tohoto důvodu bude vytvořeno několik kompozitních indikátorů porovnávajících jak KI s ošetřením odlehlých případů v datové matici, tak bez jejich ošetření.

V další fázi budou aplikovány vícerozměrné statistické metody. Nejdříve korelační analýza, která prokáže závislost mezi ukazateli a bude tak nápomocna k výběru sady proměnných pro sestavení kompozitního indikátoru. Dále pak analýza hlavních komponent či shluková

analýza k zjištění skryté struktury vstupních proměnných. Poté budou diskutovány kombinace metod normalizace, metody stanovení vah a agregace. Veškeré výpočty budou zpracovány v programu IBM SPSS Statistics 25 či Microsoft Excel 2016. Ve vlastní části práce bude aplikován tento postup jako případová studie k detekci hospodářsky slabých regionů, kde budou porovnány stabilní běžné roky 2012 a 2016.

Konstrukce kompozitního indikátoru

Kompozitní indikátory (agregované ukazatele) slouží ke komplexnímu hodnocení a umožňují tak srovnání regionů na základě výsledného skóre KI a tím jsou nápomocny pochopení širší veřejností. Umožňují porovnání výkonnosti vybrané jednotky v čase nebo s ostatními jednotkami. Je důležité dodržení transparentnosti jednotlivých vstupních proměnných a samotné konstrukce kompozitního indikátoru z důvodu věrohodných výsledů a jejich interpretace (OECD, 2008). Podobnou teorii již publikovali Funtowicz a Ravetz (1990) a ta se v oblasti informačních technologií dostala do obecného povědomí jako „*Garbage in, garbage out*“, ovšem tuto teorii lze chápat obecně tak, že pokud jsou nesprávná vstupní data, výstupy a závěry z nich budou také nesprávné.

Stěžejní je vhodná definice měřeného jevu, která by měla co nejvíce zrcadlit realitu, každý ukazatel by měl odpovídat věcnému, časovému a prostorovému vymezení (Hindls a kol., 2004). Dle Hudrlíkové (2014) z pohledu časového vymezení může docházet k potížím se srovnatelností údajů v rozdílných časových okamžicích, jinak s ním nebývá problém. Avšak k největším nesrovnalostem může docházet v oblasti věcného vymezení, neboť představuje přesné určení a definici sledovaného jevu a znaku odpovídající určité části reality, např. metodické popisy ukazatelů Českého statistického úřadu. Ovšem svět je natolik složitý, že lze velice obtížně přesně popsat všechny atributy a je nutné je generalizovat a tímto způsobem dochází k tzv. adekvačnímu problému. Přestože je systém metodik velice propracovaný, vzniká diference mezi pojmem a tím, co skutečně pomocí ukazatele měříme, tzv. adekvační mezera. U kompozitního indikátoru tak může vznikat větší riziko, protože je tvořen z několika individuálních ukazatelů agregovaných v ukazatel jeden, zachycující vícerozměrný koncept. Podle autorů Fischera a Sixty (2009) adekvace neboli připodobnění představuje přiřazení indikátorů získaných v rámci statistického přístupu k reálným jevům.

K prostorovému vymezení je hojně využívanou klasifikací pro stanovení standardizovaných územních jednotek klasifikace územních statistických jednotek NUTS (Nomenclature of Territorial Units for Statistics), což je hierarchický systém pro členění hospodářského území Evropské unie za účelem sběru, rozvoje a harmonizace regionálních statistik a sociálně-ekonomických analýz regionů (EUROSTAT, 2012). CZ-NUTS klasifikace charakterizuje územní struktury do úrovně krajů (NUTS 3). Má právní základ v nařízení Evropského parlamentu a Rady č. (ES) 1059/2003. Klasifikace představuje šest úrovní územní struktury NUTS v ČR pro potřeby statistické a analytické a pro potřeby EU. ČSÚ je vymezuje následovně (2012-b):

NUTS 0 – stát Česká republika,

NUTS 1 – představuje území celé ČR,

NUTS 2 – oblast sdružených krajů,

NUTS 3 – kraje (vyšší územní samosprávné celky),

NUTS 4 – okresy,

NUTS 5 – představuje obce.

LAU (Local Administrative Units) je systém určený především pro potřeby statistik regionů. Od systému NUTS se liší tím, že LAU nemá legislativní oporu. LAU mají dvě úrovně tvořené samostatnými číselníky propojenými vazbami (ČSÚ, 2012-c):

LAU 1 – v ČR tvořeny okresy. V roce 2008 územní jednotky na úrovni LAU 1 převzaly kódy od jednotek dříve označovaných jako NUTS 4,

LAU 2 – v ČR představují obce (dříve NUTS 5).

Dle Nardo a kol. OECD (2008) je vhodné sestavovat kompozitní indikátor v deseti následujících krocích, které jsou diskutovány níže.

2.1.1 První krok – Sestavení teoretického rámce

Teoretický rámec by měl být sestaven takovým způsobem, aby poskytl vhodnou základnu pro výběr a kombinaci indikátorů pro vytvoření smysluplného kompozitního indikátoru. V tomto kroku by mělo být stanoveno následující (Nardo a kol. OECD, 2008):

a. Definice konceptu – Jasně definovat, co je kompozitním indikátorem měřeno. Nejprve by měl pomoci porozumět a definovat vícerozměrný jev, který bude měřen pomocí kompozitního indikátoru.

b. Určení podskupin – Nápomocná může být vnořená struktura indikátorů rozdělených do skupin, které na sobě nemusí být statisticky nezávislé.

c. Identifikace výběrového kritéria – Výběr základních indikátorů s popisem, proč ten či onen indikátor byl či nebyl vybrán pro sestavení kompozitního indikátoru. Je zapotřebí stanovit, CO, PROČ a JAK bude kompozitním indikátorem měřeno (Vértesy JRC, 2018).

Dle Saltelliho (2007) by měl být teoretický rámec zformován tak, aby poskytl základ pro výběr a kombinaci jednotlivých indikátorů do smysluplného kompozitního indikátoru ve vzájemné souvztažnosti s účelem jeho použití. Existují tři úrovně seskupení indikátorů (Vértesy JRC, 2018):

Jednotlivé sady indikátorů představují samostatné indikátory či statistiky.

Takzvané *tematické ukazatele* jsou takové, které tvoří skupiny v rámci určité oblasti nebo tématu. Tento přístup vyžaduje identifikaci souboru ukazatelů, které spolu nějakým způsobem souvisí.

Kompozitní indikátory se vytvářejí pomocí tematického zkompileování ukazatelů do syntetického indexu.

Vértesy JRC (2018) označuje indikátory, které tvoří určité skupiny dle oblasti či tématu za dimenze, takzvané pilíře. Občas je struktura natolik složitá, že mohou být pilíře tvořeny dalšími sub-pilíři, jako například Global Innovation Index (WIPO, Cornell, INSEAD), jehož struktura je tvořena dvěma sub-indexy, které jsou sestaveny ze sedmi pilířů a 21 sub-pilířů, v nichž je 82 různých indikátorů.

2.1.2 Druhý krok – Výběr jednotlivých ukazatelů

Jednotlivé proměnné by měly být vybírány podle analytické spolehlivosti, měřitelnosti a dostupnosti v zemi, aby měl sledovaný jev význam a zároveň byl ve vztahu s ostatními indikátory. Tato část postupu zahrnuje stanovení silných a slabých stránek jednotlivých indikátorů či například tvorbu souhrnné tabulky s charakteristikou dat, jejich dostupností, uvedením zdroje či typu (tvrdá, měkká data, input, output atd.), protože ovlivňují silné a slabé stránky konečného kompozitního indikátoru. (Nardo a kol. OECD, 2008) Jak uvádí Munda a Nardo (2005), je nezbytné rovněž určit směr (polaritu) indikátorů, který není vždy zcela jasný. Již při výběru vstupních indikátorů bychom měli mít na paměti, že bude kompozitní indikátor v budoucnosti přepočítáván a aktualizován (Vértesy JRC, 2018).

2.1.3 Třetí krok – Nahrazení chybějících hodnot a detekce odlehlých pozorování

Chybějící hodnoty by mohly ovlivnit robustnost kompozitního indikátoru. Je třeba zvážit různé typy přístupů k nahrazení chybějících hodnot a práce s extrémními pozorováními k vytvoření kompletní sady dat bez chybějících hodnot s podrobným vysvětlením vybraných postupů nahrazení chybějících dat. (Nardo a kol. OECD, 2008)

Vértesy JRC (2018) uvádí následující metody pro ošetření chybějících hodnot:

Vyřazení hodnoty (listwise či pairwise).

Nahrazení jednotlivých hodnot – průměrem, mediánem, modem, substitucí, pomocí regrese či náhodnou hot-deck imputací.

Metody založené na modelování – metoda maximální věrohodnosti či vícenásobné imputace.

Dále je také vhodné posoudit typ chybějících dat, která mohou být:

MCAR (missing completely at random) – chybějící hodnota zcela náhodně bez závislosti na sledovaném ukazateli, chybějící náhodně nezávislá přímo na ukazateli, ale s vazbou na jiné ukazatele,

MAR (missing at random) – chybějící hodnota je ve vztahu s proměnnými s kompletními informacemi,

NMAR (not missing at random) – chybějící hodnota nenáhodně. Chybějící je ve vztahu s proměnnou s chybějícími pozorováními.

Také je třeba věnovat pozornost odlehlým a extrémním hodnotám, protože mohou ovlivnit následující kroky při sestrojování kompozitního indikátoru a může tak nastat problém (Nardo a kol. OECD, 2008). Jak uvádí Saisana a Philippas (2012-b), outliery je vždy nutné identifikovat a pečlivě zvážit, jak s odlehlými hodnotami naložit. Dle Cousineau a Chartiera (2010) by odlehlé hodnoty měly být odstraněny. Nicméně, neexistuje jedno jediné jasné řešení problému detekce odlehlých pozorování a jejich následného ošetření. V případech s více proměnnými se současný výzkum přiklání ke klastrování a předpokládá, že izolované klastry jsou pravděpodobně složeny z odlehlých hodnot.

Identifikace odlehlých pozorování v datové matici

Standardizace (z-skóre)

Pro detekci odlehlých pozorování (outlierů) lze využít například z-skóre. Za outlier je možné považovat z-skóre, která jsou menší než $-3,30$ a větší než $+3,30$ (Warner, 2008).

Giacomo JRC (2018) doporučuje hranici $|z_i| \geq 2,5$ pro menší datové soubory (s počtem pozorování $n < 80$) a pro větší datové soubory ($n > 80$) pravidlo $|z_i| \geq 3$.

Koeficienty šikmosti a špičatosti

Podle Hendla (2012) se k výpočtu těchto charakteristik přistupuje různými způsoby, nejčastěji je využíván centrální moment k -toho stupně m_k , jenž lze vyjádřit vzorcem:

$$m_k = \frac{\sum(x_i - \bar{x})^k}{n} \quad (1)$$

Šikmost S_1 měří zešikmení, jinými slovy nesymetrii v datech, a je definována takto:

$$S_1 = \frac{m_3}{m_2^{3/2}} \quad (2)$$

$S_1 = 0$ je rozdělení přibližně symetrické;

$S_1 > 0$ rozdělení s prodlouženým pravým koncem;

$S_1 < 0$ rozdělení s prodlouženým levým koncem.

Špičatost S_2 měří odchylku špičatosti zkoumaného rozdělení od normálního rozdělení:

$$S_2 = \frac{m_4}{m_2^2} - 3 \quad (3)$$

$S_2 = 0$ pokud mají data normální rozdělení;

$S_2 > 0$ s rozdělením ve tvaru plošší křivky (platykurtické);

$S_2 < 0$ s rozdělením ve tvaru špičatější křivky (leptokurtické) (Hendl, 2012).

Groeneveld a Meeden (1984) stanovili kriteria pro absolutní hodnotu $|S_1| > 1$ a $|S_2| > 3,5$. Saisana a Philippas (2012-b) tyto hodnoty pro odhalení asymetrie v datech upravili za použití míry šikmosti s hranicí $|S_1| > 2$ a pro detekci míry špičatosti s hranicí ($|S_2| > 3,5$). Metoda založená na hodnotách šikmosti a špičatosti identifikuje nejnížší počet extrémů, tj. je méně „invazivní“.

Interkvartilové rozpětí

Interkvartilové rozpětí (IQR) je definováno jako rozdíl mezi horním a dolním kvantilem (Meloun, 2012).

$$R_q = \tilde{X}_{75} - \tilde{X}_{25} \quad (4)$$

kde \tilde{X}_{75} je horní kvartil a \tilde{X}_{25} dolní kvartil (Giacomo JRC, 2018).

Hendl (2012) definuje IQR jako charakteristiku rozptýlenosti, jež se používá spolu s kvantily k popisu tvaru dat, když se z nějakého důvodu nechceme spoléhat na průměrové charakteristiky (aritmetický průměr, směrodatná odchylka). V IQR se nachází 50 % dat a není citlivé vůči odlehlým hodnotám, jako je tomu u směrodatné odchylky.

Souček (2006) uvádí, že první (dolní) kvartil ($Q1$) odděluje 25 % vzestupně seřazených jednotek s nejnižšími hodnotami. Druhý (prostřední) kvartil ($Q2$) odděluje 50 % seřazených jednotek s nízkými hodnotami od zbylých 50 % jednotek s vysokými hodnotami a mimo jiné se nazývá medián. Třetí (horní) kvartil ($Q3$) odděluje 75 % seřazených jednotek s nízkými hodnotami od zbylých 25 % jednotek s vyššími hodnotami.

Ovšem tato technika interkvartilového rozpětí poukazuje na více odlehlých případů než ostatní výše popsané metody (Giacomo JRC, 2018).

Hojně využívanou metodou je Tukeyovo pravidlo. Hodnota detekovaná jako outlier je dle Greena a kol. (2018) taková, která dosahuje více než 1,5násobku interkvartilového rozpětí (IQR) nad třetím kvantilem (75. percentil) nebo pod prvním kvantilem (25. percentil). Tukeyovu mez lze vypočítat jako $Q1 - 1,5IQR$ a $Q3 + 1,5IQR$, jakékoli pozorování mimo tento interval představuje odlehlé pozorování.

Box-plot

Krabicový graf znázorňuje robustní odhad polohy, mediánu M , posouzení symetrie v okolí kvartilů, posouzení symetrie u konců rozdělení, ale mimo jiné také identifikaci odlehlých pozorování. Prvky výběru ležící mimo interval vnitřních hradeb jsou považovány za podezřelé, obvykle vybočující body (v grafu znázorněny kroužky či hvězdou). (Meloun, 2012) Krabicový graf pracuje pro odhalení odlehlých hodnot s kritériem, jež je založeno

na interkvartilovém rozpětí. Označí hodnoty jako odlehlá pozorování v případě, kdy měření je od dolního nebo horního kvartilu vzdáleno více než $3/2R_q$. Další kritérium vychází ze znalosti mediánové absolutní odchylky (MAD). Pokud je měření vzdáleno od mediánu o více než 5 MAD, pak označí toto pozorování za odlehlé. (Hendl, 2012)

Techniky ošetření odlehlých pozorování

Giacomo JRC (2018) k nahrazení outlierů doporučuje následující metody:

Metoda winsorizace

Winsorizing se podobá metodě trimming, s tím rozdílem, že namísto ponechání prázdných položek v datové matici („oříznutí“) se prázdné buňky vytvořené odstraněním extrémních pozorování nahrazují hodnotami nejbližších pozorování nebo jinými vhodnými hodnotami. Obě techniky ošetření dat, ať už trimming, či winsorizing, ovlivňují popisné statistiky (průměr, směrodatná odchylka atd.). (Eriksson a kol., 2013) Tato technika je vhodná pro proměnné, kde se nachází méně jak 5 odlehlých případů (Giacomo JRC, 2018).

Rodina Box-Coxových transformací

Rodina Box-Coxových transformací je lineární transformace prosté mocninné transformace (Militký a Meloun, 2009). Pokud je třeba ošetřit více jak 5 odlehlých hodnot u proměnné, pak je vhodnější použít tuto metodu (Giacomo JRC, 2018).

2.1.4 Čtvrtý krok – Vícerozměrná analýza

Barré (2010) definuje metodiku konstrukce kompozitního indikátoru jako rozhodovací proces a věnuje se ve své publikaci jednotlivým fázím rozhodování.

Nardo a kol. OECD (2008) uvádí, že průzkumová analýza by měla prověřit celkovou strukturu indikátorů, vhodnost datového souboru a podat vysvětlení metodických rozhodnutí (např. metody stanovení vah, agregace). Je třeba vyhodnotit základní strukturu dat v různých dimenzích za pomoci vícerozměrných metod, např. analýzy hlavních komponent (PCA), faktorové analýzy (FA) či shlukové analýzy. Rovněž je nutné identifikovat podskupiny indikátorů nebo skupiny zemí, které jsou podobné, a interpretovat samostatné komponenty a faktory. Často se používá takzvaná „analýza tandem“, v jejímž rámci lze použít jednotlivé

metody postupně, začít metodou PCA a následně aplikovat algoritmy klastrové analýzy na objekt. Alternativou k „analýze tandemu“ pak může být faktoriálová k-means analýza v kombinaci s k-means metodou klastrové analýzy s prvky FA a PCA. Faktoriálová k-means analýza je vhodná též pro velké datové soubory.

Analýza hlavních komponent

Analýza hlavních komponent (Principal Component Analysis, PCA) je podle Hebáka (2005) diagnostický nástroj pro identifikaci a hodnocení zvláštnosti posuzovaných a analyzovaných údajů. Je jedním z nejužitečnějších nástrojů pro posouzení a prověření kvality vícerozměrných dat. Proto se doporučuje téměř každou vícerozměrnou úlohu začít výpočtem hlavních komponent. Používá se v první řadě jako nástroj pro průzkumovou analýzu dat. Meloun (2002) zmiňuje, že záměr této metody spočívá v transformaci dat z původních proměnných x_i , $i = 1, \dots, m$ do menšího počtu proměnných a nalezení nových proměnných y_j . Tyto nově vzniklé komponenty mají vhodnější vlastnosti, sníží se jejich počet, vysvětlují téměř celou proměnlivost původních proměnných a zároveň jsou nekorelované. Latentní proměnné představují hlavní komponenty a charakterizují lineární kombinace původních proměnných. Lze je interpretovat následovně: první hlavní komponenta y_1 popisuje největší část proměnlivosti neboli rozptylu původních dat, druhá komponenta y_2 popisuje menší část proměnlivosti a poslední komponenta y_n popisuje nejmenší část proměnlivosti původních proměnných. Jinými slovy, komponenty jsou seřazeny podle stupně důležitosti.

Dle Hebáka (2005) by měl tvořit větší rozměr prostor, v němž se data nacházejí, než je počet sledovaných veličin. Vhodný je případ, kdy disponujeme velkým náhodným výběrem z vícerozměrného normálního rozdělení hodnot příliš velkého počtu vzájemně korelovaných veličin. Jsou-li sledované ukazatele v normálním tvaru rozdělení nebo jde o proměnné v odlišných měrných jednotkách, je nutné v komponentní analýze vycházet z korelační matice. Pro metodu hlavních komponent je při stejných měrných jednotkách a relativně podobné variabilitě všech proměnných vhodnější vycházet z kovariační matice. Pokud vyžadujeme, aby nové komponenty co nejvíce vysvětlovaly variabilitu původních proměnných, pak přistupujeme k metodě hlavních komponent. Pomocí kritéria KMO (Kaiser – Meyer – Olkin) lze určit vhodnost pro sestavení hlavních komponent. Hodnoty KMO blízké jedné představují silnou vzájemnou závislost. Hodnoty KMO pohybující

se okolo 0,9 a vyšší se považují za vynikající pro použití analýzy hlavních komponent, popř. faktorové analýzy, okolo 0,8 za chvályhodné, kolem 0,7 za středně užitečné, okolo 0,6 jen průměrné, blízko 0,5 již špatné a pod touto hodnotou za nepřijatelné. Hutcheson (1999) uvádí, že pro jednotlivé proměnné lze míru KMO získat z takzvané anti-image korelační matice, na jejíž diagonále nalezneme hodnoty koeficientů. Tyto koeficienty by měly být vyšší než 0,5. V případě, kdy nejsou vyšší nežli tato hranice, by měly být z další analýzy odstraněny.

Výběr počtu nově vzniklých komponent lze určit dle Kaiserova pravidla, kdy budou do dalšího hodnocení zahrnuty komponenty, jejichž hodnota vlastního čísla je větší než 1 (Hebák, 2005). Podle Melouna (2002) postačují první komponenty k dostatečnému vysvětlení variability původních proměnných v případě, že je součet nejvyšších podílů proměnlivosti dostatečně blízky 1, resp. 100 % (obvykle stačí 80–90 %). Analýzu hlavních komponent například využili ve své studii Max Lu a Enru Wang (2002) k nalezení hlavních faktorů ovlivňujících změny regionálních nerovností mezi čínskými vesnicemi a městy během a po čínské reformě 1978–1998.

Faktorová analýza

Analýza hlavních komponent i faktorová analýza (Factor analysis, FA) představují metody pro redukci počtu původních proměnných. Předpokladem faktorové analýzy je, že každou vstupující proměnnou můžeme popsat lineární kombinací nevelkého počtu společných skrytých faktorů a jednoho chybového faktoru.

Existuje rozdíl mezi metodou hlavních komponent a faktorovou analýzou. Při faktorové analýze usilujeme o vysvětlení závislosti proměnných. K odhadu parametrů faktorového modelu se mnohdy používá metody hlavních komponent, která je aplikována na redukovanou kovariační matici. (Meloun, 2002)

Shluková analýza

Shluková analýza (Cluster analysis, CLU) je jedním z nástrojů vícerozměrných statistických metod, pomocí kterého je možné klasifikovat množiny objektů do několika shluků na základě podobnosti (nepodobnosti, vzdálenosti). Shlukové analýzy lze využít tam, kde se objekty či proměnné rozpadají do tříd. Jinými slovy, množina objektů má sklon

se seskupovat do takzvaných shluků. (Hebák, 2007) Základním problémem shlukové analýzy je kvantitativní vyjádření podobnosti či vzdálenosti objektů. V jednotlivých krocích algoritmů se posuzuje podobnost, respektive vzdálenost dvou objektů, dvou shluků nebo objektu a shluku. (Kubanová, 2003) Nejčastější vzdálenostní mírou je euklidovská vzdálenost zvaná též geometrická metrika, která představuje délku přepony pravoúhlého trojúhelníka. Její výpočet je založen na Pythagorově větě. Kromě toho se užívá rovněž čtverec euklidovské vzdálenosti, který tvoří základ Wardovy metody shlukování. (Meloun, 2004)

Podle Melouna (2002) je možné shlukovou analýzu dělit na hierarchické a nehierarchické shlukování. Přičemž metody hierarchického shlukování se člení dle podobnosti, či nepodobnosti na aglomerativní a divizní postupy shlukování. Metoda si klade za cíl spojování objektů a jejich shluků do dalších, větších shluků. Výhodou této metody je, že není potřeba znát optimální počet shluků. Tento počet se určuje dodatečně. Často využívanou metodou v praxi je metoda hierarchického seskupování s pomocí Wardovy metody. Na základě hierarchické shlukové analýzy je například možné seskupovat do homogenních skupin města tak, aby mohla být dále vybírána k testování různých, například marketingových strategií (IBM Corporation, 2011). Naopak, jak uvádí Meloun (2002), u nehierarchického shlukování je předem stanoven počet shluků, který se může v průběhu výpočtu měnit. Tyto metody se klasifikují na dvě základní skupiny, a to na optimalizační metody a analýzu modů, medoidů. Předpokladem použití shlukové analýzy je co nejmenší korelace mezi proměnnými a standardizace proměnných.

Shluková analýza bude vypočtena na základě Wardovy metody. Při postupu dle této metody se dle Melouna (2002) vybírají takové shluky, ve kterých vychází minimální součet čtverců. Zakládá se tedy na minimalizaci ztráty informace při spojení dvou tříd. Výhodou této metody je, že má sklon odstranit malé shluky, a tím vytvářet shluky podobné velikosti.

2.1.5 Pátý krok – Normalizace dat

Indikátory by měly být normalizovány takovým způsobem, aby byly porovnatelné. Nejdříve je třeba upravit směr proměnných tak, aby vyšší hodnota představovala lepší situaci pro region. Dále je nezbytné zvolit vhodnou metodu normalizace ve vzájemné souvztažnosti

s teoretickým rámcem a stanoveným cílem. Každá z těchto metod normalizace, byť jen nepatrně, ovlivňuje finální pořadí indikátoru. (Del Sorbo JRC, 2018)

Metody normalizace

Existuje celá řada způsobů normalizace, které vedou k různým výsledkům. V disertační práci jsou diskutovány pouze techniky, které jsou používané nejčastěji. Normalizace je nezbytná před provedením agregace dat, neboť jednotlivé indikátory mají často různé měrné jednotky (Nardo a kol. OECD, 2008). Jedná se o změnu rozsahu dat, obvykle to bývá na škálu [0, 1] nebo [0, 100]. Výběr té, či oné metody normalizace závisí na struktuře datové matice a na tom, co bude kompozitním indikátorem měřeno. Ovšem ve většině případů má krok normalizace nejnižší dopad na finální pořadí kompozitního indikátoru (Del Sorbo JRC, 2018).

Metoda pořadí

Metoda pořadí patří mezi nejjednodušší normalizační techniky. Výhodou této metody je, že není ovlivněna odlehlými hodnotami, a umožňuje tak sledovat výkonnost zemí na základě nahrazení původních hodnot pořadím dle vzorce

$$I_{ij}^t = \text{pořadí}(x_{ij}^t) \quad (5)$$

kde x_{ij} je původní hodnota ukazatele i porovnávané jednotky j v daném čase t (Nardo a kol. OECD, 2008).

K nejlepší hodnotě je přiřazeno první pořadí a nejhorší hodnotě ukazatele poslední pořadí. Hudrlíková (2014) uvádí jako výhodu této metody snadnost porozumění a rovněž sjednocení rozptylu a rozpětí pro všechny indikátory. Metoda není citlivá na odlehlá a extrémní pozorování, ovšem pro následující analýzy je možné využít pouze ordinální data s informací o pořadí (Del Sorbo JRC, 2018).

Metoda standardizace (z-skóre)

Tento postup transformuje indikátory na společné měřítko se střední hodnotou nula a směrodatnou odchylkou jedna (Nardo a kol. OECD, 2008).

Vztah výpočtu lze zapsat takto

$$I_{ij}^t = \frac{x_{ij}^t - \bar{x}_{ij=j}^t}{\sigma_{ij=j}^t} \quad (6)$$

kde x_{ij} je původní hodnota ukazatele i pro jednotku j v čase t ,

$\sigma_{ij=j}^t$ směrodatná odchylka i -tého ukazatele přes všechny jednotky j ,

$\bar{x}_{ij=j}^t$ průměr přes všechny jednotky j (regiony) (Nardo a kol. OECD, 2005).

Dle Nardo a kol. OECD (2005) je výhodou této metody, že nezkrusluje hodnoty od průměru a sjednotí rozptyl jednotlivých indikátorů. Přestože z-skóre neeliminuje vliv odlehlých pozorování, jejich vliv není tak vysoký jako u jiných postupů. Přesto indikátory s extrémními hodnotami mají větší vliv na konečný výsledek kompozitního indikátoru, což nemusí být vždy žádoucí. Tento problém může být vyřešen metodou agregace, například vyřazením hodnoty ukazatele s nejlepším či nejhorším výsledkem nebo přiřazením diferenciálních vah (Nardo a kol. OECD, 2008). Jak uvádí Del Sorbo JRC (2018), pokud je žádoucí dosáhnout stejného rozptylu, je vhodná metoda standardizace (z-skóre). Ovšem ne vždy dosahují standardizované hodnoty stejného rozpětí, např. [0,1], jako je tomu u metody Min-Max.

Metoda Min-Max

Použitím metody Min-Max jsou indikátory přepočteny na hodnoty o stejném rozpětí [0, 1] odečtením minimální hodnoty a vydělením variačním rozpětím. Ovšem extrémní nebo odlehlé hodnoty mohou zkreslit transformovaný indikátor. Normalizace Min-Max, která pracuje s rozsahem indikátorů ležících v malém intervalu, má vyšší vliv na kompozitní indikátor než metoda standardizace (z-skóre). (Nardo a kol. OECD, 2008)

Pro použití metody normalizace Min-Max u pozitivně orientovaných indikátorů lze zapsat vztah jako

$$I_{ij}^t = \frac{x_{ij}^t - \min_j(x_i^t)}{\max_j(x_i^t) - \min_j(x_i^t)} \quad (7)$$

kde x_{ij} je hodnota ukazatele i pro jednotku j v čase t (Nardo a kol. OECD, 2008).

U negativně orientovaných indikátorů je třeba použít vzorec s maximální hodnotou v čitateli

$$I_{ij}^t = \frac{\max_j(x_i^t) - x_i^t}{\max_j(x_i^t) - \min_j(x_i^t)} \quad (8)$$

kde x_{ij} je hodnota ukazatele i pro jednotku j v čase t (Nardo a kol. OECD, 2008).

Pokud chceme docílit stejného rozpětí, např. $[0,1]$, pak je vhodné použít metodu Min-Max (Del Sorbo JRC, 2018). Hudrlíková (2014) nevýhodu shledává v tom, že metoda není založena na rozptylu, nýbrž na rozpětí, proto je také citlivější na odlehlá pozorování.

Techniky řešení nulových hodnot pro geometrickou agregaci

V datové matici normalizované pomocí metody Min-Max se nachází nulové hodnoty, neboť se původní hodnoty přepočítávají na škálu 0–1. Dochází tak k problému při aplikaci geometrické agregace. Geometrická agregace vyžaduje striktně pozitivní hodnoty (Adler, 2012). Jednotliví autoři doporučují různá řešení tohoto problému.

Transformace datové matice na škálu 1–10

Saisana a Philippos (2012-b) upřednostňují provést transformaci datové matice na škálu 1–10 z toho důvodu, že by indikátory blízké hodnotě 0 dosahovaly téměř nulového celkového skóre. A to za použití vzorce

$$\frac{x_i - \min(x)}{\max(x) - \min(x)} \times 9 + 1 \quad (9)$$

$$\frac{\max(x) - x_i}{\max(x) - \min(x)} \times 9 + 1 \quad (10)$$

(Saisana a Philippos, 2012-b)

Převedení nulové hodnoty na velmi nízké číslo

Roelfeldt (2018) doporučuje převést nulové hodnoty na velmi malé číslo (pod tzv. detekčním limitem), které je menší než další nejmenší číslo v datové matici. Také Saisana a kol. (2017) ve svém návodu s doporučeními pro sestavení kompozitního indikátoru (COIN Tool) nahrazují nulové hodnoty hodnotou 0,1. Hudrlíková (2014) používá opatrnější řešení a v případě nulové hodnoty ukazatele substituuje hodnotou 0,0001.

Přičtení konstanty

V rámci geometrické transformace lze vyřešit problém nulové hodnoty v datové matici normalizované pomocí metody Min-Max přičtením hodnoty 1. Jak uvádí Roenfeldt (2018), je možné upravit měřítko tak, aby byla ke každému číslu přičtena 1 a poté hodnota 1 odečtena z výsledné geometrické agregace.

2.1.6 Šestý krok – Stanovení vah a agregace

Dle základního teoretického rámce stanoveného na počátku by měly být indikátory agregovány, popřípadě váženy. Zvolená metoda stanovení vah a agregace má větší dopad na finální kompozitní indikátor nežli ostatní kroky postupu (Nardo a kol. OECD, 2008).

Stanovení vah

Existuje celá řada metod stanovení vah (Papadimitriou JRC, 2018):

Stejně váhy

Váhy založené na statistických metodách

- Analýza hlavních komponent (PCA)

- Faktorová analýza (FA)

- Analýza datových obalů (DEA)

- Regresní přístup

Váhy založené na expertním/veřejném mínění

- Proces rozdělování rozpočtu (BAP)

- Analytický hierarchický proces (AHP)

- Preferenční analýza (Conjoint analýza)

Avšak neexistuje žádná osvědčená metodika, jak vybrat nejlepší metodu vážení.

V disertační práci jsou uvažovány scénáře kompozitního indikátoru bez vah, se stejnými vahami a vahami stanovenými pomocí metody hlavních komponent (PCA).

Metoda stejných vah

Postup vážení pomocí stejných vah je jeden z nejjednodušších, tyto váhy lze vyčíslit jako podíl

$$w_i = \frac{1}{Q} \quad (11)$$

kde pro w_i je váha u i -tého ukazatele ($i = 1, \dots, Q$) pro každou porovnávanou jednotku.

Hudrlíková (2014) shledává v této metodě riziko, že jedné dimenzi (pilíři) bude přiřazena větší váha tím, že bude kompozitní indikátor zastoupen větším počtem ukazatelů, což může mít vliv na konečný výsledek kompozitního indikátoru. Doporučuje tak tuto metodu v případě, kdy je k dispozici velké množství ukazatelů a není jasná představa, která metoda by měla být použita. Pokud není známa míra důležitosti dílčích vstupů v odborné literatuře, pak je vhodné použití stejných vah. Jejich výhodou je jednoduchost výpočtu, ovšem je třeba brát v potaz, že stejné váhy nezaručují stejnou důležitost a rovnoměrný příspěvek jednotlivých indikátorů v kompozitním indikátoru.

Metoda analýzou hlavních komponent / faktorovou analýzou

Analýza hlavních komponent a faktorová analýza byly již popsány v rámci vícerozměrných metod. Ovšem pomocí těchto metod je možné též stanovit váhy pro kompozitní indikátor, čemuž bude věnována tato část metodiky.

Stanovení vah přístupem FA či PCA funguje mimo jiné také jako redukční nástroj ke snížení většího počtu proměnných na menší množinu (Papadimitriou JRC, 2018). Nardo a kol. OECD (2008) doporučují výběr počtu faktorů, popř. komponent s vlastní hodnotou větší než jedna a zároveň ty, které jednotlivě přispívají k vysvětlení celkového rozptylu více jak 10 %. Dále volí počet faktorů tak, aby kumulativní procento vysvětleného celkového rozptylu bylo větší než 60 %. Při konstrukci vah vychází z matice komponentních/faktorových zátěží po rotaci. Poté je třeba spočítat čtverec těchto zátěží a přepočítat na škálu 0–1. Dále se vyjádří podíl vysvětlené variability faktorem a celkové vysvětlené variability. Váhy k jednotlivým indikátorům se vyčíslí jako součin tohoto podílu a faktoru s největší zátěží (vysvětlující nejvíce variability) v relativním vyjádření. Tento přístup rovněž doporučuje Nicoletti a kol. (2000), kteří jej použili pro Technology Achievement Index (TAI). Největší rozdíl mezi touto metodou a přístupem doporučovaným

Berlagem a Terweduwem (1988) je, že jejich přístup váží kombinaci všech proměnných (namísto aby byla váha přiřazena pouze jednomu faktoru) a váhy jsou dány jednoduše faktorovými zátěžemi (namísto sumy čtverců faktorových zátěží) (Döpke a kol., 2017).

Analýzu hlavních komponent považují Nardo a kol. OECD (2005) za užitečnou průzkumnou techniku pro zkoumání korelační struktury skupin proměnných s tím, že faktorová analýza se obvykle používá jako doplňková metoda s cílem prověřit vztahy mezi subindikátory. FA představuje způsob, jak kontrolovat homogenitu spíše než reprezentovat pluralitu. FA lze ve skutečnosti použít pouze tehdy, když proměnné korelují a pohybují se ve stejném směru.

Agregační metody

Agregační metody je možné rozdělit do dvou skupin, a to na metody lineární a geometrické agregace. Dále je lze také členit na metody založené na pořadí a metody založené na skóre.

Metody založené na pořadí

Mezi nejjednodušší metody založené na pořadí patří výpočet:

- a. Součet pořadí
- b. Medián pořadí

Výsledkem není skóre, jako je tomu u ostatních metod, nýbrž pořadí. U těchto metod se nevyužívá vah, proměnné vstupují do kompozitního indikátoru se stejnou důležitostí. (Hudrlíková, 2014) Tyto jednoduché techniky nejsou ovlivněny odlehlými pozorováními. Součet pořadí a medián pořadí se používají tehdy, když je potřeba získat pouze pořadí. (Nardo a kol. OECD, 2008) Tyto přístupy lze vyjádřit následujícími vztahy:

Součet pořadí

$$KI_j = \sum_{i=1}^Q \text{pořadí}_{ij} \quad (12)$$

kde KI_j představuje kompozitního indikátor pro jednotku j ($j = 1, \dots, N$), ukazatel i ($i = 1, \dots, Q$) (Nardo a kol. OECD, 2008).

Medián pořadí

$$KI_j = \tilde{x}(\text{pořadí}_{ij}) \quad (13)$$

kde KI_j představuje kompozitního indikátor pro jednotku j ($j = 1, \dots, N$), ukazatel i ($i = 1, \dots, Q$), \tilde{x} medián (Hudrlíková, 2014).

Metody založené na skóre

Nejvíce využívanou metodou agregace bývá (Caperna JRC, 2018):

- a. Aritmetický průměr
- b. Geometrický průměr

Lineární agregace je nejvyužívanější metoda agregace. U tohoto typu agregace je perfektní kompenzace, tj. kompenzace špatného výkonu v jednom směru s dobrým výkonem v druhém směru (Caperna JRC, 2018). Aritmetického průměru například využívá Global Talet Competitiveness Index (GTCI).

U geometrického průměru je částečná kompenzace, tj. snižuje penalizací nízký výkon v některých aspektech (Caperna JRC, 2018). Nardo a kol. OECD (2005) uvádí, že lineární agregace představuje plnou kompenzaci a může být použita, pokud všechny indikátory mají stejné měrné jednotky. Jinými slovy, horší výkon v jednotlivých indikátorech může být kompenzován dostatečně vysokými hodnotami ostatních indikátorů. Geometrická agregace je vhodná, pokud jsou striktně pozitivní ukazatele vyjádřeny ve škálách. Představuje částečnou kompenzaci, tzn. vyrovnávací schopnost je nižší, pokud kompozitní indikátor obsahuje indikátory s nízkými hodnotami. Mimo jiné lineární agregace odměňují sub-indikátory u vah proporcionálně, zatímco geometrické agregace odměňují více zemí s vyššími skóre. Ovšem u obou metod agregační váhy vyjadřují kompromis mezi ukazateli: deficit v jedné dimenzi mohou být vyrovnány přebytkem v jiné dimenzi.

Saisana (2011) například doporučuje u dvoustupňové agregace použití lineární agregace v pilířích a geometrickou agregaci pilířů.

2.1.7 Sedmý krok – Analýza k posouzení robustnosti a citlivosti

Robustnost je mírou kapacity postupu zůstat netečným vůči malým, ale záměrným změnám parametrů metody a poskytuje informaci o jeho spolehlivosti během běžného používání (Youden, 1967). Před samotným výpočtem robustnosti a citlivosti doporučuje De Pedraza JRC (2018) provedení statistické koherence, jinými slovy ověření síly korelace mezi pilíři a sub-pilíři, kdy není vhodné ponechávat v datové matici negativní korelace, velice nízké korelace a je třeba ošetřit velice vysoké korelace.

Vyřazení jednoho z indikátorů s vysokou hodnotou korelace je nutností, nikoli že by tato vysoká hodnota byla pouze postačující podmínkou pro vyřazení (Saltelli a kol., 2005). Podle De Pedraza JRC (2018) výskyt velice vysoké korelace v datové matici má za následek index „uni-dimensional“, který je plně robustní a možná redundantní. Velice nízké korelace naopak tvoří index „multi-dimensional“, který je citlivý na předpoklady.

Saltelli a kol. (2005) považují indikátor, který je zkonstruovaný z vysoce korelovaných veličin, za velmi robustní, a to se bude projevovat velmi nízkou citlivostí hodnot kompozitního indikátoru na použitý typ transformace ukazatelů, zvolené metody určení vah a modifikaci parametrů v ostatních fázích analýzy. Zda je takový indikátor vhodný k použití, pak záleží na teoretickém rámci. Použití analýzy citlivosti a neurčitosti při konstrukci kompozitního indikátoru přispívá k jeho kvalitě a je nezbytnou součástí tvorby, neboť malá změna v konstrukci indexu či vah může dramaticky zamíchat pořadím např. jednotlivých zemí.

V této fázi by měla být provedena analýza k posouzení robustnosti systému kompozitního indikátoru, např. mechanismus pro zahrnutí, nebo vyloučení indikátoru, normalizační schéma, nahrazení chybějících údajů, výběr vah a metody agregace (Nardo a kol. OECD, 2008). Lze využít následujících nástrojů ke zvýšení robustnosti a důvěryhodnosti (De Pedraza JRC, 2018):

- Transparentnost
- Statistická spolehlivost (reliability)
- Analýza nejistoty a citlivosti

Při konstrukci kompozitního indikátoru dochází k několika rozhodovacím fázím. Často tak dochází k subjektivní volbě metody, např. metody normalizace, stanovení vah, metody agregace apod. Z tohoto důvodu je důležité zjistit nejistotu, která v případě použití té či oné metody vzniká.

Nardo a kol. OECD (2008) uvádí, že kombinace metod nejistoty a analýzy citlivosti může pomoci posoudit robustnost ukazatele, aby se zvýšila jeho transparentnost. Analýza nejistoty tedy ověřuje, jak jednotlivé zdroje nejistoty ovlivňují hodnotu kompozitního indikátoru. Analýza citlivosti pak řeší, jakou mírou jednotlivé zdroje nejistoty přispívají k hodnotě rozptylu kompozitního indikátoru a jeho pořadí. Zdroje nejistoty by měly být minimalizovány.

Podle Nardo a kol. OECD (2005) lze na kompozitní indikátory pohlížet jako na modely a doporučují provedení analýzy nejistoty na základě metody Monte Carlo, kde závisle proměnná představuje rank (CI), tzn. získané pořadí kompozitního indikátoru a \overline{R}_s (průměrný posun pořadí). Analýza nejistoty je tedy založena na simulacích, které jsou vypočteny na základě rovnic tvořících model. Vytvoří se vícenásobné ohodnocení modelu s k náhodně vybranými vstupními faktory, ke kterým se přiřadí pravděpodobnostní funkce hustoty (PDF). Přičemž vstupní faktory (proměnné) představují právě dílčí metody popsané výše. Například vstupní proměnné mohou být stanoveny následovně:

x_1 práce s chybějícími hodnotami,

x_2 metoda normalizace (z-skóre, Min-Max apod.),

x_3 práce se sub-indikátory,

x_4 metoda agregace (lineární, geometrická),

x_5 metoda stanovení vah (bez vah, stejné váhy, PCA apod.).

Míra nejistoty je vyjádřena jako rozptyl.

Hudrlíková (2014) například používá k hodnocení robustnosti jednotlivých metod porovnání k průměrnému posunu v hodnocení kompozitního indikátoru \overline{R}_s definovaného vzorcem

$$\overline{R}_s = \frac{1}{N} \sum_{j=1}^N |\text{Pořadí}_{\text{ref}}(KI_j) - \text{Pořadí}(KI_j)| \quad (14)$$

kde KI_j je kompozitní indikátor pro $j = 1, 2, \dots, N$ počet regionů, popř. zemí.

Tato míra posunu v hodnocení se počítá jako průměr absolutní hodnoty rozdílů v pořadí regionů (popř. zemí) s ohledem na referenční pořadí ve všech regionech N . Jako referenční hodnota je stanovena střední hodnota všech pořadí za daný region. Rovněž lze na problematiku pohlížet z jiného úhlu pohledu, a to tak, že hodnota N může značit kompozitní indikátor a statistiku lze spočítat pro pořadí jednotlivých KI s referenční hodnotou střední hodnoty KI . Hodnoty blíží se k nulové hranici poukazují na nižší variabilitu v pořadí, a tedy menší odchýlení pořadí od mediánu. Nardo a kol. OECD (2005) doporučují pracovat vždy s finálním pořadím kompozitního indikátoru KI_j , nikoli přímo s hodnotou výsledku.

2.1.8 Osmý krok – „Back to the details“

Kompozitní indikátory by měly být především transparentní a vhodné k rozložení jejich podkladových indikátorů a hodnot. Přestože je kompozitní indikátor používán pro souhrnné vyhodnocení, je vhodné provést také jeho rozložení na dílčí komponenty, identifikovat jednotlivé indikátory a vypočítat korelaci, pokud je to možné. Také lze vyhodnotit data pomocí následujících grafických technik:

Leadři a zaostávající (leaders and laggards): Výkon každého ukazatele lze porovnat s lídrem, zaostávajícím a průměrným výkonem ve sloupcovém grafu. (Nardo a kol. OECD, 2005)

Pavučinový diagram: Sférické polární souřadnice, které určují umístění bodu ve třech rozměrech. Základem těchto souřadnic je množina tří vzájemně kolmých os, Ox , Oy a Oz , které se protínají v O . (Upton, 2014)

Metoda semaforu: Další způsob, jak ilustrovat výkonnost země/regionu pomocí odstínů jednotlivých barev, značek apod. (Nardo a kol. OECD, 2005)

2.1.9 Devátý krok – Vztah s ostatními proměnnými

Další krok obnáší zjištění korelace mezi kompozitním indikátorem a dalšími indikátory a identifikaci jednotlivých vazeb pomocí regresní analýzy. Korelační analýza by neměla být zaměňována s kauzalitou. Změna v jednotlivých indikátorech nemusí nutně vést ke změně kompozitního indikátoru a naopak. Pro testy kauzality tvoří vstupní matici data v časové řadě, což bývá často problém z důvodu jejich dostupnosti. (Nardo a kol. OECD, 2008)

2.1.10 Desátý krok – Presentace a vizualizace výsledků

Kompozitní indikátory lze vizualizovat nebo prezentovat různými způsoby, které mohou ovlivnit jejich následnou interpretaci, pomocí grafů, tabulek a kartogramů (Nardo a kol. OECD, 2008). Jak uvádí Hudrlíková (2014), metody normalizace, stanovení vah a agregace jsou na sobě při konstrukci kompozitního indikátoru závislé. Volba typu jednotlivých metod a jejich kombinace mají významný vliv na výsledek finálního kompozitního indikátoru.

3. Teoretická východiska

Disparity mezi regiony a jejich změny je důležité sledovat. V některých regionech je hospodářská situace horší nežli v jiných, což je spojeno s rizikem vylidňování, opouštění regionu a v neposlední řadě odlivu kvalifikované pracovní síly. Hospodářsky slabé regiony dle MMR (2013a) s nadprůměrnou mírou nezaměstnanosti jsou Liberec, Vsetín, Opava, Znojmo, Sokolov, Děčín, Most, Chomutov, Bruntál, Teplice, Hodonín, Šumperk, Karviná, Ústí nad Labem, Jeseník, Semily, Karlovy Vary a Český Krumlov (ČSÚ, 2015). Mnohé z těchto regionů leží v příhraniční oblasti České republiky. Vliv nejvyššího dosaženého vzdělání je rovněž důležitý. Nezaměstnané osoby v České republice se základním vzděláním tvoří 26 % z celkového počtu nezaměstnaných, osob se středoškolským vzděláním či výučním listem bez maturity tvoří 38 %, se středoškolským vzděláním s maturitou 25 % a u vysokoškoláků podíl tvoří 11 % (ČSÚ, 2016). Prosperita regionu závisí stále více na schopnosti občanů a podniků v rámci území (KOMISE EVROPSKÝCH SPOLEČENSTVÍ, 2008). Životní podmínky obyvatelstva, jejich stav a vývoj také představují velmi důležitý ukazatel celé ekonomické situace a především perspektiv dalšího rozvoje daného území (Svatošová, Svobodová, 2015).

Hospodářská situace zemí, se kterými z největší části Česká republika sousedí (Německo a Rakousko), je lepší než v samotné České republice, takže jsou pro obyvatele atraktivní z hlediska využití dojíždění do zaměstnání. I přesto, že dojíždění přes hranice států je spojeno s mnoha negativními důsledky, lidé mohou těžit z nižších nákladů na bydlení, nižší ceny nemovitostí a vyšší mzdy na druhé straně hranice. Podle výsledků strategických dokumentů Ministerstva pro místní rozvoj ČR oblasti lokalizované v příhraničí nejčastěji spadají do skupiny hospodářsky slabých regionů (MMR, 2013a). Průměrný podíl nezaměstnaných 5,11 % byl překročen ve 34 regionech na úrovni LAU 1 (ČSÚ-KROK, 2016). Především většina regionů na periferiích se markantně liší od ostatních. Periferní regiony byly v minulosti vnímány tak, že jejich zeměpisná poloha byla příznivější a mohou se znovu otevřít jako prostory pro nové ekonomické činnosti. Dle Knudsena (2018) venkovské periferní regiony již nejsou oblastmi vnitřní ekonomické expanze, ale oblastmi problematickými. Po druhé světové válce měly národní politické nástroje pro regionální rozvoj dva hlavní cíle: podpořit hospodářský růst a rozvoj a zajistit rovnoměrné rozložení obyvatelstva v celé zemi. Je třeba podotknout, že dichotomizace mezi venkovským

a městským životem je zkruslována rostoucím počtem lidí, kteří jsou schopni žít na obou místech, protože spousta lidí má ve venkovských prostorech letní sídla, zahrady, chaty a chalupy. Eriksson (2010) uvádí, že periferní oblasti ve většině zemí procházejí fází, kdy jsou vnímány jinak, jako příhraniční, jako podřadné, jako problematické. Ze strukturálního pohledu jsou periferie v posledních letech především považovány za oblasti problémů. Na druhé straně se na ně pohlíží jako na součásti kraje, které jsou marginalizovány jako zaostávající a odlišné, ale bez atraktivity pro lidi, kteří chtějí vést moderní život.

Binek a kol. (2012) identifikují v regionech negativní disparity, které v daných regionech znamenají problémy, a pozitivní disparity, de facto rozvojové póly. Pro nastavení podpůrných nástrojů je pak stěžejní orientace regionální politiky, a to zda je koncipována jako stabilizační, podporující slabé regiony, nebo jako rozvojová, podporující silné regiony. Regionální politika Evropské unie (EU) byla vytvořena za účelem vyrovnání hospodářských, sociálních a dalších rozdílů. Zajištění rovných životních podmínek obyvatelstva patří k základním cílům regionální politiky jak v rámci komunitární unie, tak i České republiky. Posouzení změn v rozvoji regionů představuje poměrně složitý úkol, protože je třeba zvážit velký počet ukazatelů. (Svatošová, 2012) Tyto disparity však nemusí být vnímány vždy negativně, do jisté míry mohou být i pozitivní. Cílem regionu je taková alokace zdrojů v oblasti a směřování regionální politiky takovým způsobem, aby docházelo k celkovému rozvoji a využití potenciálu regionu. Regionální politika EU je určena pro všechny regiony s cílem podpořit vytvoření pracovních míst, obchodní konkurenceschopnosti, hospodářského růstu a vylepšení kvality života občanů. (Evropská komise, 2015a) EU poskytuje dotace znevýhodněným regionům na úrovni NUTS2 (oblast sdružených krajů) s HDP na obyvatele nižším než 75 % průměru EU. Politika je cílena na regiony NUTS2 a menší plochy LAU 1 – okresy (Local Administrative Units) nejsou brány v úvahu. (Becker, 2010) Prostředky z fondu soudržnosti vycházely z rozhodnutí odkazujícího k průměrnému HDP na hlavu. Během roku 2016 se prováděl přezkum přidělených prostředků, na základě jehož závěrů byly uskutečněny změny v systému – regionální politiky a Evropa 2020. (EUROSTAT, 2016) Regiony jsou členěny na méně rozvinuté regiony, které mají HDP na obyvatele nižší než 75 % průměru EU, přechodové regiony, s HDP na obyvatele v rozmezí 75 % až 90 % průměru EU, a více rozvinuté regiony, s HDP na obyvatele 90 % průměru EU a více (Evropská komise, 2015b).

3.1 Měření regionálních disparit za použití kompozitního indikátoru

Kompozitní indikátor představuje dle OECD (2004) vytvoření jednoho jediného ukazatele sestavením individuálních ukazatelů pomocí agregace na základě modelu zachycujícího měřený vícerozměrný koncept.

Podle Huschky a Wagnera (2010) zaměření se pouze na ekonomické ukazatele umožňuje pouze velice úzký pohled na to, co představuje blahobyt v regionech, nejen při konstrukci kompozitních indikátorů. Zvážení dalších ukazatelů z jiných dimenzí (sociální, environmentální atd.) může perspektivu značně rozšířit.

OECD (2014) používá například Well-Being Index, který zahrnuje devět různých dimenzí týkajících se blahobytu na úrovni regionů TL-2, což odpovídá Evropskému NUTS 1 a v některých zemích NUTS 2. Těchto devět dimenzí tvoří vzdělání, pracovní trh, příjmy, bezpečnost, zdraví, životní prostředí, občanská angažovanost, dostupnost služeb a bydlení. V rámci těchto dimenzí je bráno v úvahu celkem jedenáct proměnných. OECD využívá k detekci a následnému ošetření outlierů hranici pod 10. percentilem a nad 90. percentilem.

K měření regionálních disparit se hojně využívá HDP. Ovšem podle Wahl a kol. (2010) má tento ukazatel své limity a vypovídá pouze o potenciálu aktivit směřujících ke změně blahobytu. Nezahrnuje domácí práce, dobrovolnictví či aktivity ve stínové ekonomice. Stejně tak nejsou zahrnuty do indexu spotřeby zdrojů či poškození životního prostředí a rozdělení příjmů je více méně ignorováno. Přestože, je ukazatel HDP základním měřítkem národních účtů, HDP na úrovni LAU 1 není směrodatným faktorem pro stanovení podpory EU (KOMISE EVROPSKÝCH SPOLEČENSTVÍ, 2008). Dle Eurostatu (2014) venkovské, horské a vzdálené regiony potřebují intenzivnější podporu v rozvoji dopravy a ostatních spojení, jako jsou internet a energetické sítě. Lepší definice těchto specifických faktorů, včetně stanovení příslušné sady proměnných, může pomoci k lepší alokaci hospodářských zdrojů, rychlejšímu ekonomickému růstu, konvergenci znevýhodněných regionů a celé EU.

Například Döpke a kol. (2017) se zabývají sestavením kompozitního indikátoru k měření blahobytu a disparit mezi regiony namísto HDP na obyvatele. Autoři detekují odlehlá pozorování na základě hranic percentilů, hodnoty pod 4. percentilem a nad 96. percentilem

vyřazují z dalších úvah. Pro normalizaci proměnných využívají metodu Min-Max k přepočtení hodnot na škálu 0–10. U dimenzí, které zahrnovaly více než jednu proměnnou, autoři použili aritmetického průměru. V rámci výpočtu vážení a agregace autor uvažoval několik metod vážení, a to stejné váhy, váhy stanovené pomocí faktorové analýzy (dva typy výpočtů FA vah), na základě regresní analýzy a regrese založené na faktorech z faktorové analýzy. Pro stanovení vah pomocí faktorové analýzy byly uvažovány dva různé přístupy, a to postup podle Nardo a kol. OECD (2008) a Berlageho a Terweduwea (1988). Dle Nardo a kol. OECD (2008) se váhy počítají jako sumy čtverců faktorových zátěží a Berlage a Terweduwe (1988) stanovují váhy jednoduše faktorovými zátěžemi, viz kapitola 2.1.6. Výsledky kompozitního indikátoru v závěru porovnávají s hodnotami HDP na obyvatele, kdy nejvyššího korelačního koeficientu ($r = 0,82$) mezi použitou metodou a HDP na obyvatele dosahují metody konstrukce KI, kdy byly použity stejné váhy a PCA/FA za použití výpočtu vah podle Nardo a kol. OECD (2008). Nejnižších korelací pak dosahovaly metody, u kterých byla použita regresní analýza pro stanovení vah. Výsledky především poukazují na to, že výběr metody agregace a vážení silně ovlivňuje výsledný kompozitní indikátor. Tyto dva přístupy vážení stejné váhy a PCA dle přístupu Nardo a kol. OECD (2008) budou také uvažovány v této disertační práci.

Papadimitriou JRC (2018) využívá stejných vah v rámci dimenzí například pro index lidského rozvoje (HDI). Tento index se potýkal s nedokonalou substitucí v dimenzích, proto došlo v jeho konstrukci ke změně na výpočet pomocí stejných vah, aby se dosáhlo snížení kompenzační povahy lineární agregace (United Nations Development Programme, 2010). Metodu PCA ke stanovení vah používá Papadimitriou JRC (2018) v případě, že je pouze jedna hlavní komponenta (řešení o jedné dimenzi) a koeficienty první hlavní komponenty přepočtené na škálu 0–1 se používají jako váhy. Tento postup stanovení vah byl použit při tvorbě Social Progress Index.

Poledníková a Melecký (2017) diskutují k měření regionálních disparit několik přístupů vážení, neboť stanovení vah silně ovlivňuje výsledný KI. Autoři se zaměřují na stejné váhy a objektivní (statistické) váhy. Z objektivních metod uvažují entropickou metodu a metodu CRITIC (The Criteria Importance through Intercriteria Correlation). V závěru autoři dospěli k tomu, že pro typ dat použitých v jejich studii jsou nejvhodnější entropická metoda a metoda CRITIC, která používá korelační analýzu k detekci kontrastů mezi kritérii. Tyto metody volí

jako vhodné, protože představují objektivní metody bez subjektivního rozhodování. Ke stejnému závěru dospěla Minarčíková (2016) pro stanovení regionálních disparit pomocí metod multikriteriálního rozhodování.

Melecký a Stáničková (2015) navrhli vážený kompozitní indikátor pro měření regionálních disparit CWAID (The Composite Weighted Aggregate Index of Regional Disparities) k analýze ekonomických, sociálních a teritoriálních disparit na úrovni NUTS 2 pro Visegrádskou skupinu zemí v letech 2000–2011. Autoři používají celkem 24 různých proměnných, z nichž vždy 8 je zástupcem jedné ze tří dimenzí. Proměnné standardizují podle metody z-skóre a ke stanovení vah používají entropickou metodu. Mimo jiné provádějí konstrukci kompozitního indikátoru přes tři různé úrovně v rámci každé dimenze separé. Tyto tři úrovně jsou následující:

I. Přípravná fáze – první krok zahrnující explorační analýzu, standardizaci, výpočet mediánu a stanovení míry vzdálenosti (euklidovská vzdálenost).

II. Kalkulace sub-indexů pro regionální disparity – v této fázi je provedena faktorová analýza a výstupem je pak sub-index disparit za každou dimenzi zvlášť součinem čtverců euklidovské vzdálenosti a faktorových zátěží vypočtených dle Nardo a kol. OECD (2008).

III. Kalkulace vah a agregace indexu pro stanovení disparit – ke stanovení vah autoři používají entropickou metodu. Na závěr je vypočten finální CWAID váženým součtem jednotlivých dimenzí.

3.2 Regionální politika a metodiky vymezení hospodářsky problémových regionů České republiky

Současná regionální politika podle Hučka (2009) používá tzv. Neo-endogenní přístup. Tento přístup nastoupil v druhé polovině sedmdesátých let minulého století. Typickými nástroji dnešní regionální politiky jsou podpory malých a středních firem, tvorby a inovací, tvorby klastrů, aplikace marketingu a managementu v územním rozvoji, deregulační a decentralizační opatření, partnerství veřejného a soukromého sektoru, péče o zahraniční investory, investice do lidských zdrojů, podpora kvality životního a sociálního prostředí.

Obecná definice pojmu region neexistuje. Majerová (2011) region charakterizuje jako územní celek, který lze vyčlenit z rozsáhlejšího území. Kritérium vyčlenění bývá zvoleno s konkrétním cílem, ať už ekonomickým, sociálním či prostorového uspořádání a podobně.

Regionální politika na konkrétní druhy územních celků se uplatňuje na základě typologie regionů provedené podle hospodářské výkonnosti oblastí, dlouhodobého socio-ekonomického vývoje a míry koncentrace aktivit a geografické polohy. Dle těchto aspektů můžeme v České republice rozlišit podle krajů na: rozvíjející se regiony, regiony s průměrnou nebo nižší dynamikou rozvoje a zaostávající nebo jinak problémové regiony. Regiony ohrožené regionálními rozdíly jsou regiony s významnými disparitami v oblasti hospodářského, environmentálního a sociálního rozvoje, ve srovnání s ostatními regiony daného územního celku. Tyto regiony vyžadují institucionální podporu k vyrovnání disparit.

Diskutovány jsou různé metody pro stanovení hospodářsky problémových regionů. Nejdříve metodiky, které používá Strategie regionálního rozvoje pro léta 2007–2013, SRR 2014–2020 a SRR 2021+. Poté postupy a vybrané ukazatele pro výpočet, které si stanoví jednotlivé kraje samostatně, neboť pro ně neexistuje jednotná metodika. Pro využití strukturálních fondů Evropské unie se používá klasifikace na hospodářsky slabé regiony (EU nazývá jako regiony objective 5b) a strukturálně slabé regiony (objective 2) (Jacoby, 2006).

Hospodářsky problémové regiony jsou v krajích vymezovány v následujících dokumentech:

a. Strategie regionálního rozvoje ČR (SRR ČR)

b. Strategie rozvoje územního obvodu kraje (SRÚOK)

Kraj v rámci své samostatné působnosti dle Zákona o podpoře regionálního rozvoje (Zákon č. 248/2000 Sb.) podporuje regiony vymezené v programu rozvoje územního obvodu kraje podle svých konkrétních potřeb s ohledem na vyvážený rozvoj svého územního obvodu. Vymezení hospodářsky problémových regionů je provedeno na úrovni správních obvodů obcí s pověřeným obecním úřadem (SO POÚ). Kraje i obce ve svých koncepčních dokumentech zohledňují hlavní směry a výsledky dokumentů vyššího řádu, tzn. včetně SRR ČR 2021+. V rámci hodnocení některých krajských dotačních programů je stanoveno kritérium hodnocení žádostí na základě naplnění strategie a cílů Strategie rozvoje územního obvodu kraje.

c. Rozbor udržitelného rozvoje území obcí (RURÚ)

Rozbor udržitelného rozvoje vyplývá ze Zákona č. 183/2006 Sb. Stavební zákon a jeho prováděcích předpisů. Rozbor udržitelného rozvoje je nedílnou součástí územně analytických podkladů, které jsou nástrojem územního plánování. Základní sledovanou jednotkou je území obce (LAU2).

Výraznější rozdíly ve vyhodnocení SRÚOK a RURÚ jsou patrné pouze v hospodářském pilíři a jsou způsobeny především správní jednotkou pro hodnocení (POÚ versus LAU2). Výběr indikátorů a použitá metoda hodnocení na výsledek nemají pravděpodobně větší vliv. (Krajský úřad Olomouckého kraje, 2018)

3.2.1 Metodika dle Strategie regionálního rozvoje

Ministerstvo pro místní rozvoj ČR dle zákona č. 2/1969 Sb. ve znění pozdějších předpisů je ústředním orgánem státní správy zabývající se regionální politikou. Definiuje její zásady a podniká kroky k jejich uskutečnění. Strategie regionálního rozvoje představuje stěžejní dokument zaměřený na regionální politiku ČR na úrovni státu. Tento dokument obsahuje například analýzu stavu regionálního rozvoje, charakteristiku silných a slabých stránek v rozvoji jednotlivých krajů a okresů, strategické cíle regionálního rozvoje ČR, vymezení státem podporovaných regionů a podobně. (MMR, 2006) Od roku 1998 se stanovují na úrovni okresů dva typy oblastí se soustředěnou podporou státu, a to strukturálně postižené regiony a hospodářsky slabé regiony (Labounková, 2005).

V rámci vymezení regionů se soustředěnou podporou státu je zapotřebí stanovit oblasti, které je nutno podpořit. Podle zákona §4 zákona č. 248/2000 Sb., o podpoře regionálního rozvoje jsou v současné době pro určení problémových regionů České republiky používány Strategie regionálního rozvoje ČR. Od roku 2000 byl přijat zákon o podpoře regionálního rozvoje, při němž byla vytvořena Strategie pro léta 2000–2010 a poté na období 2007–2013. Posléze byla zpracována v roce 2013 Strategie regionálního rozvoje ČR pro léta 2014–2020. (Chabičovská, 2008) Aktuálně je platná Strategie regionálního rozvoje ČR 2021+. Jako důvod výpočtu udává MMR (2021) zákon o podpoře regionálního rozvoje SRR, který „*stanovuje podmínky pro vymezení státem podporovaných regionů*“ a vymezením indikátorů je tento požadavek splněn. Dalším cílem podpory regionálního rozvoje je také „*přispět ke zvyšování konkurenceschopnosti regionů*“.

Vymezení hospodářsky slabých regionů dle Strategie regionálního rozvoje ČR 2007–2013

Regiony se soustředěnou podporou státu, v rámci těchto regionů se dále rozeznávají strukturálně postižené regiony, hospodářsky slabé regiony a venkovské regiony (MMR, 2006).

Strukturálně postižené regiony MMR (2006) definuje jako oblasti s hlubokými strukturálními změnami a růstem nezaměstnanosti. Toto je způsobeno nevhodnou kvalifikační strukturou nabídkové strany na trhu práce, odpovídající minulé struktuře hospodářství, neadekvátní technickou a podnikatelskou infrastrukturou apod.

Hospodářsky slabé regiony jsou takové, do kterých spadají oblasti, které mají podstatně nižší úroveň hospodářského a sociálního rozvoje, než je průměrná úroveň České republiky (Dočkal, 2004). Tyto regiony jsou podle MMR (2006) specifické nízkou ekonomickou výkonností, spojenou s nízkými mzdami, slabou ekonomickou aktivitou, vysokou nezaměstnaností, nepříznivou geografickou polohou a nerozvinutou technickou infrastrukturou. Tyto regiony se v tomto období stanovovaly např. na základě ukazatelů Míra nezaměstnanosti, Výše mzdových příjmů a příjmů ze zemědělství, Úroveň daňových příjmů, Rozsah útlumu primárních odvětví, Hustota zalidnění.

Venkovské regiony jsou dle Labounkové (2005) oblasti, které jsou specifické nízkou hustotou obyvatelstva, poklesem počtu obyvatel a vyšším podílem zaměstnanosti v zemědělství. K základním ukazatelům pro jejich vymezení patří vývoj počtu obyvatelstva, struktura jeho zaměstnanosti a podíl obyvatelstva ve venkovských obcích.

Ostatní regiony představují území, kam spadají například bývalé vojenské prostory, pohraniční regiony, postižené živelnými pohromami, regiony se silně narušeným či poškozeným životním prostředím a další (MMR, 2006).

Vymezení hospodářsky slabých regionů dle Strategie regionálního rozvoje ČR 2014–2020


Ve „Strategii regionálního rozvoje České republiky pro léta 2014 až 2020“ (SRR) se na rozdíl od SRR 2007–2013 v rámci regionů se soustředěnou podporou státu vymezují pouze hospodářsky problémové regiony a ostatní regiony.

Regiony se soustředěnou podporou státu:

Hospodářsky problémové regiony jsou takové, které stejně jako hospodářsky slabé regiony ve SRR 2007–2013 vykazují v rámci vybraných hospodářských a sociálních ukazatelů nižší úroveň, než je průměrná úroveň v ČR. Tyto oblasti jsou typické nadprůměrnou mírou nezaměstnanosti, nízkou životní úrovní, nízkým stupněm ekonomické výkonnosti, nízkým průměrným příjmem obyvatel a nepříznivým demografickým vývojem (viz Obrázek 1). Určení hospodářsky problémových regionů na období 2014–2020 se opírá o tyto ukazatele (MMR, 2013-a):

- ✓ *Odhad výkonnosti ekonomiky (váha 25%):* ukazatel odhadu výkonnosti ekonomiky (odhad HDP) za ORP (obce s rozšířenou působností), který představuje peněžní vyjádření celkové hodnoty statků a služeb nově vytvořených za určité časové období. Tento ukazatel se vypočte za pomoci produkční metody.
- ✓ *Míra nezaměstnanosti (váha 55%):* ukazatel počtu nezaměstnaných osob.
- ✓ *Zadluženost ORP na 1 obyvatele (váha 5%):* dluh vykázaný podle metodiky využívané pro potřeby Státního závěrečného účtu. Data obsahují dluh obcí a jimi zřizovaných příspěvkových organizací.
- ✓ *Dávky v hmotné nouzi – příspěvek na živobytí, bydlení, mimořádnou okamžitou pomoc (váha 10%):* ukazatel představuje objem finančních prostředků osobám či rodinám, které nemají postačující příjmy a jejich sociální a majetková situace neumožňuje uspokojení základních životních potřeb na společensky přijatelné úrovni. Ukazatel obsahuje příspěvek na živobytí, doplatek na bydlení a mimořádnou okamžitou pomoc.
- ✓ *Saldo migrace na 1 000 obyvatel (váha 5%):* ukazatel salda migrace vyjadřuje rozdíl počtu přistěhovalých a vystěhovalých osob na 1 000 obyvatel za stejné období a na daném území.

Obrázek 1 Hospodářsky problémové regiony dle Ministerstva pro místní rozvoj ČR




Zdroj: MMR (2013-b)

Ostatní regiony představují oblasti, které se stanovují na základě ukazatelů míry dlouhodobé nezaměstnanosti za ORP, počtu vyplacených dávek obyvatel 15–64 let za ORP, odhad celkového počtu romských obyvatel zkoumaných sociálně vyloučených lokalit v kraji či počtu obcí s POÚ (pověřeným obecním úřadem) v rámci ORP s výskytem sociálně vyloučených lokalit. Do těchto regionů spadají (MMR, 2013-a):

Sociálně znevýhodněné oblasti, které představují ORP s dlouhodobou nezaměstnaností a oblasti s výskytem sociálně vyloučených lokalit a lokalit ohrožených sociálním vyloučením (viz Obrázek 2).

Současné a bývalé vojenské újezdy jsou vyčleněná území pro účel obrany státu. Část těchto území je navracena k civilnímu užití.

Obrázek 2 Sociálně znevýhodněné oblasti dle Ministerstva pro místní rozvoj ČR



Zdroj: MMR (2013-b)

Vymezení hospodářsky slabých regionů dle Strategie regionálního rozvoje ČR 2021+

Ve „Strategii regionálního rozvoje České republiky pro léta 2021+“ (SRR) vychází ze Strategického rámce ČR 2030, který je zastřešujícím rozvojovým dokumentem ČR. V dokumentu SRR 2021+ podle MMR (2021) se na rozdíl od SRR pro roky 2014–2020 vymezují:

Metropolitní území představují Pražské, Brněnské a Ostravské metropolitní území včetně jejich venkovského zázemí.

Aglomerace jsou ostatní krajská města a jejich zázemí mimo Prahy, Brna a Ostravy.

Regionální centra a jejich venkovské zázemí

Regionální centra vyššího řádu identifikována z národní úrovně, sídla s více než 15 tis. obyvateli a spádovým územím alespoň 30 tis. obyvatel.

Regionální centra nižšího řádu identifikována z krajské úrovně, sídla s alespoň 5 tis. obyvateli a spádovým územím cca 10 tis. obyvatel.

Venkovská zázemí je definováno jako území, které nespadá do kategorie metropolitních území a aglomerací. Některá regionální centra jsou zároveň zázemím metropolí/aglomerací. Specifickým příkladem je město Mladá Boleslav jako typ regionálního centra, neboť mu je umožněno využívat v letech 2021–2027 nástroj ITI (nástroj uplatnění integrovaného přístupu s využitím Evropských strukturálních a investičních fondů), stejně jako metropolitním územím a aglomeracím.

Strukturálně postižené kraje jsou kraje (Ústecký, Moravskoslezský a Karlovarský) s koncentrací sociálních, ekonomických a enviromentálních problémů s vazbou na Strategický rámec hospodářsky restrukturalizace Ústeckého, Moravskoslezského a Karlovarského kraje (MMR, 2021).

Hospodářsky a sociálně ohrožené území jsou správní obvody obcí ORP definované pomocí následujících proměnných (MMR, 2021):

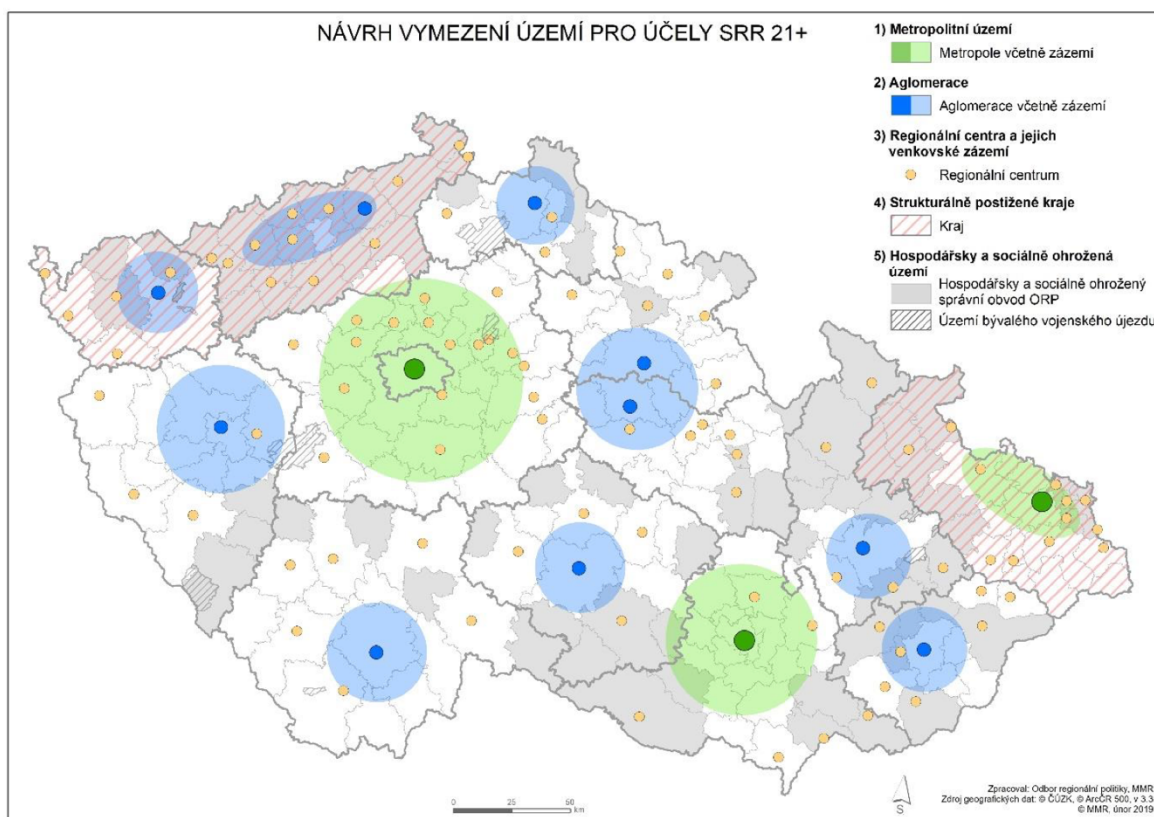
- ✓ *Intenzita bytové výstavby,*
- ✓ *Hrubá míra celkového přírůstku (%):* základní ukazatel vyjadřující úbytek či přírůstek obyvatelstva v obci. Výpočet: Přírůstek/úbytek obyvatelstva. Hodnoty jsou uváděny na 1 000 obyvatel. Počátek monitoringu ČSÚ je rok 2019.
- ✓ *Index stáří,*
- ✓ *Podíl nezaměstnaných osob,*
- ✓ *Intenzita podnikatelské aktivity.*

Ke stanovení hospodářsky a sociálně ohrožených území se používají průměrné hodnoty za období 2013–2017. Vymezeny jsou správní obvody ORP, které vykazují nejhorší výsledky v těchto indikátorech a v nichž žije 25 % obyvatel ČR. Mimo tento rámec správních obvodů ORP definovaných podle výše popsaných proměnných jsou zařazena také správní území obce zasahující do bývalých vojenských újezdů. Kraje mohou vymezit ve strategiích rozvoje územního obvodu hospodářsky a sociálně ohrožená území na nižší administrativní

(např. správní obvody pověřených obecních úřadů) úrovni a řešit disparity i v rámci jednotlivých správních obvodů ORP. Dále mohou definovat jako hospodářsky a sociálně ohrožená i jiná území, než jaká stanovuje SRR, ovšem bez nároku na podporu regionální politiky státu. Takto definovaná území jsou v vyobrazena v mapě viz Obrázek 3. Výčet správních obvodů ORP v kategorii hospodářsky a sociálně ohrožených území dle SRR 2021 (MMR, 2021):

- **Plzeňský kraj:** Horažďovice, Nepomuk, Sušice
- **Jihočeský kraj:** Milevsko, Soběslav, Dačice, Blatná
- **Karlovarský kraj:** Kraslice, Sokolov, Ostrov
- **Ústecký kraj:** Litvínov, Most, Rumburk, Děčín, Varnsdorf, Podbořany, Chomutov, Kadaň, Ústí nad Labem, Lovosice, Teplice, Žatec, Louny, Litoměřice
- **Liberecký kraj:** Tanvald, Frýdlant, Semily, Nový Bor
- **Královéhradecký kraj:** Broumov, Dvůr Králové nad Labem
- **Pardubický kraj:** Moravská Třebová, Česká Třebová, Svitavy, Králíky
- **Kraj Vysočina:** Moravské, Budějovice, Pacov, Bystřice nad Pernštejnem, Telč, Světlá nad Sázavou, Náměšť nad Oslavou, Chotěboř, Třebíč
- **Jihomoravský kraj:** Veselí nad Moravou, Hodonín, Kyjov, Moravský Krumlov, Znojmo

Obrázek 3 Vymezení metropolí, aglomerací, regionálních center vyššího řádu a hospodářsky a sociálně ohrožených území pro účely SRR



Zdroj: MMR (2021)

MMR (2021) uvádí, že území stanovená jako strukturálně postižené kraje nebo hospodářsky a sociálně ohrožená území mohou využívat specifické cíle a typová opatření stanovená pro metropolitní území/aglomerace/regionální centra a jejich venkovské zázemí a pro strukturálně postižené kraje/hospodářsky a sociálně ohrožená území. To znamená, že jedna obec může spadat nejvýše do čtyř strategických cílů.

3.2.2 Metodika vymezení hospodářsky problémových regionů vybraných krajů

Proměnné k hodnocení disparit v regionálním rozvoji uvedené v rámci Strategie regionálního rozvoje slouží k hodnocení na úrovni státu. Pro jednotlivé kraje jsou indikátory doporučujícími a kraje mohou na základě svých priorit využívat individuální sady proměnných. Zákon o podpoře regionálního rozvoje č. 248/2000 Sb. stanovuje sledování regionálních disparit uvnitř kraje v socio-ekonomické oblasti a vymezuje tak území, kde je nutné tyto rozdíly zmírnit veřejnou podporou. Ovšem neukládá jednotnou metodiku

pro to, aby mohly být vymezeny hospodářsky problémové oblasti (Labounková, 2005). Skupina krajů pro zhodnocení jejich metodiky je vybrána dle dostupnosti dat. Souhrn veškerých ukazatelů za jednotlivé kraje, včetně jejich zdroje a směru je uveden v Příloze 1, z níž je také zřejmé, které proměnné jsou pro kraje společné a které volí jiné proměnné.

Jihočeský kraj

Program rozvoje Jihočeského kraje 2014–2020 (KP projekt s.r.o. a Krajský úřad Jihočeského kraje, 2013) obsahuje socioekonomickou analýzu a SWOT analýzu v rámci analytické části, dále pak vize kraje, globálního cíle, pěti prioritních os a 17 opatření v rámci strategické části. Součástí dokumentu je metodika stanovení hospodářsky slabých oblastí, evaluace, indikátory a návrh financování PRK 2014–2020.

Kraj používá pro definici hospodářsky slabých regionů pro rok 2014–2020 regionů stejnou metodu jako v předchozím období, a to vážený součet za každý obvod obcí s pověřeným obecním úřadem (POÚ) (KP projekt s.r.o. a Krajský úřad Jihočeského kraje, 2013). Výsledné problémové regiony v Jihočeském kraji byly dříve dle Chabičovské (2008) stanovovány na základě výběru necelé poloviny obvodů, jejichž kumulativní součet počtu obyvatel tvořil přibližně čtvrtinu populace kraje. Tyto problémové regiony jsou zaneseny do grafů a kartogramů, aby bylo zřejmé v čem spočívá jejich problémovost.

Pro tento postup jsou zvoleny následující ukazatele a jejich váhy (KP projekt s.r.o. a Krajský úřad Jihočeského kraje, 2013):

Migrace obyvatelstva (váha ukazatele 0,1): hodnoty přírůstku obyvatel stěhováním na tisíc obyvatel. Posuzován byl roční průměr za roky 2007–2011,

Cestní síť (váha ukazatele 0,2): hustota dopravní sítě vypočtena na základě dat týkajících se délky silnic I.–III. třídy a délky železnic v jednotlivých územích obvodů obcí s pověřeným obecním úřadem v roce 2012,

Nezaměstnanost (váha ukazatele 0,3): hodnocena na základě počtu uchazečů o zaměstnání, uchazečů o zaměstnání s dobou evidence nad 12 měsíců, volných pracovních míst a počet ekonomicky aktivních obyvatel za rok 2011,

Hrubá mzda (váha ukazatele 0,1): výše hrubé měsíční mzdy v Kč za jednotlivá POÚ v roce 2011 přepočtená na osoby plně zaměstnané,

Zaměstnanost v zemědělství (váha ukazatele 0,1): podíl pracujících v zemědělství, lesnictví a rybolovu v jednotlivých územích POÚ – v % v roce 2011,

Hustota osídlení (váha ukazatele 0,1): porovnání počtu obyvatel k 31.12. 2011 a výměry území jednotlivých POÚ v ha.

Liberecký kraj

Liberecký kraj (2013) používá specifickou metodiku. Po vyhodnocení všech stanovených ukazatelů jsou oblasti klasifikovány do třech oblastí dle dosaženého počtu bodů, a to na hospodářsky podprůměrné oblasti (hranice 10 000 bodů), hospodářsky slabé oblasti (hranice 9 200 bodů) nebo ostatní oblasti (vyšší než 10 000 bodů). Pro tuto metodiku používá jako základní územní jednotku tzv. generelové jednotky (GJ). Jedná se o mikroregiony na nejnižší regionální úrovni, které mají své středisko a k němu vymezené spádové území. Součet vážených hodnot představuje výslednou míru problémovosti daného POÚ (Chabičovská, 2008).

K posuzování GJ byly aplikovány stejné ukazatele a váhy jako v Programu rozvoje Libereckého kraje 2014–2020. Jedná se o následujících jedenáct ukazatelů (Liberecký kraj, 2013):

Intenzita bytové výstavby (váha 7): celkový počet dokončených bytů na průměrný počet obyvatel. Vše je hodnoceno za pětileté období roků 2007–2011. Hodnota je vynásobena tisícem,

Index vzdělanosti (váha 8): obyvatelstvo s vyšším stupněm vzdělání v přepočtu na počet obyvatel starších 15 let,

Index ekonomického zatížení (váha 10): obyvatelstvo v neproduktivním věku v přepočtu na počet obyvatel v produktivním věku. Hodnota je vynásobena stem,

Počet pracovních příležitostí (váha 14): počet pracovních příležitostí v přepočtu na počet ekonomicky aktivních obyvatel. Hodnota je vynásobena stem,

Míra nezaměstnanosti (váha 15): průměrný počet evidovaných nezaměstnaných za 12 měsíců v poměru počtu ekonomicky aktivních obyvatel, vynásoben stem,

Intenzita podnikatelské aktivity (váha 15): počet podnikatelských subjektů na počet obyvatel, vynásoben tisícem,

Daňové příjmy (váha 7): daňové příjmy obcí v Kč na počet obyvatel,

Hustota zalidnění (váha 1): počet obyvatel v přepočtu na jednotku rozlohy v km²,

Dopravní obslužnost (váha 8 a 5): počet spojů zastavujících ve všech obcích GJ ve středu 15.1. 2014 na počet obcí v GJ (váha 8) a počet spojů zastavujících ve všech obcích GJ v sobotu 18.1. 2014 na počet obcí GJ (váha 5),

Technická infrastruktura (váha třech ukazatelů 1): podíl domů napojených na vodovod na celkový počet domů (váha 1) a podíl domů napojených na kanalizaci na celkový počet domů (váha 1). Třetím ukazatelem v této oblasti je podíl domů napojených na plynovod na celkový počet domů (váha 1),

Občanská vybavenost (váha 2 a 5): existence ordinace praktického lékaře na počet obyvatel. Ukazatel vynásoben tisícem (váha 2). Druhým ukazatelem je existence základní školy (váha 5).

Olomoucký kraj

Podle Programu rozvoje územního obvodu Olomouckého kraje pro roky 2012–2015 jsou používány tyto ukazatele (BermanGroup, 2010):

Hustota zalidnění: počet obyvatel na km²,

Index stáří: hodnocen jako podíl obyvatel starších 65 let a obyvatelstva ve věku do 14 let,

Podíl produktivní složky populace,

Daně z příjmu na obyvatele,

Technická vybavenost obcí,

Zaměstnanost v zemědělství.

V nové etapě 2015–2020 již používá kraj stejné ukazatele dle SRR, a to *HDP*, *míru nezaměstnanosti*, *zadluženost ORP na 1 obyvatele*, *dávky v hmotné nouzi* a *saldo migrace na 1 000 obyvatel* (GaREP, spol. s r.o., 2008).

Dokument Strategie rozvoje územního obvodu Olomouckého kraje vymezuje 4–5 indikátorů ve třech pilířích (sociální, ekonomický a environmentální) a dokument hodnocení rozboru udržitelného rozvoje území vymezuje 7–8 indikátorů ve třech pilířích (společenský, hospodářský a environmentální). Celkem tedy 37 indikátorů ve třech oblastech. Hodnoty ukazatelů ze Strategie rozvoje územního obvodu jsou porovnávány s průměrem kraje a vyhodnocovány na úrovni SO POÚ. Jedná se o následující ukazatele (GaREP, spol. s r.o., 2008):

Změna počtu obyvatel: počet obyvatel v roce 2016 / počet obyvatel v roce 2012 * 100 (ČSÚ, roční),

Index stáří: počet osob ve věku nad 65 let / počet osob ve věku 0–15 let * 100 (ČSÚ, roční),

Bytová výstavba: počet dokončených bytů / počet obyvatel * 1000 (ČSÚ, roční),
Neobydlené byty: počet neobydlených bytů / celkový počet bytů * 100 (SLDB, 10let),
Vybavení internetem: počet domácností s počítačem připojeným na internet / počet domácností * 100 (SLDB, 10let),
Podnikatelská aktivita: počet ekonomických subjektů / počet obyvatel * 1000 (ČSÚ, roční),
Zaměstnanost ve službách: počet osob zaměstnaných ve službách / počet zaměstnaných osob * 100 (SLDB, 10let),
Maturitní vzdělání: počet osob s maturitou a vyšším vzděláním / počet obyvatel nad 15 let * 100 (SLDB, 10let),
Podíl nezaměstnaných: Počet uchazečů o zaměstnání / počet osob ve věku 15–64 let * 100 (MPSV, měsíční),
Počet uchazečů na volné pracovní místo: počet uchazečů o zaměstnání / počet volných pracovních míst (MPSV, měsíční),
Ekologická stabilita: výměra chmelnic, vinic, zahrad, ovocných sadů, trvalých travních porostů, lesní půdy a vodních ploch / výměra orné půdy, zastavěných ploch a ostatních ploch (ČSÚ, roční),
Pozemkové úpravy: počet obcí se schválenými zpracovanými nebo zahájenými KPÚ / celkový počet obcí * 100 (MZ),
Ochrana přírody: výměra území obce, jež je součástí chráněného území / celková výměra obce * 100 (ÚAP OK, 2roční),
Záplavové území Q100: výměra zastavěného území obce, které je dotčeno plochou záplavy Q100 / celková výměra obce * 100 (ÚAP OK, 2roční).

Hodnoty z rozboru udržitelného rozvoje území jsou váženy a analyzovány za počet obcí v intervalu u následujících indikátorů (GaREP, spol. s r.o., 2008):

Hrubá míra přirozeného přírůstku (váha 0,15): rozdíl mezi počtem živě narozených dětí ve sledovaném období a území a celkovým počtem zemřelých osob ve stejném období a území. Počet/100 obyvatel. (CZSO)

Hrubá míra migračního salda (váha 0,15): absolutní rozdíl mezi počtem imigrantů a emigrantů. Počet/100 Obyvatel. (CZSO)

Počet dokončených bytů (váha 0,2): Počet bytů v budovách pro bydlení, nových i stávajících, jejichž výstavba byla ve sledovaném období dokončena. Počet/100 obyvatel. (CZSO)

Míra dostupné urbanizace (váha 0,05): rozsah zastavitelných ploch pro bydlení. Hektary/100 obyvatel. (CZSO)

Index stáří (váha 0,2): kolik je v populaci obyvatel ve věku 65 let a více na 100 dětí ve věku 0–14 let. Index (CZSO)

Index vzdělanosti (váha 0,2): Součet podílu obyvatel se středoškolským vzděláním (s maturitou, nadstavbové a vyšší odborné studium) a dvojnásobku vysokoškolsky vzděláním k celkovému počtu obyvatel starších 15 let (vč. nezjištěných). (SLBD)

Trend hrubé míry celkového přírůstku (váha 0,05): trend vývoje a dynamiku změny hodnoty hrubé míry celkového přírůstku obyvatel. Počet/100 obyvatel. (CZSO)

Podíl osob zaměstnaných v terciéru (váha 0,1): Procentuální zastoupení terciéru (zde + kvartér i kvintér) na celku. Procento. (SLBD)

Míra podnikatelské aktivity (váha 0,2): Počet ekonomický subjektů se zjištěnou aktivitou celkem se sídlem v obci přepočten na 100 obyvatel. (CZSO)

Index dostupnosti dálniční sítě (váha 0,2): Průměrná hodnota vzdálenosti k nejbližší dálnici nebo rychlostní komunikaci přepočtena z rastru vypočteného ze sjednocené dálniční sítě a rychlostní komunikace v km. (ÚAP OK)

Podíl cizích zdrojů obce k celkovým aktivům obce (váha 0,05): Podíl cizích zdrojů (bankovních úvěrů a půjček, krátkodobých a dlouhodobých závazků, případně rezerv) k celkovým aktivům. Procento. (MF)

Hrubá míra salda dojížděky (váha 0,2): Rozdíl mezi dojíždějícími obyvateli do obce a vyjíždějícími obyvateli z obce za prací, vztaženo na počet ekonomicky aktivních. Počet/100 EAO. (SLBD)

Podíl nezaměstnaných osob (váha 0,15): Podíl nezaměstnaných osob na obyvatelstvu ve věku 15–64 let. Procento. (MPSV)

Podíl dlouhodobě nezaměstnaných osob (váha 0,1): Nezaměstnaní déle než 12 měsíců v evidenci úřadů práce k počtu obyvatel ve věku 15–64 let. Procento. (MPSV)

Trend podílu nezaměstnaných osob (váha 0,05): Trend vývoje a dynamiku změny hodnoty nezaměstnanosti mezi hodnotami v intervalu jednoho roku v příslušné obci. Procento. (MPSV)

Podíl pásem ochrany vod (váha 0,15): Procento území obce, jež se nachází v ochranném pásmu vodního zdroje, ochranném pásmu léčivého zdroje nebo chráněné oblasti přirozené akumulace vod. Procento. (ÚAP OK)

Podíl ploch ochrany přírody (váha 0,15): Procento výměry území obce, jež je součástí zvláště chráněného území (národního parku, CHKO, přírodní památky, přírodní rezervace nebo národní přírodní památky nebo národní přírodní rezervace) přírodního parku nebo lokalit Natura 2000. Procento. (ÚAP OK)

Kvalita ovzduší – koncentrace prachových částic PM10(váha 0,15): Průměrná koncentrace prachových částic PM10 za pětileté období. Ug/m³. (ČHMÚ)

Ekologická fragmentace nezastavěného území (váha 0,1): Vážená délka bariér v nezastavěném území v km ve vztahu k celkové výměře nezastavěného území obce v km². km/km². (ArcČR 500)

Koeficient ekologické stability (váha 0,1): Podíl ekologicky příznivých ploch (ekologicky stabilních) a ploch ekologicky nestabilních, které „zatěžují“ životní prostředí. Index. (CZSO)

Podíl lesa (váha 0,1): Počítá se jako procentuální výměra lesních ploch k celkové rozloze obce. Procento. (ÚAP OK)

Podíl půd 1. a 2. třídy ochrany (váha 0,15): Procentní podíl součtu ploch zemědělského půdního fondu s 1. a 2. třídou ochrany na celkové výměře zemědělského půdního fondu. Procento. (ÚAP OK)

Stupeň realizace pozemkových úprav (váha 0,1): Hodnocení obcí dle zpracovaných nebo realizovaných pozemkových úprav. Syntetický výpočet. (MZ)

Podle Chabičovské (2008) kromě regionů vymezených na státní úrovni byly k problémovým regionům mimo jiné začleněny také další obvody POÚ dle počtu získaných bodů, jejichž kumulativní součet obyvatel nepřesáhl 10,2 % obyvatel kraje.

Pardubický kraj

Pardubický kraj detekuje své problémové regiony od roku 2001. Na základě toho věnuje větší pozornost těmto regionům, např. pro tyto problémové regiony vytvořen krajský dotační program. Kraj v roce 2011 schválil aktualizovanou verzi Programu rozvoje Pardubického kraje pro období 2012–2016 s výhledem do roku 2020. Ukazatele využívány k vymezení problémových regionů Pardubického kraje jsou následující (GaREP, spol. s.r.o., 2011):

Migrace: rozdíl počtu přistěhovaných a vystěhovaných, vztažený na 1 000 obyvatel kraje,

Index stáří: poměr počtu obyvatel ve věku nad 65 let k počtu obyvatel mladších 14 let, vyjádřený v procentech,

Relativní počet podnikatelů: poměr počtu podnikatelů k počtu obyvatel s trvalým bydlištěm v tisících,

Míra nezaměstnanosti: poměr počtu registrovaných uchazečů o zaměstnání u úřadu práce ku počtu ekonomicky aktivních obyvatel,

Daňová výtežnost: poměr daňových příjmů v daném území ku počtu trvale bydlících obyvatel,

Hustota obyvatelstva: počet trvale bydlících obyvatel na km².

Hodnocena jsou průměrná data v časové řadě za tři roky. U hustoty obyvatelstva a indexu stáří byl použit pouze údaj za jeden rok za předpokladu, že tyto údaje se příliš nemění. Pro výběr konkrétních obvodů ORP byly použity původní dvě metody dalšího postupu (GaREP, spol. s.r.o., 2011):

Vážený součet číselných hodnot indikátorů, kombinovaný s kvalitativní hodnotou indikátoru migrace; Třem ukazatelům byla přisouzena váha 1, poloviční váha byla přiznána ukazatelům hustoty obyvatelstva a indexu stáří.

Srovnání s kritickou hodnotou (průměr kraje): Jako kritická hodnota byla u všech ukazatelů vybrána hodnota menší než 1, indikátor nenabývá úrovně krajského průměru. Vyskytují se zde dvě výjimky: index stáří je z logiky konstrukce daného indikátoru volen za kritickou hodnotu hodnoty 1,1 a více a hodnoty pod 0,9 (zde byly hodnoty vůči konstrukci ukazatele recipročně přepočteny – nižší hodnoty ukazatele znamenají starší obyvatelstvo a naopak). Druhá výjimka je ukazatel migrace, kde je nezbytné provádět hodnocení s absolutními čísly. Z tohoto důvodu byly kritické hodnoty stanoveny ty, které jsou nižší než 4,1 (průměr kraje). Výsledkem je na závěr průnik obou použitých metod.

Kraj Vysočina

Krajský úřad Kraje Vysočina (2018) svou vlastní metodiku nemá a přebírá vymezení hospodářsky problémových regionů na úrovni obcí s rozšířenou působností ze Strategie regionálního rozvoje ČR. Také žádný z dotačních titulů kraje není směřován pouze do hospodářsky slabých regionů (ORP). V předchozím programovém období využíval kraj metodiku, která definovala čtyři skupiny a v každé čtyři indikátory, tzn. celkem 16 indikátorů ve skupinách sídla, obyvatelstvo, nezaměstnanost a ekonomika. Tyto indikátory

byly váženy a data byla vyhodnocována na úrovni SO ORP. Jedná se o následující ukazatele (Krajský úřad Kraje Vysočina, 2018):

Hustota zalidnění (váha 1): poměru počtu obyvatel a jednotky rozlohy,

Průměrná populační velikost obce (váha 0,5): poměr, kdy v čitateli je uváděn počet obyvatel studovaného území a ve jmenovateli počet obcí,

Průměrná populační velikost obce v zázemí střediska (váha 0,5): poměr mezi počtem obyvatel a počtem obcí v SO ORP bez zahrnutí středisek správních obvodů,

Průměrná populační velikost části obce (váha 0,5): průměrný počet obyvatel připadající na jednu místní část,

Přirozený přírůstek (váha 1): rozdíl počtu živě narozených a zemřelých ve sledovaném regionu,

Migrační saldo (váha 1): rozdíl mezi počtem přistěhovalých a vystěhovalých ve zkoumaném územním celku,

Sňatečnost, rozvodovost (váha 0,5): poměr mezi počtem rozvodů a počtem sňatků,

Index ekonomické závislosti I. (váha 1): poměr mezi počtem osob ve věku 0–14 let k počtu osob ve věku 15–64 let,

Průměrná měsíční míra nezaměstnanosti (váha 1): podíl registrovaných dosažitelných uchazečů o zaměstnání a ekonomicky aktivních násobený stem,

Podíl nezaměstnaných osob ve věku 15–24 let (váha 0,75): poměr počet nezaměstnaných osob ve věku 15–24 s počtem osob ve věku 15–24 let,

Podíl nezaměstnaných osob ve věku 50–64 let (váha 0,75): podíl nezaměstnaných ve věku 50–64 let na počtu osob v této věkové kategorii,

Míra dlouhodobé nezaměstnanosti (váha 0,5): zastoupení uchazečů s dobou evidence na úřadu práce delší než 12 měsíců na počtu ekonomicky aktivních,

Intenzita bytové výstavby (váha 1): poměru mezi počtem dokončených bytů a středního stavu obyvatelstva,

Intenzita bytové výstavby v rodinných domech (váha 0,5): poměru mezi počtem dokončených bytů v rodinných domech a středního stavu obyvatelstva,

Intenzita podnikatelské aktivity (váha 0,75): počet podnikatelských subjektů přepočtený na střední stav obyvatel,

Koncentrace ubytovacích kapacit (váha 0,75): počet lůžek v hromadných ubytovacích zařízeních na počet obyvatel středního stavu.

Královéhradecký kraj

Královéhradecký kraj vymezuje hospodářsky slabé a silné regiony do úrovně jednotlivých obcí na základě vyhodnocení souhrnného indikátoru osmi vážených ukazatelů, které charakterizují sociálně-ekonomický rozvoj a hospodářskou sílu. Tato metodika má ovšem jen doporučující charakter, přesto, že na ni existuje všeobecná shoda (Krajský úřad Královéhradeckého kraje, 2018):

Průměrná intenzita podnikatelské aktivity (váha 0,14): Průměrná intenzita podnikatelské aktivity – počet ekonomických subjektů na 100 obyvatel (2010–2015),

Podíl nezaměstnaných osob (váha 0,16): Podíl nezaměstnaných osob (2010–2015),

Počet uchazečů o zaměstnání: Průměrný počet uchazečů o zaměstnání (2010–2015),

Index ekonomického zatížení (váha 0,13): Index ekonomického zatížení (v roce 2015),

Intenzita bytové výstavby (váha 0,11): Intenzita bytové výstavby (2010–2015),

Vývoj počtu obyvatel (váha 0,9): Index vývoje počtu obyvatel (změna 2010–2015),

Index stáří (váha 0,1): Index stáří (v roce 2015),

Daňová výtěžnost (váha 0,15): Daňová vytiženost (v roce 2016).

Krajský úřad Královéhradeckého kraje (2018) prozatím jediné praktické využití pro vymezení hospodářsky problémových regionů uvádí v krajských dotačních programech pro obce – Program obnovy venkova a Program obnovy místních částí pro příští rok. V obou programech jsou hodnotící kritéria, která zvýhodní (o 10 % bodů) jako žadatele o dotaci obce, která je v hospodářsky slabém regionu. Praktický dopad a takto nastaveného zvýhodnění ale zatím není známo, poprvé bude použito v příštím roce.

Plzeňský kraj

Krajský úřad Plzeňského kraje (2018) v loňském a ani v letošním roce nevymezil na svém území žádné hospodářsky problémové regiony. Kraj se zabývá touto problematikou při zpracování strategických či koncepčních materiálů, akčních plánů a dílčích dokumentů. Výchozími dokumenty pro jejich tvorbu jsou nadřazené dokumenty ČR – jedná se zejména o aktuální dokument Strategie regionálního rozvoje ČR (základní dokument v oblasti regionálního rozvoje) a aktuální dokumenty z oblasti územního plánování (Politika ÚR). Sama Strategie regionálního rozvoje ČR 2014–2020 určuje typologii území ČR na periferní, stabilizovaná a rozvojová území. V rámci územního plánování např. dle zákona Zásady územního rozvoje Plzeňského kraje i aktualizace územně analytických podkladů (ÚAP).

V rámci poslední aktualizace ÚAP „regionální pohled“ na území kraje z hlediska 3 pilířů – environmentální, ekonomický a sociální. Výsledkem průměru těchto základních hledisek (na úrovni obcí) je pak kartogram. Plzeňský kraj v loňském roce ani v letošním nevyhlásil přímo dotační titul pro hospodářsky slabé „problémové“ regiony. To však neznamená, že v určitých titulech nezvýhodňuje některá území – např. území Brd (titul na podporu územních plánů je zvýhodňoval finančně), území se zhoršenou bezpečností (titul pro obce při zajišťování bezpečnosti v souvislosti s rozvojem průmyslových zón) atd. Veškeré tituly musí mít podle zákona stanovená kritéria hodnocení, i tam se může napříč tituly objevit právě určitá předem daná „diferenciace“ žadatelů.

Karlovarský kraj

Dle metodiky karlovarského kraje (URÚ) se člení na deset témat, každé téma obsahuje SWOT analýzu a jeden nebo více indikátorů. Zároveň definuje tři pilíře udržitelnosti. Celkem má Karlovarský kraj 29 indikátorů a 3 oblasti (přírodní, ekonomickou a sociální). Jednotlivé indikátory nejsou váženy a data jsou vyhodnocována na úrovni obcí (Krajský úřad Karlovarského kraje, 2017):

Těžba a ochrana surovin: % podíl území obce, který zaujímají dobývací prostory, chráněná ložisková území a ložiska a prognózy vyhrazených surovin,

Vodohospodářský význam území: poměr součtu ploch chráněných oblastí přirozené akumulace vod, vodních ploch a toků, ochranných pásem vodních zdrojů a ochranných pásem přírodních léčivých zdrojů, vztažený k území obce,

Retenční schopnost krajiny: poměr součtu ploch lesů a trvalých travních porostů, zmenšený o plochy meliorací, zastavěné plochy a nádvoří a polovinu ostatních ploch, vztažený k území obce,

Záplavové území Q100: % podíl zastavěného území obce, který zabírají plochy záplavových území Q100,

Hluk z dopravy: poměr součtu ploch zatížených hlukem v okolí dálnic, silnic I. až III. třídy, železnic a z letecké dopravy, vztažený k území obce,

Bodové zdroje znečištění: % podíl území obce v dosahu významných zdrojů znečištění ovzduší (stacionární tepelný zdroj s příkonem vyšším než 0,3 MW),

Rizikové vodní útvary: poměr součtu území povrchových a podzemních vodních útvarů klasifikovaných jako rizikové nebo potenciálně rizikové, vztažený k území obce,

Ochrana přírody a krajiny: poměr součtu ploch přírodních parků, přírodních rezervací, přírodních památek, CHKO a lokalit NATURA, vztažený k území obce,

Ekologická stabilita: poměr součtu ploch druhů pozemků ekologicky stabilních (lesní půdy, vodní plochy a toky, trvalé travní porosty, pastviny, mokřady, sady a vinice) ku součtu ploch druhů pozemků ekologicky nestabilních (orná půda, zastavěné plochy a ostatní plochy),

Urbanizované území: % podíl území obce, který zabírají pozemky zastavěné a pozemky ostatních ploch,

Hospodářské využití lesů: potenciál hospodářského využití lesů hospodářských, ale i lesů ochranných a zvláštního určení (podíl plochy využitelných lesních porostů v různých poměrech na rozloze obce v ha),

Hospodářské využití zemědělské půdy: potenciál zemědělského využití půdy v závislosti na jejích kulturách (podíl plochy hospodářských ploch na rozloze obce v ha),

Obyvatelé v plynofikovaných bytech: % podíl obyvatel v plynofikovaných obydlených bytech z počtu obyvatel (data SLBD 2011),

Obyvatelé v odkanalizovaných bytech: % podíl obyvatel v odkanalizovaných obydlených bytech z počtu obyvatel (data SLBD 2011),

Hustota komunikací: hustota dálnic, silnic a železnic na území obce,

Počet obyvatel: počet obvykle bydlících obyvatel obce v tisících,

Změna počtu obyvatel za 5 let: relativní přírůstek nebo úbytek obyvatel obce celkem za posledních pět let,

Intenzita migrace: průměrný roční % podíl součtu přistěhovaných a odstěhovaných obyvatel za 3 roky,

Index stáří: počtu obyvatel ve věku 65 let a více vztažený k počtu obyvatel ve věku 0–14 let,

Vysokoškolská vzdělanost: % podíl počtu vysokoškolsky vzdělaných obyvatel z celkového počtu obyvatel obce starších 15 let (data SLBD 2011),

Bytová výstavba: průměrný počet dokončených bytů na 1000 obyvatel obce za 3 roky,

Neobytné byty: % podíl počtu neobydlených bytů z celkového počtu bytů v obci při vyloučení bytů sloužících k rekreaci,

Základní vybavenost: stupeň základního vybavení obce (základní škola, mateřská škola, ordinace lékaře, zařízení pro seniory),

Byty užívané k rekreaci: podíl počtu bytů užívaných k rekreaci k počtu obydlených bytů,

Hromadná ubytovací zařízení: počet zařízení hromadného ubytování na území obce,

Podíl nezaměstnaných: % podíl počtu dosažitelných nezaměstnaných, registrovaných úřady práce, z počtu ekonomicky aktivních osob v obci,

Zaměstnanost mimo primér a sekundér: % podíl počtu ekonomicky aktivních osob zaměstnaných mimo primární a sekundární sektor hospodářství z celkového počtu zaměstnaných ekonomicky aktivních osob,

Saldo dojížděky za prací: rozdíl mezi počtem osob dojíždějících do zaměstnání do obce a vyjíždějících do zaměstnání mimo obec,

Daňové příjmy obce: daňové příjmy obce v milionech Kč.

Ústecký kraj

Metodika Ústeckého kraje definuje tři skupiny charakteristik a každé přiřazuje tři indikátory. Celkem má Ústecký kraj 9 indikátorů a 3 oblasti (environmentální, ekonomickou a sociální). Jednotlivé indikátory nejsou váženy, data jsou vyhodnocována na úrovni SO ORP (Krajský úřad Královéhradeckého kraje, 2018):

Základní vzdělání: Podíl obyvatel se základním vzděláním na populaci (v %, SLDB 2011),

Sociálně vyloučené lokality: Podíl obyvatel sociálně vyloučených lokalit na obyvatelstvu (v %, GAC 2015),

Vývoj počtu obyvatel: Změna počtu obyvatel mezi roky 1991 a 2016 (index změny, VDB ČSÚ 2017),

Nezaměstnanost: Podíl nezaměstnaných v měsíci dubnu 2017 (Portál MPSV 2017),

Podnikatelská aktivita: Počet ekonomických subjektů na 1000 obyvatel k 31.12. 2015 (VDB ČSÚ 2017),

Bytová výstavba: Počet dokončených bytů v období let 2011–2016 v přepočtu na 1000 obyvatel (VDB ČSÚ 2017),

Staré ekologické zátěže: Počet lokalit starých ekologických zátěží s prioritou A2 a A3 (SEKM 2017),

Kvalita ovzduší: Podíl území s průměrnou pětiletou koncentrací PM10 v období 2011–2015 nad 25 µg/m³ (výpočet na základě čtvercové sítě ČHMÚ, ČHMÚ 2017),

Ekologická stabilita: Koeficient ekologické stability (VDB ČSÚ 2017).

Jihomoravský kraj

Dokument metodiky Jihomoravského kraje definuje 18 indikátorů pocházejících ze Strategie rozvoje Jihomoravského kraje 2020 a 14 indikátorů pocházejících z Programu rozvoje

Jihomoravského kraje 2018–2021 ve dvou oblastech. Celkem má Jihomoravský kraj 32 indikátorů. Jednotlivé indikátory nejsou váženy, data jsou vyhodnocována na úrovni SO ORP a standardizována pomocí z-skóru (Krajský úřad Královéhradeckého kraje, 2018):

Průměrná velikost obcí: průměrný počet obyvatel na jednu obec,

Změna indexu stáří: podíl počtu obyvatel ve věku 65+ let a počtu obyvatel ve věku 0–14 let za posledních 5 let,

Celkový přírůstek obyvatelstva: celkový přírůstek počtu obyvatel na 1000 obyvatel (průměr za poslední 3 roky),

Ekologická stabilita: Podíl ekologicky stabilních ploch (sady, trvalé travní porosty, lesní pozemky) na celkové rozloze,

Podíl zemědělské půdy: Podíl zemědělské půdy na celkové rozloze SO ORP,

Nezaměstnanost: Míra registrované nezaměstnanosti,

Občanská vybavenost: Počet zařízení základních veřejných služeb (MŠ, ZŠ, SŠ, ordinace praktického lékaře, domov pro seniory, domov s pečovatelskou službou) na 1000 obyvatel.,

Podnikatelská aktivita: Podíl počtu podnikajících fyzických osob a celkového počtu obyvatel ve věku 15–64 let,

Hosté v HUZ: Počet ubytovaných hostů v hromadných ubytovacích zařízeních přepočtený na 1000 obyvatel.,

Intenzita bytové výstavby: Počet dokončených bytů na 1000 obyvatel,

Vodovodní infrastruktura: Podíl obcí se zavedeným vodovodem v celé obci na celkovém počtu obcí,

Kanalizační infrastruktura: Podíl obcí se zavedenou kanalizací v celé obci na celkovém počtu obcí,

Volná pracovní místa: Počet volných pracovních míst na 1000 obyvatel ve věku 15–64 let,

Dlouhodobá nezaměstnanost: Dlouhodobě nezaměstnaní (12 měsíců a déle) jako procento celkového ekonomicky aktivního obyvatelstva ve věku 15–64 let,

Velké podniky: Počet velkých firem (500+ zaměstnanců),

Internetové služby: Podíl obcí poskytujících občanům bezplatné internetové připojení prostřednictvím sítě Wi-Fi,

Zaměstnanost v kvintéru: Podíl zaměstnanců pracujících ve výzkumu a vývoji na celkové pracovní síle 15–64 let,

Sociální dávky: Počet přiznaných sociálních dávek (přídavky na děti, sociální příplatek, příspěvek na bydlení) na 1 obyvatele,

Změna počtu obyvatel: Změna počtu obyvatel (srovnání let 2010 a 2016),
Index stáří: Index stáří (stav v roce 2016),
Dlouhodobá nezaměstnanost: Podíl dlouhodobě nezaměstnaných (stav k 31. 12. 2016),
Sociálně vyloučené lokality: Výskyt sociálně vyloučené lokality (dle Analýzy sociálně vyloučených lokalit v ČR, 2015),
Ohrožení rizikovými jevy: Ohrožení větrnou a vodní erozí, extrémními projevy podnebí, záplavami, suchem a sesuvy,
Imisní limity: překročení imisních limitů s dopadem na lidské zdraví (konkrétně nedefinováno),
Dobývací prostory: narušení velké části povrchu těžbou (blíže nespecifikováno),
Hlukové limity: limity hluku jsou u řady pozemních komunikací (úžeji nepřiblíženo),
Chráněná území: rozložení velkoplošných chráněných území (dále neurčeno).

Zlínský kraj

Metodika Programu rozvoje územního obvodu (PRÚO) Zlínského kraje používá množství indikátorů v pěti oblastech. Celkem má Zlínský kraj 22 indikátorů. Jednotlivé indikátory nejsou váženy a data jsou vyhodnocována na úrovni ORP. V PRÚO využívá kraj Bennetovu metodu (Krajský úřad Královéhradeckého kraje, 2018):

Změna počtu obyvatel: průměrné roční tempo změny počtu obyvatel za poslední čtyři roky,
Index stáří: Index stáří,
Mikropodniky: počet podniků bez zaměstnanců a mikropodniků na 1000 obyvatel,
Malé a střední podniky: počet malých a středních podniků na 1000 obyvatel,
Změna intenzity podnikatelské aktivity: průměrné roční tempo přírůstku/úbytku ekonomických subjektů za poslední čtyři roky,
Nezaměstnanost: míra registrované nezaměstnanosti,
Dosažitelní uchazeči: počet uchazečů o práci na jedno volné místo,
Dlouhodobě nezaměstnaní: podíl uchazečů o práci v evidenci ÚP nad 12 měsíců,
Vysokoškolská vzdělanost: podíl obyvatel ve věku 15 a více let s vysokoškolským vzděláním,
Základní školy: počet základních škol na 1000 obyvatel ve věku 0 až 14 let,
Praktičtí lékaři: počet praktických lékařů pro dospělé na 1000 obyvatel ve věku 15 a více let,

Domovy pro seniory: počet lůžek v domovech pro seniory na 1000 obyvatel ve věku 65 a více let,

Dopravní obslužnost: počet veřejných dopravních spojů ve špičce na 1000 obyvatel,

Bytová výstavba: počet dokončených bytů za poslední čtyři roky na 1000 obyvatel,

Kanalizační infrastruktura: podíl obyvatel žijících v obcích s kanalizací napojenou na ČOV,

Hustota komunikací: délka silnic II. a III. třídy v km na 100 km²,

Obyvatelstvo venkovských obcí: změna počtu obyvatel ve venkovských obcích od roku 2007,

Lůžka v HUZ: počet lůžek hromadných ubytovacích zařízení na 1000 obyvatel,

Kulturní památky: počet nemovitých kulturních památek na 100 km²,

Hosté v HUZ: počet přenocování v hromadných ubytovacích zařízeních na 1000 obyvatel,

Knihovny: počet knihoven včetně poboček na 1000 obyvatel,

Sportovní zařízení: počet sportovních zařízení na 1000 obyvatel.

Moravskoslezský kraj

Metodika SZO Moravskoslezského kraje používá řadu indikátorů v sedmi oblastech, celkem 17 indikátorů. Jednotlivé indikátory jsou váženy a data jsou vyhodnocována za generelové jednotky (Krajský úřad Královéhradeckého kraje, 2018):

Migrace (váha 9): Hrubá míra migračního salda,

Index stáří (váha 4): Průměr Indexu stáří,

Hustota zalidnění (váha 2): Průměrná hustota zalidnění,

Občanská vybavenost (váha 9): Počet ordinací praktického lékaře na 1 000 obyvatel,

Bytová výstavba (váha 7): Intenzita bytové výstavby,

Ekonomická zátěž (váha 10): Index ekonomického zatížení,

Podnikatelská aktivita (váha 16): Počet podnikatelů (FO) na 1 000 obyvatel,

Daňové příjmy (váha 11): Daňové příjmy (v tis. Kč na 1 obyvatele),

Nezaměstnanost: Míra nezaměstnanosti,

Dlouhodobá nezaměstnanost (váha 17): Míra dlouhodobé nezaměstnanosti,

Veřejná doprava ve všední dny (váha 7): Počet spojů zastavujících v jednotlivých obcích Moravskoslezského kraje – všední den (bez měst s MHD). Počet spojů zastavujících v jednotlivých obcích Moravskoslezského kraje – všední den (bez měst s MHD),

Veřejná doprava o víkendů (váha 4): Počet spojů zastavujících v jednotlivých obcích Moravskoslezského kraje – víkendový den (bez měst s MHD),

Kanalizační infrastruktura (váha 2): Vybavenost jednotlivých obcí Moravskoslezského kraje kanalizací,

Vodovodní infrastruktura (váha 1): Vybavenost jednotlivých obcí Moravskoslezského kraje vodovodem,

Infrastruktura plynovodů (váha 1): Vybavenost jednotlivých obcí Moravskoslezského kraje plynovodem,

Imisní limity: Překročení denních imisních limitů (d IL) pro polétavý prach,

Ekologická stabilita: Koeficient ekologické stability.

4. Vlastní práce

Konstrukce kompozitního indikátoru představuje použití jednorozměrných a vícerozměrných statistických metod. Vytvoření KI bude zahrnovat celkem deset kroků, na základě kterých je v disertační práci zkonstruováno 48 typů KI za použití různých kombinací metod, v rámci nichž jsou naplněny hlavní a dílčí cíle práce. Konkrétně se jedná o kombinace jednotlivých postupů ošetření odlehlých pozorování, metod normalizace, určování vah, agregace a technik řešení nulových hodnot pro geometrickou agregaci. Výstupem bude jedna zvolená varianta konstrukce KI dovolující detekovat hospodářsky problémové regiony, která může sloužit regionům jako návrh metodologického aparátu. Tato varianta KI bude zvolena na základě zvážení robustnosti, vztahů s ostatními proměnnými a veškerých výhod a nevýhod jednotlivých metod. K lepšímu porozumění vlastní části práce slouží schéma (Obrázek 4). Tento postup je aplikován jako případová studie k detekci hospodářsky slabých regionů ke komparaci let 2012 a 2016.

Obrázek 4 Schéma postupu vlastní části disertační práce

1. Sestavení teoretického rámce	<ul style="list-style-type: none"> • Definice konceptu • Určení podskupin indikátorů • Identifikace výběrových kritérií (viz Příloha 1)
2. Výběr jednotlivých indikátorů	<ul style="list-style-type: none"> • Souhrnné tabulky s charakteristikou dat, dostupnost, zdroj, typ • Určení směru indikátorů viz Příloha 1
3. Nahrazení chybějících hodnot a detekce odlehlých pozorování	<ul style="list-style-type: none"> • Detekce odlehlých pozorování: explorační analýza, standardizace (z-skóre), koeficienty šikmosti a špičatosti, IQR, Box-Plot • Ošetření odlehlých pozorování: metoda winsorizace
4. Normalizace dat	<ul style="list-style-type: none"> • Metoda pořadí, metoda standardizace (z-skóre), Min-Max • Metoda Min-Max: řešení nulových hodnot u geometrické agregace (transformace na škálu, převedením na nízké číslo, konstanta)
5. Vícerozměrná analýza	<ul style="list-style-type: none"> • Faktorová analýza • Analýza hlavních komponent • Shluková analýza
DÍLČÍ CÍL: NALEZENÍ NEJVHODNĚJŠÍ SADY PROMĚNNÝCH	
6. Stanovení vah a agregace	<ul style="list-style-type: none"> • Bez vah vs. s vahami, pilíře (hospodářský a sociální) vs. bez pilířů, • Normalizace metoda pořadí – agregace metody založené na pořadí, • Normalizace metoda standardizace (z-skóre) – lineární agregace, • Normalizace metoda Min-Max – lineární a geometrická agregace
7. Analýza k posouzení robustnosti a citlivosti	<ul style="list-style-type: none"> • Pro techniky řešení nulových hodnot u geometrické agregace • Na základě přístupu k odlehlým pozorováním • Pro metody normalizace • Na základě stanovených vah • Pro metody agregace I a agregace II • Na základě metod agregace
8. Back to details	<ul style="list-style-type: none"> • Výhody a nevýhody zvolených metod • Porovnání Spearmanův korelační koeficient jednotlivých typů KI a medián pořadí
KONSTRUKCE 48 TYPŮ KOMPOZITNÍCH INDIKÁTORŮ	
<p>DÍLČÍ CÍLE: KOMPARECE JEDNOTLIVÝCH KOMBINACÍ POSTUPŮ OŠETŘENÍ ODLEHLÝCH POZOROVÁNÍ, METOD NORMALIZACE, URČOVÁNÍ VAH, AGREGACE A TECHNIK ŘEŠENÍ NULOVÝCH HODNOT PRO GEOMETRICKOU AGREGACI PREZENTOVANÉ NA DATOVÉ MATICI SESTAVENÉ Z UKAZATELŮ PRO STANOVENÍ HOSPODÁŘSKY PROBLÉMOVÝCH OKRESŮ (LAU 1) ČR.</p> <p>ZPRACOVÁNÍ ZÁVĚŘŮ, KTERÉ VYPLYNOU Z VÝŠE UVEDENÝCH VÝPOČTŮ.</p>	
9. Vztah s ostatními proměnnými	<ul style="list-style-type: none"> • Vícenásobný lineární regresní model
10. Presentace a vizualizace výsledků	<ul style="list-style-type: none"> • Grafy, tabulky, kartogramy
HLAVNÍ CÍL: NÁVRH METODOLOGICKÉHO APARÁTU KONSTRUKCE KOMPOZITNÍHO INDIKÁTORU K IDENTIFIKACI HOSPODÁŘSKY PROBLÉMOVÝCH OKRESŮ ČR, DLE KTERÉHO BUDE MOŽNÉ STANOVIT DISPARITY MEZI REGIONY V HOSPODÁŘSKÉ A SOCIÁLNÍ OBLASTI.	


Zdroj: vlastní zpracování

4.1 Teoretický rámec

Sestavení teoretického rámce představuje první krok před konstrukcí kompozitního indikátoru. V první řadě byl definován koncept kompozitního indikátoru. Budou jím stanoveny disparity mezi regiony a podá informaci o tom, zda je region hospodářsky problémový, či nikoli. Hospodářsky problémový region je takový, který vykazuje nejhorší výsledky v hospodářské a sociální oblasti. Celkem bude pomocí KI vymezeno 20 regionů, z toho 10 hospodářsky problémových a 10 rizikových. Rizikové regiony představují takové regiony, které stojí na hranici zařazení do hospodářsky problémových oblastí.

V rámci teoretického rámce byly následně určeny podskupiny indikátorů. Vzhledem k definici hospodářsky problémových regionů byly indikátory rozděleny do dvou podskupin (oblastí, pilířů), a to hospodářské a sociální. Hospodářsky problémové regiony jsou specifické nejhoršími výsledky v rámci nezaměstnanosti a množství pracovních příležitostí, podnikatelské aktivity, daňové vytíženosti, zadlužení a objemu sociálních dávek. Tato skupina indikátorů reprezentuje hospodářskou oblast. Dále se hospodářsky problémové regiony stanovují pomocí indikátorů zastupujících sociální oblast, a to nepříznivým demografickým vývojem, nedostatečně rozvinutou technickou infrastrukturou, nízkou úrovní vzdělanosti, intenzitou bytové výstavby a občanské vybavenosti.

Obrázek 5 Schéma postupu vymezení teoretického rámce



Zdroj: vlastní zpracování

Z vybraných metodik krajů a evropských dokumentů strategie rozvoje v jednotlivých letech je zřejmé, že se pro vymezení hospodářsky slabých regionů nejčastěji používá metoda váženého součtu jednotlivých indikátorů. Například Pardubický kraj používá vážený součet a srovnání s kritickou hodnotou (průměr kraje). Strategie regionálního rozvoje 2014–2020 používá některé ukazatele nedostupné na úrovni LAU 1. Zejména odhad *HDP* by mohl být nepřesný a zkreslený. Mimo jiné dle Hudrlíkové (2009) indikátoru *HDP* začal být přisuzován mnohem širší význam, než odpovídá skutečnosti, a následně nesprávnou interpretací vznikají nesrovnalosti, pokud je chybně považován za všeřikající výpověď

o ekonomice země či životní úrovni jak ze strany uživatelů, tak zpracovatelů statistických dat. Nejen z tohoto důvodu tento ukazatel nebude zahrnut do výběru. Strategie regionálního rozvoje 2021+ zahrnuje proměnnou *Hrubá míra celkového přírůstku* (základní ukazatel vyjadřující úbytek, či přírůstek obyvatelstva v obci), ovšem počátek monitoringu ČSÚ je až rok 2019. SRR 2021+ používá průměrné hodnoty za období 2013–2017.

Souhrn veškerých indikátorů používaných k detekci hospodářsky problémových regionů v jednotlivých krajích byl sestaven do tabulky, viz Příloha 1, kde jsou pro větší přehlednost každému indikátoru přiřazeny četnosti opakování, jeho zdroj či pluralita. Na závěr byla identifikována výběrová kritéria jednotlivých indikátorů pro sestavení kompozitního indikátoru.

Definice výběrových kritérií

- Indikátor spadá logicky i tematicky do hodnocení hospodářsky problémových regionů.
- Dostupnost a časová pravidelnost sledování indikátoru.
- Jasný směr směřování indikátoru (pozitivní, či negativní).
- Zjištění závislosti mezi zkoumanými ukazateli na základě korelační matice.
- V případě nejasnosti je dána přednost indikátoru s vyšší relativní variabilitou.

4.2 Výběr jednotlivých indikátorů

Na základě souhrnné tabulky (Příloha 1) a výše definovaných kritérií v teoretickém rámci byl určen následující výběr nejpoužívanějších indikátorů jako průřez jednotlivých metodik v závislosti na dostupnosti dat, logického vyhodnocení a komparační analýzy. Nejprve byly vybrány pouze ukazatele z hospodářské a sociální oblasti (pilíře), tzn. ekonomika, demografie, bydlení, technická infrastruktura a vybavenost regionu. Některé kraje zahrnují pro výpočet hospodářsky problémových regionů též oblasti ochrana přírody, rekreace, vodní režim, zemědělství a lesy, horninové prostředí a geologie. Nicméně z důvodu čisté podstaty charakteristiky hospodářsky problémových oblastí nebyly tyto oblasti shledány jako vhodné, a proto nebyly zahrnuty do užšího výběru proměnných. Stejně tak nebyly zařazeny *Saldo dojížděky za prací (do/mimo území)*, *Zaměstnanost mimo primér a sekundér* či *Podíl domácností připojených na internet*, protože se tyto proměnné sledují pouze jednou za 10 let. Dále byly vyřazeny proměnné *Míra urbanizace (zastavěné plochy)* a *Podíl zaměstnanců*

v zemědělství kvůli jejich spornému směru, jenž je nezbytně nutné si ujasnit před samotnou konstrukcí kompozitního indikátoru. Tyto proměnné nebyly příliš často využívány k detekci hospodářsky problémových regionů, viz Příloha 1. Dále proměnná *Hustota obyvatel* byla vyloučena z uvažovaných proměnných, protože valná většina proměnných již byla přepočtena na 1000 obyvatel.

Data byla podrobena korelační analýze a pomocí Spearmanova korelačního koeficientu byla odhalena síla závislosti mezi dílčími ukazateli. Dle popisných charakteristik byl mimo jiné zjištěn koeficient relativní variability (variační koeficient, v). Pro rok 2016 byla detekována silná korelace mezi proměnnými *Podíl dlouhodobě nezaměstnaných obyvatel* ($v = 58,56 \%$) a *Dosažitelní uchazeči* ($v = 75,93 \%$), dále pak mezi *Volná pracovní místa* ($v = 39,60 \%$) a *Dosažitelní uchazeči* ($v = 75,93 \%$). Z těchto proměnných byly vybrány mezi vstupní proměnné pro tvorbu kompozitního indikátoru takové proměnné, u kterých byla zjištěna vyšší relativní variabilita, tzn. *Dosažitelní uchazeči*. Problém silné korelace nastává rovněž u proměnných týkajících se *Technické infrastruktury (vodovod, plynovod, kanalizace)*. Na základě logického usouzení a nízké variability byla vyřazena proměnná *Technická infrastruktura – počet bytů v domech s vodovodem* ($v = 35 \%$). Ukazatele nemusí vzhledem k nízkému variačnímu koeficientu příliš ovlivňovat disparity mezi regiony. Dále proměnná *Technická infrastruktura – počet bytů v domech s plynovodem* ($v = 54,21 \%$ v roce 2016, $v = 124,04 \%$ v roce 2012) silně koreluje s proměnnou *Podíl neobydlených bytů* ($v = 34,04 \%$ v roce 2016, $v = 38,24 \%$ v roce 2012) a *Technická infrastruktura – počet bytů v domech s kanalizací* ($v = 48,61 \%$ v roce 2016, $v = 138,77 \%$ v roce 2012). Proměnná *Technická infrastruktura – počet bytů v domech s plynovodem* má obdobnou variabilitu jako proměnná *Technická infrastruktura – počet bytů v domech s kanalizací*. Aby nebylo odstraněno příliš mnoho proměnných a nedocházelo ke ztrátám informací, byla vybrána k odstranění proměnná *Technická infrastruktura – počet bytů v domech s plynovodem*. Pro rok 2012 nastával stejný problém s multikolinearitou u proměnné *Volná pracovní místa* ($v=56,46 \%$) a *Dosažitelní uchazeči* ($v=73,03 \%$), což jen potvrdilo výběr proměnné s vyšší relativní variabilitou *Dosažitelní uchazeči* pro rok 2016. Vztah mezi proměnnými *Podíl dlouhodobě nezaměstnaných obyvatel* ($v=43,11 \%$) a *Podíl nezaměstnaných* ($v=26,5 \%$) také vykazoval multikolinearitu, *Podíl dlouhodobě nezaměstnaných obyvatel* již prokázal silné korelace s ostatními proměnnými v roce 2016 a byl také vyřazen z uvažovaných proměnných. *Index ekonomické zátěže*, *Index vzdělanosti*, *Index stáří*, *Daňové příjmy*, *Počet samostatných*

ordinací praktického lékaře pro dospělé na 1000 obyvatel či *Počet registrovaných jednotek na 1000 obyvatel* disponují poměrně nízkou relativní variabilitou, mohou zde sice vystupovat jako konstanta, přesto jsou tyto ukazatele ponechány pro postoupení další analýzy z důvodu úplnosti dat.

Jednotlivé indikátory by měly být vybírány dle analytické spolehlivosti, měřitelnosti a dostupnosti v zemi, aby měl sledovaný jev význam a zároveň byl ve vztahu s ostatními indikátory. V tomto kroku by měly být také stanoveny silné a slabé stránky jednotlivých indikátorů či například tvorba souhrnné tabulky s charakteristikou dat, jejich dostupnost, zdroj, protože ovlivňují silné a slabé stránky konečného kompozitního indikátoru.

Z další analýzy byla vyřazena proměnná *Průměrná populační velikost obce*, která koreluje s dalšími proměnnými. Dále pak *Zaměstnanost v zemědělství*, u které není jasný směr. *Hrubá míra celkového přírůstku* též koreluje s *Hrubou mírou přirozeného přírůstku* a *Hrubou mírou migračního salda*. V závěru byly vybrány do vstupní matice indikátory uvedené níže. Podle Hebáka (2005) by měl tvořit větší rozměr prostor, v němž se data nacházejí, než je počet sledovaných veličin. Tento předpoklad byl splněn.

Finální výčet proměnných za hospodářskou oblast zvolených pro následující konstrukci KI včetně popisu jednotlivých proměnných, plurality a zdrojů jsou uvedeny v Příloze 2, též za sociální oblast v Příloze 3.

4.3 Detekce chybějících hodnot a odlehlých pozorování

V datovém souboru nejsou žádné chybějící hodnoty, proto nebylo třeba zvažovat různé metody nahrazení. Na základě testu normality dle Shapiro-Wilkova testu, který je určen pro menší datové soubory, byla detektována většina proměnných, které nepochází z normálního rozdělení. Data byla podrobena explorační analýze, na základě níž byly zaznamenány odlehlé a extrémní hodnoty. Odlehlá pozorování se v datovém souboru nacházejí a lze je vyřešit pomocí mnoha metod, např. trimmed mean či vzdálenosti Mahalanobis. Nicméně vyvstává otázka, zda odlehlá (popř. extrémní) pozorování v případě kompozitního indikátoru řešit či neřešit. Pokud je kompozitní indikátor sestavován k účelu získání pořadí okresů od nejlepších po nejhorší, pak by se zdálo logické ponechat tyto hodnoty ve vstupní datové matici a nesnižovat tak vyšší relativní variabilitu v datové matici

tak, aby výsledek opravdu poukázal na skutečně problémové okresy. Ovšem na druhou stranu při sestavování kompozitního indikátoru pracujeme s celou řadou statistik a metod, které jsou náchylné na odlehlá pozorování, např. průměr, směrodatná odchylka, korelační koeficient a bez ošetření odlehlých případů by tak mohlo dojít k nesprávným interpretacím kompozitního indikátoru. Ovšem v případě použití normalizace pořadí není vhodné řešit odlehlé případy. Podle Saisana (2012-a) jsou odlehlá pozorování problém, pokud je normalizační metoda založena na vzdálenosti, nikoli na pořadí. Z tohoto důvodu byla odlehlá pozorování ošetřena (kromě postupu za použití normalizace pořadí) dle doporučení Saisana a Philippase (2012-b) a Giacoma JRC (2018) následujícím způsobem.

Standardizace (z-skóre)

Bylo použito pravidlo pro detekci odlehlých pozorování $|z_i| \geq 3$. Jak uvádí Saisana a Philippas (2012-b), tato hranice může být upravována podle konkrétní situace. Datová matice tvoří 76 pozorování a vzhledem k tomu, že je třeba odlehlá pozorování ošetřit s velkou opatrností, aby nebyla vstupní data příliš zkreslena, bylo zvoleno benevolentnější kritérium $|z_i| \geq 3$ které pomohlo detekovat spíše extrémní pozorování.

Koeficienty šikmosti a špičatosti

Pro zjištění asymetrie v datech byly použity míry šikmosti a špičatosti s hranicí $|S_1| > 2$ a pro detekci míry špičatosti s hranicí $|S_2| > 3,5$.

Box-plot

Dále byl vytvořen krabicový diagram pro odhalení extrémních a odlehlých pozorování.

Mimo jiné je možné identifikovat odlehlé případy pomocí interkvartilového rozmezí, ovšem tato metoda je poněkud „přísnější“ v porovnání použití z-skóre či koeficientů šikmosti a špičatosti poukazuje na více odlehlých případů než z-skóre, proto označuje více případů jako odlehlá pozorování. Interkvartilové rozpětí nebylo využito k rozpoznání odlehlých případů z důvodu větší opatrnosti v práci s odlehlými hodnotami a bylo přistoupeno na více benevolentní metody (z-skóre, koeficienty šikmosti a špičatosti) takovým způsobem, aby byly ošetřeny tyto hodnoty co nejšetrněji. K nahrazení těchto hodnot byla použita dle Giacoma JRC (2018) metoda winsorizace, která je vhodná pro proměnné, kde se nachází méně jak 5 odlehlých případů. V Příloze 37 (rok 2012) a Příloze 38 (rok 2016) jsou

vypočteny popisné statistiky včetně výše zmíněných koeficientů šikmosti a špičatosti před a po ošetření odlehlých pozorování, výběr z popisné statistiky pro rok 2016 viz Tabulka 1.

Tabulka 1 Výběr z popisné statistiky 2016 (kompletní popisná statistika viz Příloha 38)

Popisná statistika 2016								
	Minimum	Maximum	Průměr	Směrodatná odchylka	Rozptyl	Variační koeficient	Šikmost	Špičatost
I1 Počet registrovaných jednotek	1 59,82	345,22	238,5474	30,69860	942,404	12,87%	0,915	1,774
H Daňové příjmy	5493,15	23643,46	14666,0363	2217,13143	4915671,791	15,12%	1,448	10,983
H Dosažitelní uchazeči na pracovní místo	0,57	15,35	3,5674	2,70872	7,337	75,93%	1,990	4,714
I1 Velké podniky	0,0629	0,3563	0,159809	0,0552349	0,003	34,56%	1,203	2,002
S Index vzdělanosti	1,5430	2,4718	1,858504	0,1516426	0,023	8,16%	1,428	4,122
S I hrubá míra přirozeného přírůstku	-2,53	5,25	0,0897	1,42392	2,028	1587,85%	1,101	2,809
S Lékaři	0,2972	0,5960	0,442186	0,0541887	0,003	12,25%	0,063	0,712
S Základní školy	0,1914	0,3668	0,274778	0,0404411	0,002	14,72%	0,076	-0,432
S Domovy pro seniory	0,0178	0,1547	0,056380	0,0210630	0,000	37,36%	1,431	5,130
S Počet dokončených bytů	0,81	7,71	2,1896	1,15837	1,342	52,90%	1,994	6,278
S Technická infrastruktura - kanalizace	0,88	4,60	1,6060	0,78074	0,610	48,61%	2,096	4,134
S Hustota silniční sítě	41,0275	111,2995	74,228863	16,9066671	285,835	22,78%	0,216	-0,551
S Sňatky a rozvody	1,38	3,66	2,4164	0,47045	0,221	19,47%	-0,115	-0,163
S Hrubá míra migračního salda	-6,05	20,61	1,0319	4,32883	18,739	419,51%	1,909	5,815
H Podíl nezaměstnaných osob	1,76	10,08	5,1088	1,80016	3,241	35,24%	0,655	0,020
I1 Dávky v hmotné nouzi	196,53	2986,76	852,4480	620,33701	384818,006	72,77%	1,667	2,449
H Cizí zdroje	31 29,18	23968,86	9979,5640	4193,64090	17586624,022	42,02%	1,222	1,675
S Index stáří	67,09	137,23	107,7988	12,85536	165,260	11,93%	-0,508	1,125
S Index ekonomické zátěže	56,28	69,74	62,9488	2,44003	5,954	3,88%	-0,033	0,105
S Podíl neobydlených bytů	7,60	43,22	20,8124	7,08509	50,199	34,04%	0,644	0,454

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

V dalším kroku konstrukce KI je vhodné podrobit data korelační analýze, ovšem v případě, že indikátory nemají stejný směr, je možné jak doporučuje Saisana (2012-a) provést korelační analýzu po provedení normalizace a vyřadit indikátory s vysokou silou závislosti, protože by mohly ovlivnit výsledky PCA či v příslušné dimenzi nadhodnotit skóre některého regionu.

4.4 Normalizace dat

Dle metodiky Nardo a kol. OECD (2008) by měla být ve čtvrtém kroku provedena vícerozměrná analýza a v pátém normalizace dat. Nicméně autorka shledává nezbytné nejdříve normalizovat data ve čtvrtém kroku a poté přistoupit k vícerozměrné analýze. Z tohoto důvodu jsou tyto dva kroky opačně v porovnání s metodikou *Handbook on Constructing Composite Indicators: Methodology and User Guide, Brussels: OECD* (2008).

Indikátory by měly být normalizovány takovým způsobem, aby byly porovnatelné. Normalizace byla provedena pomocí tří metod. Pomocí metody pořadí, metody standardizace (z-skóre) a metody Min-Max podle vzorců uvedených v kapitole 2.1.5.

Pomocí těchto metod normalizace byly eliminovány různé směry indikátorů – vyšší hodnoty tedy znamenají pozitivní směr hodnot v rámci příslušného indikátoru.

Ovšem v datové matici normalizované pomocí metody Min-Max se nachází nulové hodnoty, neboť se původní hodnoty přepočítávají na škále 0–1. Jak již bylo diskutováno v metodické části práce, jednotliví autoři přistupují k řešení tohoto problému pomocí různých technik, ovšem tyto metody vedou k odlišným výsledkům a ovlivňují konečný výsledek kompozitního indikátoru. Z tohoto důvodu byly zvoleny tři přístupy řešení problému nulových hodnot v datové matici při geometrické agregaci vypočteny a následně porovnány. Jedná se o transformaci datové matice na škálu 1–10, převedení nulové hodnoty na velmi malé číslo (např. 0,0001) a přičtení konstanty (hodnoty 1). U převedení nulové hodnoty na nízké číslo je zvolena hodnota 0,0001 dle Hudrlíkové (2014), přestože v návodu na sestavení kompozitního indikátoru Saisana a kol. (2017) uvádí jako příklad hodnotu 0,1. V disertační práci bylo přistoupeno k opatrnějšímu řešení této transformace na hodnotu 0,0001, neboť tato transformace má velice silný vliv na výsledný indikátor.

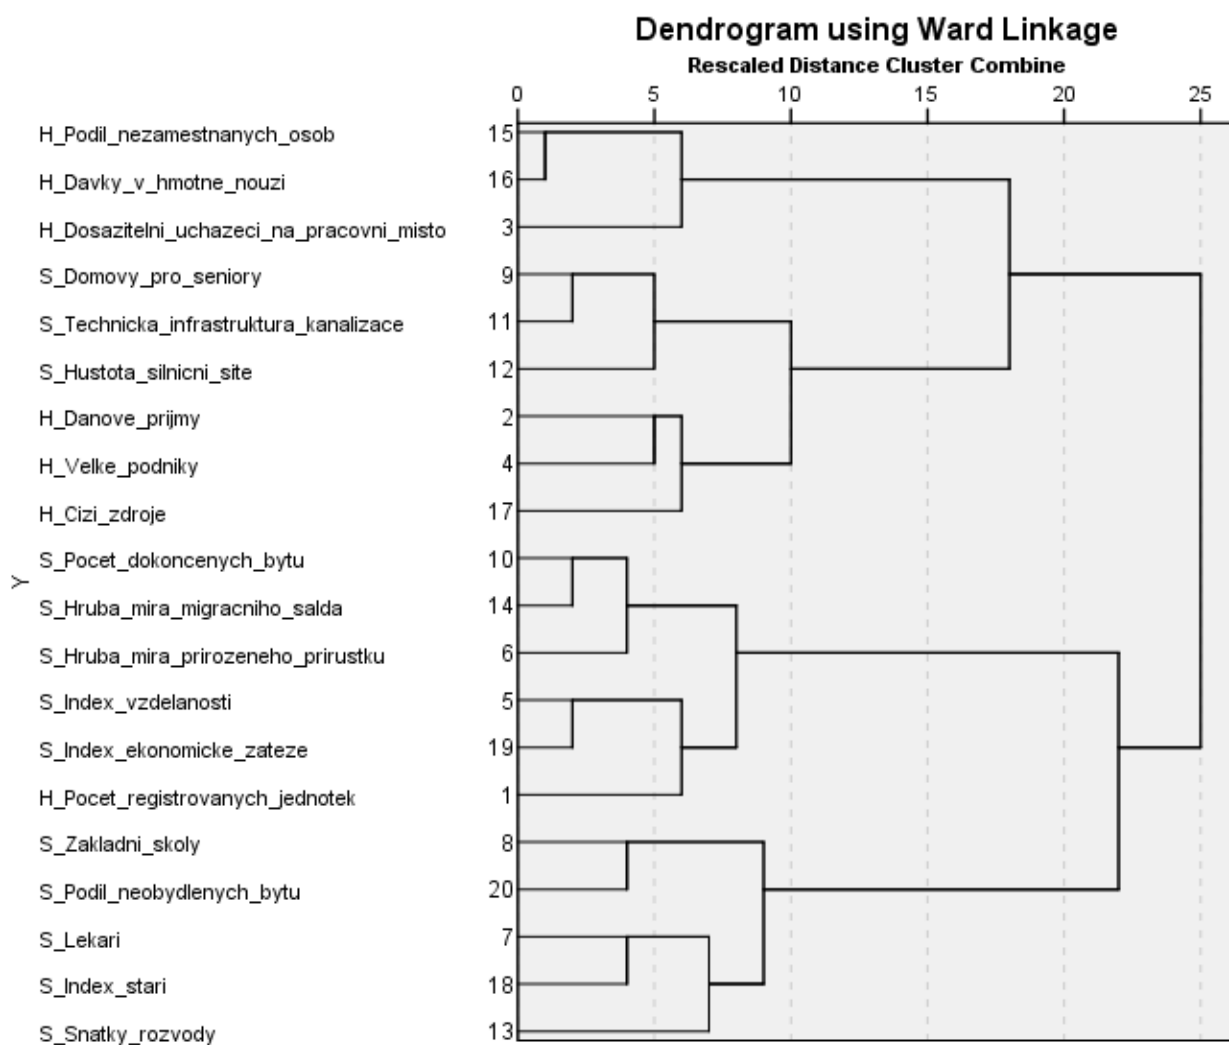
4.5 Vícerozměrná analýza

Průzkumová analýza byla provedena pro prověření struktury dat, identifikaci podskupiny indikátorů, které jsou si podobné, pomocí klastrové analýzy. Podle Hebáka (2005) jsou-li sledované ukazatele v normovaném normálním tvaru nebo jde o proměnné v nestejných měřících jednotkách, je nutné vycházet z korelační matice.

Vícerozměrná analýza byla použita k nalezení struktury mezi proměnnými pro rok 2016 a 2012. Jako vhodná metoda byla zvolena shluková analýza, konkrétně Wardova metoda. Tato metoda je citlivá na odlehlé a extrémní hodnoty v datové matici, proto vstupní matici tvořil normalizovaný soubor dat pomocí metody z-skóre očištěný o odlehlá pozorování za použití metody winsorizace (viz kapitola 4.3). Wardova metoda byla zvolena z důvodu, že se jedná o hierarchický postup, u kterého není nutné předem znát počet shluků, je založena na minimalizaci ztráty informace při spojení dvou tříd a výhodou této metody je, že má tendenci odstranit malé shluky, a tím tvoří shluky podobné velikosti. Metoda je velice často využívána v praxi právě u shlukování měst, regionů apod.


Následující dendrogramy popisují zařazení do jednotlivých shluků. Řez byl proveden v hodnotě patnáct euklidovské vzdálenosti a tím byly vytvořeny celkem čtyři relativně homogenní shluky proměnných pro rok 2012 a tři shluky pro rok 2016. Zařazení jednotlivých proměnných do shluků je znázorněno následujícími dendrogramy (viz Graf 1 pro rok 2012 a Graf 2 pro rok 2016).

Graf 1 Dendrogram – rok 2012



Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

Graf 2 Dendrogram – rok 2016



Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

Z dendrogramů je možné dedikovat rozložení proměnných do vytvořených shluků na základě jejich podobnosti pro rok 2012 a 2016. Podobnost mezi proměnnými, které patří do stejného klastru se snižuje s rostoucí propojovací vzdáleností. Mezi některými proměnnými tyto vzdálenosti do roku 2016 vzrostly nebo se naopak snížily. Například první shluk proměnných (2016) lze označit jako Atraktivita prostředí a populační růst (sociální pilíř), spadají do něj proměnné: *Počet dokončených bytů*, *Hrubá míra migračního salda*, *Hrubá míra přirozeného přírůstku* a v porovnání s rokem 2012 je s těmito proměnnými více podobná proměnná *Hustota silniční sítě*. Všechny tyto proměnné patří do sociálního pilíře. Druhý shluk (2016) lze nazvat Finance, hospodářství a vzdělání (hospodářský pilíř) a tvoří jej proměnné: *Daňové příjmy*, *Cizí zdroje*, *Velké podniky* a oproti roku 2012 také *Index*

vzdělanosti a *Počet registrovaných jednotek*. Většina těchto ukazatelů patří do hospodářského pilíře. Úroveň vzdělání souvisí s kvalitou získaného zaměstnání a hospodářským rozvojem v rámci podniků a registrovaných jednotek, u kterých byla v roce 2012 detekována větší podobnost. Třetí shluk (2016) Pracovní trh a technická infrastruktura (hospodářský pilíř): *Dávky v hmotné nouzi, Dosažitelní uchazeči na pracovní místo, Podíl nezaměstnaných osob* a oproti roku 2012 také *Technická infrastruktura kanalizace*. Tyto indikátory prezentují z velké části hospodářský pilíř. Čtvrtý shluk (2016) Občanská vybavenost (sociální pilíř): *Základní školy, Podíl neobydlených bytů a Domovy pro seniory*. Tento shluk reprezentuje sociální pilíř. Pátý shluk (2016) Stárnutí populace a sociální aspekty (sociální pilíř): *Index stáří, Index ekonomické zátěže, Lékaři a Sňatky a rozvody*. Všechny tyto proměnné zastupují sociální pilíř. Shluková analýza přiblížila strukturu vybraných indikátorů, tato struktura může být nápomocna při konstrukci kompozitního indikátoru.

Dalších vícerozměrných metod jako PCA bude využito v následujících krocích nejen pro stanovení vah, ale také k zjištění struktury proměnných a její změny od roku 2012 do roku 2016. Mimo jiné PCA poslouží k redukci počtu proměnných a jejich transformaci do nižšího počtu latentních proměnných při zachování téměř celé jejich původní variability (tzv. hlavní komponenty). Vzhledem k tomu, že do konstrukce KI vstupuje dvacet zvolených proměnných, je splněn předpoklad o vyšším počtu objektů než proměnných. Jak pro analýzu hlavních komponent, tak pro faktorovou analýzu je nezbytné, aby byly mezi proměnnými vztahy. Vztahy mezi proměnnými prokázala korelační matice na základě Pearsonova korelačního koeficientu (viz Přílohy 4–5).

V roce 2012 se slabší korelace nacházejí u proměnných *Počet lékařů* a *Sňatečnost a rozvodovost*, nicméně u těchto proměnných jsou mimo jiné středně silné vztahy ($r > 0,3$), proto budou ve vstupní matici zachovány. Do vstupní matice pro PCA pro rok 2016 vstupuje stejná sada proměnných jako pro rok 2012 (Příloha 4). Z korelační matice je zřejmé, že proměnná *Podíl nezaměstnaných* a *Počet domovů pro seniory* příliš nekorelují s ostatními proměnnými (Příloha 5).

V rámci PCA analýzy byla zjištěna anti-image korelační matice (Tabulka 2), tj. matice záporných parciálních korelačních koeficientů, na jejíž diagonále nalezneme hodnoty míry KMO.

Tabulka 2 Anti-image matice pro rok 2012

Anti-image Matrices

Anti-image Correlation

	H_Pocet_registrovanych_jednotek	H_Danove_prijmy	H_Dosažiteln_uchazeči_na_pracovní_místo	H_Velké_podniky	S_Index_vzdelanosti	S_Hrubá_míra_přirozeného_přírůstu	S_Lekari	S_Zakladní_skoly	S_Domovy_pro_seniory	S_Pocet_dokoncenyh_bytu	S_Technická_infrastruktura_kanalizace	S_Hustota_silnicni_site	S_Snatečnost	S_Hrubá_míra_migračního_salda	H_Podíl_nezaměstnaných_osob	H_Dávky_v_hmotné_nouzi	H_Cizí_zdroje	S_Index_stáří	S_Index_ekonomické_zátee	S_Podíl_neobydlených_bytu
H_Pocet_registrovanych_jednotek	.676 ^a	-.398	.318	-.019	-.168	.058	-.015	.029	.177	-.326	-.080	.096	.301	.271	-.046	.130	.049	.092	-.125	-.088
H_Danove_prijmy	-.398	.583 ^a	.018	-.147	-.023	-.250	.052	-.041	.113	.130	.055	-.081	-.160	-.016	.159	-.371	-.23	-.246	.308	-.039
H_Dosažiteln_uchazeči_na_pracovní_místo	.318	.018	.642 ^a	-.024	-.150	.044	.070	.112	.117	-.291	-.019	.110	.074	.297	-.439	.120	.242	.002	-.074	.010
H_Velké_podniky	-.019	-.147	-.024	.747 ^a	-.158	-.246	.024	.088	-.041	.126	-.273	.202	-.194	-.149	.263	-.303	-.12	-.247	.188	-.101
S_Index_vzdelanosti	-.168	-.023	-.150	-.158	.851 ^a	-.264	-.051	.103	-.209	-.049	-.179	-.061	-.156	-.252	.033	.116	.00	-.206	-.366	.069
S_Hrubá_míra_přirozeného_přírůstu	.058	-.250	.044	-.246	-.264	.566 ^a	-.107	.018	.200	-.229	-.076	.110	.192	.294	-.088	.391	-.04	.746	-.227	.196
S_Lekari	-.015	.052	.070	.024	-.051	-.107	.726 ^a	-.332	-.164	.171	-.141	.122	-.048	.064	-.002	.042	.069	-.221	-.038	.034
S_Zakladní_skoly	.029	-.041	.112	.088	.103	.018	-.332	.781 ^a	.100	-.119	.125	.001	-.096	.279	-.199	.113	-.07	.176	-.090	-.255
S_Domovy_pro_seniory	.177	.113	.117	-.041	-.209	.200	-.164	.100	.665 ^a	-.223	-.429	.074	.186	.301	.021	-.043	-.09	.219	.017	-.190
S_Pocet_dokoncenyh_bytu	-.326	.130	-.291	.126	-.049	-.229	.171	-.119	-.223	.792 ^a	-.001	.026	-.186	-.386	.178	.019	-.13	-.067	.056	.089
S_Technická_infrastruktura_kanalizace	-.080	.055	-.019	-.273	-.179	-.076	-.141	.125	-.429	-.001	.701 ^a	-.586	.045	.121	-.240	.148	.040	-.086	.121	.380
S_Hustota_silnicni_site	.096	-.081	.110	.202	-.061	.110	.122	.001	.074	.026	-.586	.617 ^a	-.087	-.179	.208	-.285	-.03	.042	-.084	-.308
S_Snatečnost	.301	-.160	.074	-.194	-.156	.192	-.048	-.096	.186	-.186	.045	-.087	.504 ^a	.341	-.109	.366	.027	.120	-.032	.055
S_Hrubá_míra_migračního_salda	-.271	-.016	.297	-.149	-.252	.294	.064	.279	.301	-.386	.121	-.179	.341	.633 ^a	-.210	.414	.075	.453	-.275	.138
H_Podíl_nezaměstnaných_osob	-.046	.159	-.439	.263	.033	-.088	-.002	-.199	.021	.178	-.240	-.208	-.109	-.210	.730 ^a	-.592	-.19	-.197	.340	-.081
H_Dávky_v_hmotné_nouzi	.130	-.371	.120	-.303	.116	.391	.042	.113	-.043	.019	.148	-.285	.366	.414	-.592	.595 ^a	.060	.483	-.452	.421
H_Cizí_zdroje	.049	-.226	.242	-.123	-.001	-.037	.069	-.067	-.086	-.125	.040	-.027	.027	.075	-.190	.060	.734 ^a	-.026	-.221	.089
S_Index_stáří	.092	-.246	.002	-.247	-.206	.746	-.221	.176	.219	-.067	-.086	.042	.120	.453	-.197	.483	-.03	.434 ^a	-.474	.101
S_Index_ekonomické_zátee	-.125	.308	-.074	.188	-.366	-.227	-.038	-.090	.017	.056	.121	-.084	-.032	-.275	.340	-.452	-.22	-.474	.638 ^a	-.263
S_Podíl_neobydlených_bytu	-.088	-.039	.010	-.101	.069	.196	.034	-.255	-.190	.089	.380	-.308	.055	.138	-.081	.421	.089	.101	-.263	.685 ^a

a. Measures of Sampling Adequacy(MSA)

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

Dle Hutchesona (1999) by měly míry KMO dosahovat větší hodnoty než 0,5. Tyto hodnoty nás upozorňují na méně vhodné ukazatele pro analýzu. Podle Hebáka (2007) jsou hodnoty KMO kolem 0,5 brány za špatné, okolo 0,6 za jen průměrné a 0,7 za středně užitečné. Z tohoto důvodu bylo stanoveno pro analýzu přísnější kritérium, dle kterého byly v anti-image korelační matici detekovány ukazatele s hodnotou nižší jak 0,6 jedná se o ukazatel *Index stáří*, *Daňové příjmy*, *Hrubá míra přirozeného přírůstu*, *Sňatečnost a rozvodovost a Dávky v hmotné nouzi*. Tyto ukazatele byly z další analýzy vyřazeny a znovu byla přepočtena matice záporných parciálních korelačních koeficientů, kde nesplnily kritérium proměnné *Počet lékařů* a *Dosažitelní uchazeči na jedno pracovní místo*, tyto proměnné byly taktéž vyřazeny z další analýzy (Tabulka 3).

Tabulka 3 Úprava anti-image matice pro rok 2012

Anti-image Matrices

Anti-image Correlation

	H_Pocet registr ovaných jednot ek	H_Dosazi telni_uch azeci_na pracovni misto	H_Velke podniky	S_Index vzdelan nosti	S_Lekari	S_Zaklad ni_skoly	S_Domov y_pro_se niory	S_Pocet dokon cenyh_ bytu	S_Techn icka_inf rastrukt ura_kan alizace	S_Hust ota_siln icni_sit e	S_Hrub a_mira migra cniho_s alda	H_Podil neza mestn anych_o sob	H_Cizi_ zdroje	S_Index ekono micke_ zateze	S_Podil neob ydleny ch_byt u
H_Pocet_registrovani_jednotek	.720 ^a	.378	-.085	-.160	.047	.042	.202	-.294	-.060	.076	.288	-.025	-.053	-.034	-.063
H_Dosazitelni_uchazeci_na_pracovni_misto	.378	.556^a	.036	-.186	.044	.126	.134	-.312	-.056	.180	.319	-.476	.260	-.079	-.075
H_Velke_podniky	-.085	.036	.834^a	-.245	.023	.132	.054	-.141	-.259	.122	.105	.145	-.213	.123	.069
S_Index_vzdelanosti	-.160	-.186	-.245	.799^a	-.167	.088	-.071	-.189	-.293	.068	-.236	.247	-.041	-.472	-.017
S_Lekari	.047	.044	.023	-.167	.557^a	-.323	-.088	-.162	-.220	.221	.191	.073	.071	-.151	-.060
S_Zakladni_skoly	.042	.126	.132	.088	-.323	.769^a	.118	-.194	.137	.032	.266	-.152	-.076	.063	-.329
S_Domovy_pro_seniory	.202	.134	.054	-.071	-.088	.118	.751^a	-.182	-.428	.021	.224	-.081	-.038	.030	-.170
S_Pocet_dokoncenych_bytu	-.294	-.312	.141	-.189	.162	-.194	-.182	.680^a	-.046	.127	-.486	.347	-.125	.127	.093
S_Technicka_infrastruktura_kanalizace	-.060	-.056	-.259	-.293	-.220	.137	-.428	-.046	.695^a	-.552	.123	-.165	.046	.166	.342
S_Hustota_silnicni_site	.076	.180	.122	.068	.221	.032	.021	.127	-.552	.670^a	-.113	-.010	-.037	-.214	-.205
S_Hrubamira_migračního_salda	.288	.319	.105	-.236	.191	.266	.224	-.486	.123	-.113	.706^a	-.004	.133	-.056	.029
H_Podil_nezaměstnaných_osob	-.025	-.476	.145	.247	.073	-.152	-.081	.347	-.165	-.010	-.004	.768^a	-.205	.119	.269
H_Cizi_zdroje	-.053	.260	-.213	-.041	.071	-.076	-.038	-.125	.046	-.037	.133	-.205	.676^a	-.223	.109
S_Index_ekonomické_zateze	-.034	-.079	.123	-.472	-.151	.063	.030	.127	.166	-.214	-.056	.119	-.223	.762^a	-.210
S_Podil_neobydlených_bytu	-.063	-.075	.069	-.017	-.060	-.329	-.170	.093	.342	-.205	.029	.269	.109	-.210	.694^a

a. Measures of Sampling Adequacy(MSA)

Anti-image Matrices

Anti-image Correlation

	H_Pocet registr ovaných jednot ek	H_Velk e_podn iky	S_Index vzdelan nosti	S_Zakla dni_skol y	S_Domo vy_pro seniory	S_Pocet dokon cenyh_ bytu	S_Techn icka_inf rastrukt ura_kan alizace	S_Husto ta_siln icni_sit e	S_Hrub a_mira migra cniho_s alda	H_Podil neza mestn anych_o sob	H_Cizi_ zdroje	S_Index ekono micke_ zateze	S_Podil neobyd lenych_ bytu
H_Pocet_registrovani_jednotek	.813^a	-.107	-.094	.006	.168	-.210	-.036	.002	.188	.188	-.171	.001	-.036
H_Velke_podniky	-.107	.817^a	-.242	.144	.052	.160	-.259	.116	.096	.183	-.232	.131	.074
S_Index_vzdelanosti	-.094	-.242	.792^a	.065	-.063	-.242	-.358	.146	-.165	.204	.018	-.534	-.041
S_Zakladni_skoly	.006	.144	.065	.813^a	.076	-.111	.079	.089	.326	-.075	-.099	.027	-.363
S_Domovy_pro_seniory	.168	.052	-.063	.076	.761^a	-.134	-.459	.018	.216	-.010	-.071	.028	-.169
S_Pocet_dokoncenych_bytu	-.210	.160	-.242	-.111	-.134	.753^a	-.028	.162	-.481	.223	-.060	.139	.086
S_Technicka_infrastruktura_kanalizace	-.036	-.259	-.358	.079	-.459	-.028	.689^a	-.529	.198	-.201	.078	.134	.336
S_Hustota_silnicni_site	.002	.116	.146	.089	.018	.162	-.529	.683^a	-.233	.066	-.104	-.178	-.188
S_Hrubamira_migračního_salda	.188	.096	-.165	.326	.216	-.481	.198	-.233	.709^a	.161	.044	-.005	.068
H_Podil_nezaměstnaných_osob	.188	.183	.204	-.075	-.010	.223	-.201	.066	.161	.840^a	-.103	.110	.274
H_Cizi_zdroje	-.171	-.232	.018	-.099	-.071	-.060	.078	-.104	.044	-.103	.722^a	-.204	.138
S_Index_ekonomické_zateze	.001	.131	-.534	.027	.028	.139	.134	-.178	-.005	.110	-.204	.748^a	-.229
S_Podil_neobydlených_bytu	-.036	.074	-.041	-.363	-.169	.086	.336	-.188	.068	.274	.138	-.229	.673^a

a. Measures of Sampling Adequacy(MSA)

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

Při analýze hlavních komponent souboru ukazatelů očištěných o proměnné uvedené výše byly zjištěny následující výsledky. Z původní vstupní matice 20 proměnných bylo použito 13 proměnných pro vstup do analýzy hlavních komponent:

- *Počet registrovaných jednotek*
- *Velké podniky*
- *Index vzdělanosti*
- *Základní školy*
- *Domovy pro seniory*
- *Počet dokončených bytů*
- *Technická infrastruktura – kanalizace*
- *Hustota silniční sítě*
- *Hrubá míra migračního salda*
- *Podíl nezaměstnaných osob*

- *Cizí zdroje*
- *Index ekonomické zátěže*
- *Podíl neobydlených bytů*

Tabulka 4 KMO a Bartlettův test

KMO and Bartlett's Test		2012	2016
Kaiser-Meyer-Olkin Measure of Sampling Adequacy.		0,755	0,618
Bartlett's Test of Sphericity	Approx. Chi-Square	495,939	431,676
	df	78	78
	Sig.	0,000	0,000

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

Pomocí kritéria KMO lze zjistit vhodnost pro sestavení hlavních komponent. Hodnoty KMO blízké jedné představují silnou vzájemnou závislost. Podle Hebáka (2005) hodnoty KMO pohybující se kolem 0,8 považují za chvályhodné. Z Kaiser-Meyer-Olkinova testu (KMO) doloženého v Tabulce 4 tedy vyplývá, že je soubor ukazatelů vhodný pro sestavení analýzy hlavních komponent. KMO míra činí 76 % (rok 2012) a 62 % (rok 2016). Podle Bartlettova testu byla prokázána statistická významnost ($p < 0,001$). Z analýzy hlavních komponent bylo zjištěno, že je možné vysvětlit model celkem pomocí čtyř komponent. Lze říci, že při zahrnutí zbylých proměnných do komponentní analýzy vysvětlují model čtyři nově vzniklé komponenty 72,95 % variability původních proměnných (rok 2012) a 67 % variability původních proměnných (rok 2016).

Tabulka 5 Podíl vysvětleného rozptylu jednotlivými komponentami pro rok 2012

Komponenta	Rotace sumy čtverců zátěží (2012)		
	Celkem	% rozptylu	kumulativní %
1	3.270	25.152	25.152
2	2.709	20.835	45.987
3	1.781	13.701	59.688
4	1.723	13.257	72.945

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV


Tabulka 6 Podíl vysvětleného rozptylu jednotlivými komponentami pro rok 2016

Komponenta	Rotace sumy čtverců zátěží (2016)		
	Celkem	% rozptylu	kumulativní %
1	2.575	19.805	19.805
2	2.308	17.752	37.557
3	2.124	16.339	53.895
4	1.715	13.194	67.089

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV


Důležitost jednotlivých komponent dle množství vysvětleného rozptylu prokazuje Tabulka 5 a 6. Počet komponent dokládá také sutinový graf (Scree-Plot viz Grafy 3 a 4). Podle Melouna (2002) tento graf zobrazuje užitečné komponenty jako kolmou stěnu a neužitečné komponenty tvoří vodorovné dno grafu. Z grafu je tedy zřejmé, že lze považovat za užitečné první tři až čtyři komponenty. Tyto čtyři komponenty a jejich rotace sumy čtverců zátěží jsou uvedeny v Tabulce 5 a 6. Vztah mezi původními proměnnými a nově vzniklými komponentami jsou zobrazeny v matici hlavních komponent.

Graf 3 Výstup z programu SPSS – Cattellův sutinový graf (Scree-Plot) pro rok 2012



Zdroj: vlastní zpracování, ČSÚ-KROK, MF-MONITOR, MPSV

Graf 4 Výstup z programu SPSS – Cattellův sutinový graf (Scree-Plot) pro rok 2016



Zdroj: vlastní zpracování, ČSÚ-KROK, MF-MONITOR, MPSV

4.6 Stanovení vah a agregace

Dle stanoveného teoretického rámce na počátku konstrukce KI byly pečlivě uváženy metody stanovení vah, protože zvolená metoda má vliv na finální výsledek kompozitního indikátoru. Bylo vypočteno několik scénářů, a to jak kompozitní indikátory bez očištěné datové matice od odlehlých pozorování, tak s očištěnou datovou maticí od odlehlých pozorování pro metody normalizace založené na skóre. Byly uvažovány jak indikátory bez vah, tak s vahami. Poté byly porovnávány výsledky řešení s pilíři (hospodářský a sociální pilíř) či bez pilířů.

Na základě normalizace pomocí metody pořadí byly použity pro výpočet agregace pouze metody založené na pořadí (např. medián, součet pořadí/průměr).

Pro data upravená metodou standardizace (z-skóre) byla následně použita pro agregaci metoda lineární agregace vycházející z výpočtu skóre.

Normalizované indikátory pomocí metody Min-Max byly následně využity pro lineární i geometrickou agregaci.

Pro větší přehlednost jsou veškeré použité kombinace těchto scénářů zobrazeny v Tabulce 7 níže. Celkem tedy bylo vytvořeno 48 variant kompozitních indikátorů za užití výše zmíněných kombinací metod (metod normalizace, vážení, ošetření odlehlých pozorování, agregace atd.).

Tabulka 7 Přehled vytvořených kompozitních indikátorů za kombinace použitých metod

Kompozitní indikátor	Kód - Typ indikátoru	Odlehlá pozorování	Metoda normalizace	Váhy	Agregace I	Techniky řešení nulových hodnot	Agregace II
1	33712	Odlehlá pozorování v datové matici	Pořadí	Bez vah	Medián		
2	33812				Součet		
3	11112		MIN - MAX	Stejně váhy	Lineární agregace		
4	11212				Geometrická agregace	Přepočtení na škálu 1-10	
5	11312				Přičtení konstanty (jedničky)		
6	11912					Nahrazení nul 0.0001	
7	21112		Z-skóre	Stejně váhy	Lineární agregace		
8	12112				Lineární agregace		
9	12212		MIN - MAX	PCA váhy	Geometrická agregace	Přepočtení na škálu 1-10	
10	12312				Přičtení konstanty (jedničky)		
11	12912				Nahrazení nul 0.0001		
12	22112		Z-skóre	PCA váhy	Lineární agregace		
13	11422				Lineární agregace v pilířích		Lineární agregace pilířů
14	11432		MIN - MAX	Stejně váhy	Geometrická agregace v pilířích	Přepočtení na škálu 1-10	Geometrická agregace pilířů
15	11522					Přičtení konstanty (jedničky)	Lineární agregace pilířů
16	11532					Nahrazení nul 0.0001	Geometrická agregace pilířů
17	11622				Lineární agregace v pilířích	Lineární agregace pilířů	
18	11632				Geometrická agregace v pilířích	Geometrická agregace pilířů	
19	11022				Lineární agregace v pilířích	Lineární agregace pilířů	
20	11032				Geometrická agregace v pilířích	Geometrická agregace pilířů	
21	21422		Z-skóre	Stejně váhy	Lineární agregace v pilířích		Lineární agregace pilířů
22	12432				Lineární agregace v pilířích		Geometrická agregace pilířů
23	12522		MIN - MAX	PCA váhy	Geometrická agregace v pilířích	Přepočtení na škálu 1-10	Lineární agregace pilířů
24	12622				Přičtení konstanty (jedničky)	Lineární agregace pilířů	
25	12022				Nahrazení nul 0.0001	Lineární agregace pilířů	
26	11111	Očištěná datová matice od odlehlých pozorování	MIN - MAX	Stejně váhy	Lineární agregace		
27	11211				Geometrická agregace	Přepočtení na škálu 1-10	
28	11311			Přičtení konstanty (jedničky)			
29	11911			Nahrazení nul 0.0001			
30	21111		Z-skóre	Stejně váhy	Lineární agregace		
31	12111				Lineární agregace		
32	12211		MIN - MAX	PCA váhy	Geometrická agregace	Přepočtení na škálu 1-10	
33	12311				Přičtení konstanty (jedničky)		
34	12911				Nahrazení nul 0.0001		
35	22111		Z-skóre	PCA váhy	Lineární agregace		
36	11421				Lineární agregace v pilířích		Lineární agregace pilířů
37	11431		MIN - MAX	Stejně váhy	Geometrická agregace v pilířích	Přepočtení na škálu 1-10	Geometrická agregace pilířů
38	11521					Přičtení konstanty (jedničky)	Lineární agregace pilířů
39	11531					Nahrazení nul 0.0001	Geometrická agregace pilířů
40	11621				Lineární agregace v pilířích	Lineární agregace pilířů	
41	11631				Geometrická agregace v pilířích	Geometrická agregace pilířů	
42	11021				Lineární agregace v pilířích	Lineární agregace pilířů	
43	11031				Geometrická agregace v pilířích	Geometrická agregace pilířů	
44	21421		Z-skóre	Stejně váhy	Lineární agregace v pilířích		Lineární agregace pilířů
45	12431				Lineární agregace v pilířích		Geometrická agregace pilířů
46	12521		MIN - MAX	PCA váhy	Geometrická agregace v pilířích	Přepočtení na škálu 1-10	Lineární agregace pilířů
47	12621				Přičtení konstanty (jedničky)	Lineární agregace pilířů	
48	12021				Nahrazení nul 0.0001	Lineární agregace pilířů	

Zdroj: vlastní zpracování, ČSÚ-KROK, MF-MONITOR, MPSV

Pětimístný kód jednotlivých typů scénářů KI byl stanoven následujícím způsobem:

První číslo – kód metody normalizace, kde 1 – Min-Max, 2 – z-skóre, 3 – pořadí

Druhé číslo – kód stanovených vah, kde 1 – Stejně váhy, 2 – PCA váhy, 3 – bez vah

Třetí číslo – kód metody agregace prvního řádu, kde 1 – Aritmetický průměr, 2 – Geometrický průměr (přepočtení na škálu 1–10), 3 – Geometrický průměr (přičtení konstanty), 4 – Aritmetický průměr v pilířích, 5 – Geometrický průměr v pilířích (přepočtení na škálu 1–10), 6 – Geometrický průměr v pilířích (přičtení konstanty), 7 – medián, 8 – součet, 9 – Geometrický průměr (nahrazení nul 0,0001), 0 – Geometrický průměr v pilířích (nahrazení nul 0,0001)

Čtvrté číslo – kód metody agregace druhého řádu, kde 1 – bez Agregace II, 2 – Agregace II aritmetický průměr, 3 – Agregace II geometrický průměr

Páté číslo – kód zda se pracovalo s očištěnou datovou maticí o odlehlá pozorování či ne, kde 1 – matice bez outlierů, 2 – matice s outlieri.

V případě scénářů, kdy byly váhy použity, byly uvažovány následující přístupy pro stanovení vah, a to stejné váhy a váhy vypočtené pomocí FA/PCA dle přístupu Nardo a kol. OECD (2008). Tyto dva přístupy dosahovaly v porovnání s ostatními uvažovanými přístupy vážení lepších výsledků konečného KI k měření regionálních disparit a blahobytu v regionech v publikaci Döpke a kol. (2017) viz kapitola 3.1.

4.6.1 Metoda stejných vah

Pro kompozitní indikátor bylo vybráno celkem dvacet různých indikátorů (viz druhý krok, výběr nejpoužívanějších indikátorů). V případě scénáře bez uvažování jednotlivých pilířů byla pro každý z indikátorů stanovena 5% váha. U druhého případu scénáře, kdy jsou brány v potaz pilíře (hospodářský a sociální), a to každý s vahou 50 %, indikátory spadající do hospodářského pilíře obdržely váhu 7,14 % a indikátory spadající do sociálního pilíře váhu 3,85 %. V následující Tabulce 8 jsou uvedeny přiřazené váhy jednotlivým proměnným pro rok 2012 a 2016.

Tabulka 8 Stanovené váhy bez použití pilířů a s pilíři

Proměnná	Bez pilířů		Pilíře		
	Stejně váhy		Stejně váhy		
	2016	2012	2016	2012	
II Počet registrovaných jednotek	0,05	0,05	0,5	0,0714	0,0714
II Daňové příjmy	0,05	0,05		0,0714	0,0714
II Dosažitelní uchazeči na pracovní místo	0,05	0,05		0,0714	0,0714
II Velké podniky	0,05	0,05		0,0714	0,0714
II Podíl nezaměstnaných osob	0,05	0,05		0,0714	0,0714
II Dávky v hmotné nouzi	0,05	0,05		0,0714	0,0714
II Cizí zdroje	0,05	0,05		0,0714	0,0714
S Index vzdělanosti	0,05	0,05	0,5	0,0385	0,0385
S Hrubá míra přirozeného přírůstku	0,05	0,05		0,0385	0,0385
S Lékaři	0,05	0,05		0,0385	0,0385
S Základní školy	0,05	0,05		0,0385	0,0385
S Domovy pro seniory	0,05	0,05		0,0385	0,0385
S Počet dokončených bytu	0,05	0,05		0,0385	0,0385
S Technická infrastruktura kanalizace	0,05	0,05		0,0385	0,0385
S Hustota silniční sítě	0,05	0,05		0,0385	0,0385
S Sňatky rozvody	0,05	0,05		0,0385	0,0385
S Hrubá míra migračního salda	0,05	0,05		0,0385	0,0385
S Index stáří	0,05	0,05		0,0385	0,0385
S Index ekonomické zátěže	0,05	0,05		0,0385	0,0385
S Podíl neobydlených bytu	0,05	0,05		0,0385	0,0385

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

4.6.2 Metoda analýzou hlavních komponent/faktorovou analýzou

Poté bylo přistoupeno k analýze hlavních komponent (PCA). Nestejné měrné jednotky v datové matici byly ošetřeny normalizací pomocí metody Min-Max či z-skóre (obě metody normalizace dochází ke stejným výsledkům a PCA vahám), tudíž PCA analýza vychází z kovariační matice.

Podle Nardo a kol. OECD (2005) stejné váhy fungují dobře, pokud jsou všechny pilíře (hospodářský, sociální) zastoupeny stejným počtem dílčích indikátorů. Autor si dovolí nesouhlasit s tímto tvrzením, neboť by docházelo ke stejným výsledkům jako za použití stejných vah bez pilířů.

V následující Tabulce 10 je zobrazen postup stanovení vah založených na PCA analýze pro rok 2016 za použití komponentních zátěží z Tabulky 9 (rok 2012 viz Příloha 6). Použité

vícerozměrné metody umožnily transformaci původního vysokého počtu proměnných do nižšího počtu, což by mohlo být výhodou metody stanovení vah PCA oproti ostatním metodám. Takto bylo možné na základě analýzy charakterizovat důležité proměnné, které ovlivňují hospodářskou problémovost (sílu) regionu a je možné porovnat jednotlivé regiony mezi s sebou.

Tabulka 9 Tabulka komponentních zátěží pro výpočet vah pro rok 2016

Proměnná	Komponentní zátěže				Čtverec komponentní zátěže (ve škále 0-1)			
	Komponenta 1	Komponenta 2	Komponenta 3	Komponenta 4	Komponenta 1	Komponenta 2	Komponenta 3	Komponenta 4
S Hrubá míra migračního salda	0.883	-0.009	0.001	0.142	0.30	0.00	0.00	0.01
S Počet dokončených bytů	-0.778	-0.284	0.148	-0.160	0.24	0.04	0.01	0.01
H Podíl nezaměstnaných osob	0.665	-0.305	-0.211	-0.251	0.17	0.04	0.02	0.04
S Index vzdělanosti	0.476	-0.086	0.142	-0.325	0.09	0.00	0.01	0.06
S Index ekonomické zátěže	0.010	0.815	0.313	0.279	0.00	0.29	0.05	0.05
S Technická infrastruktura-kanalizace	0.117	0.814	0.172	0.420	0.01	0.29	0.01	0.10
S Hustota silniční sítě	0.389	-0.731	-0.009	0.385	0.06	0.23	0.00	0.09
S Domovy pro seniory	0.124	0.387	0.742	0.015	0.01	0.06	0.26	0.00
S Podíl neobydlených bytů	-0.073	-0.031	0.729	-0.050	0.00	0.00	0.25	0.00
S Základní školy	-0.160	0.179	0.699	0.477	0.01	0.01	0.23	0.13
H Cizí zdroje	-0.539	0.238	0.579	0.000	0.11	0.02	0.16	0.00
H Počet registrovaných jednotek	-0.100	0.160	0.069	0.723	0.00	0.01	0.00	0.30
H Velké podniky	-0.081	-0.030	-0.015	-0.587	0.00	0.00	0.00	0.20
Vysvětlený rozptyl (Eigenvalue)	2.57	2.31	2.12	1.72				
SUMA vysvětleného rozptylu (Eigenvalue)	8.72							
Vysvětlený rozptyl/SUMA vysvětleného rozptylu	0.30	0.26	0.24	0.20				

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

Tabulka 10 Výpočet váhy pro rok 2016

Proměnná	Vysvětlený rozptyl/SUMA vysvětleného rozptylu	Nejvyšší zátěže na druhou (ve škále 0-1)	Součin	Váha
S Podíl neobydlených bytů	0.30	0.30	0.09	0.1167
S Technická infrastruktura-kanalizace	0.30	0.24	0.07	0.0906
S Základní školy	0.30	0.17	0.05	0.0661
S Domovy pro seniory	0.30	0.09	0.03	0.0339
S Počet dokončených bytů	0.26	0.29	0.08	0.0993
S Hrubá míra migračního salda	0.26	0.29	0.08	0.0991
S Index ekonomické zátěže	0.26	0.23	0.06	0.0799
H Počet registrovaných jednotek	0.24	0.26	0.06	0.0823
H Cizí zdroje	0.24	0.25	0.06	0.0795
S Index vzdělanosti	0.24	0.23	0.06	0.0730
H Velké podniky	0.24	0.16	0.04	0.0501
S Hustota silniční sítě	0.20	0.30	0.06	0.0781
H Podíl nezaměstnaných osob	0.20	0.20	0.04	0.0516
SUMA		4.15	1.46	

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

Kompletní hodnoty stanovených vah pomocí metody hlavních komponent pro rok 2012 a 2016 jsou uvedeny v následující Tabulce 11.

Tabulka 11 Finální PCA váhy pro roky 2012 a 2016

Proměnná	Váhy PCA	
	2016	2012
S Podíl neobydlených bytů	0.1167	0.1122
S Počet dokončených bytů	0.0993	0.0815
S Hrubá míra migračního salda	0.0991	0.0953
S Technická infrastruktura kanalizace	0.0906	0.1279
H Počet registrovaných jednotek	0.0823	0.0457
S Index ekonomické zátěže	0.0799	0.0373
H Cizí zdroje	0.0795	0.0545
S Hustota silniční sítě	0.0781	0.1220
S Index vzdělanosti	0.0730	0.0547
S Základní školy	0.0661	0.0491
H Podíl nezaměstnaných osob	0.0516	0.0750
H Velké podniky	0.0501	0.0305
S Domovy pro seniory	0.0339	0.1145

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

V této fázi byly vypočteny veškeré zvolené typy scénářů kompozitních indikátorů (KI) za použití kombinace všech výše zmíněných metod. Jedná se celkem o čtyřicet osm typů KI. Agregace byly provedeny dle vzorců v kapitole 2.1.6. Výsledné pořadí za použití kombinace těchto různých metod jsou uvedeny v Přílohách 7–10.

4.7 Analýza k posouzení robustnosti a citlivosti

Při konstrukci indikátoru došlo hned v několika předchozích krocích k volbě metody, např. metody normalizace, stanovení vah, metody agregace. Toto rozhodnutí může být subjektivní a dochází tedy k určité míře nejistoty a citlivosti indikátoru na výběr té či oné metody. Robustnost (Youden, 1967) je mírou kapacity postupu zůstat netečný vůči malým změnám parametrů metody a poskytuje informaci o jeho spolehlivosti během používání. Analýza k posouzení robustnosti je tedy velice důležitým a nezbytným krokem. K tomu se používají simulace Monte Carlo, kde závisle proměnné představuje Pořadí (KI), ovšem vzhledem k malému počtu vytvořených KI je tento postup redundantní a lze použít postup porovnání pořadí k mediánu pořadí okresu. Jak uvádí Hudrlíková (2014), hodnocení

robustnosti jednotlivých metod lze nazvat jako míra posunu v hodnocení, která se počítá jako průměr absolutní hodnoty rozdílů v pořadí regionů s ohledem na referenční pořadí ve všech regionech N . Jako referenční hodnota je stanovena střední hodnota pořadí. V této disertační práci je použit medián všech pořadí za daný region jako referenční hodnota a míra posunu v hodnocení je nazvána jako míra robustnosti.

Celkem bylo vytvořeno čtyřicet osm různých typů kompozitních indikátorů. V rámci nich byly detekovány extrémní a odlehlé pozorování na základě z-skóre. Pro odhalení outlierů bylo použito kritérium $|z_i| \geq 2,5$ pro menší datové soubory ($n < 80$). Typy KI detekovány jako odlehlá pozorování jsou zobrazena v Tabulce 12.

Tabulka 12 Detekce extrémních a odlehlých pozorování u typu kompozitního indikátoru na základě hodnot z-skóre

Rok 2016					
Typ KI	Normalizace	Váhy	Agregace I	Agregace II	Odlehlá pozorování
11211	MIN-MAX	Stejně váhy	Geometrický průměr (škála 1-10)	Bez Agregace II	Bez outlierů
11521	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (škála 1-10)	Aritmetický průměr pilířů	Bez outlierů
11522	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (škála 1-10)	Aritmetický průměr pilířů	S outlierů
11531	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (škála 1-10)	Geometrický průměr pilířů	Bez outlierů
11532	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (škála 1-10)	Geometrický průměr pilířů	S outlierů
12211	MIN-MAX	PCA váhy	Geometrický průměr (škála 1-10)	Bez Agregace II	Bez outlierů
12432	MIN-MAX	PCA váhy	Aritmetický průměr v pilířích	Geometrický průměr pilířů	S outlierů
21111	Z-skóre	Stejně váhy	Aritmetický průměr	Bez Agregace II	Bez outlierů
21112	Z-skóre	Stejně váhy	Aritmetický průměr	Bez Agregace II	S outlierů
21422	Z-skóre	Stejně váhy	Aritmetický průměr	Aritmetický průměr pilířů	S outlierů
21421	Z-skóre	Stejně váhy	Aritmetický průměr v pilířích	Aritmetický průměr pilířů	Bez outlierů
22111	Z-skóre	PCA váhy	Aritmetický průměr	Bez Agregace II	Bez outlierů
22112	Z-skóre	PCA váhy	Aritmetický průměr	Bez Agregace II	S outlierů
33812	Pořadí	Bez vah	Součet	Bez Agregace II	S outlierů
Rok 2012					
11211	MIN-MAX	Stejně váhy	Geometrický průměr (škála 1-10)	Bez Agregace II	Bez outlierů
11521	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (škála 1-10)	Aritmetický průměr pilířů	Bez outlierů
11522	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (škála 1-10)	Aritmetický průměr pilířů	S outlierů
11531	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (škála 1-10)	Geometrický průměr pilířů	Bez outlierů
11532	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (škála 1-10)	Geometrický průměr pilířů	S outlierů
12111	MIN-MAX	PCA váhy	Aritmetický průměr	Bez Agregace II	Bez outlierů
12112	MIN-MAX	PCA váhy	Aritmetický průměr	Bez Agregace II	S outlierů
12432	MIN-MAX	PCA váhy	Aritmetický průměr v pilířích	Geometrický průměr pilířů	S outlierů
21111	Z-skóre	Stejně váhy	Aritmetický průměr	Bez Agregace II	Bez outlierů
21112	Z-skóre	Stejně váhy	Aritmetický průměr	Bez Agregace II	S outlierů
21422	Z-skóre	Stejně váhy	Aritmetický průměr	Aritmetický průměr pilířů	S outlierů
21421	Z-skóre	Stejně váhy	Aritmetický průměr v pilířích	Aritmetický průměr pilířů	Bez outlierů
22111	Z-skóre	PCA váhy	Aritmetický průměr	Bez Agregace II	Bez outlierů
22112	Z-skóre	PCA váhy	Aritmetický průměr	Bez Agregace II	S outlierů
33712	Pořadí	Bez vah	Medián	Bez Agregace II	S outlierů

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

Z Tabulky 12 je zřejmé, že u obou sledovaných roků jsou často odlehlými pozorováními typy metod, kde bylo využito postupu přepočtení nulových hodnot na škálu 1–10 pro výpočet geometrické agregace. Jako outlier se též projeví všechny typy KI, kde bylo použito pro konstrukci normalizace z-skóre, a to jak u stejných vah, tak PCA vah. Zda výsledné pořadí kompozitního indikátoru ovlivňuje ošetření odlehlých pozorování či stupeň agregace není z tabulky jednoznačně zřejmé, tyto kategorie proměnných se jeví téměř rovnoměrně zastoupené a pravděpodobně nemají příliš velký vliv na výsledné pořadí okresu. Z pohledu porovnávaných let se odlehlá pozorování liší především u typů KI založených na pořadí, u roku 2016 je detekován jako outlier metoda agregace pomocí součtu, a naopak u roku 2012 agregace pomocí mediánu.

Výsledky dokládá také vytvořený Box-Plot viz Graf 5 (kompletní graf Příloha 11 pro rok 2012 a Příloha 12 pro rok 2016) s vyznačením typu kompozitního indikátoru u kterých dochází k extrémním či odlehlým pozorováním. Kódy jednotlivých typů jsou již uvedeny výše v přehledu vytvořených kompozitních indikátorů za kombinace použitých metod viz popis Tabulky 7.

Z důvodu vysokého počtu okresů jsou některé grafy příliš rozměrné, proto je ve vlastní práci uvedena pouze ukázka, kde je vyobrazen první okres dle pořadí KI a pak každý třetí jako zástupce. V příloze 8 je pak doložen kompletní graf se všemi okresy.

oproti zbylým dvěma technikám. Z dalšího zkoumání je tedy možné vyloučit postup nahrazení nulové hodnoty číslem 0,0001 na základě které dochází k významnému zkreslení výsledného pořadí kompozitního indikátoru viz Přílohy 7–10. Za vhodnější se jeví postup podle starší publikace Saisana a Philippase (2012-b) provést transformaci datové matice na škálu 1–10 či dle Roenfeldt (2018) přičtení hodnoty 1 (konstanty).


Tabulka 13 Výpočet měr robustnosti pro porovnání KI dle technik řešení nulových hodnot pro geometrickou agregaci (2012 a 2016)

Kód	Normalizace	Váhy	Agregace I	Agregace II	Odlehlá pozorování	Míra robustnosti	
						2016	2012
11311	MIN-MAX	Stejně váhy	Geometrický průměr (přičtení konstanty)		Bez outlierů	3.4408	3.7171
11631	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přičtení konstanty)	Geometrický průměr pilířů	Bez outlierů	3.8618	4.8355
11621	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přičtení konstanty)	Aritmetický průměr pilířů	Bez outlierů	3.8618	4.9276
11312	MIN-MAX	Stejně váhy	Geometrický průměr (přičtení konstanty)		S outlieri	3.9145	4.4013
11632	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přičtení konstanty)	Geometrický průměr pilířů	S outlieri	4.9539	5.1513
11622	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přičtení konstanty)	Aritmetický průměr pilířů	S outlieri	5.1513	5.2434
11211	MIN-MAX	Stejně váhy	Geometrický průměr (přepočtení na škálu 1-10)		Bez outlierů	5.6118	6.2039
11212	MIN-MAX	Stejně váhy	Geometrický průměr (přepočtení na škálu 1-10)		S outlieri	5.9539	4.9671
11521	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přepočtení na škálu 1-10)	Aritmetický průměr pilířů	Bez outlierů	6.6382	6.8882
11531	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přepočtení na škálu 1-10)	Geometrický průměr pilířů	Bez outlierů	6.6908	6.8618
12522	MIN-MAX	PCA váhy	Geometrický průměr (přepočtení na škálu 1-10)		S outlieri	7.0066	7.7829
12521	MIN-MAX	PCA váhy	Geometrický průměr (přepočtení na škálu 1-10)		Bez outlierů	7.3618	8.2566
11532	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přepočtení na škálu 1-10)	Geometrický průměr pilířů	S outlieri	7.4539	5.2303
11522	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přepočtení na škálu 1-10)	Aritmetický průměr pilířů	S outlieri	7.5592	5.5724
12521	MIN-MAX	PCA váhy	Geometrický průměr v pilířích (přepočtení na škálu 1-10)	Aritmetický průměr pilířů	Bez outlierů	7.6645	10.0066
12522	MIN-MAX	PCA váhy	Geometrický průměr v pilířích (přepočtení na škálu 1-10)	Aritmetický průměr pilířů	S outlieri	7.7829	8.7303
12621	MIN-MAX	PCA váhy	Geometrický průměr v pilířích (přičtení konstanty)	Aritmetický průměr pilířů	Bez outlierů	7.8092	8.4671
12311	MIN-MAX	PCA váhy	Geometrický průměr (přičtení konstanty)		Bez outlierů	7.8224	8.2961
12312	MIN-MAX	PCA váhy	Geometrický průměr (přičtení konstanty)		S outlieri	8.0987	7.6645
12622	MIN-MAX	PCA váhy	Geometrický průměr v pilířích (přičtení konstanty)	Aritmetický průměr pilířů	S outlieri	8.2829	7.8224

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

Na základě výše uvedených výpočtů je možné ověřit, která z těchto technik je více robustní a dle vyčíslených měr se zdá být více robustní metoda přičtení konstanty, nežli transformace hodnot na škálu 1–10. Z Tabulky 13 výše je zřetelné, že postup přičtení konstanty dosahuje nižších měr robustnosti v kombinaci se stejnými vahami, naopak u PCA vah dosahuje vysokých měr robustnosti, to lze částečně odůvodnit tím, že volba metody vah má pravděpodobně silný vliv na výsledné pořadí kompozitního indikátoru. Rovněž to dokládá výše uvedená detekce odlehklých pozorování na základě z-skóre, kde u postupu transformace hodnot na škálu 1–10 docházelo často k extrémním či odlehklým hodnotám finálního pořadí v rámci okresu. Mimo jiné výsledky také dokazuje následující ukázka krabicového diagramu v Grafu 6 (Příloha 13 pro rok 2012 a Příloha 14 pro rok 2016), kde jsou tyto dva postupy porovnány. K odlehklým hodnotám v pořadí okresu docházelo především u typů KI s hodnotami převedenými na škálu 1–10.

Graf 6 Výběr okresů – Box-Plot pro pořadí KI jednotlivých okresů – porovnání technik ošetření nulových hodnot pro geometrickou transformaci za rok 2016 (kompletní verze Příloha 14)



Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

V Tabulce 14 je vypracován souhrn všech kombinací metod a sestavených typů kompozitních indikátorů s vypočtenou mírou robustnosti na základě mediánu pořadí, seřazených od nejnižší hodnoty (nejvíce robustní metody) po nejvyšší hodnoty (nejméně robustní). Z tabulky je zřejmé, že nejvíce robustní vycházejí typy KI vypočtené pomocí metody normalizace Min-Max, stejných vah a s ošetřenými odlehlými pozorováními pomocí metody winsorizace.

Tabulka 14 Výpočet měr robustnosti pro všechny uvažované typy KI (2012 a 2016)

Kód KI	Normalizace	Váhy	Agregace I	Agregace II	Odlehlá pozorování	Míra robustnosti	
						2016	2012
11311	MIN-MAX	Stejně váhy	Geometrický průměr (přičtení konstanty)		Bez outlierů	3.4408	3.7171
11111	MIN-MAX	Stejně váhy	Aritmetický průměr		Bez outlierů	3.7039	3.9803
11631	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přičtení konstanty)	Geometrický průměr pilířů	Bez outlierů	3.8618	4.8355
11621	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přičtení konstanty)	Aritmetický průměr pilířů	Bez outlierů	3.8618	4.9276
11312	MIN-MAX	Stejně váhy	Geometrický průměr (přičtení konstanty)		S outlieri	3.9145	4.4013
11431	MIN-MAX	Stejně váhy	Aritmetický průměr v pilířích	Geometrický průměr pilířů	Bez outlierů	3.9408	4.5592
11421	MIN-MAX	Stejně váhy	Aritmetický průměr v pilířích	Aritmetický průměr pilířů	Bez outlierů	4.0987	5.0592
11112	MIN-MAX	Stejně váhy	Aritmetický průměr		S outlieri	4.2961	4.9803
33812	Pořadí	Bez vah	Součet		S outlieri	4.8092	4.7566
11632	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přičtení konstanty)	Geometrický průměr pilířů	S outlieri	4.9539	5.1513
11432	MIN-MAX	Stejně váhy	Aritmetický průměr v pilířích	Geometrický průměr pilířů	S outlieri	5.0461	5.1645
11622	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přičtení konstanty)	Aritmetický průměr pilířů	S outlieri	5.1513	5.2434
11422	MIN-MAX	Stejně váhy	Aritmetický průměr v pilířích	Aritmetický průměr pilířů	S outlieri	5.2961	5.9408
11211	MIN-MAX	Stejně váhy	Geometrický průměr (přepočtení na škálu 1-10)		Bez outlierů	5.6118	6.2039
11212	MIN-MAX	Stejně váhy	Geometrický průměr (přepočtení na škálu 1-10)		S outlieri	5.9539	4.9671
11521	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přepočtení na škálu 1-10)	Aritmetický průměr pilířů	Bez outlierů	6.6382	6.8882
11531	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přepočtení na škálu 1-10)	Geometrický průměr pilířů	Bez outlierů	6.6908	6.8618
12212	MIN-MAX	PCA váhy	Geometrický průměr (přepočtení na škálu 1-10)		S outlieri	7.0066	7.7829
33712	Pořadí	Bez vah	Medián		S outlieri	7.2566	8.9671
12211	MIN-MAX	PCA váhy	Geometrický průměr (přepočtení na škálu 1-10)		Bez outlierů	7.3618	8.2566
11532	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přepočtení na škálu 1-10)	Geometrický průměr pilířů	S outlieri	7.4539	5.2303
11522	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přepočtení na škálu 1-10)	Aritmetický průměr pilířů	S outlieri	7.5592	5.5724
12521	MIN-MAX	PCA váhy	Geometrický průměr v pilířích (přepočtení na škálu 1-10)	Aritmetický průměr pilířů	Bez outlierů	7.6645	10.0066
12522	MIN-MAX	PCA váhy	Geometrický průměr v pilířích (přepočtení na škálu 1-10)	Aritmetický průměr pilířů	S outlieri	7.7829	8.7303
12621	MIN-MAX	PCA váhy	Geometrický průměr v pilířích (přičtení konstanty)	Aritmetický průměr pilířů	Bez outlierů	7.8092	8.4671
12311	MIN-MAX	PCA váhy	Geometrický průměr (přičtení konstanty)		Bez outlierů	7.8224	8.2961
12312	MIN-MAX	PCA váhy	Geometrický průměr (přičtení konstanty)		S outlieri	8.0987	7.6645
12622	MIN-MAX	PCA váhy	Geometrický průměr v pilířích (přičtení konstanty)	Aritmetický průměr pilířů	S outlieri	8.2829	7.8224
12431	MIN-MAX	PCA váhy	Aritmetický průměr v pilířích	Geometrický průměr pilířů	Bez outlierů	8.3750	7.8487
12111	MIN-MAX	PCA váhy	Aritmetický průměr		Bez outlierů	8.5461	8.7303
12112	MIN-MAX	PCA váhy	Aritmetický průměr		S outlieri	8.8224	8.1118
12432	MIN-MAX	PCA váhy	Aritmetický průměr v pilířích	Geometrický průměr pilířů	S outlieri	8.9803	7.5724
21111	Z-skóre	Stejně váhy	Aritmetický průměr		Bez outlierů	16.3224	14.0197
21112	Z-skóre	Stejně váhy	Aritmetický průměr		S outlieri	17.3750	14.5592
22111	Z-skóre	PCA váhy	Aritmetický průměr		Bez outlierů	17.7829	13.6513
21421	Z-skóre	Stejně váhy	Aritmetický průměr v pilířích	Aritmetický průměr pilířů	Bez outlierů	17.8355	17.7697
22112	Z-skóre	PCA váhy	Aritmetický průměr		S outlieri	18.6645	14.1513
21422	Z-skóre	Stejně váhy	Aritmetický průměr v pilířích	Aritmetický průměr pilířů	S outlieri	18.7171	18.3487

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

4.7.2 Posouzení robustnosti na základě přístupu k odlehlým pozorováním

V následující Tabulce 15 jsou seřazeny metody takovým způsobem, aby byly jasně porovnatelné míry robustnosti u očištěné datové matice vs. neočištěné datové matice od odlehlých pozorování. Pokud pohlížíme na tyto míry z pohledu ošetření odlehlých hodnot, pak vycházejí robustnější typy kompozitních indikátorů, kde byla datová matice očištěna od odlehlých hodnot pomocí techniky winsorizace. Z tohoto důvodu bude dále vyhodnocena robustnost pouze u typů KI s ošetřenými odlehlými hodnotami za použití normalizace Min-Max a z-skóre. Pro metody založené na pořadí není třeba odlehlá pozorování řešit, proto je u těchto metod použita neočištěná datová matice od odlehlých případů.


Tabulka 15 Výpočet měr robustnosti pro porovnání KI dle přístupu k odlehlým pozorováním (2012 a 2016)

Kód	Normalizace	Váhy	Agregace I	Agregace II	Odhlelá pozorování	Míra robustnosti	
						2016	2012
11111	MIN-MAX	Stejně váhy	Aritmetický průměr		Bez outlierů	3.7039	3.9803
11112	MIN-MAX	Stejně váhy	Aritmetický průměr		S outlierů	4.2961	4.9803
11311	MIN-MAX	Stejně váhy	Geometrický průměr (přičtení konstanty)		Bez outlierů	3.4408	3.7171
11312	MIN-MAX	Stejně váhy	Geometrický průměr (přičtení konstanty)		S outlierů	3.9145	4.4013
11421	MIN-MAX	Stejně váhy	Aritmetický průměr v pilířích	Aritmetický průměr pilířů	Bez outlierů	4.0987	5.0592
11422	MIN-MAX	Stejně váhy	Aritmetický průměr v pilířích	Aritmetický průměr pilířů	S outlierů	5.2961	5.9408
11431	MIN-MAX	Stejně váhy	Aritmetický průměr v pilířích	Geometrický průměr pilířů	Bez outlierů	3.9408	4.5592
11432	MIN-MAX	Stejně váhy	Aritmetický průměr v pilířích	Geometrický průměr pilířů	S outlierů	5.0461	5.1645
11621	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přičtení konstanty)	Aritmetický průměr pilířů	Bez outlierů	3.8618	4.9276
11622	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přičtení konstanty)	Aritmetický průměr pilířů	S outlierů	5.1513	5.2434
11631	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přičtení konstanty)	Geometrický průměr pilířů	Bez outlierů	3.8618	4.8355
11632	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přičtení konstanty)	Geometrický průměr pilířů	S outlierů	4.9539	5.1513
12111	MIN-MAX	PCA váhy	Aritmetický průměr		Bez outlierů	8.5461	8.7303
12112	MIN-MAX	PCA váhy	Aritmetický průměr		S outlierů	8.8224	8.1118
12311	MIN-MAX	PCA váhy	Geometrický průměr (přičtení konstanty)		Bez outlierů	7.8224	8.2961
12312	MIN-MAX	PCA váhy	Geometrický průměr (přičtení konstanty)		S outlierů	8.0987	7.6645
12431	MIN-MAX	PCA váhy	Aritmetický průměr v pilířích	Geometrický průměr pilířů	Bez outlierů	8.3750	7.8487
12432	MIN-MAX	PCA váhy	Aritmetický průměr v pilířích	Geometrický průměr pilířů	S outlierů	8.9803	7.5724
12621	MIN-MAX	PCA váhy	Geometrický průměr v pilířích (přičtení konstanty)	Aritmetický průměr pilířů	Bez outlierů	7.8092	8.4671
12622	MIN-MAX	PCA váhy	Geometrický průměr v pilířích (přičtení konstanty)	Aritmetický průměr pilířů	S outlierů	8.2829	7.8224
21111	Z-skóre	Stejně váhy	Aritmetický průměr		Bez outlierů	16.3224	14.0197
21112	Z-skóre	Stejně váhy	Aritmetický průměr		S outlierů	17.3750	14.5592
21421	Z-skóre	Stejně váhy	Aritmetický průměr v pilířích	Aritmetický průměr pilířů	Bez outlierů	17.8355	17.7697
21422	Z-skóre	Stejně váhy	Aritmetický průměr v pilířích	Aritmetický průměr pilířů	S outlierů	18.7171	18.3487
22111	Z-skóre	PCA váhy	Aritmetický průměr		Bez outlierů	17.7829	13.6513
22112	Z-skóre	PCA váhy	Aritmetický průměr		S outlierů	18.6645	14.1513
33712	Pořadí	Bez vah	Medián		S outlierů	7.2566	8.9671
33812	Pořadí	Bez vah	Součet		S outlierů	4.8092	4.7566

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

Avšak při zobrazení krabicového diagramu k porovnání typů kompozitního indikátoru pracující s datovou maticí s ošetřenými odlehlými hodnotami či s neočištěnou datovou maticí od odlehlých pozorování je zřetelné, že tato proměnná finální pořadí KI příliš neovlivňuje. Oba typy přípravy datové matice jsou v krabicovém diagramu Grafu 7 (Přílohy 15–16) rozmístěny více méně rovnoměrně. Pravděpodobně na výsledné pořadí KI mají větší vliv jiné metody jako metoda normalizace, stanovení vah či metoda použité agregace, nežli očištění datové matice.

Graf 7 Výběr okresů – Box-Plot pro pořadí KI jednotlivých okresů – porovnání dle přístupu k odlehlým pozorováním za rok 2016 (kompletní verze Příloha 16)



Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV


Dále byla vypočtena korelační matice pro jednotlivé pořadí okresů dle typu KI (korelační matice viz Příloha 17). Podle Spearmanova korelačního koeficientu byly vypočteny síly závislosti mezi výslednými pořadími jednotlivých typů kompozitních indikátorů, kde KI 21111, 21421 a 22111 vykazují nižší až středně silnou sílu vztahu s ostatními typy indikátorů. KI začínající číslem kódu 2 jsou založené na normalizaci pomocí z-skóre. Tyto typy KI byly již výše identifikovány jako extrémní či odlehlé hodnoty, ovšem to může být dáno nižším počtem zastoupení a tím, že je metoda založena na jiném principu než ostatní metody.

4.7.3 Posouzení robustnosti na základě metody normalizace

Pokud pohlížíme na výsledky z pohledu metod normalizace, pak se jeví jako nejvíce robustní metoda Min-Max, dále metoda pořadí jako nejméně robustní postup pomocí z-skóre.

Pro metodu Min-Max je nejvíce robustní již zmiňovaný typ KI (11311) v kombinaci se stejnými vahami, s jednostupňovou geometrickou agregací (přičtení konstanty), s ošetřenými odlehlými pozorováními pomocí metody winsorizace. V rámci metody normalizace pořadí, pak vychází více robustní metoda součtu (typ KI 33812) nežli mediánu (typ KI 33712) u obou let 2016 i 2012. U postupu z-skóre je nejvíce robustní typ KI (21111) za použití stejných vah, lineární agregace prvního stupně s ošetřenými odlehlými hodnotami.

Graf 8 Výběr okresů – Box-Plot pro pořadí KI jednotlivých okresů – porovnání metod normalizace za rok 2016 (kompletní verze Příloha 19)




Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

Box-Plot (Graf 8) výše prokazuje výsledky měř robustnosti (Příloha 18 pro rok 2012 a Příloha 19 pro rok 2016). Z grafu je patrné, že odlehlé případy pořadí pro jednotlivé okresy se především týkají metody standardizace z-skóre.

Otázkou zůstává, zda je vhodnější metoda Min-Max či metoda pořadí. Robustnější výsledky vykazují typy indikátorů, u kterých je použita metoda Min-Max. Následující Graf 9 znázorňuje postavení okresů dle zvolených metod normalizace a opět potvrzuje předchozí


závěry týkající se metody z-skóre, která dosahuje odlehlých pozorování, ovšem z grafu není jednoznačně zřetelné, zda je adekvátnější metoda Min-Max či metoda pořadí (viz Příloha 20 pro rok 2012 a Příloha 21 pro rok 2016). Pro větší přehlednost k porovnání byl také vytvořen graf mediánu metod normalizace (viz Graf 10, Přílohy 22–23).

Graf 9 Výběr okresů – výsledné pořadí KI jednotlivých okresů – porovnání metod normalizace za rok 2016 (kompletní verze Příloha 21)



Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

Graf 10 Výběr okresů – výsledné pořadí KI jednotlivých okresů – porovnání mediánu metod normalizace za rok 2016 (kompletní verze Příloha 23)



Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

4.7.4 Posouzení robustnosti na základě stanovených vah

Z pohledu jednotlivých metod vah se jeví nejvíce robustní pro skupinu metod bez vah typ KI (33812) za použití agregace součtu. Při zvolení metody stanovení PCA vah je nejrobustnější metoda pro rok 2016 KI (typ 12621) s normalizací Min-Max a dvoustupňovou agregací, přičemž při agregaci prvního stupně byl použit geometrický průměr (technika ošetření nulových hodnot přičtením konstanty) a v druhém stupni byla použita lineární agregace pilířů. U roku 2012 pak vychází nejrobustněji typ KI (12431) založený na podobném principu s tím rozdílem, že je nejdříve provedena lineární agregace a poté v druhém stupni geometrická agregace pilířů. Za použití stejných vah vychází nejrobustněji typ KI (11311) již zmíněný výše, který je nejrobustnější metodou celkově.


Tabulka 16 Výpočet měř robustnosti pro porovnání KI dle typu vah (2012 a 2016)

Kód	Normalizace	Váhy	Agregace I	Agregace II	Odlehlá pozorování	Míra robustnosti	
						2016	2012
11311	MIN-MAX	Stejně váhy	Geometrický průměr (přičtení konstanty)		Bez outlierů	3.4408	3.7171
11111	MIN-MAX	Stejně váhy	Aritmetický průměr		Bez outlierů	3.7039	3.9803
11621	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přičtení konstanty)	Aritmetický průměr pilířů	Bez outlierů	3.8618	4.9276
11631	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přičtení konstanty)	Geometrický průměr pilířů	Bez outlierů	3.8618	4.8355
11431	MIN-MAX	Stejně váhy	Aritmetický průměr v pilířích	Geometrický průměr pilířů	Bez outlierů	3.9408	4.5592
11421	MIN-MAX	Stejně váhy	Aritmetický průměr v pilířích	Aritmetický průměr pilířů	Bez outlierů	4.0987	5.0592
21111	Z-skóre	Stejně váhy	Aritmetický průměr		Bez outlierů	16.3224	14.0197
21421	Z-skóre	Stejně váhy	Aritmetický průměr v pilířích	Aritmetický průměr pilířů	Bez outlierů	17.8355	17.7697
33812	Pořadí	Bez vah	Součet		S outliery	4.8092	4.7566
33712	Pořadí	Bez vah	Medián		S outliery	7.2566	8.9671
12621	MIN-MAX	PCA váhy	Geometrický průměr v pilířích (přičtení konstanty)	Aritmetický průměr pilířů	Bez outlierů	7.8092	8.4671
12311	MIN-MAX	PCA váhy	Geometrický průměr (přičtení konstanty)		Bez outlierů	7.8224	8.2961
12431	MIN-MAX	PCA váhy	Aritmetický průměr v pilířích	Geometrický průměr pilířů	Bez outlierů	8.3750	7.8487
12111	MIN-MAX	PCA váhy	Aritmetický průměr		Bez outlierů	8.5461	8.7303
22111	Z-skóre	PCA váhy	Aritmetický průměr		Bez outlierů	17.7829	13.6513

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV


Z následujících grafů byly vyloučeny typy KI používající normalizaci z-skóre, protože tato metoda vykazuje příliš mnoho odlehlých pozorování a mohlo by tak dojít ke zkreslení výsledků porovnávání jednotlivých metod stanovení vah. Stejně jako u předchozích proměnných byl také vytvořen krabicový diagram k zobrazení odlehlých pozorování viz Přílohy 24–25. Z grafu je patrné, že odlehlá pozorování jsou především typy KI s vahami PCA či bez vah, což také odpovídá mírám robustnosti uvedeným výše (Tabulka 16), neboť stejné váhy vykazují větší robustnost oproti vahám PCA či bez vah (viz Přílohy 26–27). To mimo jiné dokládá rovněž graf pořadí mediánu jednotlivých metod vah (Grafy 11–12, Přílohy 28–29).

Graf 11 Výběr okresů – výsledné pořadí KI jednotlivých okresů – porovnání metod stanovení vah za rok 2016 (kompletní verze viz Příloha 27)



Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

Graf 12 Výběr okresů – výsledné pořadí KI jednotlivých okresů – porovnání mediánu metod stanovení vah za rok 2016 (kompletní verze Příloha 25)



Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

4.7.5 Posouzení robustnosti na základě metody agregace I a agregace II

Pokud se zvažuje dvoustupňová agregace či jednostupňová, pak nepatrně robustnější výsledky vykazuje jednostupňová agregace. Nejvíce robustní je pak v rámci jednostupňové agregace pro oba sledované roky KI (typ 11311) sestrojený za použití normalizace Min-Max, stejných vah a geometrického průměru (přičtení konstanty).

U dvoustupňové agregace vychází nejrobustněji KI pro rok 2016 (typ 11621), kde jsou hodnoty taktéž normalizovány pomocí metody Min-Max, dále váženy stejnými vahami, poté je provedena geometrická agregace v pilířích (technika ošetření nulových hodnot přičtením konstanty), odlehle hodnoty jsou ošetřeny pomocí postupu winsorizace. Ve druhém stupni agregace je pak použit aritmetický průměr pilířů. Pro rok 2012 vykazuje robustnost KI (11431), kde je použita normalizace Min-Max, stejné váhy, ovšem první stupeň agregace je vypočten pomocí aritmetického průměru v pilířích a v druhém stupni agregace pomocí geometrického průměru pilířů. Tato metoda má výhodu v tom, že není třeba řešit nulové hodnoty po normalizaci Min-Max pro geometrickou agregaci v prvním stupni a taktéž ji pro dvoustupňovou agregaci doporučuje Saisana (2011).

Tabulka 17 Výpočet měr robustnosti pro porovnání KI dle typu agregace (2012 a 2016)


Kód	Normalizace	Váhy	Agregace I	Agregace II	Odlehlá pozorování	Míra robustnosti	
						2016	2012
11621	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přičtení konstanty)	Aritmetický průměr pilířů	Bez outlierů	3.8618	4.9276
11631	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přičtení konstanty)	Geometrický průměr pilířů	Bez outlierů	3.8618	4.8355
11431	MIN-MAX	Stejně váhy	Aritmetický průměr v pilířích	Geometrický průměr pilířů	Bez outlierů	3.9408	4.5592
11421	MIN-MAX	Stejně váhy	Aritmetický průměr v pilířích	Aritmetický průměr pilířů	Bez outlierů	4.0987	5.0592
12621	MIN-MAX	PCA váhy	Geometrický průměr v pilířích (přičtení konstanty)	Aritmetický průměr pilířů	Bez outlierů	7.8092	8.4671
12431	MIN-MAX	PCA váhy	Aritmetický průměr v pilířích	Geometrický průměr pilířů	Bez outlierů	8.3750	7.8487
21421	Z-skóre	Stejně váhy	Aritmetický průměr v pilířích	Aritmetický průměr pilířů	Bez outlierů	17.8355	17.7697
11311	MIN-MAX	Stejně váhy	Geometrický průměr (přičtení konstanty)		Bez outlierů	3.4408	3.7171
11111	MIN-MAX	Stejně váhy	Aritmetický průměr		Bez outlierů	3.7039	3.9803
33812	Pořadí	Bez vah	Součet		S outlierů	4.8092	4.7566
33712	Pořadí	Bez vah	Medián		S outlierů	7.2566	8.9671
12311	MIN-MAX	PCA váhy	Geometrický průměr (přičtení konstanty)		Bez outlierů	7.8224	8.2961
12111	MIN-MAX	PCA váhy	Aritmetický průměr		Bez outlierů	8.5461	8.7303
21111	Z-skóre	Stejně váhy	Aritmetický průměr		Bez outlierů	16.3224	14.0197
22111	Z-skóre	PCA váhy	Aritmetický průměr		Bez outlierů	17.7829	13.6513

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

Pokud uvažujeme jednotlivé metody agregace prvního stupně, pak u lineární agregace vycházejí více robustní metody se stejnými vahami, normalizované hodnoty pomocí Min-Max s ošetřenými outlierů.

Nejvíce robustní metoda u lineární agregace je pak KI (typ 11111) za použití normalizace Min-Max, stejných vah s ošetřenými outliery. Z pohledu geometrické agregace vychází nejvíce robustní již výše zmiňovaná kombinace metod u typu KI (11311).


Graf 13 Výběr okresů – Box-Plot pro pořadí KI jednotlivých okresů – porovnání metod jednostupňové a dvoustupňové agregace za rok 2016 (kompletní verze Příloha 31)



Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

Dle měr robustnosti není jednoznačně zřejmé, zda jsou robustnější typy KI jednostupňové či dvoustupňové agregace, pokud se porovnávají typy KI založené na podobném principu. Na Box-Plotu výše (Graf 13) je zřejmé, že odlehlých pozorování z velké části dosahují typy KI s jednostupňovou agregací, a to je jednoznačně v roce 2016. Kompletní verze krabicového diagramu pro rok 2016 je uvedena v Příloze 31 a pro rok 2012 v Příloze 30. Toto potvrzuje též následující Graf 14 porovnání výsledného pořadí podle obou stupňů agregace, jenž je v kompletní verzi uveden v Příloze 32.

Graf 14 Výběr okresů – výsledné pořadí KI jednotlivých okresů – porovnání metod jednostupňové a dvoustupňové agregace za rok 2016 (kompletní verze Příloha 32)




Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

4.7.6 Posouzení robustnosti na základě metod agregace

Pokud jsou porovnávány jednotlivé metody agregace I, pak dle následujícího Grafu 15 (kompletní verze viz Příloha 33 pro rok 2012 a Příloha 34 pro rok 2016) nejméně robustní vychází metoda založená na pořadí používající k agregaci medián. Tento výsledek rovněž potvrzuje předchozí porovnávání metod pořadí. Mimo jiné méně robustní se z grafu zdají být také metody jednostupňové agregace, jak lineární, tak geometrické, což též dokládají předchozí výsledky.


Graf 15 Výběr okresů – výsledné pořadí KI jednotlivých okresů – porovnání metod agregace I za rok 2016 (kompletní verze Příloha 34)



Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

Pro větší přehlednost byl vytvořen Graf 16, který reprezentuje medián pořadí jednotlivých metod lineární, geometrické agregace a součtu pořadí (Příloha 35 pro rok 2012 a Příloha 36 pro rok 2016). Metoda součtu pořadí vycházela více robustním, než metoda mediánu pořadí. Tento graf potvrzuje matematickou teorii, že geometrický průměr je více robustní, tzn. bude při grafickém vyobrazení ležet v přímém středu hodnot, zatímco aritmetický průměr bude spíše „tažen“ směrem k vyšším hodnotám, a tudíž by ve skutečnosti nepředstavoval střed dat, což mimo jiné dokazuje také Roenfeldt ve své publikaci „Better than Average: Calculating Geometric Means Using SAS“ (2018). Jak Roenfeldt (2018) uvádí, geometrické průměry představují to nejlepší jak z mediánu, tak z aritmetického průměru a poskytují odhady, které berou v úvahu všechna pozorování datového souboru, aniž by byla ovlivněna extrémny. Matematicky, geometrický průměr dodává průměru hloubku a stabilitu.

Graf 16 Výběr okresů – výsledné pořadí KI jednotlivých okresů – porovnání mediánu metod lineární, geometrická agregace a součet pořadí za rok 2016 (kompletní verze Příloha 36)



Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

4.8 Back to details

Korelace k mediánu pořadí za jednotlivé typy kompozitních indikátorů byly vypočteny na základě Spearmanova korelačního koeficientu viz Tabulka 18. Výsledky odpovídají více méně předchozím výsledkům uvedeným výše. Medián pořadí okresů spočtený napříč všemi metodami nejvíce koreluje s metodou typ KI 11311.

Tabulka 18 Spearmanův korelační koeficient pro jednotlivé typy KI a medián pořadí

Spearmanův korelační koeficient	
	Medián pořadí
K_11311	0.9746
K_11111	0.9692
K_11621	0.9672
K_11631	0.9671
K_11431	0.9625
K_11421	0.9621
K_33812	0.9555
K_11211	0.9371
K_11521	0.9104
K_11531	0.9089
K_33712	0.8928
K_12211	0.8823
K_12521	0.8738
K_12621	0.8580
K_12311	0.8576
K_12111	0.8327
K_12431	0.8257
K_21111	0.4904
K_22111	0.4654
K_21421	0.4330

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

4.8.1 Výhody a nevýhody zvolených metod

Podle výše uvedených výsledků v sedmém kroku 4.7 (Analýza k posouzení robustnosti a citlivosti) se zdají být nejvíce robustní metody používající metodu normalizace Min-Max, za použití stejných vah, s ošetřenými odlehlými hodnotami a nulovými hodnotami pomocí přičtení konstanty. Nicméně vyhodnocení u metod normalizace, stanovení vah a agregace může být ovlivněno nižším počtem typů indikátorů v určité kategorii, například u normalizace nižší počet metod používající z-skóre či metody založené na pořadí. Dále u typu stanovení vah tvoří menší počet druhy indikátorů za použití PCA vah či bez vah. Z tohoto důvodu je třeba zvážit a posoudit výhody a nevýhody jednotlivých technik ošetření odlehlých pozorování, metod normalizace, agregace, stanovení vah a ošetření nulových hodnot při geometrické agregaci.

Metody normalizace

Metoda součtu založená na pořadí má podle Saisana a Tarantoly (2002) velkou výhodu, a to že je založena na ordinálních úrovních. Její předností je jednoduchost a nezávislost na odlehlých hodnotách. Nevýhodou této metody je, že ztrácí absolutní úroveň informace. U metod Min-Max a z-skóre mohou dle Nardo a kol. OECD (2008) extrémní nebo odlehlé případy zkreslit finální kompozitní indikátor. Normalizace Min-Max má vyšší vliv na KI nežli metoda standardizace. Metoda standardizace z-skóre má nevýhodu v tom, že se počítá pomocí průměru, takže není nejvhodnější, pokud mají data velké zešíkmení dat (Paruolo a kol., 2013). Mimo jiné záleží na tom, zda chceme docílit stejného rozptylu, pak je vhodná metoda z-skóre či stejného rozpětí [0,1] jako je tomu u metody Min-Max (Del Sorbo JRC, 2018). Dalším rozhodovacím kritériem může být použití metody agregace, neboť pro data standardizovaná pomocí z-skóre lze použít pouze lineární agregaci vzhledem k výskytu záporných hodnot. Naopak při použití metody Min-Max může nastat problém pro geometrickou agregaci, neboť se v datové matici vyskytují nulové hodnoty, které byly v této práci řešeny různými technikami transformace. V následující tabulce je zpracován souhrn metod normalizace pro jednodušší orientaci.

Tabulka 19 Souhrn metod normalizace

		Metoda normalizace		
		Pořadí	Standardizace (z-skóre)	Min-Max
Úprava měrných jednotek		✓	✓	✓
Úprava rozptylu		✓	✓	✗
Úprava variačního rozpětí		✓	✗	✓
Necitlivá na extrémní/odlehlá pozorování		✓	✗	✗
Použití vah		✗	✓	✓
Agregace I - metody založené na pořadí	Medián, součet/průměr	✓	✓	✓
	Lineární agregace	✗	✓	✓
Agregace I - metody založené na skóre		✗	✗	✓*

* možné po úpravě škály či nahrazení nulových hodnot

Zdroj: vlastní zpracování, Del Sorbo JRC (2018)

Metody stanovení vah

Metoda stejných vah má velkou výhodu v jednoduchosti výpočtu. Hudrlíková (2014) doporučuje tak tuto metodu v případě, kdy je k dispozici velké množství ukazatelů a není jasná představa, která metoda by měla být použita.

Jak uvádí Nardo a kol. OECD (2005), metoda PCA pro určení vah disponuje výhodou, že může shrnout soubor dílčích ukazatelů při zachování maxima celkového rozptylu původních dat. Největší zátěž faktorů je přiřazena dílčím ukazatelům, které mají největší rozdíly například mezi jednotlivými zeměmi/regiony, což je žádoucí vlastnost pro srovnávání zemí/regionů. Dílčí ukazatele, které jsou podobné ve všech regionech nemohou vysvětlit rozdíly ve výkonnosti. Naopak korelace nemusí nutně představovat skutečný vliv dílčích ukazatelů na měřený jev, což je nevýhodou metody. Další nevýhodou je pak citlivost na změny základních dat: revize a aktualizace dat (např. přidání nových regionů do vstupní matice). Dále pak citlivost na přítomnost odlehlých hodnot a problém, pokud je ve vstupní matici málo regionů, například v případě, kdy je třeba se zaměřit na menší okruh regionů.

Z výše uvedených výsledků v předcházejících krocích a zvážených veškerých výhod a nevýhod jednotlivých metod vycházejí jako nejvhodnější následující metody.

Tabulka 20 Vybrané typy KI jako nejvhodnější (2012 a 2016)

Kód KI	Normalizace	Váhy	Agregace I	Agregace II	Odehlá pozorování	Míra robustnosti	
						2016	2012
11311	MIN-MAX	Stejně váhy	Geometrický průměr (přičtení konstanty)		Bez outlierů	3.4408	3.7171
11631	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přičtení konstanty)	Geometrický průměr pilířů	Bez outlierů	3.8618	4.8355
11621	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přičtení konstanty)	Aritmetický průměr pilířů	Bez outlierů	3.8618	4.9276
11431	MIN-MAX	Stejně váhy	Aritmetický průměr v pilířích	Geometrický průměr pilířů	Bez outlierů	3.9408	4.5592
33812	Pořadí	Bez vah	Součet		S outliers	4.8092	4.7566

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

Jedná se tedy o dva typy kombinací metod jednostupňové a o tři typy metod dvoustupňové agregace, založené na metodě Min-Max, použití stejných vah a s ošetřenými odlehlými hodnotami, popř. metoda pořadí za použití agregace součtem bez očištění vstupní matice od odlehlých pozorování. Pokud se zaměříme přímo na pořadí dvoustupňových metod 11631 a 11621, vycházejí téměř totožně.

4.9 Vztah s ostatními proměnnými

U vybraných metod byl sestaven vícenásobný lineární regresní model pro zjištění vztahu mezi původními proměnnými a vypočteným kompozitním indikátorem. Za účelem výběru jednoho adekvátního scénáře KI s nejvhodnější kombinací metod (metod agregace, stanovení vah atd.), neboť dosavadní výsledky poukazují na několik vhodných typů KI.

Závisle proměnnou zde představuje vždy finální vypočtený kompozitní indikátor a vysvětlující proměnné tvoří původní proměnné vstupující do indikátoru. Dle koeficientu determinace je zřejmé, že nejvíce variability původních proměnných vysvětluje regresní model, kde je stanoven jako závisle proměnná typ KI 11431, tento typ doporučuje ve své publikaci rovněž Saisana (2011), neboť jeho výhodou je, že není třeba řešit nulové hodnoty v datové matici jako u geometrické agregace. Ovšem všechny vybrané typy KI vysvětlují více jak 90 % variability původních průměrných a všechny vytvořené regresní modely jsou statisticky významné.

Tabulka 21 Výše koeficientu determinace v regresní analýze u nejhodnějších typů KI (2012 a 2016)

Kód KI	Normalizace	Váhy	Agregace I	Agregace II	Odlehlá pozorování	Koeficient determinace	
						2016	2012
33812	Pořadí	Bez vah	Součet		S outliery	94,1 %	94,3 %
11631	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přičtení konstanty)	Geometrický průměr pilířů	Bez outliery	99,0 %	99,0 %
11621	MIN-MAX	Stejně váhy	Geometrický průměr v pilířích (přičtení konstanty)	Aritmetický průměr pilířů	Bez outliery	99,0 %	99,0 %
11311	MIN-MAX	Stejně váhy	Geometrický průměr (přičtení konstanty)		Bez outliery	99,2 %	98,9 %
11431	MIN-MAX	Stejně váhy	Aritmetický průměr v pilířích	Geometrický průměr pilířů	Bez outliery	99,9 %	99,4 %

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

Tabulka 22 Regresní koeficienty regresního modelu KI 11431 (2016)

Regresní koeficienty			
	Coefficients		Sig.
	B	Std. Error	
(Constant)	0,0345	0,007	0,000
H Počet registrovaných jednotek	0,0002	0,000	0,000
H Daňové příjmy v tis. Kč	0,0000	0,000	0,000
H Uchazezí na místo	0,0032	0,000	0,000
H Velké podniky	0,1439	0,004	0,000
S Index vzdělanosti	0,0316	0,002	0,000
S Přirozený přírůstek	0,0034	0,000	0,000
S Lékaři	0,0643	0,003	0,000
S ZS	0,1183	0,005	0,000
S Domovy	0,2392	0,007	0,000
S Počet dokončených bytů	0,0042	0,000	0,000
S Kanalizace	0,0081	0,000	0,000
S Hustota silniční sítě	0,0003	0,000	0,000
S Sňatky rozvody	0,0083	0,000	0,000
S Migrační saldo	0,0010	0,000	0,000
H Nezamestnaní	-0,0039	0,000	0,000
H Dávky	0,0000	0,000	0,000
H Cizí zdroje	0,0000	0,000	0,000
S Index stáří	-0,0003	0,000	0,000
S Ekonomická zátěž	-0,0016	0,000	0,000
S Neobydlené byty v procentech	-0,0007	0,000	0,000

a. Dependent Variable: @11431

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

U typu regresního modelu 11431 jsou všechny regresní koeficienty signifikantní a dosahují logického směru viz Tabulka 22. Model 11431 byl zvolen jako nejvhodnější metoda konstrukce kompozitního indikátoru k identifikaci hospodářsky slabých okresů, podle které lze stanovit disparity mezi regiony. Přesný postup zvoleného KI je podrobně popsán v kapitole 4.11 (Obrázek 8).

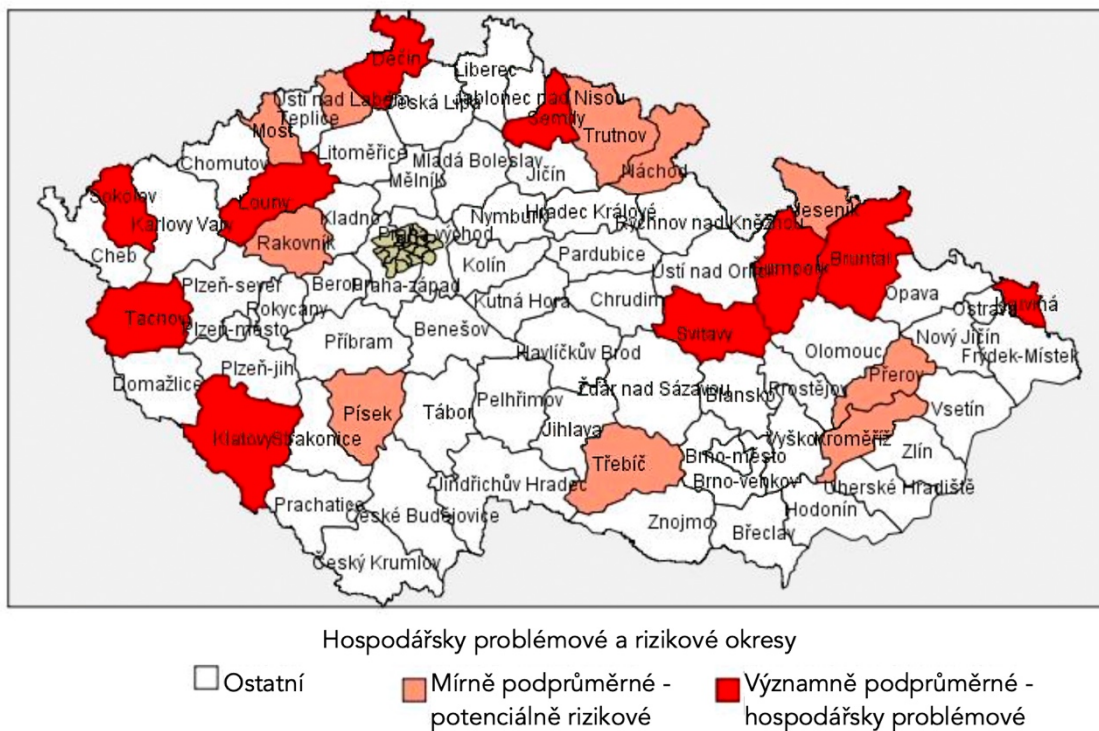
4.10 Prezentace a vizualizace výsledků

Na základě výše zvoleného typu kompozitního indikátoru (kód 11431) byly vytvořeny kartogramy (Obrázek 6 a 7) se zvýrazněnými oblastmi, které spadají do hospodářsky problémové oblasti či jsou detekovány jako rizikové, a to jak pro rok 2012, tak pro rok 2016 k jejich porovnání. SRR 2014–2020 a SRR 2021+ doporučuje hranici 25 % kumulativního součtu obyvatelstva v ORP, pod kterou spadají problémové regiony. Dle teoretické části

práce je ve SRR 2014–2020 vymezeno 27,80 % regionů na úrovni ORP jako hospodářsky problémových a ve SRR 2021 17,30 % ORP v kategorii hospodářsky a sociálně ohrožených území. Z tohoto důvodu byla zvolena hranice 20 regionů, z toho 10 regionů charakterizovaných jako hospodářsky problémové a 10 regionů jako rizikové, tzn. 26,70 % všech regionů a zhruba 20 % obyvatel okresů ČR pro rok 2016.

De facto v závěru uvažované metody jako nejvíce robustní 11431, 11311, 11621, 11631 a 33812 detekují na základě výsledků pořadí v roce 2016 až na malé nuance téměř stejnou skupinu hospodářsky problémových okresů, a to *Děčín, Bruntál, Šumperk, Tachov, Svitavy, Trutnov, Klatovy, Most, Karviná a Rokycany*. Menší nuance se nacházejí u okresů Rokycany a Rakovník, které jsou na pomezí hospodářsky problémových a rizikových regionů u jednotlivých typů KI. Pouze metoda 11311 se liší tím, že detekuje jako hospodářsky problémový region Jeseník namísto Svitav, které jsou uvažovány jako rizikové. Velice dobře posloužila také metoda součtu 33812, která se liší u regionu Hodonín, jenž je ve skupině hospodářsky problémových regionů, zatímco Rakovník je jako rizikový region. Stejně tak velice podobně napříč typy KI vychází rizikové skupiny regionů pro rok 2016: *Rakovník Náchod, Jeseník, Prostějov, Semily, Louny Kroměříž, Hodonín, Teplice a Jindřichův Hradec*. Nepatrné rozdíly mezi jednotlivými metodami jsou pouze u regionu Prostějov, Rychnov nad Kněžnou a Jindřichův Hradec, které se pohybují na pomezí rizikové skupiny.

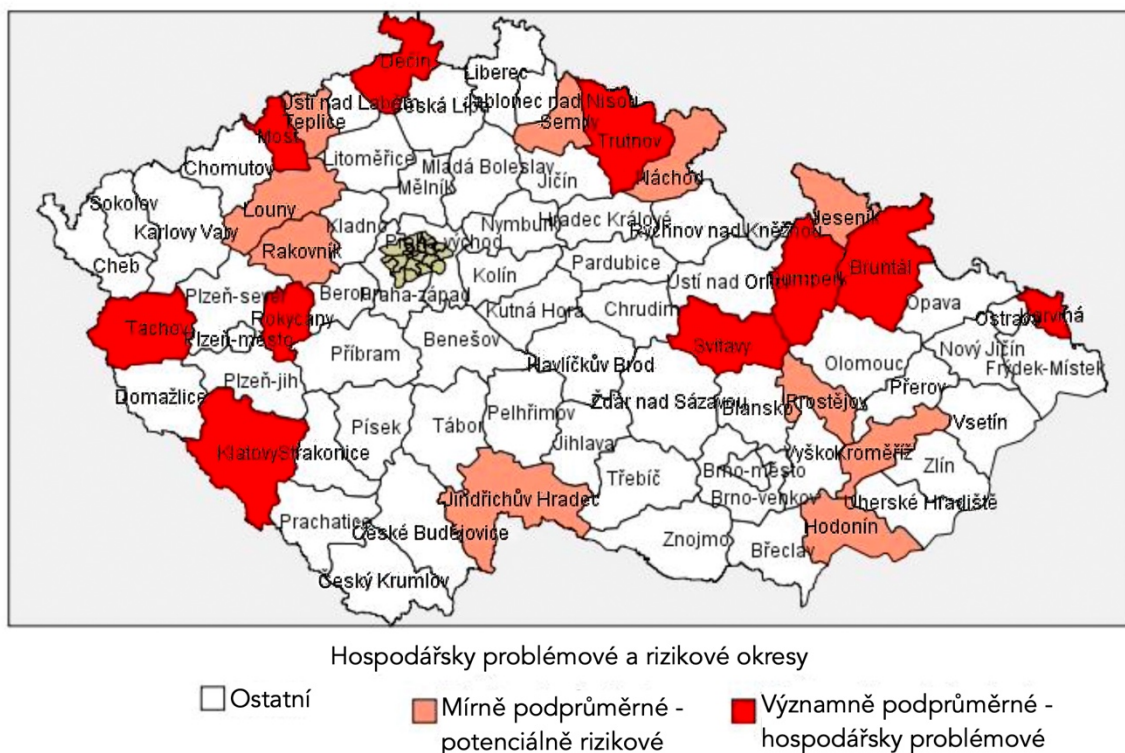
Obrázek 6 Hospodářsky problémové a rizikové okresy dle KI 11431 pro rok 2012



Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

Ve finální detekci hospodářsky problémových oblastí a rizikových regionů není pozorován mezi lety 2012 a 2016 příliš velký posun. Do roku 2016 tak od roku 2012 přibyl pouze okres Most, Rokycany a Trutnov do hospodářsky problémových oblastí, z nichž většina spadala do rizikových oblastí již v roce 2012.

Obrázek 7 Hospodářsky problémové a rizikové okresy dle KI 11431 pro rok 2016



Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

Jak vyplývá z údajů Ministerstva pro místní rozvoj (2013b), mnohé regiony České republiky mají ekonomické problémy především v příhraniční oblasti (viz Obrázek 1). Stejnou informaci dokládá také Obrázek 3, který vychází z metodiky SSR 2021 (MMR, 2021). To víceméně také potvrzuje vizualizace výsledků KI výše v kartogramech (Obrázky 6 a 7). Na druhé straně sociálně vyloučené oblasti jsou rozprostřeny po celém území České republiky, a nejen v oblasti příhraničních regionů (viz Obrázek 2) (MMR, 2013b). Podle SSR 2021 jsou hospodářsky a sociálně ohrožené oblasti jednou uvažovanou kategorií (MMR, 2021).

4.11 Návrh metodologického aparátu konstrukce kompozitního indikátoru k identifikaci hospodářsky problémových regionů ČR

Hospodářsky problémové regiony by bylo vhodné sledovat kontinuálně jednotnou metodikou na základě kompozitního indikátoru, aby bylo možné monitorovat a porovnávat disparity mezi regiony a vyhodnocovat změny mezi nimi v letech. Bez kontinuity metody nebude možné provádět mezičasové komparace. Pro lepší porozumění je postup konstrukce zvoleného kompozitního indikátoru 11431 přehledně popsán v následujícím schématu (viz Obrázek 8). Toto schéma vychází z empirické části disertační práce a jeho aplikovatelnost byla ověřena v případové studii na datovém souboru let 2012 a 2016. Metodika zahrnuje celkem deset kroků, ve kterých byla zvolena vždy jedna metoda jako nejvhodnější, ať už metoda práce s odlehlými hodnotami, normalizace, určování vah, či agregace. Volba každé z těchto metod ovlivňuje finální výsledek KI.

Metoda 11431 pracuje s datovou maticí očištěnou od odlehlých pozorování, používá normalizaci pomocí metody Min-Max, stejné váhy, lineární agregaci v pilířích (hospodářský a sociální) a geometrickou agregaci pilířů. Tato metoda disponuje výhodou v jednoduchosti výběru proměnných. Také lineární agregace v prvním stupni usnadňuje výpočet, a není tak třeba řešit problém transformace nulových hodnot, jako je tomu u geometrické transformace.

Jako alternativa k tomuto řešení taktéž poslouží metoda KI 33812 (odlehlá pozorování v datové matici, normalizace metodou pořadí, bez vah, agregace součtem), která disponuje velkou předností v jednoduchosti konstrukce. Tato metoda dosahuje téměř srovnatelných výsledků s drobnými rozdíly ve finálním pořadí KI v porovnání s KI 11431.

Obrázek 8 Návrh metodologického aparátu konstrukce kompozitního indikátoru k identifikaci hospodářsky problémových regionů ČR (KI 11431)

1. Sestavení teoretického rámce	• Viz kapitola 4.1 (viz Příloha 1)
2. Výběr jednotlivých indikátorů	• Viz Příloha 1 a kapitola 4.2
3. Nahrazení chybějících hodnot a detekce odlehlých pozorování	• Ošetření odlehlých pozorování: metoda winsorizace
4. Normalizace dat	• Metoda Min-Max
5. Vícerozměrná analýza	• Viz kapitola 4.5
DÍLČÍ CÍL: NALEZENÍ NEJVHODNĚJŠÍ SADY PROMĚNNÝCH	<ul style="list-style-type: none"> • Za hospodářskou oblast: <i>Podíl nezaměstnaných osob, Dávky v hmotné nouzi, Dosažitelní uchazeči na pracovní místo, Daňové příjmy, Velké podniky, Cizí zdroje, Počet registrovaných jednotek.</i> • Za sociální oblast: <i>Domovy pro seniory, Technická infrastruktura kanalizace, Hustota silniční sítě, Počet dokončených bytů, Hrubá míra migračního salda, Hrubá míra přirozeného přírůstku, Index vzdělanosti, Index ekonomické zátěže, Základní školy, Podíl neobydlených bytů, Počet lékařů, Index stáří, Sňatky a rozvody.</i>
6. Stanovení vah a agregace	<ul style="list-style-type: none"> • S vahami – stejné váhy, • Normalizace metoda Min-Max – lineární agregace v pilířích, • S pilíři (hospodářský a sociální), geometrická agregace pilířů
7. Analýza k posouzení robustnosti a citlivosti	• viz kapitola 4.7
8. Back to details	<ul style="list-style-type: none"> • Korelace k mediánu pořadí za jednotlivé typy KI • Výhody a nevýhody: • Stejně váhy: jednoduchost výpočtu, při velkém množství ukazatelů a pokud není jasná představa, která metoda by měla být použita, více viz kapitola 4.8, • Normalizace Min-Max: úprava měrných jednotek, úprava variačního rozpětí, možnost použití vah a všech typů agregace (v pilířích i bez pilířů), citlivá na odlehlá pozorování viz Tabulka 19, • Není třeba transformovat nulové hodnoty v datové matici pro geometrickou agregaci, • Jednoduchost výběru proměnných, není nutný výběr pomocí PCA.
9. Vztah s ostatními proměnnými	• Viz kapitola 4.9
10. Prezentace a vizualizace výsledků	• Viz kapitola 4.10
HLAVNÍ CÍL: NÁVRH METODOLOGICKÉHO APARÁTU K IDENTIFIKACI HOSPODÁŘSKY PROBLÉMOVÝCH OKRESŮ POMOCÍ KI	• Finální kompozitní indikátor 11431, více viz kapitola 5 (popřípadě KI 33812 – výhoda jednoduchého výpočtu)

Zdroj: vlastní zpracování

5. Výsledky a diskuse

Při konstrukci kompozitního indikátoru dochází hned v několika fázích k rozhodování o typu metody a její volba může zásadně ovlivnit finální výsledek KI. Nejdříve je třeba provést sestavení teoretického rámce a pečlivý výběr jednotlivých indikátorů. Strategie regionálního rozvoje 2014–2020 používá některé ukazatele nedostupné na úrovni LAU 1. Především HDP by mohl být velice zkreslený. Strategie regionálního rozvoje 2021+ zahrnuje proměnnou Hrubá míra celkového přírůstku. Ovšem ČSÚ monitoruje tento ukazatel od roku 2019. Pokud jsou data k dispozici v časové řadě, pak je vhodnější pracovat s průměrem za toto období nežli s údajem za jeden rok, tak jak jej používá SRR 2021+ (průměr za období 2013–2017). Z tohoto důvodu by bylo vhodné sledovat vybranou sadu proměnných (Obrázek 8) každoročně na regionální úrovni, za kterou kraje, okresy a ORP monitorují hospodářsky problémové regiony.

Metodika *Handbook on Constructing Composite Indicators: Methodology and User Guide*, Brussels: OECD (2008) doporučuje nejdříve krok vícerozměrné analýzy a poté provedení normalizace dat. Avšak autorka práce doporučuje nejdříve normalizovat data ve čtvrtém kroku a následně přistoupit k vícerozměrné analýze. V rámci posouzení měr robustnosti vycházejí nejvíce robustní metody používající metodu normalizace Min-Max, za použití stejných vah, s ošetřenými odlehlými hodnotami a nulovými hodnotami pomocí přičtení konstanty. Při metodě normalizace pomocí Min-Max dochází k problému, pokud je třeba provést geometrickou agregaci, neboť se v matici nachází nulové hodnoty. Saisana a Philippas (2012-b) doporučují transformaci matice na škálu 1–10, protože by proměnné blízké nule dosahovaly téměř nulového celkového skóre. Roenfeldt (2018) upřednostňuje převedení nulové hodnoty na velmi nízké číslo. Saisana a kol. (2017) navrhují pro sestavení kompozitního indikátoru (COIN Tool) nahrazení nulové hodnoty hodnotou 0,1. Hudrlíková (2014) substituuje hodnotou 0,0001. Roenfeldt (2018) upravuje měřítko tak, aby byla ke každé hodnotě přičtena 1, a následně hodnotu 1 odečítá z výsledné geometrické agregace. Existuje řada řešení tohoto problému, tři z nich byly vypočteny a následně vyhodnoceny v disertační práci. Jako naprosto nevhodné řešení bylo shledáno převedení nulové hodnoty na velmi nízké číslo, které doporučují autoři Saisana a kol. (2017) či Hudrlíková (2014). Při použití tohoto postupu došlo k markantním rozdílům ve finálním pořadí okresů oproti zbylým postupům ošetření nulových hodnot. Coby vhodnější byly tedy vyhodnoceny

dle publikace Saisana a Philippase (2012-b) transformace dat na škálu 1–10 či přičtení konstanty (číslo jedna) podle Roenfeldt (2018). Po analýze robustnosti ve vlastní části práce byla zvolena za nejvhodnější metoda přičtení konstanty.

Metody vážení v rámci konstrukce KI jsou již léta diskutovány, každá z nich má své výhody a nevýhody. Podle OECD (2008) neexistuje jakási „univerzální“ metoda vážení, ale je třeba zvolit přístup vážení ve vzájemné souvztažnosti s tím, za jakým účelem je KI sestaven a co je jím sledováno, jak je definováno v teoretickém rámci. Váhy za použití metody PCA využil Ram (1982) u indikátoru kvality života či Noorbakhsh (1996) v indexu lidského rozvoje. Dále jich využívají Saisana a Tarantola (2002) pro Internal Market Index, Science and Technology Indicator a Business Climate Indicator (Greco, 2019). Autorka si dovoluje nesouhlasit s tvrzením Nardo a kol. OECD (2005), že stejné váhy fungují dobře, pokud jsou všechny pilíře (hospodářský, sociální) zastoupeny stejným počtem dílčích indikátorů, neboť by docházelo ke stejným výsledkům jako za použití stejných vah bez pilířů. Naopak autorka této práce doporučuje jiný počet dílčích indikátorů zastoupených v pilířích.

Výsledky mimo jiné potvrdily matematickou teorii dle Roenfeldt (2018), že geometrický průměr je více robustní, tzn. bude při grafickém vyobrazení ležet v přímém středu hodnot, zatímco aritmetický průměr bude „tažen“ směrem k vyšším hodnotám. Stejně jako u metod vážení dokonalý postup agregace rovněž neexistuje a záleží na účelu konstrukce KI a stanoveném teoretickém rámci (Arrow a Raynaud 1986; Greco, 2019). Také autoři indexu lidského rozvoje HDI byli často kritizováni za použití lineární agregace a v roce 2010 jej změnili na geometrickou (Greco, 2019). Odborníci doporučují u dvoustupňové agregace v pilířích lineární agregaci a pro agregaci pilířů geometrickou agregaci jako Saisana (2011), toto doporučení potvrdil také výsledek disertační práce (KI 11431). Stejného postupu agregace využívají také Tarantola a Vertesy (2012) ve studii Indicators of Research Excellence, mimo jiné také používají metodu normalizace Min-Max a stejných vah s ohledem na pilíře.

Při posouzení robustnosti kompozitní indikátor fragmentace krajiny (CILF) používají De Montis a kol. (2020) a De Montis a kol. (2021) k jejímu vyhodnocení výpočtu průměrného posunu a jejich porovnání pořadí po párech. Mimo jiné provádí normalizaci podle metody Min-Max a geometrickou agregaci. Pro měření regionálního rozvoje na úrovni

LAU 1 aplikuje Hudrlíková (2014) k výpočtu průměrného posunu v hodnocení KI referenční hodnotu stanovenou pomocí průměru pořadí za daný region. Autorka disertační práce doporučuje ve výpočtu míry robustnosti jako referenční hodnotu medián, který není ovlivněn extrémními hodnotami, jako je tomu u průměru.

Hospodářsky problémové regiony v ČR nejsou homogenní. Existují zde mimo sociální a hospodářskou oblast též různé přírodní a historické podmínky. Okresy s nejlepšími výsledky v porovnání s ostatními jsou především v okolí hlavního města Prahy a velká města jako České Budějovice, Brno, Plzeň apod. Spadají do nich také okresy s významnými veřejnými univerzitami (MŠMT, 2015). Tyto regionální univerzity zvyšují úroveň vzdělání a mohou zlepšit situaci na trhu práce. Některé z hospodářsky problémových regionů se nachází na hranicích s Polskem, kam není příliš atraktivní dojíždět do zaměstnání, takže závisí na svém vlastním zlepšení. V letech 2000–2012 byla míra zaměstnanosti v ČR vyšší než v Polsku, zatímco ekonomická situace v příhraničí byla podprůměrná u obou zemí (Gajdová, 2015). Řada místních firem byla zavřena, ale je zde potenciál k restrukturalizaci a založení nových podniků. V okresech sousedících s Polskem spadajících do hospodářsky problémových či rizikových okresů je několik středně velkých měst, ovšem bez veřejných univerzit. Okresy Liberec a Jablonec nad Nisou se také nachází u hranic s Polskem a jsou horské, ale tento fakt je částečně kompenzován intenzivním turistickým ruchem. V Liberci je také mimo jiné jedna z veřejných univerzit. Jsou zde též odlehle oblasti jako Šumperk, Bruntál a Jeseník se špatným dopravním spojením. Tato skupina okresů je v oblasti pracovního trhu podprůměrná a dojíždění do zahraničí je někdy jediným řešením pro mnoho obyvatel, zejména pro ty kvalifikované. Vysoká míra nezaměstnanosti způsobuje odchod obyvatel z těchto oblastí a nízkou cenu nemovitostí. Část skupiny okresů, kde jsou dlouho přetrvávající ekonomické a sociální problémy, se nachází na území bývalé železné opony a přeshraniční spolupráce tu započala teprve nedávno. Přeshraniční spolupráce u regionů sousedících s Německem a Rakouskem je velice důležitá. Výjezdu do zaměstnání do zahraničí hojně využívají obyvatelé těchto regionů. Jsou zde ale také pracovní příležitosti v oblasti cestovního ruchu. Není zde žádná veřejná univerzita. Celkově je v příhraničních regionech vzdělanost obyvatel spíše podprůměrná. V roce 2016 se žádný z problémových či rizikových okresů nenachází na hranici se Slovenskem. Zde je nejsilnější přeshraniční spolupráce, protože tyto hranice před rokem 1993 neexistovaly. (Svobodová a kol., 2018, KOMISE EVROPSKÝCH SPOLEČENSTVÍ, 2008)

Pro detekci hospodářsky problémových regionů jsou zahrnuty pouze hospodářské a sociální indikátory. Nicméně pokud na regiony pohlížíme z pohledu zemědělství, též se problémové regiony nacházejí spíše u hranic se sousedními zeměmi a výsledky spolu svým způsobem souhlasí a poukazují na fakt, že jsou spolu jednotlivé oblasti úzce provázány. Na základě výpočtu problémovosti regionů v oblasti zemědělství spadají do problémových regionů: Břeclav, České Budějovice, Český Krumlov, Děčín, Frýdek-Místek, Jablonec nad Nisou, Klatovy, Liberec, Náchod, Prachatice, Semily, Trutnov a Ústí nad Labem. Dále jsou detekovány jako podprůměrné: Bruntál, Česká Lípa, Cheb, Chomutov, Jeseník, Karlovy Vary, Most, Karviná, Sokolov, Tachov, Teplice, Hodonín, Jindřichův Hradec, Uherské Hradiště, Ústí nad Orlicí a Znojmo.

6. Závěr

Hlavním cílem disertační práce bylo vytvoření návrhu metodologického aparátu k identifikaci hospodářsky problémových okresů ČR pomocí kompozitního indikátoru, dle něhož lze stanovit nerovnosti mezi regiony v oblasti hospodářské a sociální. Tento cíl byl v rámci vlastní části disertační práce naplněn. Dílčím cílem pak bylo nalezení nejvhodnější sady proměnných a komparace jednotlivých kombinací postupů ošetření odlehlých pozorování, metod normalizace, určování vah, agregace a technik řešení nulových hodnot pro geometrickou agregaci prezentované na datové matici sestavené z ukazatelů pro stanovení hospodářsky problémových okresů (LAU 1) ČR. Výše zmíněné metody spolu úzce souvisí a ovlivňují finální KI. Celkem bylo vytvořeno čtyřicet osm typů kompozitních indikátorů za použití kombinace metod, jejichž výsledky byly vyhodnocovány a porovnávány v rámci vlastní části práce. Na závěr byl zvolen jeden typ kompozitního indikátoru jako adekvátní návrh metodologického aparátu pro identifikaci hospodářsky problémových regionů. Navíc byla doporučena jedna alternativa k výslednému KI, která má velkou přednost v jednoduchosti konstrukce. Mimo jiné bylo dílčím cílem zpracování závěrů, které vyplynuly z propočtů ve vlastní části práce. Tyto cíle byly naplněny v rámci empirické části disertační práce.

Dle MMR (2021) je jedním z cílů podpory regionálního rozvoje navyšování konkurenceschopnosti v regionech. Odhalení hospodářsky slabých regionů mimo jiné udává zákon o podpoře regionálního rozvoje SRR, který vytyčuje podmínky pro detekci podporovaných regionů, a zjištěním vhodné soustavy indikátorů je tento požadavek splněn. Toto jsou důvody identifikace těchto problémových regionů a k sestavení vhodného kompozitního indikátoru.

Ve vlastní části práce bylo v první řadě třeba zvolit proměnné pro konstrukci finálního pořadí okresů na základě KI. Ukazatel HDP je základním měřítkem národních účtů, HDP ovšem na úrovni LAU 1 není směrodatným faktorem a autorka práce jej sledává nevhodným na této úrovni. Na základě korelací, relativní variability a logického úsudku bylo vybráno celkem dvacet proměnných za hospodářskou a sociální oblast. Za hospodářskou oblast *Podíl nezaměstnaných osob, Dávky v hmotné nouzi, Dosažitelní uchazeči na pracovní místo, Daňové příjmy, Velké podniky, Cizí zdroje, Počet registrovaných jednotek*. Za sociální oblast

Domovy pro seniory, Technická infrastruktura kanalizace, Hustota silniční sítě, Počet dokončených bytů, Hrubá míra migračního salda, Hrubá míra přirozeného přírůstku, Index vzdělanosti, Index ekonomické zátěže, Základní školy, Podíl neobydlených bytů, Počet lékařů, Index stáří, Sňatky a rozvody. Výsledky z vlastní části disertační práce mimo jiné potvrdila také PCA analýza při stanovení jednotlivých vah. Za použití PCA byl výběr proměnných zúžen na třináct, a to na *Počet registrovaných jednotek, Velké podniky, Index vzdělanosti, Základní školy, Domovy pro seniory, Počet dokončených bytů, Technická infrastruktura – kanalizace, Hustota silniční sítě, Hrubá míra migračního salda, Podíl nezaměstnaných osob, Cizí zdroje, Index ekonomické zátěže, Podíl neobydlených bytů.* Zúžení výběru proměnných může být velkou výhodou této metody, nicméně z praktického hlediska a kvůli složitosti konstrukce se jeví být vhodnější typy kompozitních indikátorů založených na jednodušších výpočtech bez použití PCA, které nakonec poslouží téměř srovnatelně.

Takto zvolené vstupní sady proměnných byly uvažovány s ošetřenými odlehlými hodnotami pomocí metody winsorizace a neošetřenými odlehlými hodnotami. Dále byla provedena normalizace pořadí, z-skóre a Min-Max. Pro hodnoty normalizované pořadím byly proměnné hodnoceny bez vah. Pro proměnné normalizované pomocí z-skóre a Min-Max pak byly porovnávány metody stejných vah a vah stanovených pomocí metody PCA. Dále byla provedena geometrická či lineární agregace, jednostupňová či dvoustupňová. U těchto kroků dochází často k subjektivním rozhodnutím, a je tedy třeba vyhodnotit robustnost té či oné metody. Celkem bylo vytvořeno čtyřicet osm různých typů kompozitních indikátorů za kombinace výše uvedených metod.

Při metodě normalizace pomocí Min-Max dochází k problému, pokud je třeba provést geometrickou agregaci, neboť se v matici nacházejí nulové hodnoty. Převedení nulové hodnoty na velmi nízké číslo podle Hudrlíkové (2014) či Saisana a kol (2017) vyšlo jako nevhodné řešení, protože došlo k markantním rozdílům ve finálním KI v porovnání s ostatními metodami. Řešení dle publikace Saisana a Philippase (2012-b) pomocí transformace dat na škálu 1–10 či přičtení konstanty (číslo 1) podle Roenfeldt (2018) je vhodnější východisko z problému. Po vyhodnocení robustnosti jednotlivých typů KI byl zvolen nejvhodnější a nejrobustnější postup přičtení konstanty (hodnoty 1). Z výsledků měř robustnosti je patrné, že nejvíce robustní vycházejí typy KI vypočtené metodou normalizace

Min-Max, stejných vah a s ošetřenými odlehlými pozorováními pomocí metody winsorizace. Stejně váhy vykazují větší robustnost oproti vahám PCA či použití bez vah. Autorka doporučuje jiný počet dílčích indikátorů zastoupených v pilířích (hospodářský a sociální), nikoliv, jak uvádí Nardo a kol. OECD (2005), stejný počet zastoupení. Také metoda normalizace Min-Max a pořadí vykazují vyšší robustnost nežli metoda z-skóre. Nicméně to neznamená, že jsou tyto metody špatné, mohou být pouze založeny na jiném principu. Z grafů prezentovaných v disertační práci se zdají být méně robustní spíše metody jednostupňové agregace, jak lineární, tak geometrické. Výsledky také potvrdily matematickou teorii Roenfeldt (2018), že geometrický průměr je více robustní.

Dle výše uvedených výsledků, měr robustnosti, posouzení korelace mezi mediánem pořadí a jednotlivými typy KI byly zvoleny jako nejvhodnější metody:

11311 – data očištěná od odlehlých pozorování, normalizace Min-Max, stejné váhy, geometrická agregace prvního řádu, technika řešení nulových hodnot přičtením konstanty.

11631 – data očištěná od odlehlých pozorování, normalizace Min-Max, stejné váhy, geometrická agregace v pilířích, technika řešení nulových hodnot přičtením konstanty, geometrická agregace pilířů.

11621 – data očištěná od odlehlých pozorování, normalizace Min-Max, stejné váhy, geometrická agregace v pilířích, technika řešení nulových hodnot přičtením konstanty, lineární agregace pilířů.

11431 – data očištěná od odlehlých pozorování, normalizace Min-Max, stejné váhy, lineární agregace v pilířích, geometrická agregace pilířů.

33812 – odlehlá pozorování v datové matici, normalizace metodou pořadí, bez vah, agregace součtem.

Tyto typy KI jsou založené na metodách normalizace Min-Max a stejných vah s ošetřenými odlehlými případy pomocí winsorizace, popř. metoda pořadí, bez vah, s neočištěnou vstupní maticí. Každá z těchto metod má své výhody a nevýhody již diskutované v analytické části práce, např. metoda 11311 vychází podle míry robustnosti nejvíce robustní, využívá geometrické agregace, která se jeví být vhodným řešením dle výše uvedené matematické teorie. Metoda součtu pořadí 33812 disponuje velkou výhodou v jednoduchosti konstrukce. Výhodou metody 11431 je lineární agregace v prvním stupni, tudíž by nebylo třeba transformovat nulové hodnoty pro geometrickou transformaci. U těchto zvolených

kombinací metod byl sestaven vícenásobný lineární regresní model pro zjištění vztahu mezi původními proměnnými a kompozitním indikátorem. Nejvíce variability původních proměnných vysvětluje regresní model, kde je stanoven jako závisle proměnná typ KI 11431. Tento typ doporučuje ve své publikaci také Saisana (2011). Jednoznačnou výhodou tohoto typu KI je, že není třeba transformovat nulové hodnoty v datové matici pro geometrickou agregaci. Typ regresního modelu 11431 vykazuje signifikantní regresní koeficienty s logickým směrem.

Varianta KI 11431 byla zvolena jako adekvátní pro výpočet disparit a stanovení hospodářsky problémových okresů (kapitola 4.11, Obrázek 8). Na základě tohoto typu KI bylo identifikováno v případové studii deset nejslabších regionů jako hospodářsky problémové: *Děčín, Bruntál, Šumperk, Tachov, Svitavy, Trutnov, Klatovy, Most, Karviná a Rokycany* a dalších deset regionů dle pořadí KI jako rizikové oblasti: *Rakovník Náchod, Jeseník, Prostějov, Semily, Louny Kroměříž, Hodonín, Teplice a Jindřichův Hradec*. Tyto detekované skupiny regionů se nachází především v oblasti příhraničí, což dokládá mimo jiné literatura v úvodu disertační práce a výsledky SRR. V závěru finálně zvolené typy KI 11431, 11311, 11621, 11631 a 33812 detekují na základě výsledků pořadí v roce 2016 až na malé nuance téměř stejnou skupinu hospodářsky problémových a rizikových okresů a je zřejmé, že vyloženě jednoduchá metoda konstrukce KI na základě metody normalizace pořadí, bez vah a agregování hodnot součtem může vykazovat s malými rozdíly v porovnání s ostatními metodami robustní a téměř porovnatelné výsledky. SRR (2021) aplikuje k určení hospodářsky a sociálně ohrožených území průměrné hodnoty za období 2013–2017 ORP, které vykazují nejhorší výsledky u zvolených proměnných a v nichž žije 25 % obyvatel ČR (viz kapitola 3.2.1). Nicméně již neuvádí detailnější metodiku výpočtu.

Z disertační práce plyne závěrečné doporučení metodologického aparátu pro určení hospodářsky problémových regionů při použití průměru za období v časové řadě zvolené sady proměnných v empirické části práce a aplikaci konstrukce KI typu **11431** (data očištěná od odlehlých pozorování, normalizace Min-Max, stejné váhy, lineární agregace v pilířích, geometrická agregace pilířů). Popřípadě je možné využít jeho alternativy s výhodou v jednoduchosti postupu konstrukce KI **33812** (odlehlá pozorování v datové matici, normalizace metodou pořadí, bez vah, agregace součtem), který poslouží téměř srovnatelně. Nezbytná je kontinuita metodologického aparátu v letech, aby bylo možné provádět

mezičasové srovnávání hospodářsky problémových regionů. Doporučení v disertační práci mohou být využita pro budoucí sestavení SRR, lepší cílení regionální politiky či podpory hospodářsky slabým regionům.

7. Seznam použitých zdrojů

ADLER, F. R. Modeling the dynamics of life: calculus and probability for life scientists. Nelson Education, 2012.

ARROW, K. J., a kol.. Social choice and multicriterion decision-making. MIT Press Books, 1986, 1.

BARRÉ, R. Towards *socially robust S&T indicators: Indicators as debatable devices, enabling collective learning*. Research Evaluation, 2010, 19(3), 227-231.

BECKER, S.O., EGGER, P.H., EHRLICH, M. *Going NUTS: the effect of EU structural funds on regional performance*, Journal of Public Economics, 2010, číslo 94, s. 578–590.

BERMANGROUP *Podpora rozvoje Olomouckého kraje, Příloha č. 2: Analýza území Olomouckého kraje s výraznými rozdíly v socio-ekonomickém vývoji* [online]. 2010 [cit. 2014-06-22]. Dostupné z: <http://www.kr-olomoucky.cz/clanky/dokumenty/1350/priloha-2-se-analyzy-olk-uzemni-diferenciace-final.pdf>

BERLAGE, L., TERWEDUWE, D. *The classification of countries by cluster and by factor analysis*. World Development, 16(12), pp.1527-1545. 1988.

BINEK, J. a kol. Metodika „*RoIA–INOVATIVNÍ PŘÍSTUP K PLÁNOVÁNÍ ROZVOJE OBCÍ*“. [online]. 2012 [cit. 2019-08-22]. Dostupné z: <http://www.garep.cz/wp-content/uploads/2013/03/Metodika-planovani1.pdf>

CAPERNA G. (JRC). *Aggregation rules. COIN 2018 - 16th JRC Annual Training on Composite Indicators & Scoreboards 05-07/11/2018, Ispra (IT)*) [online]. 2018 [cit. 2019-02-05]. Dostupné z: <https://composite-indicators.jrc.ec.europa.eu/sites/default/files/COIN%202018%20Step%206%20Aggregation%20rules.pdf>

COUSINEAU D., CHARTIER, S. *Outliers detection and treatment: a review*. *International Journal of Psychological Research*, 2010. 3 (1), 58-67.

ČSÚ *Číselník okresů LAU1 NUTS* [online]. 2012-c [cit. 2014-06-05]. Dostupné z: http://www.czso.cz/csu/klasifik.nsf/i/ciselnik_okresu_lau1_nuts_2008

ČSÚ *Podíl nezaměstnaných na obyvatelstvu podle okresů České republiky k 30. 9. 2015* [online]. 2015 [cit. 2015-9-28]. Dostupné z: <https://www.czso.cz/csu/xl/151008nezamestnanost-v-libereckem-kraji-k-30-9-2015>

ČSÚ *Zaměstnanost a nezaměstnanost podle výsledků VŠPS - roční průměry - rok 2016* [online]. 2016 [cit. 2019-5-11]. Dostupné z: <https://www.czso.cz/csu/czso/zamestnanost-a-nezamestnanost-podle-vysledku-vsps-rocni-prumery-rok-2016>

ČSÚ *Vymezení územních jednotek NUTS v ČR* [online]. 2012-b [cit. 2014-06-05]. Dostupné z: http://www.czso.cz/csu/redakce.nsf/i/vymezeni_uzemnich_jednotek_nuts_v_cr_pro_potreby

DE PEDRAZA, P. (JRC). *Statistical Coherence (I) Simple Correlations. COIN 2018 - 16th JRC Annual Training on Composite Indicators & Scoreboards 05-07/11/2018*, Ispra (IT) [online]. 2018 [cit. 2018-12-20]. Dostupné z: https://composite-indicators.jrc.ec.europa.eu/sites/default/files/COIN%202018%20Step%207%20Statistical%20Coherence%20%28I%29_Simple%20Correlations.pdf

DEL SORBO, M. (JRC). *Normalisation for Composite Indicators. COIN 2018 - 16th JRC Annual Training on Composite Indicators & Scoreboards 05-07/11/2018*, Ispra (IT) [online]. 2018 [cit. 2018-12-12]. Dostupné z: <https://composite-indicators.jrc.ec.europa.eu/sites/default/files/COIN%202018%20Step%204%20Normalisation.pdf>

DE MONTIS, A., a kol. *Assessing landscape fragmentation: A composite indicator*. Sustainability, 2020, 12.22: 9632.

DE MONTIS, A., a kol. *To weight or not to weight, that is the question: the design of a composite indicator of landscape fragmentation*. Applied Sciences, 2021, 11.7: 3208.

DOČKAL, V. *Ústřední pojmy regionální politiky EU: Příspěvek ke studiu euroregionálního*, 2004. Středoevropské politické studie, 6(1).

DÖPKE, J., KNABE, A., LANG, C., MASCHKE, P. *Multidimensional Well-being and Regional Disparities in Europe. JCMS: Journal of Common Market Studies*, 55(5), pp.1026-1044 [online]. 2017. [cit. 2019-08-20]. Dostupné z: <https://www.econstor.eu/handle/10419/130225>

ERIKSSON, M. *(Re) producing a periphery: Popular representations of the Swedish North*. 2010.

ERIKSSON, L. a kol. *Multi-and megavariate data analysis basic principles and applications*. Umetrics Academy, 2013.

EUROSTAT *Europe 2020 indicators - poverty and social exclusion* [online]. 2014 [cit. 2015-10-22]. Dostupné z: http://ec.europa.eu/eurostat/statistics-explained/index.php/Europe_2020_indicators_-_poverty_and_social_exclusion#Which_groups_are_at_greater_risk_of_poverty_or_social_exclusion.3F

EUROSTAT *HDP na regionální úrovni* [online]. 2016 [cit. 2018-09-29]. Dostupné z: https://ec.europa.eu/eurostat/statistics-explained/index.php/Archive:HDP_na_region%C3%A1ln%C3%AD_%C3%BArovní

EUROSTAT *NUTS Nomenclature* [online]. 2012 [cit. 2014-06-02]. Dostupné z: http://epp.eurostat.ec.europa.eu/portal/page/portal/nuts_nomenclature/introduction

EVROPSKÁ KOMISE *European Structural and Investment Funds 2014-2020: official texts and commentaries* [online]. 2015b [cit. 2018-09-29]. Dostupné z: http://ec.europa.eu/regional_policy/sources/docgener/guides/blue_book/blueguide_en.pdf

EVROPSKÁ KOMISE *The EU's main investment policy* [online]. 2015a [cit. 2015-10-22]. Dostupné z: http://ec.europa.eu/regional_policy/en/policy/what/investment-policy/

FISCHER, Jakub a Jaroslav SIXTA, 2009. K propočtu souhrnné produktivity faktorů. *Politická ekonomie*. 4, 544-554. ISSN 0032-3233.

FUNTOWICZ, S., RAVETZ., J. *Uncertainty and Quality in Science for Policy*. The Netherlands, Kluwer Academic Publishers, 1990. 229s. ISBN 0-7923-0799-2.

GAJDOVÁ, K., TULEJA, P. *Analysis of the Economically Active Population in the Czech-Polish Border Regions*, *International Journal of Information and Education Technology*, 2015. 237 s.

GaREP, spol. s r.o., *Program rozvoje Pardubického kraje* [online]. 2011 [cit. 2018-09-02]. Dostupné z: <https://www.pardubickykraj.cz/rozvoj-kraje/37774>

GaREP, spol. s r.o., *Program rozvoje územního obvodu Olomouckého kraje na období 2015-2020* [online]. 2008 [cit. 2018-09-02]. Dostupné z: <https://www.prerov.eu/filemanager/files/file.php?file=30852>

GIACOMO, D. (JRC). The identification and treatment of outliers. COIN 2018 - 16th JRC Annual Training on Composite Indicators & Scoreboards 05-07/11/2018, Ispra (IT) [online]. 2018 [cit. 2019-02-05]. Dostupné z: <https://composite-indicators.jrc.ec.europa.eu/sites/default/files/COIN%202018%20Step%203%20Outliers%20and%20Missing%20data.pdf>

GRECO, S., a kol. On the methodological framework of composite indices: A review of the issues of weighting, aggregation, and robustness. *Social indicators research*, 2019, 141.1: 61-94.

GREEN, J. W. SPRINGER, T. A. HOLBECH, H. *Statistical Analysis of Ecotoxicity Studies*, 2018. ISBN 9781119488798.

GROENEVELD, R. A., MEEDEN, G. *Measuring skewness and kurtosis*. *The Statistician* 33: 391-399. 1984.

HEBÁK, P., HUSTOPECKÝ, J., MALÁ, I. *Vícerozměrné statistické metody (2)*. Praha: Informatorium, 2005. 239 s. ISBN 80-7333-036-9.

HEBÁK, P., HUSTOPECKÝ, J., MALÁ, I. *Vícerozměrné statistické metody (1)*. Praha: Informatorium, 2007. 253 s. ISBN 80-7333-025-3.

HENDL, J. *Přehled statistických metod - Analýza a metaanalýza dat*. Praha: Portál, 2012. ISBN 978-80-262-0200-4.

HINDLS, R., HRONOVÁ, S. & SEGER, J. (2004). *Statistika pro ekonomy*, Professional publishing.

HUSCHKA, D., WAGNER, G.G. *Sind Indikatoren zur Lebensqualität und zur Lebenszufriedenheit als politische Zielgrößen sinnvoll?* (No. 275). SOEPPapers on Multidisciplinary Panel Data Research, 2010.

HUČKA, M., KUTSCHERAUER, A., SUCHÁČEK, J. *Teorie, metodologie a klasifikace regionálních disparit*, 2009.

HUDRLÍKOVÁ, L., *Kompozitní indikátory: Konstrukce, využití, interpretace*. Doktorská disertační práce. VŠE, Praha 2014.

HUTCHESON, G. *The Multivariate Social Scientist: Introductory Statistics Using Generalized Linear Models*, SAGE Publications Ltd, 1999. 1 edition, 288 s. ISBN 978-0761952015.

CHABIČOVSKÁ, K., *Vymezování problémových regionů v rámci krajů*. Rigorózní práce. Masarykova univerzita, Přírodovědecká fakulta, Brno 2008.

IBM CORPORATION *Statistics Base Option* [online]. 2011 [cit. 2014-07-02]. Dostupné z: <http://www.ibm.com/us/en>

JACOBY, W. *The Enlargement of the European Union and NATO: Ordering from the Menu in Central Europe*. Cambridge, 2006. ISBN 9780521682084.

KNUDSEN, J.P., 2018. *Vicarious habitation—reinterpreting the role of peripheral living in a Nordic context*. *European Planning Studies*, 26(2), pp.279-296.

KOMISE EVROPSKÝCH SPOLEČENSTVÍ *Green Paper on Territorial Cohesion, Turning territorial diversity into strength* [online]. 2008 [cit. 2015-10-5]. Dostupné z: http://ec.europa.eu/regional_policy/archive/consultation/terco/paper_terco_en.pdf

KP PROJEKT S.R.O. A KRAJSKÝ ÚŘAD JIHOČESKÉHO KRAJE, *OREG Program rozvoje Jihočeského kraje 2014 – 2020*, Příloha č. 1. Vymezení hospodářsky slabých oblastí [online]. 2013 [cit. 2014-06-02]. Dostupné z: http://www.kraj-jihocesky.cz/1598/program_rozvoje_jihoceskeho_kraje_2014_8211_2020.htm

KRAJSKÝ ÚŘAD KARLOVARSKÉHO KRAJE, *Územně analytické podklady Karlovarského kraje - Rozbor udržitelného rozvoje území* [online]. 2017 [cit. 2018-09-19]. Dostupné z: http://www.kr-karlovarsky.cz/region/uzem_plan/Stranky/UAP-KK/UAP_Karlovarskeho_kraje.aspx

KUBANOVÁ, J. *Statistické metody pro ekonomickou a technickou praxi*. 1. vyd. Bratislava: Statis, 2003. 247 s. ISBN 80-85659-31-X.

LABOUNKOVÁ, V. Ústav územního rozvoje. *Ekonomicky slabé mikroregiony v Jihomoravském kraji* [online]. 2005 [cit. 2014-06-02]. Dostupné z: http://www.uur.cz/images/uzemnirozvoj/regionalnipolitika/Mikroregiony/MikroregionyJmKraje/2005/Ekonomicky_slabe_oblasti.pdf

LIBERECKÝ KRAJ *Program rozvoje Libereckého kraje 2014 – 2020* [online]. 2013 [cit. 2018-06-09]. Dostupné z: <https://regionalni-rozvoj.kraj-lbc.cz/page1874/regiony-a-oblasti-lk/hospodarsky-slabe-oblasti>

LU, M., WANG, E. *Forging Ahead and Falling Behind: Changing Regional Inequalities in Post-reform China*. Lexington, Ky : Univ. of Kentucky, 2002. ISSN 0017-4815.

MELECKÝ, L., STANIČKOVÁ, M. Contribution to regional disparities measurement: Evidence of composite weighted aggregate index based on EU cohesion concept. In *Great transformation: Recasting regional policy: Conference proceedings of the regional studies association winter conference* (pp. 130-135). Seaford: Regional Studies Association. [online]. 2015 [cit. 2018-08-25]. Dostupné z: https://www.researchgate.net/profile/Lukas_Melecky/publication/284285118_Contribution_to_Regional_Disparities_Measurement_Evidence_of_Composite_Weighted_Aggregate_Index_Based_on_EU_Cohesion_Concept/links/5650f0cb08ae1ef929721efc.pdf

MAJEROVÁ, V., KOSTELECKÝ, T., SÝKORA, L. *Sociální kapitál a rozvoj regionu. Příklad kraje Vysočina*. Grada Publishing, a.s., Praha, 2011. 224 s. ISBN 978-80-247-4093-5.

MELOUN, M., MILITKÝ, J. *Kompendium statistického zpracování dat*, Praha: Academia, 2002. 766 s. ISBN 80-200-1008-4.

MELOUN, M., MILITKÝ, J. *Statistická analýza experimentálních dat*, Praha: Academia, 2004. 980 s. ISBN 80-200-1254-0.

MILITKÝ, J., MELOUN, M. *Transformace dat a počítačově intenzivní metody*. [online]. 2009 [cit. 2019-12-28]. Dostupné z: <https://meloun.upce.cz/docs/publication/247.pdf>

MINARČIKOVÁ, E. Application of Selected Weighting Methods and Topsis Method in Regional Disparities Analysis. *Proceedings of 10th International Days of Statistics and Economics*, pp.1240-1249. [online]. 2016 [cit. 2019-08-25]. Dostupné z: https://msed.vse.cz/msed_2016/article/108-Minarcikova-Eva-paper.pdf

MINAŘÍK, B.; BORŮVKOVÁ, J.; VYSTRČIL, M. *Analýzy v regionálním rozvoji*. Professional Publishing, 2013.

MMR *Strategie regionálního rozvoje České republiky pro léta 2007 – 2013* [online]. 2006 [cit. 2014-06-02]. Dostupné z: <http://www.mmr.cz/cs/Podpora-regionu-a-cestovni-ruch/Regionalni-politika/Koncepce-Strategie/Strategie-regionalniho-rozvoje-Ceske-republiky-na>

MMR *Strategie regionálního rozvoje ČR 2014* + [online]. 2013-b [cit. 2016-04-16]. Dostupné z: http://www.mmr.cz/getmedia/f3ce45a1-66e7-4040-b2dd-3eaf977d0d5a/Postranecky_SRR_CR_2014-2020.pdf

MMR *Strategie regionálního rozvoje ČR 2014-2020* [online]. 2013-a [cit. 2015-09-28]. Dostupné z: <http://www.mmr.cz/getmedia/08e2e8d8-4c18-4e15-a7e2-0fa481336016/SRR-2014-2020.pdf?ext=.pdf>

MMR *Strategie regionálního rozvoje ČR 2021* [online]. 2021 [cit. 2021-02-04]. Dostupné z: <https://mmr.cz/getmedia/58c57a22-202d-4374-af5d-cbd8f9454adb/SRR21.pdf.aspx?ext=.pdf>

MŠMT *Přehled vysokých škol v ČR* [online]. 2015 [cit. 2016-01-10]. Dostupné z: <http://www.msmt.cz/vzdelavani/vysoke-skolstvi/prehled-vysokych-skol-v-cr-3?highlightWords=seznam+vysok%C3%BDch+%C5%A1kol>

MUNDA, G., NARDO, M. (OECD/JRC). *Constructing consistent composite indicators: the issue of weights*. EUR 21834 EN. [online]. 2005 [cit. 2019-24-08]. Dostupné z: https://www.researchgate.net/profile/Giuseppe_Munda/publication/239751435_Constructing_Consistent_Composite_Indicators_The_Issue_of_Weights/links/59eee715a6fdcc32187ddcaf/Constructing-Consistent-Composite-Indicators-The-Issue-of-Weights.pdf

NARDO, M., SAISANA, M., SALTELLI, A., TARANTOLA, S. (OECD/JRC). *Tools for Composite Indicators Building*. Ispra: Joint Research Centre. EUR 21682. [online]. 2005 [cit. 2018-12-05]. Dostupné z: <http://publications.jrc.ec.europa.eu/repository/bitstream/JRC31473/EUR%2021682%20EN.pdf>

NARDO, M., SAISANA, M., SALTELLI, A., TARANTOLA, S., HOFFMANN, A., GIOVANNINI, E. (OECD/JRC). *Handbook on Constructing Composite Indicators: Methodology and user Guide*, 2008. Brussels: OECD Publishing, ISBN 978-92-64-04345-9.

OECD, 2004, “*The OECD-JRC Handbook on Practices for Developing Composite Indicators*”, paper presented at the OECD Committee on Statistics, 7-8 June 2004, OECD, Paris.

PAPADIMITRIOU, E. (JRC). *Weighting methods (I). COIN 2018 - 16th JRC Annual Training on Composite Indicators & Scoreboards 05-07/11/2018*, Ispra (IT) [online]. 2018 [cit. 2018-12-19]. Dostupné z: <https://composite-indicators.jrc.ec.europa.eu/sites/default/files/COIN%202018%20Step%205%20Weighting%20methods%20%28I%29%20PCA.pdf>

PARUOLO, P., SAISANA, M., SALTELLI, A. *Ratings and rankings: voodoo or science?*. Journal of the Royal Statistical Society: Series A (Statistics in Society), 176(3), pp.609-634. [online]. 2013 [cit. 2019-04-04]. Dostupné z: http://www.andreasaltelli.eu/file/repository/rssa_1059.pdf

PAVLÍK, M. a kol., *Jak úspěšně řídit obec a region: cíle, nástroje, trendy, zahraniční zkušenosti*. Praha: Grada Publishing, 2014. ISBN 978-80-247-5256-3.

POLEDNÍKOVÁ, E., MELECKÝ, L. *WEIGHTING METHODS FOR CONSTRUCTING COMPOSITE INDICES IN REGIONAL DEVELOPMENT*. The 11th International Days of Statistics and Economics, Prague, September 14-16. [online]. 2017 [cit. 2019-08-25]. Dostupné z: https://msed.vse.cz/msed_2017/article/225-Polednikova-Eva-paper.pdf

ROENFELDT, K. *Better than Average: Calculating Geometric Means Using SAS*. [online]. 2018 [cit. 2019-03-09]. Dostupné z: https://www.lexjansen.com/wuss/2018/56_Final_Paper_PDF.pdf

SAISANA, M. *European Commission, JRC, Institute for the Protection and Security of the Citizen, G03: Econometrics and Applied Statistics, A do it yourself guide in Excel for composite indicator development*, Italy. [online]. 2012-a [cit. 2019-02-01]. Dostupné z: https://ec.europa.eu/jrc/sites/jrcsh/files/20140922_JRC_COIN_COIN2014_Excelguidefor CIs.pdf

SAISANA, M. *Weighting Methods, Seminar on Composite Indicators: From Theory to Practice. Ispra, Italy*. 2011.

SAISANA, M., BECKER, W., DOMINGUEZ-TORREIRO, M., VÉRTESY, D. *COIN Tool – beta version. A quality assurance Excel-based tool for developers and users of composite indicators and scoreboards*. European Commission. JRC105377. [online]. 2017 [cit. 2019-02-02]. Dostupné z: https://composite-indicators.jrc.ec.europa.eu/sites/default/files/COIN%20Tool%20-%20beta%20version_0.pdf

SAISANA, M., TARANTOLA, S. *State-of-the-art Report on Current Methodologies and Practices for Composite Indicator Development Ispra*. Italy: European Commission, Joint Research Centre, Institute for the Protection and the Security of the Citizen, Technological and Economic Risk Management Unit. [online]. 2002 [cit. 2019-04-04]. Dostupné z: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.402.5612&rep=rep1&type=pdf>

SAISANA, M., PHILIPPAS, D. *Sustainable Society Index (SSI): Taking societies' pulse along social, environmental and economic issues*. Environmental Impact Assessment Review, 32: 94-106. [online]. 2012-b [cit. 2019-02-01]. Dostupné z: http://www.ssindex.com/ssi2016/wp-content/uploads/pdf/JRCauditSSI2006_2012.pdf

SALTELLI, A. *Composite indicators between analysis and advocacy*. *Social Indicators Research*, 2007. 81(1), 65-77.

SALTELLI, A. *Making best use of model evaluations to compute sensitivity indices*. *Computer physics communications*, 2002, 145.2: 280-297.

SALTELLI, A., NARDO, M., SAISANA, M., TARANTOLA, S., LIŠKA, R. *Agregované indikátory – kontroverze a její možná řešení*. *Statistika*, 2, 93-106. [online]. 2005 [cit. 2018-12-12]. Dostupné z: https://www.researchgate.net/profile/Michela_Nardo/publication/228621081_Agregovane_indikatory-kontroverze_a_jeji_mozna_reseni/links/00b495228339e0a406000000/Agregovane-indikatory-kontroverze-a-jeji-mozna-reseni.pdf

SOUČEK, E., *Statistika pro ekonomy*. VSEM. 2006.

SVATOŠOVÁ, L. *The development of regional disparities in Czech Republic over the 2005–2010 years*. *Acta univ. agric. et silvic. Mendel. Brun.*, 2012, LX, No. 7, pp. 337-344.

SVATOŠOVÁ, L., SVOBODOVÁ, J. *Changes in the assessment of conditions of living in regions of the Czech Republic*. In: *Agrarian Perspectives XXIV. Global Agribusiness and the Rural Economy, Proceedings of the 24th International Scientific Conference, 16-18 September 2015, Prague, Czech Republic*. Czech University of Life Sciences Prague, Faculty of Economics and Management, 2015. p. 407-415.

SVOBODOVÁ, J., DÖMEOVÁ, L., JINDROVÁ, A. *Economic Differences of Border Regions in the Czech Republic*. *Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis*, 2018. 66(2), 571-582.

ŠIPIKAL, M., PISÁR, P., LABUDOVÁ V. *Are subsidies really needed? The case of EU regional policy in the Czech and Slovak Republics*, *E+M Ekonomie a management*, 2013. vol. 16, Iss. 4, s. 30-41, ISSN 1212-3609.

TARANTOLA, S.; VERTESY, D.. *Composite indicators of research excellence. EUR-Scientific and Technical Research Reports*, 2012.

United Nations Development Programme (2010). *Human development report 2010. Technical report*, <http://hdr.undp.org/en/reports/>.

UPTON, J.G., COOK, I *A Dictionary of Statistics*, Oxford University Press, 2014. ISBN: 978-0-19-967918-8.

VÉRTESY, D. (JRC). *Frameworks and Indicators. COIN 2018 - 16th JRC Annual Training on Composite Indicators & Scoreboards 05-07/11/2018, Ispra (IT)* [online]. 2018 [cit. 2019-01-02]. Dostupné z: <https://composite-indicators.jrc.ec.europa.eu/sites/default/files/COIN%202018%20Steps%201%20%26%20%20Frameworks%20and%20Indicators.pdf>

WAHL, S., SCHULTE, M., BUTZMANN, E. *The Prosperity Quintett—Measuring Prosperity in Germany and other early Industrialised Countries*. 2010.

WARNER, R. M. *Applied statistics: From bivariate through multivariate techniques*. Sage Publications, Inc., Thousand Oaks. 2008. ISBN: 978-0-7619-2772-3.

YOU DEN, W.J. *Statistical techniques for collaborative tests*. Washington, DC, 20044. 1967.

ZÁKON č. 183/2006 Sb. *Stavební zákon*. In: *Sbírka zákonů*.

ZÁKON č. 248/2000 Sb., *Zákona o podpoře regionálního rozvoje*. In: *Sbírka zákonů*

Přílohy

Příloha 1 Seznam všech uvažovaných indikátorů dle metodik jednotlivých krajů a SRR

Oblast	Kategorie	Podkategorie	Název indikátoru	Metodika indikátoru	Jednotky	Směr	Příj	Zdroj dat pro DP na úrovni IAMI	Počet opakování	Kraj													
										ULK	LBK	HKK	VYS	JHM	OLK	ZLK	MSK	JHC	PAK	SRR			
Hospodářská	Ekonomika	Nezaměstnanost	Podíl nezaměstnaných osob	Podíl dohodlivých uchazečů evidovaných na ÚP a ekonomicky aktivních obyvatel v %	%	↓	H.S.	KROK	11	KVK	ULK	LBK	HKK	VYS	JHM	OLK	ZLK	MSK	JHC	PAK	SRR		
	Ekonomika	Podnikatelská aktivita	Intenzita podnikatelské aktivity	Počet ekonomických subjektů na 1000 obyvatel	na 1000 obyvatel	↑	H	KROK	9	ULK	LBK	HKK	VYS	JHM	OLK	ZLK	MSK						
	Ekonomika	Nezaměstnanost	Podíl dohodlivě nezaměstnaných osob	Podíl dohodlivých uchazečů evidovaných na ÚP dle než 12 měsíců a ekonomicky aktivních obyvatel v %	%	↓	H.S.	KROK	5	VYS	JHM	OLK	ZLK	MSK									
	Ekonomika	Dobrovolná práce	Dobrovolná práce	Dobrovolná práce v tis. Kč na 1000 obyvatel	tis. Kč na 1000 obyvatel	↑	H.S.	MONITOR MF	5	KVK	LBK	HKK	MSK	PAK									
	Ekonomika	Pracovní příležitosti	Dostupnost uchazečů	Počet dostupných uchazečů o práci na jedno volné pracovní místo	počet uchazečů na 1000 EA obyvatel	↑	H	KROK	3	HKK	OLK	ZLK											
	Ekonomika	Pracovní příležitosti	Volná pracovní místa	Počet volných pracovních míst na 1000 ekonomicky aktivních obyvatel (13.64 let)	na 1000 EA obyvatel	↑	H	KROK	2	LBK	JHM												
	Ekonomika	Podnikatelská aktivita	Požádky	Velikost požadavků (avg) Počet volných firem na 1000 obyvatel	Kč na 1000 obyvatel	↑	H	KROK	2	ZLK	JHM												
	Ekonomika	Zařazení a sociální dávky	Sociální dávky	Počet dávek v úmorné souč. příspěvek na školství, bydlení, mimořádnou okamžitou penzi v Kč na 1000 obyvatel	Kč na 1000 obyvatel	↓	H.S.	MPSV	1	JHM	SRR												
	Ekonomika	Zařazení a sociální dávky	Zařazení	Počet lidí vzhledem k v. Kč na 1000 obyvatel	na 1000 obyvatel	↓	H.S.	MONITOR MF	1	OLK	SRR												
	Ekonomika	Nezaměstnanost	Zaměstnanost v zemědělství	Počet pracovníků v zemědělství, lesnictví a rybnářství na 1000 ekonomicky aktivních obyvatel	na 1000 obyvatel	↑	H.S.	KROK	1	JHC													
	Sociální	Demografie	Populace a struktura	Index stáří	Počet obyvatel ve věku 65 a více let na 100 obyvatel ve věku 0-14 let	počet obyvatel na 1000 obyvatel	↓	S.H.	KROK	7	KVK	HKK	JHM	OLK	ZLK	MSK	PAK						
		Demografie	Pohyby obyvatelstva	Hrubi míra migračního salda	Rozdíl mezi počtem přistěhovavých a vystěhovavých obyvatel na 1000 obyvatel	na 1000 obyvatel	↑	S	KROK	6	KVK	VYS	OLK	MSK	JHC	PAK	SRR						
Demografie		Pohyby obyvatelstva	Hrubi míra celkového přírůstu	Rozdíl mezi počtem narozených a zemřelých a přistěhovavých a vystěhovavých na 1000 obyvatel	na 1000 obyvatel	↑	S	KROK	6	KVK	JHM	HKK	LBK	OLK	ZLK								
Demografie		Vzdělání	Index vzdělanosti	1 * SŠ bez maturity + 2 * SŠ s maturitou + 3 * VOS + 4 * VŠ; počet obyvatel nad 15 let	počet obyvatel nad 15 let	↑	S.H.	KROK	5	KVK	ULK	LBK	OLK	ZLK									
Demografie		Populace	Hustota zalidnění	Počet obyvatel na rozlohu km2 území jednotky	počet obyvatel na 1000 obyvatel	↑	S	KROK	5	LBK	VYS	MSK	JHC	PAK									
Demografie		Populace a struktura	Index ekonomické aktivity (střední)	Počet obyvatel ve věku 0-14 let a 65 a více let na 100 obyvatel ve věku 15-64 let	počet obyvatel na 1000 obyvatel	↓	S.H.	KROK	4	LBK	HKK	MSK	VYS										
Demografie		Pohyby obyvatelstva	Hrubi míra přirozeného přírůstu	Rozdíl mezi počtem narozených a zemřelých na 1000 obyvatel	na 1000 obyvatel	↑	S	KROK	2	VYS	OLK												
Demografie		Populace	Průměrná populační velikost obce	Počet obyvatel připadající na jednu územní jednotku	počet obyvatel na 1000 obyvatel	↑	S	KROK	2	VYS	JHM												
Demografie		Demografické procesy	Stárnutí a rozvodovost	Rozdíl mezi počtem alabů a rozvodů v dané územní jednotce	počet obyvatel	↓	S	KROK	1	VYS													
Bydlení		Bytová výstavba	Intenzita bytové výstavby	Počet dokončených bytů na 1000 obyvatel	na 1000 obyvatel	↑	S	KROK	9	KVK	ULK	LBK	HKK	VYS	JHM	OLK	ZLK	MSK					
Bydlení		Obytná výstavba	Stupňová vybavenost	Jakýchkoliv vhodný ukazatel (př. udržovací práce, ZŠ, domovy pro seniory na 1000 obyvatel)	na 1000 obyvatel	↑	S.H.	KROK	5	KVK	JHM	ZLK	MSK	LBK									
Bydlení		Neobydlené byty	Počet neobydlených bytů	Počet neobydlených bytů na celkový počet bytů v územní jednotce v %	%	↓	S	KROK	2	KVK	OLK												
Bydlení	Domovní ekonomika	Mír. domovní ekonomiky	Rozdílka znavávacích plachů v km2 na 1000 obyvatel	km2 na 1000 obyvatel	↑	S	KROK	1	OLK														
Bydlení	Intenzita bytové výstavby v domovních budovách	Intenzita bytové výstavby v domovních budovách	Počet bytů na 1000 obyvatel	počet bytů na 1000 obyvatel	↑	S	KROK	1	VYS														
Infrastruktura	Technická infrastruktura	Technická infrastruktura	Výkonost bytu kvalitativně; přehled v socioekonom. (ne obyvatel/ km2)	počet bytů	↑	S	KROK	5	KVK	LBK	JHM	ZLK	MSK										
Infrastruktura	Doprava	Hustota silnic	Číslo km silnic na km2 území (v km2 na rozlohu území v %)	%	↑	S.H.	KROK	4	KVK	ZLK	OLK	JHC											

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

Příloha 2 Výčet zvolených ukazatelů za hospodářskou oblast použitých pro další výpočty

Podíl nezaměstnaných osob

$$\frac{\text{Počet dosažitelných uchazečů evidovaných na ÚP ve věku 15 – 64 let}}{\text{Počet ekonomicky aktivních obyvatel}} * 100$$

Popis: Podíl dosažitelných uchazečů evidovaných na ÚP ve věku 15–64 let a ekonomicky aktivních obyvatel vyjádřený v %

Způsob hodnocení: ↓ čím vyšší hodnota indikátoru, tím nižší bodové hodnocení

Zdroj dat: KROK (ČSÚ)

Počet registrovaných jednotek (Intenzita podnikatelské aktivity)

$$\frac{\text{Počet ekonomických subjektů}}{\text{Střední stav obyvatel}}$$

Popis: Počet ekonomických subjektů přepočtený na střední stav obyvatel

Způsob hodnocení: ↑ čím vyšší hodnota indikátoru, tím vyšší bodové hodnocení

Zdroj dat: KROK (ČSÚ)

Daňové příjmy

$$\frac{\text{Daňové příjmy v tis. Kč}}{\text{Střední stav obyvatel}}$$

Popis: Daňové příjmy v tis. Kč na střední stav obyvatel

Způsob hodnocení: ↑ čím vyšší hodnota indikátoru, tím vyšší bodové hodnocení

Zdroj dat: MONITOR (Ministerstvo financí ČR)

Dosažitelní uchazeči na pracovní místo

$$\frac{\text{Počet dosažitelných uchazečů o práci}}{\text{Počet volných pracovních míst}}$$

Popis: Počet dosažitelných uchazečů o práci na jedno volné pracovní místo

Způsob hodnocení: ↑ čím vyšší hodnota indikátoru, tím vyšší bodové hodnocení

Zdroj dat: KROK (ČSÚ)

Velké podniky

Počet velkých firem **Střední stav obyvatel**

Popis: Počet velkých podnikatelských subjektů (s 250 a více zaměstnanci) na střední stav obyvatel

Způsob hodnocení: ↑ čím vyšší hodnota indikátoru, tím vyšší bodové hodnocení

Zdroj dat: KROK (ČSÚ)

Dávky v hmotné nouzi

Počet dávek v hmotné nouzi v Kč **Střední stav obyvatel**

Popis: Počet dávek v hmotné nouzi – příspěvek na živobytí, bydlení, mimořádnou okamžitou pomoc v Kč na střední stav obyvatel

Způsob hodnocení: ↓ čím vyšší hodnota indikátoru, tím nižší bodové hodnocení

Zdroj dat: Ministerstvo práce a sociálních věcí

Cizí zdroje (Zadlužení)

Cizí zdroje v tis. Kč **Střední stav obyvatel**

Popis: Podíl cizích zdrojů v tis. Kč na střední stav obyvatel

Způsob hodnocení: ↓ čím vyšší hodnota indikátoru, tím nižší bodové hodnocení

Zdroj dat: MONITOR (Ministerstvo financí ČR)

Příloha 3 Výčet zvolených ukazatelů za sociální oblast použitých pro další výpočty

Index stáří

$$\frac{\text{Počet obyvatel ve věku 65 let a více}}{\text{Počet obyvatel ve věku 0 – 14 let}} * 100$$

Popis: Počet obyvatel ve věku 65 a více let na 100 obyvatel ve věku 0–14 let

Způsob hodnocení: ↓ čím vyšší hodnota indikátoru, tím nižší bodové hodnocení

Zdroj dat: KROK (ČSÚ)

Hrubá míra migračního salda

$$\frac{\text{Počet přistěhovalých obyvatel} - \text{Počet vystěhovalých obyvatel}}{\text{Střední stav obyvatel}}$$

Popis: Rozdíl mezi počtem přistěhovalých a vystěhovalých obyvatel na střední stav obyvatel

Způsob hodnocení: ↑ čím vyšší hodnota indikátoru, tím vyšší bodové hodnocení

Zdroj dat: KROK (ČSÚ)

Index vzdělanosti

$$\frac{1 * \text{SŠ bez maturity} + 2 * \text{SŠ s maturitou} + 3 * \text{VOŠ} + 4 * \text{VŠ}}{\text{Počet obyvatel nad 15 let}}$$

Popis: Obyvatelstvo s vyšším stupněm vzdělání v přepočtu na počet obyvatel

Způsob hodnocení: ↑ čím vyšší hodnota indikátoru, tím vyšší bodové hodnocení

Zdroj dat: KROK (ČSÚ)

Index ekonomické zátěže

$$\frac{\text{Počet obyvatel ve věku 0 – 14 let a 65 a více let}}{\text{Počet obyvatel ve věku 15 – 64 let}} * 100$$

Popis: Počet obyvatel ve věku 0–14 let a 65 a více let na 100 obyvatel ve věku 15–64 let

Způsob hodnocení: ↓ čím vyšší hodnota indikátoru, tím nižší bodové hodnocení

Zdroj dat: KROK (ČSÚ)

Hrubá míra přirozeného přírůstku

Počet narozených obyvatel – Počet zemřelých obyvatel

Střední stav obyvatel

Popis: Rozdíl mezi počtem narozených a zemřelých obyvatel na střední stav obyvatel

Způsob hodnocení: ↑ čím vyšší hodnota indikátoru, tím vyšší bodové hodnocení

Zdroj dat: KROK (ČSÚ)

Sňatečnost a rozvodovost

Počet sňatků – Počet rozvodů

Střední stav obyvatel

Popis: Rozdíl mezi počtem sňatků a rozvodů v dané územní jednotce na střední stav obyvatel

Způsob hodnocení: ↑ čím vyšší hodnota indikátoru, tím vyšší bodové hodnocení

Zdroj dat: KROK (ČSÚ)

Počet dokončených bytů (Intenzita bytové výstavby)

Počet dokončených bytů

Střední stav obyvatel

Popis: Počet dokončených bytů na střední stav obyvatel

Způsob hodnocení: ↑ čím vyšší hodnota indikátoru, tím vyšší bodové hodnocení

Zdroj dat: KROK (ČSÚ)

Stupeň základní vybavenosti

Počet samostatných ordinací praktického lékaře pro dospělé

Střední stav obyvatel

Počet základních škol s 1. a 2. st.

Střední stav obyvatel

Počet domovů pro seniory

Střední stav obyvatel

Popis: a. Počet samostatných ordinací praktického lékaře pro dospělé v přepočtu na střední stav obyvatel

b. Existence základní školy v přepočtu na střední stav obyvatel

c. Existence domova pro seniory v přepočtu na střední stav obyvatel

Způsob hodnocení: ↑ čím vyšší hodnota indikátoru, tím vyšší bodové hodnocení

Zdroj dat: KROK (ČSÚ)

Podíl neobydlených bytů

$$\frac{\text{Počet neobydlených bytů}}{\text{Celkový počet bytů v územní jednotce}} * 100$$

Popis: Počet neobydlených bytů na celkový počet bytů v územní jednotce vyjádřený v %

Způsob hodnocení: ↓ čím vyšší hodnota indikátoru, tím nižší bodové hodnocení

Zdroj dat: KROK (ČSÚ)

Technická infrastruktura

$$\frac{\text{Počet bytů v domech napojených na kanalizaci}}{\text{Počet obydlených domů}}$$

Popis: Byty v domech napojené na kanalizaci v přepočtu na celkový počet obydlených domů

Způsob hodnocení: ↑ čím vyšší hodnota indikátoru, tím vyšší bodové hodnocení

Zdroj dat: KROK (ČSÚ)

Hustota silniční sítě

$$\frac{\text{Celková délka silniční a dálniční sítě v km}}{\text{Celková rozloha území v km}} * 100$$

Popis: Celková délka silniční a dálniční sítě v km na rozlohu území vyjádřena v %

Způsob hodnocení: ↑ čím vyšší hodnota indikátoru, tím vyšší bodové hodnocení

Zdroj dat: KROK (ČSÚ)

Příloha 4 Korelační matice pro rok 2012

Correlation Matrix

Correlation	H_Pocet_registrovaných_eindek	H_Dano_v_ejnových_příjmech	H_Dosažení_učazeců_na_přijímání	H_Velké_podniky	S_Index_vzdělání_nosti	S_Hrubá_míra_přirůzání	S_Lekari	S_Zakladní_skoly	S_Domovy_pro_seniony	S_Pocet_dokoncení_bytu	S_Technická_infrastruktura_kanalizace	S_Hustota_silnicí_site	S_Smrtky_rozvody	S_Hrubá_míra_migracního_salda	H_Podíl_nezaměstnaných_osob	H_Dávky_v_jmohne_nouzi	H_Cizí_zdroje	S_Index_ekonomické_zateze	S_Podíl_neobydlených_bytu	
H_Pocet_registrovaných_eindek	1.000	.360	-.442	.282	.425	.356	.014	-.125	-.018	.389	.091	-.081	-.049	.196	-.431	-.272	.263	-.069	.324	.087
H_Danove_prijmy	.360	1.000	-.149	.422	-.003	.101	.004	-.087	.046	-.197	.227	.145	-.062	-.286	.147	.388	.360	.030	-.160	-.282
H_Dosažení_učazeců_na_přijímání	-.442	-.149	1.000	-.129	-.224	-.246	.040	.050	.059	-.202	-.070	-.182	.005	-.351	.549	-.283	-.248	.074	-.273	-.186
H_Velké_podniky	.282	.422	-.129	1.000	.508	.258	.112	-.441	.378	.111	.596	.302	.051	.021	-.143	.075	.351	.214	-.157	-.338
S_Index_vzdělání_nosti	.425	-.003	-.224	.508	1.000	.397	.124	-.454	.308	.567	.449	.359	.158	.474	-.564	-.473	.265	.311	.654	-.023
S_Hrubá_míra_přirůzání	.356	.101	-.246	.258	.397	1.000	-.203	-.210	-.029	.573	.085	-.037	-.047	.449	-.398	-.323	.140	-.524	.068	-.179
S_Lekari	.014	.004	.040	.112	.124	.124	1.000	.280	.253	-.212	.194	-.028	.242	-.362	.034	-.078	.045	.478	.151	.130
S_Zakladní_skoly	-.125	-.087	.050	-.441	-.454	-.210	.280	1.000	-.289	-.248	-.494	-.374	-.233	-.368	.161	-.045	-.112	-.016	-.156	.457
S_Domovy_pro_seniony	.389	-.197	.070	.596	.449	.085	.194	-.494	.695	.026	1.000	.601	-.109	.676	-.601	-.591	.099	-.154	.364	.065
S_Pocet_dokoncení_bytu	.091	.227	-.070	.302	.359	-.037	-.028	-.374	.400	.051	.601	1.000	-.112	.140	-.076	.169	.203	.122	.263	-.141
S_Technická_infrastruktura_kanalizace	.081	.145	-.182	.302	.359	-.037	-.028	-.374	.400	.051	.601	1.000	-.112	.140	-.076	.169	.203	.122	.263	-.141
S_Hustota_silnicí_site	-.049	-.062	.005	.051	.158	-.047	.242	.233	-.123	.109	-.100	-.112	1.000	-.088	-.226	-.411	-.018	.287	.119	.277
S_Smrtky_rozvody	.196	-.286	-.351	.021	.474	.449	-.362	-.368	-.184	.676	-.097	.140	-.088	1.000	-.532	-.004	-.264	.388	.081	.081
H_Podíl_nezaměstnaných_osob	-.431	.147	.549	-.143	-.564	-.398	.034	.161	.122	-.601	.142	-.076	-.226	-.581	1.000	.784	-.054	-.090	-.561	-.379
H_Dávky_v_jmohne_nouzi	-.272	.388	.283	.075	-.473	-.323	-.078	-.045	.210	-.591	.249	.169	-.411	-.532	.784	1.000	.077	-.172	-.424	-.519
H_Cizí_zdroje	.263	.360	-.248	.351	.265	.140	.045	-.112	.188	.099	.242	.203	-.018	-.004	-.054	.077	1.000	.135	.239	-.134
S_Index_stari	.069	.030	.074	.214	.311	-.524	.478	-.016	.141	-.154	.201	.122	.287	-.264	-.090	-.172	.135	1.000	.463	.214
S_Index_ekonomické_zateze	.324	-.160	-.273	.157	.654	.068	.151	-.156	.040	.364	.047	.263	.119	.388	-.561	-.424	.239	.463	1.000	.334
S_Podíl_neobydlených_bytu	.087	-.282	-.186	-.338	-.023	-.179	.130	.457	-.261	.065	-.522	-.141	.277	.081	-.379	-.519	-.134	.214	.334	1.000

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

Příloha 5 Korelační matice pro rok 2016

Correlation Matrix

Correlation	H_Pocet_registrovanych_jednotek	H_Velke_podniky	H_Index_vzdelanosti	S_Zakladni_skoly	S_Domovy_pro_seniory	S_Pocet_dokoncenyh_bytu	S_Technicka_infrastruktura_kanalizace	S_Hustota_silnicni_site	S_Hrubá_míra_migračního_salda	H_Poill_nezaměstnaných_osob	S_Index_ekonomické_zátěže	S_Poill_neobydlených_bytu
H_Pocet_registrovanych_jednotek	1.000	.394	.524	-.158	.073	.497	.030	.116	.436	-.133	.349	.129
H_Velke_podniky	.394	1.000	.531	-.514	-.149	.307	.372	.140	.211	-.005	.310	-.395
S_Index_vzdelanosti	.524	.531	1.000	-.462	-.110	.496	-.003	.363	.384	-.217	.354	-.118
S_Zakladni_skoly	-.158	-.514	-.462	1.000	.213	-.407	-.348	-.215	-.311	.010	-.095	.533
S_Domovy_pro_seniory	.073	-.149	-.110	.213	1.000	-.101	-.175	-.132	-.104	.113	-.153	.164
S_Pocet_dokoncenyh_bytu	.497	.307	.496	-.407	-.101	1.000	-.254	.290	.791	-.184	.237	-.406
S_Technicka_infrastruktura_kanalizace	.030	.372	-.003	-.348	-.175	-.254	1.000	.043	-.315	.077	.132	-.215
S_Hustota_silnicni_site	.116	.140	.363	-.215	-.132	.290	.043	1.000	.480	-.127	.031	.069
S_Hrubá_míra_migračního_salda	.436	.211	.384	-.311	-.104	.791	-.315	.480	1.000	-.230	.148	-.361
H_Poill_nezaměstnaných_osob	-.133	-.005	-.217	.010	.113	-.184	.077	-.127	-.230	1.000	.049	-.093
H_Cizi_zdroje	.349	.310	.354	-.085	-.153	.237	.132	.031	.148	.049	1.000	-.067
S_Index_ekonomické_zátěže	-.258	-.397	-.020	.247	.164	-.406	-.215	.069	-.361	-.093	-.067	1.000
S_Poill_neobydlených_bytu	.129	-.395	-.118	.533	.269	-.022	-.639	.045	.158	-.108	-.090	.363
												1.000

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

Příloha 6 Tabulka komponentních zátěží pro výpočet vah pro rok 2012

Proměnná	Komponentní zátěže				Čtverec komponentní zátěže (ve škále 0-1)			
	Komponenta 1	Komponenta 2	Komponenta 3	Komponenta 4	Komponenta 1	Komponenta 2	Komponenta 3	Komponenta 4
S Hrubá míra migračního salda	0.888	-0.056	-0.078	-0.133	0.298	0.002	0.005	0.010
S Počet dokončených bytů	0.821	-0.051	-0.064	0.151	0.255	0.002	0.003	0.013
H Podíl nezaměstnaných osob	-0.788	0.033	-0.327	-0.194	0.235	0.001	0.090	0.021
S Index vzdělanosti	0.673	0.479	0.036	0.371	0.171	0.165	0.001	0.078
S Index ekonomické zátěže	0.556	0.306	0.516	0.258	0.117	0.067	0.224	0.038
S Technická infrastruktura-kanalizace	-0.042	0.819	-0.391	0.220	0.001	0.483	0.128	0.027
S Hustota silniční sítě	0.141	0.800	0.039	-0.015	0.007	0.461	0.001	0.000
S Domovy pro seniory	-0.146	0.775	-0.121	0.117	0.008	0.433	0.012	0.008
S Podíl neobydlených bytů	0.137	-0.205	0.876	-0.081	0.007	0.030	0.644	0.004
S Základní školy	-0.451	-0.433	0.580	-0.017	0.077	0.135	0.282	0.000
H Cizí zdroje	-0.045	0.165	-0.009	0.756	0.001	0.020	0.000	0.323
H Počet registrovaných jednotek	0.377	-0.085	0.068	0.693	0.054	0.005	0.004	0.271
H Velké podniky	0.121	0.452	-0.346	0.566	0.006	0.147	0.101	0.181
Vysvětlený rozptyl (Eigenvalue)	3.27	2.71	1.78	1.72				
SUMA vysvětleného rozptylu (Eigenvalue)	9.48							
Vysvětlený rozptyl/SUMA vysvětleného rozptylu	0.47	0.39	0.25	0.25				


Proměnná	Vysvětlený rozptyl/SUMA vysvětleného rozptylu	Nejvyšší zátěže na druhou (ve škále 0-1)	Součin	Váha
S Hrubá míra migračního salda	0.47	0.30	0.14	0.0953
S Počet dokončených bytů	0.47	0.25	0.12	0.0815
H Podíl nezaměstnaných osob	0.47	0.23	0.11	0.0750
S Index vzdělanosti	0.47	0.17	0.08	0.0547
S Index ekonomické zátěže	0.47	0.12	0.05	0.0373
S Technická infrastruktura-kanalizace	0.39	0.48	0.19	0.1279
S Hustota silniční sítě	0.39	0.46	0.18	0.1220
S Domovy pro seniory	0.39	0.43	0.17	0.1145
S Podíl neobydlených bytů	0.25	0.64	0.16	0.1122
S Základní školy	0.25	0.28	0.07	0.0491
H Cizí zdroje	0.25	0.32	0.08	0.0545
H Počet registrovaných jednotek	0.25	0.27	0.07	0.0457
H Velké podniky	0.25	0.18	0.04	0.0305
SUMA		4.15	1.46	

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV


Příloha 8 Finální pořadí dle jednotlivých typů KI (s outliery) (2016-b), Zdroj: vlastní výpočty

Označení Označení	Skvělosti											
	Normalizace pořadí		Normalizace MIN-MAX Skvělosti		Normalizace MIN-MAX Skvělosti		Normalizace Z-score Skvělosti		Normalizace MIN-MAX Skvělosti		Normalizace Z-score Skvělosti	
	AGREGACE I - medián	AGREGACE I - soutěž	AGREGACE I - aritmický průměr	AGREGACE I - aritmický průměr (přepočten na škálu 1-10)	AGREGACE I - aritmický průměr (přepočten na škálu 1-10)	AGREGACE I - aritmický průměr (přepočten na škálu 1-10)	AGREGACE I - aritmický průměr (přepočten na škálu 1-10)	AGREGACE I - aritmický průměr (přepočten na škálu 1-10)	AGREGACE I - aritmický průměr (přepočten na škálu 1-10)	AGREGACE I - aritmický průměr (přepočten na škálu 1-10)	AGREGACE I - aritmický průměr (přepočten na škálu 1-10)	AGREGACE I - aritmický průměr (přepočten na škálu 1-10)
1	3	1	1	1	1	1	1	1	1	1	1	1
2	3	1	1	1	1	1	1	1	1	1	1	1
3	3	1	1	1	1	1	1	1	1	1	1	1
4	3	1	1	1	1	1	1	1	1	1	1	1
5	3	1	1	1	1	1	1	1	1	1	1	1
6	3	1	1	1	1	1	1	1	1	1	1	1
7	3	1	1	1	1	1	1	1	1	1	1	1
8	3	1	1	1	1	1	1	1	1	1	1	1
9	3	1	1	1	1	1	1	1	1	1	1	1
10	3	1	1	1	1	1	1	1	1	1	1	1
11	3	1	1	1	1	1	1	1	1	1	1	1
12	3	1	1	1	1	1	1	1	1	1	1	1
13	3	1	1	1	1	1	1	1	1	1	1	1
14	3	1	1	1	1	1	1	1	1	1	1	1
15	3	1	1	1	1	1	1	1	1	1	1	1
16	3	1	1	1	1	1	1	1	1	1	1	1
17	3	1	1	1	1	1	1	1	1	1	1	1
18	3	1	1	1	1	1	1	1	1	1	1	1
19	3	1	1	1	1	1	1	1	1	1	1	1
20	3	1	1	1	1	1	1	1	1	1	1	1
21	3	1	1	1	1	1	1	1	1	1	1	1
22	3	1	1	1	1	1	1	1	1	1	1	1
23	3	1	1	1	1	1	1	1	1	1	1	1
24	3	1	1	1	1	1	1	1	1	1	1	1
25	3	1	1	1	1	1	1	1	1	1	1	1
26	3	1	1	1	1	1	1	1	1	1	1	1
27	3	1	1	1	1	1	1	1	1	1	1	1
28	3	1	1	1	1	1	1	1	1	1	1	1
29	3	1	1	1	1	1	1	1	1	1	1	1
30	3	1	1	1	1	1	1	1	1	1	1	1
31	3	1	1	1	1	1	1	1	1	1	1	1
32	3	1	1	1	1	1	1	1	1	1	1	1
33	3	1	1	1	1	1	1	1	1	1	1	1
34	3	1	1	1	1	1	1	1	1	1	1	1
35	3	1	1	1	1	1	1	1	1	1	1	1
36	3	1	1	1	1	1	1	1	1	1	1	1
37	3	1	1	1	1	1	1	1	1	1	1	1
38	3	1	1	1	1	1	1	1	1	1	1	1
39	3	1	1	1	1	1	1	1	1	1	1	1
40	3	1	1	1	1	1	1	1	1	1	1	1
41	3	1	1	1	1	1	1	1	1	1	1	1
42	3	1	1	1	1	1	1	1	1	1	1	1
43	3	1	1	1	1	1	1	1	1	1	1	1
44	3	1	1	1	1	1	1	1	1	1	1	1
45	3	1	1	1	1	1	1	1	1	1	1	1
46	3	1	1	1	1	1	1	1	1	1	1	1
47	3	1	1	1	1	1	1	1	1	1	1	1
48	3	1	1	1	1	1	1	1	1	1	1	1
49	3	1	1	1	1	1	1	1	1	1	1	1
50	3	1	1	1	1	1	1	1	1	1	1	1
51	3	1	1	1	1	1	1	1	1	1	1	1
52	3	1	1	1	1	1	1	1	1	1	1	1
53	3	1	1	1	1	1	1	1	1	1	1	1
54	3	1	1	1	1	1	1	1	1	1	1	1
55	3	1	1	1	1	1	1	1	1	1	1	1
56	3	1	1	1	1	1	1	1	1	1	1	1
57	3	1	1	1	1	1	1	1	1	1	1	1
58	3	1	1	1	1	1	1	1	1	1	1	1
59	3	1	1	1	1	1	1	1	1	1	1	1
60	3	1	1	1	1	1	1	1	1	1	1	1
61	3	1	1	1	1	1	1	1	1	1	1	1
62	3	1	1	1	1	1	1	1	1	1	1	1
63	3	1	1	1	1	1	1	1	1	1	1	1
64	3	1	1	1	1	1	1	1	1	1	1	1
65	3	1	1	1	1	1	1	1	1	1	1	1
66	3	1	1	1	1	1	1	1	1	1	1	1
67	3	1	1	1	1	1	1	1	1	1	1	1
68	3	1	1	1	1	1	1	1	1	1	1	1
69	3	1	1	1	1	1	1	1	1	1	1	1
70	3	1	1	1	1	1	1	1	1	1	1	1
71	3	1	1	1	1	1	1	1	1	1	1	1
72	3	1	1	1	1	1	1	1	1	1	1	1
73	3	1	1	1	1	1	1	1	1	1	1	1
74	3	1	1	1	1	1	1	1	1	1	1	1
75	3	1	1	1	1	1	1	1	1	1	1	1
76	3	1	1	1	1	1	1	1	1	1	1	1
77	3	1	1	1	1	1	1	1	1	1	1	1
78	3	1	1	1	1	1	1	1	1	1	1	1
79	3	1	1	1	1	1	1	1	1	1	1	1
80	3	1	1	1	1	1	1	1	1	1	1	1
81	3	1	1	1	1	1	1	1	1	1	1	1
82	3	1	1	1	1	1	1	1	1	1	1	1
83	3	1	1	1	1	1	1	1	1	1	1	1
84	3	1	1	1	1	1	1	1	1	1	1	1
85	3	1	1	1	1	1	1	1	1	1	1	1
86	3	1	1	1	1	1	1	1	1	1	1	1
87	3	1	1	1	1	1	1	1	1	1	1	1
88	3	1	1	1	1	1	1	1	1	1	1	1
89	3	1	1	1	1	1	1	1	1	1	1	1
90	3	1	1	1	1	1	1	1	1	1	1	1
91	3	1	1	1	1	1	1	1	1	1	1	1
92	3	1	1	1	1	1	1	1	1	1	1	1
93	3	1	1	1	1	1	1	1	1	1	1	1
94	3	1	1	1	1	1	1	1	1	1	1	1
95	3	1	1	1	1	1	1	1	1	1	1	1
96	3	1	1	1	1	1	1	1	1	1	1	1
97	3	1	1	1	1	1	1	1	1	1	1	1
98	3	1	1	1	1	1	1	1	1	1	1	1
99	3	1	1	1	1	1	1	1	1	1	1	1
100	3	1	1	1	1	1	1	1	1	1	1	1


Příloha 11 Box-Plot pro jednotlivé pořadí okresů s označením typu kompozitního indikátoru (2012), Zdroj: vlastní výpočty




Příloha 12 Box-Plot pro jednotlivé pořadí okresů označením typu kompozitního indikátoru (2016), Zdroj: vlastní výpočty




Příloha 13 Box-Plot pro pořadí KI jednotlivých okresů – porovnání technik ošetření nulových hodnot pro geometrickou transformaci (2012), Zdroj: vlastní výpočty




Příloha 14 Box-Plot pro pořadí KI jednotlivých okresů – porovnání technik ošetření nulových hodnot pro geometrickou transformaci (2016), Zdroj: vlastní výpočty



Příloha 15 Box-Plot pro pořadí KI jednotlivých okresů – porovnání dle přístupu k odlehkým pozorováním (2012), Zdroj: vlastní výpočty



Příloha 16 Box-Plot pro pořadí KI jednotlivých okresů – porovnání dle přístupu k odlehkým pozorováním (2016), Zdroj: vlastní výpočty



Příloha 17 Korelační matice (Spearmanův korelační koeficient) mezi jednotlivými typy KI (2016), Zdroj: vlastní výpočty


Correlations

Pearson Correlation	K_11111	K_11211	K_11311	K_11321	K_11431	K_11521	K_11531	K_11621	K_11631	K_12111	K_12211	K_12311	K_12431	K_12521	K_12621	K_21111	K_21421	K_22111	K_33712	K_33812
K_11111	1	.928**	.993**	.968**	.974**	.872**	.872**	.962**	.961**	.787**	.801**	.797**	.743**	.809**	.804**	.524**	.484**	.450**	.900**	.963**
K_11211	.928**	1	.957**	.915**	.918**	.955**	.958**	.942**	.942**	.716**	.818**	.754**	.708**	.812**	.754**	.459**	.430**	.388**	.840**	.917**
K_11311	.993**	.957**	1	.968**	.973**	.905**	.906**	.971**	.971**	.780**	.822**	.800**	.749**	.826**	.805**	.517**	.479**	.448**	.900**	.966**
K_11321	.968**	.915**	.968**	1	.998**	.921**	.918**	.993**	.993**	.726**	.769**	.744**	.741**	.754**	.747**	.488**	.447**	.418**	.881**	.954**
K_11431	.974**	.918**	.973**	.998**	1	.915**	.914**	.990**	.991**	.727**	.768**	.745**	.738**	.756**	.748**	.491**	.448**	.420**	.888**	.958**
K_11521	.872**	.955**	.905**	.921**	.915**	1	.999**	.951**	.951**	.657**	.781**	.702**	.706**	.750**	.698**	.420**	.399**	.350**	.788**	.876**
K_11531	.872**	.958**	.906**	.918**	.914**	.999**	1	.949**	.950**	.656**	.781**	.701**	.702**	.751**	.697**	.417**	.397**	.345**	.787**	.875**
K_11621	.962**	.942**	.971**	.993**	.990**	.951**	.949**	1	1.000**	.733**	.800**	.760**	.757**	.782**	.762**	.477**	.444**	.410**	.878**	.954**
K_11631	.961**	.942**	.971**	.993**	.991**	.951**	.951**	1.000**	1	.732**	.799**	.759**	.756**	.782**	.761**	.478**	.446**	.409**	.877**	.953**
K_12111	.787**	.716**	.780**	.726**	.727**	.657**	.656**	.733**	.732**	1	.938**	.992**	.941**	.942**	.994**	.258**	.247**	.330**	.669**	.751**
K_12211	.801**	.818**	.822**	.769**	.768**	.781**	.781**	.800**	.799**	.938**	1	.970**	.927**	.989**	.967**	.285**	.257**	.364**	.716**	.794**
K_12311	.797**	.754**	.800**	.744**	.745**	.702**	.701**	.760**	.759**	.992**	.970**	1	.951**	.969**	.999**	.275**	.254**	.355**	.692**	.773**
K_12431	.743**	.708**	.749**	.741**	.738**	.706**	.702**	.757**	.756**	.941**	.927**	.951**	1	.890**	.942**	.190**	.156**	.285**	.644**	.746**
K_12521	.809**	.812**	.826**	.754**	.756**	.750**	.751**	.782**	.782**	.942**	.989**	.989**	.951**	1	.890**	.942**	.190**	.285**	.644**	.746**
K_12621	.804**	.754**	.805**	.747**	.748**	.698**	.697**	.762**	.761**	.994**	.967**	.999**	.942**	.970**	1	.970**	.297**	.390**	.728**	.790**
K_21111	.524**	.459**	.517**	.488**	.491**	.420**	.417**	.477**	.478**	.258**	.285**	.275**	.190**	.319**	.283**	1	.926**	.843**	.574**	.524**
K_21421	.484**	.430**	.479**	.447**	.448**	.399**	.397**	.444**	.446**	.247**	.257**	.254**	.156**	.297**	.267**	.926**	1	.686**	.505**	.460**
K_22111	.450**	.388**	.448**	.418**	.420**	.350**	.345**	.410**	.409**	.330**	.364**	.355**	.285**	.390**	.358**	.843**	.926**	1	.513**	.462**
K_33712	.900**	.840**	.900**	.881**	.888**	.788**	.787**	.878**	.877**	.669**	.716**	.692**	.644**	.728**	.696**	.574**	.505**	.513**	1	.928**
K_33812	.963**	.917**	.966**	.954**	.958**	.876**	.875**	.954**	.953**	.751**	.794**	.773**	.746**	.790**	.775**	.524**	.460**	.462**	.928**	1


** Correlation is significant at the 0.01 level (2-tailed).

* Correlation is significant at the 0.05 level (2-tailed).


Příloha 18 Box-Plot pro pořadí KI jednotlivých okresů – porovnání metod normalizace (2012), Zdroj: vlastní výpočty




Příloha 19 Box-Plot pro pořadí KI jednotlivých okresů – porovnání metod normalizace (2016), Zdroj: vlastní výpočty




Příloha 20 Výsledné pořadí KI jednotlivých okresů – porovnání metod normalizace za rok 2012, Zdroj: vlastní výpočty




Příloha 21 Výsledné pořadí KI jednotlivých okresů – porovnání metod normalizace za rok 2016, Zdroj: vlastní výpočty




Příloha 22 Výsledné pořadí KI jednotlivých okresů – porovnání mediánu metod normalizace za rok 2012, Zdroj: vlastní výpočty




Příloha 23 Výsledné pořadí KI jednotlivých okresů – porovnání mediánu metod normalizace za rok 2016, Zdroj: vlastní výpočty



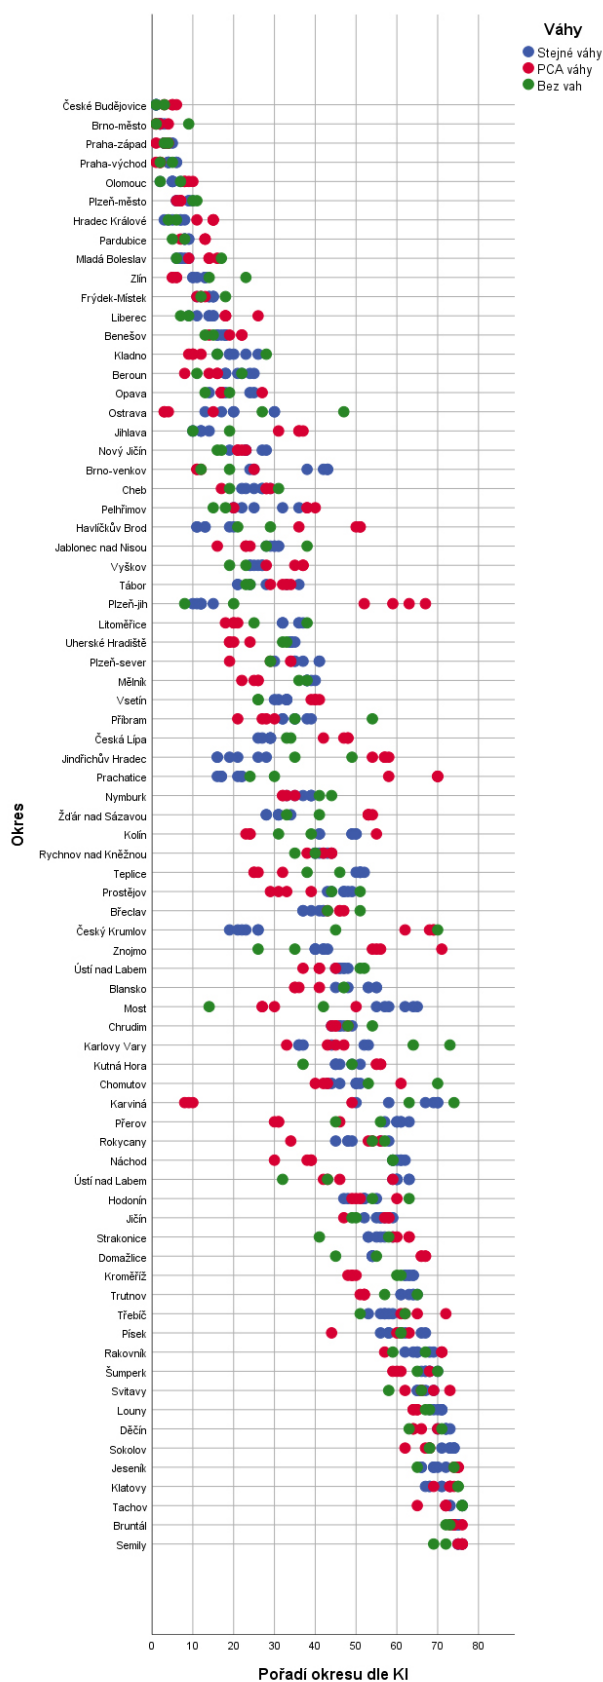
Příloha 24 Box-Plot pro pořadí KI jednotlivých okresů – porovnání metod stanovení vah (2012), Zdroj: vlastní výpočty




Příloha 25 Box-Plot pro pořadí KI jednotlivých okresů – porovnání metod stanovení vah (2016), Zdroj: vlastní výpočty




Příloha 26 Výsledné pořadí KI jednotlivých okresů – porovnání metod stanovení vah za rok 2012, Zdroj: vlastní výpočty



Příloha 27 Výsledné pořadí KI jednotlivých okresů – porovnání metod stanovení vah za rok 2016, Zdroj: vlastní výpočty




Příloha 28 Výsledné pořadí KI jednotlivých okresů – porovnání mediánu metod stanovení vah za rok 2012, Zdroj: vlastní výpočty




Příloha 29 Výsledné pořadí KI jednotlivých okresů – porovnání mediánu metod stanovení vah za rok 2016, Zdroj: vlastní výpočty




Příloha 30 Box-Plot pro pořadí KI jednotlivých okresů – porovnání metod
jednostupňové a dvoustupňové agregace (2012), Zdroj: vlastní výpočty




Příloha 31 Box-Plot pro pořadí KI jednotlivých okresů – porovnání metod
jednostupňové a dvoustupňové agregace (2016), Zdroj: vlastní výpočty




Příloha 32 Výsledného pořadí KI jednotlivých okresů – porovnání metod jednostupňové a dvoustupňové agregace za rok 2016, Zdroj: vlastní výpočty



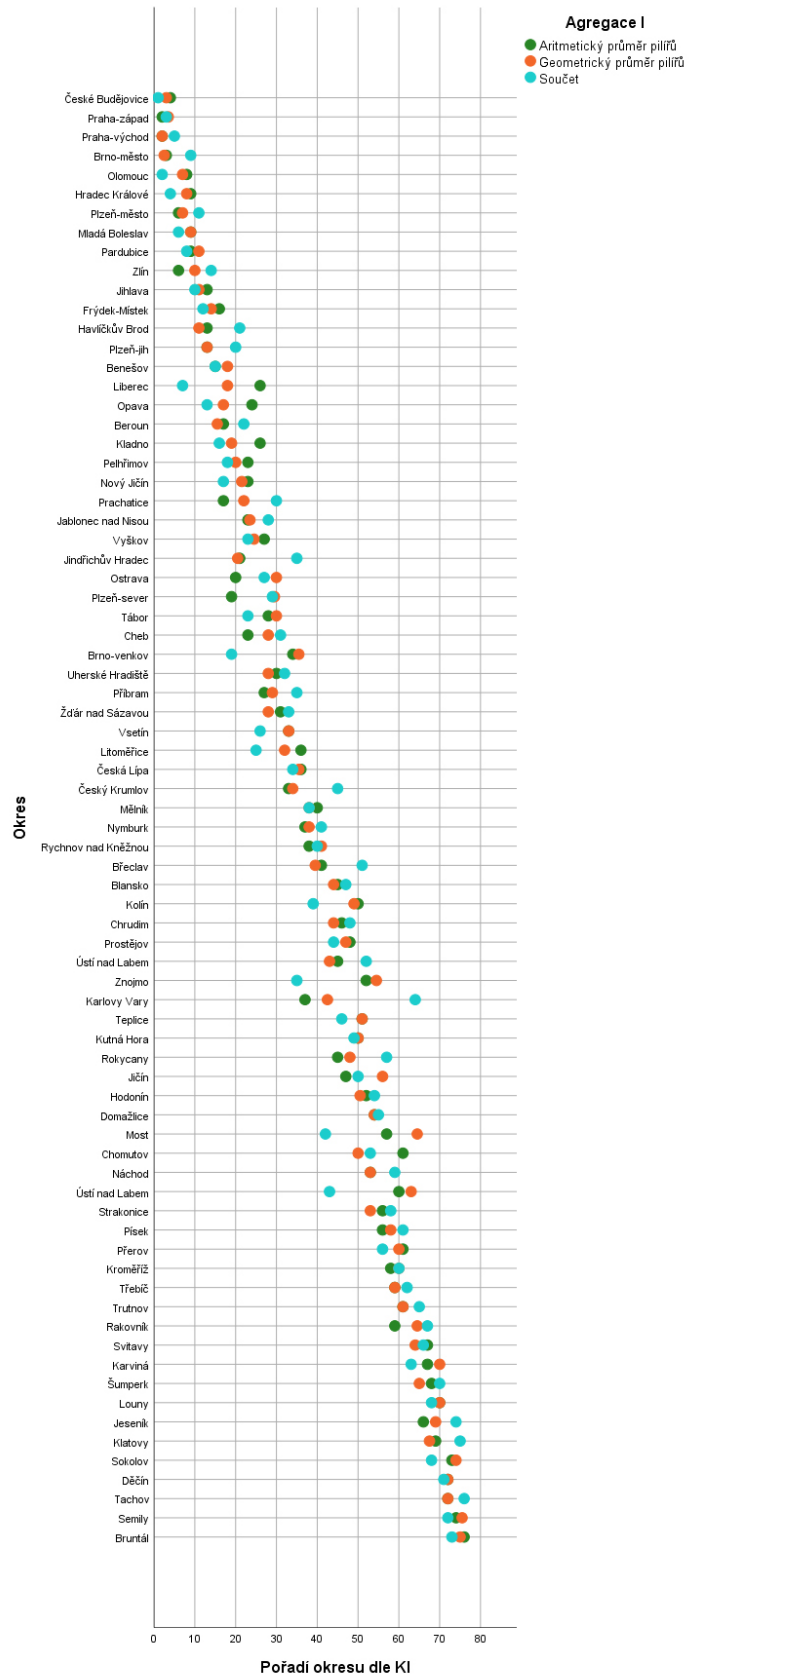
Příloha 33 Výsledného pořadí KI jednotlivých okresů – porovnání metod agregace I za rok 2012, Zdroj: vlastní výpočty



Příloha 34 Výsledného pořadí KI jednotlivých okresů – porovnání metod agregace I za rok 2016, Zdroj: vlastní výpočty



Příloha 35 Výsledného pořadí KI jednotlivých okresů – porovnání mediánu vybraných metod agregace I za rok 2012, Zdroj: vlastní výpočty



Příloha 36 Výsledného pořadí KI jednotlivých okresů – porovnání mediánu vybraných metod agregace I za rok 2016, Zdroj: vlastní výpočty



Příloha 37 Popisná statistika 2012

Popisná statistika 2012								
	Minimum	Maximum	Průměr	Směrodatná odchylka	Rozptyl	Variační koeficient	Šikmost	Špičatost
II Počet registrovaných jednotek	155,14	330,15	232,86	32,31	1044,19	13,88%	0,956	1,190
II Daňové příjmy	3381,71	20670,94	10428,66	2347,28	5509732,07	22,51%	2,225	11,563
II Dosažitelní uchazeči na pracovní místo	4,32	116,33	27,47	19,78	391,12	71,99%	2,065	5,896
II Velké podniky	0,06	0,33	0,15	0,05	0,00	35,33%	1,199	2,357
S Index vzdělanosti	1,10	1,98	1,38	0,15	0,02	10,91%	1,355	3,705
S Hrubá míra přirozeného přírůstku	-2,10	5,31	-0,24	1,34	1,80	-547,90%	1,851	5,679
S Lékaři	0,26	0,52	0,42	0,05	0,00	12,22%	-0,413	0,418
S Základní školy	0,17	0,39	0,27	0,04	0,00	16,25%	0,010	0,085
S Domovy pro seniory	0,01	0,38	0,07	0,05	0,00	69,86%	4,282	25,787
S Počet dokončených bytů	0,91	10,08	2,67	1,32	1,74	49,38%	2,945	13,613
S Technická infrastruktura - kanalizace	0,47	7,90	1,74	1,29	1,66	73,84%	3,128	11,627
S Hustota silniční sítě	43,96	277,73	98,92	33,63	1130,96	34,00%	2,416	10,366
S Sňatky a rozvody	0,80	2,61	1,72	0,39	0,15	22,62%	-0,019	-0,478
S Hrubá míra migračního salda	-6,17	22,17	0,80	4,87	23,70	608,30%	2,357	7,915
II Podíl nezaměstnaných osob	3,07	13,09	7,73	2,01	4,05	26,04%	0,293	0,075
II Dávky v hmotné nouzi	60,14	1469,04	466,70	308,53	95190,84	66,11%	1,394	1,839
II Cizí zdroje	3371,06	28841,99	10198,37	4966,05	24661683,05	48,69%	1,822	4,061
S Index stáří	69,73	137,54	111,11	12,47	155,46	11,22%	-0,729	1,689
S Index ekonomické zátěže	40,63	49,67	46,31	1,80	3,24	3,89%	-0,548	0,318
S Podíl neobydlených bytů	7,13	48,51	19,57	7,36	54,24	37,64%	1,124	2,389
Popisná statistika 2012 (po ošetření odlehlých pozorování)								
	Minimum	Maximum	Průměr	Směrodatná odchylka	Rozptyl	Variační koeficient	Šikmost	Špičatost
II Počet registrovaných jednotek	155,14	313,30	232,6358	31,68944	1004,220	13,62%	0,863	0,882
II Daňové příjmy	8881,54	11904,59	10242,5812	813,44928	661699,732	7,94%	0,541	-0,471
II Dosažitelní uchazeči na pracovní místo	4,32	85,65	27,0187	18,02805	325,011	66,72%	1,532	2,712
II Velké podniky	0,0617	0,3040	0,148855	0,0514026	0,003	34,53%	1,050	1,727
S Index vzdělanosti	1,1017	1,7301	1,379086	0,1338664	0,018	9,71%	0,629	0,912
S Hrubá míra přirozeného přírůstku	-2,10	2,30	-0,3220	1,07985	1,166	-335,34%	0,549	-0,302
S Lékaři	0,3068	0,5154	0,416320	0,0490266	0,002	11,78%	-0,188	-0,257
S Základní školy	0,1735	0,3919	0,272934	0,0443524	0,002	16,25%	0,010	0,085
S Domovy pro seniory	0,0104	0,1669	0,063804	0,0315463	0,001	49,44%	1,516	3,044
S Počet dokončených bytů	0,91	4,92	2,5762	0,93611	0,876	36,34%	0,737	0,504
S Technická infrastruktura - kanalizace	0,47	4,04	1,6265	0,84262	0,710	51,81%	1,438	1,941
S Hustota silniční sítě	43,9567	199,0559	97,883775	28,9355572	837,266	29,56%	1,240	2,676
S Sňatky a rozvody	0,80	2,61	1,7223	0,38950	0,152	22,62%	-0,019	-0,478
S Hrubá míra migračního salda	-6,17	12,42	0,5535	3,93405	15,477	710,75%	1,196	1,751
II Podíl nezaměstnaných osob	3,07	13,09	7,7333	2,01340	4,054	26,04%	0,293	0,075
II Dávky v hmotné nouzi	60,14	1383,93	465,5848	304,97725	93011,124	65,50%	1,341	1,591
II Cizí zdroje	3371,06	20979,86	9958,7085	4217,54576	17787692,257	42,35%	1,143	1,142
S Index stáří	89,48	137,54	111,6220	11,08708	122,923	9,93%	0,000	-0,408
S Index ekonomické zátěže	41,96	49,67	46,3297	1,74904	3,059	3,78%	-0,368	-0,312
S Podíl neobydlených bytů	7,13	39,36	19,4459	6,94787	48,273	35,73%	0,719	0,486

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV

Příloha 38 Popisná statistika 2016

Popisná statistika 2016								
	Minimum	Maximum	Průměr	Směrodatná odchylka	Rozptyl	Variační koeficient	Šikmost	Špičatost
II Počet registrovaných jednotek	159,82	345,22	238,5474	30,69860	942,404	12,87%	0,915	1,774
II Daňové příjmy	5493,15	23643,46	14666,0363	2217,13143	4915671,791	15,12%	1,448	10,983
II Dosažitelní uchazeči na pracovní místo	0,57	15,35	3,5674	2,70872	7,337	75,93%	1,990	4,714
II Velké podniky	0,0629	0,3563	0,159809	0,0552349	0,003	34,56%	1,203	2,002
S Index vzdělanosti	1,5430	2,4718	1,858504	0,1516426	0,023	8,16%	1,428	4,122
S Hrubá míra přirazeného přírůstku	-2,53	5,25	0,0897	1,42392	2,028	1587,85%	1,101	2,809
S Lékaři	0,2972	0,5960	0,442186	0,0541887	0,003	12,25%	0,063	0,712
S Základní školy	0,1914	0,3668	0,274778	0,0404411	0,002	14,72%	0,076	-0,432
S Domovy pro seniory	0,0178	0,1547	0,056380	0,0210630	0,000	37,36%	1,431	5,130
S Počet dokončených bytů	0,81	7,71	2,1896	1,15837	1,342	52,90%	1,994	6,278
S Technická infrastruktura - kanalizace	0,88	4,60	1,6060	0,78074	0,610	48,61%	2,096	4,134
S Hustota silniční sítě	41,0275	111,2995	74,228863	16,9066671	285,835	22,78%	0,216	-0,551
S Sňatky a rozvody	1,38	3,66	2,4164	0,47045	0,221	19,47%	-0,115	-0,163
S Hrubá míra migračního salda	-6,05	20,61	1,0319	4,32883	18,739	419,51%	1,909	5,815
II Podíl nezaměstnaných osob	1,76	10,08	5,1088	1,80016	3,241	35,24%	0,655	0,020
II Dávky v hmotné nouzi	196,53	2986,76	85,24480	620,33701	384818,006	72,77%	1,667	2,449
II Cizí zdroje	3129,18	23968,86	9979,5640	4193,64690	17586624,022	42,02%	1,222	1,675
S Index stáří	67,09	137,23	107,7988	12,85536	165,260	11,93%	-0,508	1,125
S Index ekonomické zátěže	56,28	69,74	62,9488	2,44003	5,954	3,88%	-0,033	0,105
S Podíl neobydlených bytů	7,60	43,22	20,8124	7,08509	50,199	34,04%	0,644	0,454
Popisná statistika 2016 (po ošetření odlehklých pozorování)								
	Minimum	Maximum	Průměr	Směrodatná odchylka	Rozptyl	Variační koeficient	Šikmost	Špičatost
II Počet registrovaných jednotek	159,82	320,78	238,2258	29,67740	880,748	12,46%	0,702	0,955
II Daňové příjmy	13060,50	17262,38	14529,8782	1066,73640	1137926,537	7,34%	1,263	1,287
II Dosažitelní uchazeči na pracovní místo	0,57	10,43	3,5026	2,47180	6,110	70,57%	1,509	1,743
II Velké podniky	0,0629	0,2896	0,158446	0,0511172	0,003	32,26%	0,795	0,363
S Index vzdělanosti	1,5430	2,1966	1,852653	0,1325087	0,018	7,15%	0,604	0,889
S Hrubá míra přirazeného přírůstku	-2,53	2,90	0,0297	1,24239	1,544	4179,03%	0,238	-0,253
S Lékaři	0,2972	0,5960	0,442186	0,0541887	0,003	12,25%	0,063	0,712
S Základní školy	0,1914	0,3668	0,274778	0,0404411	0,002	14,72%	0,076	-0,432
S Domovy pro seniory	0,0178	0,1004	0,055666	0,0184413	0,000	33,13%	0,363	-0,228
S Počet dokončených bytů	0,81	5,20	2,1567	1,02756	1,056	47,65%	1,181	1,280
S Technická infrastruktura - kanalizace	0,88	3,23	1,5642	0,65466	0,429	41,85%	1,605	1,589
S Hustota silniční sítě	41,0275	111,2995	74,228863	16,9066671	285,835	22,78%	0,216	-0,551
S Sňatky a rozvody	1,38	3,66	2,4164	0,47045	0,221	19,47%	-0,115	-0,163
S Hrubá míra migračního salda	-6,05	10,84	0,8441	3,66443	13,428	434,13%	0,926	0,828
II Podíl nezaměstnaných osob	1,76	10,08	5,1088	1,80016	3,241	35,24%	0,655	0,020
II Dávky v hmotné nouzi	196,53	2598,84	84,55594	598,44547	358136,981	70,78%	1,525	1,728
II Cizí zdroje	3129,18	20884,39	9916,4485	4002,71902	16021759,541	40,36%	0,994	0,734
S Index stáří	70,39	137,23	107,8422	12,72113	161,827	11,80%	-0,435	0,879
S Index ekonomické zátěže	56,28	69,74	62,9488	2,44003	5,954	3,88%	-0,033	0,105
S Podíl neobydlených bytů	7,60	36,94	20,7297	6,85310	46,965	33,06%	0,449	-0,222

Zdroj: vlastní výpočty, ČSÚ-KROK, MF-MONITOR, MPSV