

**Univerzita Palackého v Olomouci**  
**Přírodovědecká fakulta**  
**Katedra geoinformatiky**

**HODNOCENÍ VÝVOJE KRIMINALITY ČESKA  
VE VZTAHU K VYBRANÝM  
SOCIOEKONOMICKÝM UKAZATELŮM**

**Diplomová práce**

**Bc. Michal Plánka**

**doc. RNDr. Jaroslav Burian, Ph.D.**

**Olomouc 2023**  
**Geoinformatika a kartografie**

## **ANOTACE**

Kriminalita významně ovlivňuje fungování společnosti i života každého člověka. Je zkoumána mnoha obory včetně geografie, která využívá prostorový aspekt pro analýzu rozmístění kriminality. Takové výzkumy jsou běžné v zahraničí, v Česku je jim věnováno málo pozornosti. Cílem práce je pro území Česka provést časoprostorovou analýzu kriminality (od roku 2012 do současnosti) vzhledem k vybraným socioekonomickým ukazatelům a porozumět specifikům prostorových statistických vztahů kriminality v kontextu geoinformatiky a geografie. Míra kriminality je hodnocena pomocí souhrnného indexu a dílčích kategorií trestných činů. Inovativním a unikátním přístupem je autorův návrh, výpočet a vizualizace váženého indexu kriminality. Data trestných činů pochází z aplikace Mapy Kriminality, která tak byla nově využita a otestována pro statistické účely. Použití těchto dat na úrovni obcí však přináší řadu limitací, jejichž řešení je diskutováno v této práci. Pro hledání vztahu míry kriminality vůči vybraným socioekonomickým ukazatelům jsou použity především analýzy pomocí metod prostorové statistiky. Aplikace prostorové metody Geographically weighted regression (GWR) přináší efektivnější, kvalitnější a přesnější výsledky regresních koeficientů ve srovnání s metodami Spatial lag model (SLM), Spatial error model (SEM) či neprostorovou metodou Ordinary least squares (OLS). Modely mj. prokázaly přímou pozitivní souvislost mezi mírou kriminality a podílem obyvatel v exekuci, insolvenci a příjemců příspěvků na bydlení. Práce syntetizuje dílčí informace analýz do výsledného zjištění v rámci hodnocení kriminality, což přináší do jisté míry komplexní pohled na současný stav kriminality v Česku s důrazem na její prostorovou složku. Výstupy prostorových analýz poskytují užitečné informace o trendech a vzorcích kriminality v různých oblastech. Zjištěné informace mohou být využity pro plánování investic a zásahů, identifikaci prioritních oblastí a formulaci politik a strategií. Policie České republiky může tyto informace efektivně využít pro prevenci kriminality v jednotlivých obcích, resp. oblastech Česka.

## **KLÍČOVÁ SLOVA**

Geografie kriminality, trestná činnost, regresní analýza, prostorová statistika

Počet stran práce: 82

Počet příloh: 82 (z toho 1 volná a 74 elektronických)

## **ANNOTATION**

Crime has a significant impact on the functioning of society and everyone's life. It is studied by many disciplines, including geography, which uses the spatial aspect to analyze the distribution of crime. Such research is common abroad, but little attention is paid to it in the Czech Republic. This thesis aims to perform a spatiotemporal analysis of crime (from 2012 to the present) for the territory of the Czech Republic with respect to selected socio-economic indicators and to understand the specifics of spatial statistical relationships of crime in the context of geoinformatics and geography. Crime rates are assessed using an aggregate index and sub-categories of crime. An innovative and unique approach is the author's design, calculation, and visualization of a weighted crime index. The crime data comes from the Crime Map application, which has thus been newly used and tested for statistical purposes. However, the use of this data at the municipal level presents a number of limitations, the solution to which is discussed in this paper. In particular, analyses using spatial statistical methods are used to look for the relationship of crime rates to selected socio-economic indicators. The application of the spatial method Geographically Weighted Regression (GWR) yields more efficient, better quality, and more accurate regression coefficient results compared to Spatial lag model (SLM), Spatial error model (SEM), or non-spatial Ordinary least squares (OLS) methods. The models showed, among other things, a direct positive relationship between crime rates and the proportion of residents in foreclosure, insolvency, and receiving housing benefits. The paper synthesizes the partial information of the analyses into a final finding in the framework of crime assessment, which provides a somewhat comprehensive view of the current state of crime in the Czech Republic with an emphasis on its spatial component. The outputs of the spatial analyses provide useful information on trends and patterns of crime in different areas. The information found can be used to plan investments and interventions, identify priority areas and formulate policies and strategies. The Police of the Czech Republic can effectively use this information for crime prevention in individual municipalities or regions of the Czech Republic.

## **KEYWORDS**

Geography of crime, crime offences, regression analysis, spatial statistics

Number of pages 82

Number of appendixes 82

**Prohlašuji, že**

- diplomovou práci včetně příloh, jsem vypracoval samostatně a uvedl jsem všechny použité podklady a literaturu.

- jsem si vědom, že na moji diplomovou práci se plně vztahuje zákon č.121/2000 Sb. - autorský zákon, zejména § 35 – využití díla v rámci občanských a náboženských obřadů, v rámci školních představení a využití díla školního a § 60 – školní dílo,

- beru na vědomí, že Univerzita Palackého v Olomouci (dále UP Olomouc) má právo nevýdělečně, ke své vnitřní potřebě, diplomovou práci užívat (§ 35 odst. 3),

- souhlasím, že údaje o mé diplomové práci budou zveřejněny ve Studijním informačním systému UP,

- v případě zájmu UP Olomouc uzavřu licenční smlouvu s oprávněním užít výsledky a výstupy mé diplomové práce v rozsahu § 12 odst. 4 autorského zákona,

- použít výsledky a výstupy mé diplomové práce nebo poskytnout licenci k jejímu využití mohu jen se souhlasem UP Olomouc, která je oprávněna v takovém případě ode mne požadovat přiměřený příspěvek na úhradu nákladů, které byly UP Olomouc na vytvoření díla vynaloženy (až do jejich skutečné výše).

*Děkuji vedoucímu práce doc. RNDr. Jaroslavu Burianovi, Ph.D. za odborné vedení, podněty, připomínky, a především za cenné rady při tvorbě diplomové práce. Dále děkuji konzultantu Mgr. Karlovi Macků, Ph.D. za studijní materiály a poskytnuté rady při rozhodování během použití regresních modelů.*

*Za poskytnutá statistická data děkuji Ing. Mgr. Pavlovi Hájkovi (Krajská správa ČSÚ pro Středočeský kraj), Bc. Petrovi Langovi (Odbor pro sociální začleňování (Agentura) – Ministerstvo pro místní rozvoj ČR) a Ing. Václavu Jonáši (Vedoucí oddělení justiční analýzy a statistiky Odbor strategie a koncepce justice – Ministerstvo spravedlnosti ČR). Dále děkuji Radkovi Saňákovi (Odbor věcných gescí a statistik Úřadu služby kriminální policie a vyšetřování – Policejní prezidium České republiky), plk. PhDr. Ondřeji Moravčkovvi (Odbor komunikace a vnějších vztahů – Policejní prezidium České republiky) a Ing. Heleně Linhartové (odbor prevence kriminality – Ministerstvo vnitra) za odborné konzultace a poskytnutí informací. Poděkování náleží rovněž mým rodičům, celé rodině a přátelům za jejich neustálou důvěru a podporu po dobu celého studia.*

# UNIVERZITA PALACKÉHO V OLOMOUCI

Přírodovědecká fakulta

Akademický rok: 2021/2022

## ZADÁNÍ DIPLOMOVÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení: **Bc. Michal PLÁNKA**  
Osobní číslo: **R21854**  
Studijní program: **N0532A330009 Geoinformatika a kartografie**  
Téma práce: **Hodnocení vývoje kriminality Česka ve vztahu k vybraným socioekonomickým ukazatelům**  
Zadávající katedra: **Katedra geoinformatiky**

### Zásady pro vypracování

*Cílem práce je pro území Česka analyzovat kriminalitu a její vztah k vybraným socioekonomickým ukazatelům. V práci budou využita veřejně dostupná data o kriminalitě od Policie ČR za období od roku 2012 do současnosti. Kriminalita bude hodnocena jak souhrnným indexem, tak pomocí dílčích kategorií trestných činů. Vztah kriminality bude posuzován zejména k demografickým (např. index stáří) a ekonomickým (např. nezaměstnanost, blízkost škol, blízkost obchodních center) ukazatelům. Pro analytické zpracování dat bude využito především metod prostorové statistiky. Výstupem práce bude především hodnocení kriminality zpracované ohodnotnými vizualizačními metodami (grafy, mapy, mapová aplikace).*

*Celou práci, tj. text včetně všech příloh, posteru, výstupů, zdrojových i vytvořených dat, map, programových kódů a databázi, student odevdá v digitální podobě na paměťovém nosiči připevněném k deskám práce s popisem (jméno, název práce, Katedra geoinformatiky UP, rok). Text práce s přílohami odevdá ve dvou svázaných výtiscích na sekretariát katedry ve stanoveném termínu. O práci student vytvoří webovou stránku v souladu s pravidly dostupnými na stránkách katedry. Práce bude zpracována podle obecných zásad (Vozenílek, 2002) a závažné šablony pro kvalifikační práce na KGI. Povinnou přílohou práce je poster formátu A2.*

Rozsah pracovní zprávy: **max. 50 stran**  
Rozsah grafických prací: **dle potřeby**  
Forma zpracování diplomové práce: **tištěná**

#### Seznam doporučené literatury:

- Pánek, J.; Ivan, I.; Macková, L. (2019): Comparing Residents' Fear of Crime with Recorded Crime Data-Case Study of Ostrava, Czech Republic. ISPRS Int. J. Geo-Inf., 8, 401. DOI: 10.3390/ijgi8090401
- Ivan, I., Horák, J. (2018): Registered crime hot spots in Ostrava – Location, development and influencing factors. Geographical Journal/Geografický časopis, Vol. 70, No. 1, 3-21.
- Ivan, Igor & Kocich, David & Horak, Jiri. (2016). Identification of crime environmental factors based on spatial human data integration. SGEM 2016
- Ivan, Igor & Horak, Jiri. (2016). Metodika identifikace anomálních lokalit kriminality pomocí jádrových odhadů. GIS Ostrava 2016 – Geoinformatika pro společnost
- Horak, Jiri. (2016). Metodika tvorby multidimenzionální databáze pro prevenci kriminality. GIS Ostrava 2016 – Geoinformatika pro společnost
- Horak, Jiri. (2016). Metodika harmonizace, agregace a anonymizace dat kriminality. GIS Ostrava 2016 – Geoinformatika pro společnost
- Horak, Jiri. (2015). Metodika tvorby multidimenzionální databáze pro prevenci kriminality. Certifikovaná metodika.

Vedoucí diplomové práce: **doc. RNDr. Jaroslav Burian, Ph.D.**  
Katedra geoinformatiky

Datum zadání diplomové práce: 9. prosince 2021  
Termín odevzdání diplomové práce: 5. května 2023

UNIVERZITA PALACKÉHO V OLOMOUCI  
PŘÍRODOVĚDECKÁ FAKULTA  
KATEDRA GEOINFORMATIKY  
17. listopadu 50, 771 46 Olomouc

L.S.

doc. RNDr. Martin Kubala, Ph.D.  
děkan

prof. RNDr. Vít Voženílek, CSc.  
vedoucí katedry

V Olomouci dne 16. prosince 2021

# OBSAH

<b>SEZNAM POUŽITÝCH ZKRATEK .....</b>	<b>9</b>
<b>ÚVOD .....</b>	<b>10</b>
<b>1 CÍLE PRÁCE .....</b>	<b>11</b>
<b>2 METODY A POSTUPY ZPRACOVÁNÍ.....</b>	<b>12</b>
2.1 Použité metody a postup zpracování.....	12
2.1.1 Použitá data.....	17
2.1.2 Zdroje informací o kriminalitě .....	19
2.1.3 Mapa kriminality.....	20
2.2 Použité softwarové vybavení .....	25
<b>3 SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY .....</b>	<b>26</b>
3.1 Vymezení užitých pojmů .....	26
3.1.1 Vysvětlení pojmů z kriminologie a trestního práva .....	26
3.1.2 Kriminalita registrovaná a latentní .....	29
3.2 Geografie a výzkum vývoje a struktury kriminality .....	30
3.2.1 Prostorový analýzy kriminality v zahraničí.....	32
3.2.2 Prostorový analýzy kriminality v Česku .....	34
3.2.3 Mapování bezpečnosti .....	36
3.2.4 Charakteristika míry kriminality .....	37
<b>4 GEOGRAFICKÁ ANALÝZA KRIMINALITY V ČESKU.....</b>	<b>39</b>
4.1 Míra kriminality .....	39
4.1.1 Čistý a hrubý index kriminality .....	41
4.1.2 Vážený index kriminality .....	43
4.1.3 Analýza časového vývoje typů trestných činů.....	49
4.2 Závislé a nezávislé proměnné .....	52
4.2.1 Výběr nezávisle proměnných .....	52
4.2.2 Sestavení datasetu .....	54
4.2.3 Statistika dat nezávislých proměnných.....	54
4.2.4 Statistika dat závislé proměnné .....	55
4.3 Regresní modelování .....	57
4.3.1 OLS .....	58
4.3.2 Spatial Lag Model (SLM) a Spatial Error Model (SEM) .....	63
4.3.3 Geograficky vážená regrese (GWR).....	65
<b>5 VÝSLEDKY.....</b>	<b>75</b>
<b>6 DISKUZE .....</b>	<b>78</b>
<b>7 ZÁVĚR.....</b>	<b>81</b>
<b>POUŽITÁ LITERATURA A INFORMAČNÍ ZDROJE</b>	
<b>PŘÍLOHY</b>	



## SEZNAM POUŽITÝCH ZKRATEK

<b>Zkratka</b>	<b>Význam</b>
AIC	Akaike Information Criterion
ČR	Česká republika
ČSÚ	Český statistický úřad
ČÚZK	Český úřad zeměměřický a katastrální
Esri	Environmental System Research Institute
GIS	Geografický informační systém
GWR	Geographically Weighted Regression
IKSP	Institut pro kriminologii a sociální prevenci
MPSV	Ministerstvo práce a sociálních věcí
MPSV ČR	Ministerstvo práce a sociálních věcí České republiky
MŠMT ČR	Ministerstvo školství, mládeže a tělovýchovy České republiky
OLS	Ordinary Least Squares
PČR	Policie České republiky
PP ČR	Policejní prezidium České republiky
RÚIAN	Registr územní identifikace, adres a nemovitostí
SEM	Spatial Error Model
SHP	Shapefile
S-JTSK	Systém jednotné trigonometrické sítě katastrální
SLDB 2021	Sčítání lidu, domů a bytů 2021
SLM	Spatial Lag Model
TSK	Takticko-statistická klasifikace
TZ	Zákon č. 40/2009 Sb., trestní zákoník, ve znění pozdějších předpisů
ÚP ČR	Úřad práce České republiky
VIF	Variance Inflation Factor

# ÚVOD

Bezpečnost je jedním z aspektů, které zásadním způsobem ovlivňují kvalitu lidského života. Pocit bezpečí patří mezi základní podmínky spokojeného a plnohodnotného života. Tuto potřebu však do značné míry ohrožuje zločinnost neboli kriminalita.

Kriminalita je bezesporu nejnebezpečnějším významným sociálně patologickým jevem, který ovlivňuje řadu aspektů fungování společnosti i života každého člověka. Je tedy součástí našeho života z velké části nezávisle na tom, zda chceme, nebo nechceme. Netřeba být jejím přímým účastníkem, avšak přesto ji vnímáme např. prostřednictvím médií či ze zkušenosti ostatních lidí. Jedná se o jev dynamický, jehož obsah i rozsah se mění v závislosti na čase a prostoru a který vždy žije v symbióze s dalšími, z hlediska společnosti méně nebezpečnými, sociálně patologickými jevy. Kriminalita spadá mezi relevantní společenské jevy a zároveň představuje zásadní výzkumné interdisciplinární témata, která jsou předmětem výzkumu napříč obory jako jsou např. kriminologie, sociologie, sociální geografie, psychologie či trestní právo. Kriminalita je neodmyslitelně vázána s dalšími patologickými jevy, jako např. s mírou chudoby, zdravím, bydlením, vzděláním či občanskými právy. Jedná se tak o jeden z klíčových projevů sociální deprivace (Pacione, 2005). Studium kriminality představuje významné téma z vědeckého hlediska, avšak s přesahem do praktického využití. Neboť znalostí kriminality v teritoriu je možné činit preventivní opatření proti konkrétní trestné činnosti. To lze zjistit geografickým výzkumem kriminality.

Bylo by zajímavé zjistit vztah kriminality vůči socioekonomickým ukazatelům, které mohou být součástí kriminogenních faktorů, tj. rizikových činitelů, jež vyvolávají, usnadňují nebo podporují páčání trestných činů. Je překvapující, že dosud nebyla v Česku zkoumána míra kriminality ve vztahu k socioekonomickým statistickým ukazatelům v geografickém kontextu užitím prostorových statistických regresních modelů ve spolupráci s geografickými informačními systémy na úrovni obcí. V kvantitativním studiu kriminality se již ustálilo pozorování, že mnoho druhů trestné činnosti není v geografickém prostoru distribuováno náhodně (Brantingham, et Brantingham, 1981). Dlouhodobou výzvou ve výzkumu geografie kriminality je analýza na úrovni malého prostorového měřítka. Právě měřítková úroveň sledování je klíčovou při analýzách kriminality (Nemeškal et. Jíchová, 2018). Snahou je tedy zachytit prostorovou distribuci kriminality v maximálně nejpodrobnějším detailu. Tato práce reflektuje potřebu výzkumu kriminality v detailním prostředí, a sice na úrovni obcí, což činí tuto práci v českém kontextu výjimečnou a dosud unikátní i z hlediska použitých metod a datové sady. K tomu přispěla také úspěšná realizace projektu *Mapy budoucnosti II*, díky níž jsou v současnosti zveřejňována detailní prostorová data kriminality prostřednictvím webové mapové aplikace *Mapa kriminality*.

# 1 CÍLE PRÁCE

Cílem práce je pro území Česka provést časoprostorovou analýzu kriminality vzhledem k vybraným socioekonomickým ukazatelům. V práci budou využita veřejně dostupná prostorová data o kriminalitě od Policie ČR za období od roku 2012 do současnosti. Kriminalita bude hodnocena jak souhrnným indexem, tak pomocí dílčích kategorií trestných činů. Vztah kriminality bude posuzován zejména k demografickým (např. index stáří) a ekonomickým (např. nezaměstnanost, blízkost škol, blízkost obchodních center) ukazatelům. Pro analytické zpracování dat bude využito především metod prostorové statistiky. Výstupem práce bude především hodnocení kriminality zpracované vhodnými vizualizačními metodami (grafy, mapy, mapová aplikace). Výsledky práce umožní čtenáři porozumět specifikům prostorových či statistických vztahů kriminality vůči vybraným socioekonomickým a demografickým faktorům v kontextu geoinformatiky a geografie.

Celou práci, tj. text včetně všech příloh, posteru, výstupů, zdrojových i vytvořených dat, map, programových kódů a databází, student odevzdá v digitální podobě na paměťovém nosiči připevněném k deskám práce s popisem (jméno, název práce, Katedra geoinformatiky UP, rok). Text práce s přílohami odevzdá ve dvou svázaných výtiscích na sekretariát katedry ve stanoveném termínu. O práci student vytvoří webovou stránku v souladu s pravidly dostupnými na stránkách katedry. Práce bude zpracována podle obecných zásad (Voženílek, 2002) a závazné šablony pro kvalifikační práce na KGI. Povinnou přílohou práce je poster formátu A2.

## 2 METODY A POSTUPY ZPRACOVÁNÍ

### 2.1 Použité metody a postup zpracování

Úvodním krokem řešení práce bylo provedení literární rešerše za účelem hlubšího porozumění nesmírně široké problematice v oblasti hodnocení kriminality. Další krok spočíval v nalezení vhodného zdroje veřejně dostupných prostorových dat o kriminalitě za požadované období s největší možnou prostorovou podrobností v kontextu Česka.

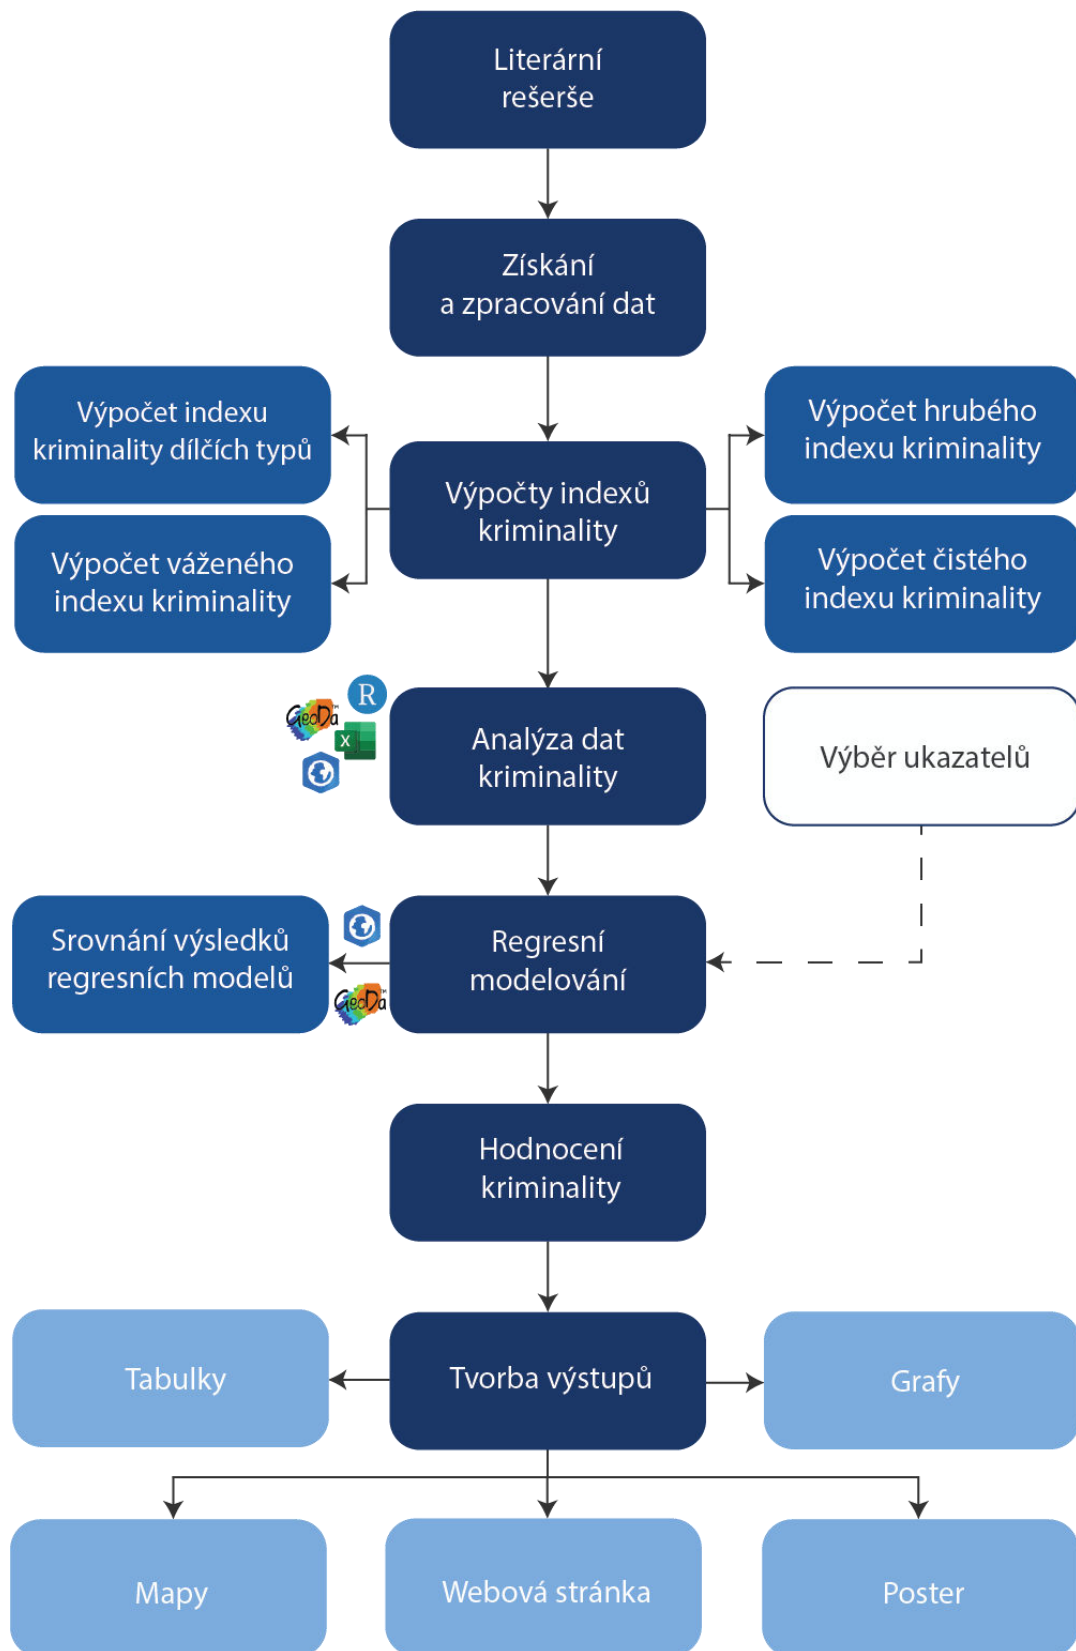
V praktickém řešení naplnění cílů práce byla aplikována celá řada metod. Za účelem prostorové analýzy kriminality proběhlo seznámení se s daty a následovalo zpracování prostorových bodových dat kriminality mj. agregací dat na úrovni obcí, což vedlo k výpočtům souhrnných indexů kriminality v obcích Česka za roky 2016 až 2021. Mezi vypočtené souhrnné indexy kriminality náleží hrubý index kriminality a čistý index kriminality podle dělení Kuchty et Válková (2005). V této praktické části práce bylo snahou vytvořit inovativní výpočet váženého indexu kriminality na základě přiřazení patřičných vah trestným činům podle průměrné doby odnětí svobody (nepodmíněného trestu) za sledovaný rok 2021. Pozornost byla věnována i analýze dílčích kategorií trestných činů.

Další významnou částí práce bylo posouzení vztahu kriminality k vybraným socioekonomickým ukazatelům. Pro tento účel byly použity metody prostorové statistiky, jako jsou regresní modely – Ordinary Least Squares (OLS) a jejich prostorové varianty – Spatial Lag Model (SLM), Spatial Error Models či geograficky vážené regrese (Geographically Weighted Regression – GWR). Charakteristika modelů je stručně popsána v závěru této podkapitoly.

Volba demografických a ekonomických ukazatelů byla uskutečněna v závislosti na dostupnosti a aktuálnosti statistických dat požadované prostorové úrovně. Dalším kritériem pro volbu konkrétních statistických ukazatelů byla zmínka jejich přítomnosti v některých ze zkoumaných studií a autorovým subjektivním posouzením vhodnosti s ohledem na výsledky explorační analýzy vstupních dat.

Závěrečná část práce syntetizuje získané poznatky nalezení prostorových vztahů kriminality především z výsledků aplikace prostorových statistických modelů. Syntézou výsledků prostorových analýz je hodnocení kriminality ve vztahu k vybraným socioekonomickým ukazatelům. Dílčí výsledky hodnocení kriminality (tj. souhrnné indexy kriminality, jednotlivé kategorie trestných činů, nalezení prostorových vztahů vzhledem k vybraným socioekonomickým ukazatelům) byly zachyceny vhodnou prostorovou vizualizací sérií několika map užitím metody pseudokartogramu umožňující kvantitativní srovnávání jednotlivých dílčích územních celků (Voženílek et Kaňok, 2011), neboť forma geovizualizace ve srovnání s číselnými hodnotami, tabulkami či grafy, dokáže přehledně zobrazit požadovanou prostorovou variabilitu vztahu. Výstupy ve formě tabulek a grafů jsou rovněž zahrnuty jako součást diplomové práce.

V důsledku náročnosti funkcionality prostorových statistických modelů je interpretace jejich výsledků a koeficientů značně obtížná (Marek, 2015). Z tohoto důvodu autor této diplomové práce přistupoval k interpretaci výsledků hodnocení kriminality s maximální možnou obezřetností. Grafická vizualizace postupu zpracování je patrná z obr 1.



Obr. 1 Postup zpracování. Zdroj: vlastní.

## Regresní analýza

Regresní modelování má za cíl analyzovat vztah mezi vysvětlovanou závislou (vysvětlovanou) proměnnou a jednou nebo více nezávislými (vysvětlujícími) proměnnými (prediktory). Tento postup umožňuje odhadnout vliv prediktorů na sledovanou proměnnou. Lineární regresní model je nejjednodušší formou regresní analýzy, kdy je vztah mezi proměnnými aproximován lineární funkcí (tj. přímkou, která nejlépe popisuje datovou sadu). Geometricky se tak jedná o úsečku, která nejlépe prochází množinou bodů v rovině. Vztah je definován v rovnici 1:

$$y = \beta_0 + \beta_1 x + \varepsilon \quad [1]$$

,kde  $y$  je sledovaná proměnná,  $\beta_0$  je úrovněová konstanta,  $\beta_1$  regresní koeficient proměnné  $x$  a  $\varepsilon$  je vektor náhodné chyby měření.

Prostorové regresní metody rozšiřují klasické regresní modely tím, že zohledňují prostorovou strukturu dat, která často vykazuje nedostatek nezávislosti mezi měřeními provedenými na blízkých místech. Existuje několik různých přístupů k prostorovým regresním analýzám. Obvykle se využívají dva základní přístupy: globální řešení pomocí explicitní formy prostorové autokorelace pro zohlednění celkového vlivu prostorové závislosti a místní řešení umožňující modelování prostorově proměnných parametrů (tj. geograficky vážené regrese) na lokální úrovni. Globální řešení přímo hodnotí prostorovou složku dat (často jako nezávislou proměnnou) a zahrnuje ji do návrhu modelu. Pro teoretické základy týkající se prostorových regresních lze využít odborné publikace jako jsou například Anselin (1988, 2002), LeSage (1998), Haining (2003), Elhorst (2010), Smith et al. (2018), Ivan (2014) a Horák (2019). Tyto publikace poskytují ucelený přehled o tématu a poskytují řadu užitečných informací, které mohou být relevantní pro aplikaci regresních modelů. Ačkoli čistý prostorový autoregresní model se týká autoregrese závislé proměnné, jak uvádí LeSage (1998), jiní autoři upozorňují na společné autoregresní rysy i v jiných modelech, včetně prostorového chybového modelu, jak naznačují Smith et al. (2018). Elhorst (2010) zavádí jednotný koncept globálních modelů prostorové závislosti, který vysvětluje vazby mezi těmito modely. Prostorový lag model, angl. Spatial Lag Model (SLM), (neboli smíšený regresní prostorový autoregresní model podle Smitha et al. (2018) zahrnuje složky standardního regresního modelu  $X\beta$  (kde  $X$  je vektor nezávislých proměnných a  $\beta$  jsou regresní koeficienty) a také prostorově zpožděnou verzi závislé proměnné  $y$  (rovnice 2) s vektorem prostorových autoregresních parametrů  $\rho$ , váhovou maticí  $W$  a vektorem chyb  $\varepsilon$ .

$$y = X\beta + \rho W y + \varepsilon \quad [2]$$

Prostorový chybový model, angl. Spatial Error Model (SEM) je definován rovnicí 3, která zahrnuje prostorové autoregresní parametry  $\lambda$  pro chyby a vektor jednotkových chyb, jak uvádí Smith et al. (2018). Prostorová autokorelace se nezahrnuje do modelu jako samostatná proměnná, ale ovlivňuje kovarianční strukturu náhodných chybových členů (Anselin, 2002).

$$y = X\beta + \varepsilon; \quad \varepsilon = \lambda W \varepsilon + u \quad [3]$$

Prostorový chybový model je volen tehdy, pokud se zdá, že existuje statisticky významná prostorová autokorelace, avšak testy prostorových zpožděných efektů neposkytují dostatečné důkazy pro zahrnutí těchto efektů. Simionescu (2014) vysvětluje, že model prostorového zpoždění je vhodnější v situacích, kdy nepozorované proměnné nemají statisticky významný vliv, zatímco model prostorové chyby je upřednostňován, pokud jsou nepozorované proměnné relevantní. Nicméně, tyto modely jsou kritizovány za svůj univerzální přístup (Weisent et al., 2012).

### **Metoda OLS (Ordinary Least squares)**

Metoda OLS představuje nejjednodušší a často používaný způsob k odhadu koeficientů rovnice přímky. Tato metoda se používá pro vícenásobné lineární modely a snaží se nalézt takové regresní koeficienty, které minimalizují součet kvadrátů reziduí. Zkratka OLS bude dále v textu využívána pro označení vícenásobného lineárního modelu řešeného metodou nejmenších čtverců. Pokud jsou dvě nebo více proměnných podobné, mohou být výsledky získané pomocí (OLS) nespolehlivé. Podrobnější informace o interpretaci OLS regrese lze nalézt v publikaci Anděl (1993). OLS je definován rovnicí 4:

$$y = \beta_0 + \beta_1 x + \varepsilon \quad [4]$$

OLS umožňuje vyhodnotit celkovou výkonnost modelu a poukázat na vliv prostorové složky (heteroskedasticita, nestacionarita, prostorová autokorelace reziduí, aj.). Dále umožňuje identifikovat prediktory s globální multikolinearitou. Pro vyhodnocení globální multikolinearity se často používá Variance Inflation Factor neboli faktor zvětšení rozptylu (VIF). Tento ukazatel udává, nakolik je rozptyl odhadovaných regresních koeficientů zvětšen ve srovnání se situací, kdy by prediktory byly vzájemně nezávislé. Prediktory s hodnotami VIF větší než 5, 7,5 či 10 by podle odborníků Ma a Gopal (2018) nebo Akinwande et al. (2015) měly být eliminovány z důvodu vážné multikolinearity. Je však třeba si uvědomit, že interpretace VIF by neměla být prováděna izolovaně, ale v kontextu (např. s ohledem na statistickou významnost prediktorů). Existují další faktory, které mohou ovlivnit stabilitu regresních koeficientů, včetně velikosti vzorku, podílu rozptylu závislé proměnné spojeného s nezávislými proměnnými a rozptylu nezávislé proměnné. Tyto faktory mohou buď zmírnit nebo zhoršit účinky multikolinearity (O'Brien, 2007).

### **Metoda geograficky vážené regrese (GWR)**

Metoda GWR byla zavedena Brundsonem et al. (1996) pro regresní modely, které umožňují prostorovou variabilitu koeficientů  $\beta$ . Koeficienty  $\beta(t)$  jsou vyhodnocovány pro každý cílový bod (tj. centroid polygonu) pomocí prostorově vážené regrese metodou nejmenších čtverců na množinu bodů v poloměru  $r$ . Místo fixní hodnoty pro  $r$  je použita funkce distance-decay  $f(d)$  – Gaussova, bilineární nebo kubická. Optimalizace výsledků je dosažena úpravou šířky pásma, která se často provádí experimentálně na základě minimalizace hodnoty Akaikeho informačního kritéria (Akaike Information Criterion – AIC) (Weisent et al., 2012; Ma, Gopal 2018).

Metoda GWR tedy rozšiřuje tradiční regresní rámec o pohyblivé regresní parametry, které umožňují odhadovat jejich lokální podobu. Tato metoda umožňuje aplikaci obecného regresního modelu na prostorově proměnná data, kde lze předpokládat prostorovou variabilitu regresních parametrů. GWR tak nabízí nový přístup k modelování

prostorových dat, který umožňuje lépe zachytit lokálně specifické (prostorové) vzorce a vztahy. Matematický zápis modelu (rovnice 5) GWR lze charakterizovat vztahem (Smith et al., 2018):

$$y = X\beta(t) + \varepsilon \quad [5]$$

Prostorová data mají své specifické vlastnosti, které je třeba brát v úvahu při jejich analýze. Charakteristiky jsou přehledně shrnuty v tabulce 1. Specifické vlastnosti zahrnují potřebu použití odlišných statistických metod a modelovacích přístupů, stejně jako citlivou interpretaci výsledků kvantitativních analýz na agregaci dat, což se týká způsobu vymezení prostorových jednotek ve spojení s ekologickou chybou, prostorovou autokorelací a prostorovou nestacionaritou (Spurná, 2008). Prostorová data mají odlišné charakteristiky ve srovnání s běžnými daty, protože obsahují prostorový kontext a závislosti mezi sousedními jednotkami. Toto zahrnuje faktory jako geografickou polohu, vzdálenost, interakce a další prostorové vztahy mezi prostorovými daty. Tyto faktory mohou ovlivnit výsledky analýzy a vyžadují použití specifických statistických metod a technik, které jsou navrženy pro prostorová data. Je tedy důležité, aby analýza prostorových dat byla provedena s ohledem na tyto specifické vlastnosti a využívala vhodné statistické metody a techniky.

Tab. 1 Specifika analýzy prostorových dat. Zdroj: Upraveno podle Spurné (2008).

Aspekt	Význam	Příklad metod
ekologická chyba (agregace dat a určenost prostorových jednotek)	vztah získaný při jednom způsobu agregace dat, tzn. v jednom souboru prostorových jednotek, se neuplatňuje ve všech dalších a není univerzální – nemožnost odvození individuálního chování jedinců z analýzy agregátních dat	ekologická regrese a metoda hranic, metoda maximalizace entropie, Kingova metoda, víceúrovňové modely
prostorová autokorelace (závislost)	závislost výskytu určitého jevu v prostoru na výskytu tohoto jevu v blízkém okolí – porušení základního předpokladu obecného lineárního modelu a řady standardních parametrických statistických testů, že jednotlivá pozorování jsou navzájem nezávislá či nekorelovaná	Moranovo I kritérium, Gearyho C kritérium, analýza LISA, obecná G statistika, lokální G statistika
prostorová nestacionarita a heterogenita	nestabilita zkoumaných jevů a vztahů v prostoru – odlišnost funkčních vztahů mezi proměnnými v různých prostorově vymezených oblastech, nestabilita regresních funkcí	metoda regrese pohyblivých oken (moving window regression), metoda geograficky vážené regrese (GWR)



### 2.1.1 Použitá data

Pro účely geostatistické analýzy byla nutná akvizice požadovaných dat za sledované období pro specifické charakteristiky, která odpovídají požadavkům prostorového modelování a jsou v rámci možností dostatečně kvalitní a prostorově detailní. Diplomová práce vzhledem ke komplexnímu zaměření, které propojuje strukturu zjištěné trestné činnosti s vysvětlujícími charakteristikami, využívá dva základní typy datových zdrojů, a sice data o trestné činnosti za období 2012 až 2021 a socioekonomická data za obyvatelstvo v roce 2021. Hlavním zdrojem poskytující informace o demografické a socioekonomické struktuře je Český statistický úřad (ČSÚ), který poskytuje mj. data pocházející ze Sčítání lidu, domů a bytů v roce 2021 (SLDB 2021). Získaná socioekonomická statistická data svou kvalitou, kvantitou a také prostorovou podrobností zcela vyhovují požadavkům pro jejich využití v geostatistických analýzách. Kromě ČSÚ posloužily zdroje dat poskytnuté Exekutorskou komorou ČR, Ministerstvem školství, mládeže a tělovýchovy České republiky (MŠMT ČR), Úřadem práce České republiky (ÚP ČR) a Ministerstvem práce a sociálních věcí České republiky MPSV ČR. Seznam vybraných socioekonomických dat je patrný z tabulky 2.

V České republice existují dva oficiální registry exekucí, konkrétně Centrální evidence exekucí, kterou spravuje Exekutorská komora České republiky, a Rejstřík zahájených exekucí, který je spravován Ministerstvem spravedlnosti. Oba tyto registry však nezahrnují exekuce správní a daňové povahy, což způsobuje, že v České republice chybí podstatné informace o celkovém počtu probíhajících exekučních řízení (Beran et Říhová, 2017).

Prostorová data o kriminalitě pochází z evidence spáchané trestné činnosti Policie České republiky, která jsou dostupná prostřednictvím portálu na adrese <<https://kriminalita.policie.cz>>.

Pro analytické účely byly za prostorovou administrativní jednotku vybrány obce ze čtyř následujících důvodů:

1. prostorové analýzy v poměrně podrobném prostorovém měřítku
2. dostatečné množství statistických charakteristik a záznamů
3. dostupnost a aktuálnost dat
4. obce jsou v mnoha případech lukrativním kompromisem mezi detailností geoanalýzy a zachováním anonymity jednotlivých případů trestných činností.

Použití prostorových polygonových dat administrativního členění (obce, SO ORP, kraje, stát) vychází z otevřené datové sady RÚIAN (Registru územní identifikace, adres a nemovitostí). Data RÚIAN jsou vytvářena každý den (pokud došlo v některém prvku obce ke změně). Předpřipravené soubory jsou generovány jednou měsíčně a jsou k dispozici ve formátu Shapefile (ČÚZK, 2021) vyvinutou firmou Environmental Systems Research Institute (Esri) v souřadnicovém systému jednotné trigonometrické sítě katastrální (S-JTSK). V práci byla použita data RÚIAN, jež přísluší k datu 4. 2. 2022 a odpovídají prostorovému měřítku 1 : 5 000. Data poskytuje Český úřad zeměměřický a katastrální (Geoportál ČÚZK, 2022).

Tab. 2 Přehled použitých socioekonomických dat (aktuálnost k roku 2021). Zdroj: vlastní.

Demografická struktura		Ekonomická struktura	
Charakteristika	Zdroj dat	Charakteristika	Zdroj dat
Počet obyvatel (podle pohlaví)	ČSÚ	Exekuce	Exekutorská komora ČR
Věková struktura	ČSÚ SLDB 2021	Příspěvky na bydlení (PnB)	MPSV
Vystěhovalí	ČSÚ	Uchazeči o zaměstnání	ÚP ČR
Přistěhovalí	ČSÚ	Osobní bankroty (insolvence)	Insolvenční rejstřík
Zemřelí	ČSÚ		
Živě narození	ČSÚ		
Vzdělanost	ČSÚ SLDB 2021		
Předčasné odchody z běžných tříd ZŠ	MŠMT		
Národnost	ČSÚ SLDB 2021		
Náboženská víra	ČSÚ SLDB 2021		
Rodinný stav	ČSÚ SLDB 2021		
Potratovost	ČSÚ SLDB 2021		
Plodnost	ČSÚ SLDB 2021		
Volby do Poslanecké sněmovny	ČSÚ		

Český statistický úřad (ČSÚ),

Sčítání lidu, domů a bytů 2021 (SLDB 2021),

Ministerstvo školství, mládeže a tělovýchovy České republiky (MŠMT ČR),

Úřad práce České republiky (ÚP ČR),

Ministerstvo práce a sociálních věcí České republiky (MPSV ČR).

## 2.1.2 Zdroje informací o kriminalitě

K prostorovému výzkumu kriminality je nutný zdroj informací o její četnosti, poloze a struktuře. Tyto zdroje mohou být oficiálního i neoficiálního původu. Nejpřesnější a nejucelenější obraz o kriminalitě podává statistika Policejního prezidia ČR (PP ČR). Statistika se dělí na Evidenčně statistický systém kriminality (ESSK) a Statistiku služby dopravní policie. Data ESSK využívá ve svých výstupech i Český statistický úřad (ČSÚ). Bezplatně poskytovaná data PP ČR o kriminalitě jsou formou měsíčních statistických přehledů vykazována souhrnně za celou ČR. Lze v nich nalézt informace o počtech registrovaných deliktů, objasněných, objasněných dodatečně, objasněných celkem, škodě a zajištěných hodnotách na místě. U objasněných skutků jsou poskytovány informace o druzích podezřelých pachatelů (nezletilý, mladistvý, dítě, opakovaně trestaná osoba, cizinec, spácháno pod vlivem, spácháno pod vlivem alkoholu). Data jsou poskytnuta souhrnně za jednotlivé třídy TSK (takticko-statistické klasifikace a klasifikována dle dílčích krajů ČR. Nevýhodou je absence dostupnosti jednotlivých deliktů či nižší administrativní členění než na kraje. Statistiky jsou dostupné na webových stránkách Policie ČR (PČR) – <https://www.policie.cz/statistiky-kriminalita.aspx>. Nutno upozornit, že se jedná o data o zjištěné trestné činnosti, tedy o skutcích, o nichž se policie dozvěděla (Válková, 2012).

Kriminalita u nás i v zahraničí je primárně sledována resortními statistickými orgány činnými v trestním řízení. Zásadním problémem je skutečnost, že tyto statistiky vykazují obsah pouze o evidované kriminalitě, a tak veškeré analýzy, pro které jsou základním zdrojem resortní statistiky, jsou informacemi jen o kriminalitě registrované orgány činnými v trestním řízení a o známých (zjištěných) pachatelích (Marešová, 2011). Jichová (2013) upozorňuje, že před interpretací datových výstupů statistik kriminality je nutno vzít na vědomí, že použitá data informují pouze o kriminalitě registrované, tj. nikoliv o veškeré spáchané kriminalitě, jejíž součástí je latentní kriminalita – nezachycená statistikami (Marešová a Scheinost, 2001). U některých trestných činů může i několikanásobně převyšovat zjištěný počet trestných činů. Signifikantní vliv na analýzy představují změny zákonů a legislativy, jež mohou způsobit výkyvy ve statistikách kriminality (Jichová, 2013). Před analýzou je nezbytné se seznámit s metadaty, jež by měly správně obsahovat informace o sběru dat a jejich charakteristiku. Před použitím dat o kriminalitě je rovněž nezbytné samotné prvotní posouzení, zda se jedná o přestupek či trestný čin (mj. Kamenický 2007).

Na webových stránkách PČR jsou pravidelně dle měsíčních intervalů zveřejňovány *Policejní statistiky*, které na rozdíl od statistik odboru informatiky Ministerstva spravedlnosti nedisponují informacemi o trestných činech dělených dle dílčích hlav trestního zákoníku. Rozdělení dat probíhá podle takticko-statistické klasifikace (TSK). Dílčí část statistiky je agregace skutků dle TSK do několika skupin. Hlavní zastoupení má kriminalita obecná, která je dále dělena do čtyř podskupin, a to na kriminalitu násilnou, mravnostní, majetkovou a ostatní. Na stejné úrovni s kriminalitou obecnou je pak kriminalita hospodářská, vojenské a protiústavní činy a kriminalita zbývající. Toto dělení umožňuje u některých skutků dostupnost informací o jejich skutečné podstatě, kdy např. trestný čin krádeže je dále rozdělen na krádež vloupáním a krádež v prostoru, které jsou následně více specifikovány. Mj. ošetřuje kompaktnost informací ve statistice obsažených i přes legislativní změny, což se výrazně projevilo v roce 2010, kdy začal platit nový trestní zákoník (Trnková, 2019).

Užitečným zdrojem informací o kriminalitě bývala v minulosti po dlouhou dobu *Statistická ročenka kriminality* zpracovávaná Ministerstvem vnitra České republiky (MV ČR). Zahrnovala statistiku státních zastupitelství a soudů, obsahovala údaje o známých pachatelích, obžalovaných osobách a pravomocně odsouzených a evidovala rovněž počet trestných činů. Poslední ročenka byla publikována za rok 2016, poté MV ČR v tomto směru ukončilo činnost, avšak v současné době je každoročně zveřejňována *Zpráva o situaci v oblasti vnitřní bezpečnosti a veřejného pořádku na území ČR*, která je schvalována vládou ČR (Trnková, 2019).

Data o kriminalitě poskytují i jiné instituce. Statistická data Vězeňské služby ČR, související s výkonem nepodmíněného trestu odnětí svobody a vazby, zpracovává a publikuje odbor Generálního ředitelství služby ČR. Obsahuje demografické údaje a informace související se zajišťováním výkonu vazby a výkonu trestu odnětí svobody. Kriminologický význam mají především údaje o obviněných a odsouzených (dle typu věznice, délky trestu, předchozích odsouzeních. Ministerstvo práce a sociálních věcí (MPSV) zveřejňuje informace o sociálně-právní ochraně dětí. Nelze opomenout Český statistický úřad (ČSÚ), jenž nabízí data o kriminalitě, resp. nehodách prostřednictvím Veřejné databáze ČSÚ a mimo data zprostředkovává odborné analýzy a komentáře o kriminalitě. Nevýhoda odlišných zdrojů dat, resp. jednotlivých statistik, spočívá v absenci shodné systematiky a terminologie. V důsledku toho mnohdy nelze exaktně vzájemně porovnávat související informace (Trnková, 2019).

### **2.1.3 Mapa kriminality**

Na základě realizace projektu *Mapy budoucnosti II* je pro veřejnost připravena aplikace *Mapy kriminality*, která obsahuje veřejně dostupná data o přestupcích a vybraných druzích trestných činů od roku 2012 až do současnosti. Primárním zdrojem následujících informací o *Mapě kriminality* jsou informace dostupné na jejím webu v sekci *Nápověda k aplikaci* <<https://kriminalita.policie.cz/napoveda/#/>> (Mapa kriminality, 2022). Jedná se o „Open data“, neboli otevřená data, tj. data jež některé instituce, státní organizace a další subjekty snažně poskytují veřejnosti v takové formě, aby bylo možné je svobodně užít k jakýmkoliv účelům (Kočvarová, 2020). Autorizovaný uživatel získá základní přehled o deliktech, které jsou evidovány za dané časové období. Data lze filtrovat dle období či druhu evidovaných skutků. Aplikace primárně slouží k rychlému přehledu o dění v místně příslušné obci za vybrané období. Nejedná se o standardní statistická data, která každý měsíc zveřejňuje PČR, ale o reálné zobrazení situace a z toho generovaný přehled. Aplikace je tedy primárně určena obcím a jejím občanům sledovat vybrané registrované trestné činy a přestupky na území obce s určením místa skutku. Data jsou tak veřejně publikována široké veřejnosti za účelem sdílení informací o kriminalitě. Aplikace nachází praktické uplatnění v reciprokém sdílení dat mezi Policií ČR a obcemi, resp. jejich městskými policiemi. Neboť sdílení dat a jejich analýza náleží mezi základní principy politiky prevence kriminality (Kolaříková, 2017). Do doby vytvoření aplikace probíhala tato výměna dat zejména osobní formou. Formální sdílení dat může být zakotveno v koordinačních dohodách mezi konkrétní obcí a místním nebo územním oddělením PČR, není však nijak automatizováno, tzn. dochází k předávání informací v různém rozsahu a obsahu dle osobního uvážení zapojených osob. Předávaná data vychází zejména ze statistických přehledů o kriminalitě zpracovávaných PP ČR, případně z aktuálních dat dostupných ve vnitřních evidencích PČR.

Obce mohou prostřednictvím aplikace *Mapa kriminality* vzájemně sdílet či vkládat svá data o přestupcích registrovaných na území obce městskou policií či jinými orgány obce. Vkládání dat je umožněno jak po jednotlivých skutcích, tak automatizovaně. Obce, které nemají evidenční systém přestupků, mohou využít kartu *Přestupky* a zde vkládat jednotlivé skutky. Data mohou zpětně editovat a zároveň s nimi pracovat stejně jako s ostatními daty – filtrovat, třdit atd. Nemělo by jít o duplicitní vedení evidence, ale o nástroj pro ty, kteří žádný systém nemají. Vložená data se v aplikaci zobrazí po dvou hodinách od vložení, případné následné smazání se projeví po 24 hodinách. Nechybí ani funkce automatizovaného importu prostřednictvím Application Programming Interface (API) – datové rozhraní pro přístup k datům. Použití API a všechna data podléhají licenci *Creative Commons BY-NC-SA* (Mapa kriminality, 2022). Aplikace je dostupná na internetu přes webový prohlížeč na adrese: <<https://kriminalita.policie.cz>>.

Prostorová data o kriminalitě (na úrovni obvodních oddělení, územních odborů, krajů nebo ČR lze bezplatně získat využitím veřejně dostupné webové aplikace *MAPAKRIMINALITY*. Jedná se o projekt Otevřené společnosti, o.p.s, dostupný z: <<https://www.mapakriminality.cz>>. Stránky *Mapy kriminality* vytvořila a provozuje ProPolice/Otevřená společnost, o.p.s., ve spolupráci s Geographics.cz, za podpory programu *Think Tank Fund* nadace *Open Society Foundations* a společnost *Webtica Software*. Cílem projektu je poskytnout veřejnosti přístup a orientaci v datech o trestné činnosti, která je vytvořena z pravidelně publikovaných statistických dat PČR v měsíčních intervalech (Svatoš, 2014). Policejní statistiky jsou zde převáděny do jednoduchých tabulkových a mapových náhledů. Data o kriminalitě jsou poskytována od začátku roku 2013 až po listopad roku 2020. Základním nástrojem pro srovnání mezi jednotlivými kraji či územními odbory je tzv. index kriminality – počet zjištěných skutků za zvolené období, přepočtený na 10 000 obyvatel (MAPAKRIMINALITY, 2022).

### **Evidenčně statistický systém kriminality (ESSK)**

Úřad služby kriminální policie a vyšetřování Policejního prezidia prostřednictvím odboru věcných gesčí a statistik vede Evidenci statistického systému kriminality (dále ESSK). ESSK je počítačový systém vedený na Policejním prezidiu obsahující údaje z formulářů o trestném činu, známém pachateli (včetně deliktů dětí ve věku 6–15 let vykazujících znaky trestného činu) a formuláře změn. Ve výkazu je považována nikoli doba spáchání, ale okamžik zjištění. Jedná se tedy o komplexní systém rozčleňující druhy trestné činnosti do číselné škály tzv. takticko-statistické klasifikace (TSK), kterou využívá PČR. TSK je strukturovaná policejní statistika, ve které jsou znázorňeny jednotlivé delikty. Jednou ze základních jednotek ESSK je *skutek*, kterým se rozumí jednání osoby nezletilé, mladistvé nebo dospělé, jenž vykazuje znaky trestného činu, provinění nebo činu jinak trestného podle právních předpisů (SURMAR, 2013). Registrovaná kriminalita je v rámci TSK členěna do několika tříd. Z těchto dílčích tříd je dále tvořeno devět souhrnných kategorií. Jednotlivé kategorie trestných činů podle TSK jsou k nalezení v příloze č. 3 (platné k září 2022).

ESSK ve svých statistických výstupech neeviduje přestupky. Význam ESSK pro účely kriminologie a praktické kriminalistiky je v kontextu relevantních zdrojů dat o stavu, struktuře a dynamice kriminality nezastupitelný. Jedná se o významný informační zdroj o kriminalitě coby hromadném jevu (Novotný et Zapletal, 2004).

## **Vztah ESSK k trestnímu zákoníku**

Základem ESSK pro rozlišení jsou kriminalistická hlediska, která jsou zpravidla stálá, neměnná a sledovatelná kontinuálně. TSK je tak nezávislá na kvalifikaci dle trestního zákoníku – paragrafu. To znamená, že ESSK nečlení trestnou činnost podle paragrafových znění trestního zákoníku, naopak do TSK. Jedno TSK může zahrnovat více paragrafů, a naopak jeden paragraf může být statisticky rozčleněn na více TSK. Toto členění zajišťuje kontinuitu sledování, neboť trestní zákoník a jeho číselná označení paragrafů podléhají častějším změnám v závislosti na novelizacích trestního zákoníku, ale druh (klasifikace) trestné činnosti zahrnutý podle TSK (např. vloupání do rodinného domu) zůstává více neměnný (Mapa kriminality, 2022; Novotný et Zapletal, 2004). Je tak umožněna i meziroční komparace dat se zachováním základních funkčních pilířů ESSK i přes určité změny legislativy. Ukázka změn TSK je k dispozici v příloze č. 4., jež byla laskavě poskytnuta Ing. Helenou Linhartovou z oddělení preventivních činností a dobrovolnictví Odboru prevence kriminality MV ČR.

Následující informace vychází z obsahu příloh Mapy kriminality (2022).

### **Projekt Mapy budoucnosti II**

PČR bere na vědomí, že prostorová data kriminality představují velký potenciál pro užší spolupráci s veřejností. Nicméně v současné době není PČR ochotna vydávat veškrá anonymizovaná data o lokalitách trestných činů a přestupků. Policejní GIS pracoviště nejsou gestorem za zpracování požadavků na základě zákona (č. 106/1999 Sb.) o svobodném přístupu k informacím. V současné době není možné vydávat kompletní export lokalit trestných činů. V souladu se stávající legislativou by bylo nutné posuzovat individuálně každý případ od případu za účelem zjištění závěru, zda je možné tyto informace poskytnout veřejnosti. Nutno zmínit, že doposud nejsou v rámci rezortu MV ČR nastavena pravidla, v jaké formě tyto informace poskytovat. Většina z těchto dat jsou pro PČR taktická data a některá z nich jsou dokonce citlivá. Podle stávající legislativy není možné vydávat informace z případů, kde nebylo ukončeno vyšetřování. Aktuálně tedy Policie ČR nemůže předávat veřejnosti celistvý a detailní dataset o výskytu trestné činnosti na území ČR. Oprávněnou potřebu veřejnosti však zástupci PČR chápou a snaží se ji aktivně řešit, a proto byl realizován projekt *Mapy budoucnosti II*, který alespoň z části řeší zmíněné nedostatky a požadavky.

*Mapa kriminalita* je výstupem klíčové aktivity tři a půl letého projektu *Mapy budoucnosti II – využití prostorových dat pro vytvoření a pilotní ověření nástrojů a postupů pro analýzu a predikci kriminality za účelem jejího předcházení a potírání*, který je financován z operačního programu *Zaměstnanost* a státním rozpočtem. Na realizaci projektu se podílel přibližně čtyřicetičlenný tým. Projekt si klade za cíl optimalizovat a zefektivnit procesy a postupy v PČR vytvořením uceleného a ověřeného souboru postupů a nástrojů, umožňujících v prostředí PČR kvalitní a efektivní mapování, provedení analýzy a využití systému predikce kriminality, odpovídající mezinárodním postupům v této oblasti, a to včetně postupů a nástrojů pro sdílení dat a výstupů mezi PČR a obcemi, a pro zveřejňování informací o vybraných druzích kriminality veřejnosti ve formě map kriminality.

Mapa kriminality eviduje k 11.11.2022 přibližně 340 000 přístupů uživatelů. Zajímavostí je, že ke stejnému datu verzi *mapy kriminality pro veřejnost* navštívili lidé z celkem 127 států (Vondrášek, 2022).

Mapa kriminality je rozčleněna na tři úrovně, resp. verze:

1. Verze pro veřejnost (delikty jsou agregovány do Thiessen polygonů).
2. Rozšířená předchozí verze pro obce. Obsahuje statistiky, grafy, implementaci funkce predikce na základě strojového učení z historických dat a přesná lokalizace deliktů, tzn. bez agregace do Thiessen polygonů pouze na území obce či městské části.
3. Třetí verze představuje aplikaci mapy pro PČR, která obsahuje veškeré funkcionality z předchozích verzí a k tomu navíc nabízí přesnější predikce výskytu kriminality, což při zohlednění pomáhá při organizaci a výkonu plánování policejní služby.

Nutno zmínit, že se v tomto projektu uplatňuje *reciprocita služeb*, tzn. do *Mapy kriminality* mimo PČR přispívají data evidence deliktů také některá města (mj. Praha 2, Kladno či Liberec). Města současně získávají data o kriminalitě od PČR. Tento přístup směřuje ke komplexnosti dat mapy kriminality a podle současného policejního prezidenta genjmr. Mgr. Martina Vondráška se tak jedná o unikátní a inovativní přístup v rámci celé Evropy (Vondrášek, 2022).

### **Data Mapy kriminality**

V aplikaci může jakýkoliv uživatel prohlížet, případně exportovat prostorová data výskytu deliktů kriminality evidovaných PČR pro území ČR či jednotlivých obcí na území ČR. Tyto informace lze dále v souladu s licenčními podmínkami (příloha 2) sdílet či využít pro tvorbu dalších technických prostředků určených pro prevenci kriminality na území ČR.

Aplikace obsahuje základní údaje o vybraných druzích trestných činů, které byly ve zvoleném období PČR oznámeny, nebo které PČR odhalila vlastní činností. Zároveň jsou zobrazeny pouze údaje obsahující informaci o poloze (údaje asi od poloviny roku 2013). V aplikaci jsou zobrazovány takové druhy trestné činnosti, u nichž může mít zveřejnění preventivní charakter a jejich zveřejnění nebrání taktické hledisko. Typově se jedná např. o násilnou trestnou činnost, majetkovou trestnou činnost, extrémismus, drogovou kriminalitu aj. U přestupků není rozsah dat tímto způsobem omezen. Nejsou zveřejňovány skutky, ve kterých se objevuje jako příznak dítě, trestná činnost na mládeži, mravnostní trestná činnost, a další delikty, u kterých není místo spáchání/zjištění/registrace skutku validní např. kybernetická kriminalita či migrace. Podrobný seznam zveřejňovaných a nezveřejňovaných trestných činů je uveden v příloze č. 2. U deliktů, tj. trestných činů i přestupků, odpovídají zobrazené informace poslednímu zjištěnému stavu věci v době, kdy bylo řízení vedeno PČR. V případě trestných činů tedy zobrazené údaje nezohledňují případnou změnu právní kvalifikace protiprávního jednání provedenou státním zástupcem nebo soudcem ani způsob, jakým bylo trestní řízení pravomocně skončeno rozhodnutím státního zastupitelství nebo soudu. Mapa kriminality např. nereflektuje skutečnost, že na základě informací získaných v průběhu trestního řízení státní zástupce učinil závěr, že se skutek PČR posouzený a v mapě zobrazovaný jako trestný čin vůbec nestal nebo že není trestným činem.

Data *Mapy kriminality* jsou veřejnosti bezplatně poskytována ve struktuře obsažené v následující tabulce 3:

Tab. 3 Datová struktura v *Mapě kriminality*. Zdroj: vlastní.

Atribut	Charakteristika atributu
ID	identifikátor deliktu
X	východní zeměpisná délka – $\lambda$ , tzn. GPS ve stupních ve formátu DD.ddddd
Y	severní zeměpisná šířka – $\varphi$ , tzn. GPS ve stupních ve formátu DD.ddddd
datum a čas oznámení	časové razítko data oznámení PČR
druh deliktu	trestný čin/přestupek
třídy	podle kriminalisticko-statistických tříd, které byly deliktem porušeny (příloha č. 1)
stav objasnění deliktu	1–zjištěn pravděpodobný pachatel; 2–neobjasněno; 3–skutek se nestal; 4–skutek není trestným činem

Prostorová data deliktů je možno stáhnout ve formátu csv nebo GeoJSON z nabídky hlavního menu (tlačítko *Ke stažení*), pro stažení je možno si zvolit konkrétní období. Uživateli jsou nabízeny dvě územní úrovně, pro které může data stahovat, a to území ČR či území obcí. Bodová data jsou k dispozici v souřadnicovém systému EPSG:4326. Součástí stažených dat jsou i tabulky, ve kterých jsou obsaženy číselníky dat. Číselníky pro formát GeoJSON lze stáhnout v záložce *KE STAŽENÍ*. Archiv \*.zip již číselníky obsahuje a není nutné je stahovat separátně. Při stahování dat je rovněž vhodné stáhnout a důsledně přečíst soubor *Licence obec* obsahující všeobecné licenční podmínky pro využití obecní sekce (příloha č. 2). V neposlední řadě lze stáhnout vygenerovaná prostorová data Voroného polygonů v různých formátech (archiv zip, GeoJSON, Geopackage, Shapefile) obsahující průběh hranic Voroného polygonů, do kterých bylo rozděleno území ČR pro potřeby anonymizace lokalit deliktů kriminality.

### Polohové zkreslení dat

Z důvodu ochrany osobních údajů poškozených a prevence jejich sekundární viktimizace a dále z důvodu ochrany osobních údajů osob podezřelých ze spáchání trestného činu, kteří by mohli být zejména v malých obcích nebo v řídké obydlených oblastech identifikováni, nejsou široké veřejnosti v *Mapě kriminality* zpřístupňovány informace o přesném místě spáchání trestného činu, nýbrž pouze oblast, v níž k události došlo (oblast je v mapě zvýrazněna podbarvením). Z důvodu nerovnoměrného zatížení území trestnou činností a také v zájmu ochrany osobních údajů poškozených a podezřelých osob, které by mohly být identifikovány v případě zobrazení přesného místa spáchání skutku, bylo nutné území obcí rozčlenit, blíže ke způsobu rozdělení území níže. Tyto oblasti nekorespondují s členěním obcí na části obce či statutárních měst na městské obvody či městské části ve smyslu zákona č. 128/2000 Sb., o obcích (obecním zřízení). Horák (2015) konstatuje, že cílem anonymizace je umožnit poskytování dat o kriminalitě v takové podobě, aby byla zajištěna ochrana osobních údajů, a tak nenastalo ohrožení základních lidských práv dle Listiny základních práv a svobod. Polohy všech publikovaných deliktů jsou z výše uvedených důvodů geograficky zkrasleny. Toho bylo dosaženo rozdělením jednotlivých obcí do tzv. Voroného polygonů (nebo také Thiessenových polygonů) s využitím klusterovací funkce K-Means.



## 2.2 Použité softwarové vybavení

V průběhu tvorby diplomové práce byla využita řada specializovaných programových prostředků, které byly vybrány dle vhodnosti, použitelnosti pro konkrétní úkol a rovněž podle dostupnosti. Mezi tyto analytické programy se řadí programy:

### **GeoDa 1.18.0**

Open source softwarový nástroj sloužící pro základní úlohy prostorového modelování a analýz prostorových dat. Pomocí programu GeoDa byla prostorově analyzována data charakterizující míru kriminality ve vztahu k vybraným socioekonomickým ukazatelům užitím regresních modelů jako jsou Ordinary Least Squares (OLS), Spatial Lag Model (SLM) a Spatial Error Model (SEM). Tyto modely byly použity pro analýzu vztahů mezi proměnnými a pro odhadování parametrů v těchto vztazích.

### **ArcGIS Pro 2.9.0**

Pro práci s prostorovými daty a pro tvorbu a mapových výstupů posloužil proprietární geografický informační systém (GIS) firmy Environmental Systems Research Institute (Esri). V prostředí ArcGIS Pro byly provedeny výpočty indexu kriminality a prvotní zpracování vstupních dat před vstupem do regresních modelů. Pro tyto účely byly v ArcGIS Pro využity geoanalytické nástroje jako *Buffer* (pro tvorbu hranic), *Clip*, *Summarize Within* (prostorové operace za účelem zpracování dat), *Join* (pro spojení atributových tabulek s jinými) či *Calculate Field* (k výpočtu indexu kriminality) a následnému exportu tabulek. V programu bylo provedeno regresní modelování (OLS, GWR) či Exploratory Regression. Rozhraní ArcGIS Pro bylo rovněž využito k tvorbě mapových výstupů. V programu byla použita kartografická metoda (pseudo)kartogramu zejména pro výsledné prostorové hodnoty indexu kriminality a statistických hodnot socioekonomických ukazatelů.

### **R Studio**

Vývojové prostředí pro programovací jazyk R, který je široce používán pro statistické výpočty a vizualizaci dat. Díky uživatelsky přívětivému prostředí a množství dostupných nástrojů umožnilo R Studio efektivní práci s daty a vizualizaci výsledků, včetně vytvoření korelační matice socioekonomických ukazatelů.

### **Adobe Illustrator CC 2017**

Jedná se o proprietární vektorový grafický editor společnosti Adobe Systems. Byl použit k výsledným grafickým úpravám map a vyhotovení některých grafických výstupů (web-design, grafy, tabulky, poster apod.).

### **Microsoft Office 365 – Excel, Word**

Ke zpracování numerických dat, vyhotovení grafů, tabulek, výsledků a sepsání diplomové práce posloužil kancelářský balík společnosti Microsoft Office, a to zejména produkty Excel a Word.

## 3 SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY

V následující kapitole jsou představeny základní pojmy z oblasti kriminologie a shrnuty historické i současné metody pro analýzu prostorových dat týkajících se kriminality. Kapitola dále zahrnuje přehled vybraných zahraničních a domácích studií, které se zabývají analýzou kriminality v geografickém kontextu.

### 3.1 Vymezení užitých pojmů

Pojem kriminologie pochází z latinského slova CRIMEN = zločin a řeckého LOGOS = učení. Obecně lze kriminologii vymezit jako nauku o kriminalitě (zločinnosti) a problémech s ní souvisejících (Hoferková, 2014). Kriminologie je uznávána jako samostatná multidisciplinární a empirická věda zabývající se kriminalitou, jejich pachatelích, obětech a kontrolou (Novotný et Zapletal, 2004; Kolaříková, 2017).

Kriminalitou se ve smyslu legálního (juristického) pojetí rozumí souhrn trestných činů spáchaných na určitém území v čase, jež trestní právo posuzuje jako trestné činy (ZOUBKOVÁ, MOULISOVÁ, 2004). Dalším významem kriminality je v kontextu sociologického trestný čin (kriminologickém smyslu) vymezován především jako čin společensky škodlivý (antisociální) nebo jako sociálně deviantní jednání. Kriminalita je tedy souhrnem těchto jednání. Tato definice vnímá definici kriminality jako širší pojem a zahrnuje postihnutelné činy i právně nepostihnutelné (tzv. deviace). Jedná se vlastně o materiální pojem trestného činu, jehož vymezení je na platném právu nezávislé (TOMÁŠEK, 2010).

Kriminologické výzkumy, jež jsou nastíněny v podkapitole 3.2, směřují zejména k poznání kriminogenních faktorů spojených s páčáním trestné činnosti s cílem vyvodit závěry pro kontrolu kriminality. K realizaci těchto výzkumů, je nezbytné nejdříve kriminalitu popsat. Základními indikátory popisu kriminality jsou stav, struktura a dynamika kriminality. Avšak je nezbytné mít na paměti, že v pojetí kriminality je v tomto kontextu nutno setrvat u jejího legálního pojetí, protože sociologické vymezení je sotva použitelné (Hoferková, 2014).

#### 3.1.1 Vysvětlení pojmů z kriminologie a trestního práva

Kriminologické studie směřují zvláště k poznání kriminogenních faktorů spojených s páčáním trestné činnosti, za účelem vyvodit závěry pro kontrolu kriminality. K provádění takových výzkumů je nezbytné nejdříve kriminalitu popsat, což je provedeno ve statistice kriminality. K tomuto účelu je nutno porozumět zavedeným základním pojmům nejen z oblasti kriminologie a trestního práva. V následujících odstavcích jsou zjednodušeně popsány autorem vybrané základní pojmy, jež je žádoucí znát alespoň v základní rovině v souvislosti s pochopením dalších částí této diplomové práce. Zdrojem informací definice většiny pojmů je Zákon č. 40/2009 Sb., (Zákon trestní zákoník, TZ) a zákon č. 250/2016 Sb. (Zákon o odpovědnosti za přestupky a řízení o nich).

#### Základy trestní odpovědnosti

*Trestný čin* (§ 13, TZ) – trestným činem je protiprávní čin, který trestní zákon označuje za trestný a který vykazuje znaky uvedené v takovém zákoně. K trestní odpovědnosti za trestný čin je třeba úmyslného zavinění, nestanoví-li trestní zákon výslovně, že postačí zavinění z nedbalosti. Trestné činy se dělí na přečiny a zločiny.

*Přečiny* (§ 14, TZ) – všechny nedbalostní trestné činy a ty úmyslné trestné činy, na něž trestní zákon stanoví trest odnětí svobody s horní hranicí trestní sazby do pěti let.

*Zločiny* (§ 14, TZ) – všechny trestné činy, které nejsou podle trestního zákona přečiny; zvláště závažnými zločiny jsou ty úmyslné trestné činy, na něž trestní zákon stanoví trest odnětí svobody s horní hranicí trestní sazby nejméně deset let.

### **Pachatel a věk**

*Pachatel* (§ 22, TZ) – Pachatelem trestného činu je, kdo svým jednáním naplnil znaky skutkové podstaty trestného činu nebo jeho pokusu či přípravy, je-li trestná. Pachatelem trestného činu je i ten, kdo k provedení činu užil jiné osoby, která není trestně odpovědná pro nedostatek věku, nepřičetnost, omyl, anebo proto, že jednala v nutné obraně, krajní nouzi či za jiné okolnosti vylučující protiprávnost, anebo sama nejednala nebo nejednala zaviněně.

*Trestně-právní pachatel* může být pouze osoba fyzická, přičetná, která dovršila věku 15 let. Pachatel trestného činu je osoba, která svým jednáním naplnila všechny znaky trestného činu (§ 3 tr. zákona).

Kriminologie tento termín definuje více ze široka než trestní právo. Zkoumá jak osoby, které se dopustily trestného činu, tak i jejich osobnost. Věnuje pozornost i osobám, které nejsou věkem (děti) nebo stavem vědomí (nepřičetnost) trestně odpovědné. Zabývá se i problematikou osob, které již trest za spáchaný trestný čin odpykaly, ale i potenciálními pachateli trestných činů (Novotný et Zapletal, 1996).

### **Ukládání a výkon trestů**

*Odnětí svobody* (§ 55, TZ) – jedním z druhu trestních opatření, které lze uložit soudem pachateli za spáchaný trestný čin. Trestní sazba je zákonem stanovována u každého trestného činu zvlášť. Nejvyšší sazba tohoto trestu je 20 let. V případě, že je ukládán trest odnětí svobody jako trest výjimečný (tj. zjednodušeně řečeno u těch trestných činů, kde to zákon dovoluje a jedná se o zvláště vysoký stupeň společenské nebezpečnosti a obžalovaný je nenapravitelný nebo jen obtížně napravitelný), odpovídá trest odnětí svobody výši od 20 do 30 let, případně na doživotí. Byl-li obžalovaný během trestního stíhání ve vazbě, doba ve vazbě strávená se mu započte do celkové výměry uloženého trestu. Odnětí svobody lze zjednodušeně rozdělit na *podmíněné* a *nepodmíněné* (Systém trestů, 2022).

*Podmíněně* (§ 55, TZ) je možno odložit výkon trestu nepřevyšujícího tři roky v případě, že vzhledem k osobě pachatele a okolnostem trestného činu lze předpokládat, že účelu trestu bude dosaženo i bez výkonu trestu. Výkon trestu lze takto podmíněně odložit na jeden rok až pět let a obžalovanému lze na danou dobu stanovit i jisté omezující podmínky (např. peněžitý trest, zákaz činnosti atp.). Považuje-li to soud za nutné, může nad obviněným vyslovit i dohled probačního úředníka, jenž bude odsouzeného pravidelně kontrolovat. Pokud odsouzený ve zkušební době neplní stanovené podmínky, pak rozhodne soud, že odsouzený trest vykoná v příslušné věznici (Systém trestů, 2022).

*Nepodmíněný trestem odnětí svobody* (§ 55, TZ) musí odsouzený bezprostředně po právní moci rozsudku vykonat v příslušné věznici. Pokud nenastoupí do vězení dobrovolně na vyzvu soudu, dodá jej tam policie (Systém trestů, 2022).

## **Stav, struktura a dynamika kriminality**

*Stav kriminality* – kvantitativní ukazatel, který je vyjádřením počtu evidovaných trestných činů nebo pachatelů (osob, které ji spáchaly) v absolutních číslech. Obecně stav kriminality charakterizují vnější stránku kriminality, tj. její výskyt, rozsah. Vyjadřuje celkový počet trestných činů, resp. pachatelů, k nimž došlo na určitém území za danou časovou jednotku (zpravidla za kalendářní rok) (Novotný et Zapletal, 2004; Marešová, 2011).

*Struktura kriminality* – kvalitativní ukazatel vyjadřující podíl jednotlivých druhů trestných činů (členěných do skupin podle předem stanovených kritérií) na celkovém počtu všech trestných činů spáchaných na teritoriu za vymezené časové období. U policejní statistiky jsou tato kritéria stanovena zvláštním předpisem – např. takticko-statistickou klasifikací (TSK), u justiční statistiky jsou užívány dvě dělení – jednak podle hlav zvláštní části trestního zákona, jednak v souladu s policejním dělením (tj. na násilnou, majetkovou, mravnostní, hospodářskou a zbývající, jinou kriminalitu). Podobně lze pro jiné potřeby vyjádřit strukturu (rozdělení) pachatelů dle různých hlediska jejich určitých charakteristik (identita, věková struktura, rozdělení podle pohlaví, vzdělání, profese atp.) a podotknout, že se nejedná o zcela shodné rozdělení, protože geografické rozložení je dalším významným kritériem pro sledování struktury kriminality (Novotný et Zapletal, 2004; Marešová, 2011).

*Dynamika kriminality* – vyznačuje trestnou činnost v pohybu (změně) v určitém konkrétním období na určitém území. Dynamikou se rozumí změna stavu či úrovně kriminality (úrovní, resp. míře kriminality se věnuje podkapitola 3.2.4) jako celku nebo jejich strukturálních částí. Dynamika kriminality popisuje veškeré prvky kriminality v časovém pohybu (zpravidla za období deseti let) (Novotný et Zapletal, 2004; Marešová, 2011).

## **Ostatní důležité pojmy**

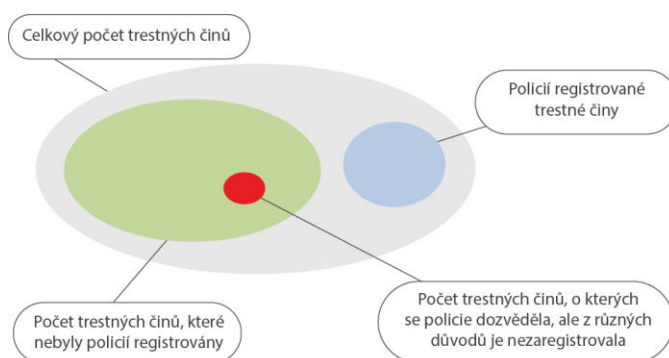
*Registrovaný skutek* charakterizuje vykázaný trestný čin, u kterého bylo zahájeno trestní řízení v předmětném období a je dosud neukončen nebo ukončen určitými způsoby (MAPAKRIMINALITY, 2022).

*Přestupek* (§ 5, 250/2016 Sb.) – společensky škodlivý protiprávní čin, který je v zákoně za přestupek výslovně označen a který vykazuje znaky stanovené zákonem, nejde-li o trestný čin.

*(Správní) delikt* – protiprávní jednání zahrnující přestupky právnických, ale i fyzických osob. Přestupky právnických a fyzických osob jsou upraveny v zákoně o přestupcích. Nová právní úprava přestupků (účinná od července 2017) však zcela vyloučila používání pojmu *správní delikt*. Všechny škodlivé protiprávní činy, které vykazují znaky stanovené zákonem a nejedná se o trestné činy, jsou přestupky. Trestné činy jsou vůči přestupkům speciální. Zpravidla se liší tím, že jsou intenzivnější ve škodlivosti, závažnosti a nebezpečnosti (AZ LEGAL, 2022). Nicméně pojem delikt je i v současnosti obecně používán jakou souhrnný pojem pro trestné činy, přečiny i přestupky.

### 3.1.2 Kriminalita registrovaná a latentní

Ze statistických údajů získáváme informace pouze o *kriminalitě registrované* (zjevné) tedy takové, která vyšla najevo a byla evidována v příslušných statistikách, jedná se tedy pouze o část celkové kriminality tedy skutečné (Kuchta, 2005), jejíž schematické znázornění vyjadřuje obrázek 2. Na schéma je nutno nahlížet jako na ideální model, jelikož ve skutečnosti mohou být do množiny kriminality registrované zaregistrovány i ty skutky, které ve skutečnosti trestnými činy nejsou. *Latentní kriminalita* je taková, o které se orgány činné v trestním řízení nedoví, není registrována v oficiálních statistikách. *Skutečnou kriminalitou* se rozumí celkově kriminalita registrovaná současně s kriminalitou latentní. *Šedými čísly kriminality* se pak rozumí buď případy, kdy byl pachatel trestně stíhán, ale nebyl odsouzen, nebo počet trestných činů, o kterých se orgány činné v trestním řízení dozvěděli, ale nebyl zjištěn jejich pachatel (Novotný et Zapletal, 2004).



Obr. 2 Schematický rozdíl mezi registrovanou a skutečnou kriminalitou.  
Zdroj: vlastní přepracování podle Kuchty et Válkové (2005).

Podle Marešové (2011) je odhad míry a rozsahu latentní kriminality zatím stále řešeným a dosud nedořešeným problémem. V současné době je latentní kriminalita do částečně zjišťována prostřednictvím kriminologických průzkumů, resp. viktimologických průzkumů vyjadřujících zastoupení obětí kriminality mezi vybranými vzorky obyvatel. V praxi se jedná dotazování respondentů, zdali se sami nedopustili v průběhu určitého časového období trestného činu, který nebyl ohlášen a evidován PČR. Martinková (2007) uvádí, že dle viktimologických výzkumů provedených Institutem pro kriminologii a sociální (IKSP) prevenci je rozsah latence u jednotlivých trestných činů v ČR značně různorodý – např. u vražd se jedná o maximálně několik skutků ročně, u kapesních krádeží a krádeží např. v obchodech o statisíce. *Koncepce rozvoje Policie České republiky do roku 2020* uvádí, že jedním z cílů, na které se PČR chce v současnosti intenzivně zaměřit je právě odhalení latentní kriminality. Policie chce tak posílit dostatečnou schopnost lépe reagovat na aktuální potřeby bezpečnostní situace a schopnost odhalovat latentní formy trestné činnosti za využití prostředků operativně pátrací činnosti pomocí různých návrhů opatření.

Latentní kriminalitu je žádoucí zmapovat, neboť je s veřejností v přímé konfrontaci. Je nezbytné zavádět komplexní přístup opatření proti stávající kriminalitě či preventivně – tj. i jako opatření proti kriminalitě latentní. Neboť pro vyvozování závěrů o stavu a dynamickém vývoji současné kriminality použití pouze oficiálních policejních statistik o evidované kriminalitě není dostačující (Kuchta et Válková, 2005).

### 3.2 Geografie a výzkum vývoje a struktury kriminality

Předmětem zkoumání kriminality v prostoru se zabývá široká škála vědních disciplín. Jednou z nich je angl. *geography of crime*, tj. geografie kriminality (zločinu). Jedním ze signifikantních aspektů kriminality je poloha v prostoru, ve kterém je kriminalita páchána (Surmař, 2013). Sherman (1995) dochází k závěru, že shlukování kriminality v geografickém prostoru podle polohy je šestkrát větší než podle osob. Některé lokality vykazují sníženou imunitu v důsledku konkrétních místních faktorů v okolí. Charakter území může přitahovat konkrétní typ trestné činnosti. Příkladů prostorových vztahů deliktů je celá řada. Rossmo (2000) uvádí, že většina trestných činů se uskuteční méně než dvě míle od bydliště pachatele. O vzdálenosti k místu činu je uvažováno, že jedinec se snaží provádět činnost za použití co nejmenšího úsilí, proto se i u pachatelů předpokládá, že páchají trestnou činnost v blízkosti svého bydliště (Chainey et Ratcliffe 2005). Výzkum prostorových aspektů kriminality vyžaduje kompetentní přístup jejího mapování a rovněž využití prostorových analýz (Horák, 2014). Základním a nezbytným předpokladem pro výzkum kriminality je, že distribuce výskytu kriminality v prostoru není náhodná (Brantingham et Brantingham, 1984), existují výrazné rozdíly mezi zeměmi, regiony, městy či ulicemi jednoho města. Pozorování prostorové koncentrace kriminality umožňuje exaktně určit, jak vysoká je pravděpodobnost viktimizace v jednotlivých čtvrtích či ulicích města (Šimon et Jíchová, 2018b).

Prostorové analýzy kriminality a studie percepce zločinu představují dva základní typy geografického výzkumu kriminality. Odlišují se v konkrétním tematickém zaměření, zdrojích dat a používaných metodických postupech. Prostorové analýzy jsou primárně zaměřeny na studium distribuce kriminality a základními zdroji dat jsou statistiky kriminality. Jedná se tedy o analýzu kvantitativních dat. Oproti tomu výzkumy percepce zločinu se zaměřují na vnímání kriminality lidmi prostřednictvím výběrových šetření (Jíchová, 2013). Nutno zmínit, že metodické přístupy i zdroje dat jsou limitovány nedostatky a neúplností kriminálních statistik, přičemž může nastat chybná interpretaci výsledků subjektivních odpovědí respondentů při dotazníkovém šetření či v důsledku omezeného vzorku dotazovaných apod. (Tomášek 2010).

Hendl (2005) popisuje tzv. metodologickou triangulaci, která spočívá ve zkoumání daného jevu využívající kombinace různých metod, datových zdrojů, výzkumníků, teoretického zázemí apod. Prostřednictvím triangulace metod ve výzkumu kriminality lze porovnat výsledky zjištěné různými metodami nebo doplnit poznatky, které jinými metodami nelze zjistit. Například viktimologické studie odhalují neohlášené trestné činy, dotazníkové šetření mezi obyvateli reflektují percepci bezpečnosti ve městě a přináší tak poznatky, které nelze zjistit ze statistik kriminality (Jíchová, 2013). Baxter a Eyles (1997) věnují pozornost analýze aplikaci metodologické triangulace přímo v sociální geografii na základě hodnocení kvalitativního výzkumu. Mimo jiné upozorňují na výzkumníky nedostatečný explicitní popis procesů a jejich zdůvodnění, výběr respondentů, klíčových změn ve směru výzkumu a analytických postupů. Vypracovali soubor evaluačních otázek a následně jej aplikovali na empirickou kvalitativní práci, tvořící argumentaci pro obecný soubor kritérií. Výsledkem jejich výzkumu je soupis kritérií, resp. pravidel, jež mohou sloužit jako opěrné body pro kvalitativní hodnocení práce.

Aktuální přístupy mapování kriminality a pokročilejších metod časoprostorových analýz vyjadřující prostorové vztahy, uspořádání i vazby s dalšími ukazateli fixovanými na území či obyvatele jsou spojeny s rozvojem geografických informačních systémů (GIS). GIS a nové softwary se v současné době významně podílí k provádění prostorových analýz

kriminality. GIS usnadňují efektivní sběr, zpracování dat a vizualizaci výsledků a také umožňují jednodušší práci s lokalizovanými daty – GPS souřadnicemi s informací o přesném místě spáchání trestného činu (Jichová et Netrdová, 2017). Aplikace GIS a analýza prostorových dat dosáhly takového stupně, že se jejich používání stalo nedílnou součástí současných policejních organizací a umožnilo modelovat prostorové vzorce rozložení kriminality a analyzovat prostorové vztahy mezi kriminalitou a dalšími demografickými a socioekonomickými charakteristikami. Ty slouží jako důležité mechanismy pro policejní vyšetřování trestné činnosti a pro předvídaní chování, sledování a lokalizace pachatelů. Kromě toho využití GIS a prostorových analýz policií poskytuje možnosti pro efektivní a účinné nasazení zdrojů a přijímání taktických a operativních rozhodnutí v oblasti boje proti trestné činnosti a její prevence. Podle Chainey et Ratcliffe (2005) mají GIS výhodu v relativně snadném grafickém vyjádření kriminálních jevů a statistik prostřednictvím pokročilých kartografických nástrojů, které umožní všem zainteresovaným osobám (kriminalisté, analytici, bezpečnostní složky aj.) efektivním způsobem pochopit a interpretovat danou problematiku. Analytici využívají GIS v oblasti kriminality v širokém spektru. Od identifikace potenciálních kriminálních subjektů, přes lokality s vysokou koncentrací kriminálních jevů, až po plánování hlídek a preventivních opatření příslušníků PČR. Analýzy kriminality mají rovněž signifikantní využití v krizovém a strategickém managementu.

V současnosti je na světovém trhu k dispozici celá řada open source i proprietárních software produktů (tabulka 4), které jsou určeny k predikci, (prostorové) analýze a vizualizaci dat o kriminalitě (Hruška, 2015). Metoda predikce vychází z prvního Toblerova geografického zákona – vše spolu souvisí, ale bližší objekty spolu souvisejí více než objekty vzdálené, z čehož vyplývá závěr, že vyšší počet kriminálních činů v určitém místě jej činí potenciálně nebezpečným i do budoucna. Detailním popisem funkcionality a použití jednotlivých softwarů k výzkumu kriminality se zabývá Kolaříková (2017) ve své diplomové práci s názvem *Mapy kriminality*. Nelze opomenout společnost T-MAPY, která vytváří v prostředí Corpiis Maps unikátní webovou mapu, jež detailně zpracovává a vyhodnocuje data kriminality poskytované PČR. Nejedná se pouze o zobrazení dat, ale o kombinaci přehledné mapové analytiky a přesných statistik jednotlivých typů deliktů, které se ve městě vyskytují. Analytická mapa je určena pro interní potřeby měst a městskou policii k prevenci kriminality. Mapa obsahuje pečlivě vybrané vizualizace a funkce doplněné o detailní statistiky deliktů. Ty v uživatelsky jednoduchém prostředí pomáhají poznat strukturu i charakter deliktů s cílem jejich budoucí eliminace a prevence. Data mohou být doplněna o přestupky od městské policie (T-MAPY, 2022).

Tab. 4 Populární programy pro analýzu dat kriminality a predikci. Zdroj: vlastní úprava podle Hrušky (2015).

<b>Software pro predikci kriminality</b>	<b>Software pro prostorovou analýzu dat</b>
HunchLab (Azevea)	ArcGIS (ESRI); QGIS
CrimeView Dashboard (Omega Group)	IBM SPSS (IBM)
PredPol (PredPol)	CrimeStat (National Institute of Justice)
Near-Repeat Calculator (Temple University)	GeoTime (Uncharted)
PRECOBS	ORACLE
Spatial and Temporal Analysis of Crime	GeoDa

### 3.2.1 Prostorové analýzy kriminality v zahraničí

Prostorové analýzy kriminality jsou založeny na analýze kvantitativních dat. Hledáním souvislostí mezi kriminalitou a charakteristikami území či populace se věnovali výzkumníci, tzv. evropští kartografičtí kriminalisté, v západní Evropě již v 1/2 19. století. V tomto období odborníci aplikovali zprvu jednoduché statistické metody (přepočítání trestných činů na obyvatele aj.) a později začali experimenty se složitějšími postupy zkoumající korelace mezi různými proměnnými (Jichová 2013). Ukázalo se, že výskyt kriminality v určitých oblastech není v žádném případě náhodný (Friendly, 2008). Cílem prvních analýz bylo zjistit existenci a povahu korelací mezi kriminalitou a sociálními ukazateli. Typickým výsledkem prostorových analýz jsou mapy. Např. Guerry et al. (1833) analyzovali úroveň osobních a majetkových trestných činů v regionech Francie ve vztahu k dalším proměnným (věk, pohlaví pachatele, hustota zalidnění apod.). Quetelet (1833) zkoumá v hrabství Anglie tzv. regionální diferenciaci kriminality, tj. hledání vztahů mezi úrovní kriminality a dalšími jevy (mj. chudobou a bohatstvím). V té době se výzkum kriminality vyvíjel jak s ohledem na cíle a metody, tak na soudobé možnosti zpracování a dostupnost dat. Prostorové analýzy dat kriminality zaznamenaly velký rozvoj v období po druhé světové válce nejen po stránce obsahové, ale i technické, a to šířením počítačů a následně specializovaných softwarů (Jichová, 2014). V této době je časté využití areálových a ekologických studií (Herbert, 1982). Areálové studie zachycují identifikaci vzorců kriminality distribuované v prostoru, zatímco ekologické studie vyjadřují korelace mezi intenzitou kriminality a dalšími socioekonomickými ukazateli obyvatelstva a území (Baldwin, 1979). Období 70. let 20. století budí ve světě zájem aplikovat různé geografické přístupy hodnocení regionálních rozdílů kriminality (mj. Harries 1971, Karabec 1973, Musil et Tichá 1977, Herbert 1982). V této době rovněž přichází ve větší míře zájem o hodnocení environmentální kriminologie zdůrazňující vliv místa (Brantingham et Brantingham, 1981). Jedná se o lokální výzkumy především v západních zemích (Wortley et Mazerolle, 2011). Cullen a Wilcox (2010) navrhli nový přístup hodnocení kriminality, který vychází z geografie kriminality. Pro každý kriminální čin definovali čtyři proměnné:

1. zákon (porušení legislativy),
2. oběť (někdo nebo něco je poškozeno),
3. pachatel (někdo spáchal kriminální čin),
4. časoprostor (trestní čin byl spáchán v nějakém prostoru a době)

Prostor je definován místem a časem, a právě tyto proměnné umožňují mapování kriminality. Všechny teorie zabývající se nějakým způsobem mapováním kriminality tak v podstatě uznávají vliv místa a jsou podskupinou environmentální kriminologie, jež zavedli v roce (Cullen, Wilcox, 2010). K rozvoji výzkumu kriminality v západních zemích v první polovině 20. století významně přispěla kvantitativní revoluce. Znakem kvantitativní revoluce bylo masivní zavádění statistických a matematických metod (modelování, matematické simulace) do geografického výzkumu. V této době došlo k rozšíření především areálových a ekologických studií zaměřených na identifikaci prostorových vztahů a korelací mezi kriminalitou a dalšími ukazateli (Baldwin 1979; Herbert, 1982). Rawson (1841) pro srovnání míry kriminality používá dosud nekonvenční přístup – vytvořenou typologii území (velká města, těžební oblasti, zemědělské oblasti s farmami a industriální oblasti).

Vliv socioekonomických faktorů na míru kriminality je s různými úspěchy hodnocen v množství zahraničních studií (Harries, 2005; Ceccato, 2009; Michálek, 2009; Mennis et al., 2010; Hagan, 2011; Ellis, Beaver a Wright, 2009). Příspěvek studie autorů



Ellise, Beavere a Wrighta (2009) přináší informace o socioekonomických jevů a vlastností, které byly ve vztahu ke kriminalitě v minulosti zkoumány, v jakých zemích (včetně měřítkové úrovně) a s jakým výsledkem. Drtivá většina zmíněných studií uvádí, že mezi nejčastěji zmiňované signifikantní přímé kriminogenní faktory patří hustota zalidnění, podíl cizinců, počet sňatků a rozvodů, rodinný stav, registrovaná míra nezaměstnanosti, náboženství, stěhování či úroveň vzdělání.

Již počátkem 21. století vzrůstá ve světě obliba prostorových analýz kriminality. Výzkumníci k těmto prostorovým analýzám využívají již zmíněný GIS. Snahou je prohloubit stávající přístupy k analýzám kriminality, a tak se objevují přínosné práce, které se zaměřují na zkoumání vlivu různých ekonomických či demografických ukazatelů kriminality. Michálek (2009) zjišťoval korelační analýzou a lineární regresí působení demografických, ekonomických a sociálních charakteristik na zločinnost na Slovensku. Prostorový výskyt deliktů byl ovlivněn zejména demografickými faktory, v kontextu koncentrace obyvatelstva a rizikového obyvatelstva, dále byla podstatná míra religiozity a míra průměrné mzdy (vyšší číselné hodnoty odpovídají snížení kriminality). Michálek upozorňuje na problematičnost kvantifikace faktorů (vliv sociálních vztahů, sociální kontroly a ekonomiky). V. Ceccato a L. Dolmen (2011) hledají kauzální příčiny kriminality vůči demografickým a ekonomickým faktorům ve venkovských oblastech. Užitím prostorového regresního modelu, byl potvrzen vyšší výskyt trestné činnosti v intravilánech. Výsledkem práce je sestavení schématu, které shrnuje vliv, dopad životního stylu a zástavby na společnost a kriminální chování. Závěr studie poukazuje na skutečnost, že venkov blíže k velkým městům disponuje s vyšší intenzitou kriminality než periferní venkovské oblasti. Mezi signifikantní kriminogenními faktory patří podíl rozvedených osob a podíl mladých mužů. V. Ceccato (2009) také odhalil spojitost nezaměstnanosti a výskytu kriminality. Míra nezaměstnanosti podle studie vykazuje kladnou korelaci s výskytem kriminality.

Mezi další faktory, které ovlivňují strach ze zločinu, patří etnicita (Riger a Gordon 1981, Skogan 1995, Webster 2003, Ceccato a Lukyte 2011, jak shrnují Reid a Konrad 2004), rodinný stav, vzdělání, sociální postavení a příjem (mj. Clemente a Kleiman 1977, Will a McGrath 1995). Těmto faktorům se výzkumech sice obvykle nedostává tolik pozornosti, ale často se využívají jako podpůrné faktory. Podle některých autorů hraje velkou roli kromě předchozí zkušenosti s kriminalitou také izolace osob, dostupnost zdrojů (finančních, informačních apod.) a přístup k nim, stejně jako zranitelnost. Mezi citlivější skupiny z hlediska dopadů viktimizace patří nejen starší lidé (Garofalo 1979, Smith 1987 atd.), u kterých se důsledky viktimizace projevují dlouhodobě, ale také osoby s horší ekonomickou situací, nižším vzděláním a sociálně vyloučené osoby (Skogan 1987).

Z předchozích studií vyplývá, že kriminalita je koncentrována spíše ve městech. Výzkumníci se tedy častěji zaměřují na výzkum kriminality v městských prostorech. V souvislosti s tím kriminalita nabírá na významu a stává se předmětem výzkumu v mnoha místech světa – Asie (např. Kalantari et al., 2016; Ingilevich et Ivanov, 2018), Afriky (např. Demombynes et Özler 2005; Singh, 2012; Chris et al., 2018 aj.), Evropy (mj. Ceccato 2009; Hart et Lersch, 2015), či Ameriky (Hojman, 2004; Levile et al., 2004; Leonardo de Castro Harth et al., 2016; Boba-Santos, 2017; Leiva et al., 2020) a další.

Inovativní a prací s netradičním přístupem je americká studie *Crime Rate Inference with Big Data* (Wang et al, 2016) analyzuje míru kriminality v Chicagu pomocí tzv. Big Data. Autoři používají prvky zájmové prostorové prvky a pohyb místních taxíků k modelování sociální interakce mezi sousedícími regiony a odvozování míry kriminality.

### 3.2.2 Prostorové analýzy kriminality v Česku

V českém prostředí ve studiích z 19. století nalezneme hodnocení kriminality maximálně do úrovně Zemí Koruny české (Zucker, 1894). Podrobnější dělení za okresní soudy je využito např. v práci Scholze (1927) zaměřené na mladistvé delikventy. Do konce 19. století v Česku nebylo věnováno výzkumu rozmístění kriminality příliš mnoho pozornosti. Počátky výzkumu kriminality v Česku se od západní Evropy výrazně odlišují. První studie kriminality se objevují až na sklonku 19. století a pozornost je věnována stavu a vývoji kriminality zejména ve vztahu k mládeži (Jichová, 2014).

Až v 60. letech 20. století v českém kontextu započala roční periodická publikace statistiky kriminality, které umožňovaly analýzy distribuce kriminality. Výzkumníci tak měli možnost pracovat s daty v detailu krajů (Karabec, 1973). Výzkum prostorové kriminality se tedy rozvíjí i mimo obor samotné kriminologie více až v 90. letech 20. století. Kriminalita je analyzována na úrovni celého státu, krajů a zejména okresů (Nemeškal et. Jichová, 2018). Oproti předchozím obdobím zde nedochází k inovativním změnám přístupů ke studiu kriminality, ale spíše k prohlubování stávajících mechanismů, zpřesňování modelů či zdokonalování teorií a konceptů. Velkému rozvoji ve výzkumu přispělo využití GIS a jejich efektivních nástrojů, které jsou mj. určeny pro prostorové analýzy, správu dat, kvalitní mapová zpracování a vizualizaci kriminality (Jichová, 2014). V této době však nebyla k dispozici data kriminality na podrobnější měřítkové úrovni než na úrovni okresů či obvodních oddělení policie. Výzkumu regionální diferenciaci sociálně-demografických znaků obyvatelstva se věnuje Bartoňová (1996), která provedla analýzu vývoje věkového složení, plodnosti, porodnosti, rozvodovosti či mimomanželské porodnosti obyvatelstva, ale také úrovně kriminality na území Česka a její časový vývoj. Dokázala identifikovat a rozpoznat souvislosti míry kriminality s městským, sociálním a životním prostředím.

Až přelom 20. a 21. století zaznamenává pro studium kriminality z geografického hlediska v českém kontextu velký zlom. Rozšiřují se nejen zkoumaná témata v oblasti kriminality, ale mění se i přístupy a objevují se nové metodiky a územní měřítko výzkumu nabývá detailnějšího charakteru. Výzkumy v Česku tak začínají intenzivněji reflektovat zahraniční výzkumy (Jichová, 2014). Prostorové analýzy kriminality vznikají ve větší míře, což ovlivnil zlepšený přístup k datům (Jichová, 2013). Zprvu je těmto tématům věnována pozornost v akademické sféře v rámci kvalifikačních pracích. Vznikají studie, které se snaží nalézt vztahy mezi výskytem a mírou kriminality ve srovnání s kriminogenními faktory. Za zmínku stojí diplomová práce Kolbábka (2007) věnující se prostorovému významu kriminality, kde porovnává intenzitu kriminality v okresech Česka a dále si všímá korelace s dalšími jevy (např. nezaměstnanost obyvatel). Nalezení vztahu mezi socioekonomickými ukazateli (podíl cizinců, vysokoškolsky vzdělaných lidí, věřících, míru nezaměstnanosti či index potratovosti nebo rozvodovosti atp.) a distribucí násilné kriminality v Česku užitím regresního modelu se zabývá Surmař (2013). Jichová a Nemeškal (2012a,b) analyzovali vývoj a strukturu kriminality v okresech Česka od 60. let 20. století. K výzkumu použili korelační analýzu celkové kriminality a ukazatelů vázaných na obyvatelstvo a území. Výstupem práce jsou přínosné mj. specializované mapy s doprovodnými texty dostupné v atlasové podobě tištěné či digitální – *Atlas sociálně prostorové diferenciacie České republiky* (dostupný na WWW <<https://www.atlasobyvatelstva.cz/cs/atlas-diferenciacie>>) (Jichová, 2017a). Kamenický (2007) se zaměřuje na prostorovou analýzu kriminality na úrovni okresů i obvodních oddělení policie (v roce 2015 má 533 jednotek).

V současnosti nalezneme ve Česku celou řadu výzkumů územní diferenciaci rozmístění kriminality. Tímto se zabývají zejména pracovníci Institutu pro kriminologii a sociální prevenci. Dlouhodobě zveřejňují studie *Analýz trendů kriminality* na úrovni krajů. V rámci akademického výzkumu se aktivně věnují kriminalitě z hlediska prostoru především RNDr. Jana Temelová Ph.D. (Univerzita Karlova), RNDr. Jana Jíchová, Ph.D. (Univerzita Karlova), RNDr. Jiří Nemeškal Ph.D. (Univerzita Karlova), doc. Dr. Ing. Jiří Horák (VŠB-TUO Ostrava) a prof. Ing. Igor IVAN, Ph.D. (VŠB-TUO Ostrava). Jíchová (2017b) zkoumá sociálně prostorovou diferenciaci Česka v podrobnosti okresů v historické perspektivě (za období 1994 až 2017) a uvádí, že vývoj kriminality v Česku je silně ovlivněn celospolečenskými událostmi, ale rovněž změnami legislativy, organizace i činností policie. Tyto aspekty mnohdy představují překážky při analýzách časové a prostorové dynamiky kriminality a při její komparaci. Jíchová et Nemeškal (2018) navazují výzkumem na Kamenického a věnují pozornost hledání prostorového vzorce kriminality v Česku v prostorovém měřítku hranic oddělení policie. Výsledkem práce je hodnocení kriminality mj. z pohledu prostorového rozlišení obvodní oddělení policie podle podobnosti struktury kriminality s využitím Wardovy metody hierarchického shlukování. Zajímavostí je, že k výpočtu indexu kriminality pro účely analýzy byla dostupná data mobilních operátorů, které odpovídají logice počtu trestných činů v daném území. Tato data však nebyla využita z důvodu neúplnosti, resp. nepřesnosti dat v kraji Vysočina a dále disponovala s metodickými nedostatky jejich sběru, což by mohlo vést k zaváděcím výsledkům a závěrům. Na druhou stranu do analýzy alespoň orientačně vstupovala tato data mobilních operátorů jako jeden ze socioekonomických ukazatelů (Jíchová et Nemeškal, 2018).

I když se prostorové analýzy kriminality neustále vyvíjí, existuje již dnes spousta zásad, pravidel, zákonů, metod a praktických postupů pro zpracování a vizualizaci dat. Pro systematickou a efektivní práci s daty kriminality sepsal Horák (2016a) metodiku harmonizace, agregace a anonymizace dat kriminality. Metodika je určena především k identifikaci unifikovaného postupu předzpracování dat kriminality a jejich interpretace, kontrole zapsaných dat, vytváření harmonizovaných údajů pro analytické potřeby, zejména hodnocení stavu či vývoje kriminality. Charakteristika logického konceptu multidimenzionální databáze, popis její struktury, definice jednotlivé dimenze sledování reality, definice vhodné granularity dat a hierarchické vazby, popis vhodných datových zdrojů kriminality a procesy transformace dat do multidimenzionální databáze zachycuje metodika podle Horáka (2015). Ivan (2020) se spolu s řešitelským kolektivem zaměřili na tvorbu metodiky pro identifikaci, hodnocení, vizualizaci a monitoring bezpečnostně rizikových lokalit s využitím prostorových mikrodát. Rovněž nelze opomenout metodiku popisující identifikaci anomálních lokalit kriminality pomocí metody jádrových odhadů s korektním nastavením jádrového vyhlazení, následného vyhodnocení a vizualizací (Ivan et Horák, 2016). Bezmála poslední metodikou, která stojí za zmínku je metodika Horáka (2016b), která se podrobně zabývá vytvářením sjednocené multidimenzionální databáze sekundárních agregovaných dat, využitím specifických analytických a reportovacích nástrojů a zajištěním přenosu anonymizovaných agregovaných údajů z různých informačních systémů veřejné správy pro podporu rozhodování v oblasti prevence kriminality. Jedná se o velmi užitečné metodiky, neboť přinášejí ověřené postupy pro efektivní práci s daty kriminality.

V posledních letech se rozvíjí zájem o studie založené na datech s GPS souřadnicemi (Ivan et Horák, 2012; Jíchová, 2017b). Šimon et Jíchová (2018a) představují návrh na zveřejnění dat o kriminalitě na mikro-úrovních uličních segmentů v podmínkách českých měst. Problematickou situaci představují trestné činy, jež byly spáchány v dopravních prostředcích (např. veřejné hromadné dopravy). Poškozený nezná přesnou polohu spáchání činu, a proto je lokalizace spáchání trestného činu generována náhodně ve zvoleném prostoru či podél trasy (např. linky MHD) (Ivan et Horák, 2012). Šimon et Jíchová (2018b) přichází s inovativním analytickým přístupem zkoumání společenské škodlivosti kriminality *jednoho středně velkého českého města* na úrovni ulic za časové období tří let. Jedná se o pilotní metodologickou studii, ve které jsou k hodnocení kriminality použity váhy trestných činů. Váhy trestných činů byly sestaveny tak, že autoři vzali základní paragrafové rozmezí trestní sazby bez zohlednění dalších specifikací činu podle písmen paragrafu a vypočetli střední hodnotu, kterou následně vyjádřili ve formě počtu dní trestní sazby. V případě přestupkové činnosti autoři vycházely ze střední hodnoty paragrafové výše pokuty, kterou vydělili výši minimální mzdy (10 tis. Kč/měsíc). Výsledkem je počet dní placené práce, který je nutný k vydělání udělené výše pokuty (Šimon et Jíchová, 2018b). Z důvodu sekundární viktimizace autoři nezmiňují název města a rovněž nezveřejňují mapové výstupy, které by jistě byly významným doplňkem výstupů studie.

### 3.2.3 Mapování bezpečnosti

Rozhodování o bezpečnosti je vždy ovlivněno skutečnostmi v místě. Místa událostí souvisejí s geografii. Mapování bylo vždy důležitým prvkem k odhalení nebezpečných lokalit z pohledu páchaných zločinů. Od špendlíkových map až po moderní mapy kriminality. Geografické informační systémy jsou pouze rozvinutější a modernizovanější implementací tradičních typů mapování a v současnosti napomáhají policejním povinnostem mapovat kriminalitu (Block, 1995). Block (1995) dále poznamenává, že kuličkové mapy jsou v místnostech policejních šéfů k vidění již od doby, kdy se kuličkové objevily. Tyto mapy sloužily k tomu, aby na první pohled ukázaly, v jakých místech dochází k trestné činnosti. Vývoj v oblasti počítačového vybavení a softwaru dal používání map další impuls. Mnoho orgánů činných v trestním řízení díky těmto technologiím používá mapy kriminality a GIS; to zvyšuje schopnost policejních vedoucích pracovníků při přijímání rozumných rozhodnutí o přidělování hlídek, lepších personálních politikách a proaktivních programech prevence kriminality. Analýzou poskytnutých údajů z různých zdrojů mohou uživatelé na různých organizačních úrovních činit zjištění, závěry a politiky. Nicméně navzdory velkému využívání GIS se mapování kriminality stále nachází ve fázi vývoje a některé technické a etické problémy čekají na vyřešení (Argun et Dağlar, 2016).

Mapování strachu ve vybraných městech Česka je realizováno prostřednictvím tzv. pocitových map. Pocitové mapy zatím nemají jednu všeobecně uznávanou definici. Obecně se však pracuje s pojetím, že pocitové mapy jsou kartografické výstupy, které umožňují zobrazit lidské pocity, myšlenky či zkušenosti v prostoru, a tvorbu vlastních pocitových geografických dat (Perkins, 2009; Nold, 2009). Vyjadřují tedy subjektivní názor autora jednotlivým místům – například město či sídliště, u kterých však nelze hodnotit správnost, ani míru shody s realitou, protože obsahují kvalitativní hodnotící soudy jejich tvůrců. Výsledná mapa je poté tvořena mapovou syntézou odpovědí více respondentů. Technicky vzato se jedná o nástroj, který nabízí možnost aktivně zapojit občany do sběru informací a názorů na lokality, v nichž bydlí. Koncept spočívá v zapojování veřejnosti, resp. dobrovolníků a následného získání jimi poskytnutých dat. Sběr dat probíhá v online

a offline podobě. V případě papírového mapování (offline varianty) probíhá sběr dat jako dotazníkové šetření přímo v rámci osobní interakce s občany na ulici. Na základě rozhovoru respondenti označí (bodově či plošně) v mapě místa, ve kterých se cítí bezpečně či nikoliv. Oproti tomu elektronické mapování (online varianta) nabízí možnost vyplnění dotazníku na webových stránkách – <www.pocitovemapy.cz/>. Nasbíraná data jsou následně zpracována v GIS a vyhodnocena prostřednictvím souhrnných analytických map a zveřejněna (Ivan et al., 2020).

Metodu mapování strachu užitím dotazníkového šetření aplikoval Pánek et al. (2019). Ve studii věnuje pozornost na představení výsledků online dotazníkového šetření na základě mapových podkladů, kterého se zúčastnilo 1 551 respondentů z města Ostravy v Česku. Snahou výzkumu je nalézt prostorový vzorec mezi registrovanou kriminalitou a strachem z kriminality ve sledovaném území. Záznamy o percepci strachu byly porovnány s daty o evidované kriminalitě získanými z evidence policejních oddělení za roky 2015–2018. Příspěvek zkoumá prostorovou autokorelaci z vnímaných hotspotů (pocitů strachu místních obyvatel) a z evidovaných míst kriminality. V rámci výsledků jsou mj. zmíněny obvyklá podezřelá místa v kontextu strachu, jako jsou např. dopravní uzly (zejména vlaková/autobusová nádraží), městské parky (především v noci), stinné úzké ulice s omezeným veřejným osvětlením či veřejná prostranství v těsné blízkosti nočních klubů/barů/heren. Závěr studie však nepřináší mnoho nových překvapení a výsledky jsou v souladu s výsledky jiných výzkumů strachu z kriminality, a to nejen v Česku, ale i jiných zemí (Pánek et al., 2019).

### 3.2.4 Charakteristika míry kriminality

Rozsah kriminality je počet skutků, které lze v kontextu trestního práva definovat jako trestné činy, spáchaných na vymezeném území za určité časové období. Při zpracování dat o rozsahu kriminality je nezbytné mít na paměti, že tato čísla neodrážejí demografické vlivy (například různou hustotu obyvatel jednotlivých porovnávaných území), se zřetelem k tomu by při jejich interpretaci mohlo dojít ke značnému zkreslení reálného stavu. Z toho důvodu je nutné absolutní čísla trestných činů relativizovat prostřednictvím výpočtu tzv. indexu kriminality, a tak lze dojít v rámci modelového přístupu k intenzitě (míře) kriminality. Proto se při kvantitativním popisu kriminality zjišťuje tzv. míra (intenzita nebo také úroveň) kriminality, která je daná přepočtem trestných činů (nebo počtem pachatelů) na počet obyvatel určitého území. Je vyjádřena indexem (dříve označováno koeficientem), který je obecně vypočten jako podíl počtu evidovaných trestných činů a počtu obyvatel na vymezeném území násobeno hodnotou 100 000. Ovšem v případě analýzy celkové kriminality bychom dostávali příliš vysoká čísla, proto je přehlednější násobit hodnotou 10 000, případně 1 000 (Válková et Kuchta, 2012). Hoferková (2014) uvádí, že může být použito i jiné menší měřítko, např. na počet obyvatel žijících v určitém uzemním celku, na ulici, na sídlišti, v určitém městském obvodu). Autor diplomové práce se domnívá, že v podstatě příliš nezáleží na volbě vynásobení nižší hodnotou (např. 100, 1 000 nebo 10 000), protože se ve výsledku jedná jen o posunutí desetinné čárky. Volba hodnoty závisí na tom, aby při vizualizaci prostřednictvím výsledných map došlo ke správné interpretaci čtenářem mapy. Matematické vyjádření výpočtu indexu kriminality je patrný ze vzorce 5:

$$\text{Index kriminality} = \frac{\text{počet evidovaných trestných činů}}{\text{počet obyvatel}} \times 100\,000 \text{ (10\,000, 1\,000)} \quad [5]$$

Index kriminality lze klasifikovat na hrubý a čistý. Hrubý index zahrnuje veškeré trvale žijící obyvatele sledovaného území, oproti tomu čistý index počítá pouze s trestně odpovědnými obyvateli (15 let a více), kteří trvale žijí ve zkoumaném území. Na stejném principu je možno kromě indexu kriminality počítat také index stíhaných osob, index osob obžalovaných, index odsouzených či index osob ve výkonu trestu odnětí svobody (Válková, 2012; Trnková, 2019).

Vypočtené hodnoty indexu standardizují míru kriminality v jednotlivých dílčích územních celcích a v důsledku toho lze tyto výsledné hodnoty vzájemně kvantitativně srovnávat. Na základě použité literatury lze konstatovat, že přístupů k výpočtu kriminality existuje celá řada. Dosud však neexistuje ucelená a bezesporná metodika, která by detailně popsala různé přístupy výpočtů indexu kriminality.

Výsledné prostorové hodnoty indexu kriminality jsou nejčastěji znázorňovány v mapě užitím kartografické metody pseudokartogramu. Voženílek et Kaňok (2001) poukazují na obezřetnost správného použití této metody, neboť při nedodržení relativizování počtu trestných činů (přepočtení na obyvatele území) dochází k hrubé chybě interpretace dat!

Prof. Igor Ivan v emailové korespondenci upozorňuje, že jak čítatel, tak jmenovatel výpočtu indexu kriminality nejsou triviální. Pro celkové hodnocení kriminality lze do čítatele dosadit sumu za více typů trestných činů ale rovněž lze aplikovat vybrané samostatné typy trestných činů. Ve jmenovateli je optimální použít data za počet přítomného obyvatelstva (v daný čas) v daném území. Zjištění těchto dat je poněkud obecně náročné, avšak je proveditelné (např. data poskytnutá mobilními operátory, což je náročné obzvláště z finančního hlediska). Nemeškal et Jichová (2018) dochází v rámci studie kriminality k závěru, že ačkoli byla pro jejich analýzu dostupná data mobilních operátorů zachycující přítomné obyvatelstvo, jež lépe odpovídá logice počtu trestných činů v území, nebyla využita jako jmenovatel ve výpočtu míry kriminality z důvodu neúplnosti dat a metodických nedostatků jejich sběru, které by celkové výsledky mohly výrazně zkreslit. Proto je ve jmenovateli častěji užíván počet trvale žijícího obyvatelstva na určitém území. Vhodnost rozdílu použití těchto přístupů odráží skutečnost, že se snižujícím se detailem se vliv zvyšuje (např. obchodní centra). Dále je třeba rozhodnout, zda bude do výpočtu zahrnuto všechno obyvatelstvo, nebo jeho podmnožina v kontextu věkové kategorie (trestně právní 15 a více let, nebo obyvatelé ve věku 18 let a více). V Česku se dlouhou dobu využívaly spíše jednodušší statistické přístupy hodnocení kriminality založené např. na přepočtu kriminality na počet obyvatel (Zucker, 1894). Avšak podle prof. Igora Ivana je v některých případech (např. s vyšším prostorovým detailem) lepší výpočet relativizovat k jiné proměnné – krádeži aut (relativizace na počet zaparkovaných aut – tato data zpravidla nejsou k dispozici), vloupání do objektů (relativizace váženým počtem objektů) apod.

V 60. a 70. letech 20. století dochází v zahraničí k užití pokročilých statistických metod, jež využívají přepočty trestných činů přes skóre a „intenzitu nebezpečnosti“ (Jüttner, 1968; Karabec, 1973). Kallab (1913) spolu s dalšími kriminologickými výzkumníky dávali přednost využití dat o počtu odsouzených osobách před daty o počtech kriminálních případů (počtu deliktů). Ke prostorové komparaci jevu různých míst byly hojně užívány různé indexy přepočítávající počet případů, resp. osob na 100 odsouzených osob, na 100 osob obyvatel v obvodu bydlicích, příp. trestně odpovědného věku, nebo na 10 000 atd. V současné době je v zahraničí index kriminality užíván především ke statistickému vyhodnocení výskytu určitých typů zločinů na určitém území a jejich trendů. Jedná se o „indexové delikty“ – vraždy, loupeže, závažná ublížení na zdraví, krádeže atp., přepočteny na počet obyvatel zájmového území. Například index loupeží je vypočten jako podíl počtu loupeží a počtu obyvatel daného území.

## 4 GEOGRAFICKÁ ANALÝZA KRIMINALITY V ČESKU

### 4.1 Míra kriminality

Pro identifikaci míry kriminality ve zkoumané prostorové jednotce je nejčastěji používán index kriminality, který porovnává nápad trestné činnosti (či přestupků) vůči počtu obyvatel daného území. K naplnění cílů diplomové práce byla z aplikace Mapy kriminality stažena data kriminality (na úrovni obcí za měsíce v období 2014–2021 ve formátu \*.geojson za dílčí měsíce v jednotlivých letech). Jedná se tak o inovativní přístup práce s daty kriminality v akademické sféře. Aplikace Mapy kriminality obsahuje základní údaje o přibližně čtrnácti milionech přestupcích (k datu 11.11.2022) a vybraných druzích trestných činů, které byly ve zvoleném období Policií (PČR) oznámeny, nebo které PČR odhalila vlastní činností.

Po stažení dat následovala explorativní a prostorová analýza, včetně vizualizace. Stažená bodová data kriminality byla importována do rozhraní geografického informačního systému (GIS) ArcGIS Pro. Datový náhled atributové tabulky bodových dat kriminality znázorňuje obrázek 3. Atribut „types“ obsahuje informace o typech trestných činů a přestupcích, které jsou zapsány ve formě textového řetězce. Atribut „state“ charakterizuje stav objasnění deliktu. K selekci dat na základě zvolených podmínek (viz dále) byl v GIS využit nástroj *Select By Attributes*.

id	date	state	types
17286494	2021-12-16T10:51:00....	2	[1,10,35,43,55,102]
17109548	2021-11-19T16:00:00....	2	[1,10,55,102]
15513731	2021-08-27T10:35:00....	2	[1,10,55,102]


Obr. 3 Datový náhled atributové tabulky bodových dat kriminality. Zdroj: vlastní.

Následně byla provedena agregace za jednotlivé měsíce do jedné vrstvy pro každý rok (nástrojem *Merge*). Poté byly záznamy filtrovány podle druhu deliktu a stavu objasnění. Pozornost byla věnována pouze trestným činům, tzn. přestupky byly odfiltrovány. Atribut „state“ byl podroben filtraci záznamů s podmínkou, kde je *zjištěn pravděpodobný pachatel* (hodnota 1) nebo *neobjasněno* (hodnota 2) – počty těchto záznamů jsou patrné z vizualizace v grafu č. 2). Záznamy obsahující *skutky, které se nestaly* (hodnota 3) nebo *nejsou trestným činem* (hodnota 4), byly následně odstraněny. Tabulka 5 charakterizuje počty záznamů zpracovaných dat kriminality. Počet <NULL> záznamů náleží atributu „types“ (typ trestné činnosti a přestupky). V důsledku nejednoznačnosti při identifikaci rozdílů mezi typem trestné činnosti a přestupkem byly hodnoty <Null> vyloučeny z analýzy. Po zohlednění skutečnosti, že přestupky byly již vyřazeny z analýzy, byly rovněž vyloučeny hodnoty <Null> v atributu „types“, neboť se dle stanoviska PČR většinou jedná o přestupky. Je nutno poznamenat, že v roce 2018 je ve srovnání s ostatními roky nejvyšší počet trestných činů, jež nejsou evidovány dle klasifikace typu činnosti, či přestupků. Roky 2012 až 2015 byly z datového souboru vyloučeny z důvodu nedostatku dostupných údajů (ve srovnání s ostatními sledovanými roky) – graf č. 1. Pro další postup práce, včetně analýz, byla použita pouze autorem filtrovaná data kriminality, tj. *Výsledný počet trestných činů*, za období 2016–2021 bez <Null> hodnot atributu „types“. Výsledná data nejsou dostatečná pro získání relevantních závěrů

o trendu a dynamickém vývoji kriminality, a proto by v případě jejich neopatrné interpretace mohlo dojít ke zkreslení reality a následně hrubému omylu.

Tab. 5 Přehled počtů záznamů zpracovaných dat kriminality. Zdroj: vlastní.

Rok	Původní počet záznamů (stav objasněno a zjištěn pravd. pach.)	Počet <NULL> záznamů	Počet záznamů s přestupky	Výsledný počet trestných činů
2012	775	24	691	60
2013	494 802	8 139	484 385	2 278
2014	977 361	9 511	961 918	5 932
2015	1 520 091	11 546	1 479 431	29 114
2016	1 628 693	22 989	1 432 638	173 066
2017	1 437 703	0	1 289 020	148 683
2018	1 469 176	41 213	1 290 136	137 827
2019	1 428 834	12 412	1 244 427	171 995
2020	1 175 147	10 590	1 020 718	143 839
2021	1 219 848	0	1 065 419	154 429
<b>celkem</b>	<b>9 879 492</b>	<b>98 750</b>	<b>8 821 789</b>	<b>958 953</b>




Graf 1 Četnost dat trestných činů za období 2012–2021. Zdroj: vlastní.

Poté byla v rozhraní GIS importována prostorová polygonová vrstva administrativních jednotek – 6258 obcí. Zdrojem dat je Registru územní identifikace, adres a nemovitostí (RÚIAN). Pomocí nástroje *Summarize Within* byla vstupní polygonová vrstva obcí překryta bodovou vrstvou trestných činů, do kterých byla automaticky vypočítána data jako *count* (počet trestných činů). Výsledkem je polygonová vrstva obcí, která obsahuje počet trestných činů, tj počet bodů v jednotlivých obcích. Při zvážení dvou odlišných přístupů ke zmíněnému prostorovému protnutí bodů s polygony, byl v důsledku povaze dat kriminality (a jejich primárnímú pořizení) zvolen přístup zápisu, kde jeden záznam v atributové tabulce odpovídá jednomu skutku (trestnímu činu), tj. bez ohledu na typy trestné činnosti). V praxi se může stát, že pachatel spáchá více různých typů trestných činů, například vloupání, krádež a násilí. I když se jedná o různé typy trestných činů, ve veřejných datech Mapy kriminality PČR je tato skutečnost zaznamenána jako jeden záznam, resp. bod. Celkový počet obcí, které jsou zahrnuty do analýzy, odpovídá číslu



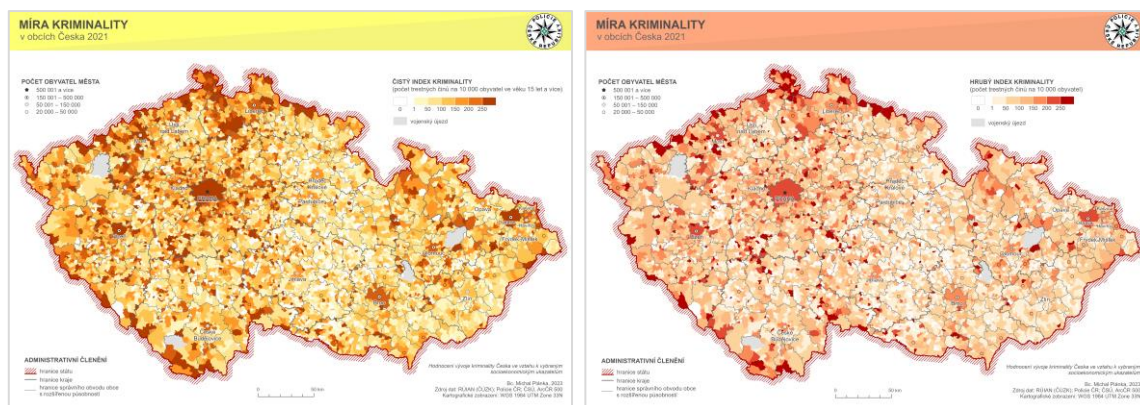
6 254, přičemž v datovém souboru kriminality nebyly nalezeny žádné záznamy trestných činů ve vojenských újezdech (Libavá, Boletice, Hradiště a Březina), a proto byly tyto záznamy odstraněny. Dalším důvodem jejich vyčlenění je absence počtu trvale žijících obyvatel.



Graf 2 Četnost dat trestných činů dle stavu zjištění za období 2016–2021. Zdroj: vlastní.

#### 4.1.1 Čistý a hrubý index kriminality

K polygonové vrstvě obcí, obsahující informace o počtu trestných činů, byla užitím nástroje *Join* připojena (podle číselného kódu obce) atributová data obsahující počty trvale žijících obyvatel (platné k 31.12.) za dílčí roky sledovaného období (2016–2021). Pro účely výpočtu indexu kriminality bylo v dané vrstvě vytvořeno nové atributové pole. Pole, datového typu Long (Numeric), s názvem CIK vyjadřující čistý index kriminality. Dále bylo vytvořeno pole s názvem HIK představující hrubý index kriminality. Rozdíl mezi čistým a hrubým indexem spočívá ve výpočtu. Hrubý index kriminality byl vypočítán jako poměr mezi počtem trestných činů (v daném roce) a počtem všech trvale žijících obyvatel (v daném roce) příslušné obce, který je následně vynásoben hodnotou 10 000, aby byl standardizován a umožnil vzájemné srovnání mezi různými územními jednotkami v průběhu let. Čistý index kriminality se odlišuje tím, že zahrnuje pouze trestně právní obyvatele, tedy osoby ve věku 15 let a více, a vylučuje osoby mladší 15 let, které nejsou trestně odpovědné. Tímto způsobem je čistý index kriminality považován za více vypovídající, neboť poskytuje objektivnější pohled na kriminalitu, která je spojena s trestně odpovědnými obyvateli dané obce. Následně byla provedena prostorová vizualizace dat za jednotlivé roky prostřednictvím šesti map čistého indexu kriminality (přílohy 1–6) a šesti map hrubého indexu kriminality (přílohy 7–12). Náhled na mapy ilustruje obrázek 4. Mapy byly vytvořeny v GIS rozhraní ArcGIS Pro pomocí metody kartogramu. Pro rozdělení intenzity jevu, resp. hodnot indexu kriminality byla použita metoda přirozených zlomů (Jenks, 1967) na základě charakteru dat. Hodnoty indexu kriminality jsou vizualizovány pomocí sekvenční barevné stupnice, kde bílá barva značí hodnotu nula pro danou obec. Odstíny červené barvy vyjadřují intenzitu indexu kriminality. Pro zlepšení orientace jsou v mapě zobrazena vybraná města.



Obr. 4 Ukázky mapových výstupů čistého (vlevo) (přílohy 1–6) a hrubého (vpravo) (přílohy 7–12) indexu kriminality. Zdroj: vlastní.

Podle Šimona et Jichové (2018b) není rozmístění kriminality v prostoru náhodné, neboť různé typy kriminality vykazují jasné lokalizační předpoklady. Mobilita pachatelů je rovněž omezena jejich možnostmi a omezenými znalostmi vhodných míst s příležitostmi pro páchaní kriminality. Většina pachatelů proto páchá trestnou činnost v relativní blízkosti svého bydliště. Potvrzení faktu o nenáhodném rozmístění kriminality v prostoru potvrzují i mapy indexu kriminality. Čím větší je počet obyvatel v určité oblasti, tím vyšší je pravděpodobnost výskytu kriminality. Velký počet obyvatel totiž znamená vyšší hustotu zalidnění a větší společenskou interakci, což může vést k vyššímu riziku kriminality (Michálek, 2009). V následné interpretaci v základní úrovni zaměřené na výsledky prostorové vizualizace kriminality je pozornost soustředěna především na místa vykazující vysokou míru kriminality charakterizovanou čistým indexem kriminality.

Napříč sledovanými roky lze vysokou míru kriminality identifikovat především v Praze, na Mostecku, Ostravsku, velkých městech s vysokým počtem obyvatel, a poté v některých místech při pohraničí (výjimkou JV Česka). Po druhé světové válce byla organizována osídlovací akce v pohraničních regionech, které byly postiženy odsunem Němců a poklesem počtu obyvatel. Nově příchozí osadníci zpočátku neměli silný vztah k danému místu a nevytvořili fungující komunitu. Tato nízká sociální koheze mohla být jedním z důvodů zvýšeného výskytu trestné činnosti v severních, severozápadních a jižních Čechách, severní Moravě a Slezsku, stejně jako v okresech Znojmo a Břeclav. V průběhu druhé poloviny 20. století se do těchto regionů navíc soustředil těžký průmysl a těžba, a příliv pracovníků, zejména dělníků a dalších zaměstnanců, zvýšil nesoudržnost místních komunit a přispěl k nárůstu kriminality (Surmař, 2013). Vyšší hodnoty indexu kriminality lze během sledovaného období nalézt také na severní Moravě a ve Slezsku. Důvodem může být vyšší míra urbanizace ve městech jako je Ostrava-město, Karviná, Frýdek-Místek a Olomouc. Dále zde může hrát roli zvýšená míra nezaměstnanosti a zejména nízká sociální soudržnost.

Autoři (Harries, 1971; Michálek, 2009) dochází k závěru, že výskyt kriminality je spojen především s místy s vysokou mírou urbanizace. Toto zjištění může sloužit jako jedno z možných vysvětlení dlouhodobě vyššího indexu kriminality v okresech jako Chomutov, Most, Teplice, Liberec nebo Ústí nad Labem.

Okresy krajů Vysočina a Zlínského byly v pozorovaných letech typické relativně nízkými hodnotami indexu kriminality. Významným faktorem této skutečnosti je pravděpodobně vysoký podíl věřících lidí, který je v těchto místech tradičně nejvyšší.

### 4.1.2 Vážený index kriminality

V současné době neexistuje certifikovaná metodika popisující exaktní postup výpočtu indexu kriminality, který by byl v maximálně možné míře vypovídající a přesný, resp. který by věrohodně reflektoval reálný stav kriminality (s ohledem na dostupnost a kvalitu dat). Avšak přístupů k výpočtu indexu kriminality je celá řada. Snahou každého z přístupů je co nejvíce se přiblížit k reálnému vyjádření stavu kriminality v dané oblasti na základě vstupních dat. Autor této diplomové práce přichází s inovativním a nekonvenčním přístupem výpočtu kriminality s použitím vah. Zprvu je důležité vymezit dva odlišné přístupy výpočtů indexu kriminality, a sice konvenční a nekonvenční přístup. Zásadní rozdíl zmíněných přístupů je v použití vah v případě nekonvenčního výpočtu.

Avšak je důležité upozornit, že žádný z těchto přístupů není dokonalý a existují různé faktory, které mohou ovlivnit výsledky indexu kriminality. Například dostupnost a spolehlivost dat, použité metody a modely, a také subjektivní rozhodnutí ohledně vah faktorů mohou mít výrazný vliv na výsledky výpočtu. Proto je důležité být kritický a pečlivý při hodnocení výsledků indexu kriminality, a brát je s určitou rezervou.

Před výpočtem indexu je nezbytné mít na paměti změny v trestním zákoníku či evidenci TSK (přehled TSK je obsažen v příloze č. 3). Evidence změn struktury TSK je součástí přílohy 4 a byla s prosbou o žádost poskytnuta Ministerstvem Vnitra České republiky (MV ČR). V případě srovnání vypočtených hodnot indexu kriminality na základě vah za více časových období je podstatné si uvědomit, že součástí změn v trestním zákoníku je rovněž délka trvání doby odnětí svobody, a to jak horní, resp. dolní sazba, tak průměrná doba odnětí svobody. Struktura TSK se v průběhu let mění za účelem zpřesnění a zlepšení evidence trestných činů (ústní sdělení Ing. Heleny Linhartové z oddělení preventivních činností a dobrovolnictví Odboru prevence kriminality MV ČR), a proto je třeba zohlednit a dodržet změny metodiky primárního sběru, resp. evidence datových záznamů deliktů. V případě nedodržení těchto podstatných aspektů může nastat nekorektní interpretace výsledků hodnocení časového vývoje kriminality!

Výpočet váženého indexu kriminality za více let je příliš komplikovaný a srovnání výsledků by mohlo vést k mylným závěrům. Důvodem jsou obzvláště legislativní aktivity v oblasti vnitřní bezpečnosti státu, přesněji změna trestního zákoníku a následná komplikace při přiřazení vah (dat za dobu odnětí svobody) jednotlivým trestným činům. Při provádění výpočtů je nezbytné brát v úvahu legislativní změny před jejich implementací, neboť tyto změny mohou mít významný vliv na výsledky výpočtů. Užitečným přínosem v této problematice může být souhrnná *Zpráva o hodnocení situace na území ČR* za daný rok (zejména sekce legislativní aktivity), jež ročně vykazuje MV ČR.

Tato část práce navazuje na pilotní výzkum provedený Šimonem et Jíchovou (2018b). Autoři ve svém výzkumu používají 17 nejčtenějších trestných činů a přestupků pro popis kriminality. V případě trestných činů vzali základní paragrafové rozmezí trestní sazby bez zohlednění dalších specifikací činu podle písmen paragrafu a vypočetli střední hodnotu. Mj. uvádí, že při aplikaci této metodiky považují za vhodné zahrnout všechny trestné činy a přestupky a využít reálná data o udělené výši trestů či pokut z evidence.

#### **Koncept výpočtu váženého indexu kriminality**

Metoda aplikace váženého indexu kriminality spočívá ve výpočtu indexu kriminality na základě zvolených vah. Index lze vypočítat několika možnými způsoby, avšak této práci jsou dále popsány dva přístupy výpočtu indexu kriminality:

## **1. Výpočet váženého indexu kriminality s využitím dat o maximální době odnětí svobody**

Přístup s využitím dat o maximální době odnětí svobody je, podle vedoucího oddělení justiční analýzy a statistiky Odboru strategie a koncepce justice Ing. Václava Jonáše z Ministerstva spravedlnosti ČR (MS ČR), nejvíce vypovídající, jelikož v právním kontextu je v případě odsouzení pachatele za více trestných činů (paragrafů trestního zákoníku TZ z roku 2009), nejzávažnější trestný čin takový, za nějž je možno uložit nejvyšší trest dle trestního zákoníku. Například – pachatel je odsouzen za trestný čin dle § 146, odstavec 1 (ubližení na zdraví) a § 358, odstavec 1 (výtržnictví). Za § 146, odstavec 1 je možné uložit trest odnětí svobody ve výši šest měsíců až tři léta a za § 358, odstavec 1 je možné uložit trest odnětí svobody až na dvě léta. Za § 146, odstavec 1 je možné uložit vyšší trest, a proto je v datech vykázán jako závažnější trestný čin a uložený trest je tedy vykázán u tohoto trestného činu. Je to tak, protože možná výše trestu je závislá právě na nejzávažnějším trestném činu.

Vážený výpočet indexu kriminality lze tedy uskutečnit tak, že nejzávažnější trestný čin v kontextu trestního zákoníku je vynásoben odpovídající hodnotou maximální doby odnětí svobody, kterou představuje horní hranice sazby jednotlivých paragrafů, odstavců a písmen. Hodnota váhy odpovídá horní hranici sazby trestního činu podle trestního zákoníku uvedenou v měsíčních časových jednotkách. Data za nejvyšší možné období udělení trestů dle trestního zákoníku lze získat z trestního zákoníku nebo žádostí o poskytnutí dat MS ČR. Číselník paragrafů trestných činů s dolní, resp. horní hranicí sazby (odnětí svobody na počet měsíců) je obsažena v příloze 66.

## **2. Výpočet váženého indexu kriminality s využitím dat o průměrné době odnětí svobody za určité časové období**

Autor práce doporučuje počítat pouze s hodnotami průměrné délky nepodmíněného trestu v měsících, jelikož se podle něj jedná o reflektující skutečnost ukládání trestů v Česku za jednotlivé trestné činy.

Tato data lze dohledat na webové aplikaci *JakTrestame.cz* dostupné z <<https://jaktrestame.cz>>. Projekt vznikl ze spolupráce skupiny doktorandů z Právnické fakulty Univerzity Karlovy, Centra pro ekonomický výzkum a doktorské studium (CERGE-EI) a datového novináře. Další možností je zaslání žádosti MS ČR o vykázání dat za průměrnou dobu odnětí svobody dle dílčích paragrafů v trestním zákoníku. Součástí přílohy 67 jsou informace průměrné doby odnětí svobody trestných činů roztrženy podle paragrafů a odstavců trestního zákoníku. Tabulka dále disponuje s počty odsouzených pachatelů celkem, počty odsouzených pachatelů nepodmíněně, počty odsouzených pachatelů podmíněně a průměrnou délkou nepodmíněného trestu odnětí svobody v měsících za časové období 2012 až 2021.

Prvním uvažovaným přístupem bylo v rámci pilotní studie snahou aplikovat výpočet indexu kriminality na úrovni obcí s použitím dat o kriminalitě z *Mapy kriminality* pro rok 2021. I přes veškeré snahy nebylo možno získat informace týkající se přiřazení dílčích paragrafů TZ k jednotlivým třídám trestných činů podle seznamu publikovaných tříd podle kriminalisticko-statistických tříd, která je použita v aplikaci *Mapa kriminality*. MV i PČR prostřednictvím emailové korespondence sdělilo, že převodník mezi klasifikací kriminalisticko-statistických tříd a klasifikací podle TZ neexistuje. Také dodali, že struktura klasifikace kriminalisticko-statistických tříd a TSK se zčásti překrývá, ale nejsou zcela totožné. V rámci konzultace se soudcem Judr. Miroslavem Trávníčkem (Okresní soud Ústí nad Orlicí) bylo zmíněné téma přiřazení hodnot a vytvoření převodníku

mezi TSK (takticko-statistickou klasifikace) a klasifikací kriminalisticko-statistických tříd (v Mapách kriminality) diskutováno. Za pomoci jeho odbornému úsudku byla sestavena tabulka obsahující přiřazení průměrných hodnot doby odnětí svobody podle kriminalisticko-statistických tříd (příloha 70). Z důvodu jiného vhodnějšího řešení výpočtu indexu kriminality však nebyl tento přístup použit, a proto lze na tento koncept navázat dalším výzkumem. Avšak je nutno upozornit na nemožnost převodu klasifikace evidence trestných činů, která je použita v Mapě Kriminality od PČR a neexistence převodníku mezi touto klasifikací a klasifikací trestního zákoníků (evidence dle ESSK – Evidenčně statistický systém kriminality). Klasifikace podle kriminalisticko-statistických tříd v Mapě kriminality neobsahuje jednoznačné přiřazení (číselník) trestných činů dle trestního zákoníku. V klasifikaci podle kriminalisticko-statistických tříd jsou pojmy jako např. násilná kriminalita, což je pojem kriminologický, nikoliv právní. Jedná se o obsáhlý seznam trestných činů různého charakteru typové závažnosti a rozdílných následků. Definice a výčet typů trestných činů je komplexní a nachází se v různých částech trestního zákoníku, v závislosti na specifických kritériích a situacích. Pro přehlednost je v příloze 3 uvedena tabulka, která obsahuje kompletní výčet trestných činů dle policejní takticko-statistické klasifikace Úřadu služby kriminální policie a vyšetřování Policejního prezidia České republiky Policie České republiky (Novotný et al., 2008).

### **Realizace výpočtu váženého indexu kriminality**

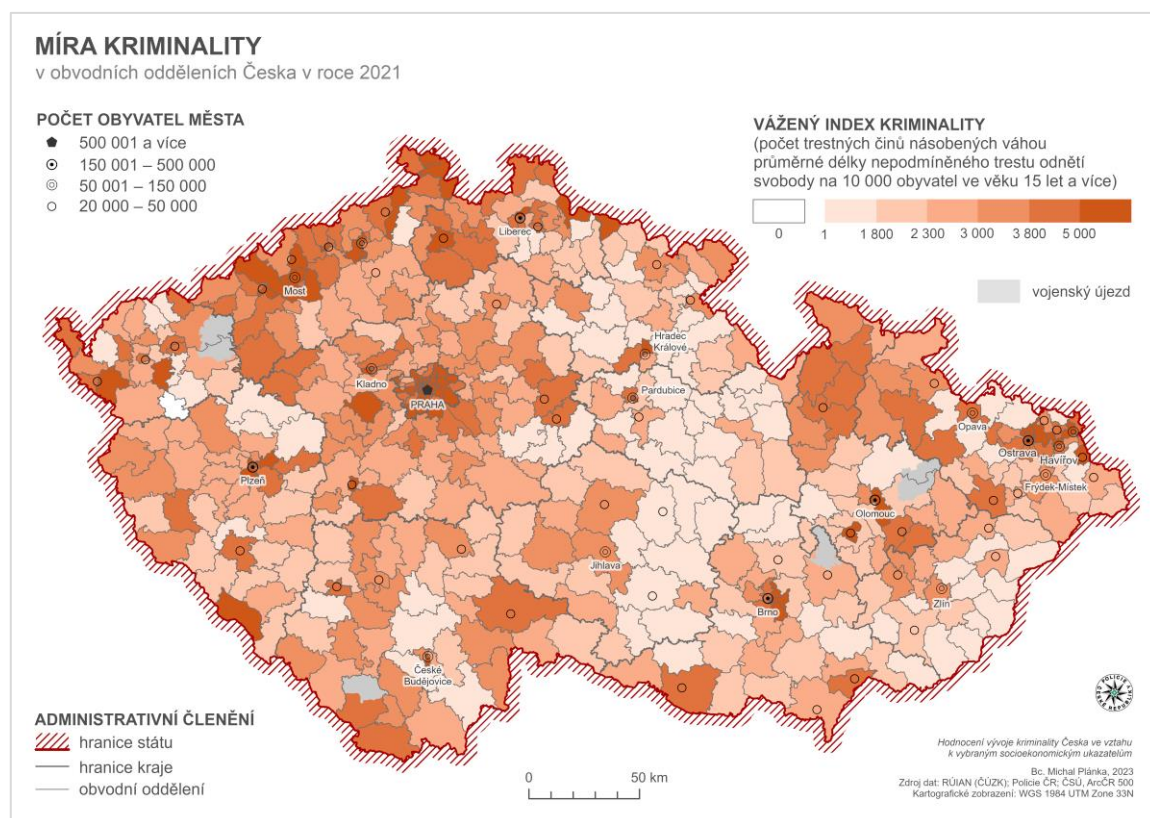
V rámci diplomové práce byl proveden výpočet váženého indexu kriminality pouze pro rok 2021 v obvodních odděleních Česka. Důvodem jsou legislativní změny napříč roky a také na aktuálnost a dostupnost statisticky relevantních registrovaných dat kriminality (příloha 74), které laskavě poskytl Radek Saňák z Odboru věcných gescí a statistik Úřadu služby kriminální policie a vyšetřování – Policejní prezidium České republiky. Těchto základních útvarů je na území Česka celkem 507. Strukturovaná data registrovaných skutků jsou klasifikována podle Takticko-statistická klasifikace (TSK). Data obsahují evidované počty všech typů trestných činů v jednotlivých policejních obvodních odděleních. Policejní obvodní oddělení v České republice jsou v kontextu prostoru nejpodrobnější územní jednotkou policejní správy. Je to nejnižší úroveň policejního členění a odpovídá územní působnosti konkrétního obvodního oddělení, které má na starosti místní správu veřejného pořádku, vyšetřování trestných činů a provádění policejních opatření na svém přiděleném území. Radek Saňák uvádí následující informace ohledně zásad pro počítání skutků:

- a) V případě jednočinného souběhu se jedná o jeden skutek.
- b) Při souběhu trestných činů se pro označení skutku použije ten, který je podle horní hranice trestní sazby u trestu odnětí svobody nejpřísněji trestný. Jsou-li horní hranice trestních sazeb při souběhu trestných činů shodné, použije se pro označení skutku trestný čin, v němž byla podstata činnosti pachatele. Výjimkou jsou případy, kdy je nutné dát přednost taktickému hledisku (např. u dopravních nehod je vykázáno TSK, pod nímž je uvedena příslušná dopravní nehoda, bez ohledu na trestně právní posouzení).
- c) Jako samostatný skutek se neposuzuje účastenství na dokonaném trestném činu nebo jeho pokusu.
- d) Jako jediný skutek jsou vykazovány i trestné činy trvající a hromadné.
- e) Jako samostatný skutek se rovněž vykazuje každý útok opakovaného trestného činu. V případě vícečinného souběhu se vykazuje každý skutek.

Ve výpočtu jsou zahrnuty váhy, které byly vypočítány na základě průměrného počtu

nepodmíněného odnětí svobody (v měsících) pro každý typ trestné činnosti klasifikovaných podle TZ. Dané hodnoty vah byly následně vynásobeny počtem příslušných trestných činů (klasifikovaných podle TSK, kde je současně obsažen i příslušný paragraf skutku v TZ), vyděleny počtem trestně právních obyvatel (ve věku 15 let a více) a vynásobeny hodnotou 10 000. Prostorová distribuce vypočtených hodnot váženého indexu kriminality je patrná z obrázku 5.

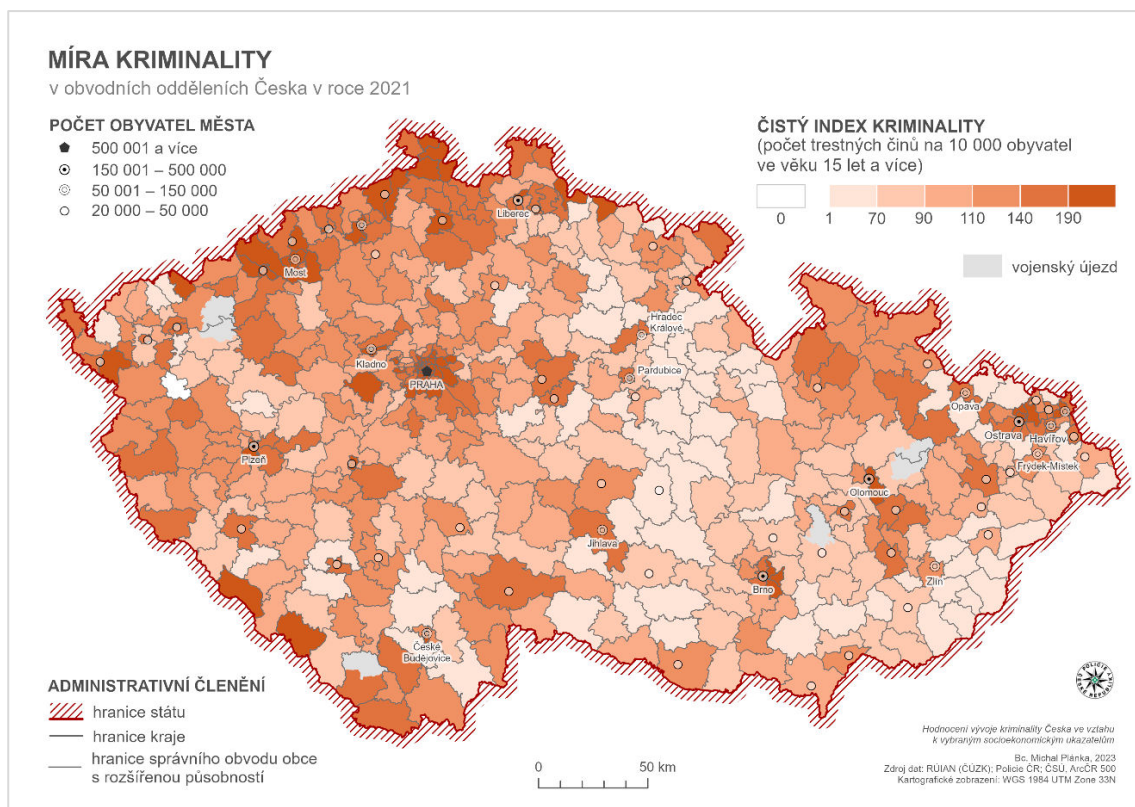
Přiřazení vah závažnosti kriminality je zjednodušené a provedeno z didaktických důvodů, avšak i tak může poskytnout solidní empirické výsledky. Tato metodika může být rovněž vhodná pro porovnání různých typů kriminality. Nicméně je důležité mít na paměti, že přiřazení vah může být ovlivněno subjektivitou a záviset na kontextu a představách jednotlivců nebo skupin.



Obr. 5 Vážený index kriminality. Zdroj: vlastní.

Významné oblasti s vysokými hodnotami indexu kriminality zahrnují především Prahu a její okolí, Mostecko, Jeseníky a Ostravsko. Naopak oblasti s nízkými hodnotami indexu lze identifikovat v pohraničních oblastech se Slovenskem a dále v pásmu rozkládajícím se od Rychnova nad Kněžnou přes Hlinsko až po Velké Meziříčí.

Statistická data kriminality byla rovněž zahrnuta do výpočtu čistého indexu kriminality. Nicméně kvůli rozdílným metodám výpočtu indexu kriminality nelze porovnat kvalitu výpočtů ve výsledných mapových výstupech. Mapa čistého indexu kriminality v policejních obvodních odděleních ČR (viz obrázek 6) byla vytvořena za účelem hlubšího porozumění a hledání vzájemných vztahů mezi kriminalitou vypočtenou užitím různých přístupů.




Obr. 6 Čistý index kriminality. Zdroj: vlastní.

Je však důležité poznamenat, že zpřesnění výpočtu indexu kriminality pomocí vah nelze jednoznačně posoudit pouze na základě dílčích mapových výstupů. Podstatou tohoto výpočtu je zahrnutí vah, které představují průměrnou dobu odnětí svobody (v měsících), což přispívá k lepšímu odrazu reality. Hodnoty dob odnětí svobody (v měsících) podle TZ jsou součástí excelové tabulky v rámci přílohy 74 v *záložce 2021\_puvod*. Tabulka obsahuje kvantitativní údaje mj. o celkovém počtu odsouzených, odsouzených nepodmíněně a odsouzených podmíněně. Tato data byla ve strukturované formě poskytnuta Ing. Václavem Jonášem, vedoucím oddělení justiční analýzy a statistiky Odboru strategie a koncepce justice Ministerstva spravedlnosti České republiky. Někdy však chybí údaje pro daný rok. Důvodem je, že pokud nebyl v daném roce zaznamenán trestný čin, nikomu nebyl uložen nepodmíněný trest odnětí svobody. To může mít několik důvodů, například:

- pachateli mohl být uložen alternativní trest
- nikdo nebyl za daný trestný čin odsouzen v daném roce
  - státní zastupitelství mohlo věc ukončit jinak než podáním obžaloby
  - u soudu mohlo dojít k zproštění či zastavení věci
  - soudní řízení mohlo skončit v jiném roce nebo ještě neskončilo.

Je také důležité poznamenat, že PČR a MS ČR mají zcela oddělené statistické systémy, což může způsobovat obtíže s "návnazností dat".

Pro zajímavost bylo vytvořeno grafické vyjádření zmíněných dat – graf 3. Data zahrnují počet odsouzených osob za období šesti let (od roku 2016 do roku 2021). Celkově lze z dat vyčíst, že od roku 2016 dochází k poklesu počtu odsouzených osob. Tato data mohou být použita pro analýzu trestní politiky, rozhodování o trestech a plánování dalších opatření v rámci trestního systému.



Graf 3 Četnost odsouzených osob. Zdroj: vlastní.

### Pokročilá vizualizace váženého a čistého indexu kriminality


Výpočet váženého indexu kriminality byl proveden pomocí vzorce, který zahrnuje váhy (průměrné počty nepodmíněných odnětí svobody) a počet registrovaných trestných činů v obvodních odděleních v roce 2021. Cílem bylo vytvořit mapovou vizualizaci, která umožní prezentovat kombinaci výsledků výpočtu čistého a váženého indexu kriminality v kompetentní formě za účelem vzájemného srovnání.

Intenzity čistého a váženého indexu kriminality byly rozděleny do tří úrovní – podprůměrná, průměrná a nadprůměrná. Pro tři úrovně výskytu těchto dvou jevů vznikla třetího řádu čtvercová matice s devíti prvky, kterým byla přiřazena kombinace dvou barevné škály. Škála prezentuje kvantitativní vztah mezi dvěma proměnnými ve vrstvě. Tato metoda vizualizace používá zmíněné barevné škály pro vizuální porovnání, zvýraznění nebo ohraničení hodnot (Bivariate colors, 2021). Dvojitá barevná škála (angl. bivariate color scheme) byla vytvořena v rozhraní ArcGIS Pro. Tyto tři úrovně intenzity jevu byly vytvořeny na základě přirozených zlomů (Jenks, 1967), kde stanovené kritické hodnoty automaticky rozdělují nízkou, střední a vysokou frekvenci jevu ve statistickém souboru jevu. Rozdělení podle kvantilů by ve výsledku ohodnotilo téměř všechna obvodní oddělení různými barvami, což by mohlo způsobit ztrátu nejdůležitějšího sdělení.

Metoda *Bivariate colors* byla zvolena za účelem optimální vizualizace k intuitivnímu vizuálnímu srovnání (kombinaci) dvou odlišných výpočtů indexu kriminality, které se však současně doplňují (obr 9). V podstatě došlo ke kalibraci a rozšíření výstupních informací v rámci vizualizace. Většina obvodních oddělení má barvu ze středové vertikální osy, což znamená že v obou případech jevů zůstávají ve stejném intervalu (intervaly hodnot spolu koreluji). Území, která inklinují k váženému indexu kriminality jsou v mapě vyjádřeny v odstínech modré barevné škály. Naopak, odstíny červené barvy signalizují náklonnost k čistému indexu kriminality.

Z mapy (obr. 7) lze vyčíst, že z hlediska kriminality jsou nejvíce zatíženy Praha, Mostecký okres, Jindřichohradecký okres, Českolipský okres, Bruntálský okres, Ostrava a další velkoměsta s počtem obyvatel přesahujícím 150 tisíc. Naopak nejnižší hodnoty indexu kriminality jsou zaznamenány na pohraničí se Slovenskem, ve východní části Vysočiny, v Pardubickém kraji až po střední oblast Karlovarského kraje.





Obr. 7 Kombinace váženého a čistého indexu kriminality (viz příloha 25). Zdroj: vlastní.

#### 4.1.3 Analýza časového vývoje typů trestných činů

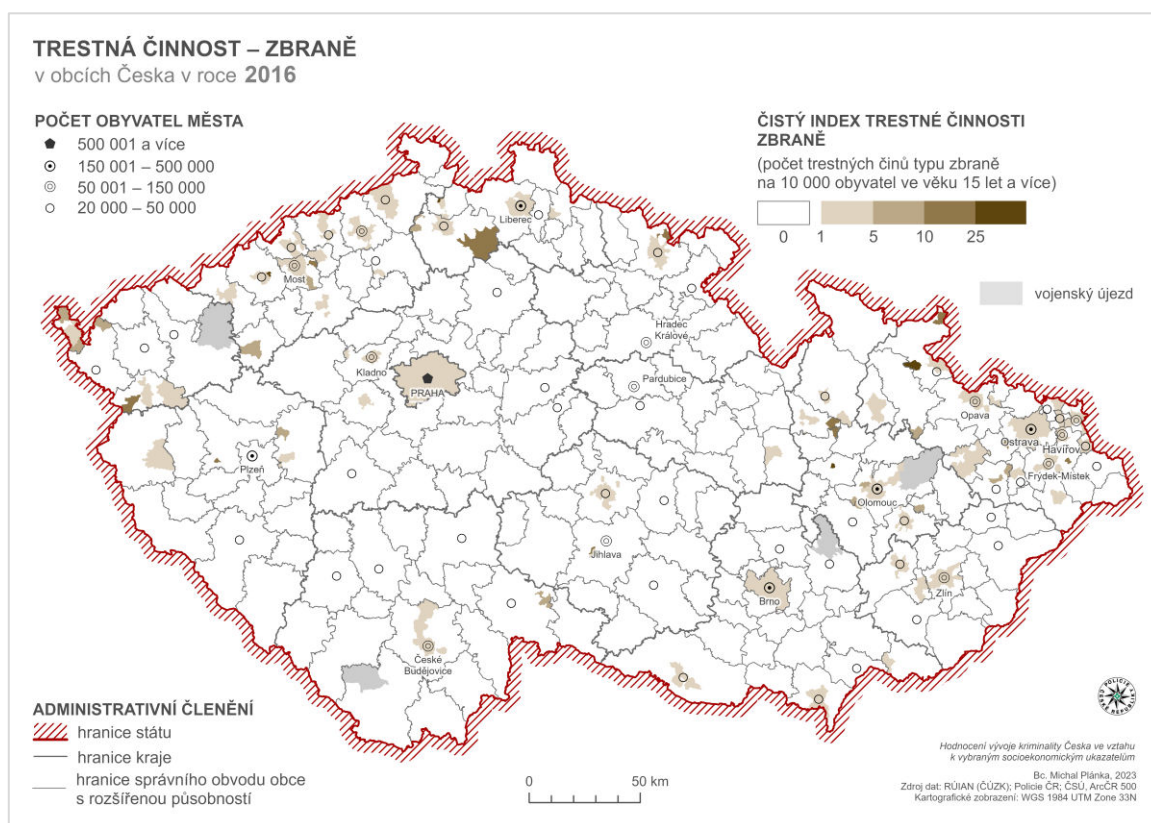
V rámci této části práce byla provedeno zpracování dat týkajících se kriminality s využitím dílčích agregovaných bodových vrstev trestných činů za jednotlivé roky (2016–2021). Nejprve byly atributové tabulky bodových vrstev vyexportovány do tabulky v datovém formátu .xlsx. Následné zpracování dat trestných činů probíhalo v programu Excel, kde byl atribut „types“ (tj. druhy trestných činů) rozdělen do jednotlivých sloupců na základě oddělovačů čárka s cílem rozdělit jednotlivé trestné činy do samostatných sloupců. Tento zpracovaný excelovský soubor byl poté zpět načten do programu ArcGIS Pro, kde byly vytvořeny nové atributy s názvy 11 typů trestných činů (dopravní nehody, krádeže, krádeže vloupáním, obecně nebezpečná, jiná majetková, extremismus, podvody, požáry a výbuchy, násilná, toxikománie a zbraně). Následoval proces dichotomizace, tj. do jednotlivých atributů byly za pomoci dílčích SQL příkazů (*Select By Attributes*) vloženy hodnoty jedniček (*Calculate Field*), což značí, že daný trestný čin se stal, a v opačném případě bylo ponechána výchozí hodnota NULL, což značí absenci trestného činu.

Dále byly vybrány u každého typu trestného činu hodnoty 1 za pomoci funkce *Summarize Within* byl spočítán počet bodů pro jednotlivé polygonové obce. Bylo vytvořeno nové pole s názvem CIK, do kterého byl vypočítán čistý index kriminality pro jednotlivé trestné činy. Tento postup byl manuálně opakován pro každý typ trestného činu za období 2016–2021. Vzhledem k různému počtu sloupců jednotlivých tříd trestných činů byla automatizace (ModelBuilder, Python script) výběru a vložení hodnot bohužel neuskutečnitelná. Dále byla vytvořena série map indexů kriminality (resp. jednotlivých trestných činů) za uvedené období. Následovalo vytvoření mapových animací (v programu Adobe Illustrator) jednotlivých typů indexů kriminality (1,5 sekundy na snímek), jež jsou

obsaženy v přílohách 16–23. Metoda animace byla autorem zvolena z několika relevantních důvodů – snadné vizuální porovnání jednotlivých map v čase, efektivní využití čas, více informací na jednom místě, lepší prezentace dynamických změn kriminality a vysvětlení či ilustrace složitějších konceptů.

Mapy jsou efektivnějším prostředkem než text pro vyjádření prostorových dat o kriminalitě. Mapy nabízí rychlé porovnání či identifikaci trendů výskytu kriminality. Pro přehlednější kontrolu a přizpůsobení nad vizualizací map typů trestných činů byla vytvořena v rámci dílčího výstupu matice 66 map, jejichž grafická úprava byla provedena rovněž v programu Adobe Illustrator (příloha 24). Je třeba poznamenat, že bylo počítáno pouze s trestně právními osobami, takže index kriminality byl „vyčištěný“ (čistý) od nežádoucích vlivů v kontextu přepočtu na trestně odpovědné osoby, tj. 15 let a více.

Zajímavostí je, že trestné činy spojené se zbraněmi byly v roce 2016 prostorově rozmístěny v ČR nejvíce (obr. 8), avšak v průběhu posledních let vykazují pokles. Typ *majetkové trestné činnosti*, která souvisí s autonehodami vykazuje vyšší míru indexu v obcích, kterými procházejí dálnice. Nicméně autonehody na dálnicích mohou vést k různým druhům kriminality, jako je poškození majetku při havarování vozidel, dále např. krádež osobních věcí z vozidel, která byla zaparkována na odstavných pružích. Vyšší míra kriminalita se může vyskytovat také v obcích poblíž dopravních komunikací, kde dochází ke zvýšenému provozu vozidel, a tím se zvyšuje i riziko trestné činnosti.

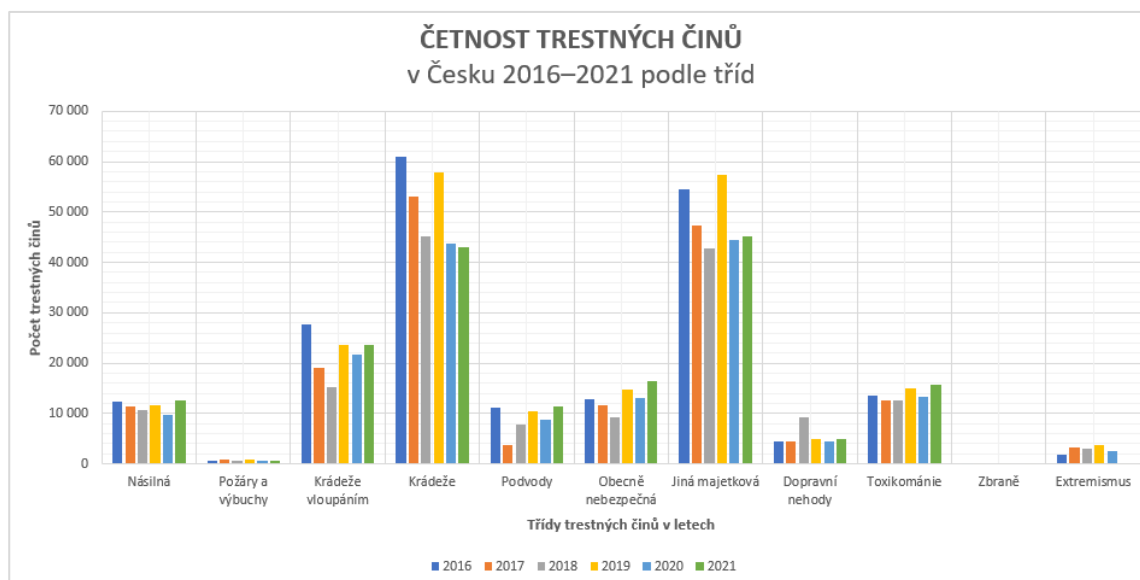


Obr. 8 Index trestné činnosti zbraní (viz příloha 17). Zdroj: vlastní.

Sumarizace statistických dat obsahující informace o různých typech trestné činnosti je prezentovaná v tabulce obsažené v příloze 73. Data ukazují, že obce Všehrady a Dobrovíz se opakují v rámci vysokých hodnot čistého indexu kriminality v kategoriích *Jiná majetková* a *Krádeže*. V letech 2017 a 2019 měla obec Všehrady nejvyšší hodnoty

čistého indexu kriminality v kategorii *Jiná majetková* s hodnotami 1641,79 a 3255,81. Obec Dobrovíz pak vykazovala vysoké hodnoty čistého indexu kriminality v kategorii *Krádeže* v letech 2016 a 2019 s hodnotami 1995,57 a 1026,55. Podle dat mohou mít obě zmíněné obce vyšší výskyt *majetkových* trestných činů, zejména *Krádeží*, v porovnání s ostatními obcemi v analyzovaném období. Tato informace může být důležitá pro místní správu a orgány činné v trestním řízení, které by se mohly zaměřit na prevenci a řešení trestné činnosti v daných obcích.

Za účelem srovnání neprostorových dat typů trestných činů byl vytvořen graf 4. Výsledky ukazují vývoj různých typů trestné činnosti za sledované období v Česku. Počet případů násilné trestné činnosti byl v roce 2021 nejvyšší, dosahující hodnoty 12 499. Celkově došlo k poklesu násilné trestné činnosti od roku 2016, s výjimkou roku 2019, kdy byl zaznamenán krátkodobý nárůst. Počet případů požárů a výbuchů se zvýšil z roku 2016 na rok 2017, ale od té doby se pohybuje na stabilní úrovni kolem hodnoty 670 případů ročně. Počet případů krádeží vloupáním zaznamenal výrazný nárůst zejména mezi roky 2016 a 2019, kdy se počet případů zvýšil z 27 621 na 23 652. Od roku 2019 se však tento typ trestné činnosti stabilizoval na hodnotě kolem 23 000 případů ročně. Počet případů běžných krádeží vykazuje postupný pokles od roku 2016, kdy bylo zaznamenáno 60 879 případů, na 42 980 případů v roce 2021. Počet případů podvodů zaznamenal několik výrazných kolísání, ale celkově se pohyboval na relativně stabilní úrovni kolem hodnoty 10 000 případů ročně s výjimkou roku 2017, kdy došlo k výraznému poklesu na hodnotu 3 669. Obecně nebezpečná trestná činnost vykazuje růst, s nejvyšším počtem případů v roce 2021 dosahujícím hodnoty 16 346. Počty případů dalších typů trestné činnosti, jako jsou jiné majetkové trestné činnosti, dopravní nehody, toxikománie, zbraně a extremismus, se různě vyvíjely v jednotlivých letech s mírným nárůstem nebo poklesem, ale žádný z nich nevykazuje dramatické změny. Důvody pro tyto poklesy a nárůsty trestné činnosti mohou být různé a mohou se lišit v závislosti na konkrétních okolnostech. Například poklesy trestné činnosti mohou být důsledkem úspěšných opatření v boji proti kriminalitě, zlepšení sociálních a ekonomických podmínek, změn ve společenských hodnotách nebo změn v právních předpisech. Naopak nárůsty trestné činnosti mohou být způsobeny například zvýšenou aktivitou kriminálních skupin, ekonomickou nestabilitou, sociálním napětím nebo změnami ve společenských a kulturních trendech.



Graf 4 Četnost trestných činů

Covid-19 a karanténní opatření výrazně ovlivnily míru kriminality v Česku. Během pandemie docházelo ke změnám v kriminálním dění, přičemž některé druhy kriminality se zvýšily, zatímco jiné se snížily. Například došlo k nárůstu podvodů pravděpodobně spojených s online nákupy a finančními transakcemi, zatímco klesla trestná činnost spojená s trestnými činy proti majetku, jako je krádež a loupeže, v důsledku omezení volného pohybu obyvatel a uzavření některých podniků. Karanténní opatření také ovlivnila trestnou činnost ve veřejném prostoru, jako je například snížení počtu trestných činů spáchaných na veřejných místech v důsledku omezení veřejných akcí a zákazu shromažďování. Celkově lze tedy konstatovat, že pandemie Covid-19 a karanténní opatření měly výrazný dopad na kriminalitu v Česku, s různými změnami v jednotlivých druzích trestné činnosti (Scheinost et al., 2021). Podle Ing. Heleny Linhartové z oddělení prevence kriminality MV ČR se během karanténních opatření v důsledku uzavření kamenných obchodů a omezení veřejné dopravy zvýšilo množství krádeží jízdních kol. Lidé hledali alternativní způsoby dopravy, zejména ve městech, kde se potřebovali pohybovat rychleji a efektivněji, a jízdní kola se stala populární volbou. Bohužel, tento trend mohl být doprovázen i zvýšeným rizikem krádeží jízdních kol, zejména pokud nebyla dostatečně zabezpečena nebo byla ponechána na veřejných místech. Tento jev ukazuje, jak pandemie a karanténní opatření mohou mít nepředvídatelné dopady na kriminalitu a chování lidí.

## **4.2 Závislé a nezávislé proměnné**

### **4.2.1 Výběr nezávisle proměnných**

Často kladenou otázkou v odborném výzkumu je, jaké a kolik indikátorů je optimálních pro hodnocení míry kriminality s dostatečnou vypovídající hodnotou. Literatura však dosud nenabízí jednoznačnou odpověď na tuto otázku. Některé studie preferují minimalistický přístup, který upřednostňuje použití menšího množství pečlivě vybraných klíčových domén a jejich indikátorů (Hagan, 2011). Existuje mnoho faktorů, které mohou ovlivnit míru kriminality v dané oblasti, a zahrnují mnoho ekonomických, kulturních a demografických faktorů. Některé z těchto faktorů jsou možná spíše korelací než příčinou kriminality.

Vzhledem k ambicióznímu konceptu práce zhodnotit míru kriminality na úrovni obcí napříč Českem byl výběr indikátorů vstupujících do regresních modelů vybrán podle dostupnosti, aktuálnosti statistických socioekonomických dat s ohledem na validní výsledky předešlých výzkumů kriminogenních faktorů (mj. Surmař, 2013; Ceccato, 2009; Michálek, 2009; Mennis et al., 2010; Hagan, 2011; Ellis, Beaver a Wright, 2009) a dle vlastního uvážení po konzultaci s odborníky. Nicméně, výsledky některých studií, které zkoumají vztah kriminality vůči socioekonomickým ukazatelům jsou obecně smíšené a někdy i protichůdné. V každém případě je důležité si uvědomit, že kriminalita je velmi komplexní jev a nelze ji vysvětlit pouze jedním faktorem. Proto je důležité provádět důkladné výzkumy a analýzy, které zohledňují více proměnných a poskytují podrobnější a přesnější informace o souvislostech mezi kriminalitou a ostatními socioekonomickými faktory.

Pro zahrnutí nezávislých proměnných (prediktorů), kterými jsou podíly kategorizovaných vzdělaných osob na počtu obyvatel starších 15 let, bylo zavedeno z několika důvodů. Předpokládá se, že jedinci s vyšším vzděláním mají lepší příležitosti na trhu práce, což snižuje riziko finanční tísně a deprivace v této skupině. Dále proto, že tito jedinci jsou pro sebe schopni lépe posoudit důsledky spáchání trestného činu. Pokud

se tedy trestná činnost vyskytuje, pravděpodobně se jedná spíše o trestné činy s finanční nebo hospodářskou povahou, které mají menší pravděpodobnost odhalení. Tito jedinci jsou pravděpodobně také schopni tuto činnost lépe skrýt. Vyšší podíl jedinců s vysokoškolským vzděláním by tak mohl vést k nižšímu indexu kriminality. Pro analýzu byla použita data o počtu jedinců s ukončeným vysokoškolským vzděláním ze sčítání lidu provedeného v roce 2011 (Surmař, 2013). Oproti tomu lidé s nižším vzděláním mohou mít omezené příležitosti na trhu práce a mohou čelit finančním obtížím. Tím se zvyšuje riziko, že se budou uchýlovat k nelegálním nebo kriminálním aktivitám jako způsobu, jak si vydělat peníze. Nedostatek vzdělání může také vést k nižší informovanosti o právech a povinnostech občanství, což může snižovat zájem o dodržování zákonů a sociálních norem.

Výzkum provedený Michálkem (2009) na Slovensku ukázal, že podíl věřících osob má významný vliv na variabilitu indexu kriminality. Vyšší podíl věřících je spojen s nižší kriminalitou. Pro regresní analýzu byla použita data z roku 2021, která zahrnuje všechny věřící osoby bez ohledu na jejich příslušnost k církvi nebo náboženské společnosti. Očekává se tedy, že výsledky regresních modelů potvrdí tuto skutečnost.

Pro dílčí zachycení sociálních vazeb byly použity ukazatele rodinného stavu, konkrétně podíly rozvedených, a svobodných obyvatel. Autor práce předpokládá, že území s vyššími hodnotami těchto ukazatelů budou charakterizovány zhoršenými sociálními vazbami, což může mít za následek zvýšení indexu kriminality. Podíl sezdaných obyvatel by dle předpokladu měl vykazovat snížení indexu kriminality.

Přehled potenciálních demografických datových zdrojů identifikuje jako nejpoužitelnější zdroje Veřejná databáze Českého statistického úřadu (ČSÚ), přesto však nabídka použitelných dat indikátorů, které splňují požadavky na vybrané prostorové vymezení a časovou aktuálnost je omezená.

Autor práce předpokládá, že osoby, které jsou v exekuci, mohou čelit finančním potížím, mají dluhy a mohou se ocitnout ve ztížené ekonomické situaci. Tato ekonomická zátěž a stres spojený s exekucemi může mít negativní dopad na jejich životní situaci, včetně jejich sociálního prostředí, rodinného života a psychického zdraví, což může vést k páchání kriminality. Výběr ostatních prediktorů byl uskutečněn na základě literární rešerše, dle autorova vlastního uvážení a po konzultaci s odborníky a vedoucím práce.

S narůstající prostorovou podrobností se obecně zvyšuje problém s nedostupností dat. V těchto situacích se často objevovalo dilema, zda rozšířit datovou sadu o nový indikátor za cenu nezachování rozsahu podrobnosti administrativního členění (úroveň obcí). Řada indikátorů byla vyloučena za účelem zachovat prostorový detail hodnocení, neboť ve vyhodnocení dat v podrobnějším prostorovém měřítku lze identifikovat jeden z hlavních cílů a také přínosů této práce. Proto byly za účelem aplikace regresních modelů vytvořeny scénáře pro rok 2021 s ohledem na kvalitu, dostupnost a časovou aktuálnost dat ze Sčítání lidu, domů a bytů (SLDB 2021).

## 4.2.2 Sestavení datasetu

Zpracování statistických socioekonomických dat bylo realizováno v programu Microsoft Excel. Data absolutních počtů ukazatelů byly přepočteny na relativní data (% podíly, míry) za účelem standardizace, tzn. srovnání různě velkých obcí v kontextu počtu obyvatel. Příloha 76 zobrazuje výsledný výběr socioekonomických ukazatelů, které vstoupí do regresních modelů. Počet obyvatel obsahuje obyvatele s obvyklým pobytem pro rok 2021.

### Kvalita dat

Sestavený dataset indikátorů vstupujících do regresních modelů má omezenou míru spolehlivosti. Jeden z aspektů je samotná spolehlivost původních dat trestných činů získaných z Mapy kriminality, která je použita v závislé proměnné (indexu kriminality). Tato spolehlivost je autorem práce zpochybňována a na základě předešlé analýzy dat trestných činů a následného výpočtu indexu kriminality lze konstatovat, že se nejedná o data statisticky relevantní, tj. data nejsou vhodná ke statistickému zpracování analýz. V tomto případě je třeba registrovat výsledky regresního modelování s určitou rezervou a kritickým postojem.

## 4.2.3 Statistika dat nezávislých proměnných

Základní popisná statistika hlavních charakteristik polohy a variability nezávislých (vysvětlujících) proměnných pro celkem 6254 sledovaných obcí je shrnuta v příloze 77. Popisné statistiky slouží k základnímu pochopení dat, avšak vzájemné srovnání ukazatelů není možno z důvodu rozdílných jednotek. Pro hodnocení relativního významu průměrné odchylky od průměru, tedy kolik procent průměru představuje směrodatná odchylka, je zajímavý bezrozměrný variační koeficient. U některých indikátorů převyšuje hodnota variačního koeficientu hodnotu 0,5, což naznačuje vysokou nesourodost sledovaného indikátoru, zejména u hustoty zalidnění, migrace, podílu obyvatel bez vzdělání, s vyšším odborným vzděláním a předčasných odchodů ze ZŠ, podílu Romů, obyvatel v exekuci, insolventů, příjemců příspěvků na bydlení, uchazečů o zaměstnání a podíl obyvatel s náboženským vyznáním. Nenulové hodnoty koeficientu šikmosti naznačují, že pravděpodobnostní rozdělení dat není normální, s nejmenší asymetrií pozorovanou u ukazatelů podílu sezdaných, obyvatel se SŠ vč. vyučení, s úplným středním, vč. nástavbového studia a procentuální volební účasti. Koeficient špičatosti u většiny indikátorů naznačuje koncentraci hodnot kolem průměrné hodnoty, nejsilnější koncentrace je pozorována u hustoty zalidnění, podílu obyvatel bez vzdělání, podílu Romů, svobodných a rozvedených. Hodnoty blízké nule naznačují rovnoměrné rozložení kolem střední hodnoty, což je pozorováno u podílů obyvatel se SŠ vč. vyučení a úplným středním, vč. nástavbového studia.

Vzájemné vztahy mezi objektivními indikátory byly analyzovány pomocí metod exploračních analýz, které odhalily potenciální vztahy mezi jednotlivými indikátory, jež je vhodné detailněji popsat a kvantifikovat. Míra lineární závislosti mezi dvěma spojitými náhodnými veličinami může být popsána kovariancí. Pro praktičtější a běžnější vyjádření tohoto vztahu se používá korelace, která je standardizovanou kovariancí. Spearmanův korelační koeficient umožňuje detekci nelineárních vztahů – jedná se o neparametrický test, který pracuje s pořadím a je tolerantní vůči odchylkám od normálního rozdělení.


Vzhledem k tomu, že většina ukazatelů není charakterizována normálním rozdělením dat, byl pro všechny kombinace ukazatelů vypočten Spearmanův korelační koeficient. V programu R studio byla vytvořena korelační matice s grafy normálního rozdělení (hlavní

diagonála) a Q-Q grafů, kde je zahrnut také index kriminality. Grafické vyjádření maticových grafů, včetně korelační matice (přílohy 49 a 50), seskupují ukazatele podle charakteru jejich vztahu. Interpretace korelačního koeficientu není jednoznačná a může se lišit. De Vaus (2002) provedl společenské vědy kategorizaci do následujících intervalů: 1,00 = *perfektní*; 0,99–0,90 = *téměř perfektní*; 0,89–0,80 = *velmi silná*; 0,79–0,70 = *silná*; 0,69–0,50 = *významná*; 0,49–0,30 = *střední*; 0,29–0,10 = *nízká*; 0,09–0,00 = *nedůležitá*. Hodnota korelačního koeficientu se může pohybovat v intervalu hodnot od -1 do 1, přičemž -1 znamená silnou zápornou korelaci (když  $X$  se zvýší,  $Y$  se sníží); 0 znamená, že mezi oběma proměnnými ( $X$  a  $Y$ ) neexistuje žádný vztah; 1 označuje silnou pozitivní korelaci ( $Y$  roste s  $X$ ).


Analýza korelace je důležitou součástí exploračních analýzy, neboť identifikace silných vztahů mezi dvojicemi ukazatelů je nezbytná pro další kroky v případové studii. Silně korelující ukazatelé mohou negativně ovlivňovat kvalitu výsledků regresních modelů (Macků, 2020). Mezi jednotlivými ukazateli byla zjištěna statisticky významná korelace. Nejvyšší hodnota korelačního koeficientu nad 0,7 byla zaznamenána mezi mírou plodnosti a porodnosti. Stejně silná, avšak negativní korelace byla nalezena mezi podílem obyv. SŠ vč. vyučení a podílem obyv. VŠ vzdělání. Smith et al. (2018) doporučují eliminovat proměnné s korelačním koeficientem vyšším než 0,8 vzhledem k multikolinearitě, což je jev, kdy jsou nezávislé proměnné vysoko korelovány. Z toho důvody byly ukazatelé plodnosti a porodnosti se zjištěnou statisticky významnou korelací z datové sady eliminovány. Oproti tomu byl proveden kompromis a ukazatelé podílu obyv. SŠ vč. vyučení a podílem obyv. VŠ vzdělání byly ponechány za účelem porozumění vztahu vůči indexu kriminality.

#### 4.2.4 Statistika dat závislé proměnné

Závislou proměnnou, která má být vysvětlena nezávislými proměnnými, představuje čistý index kriminality. V rámci základní průzkumové analýzy před vstupem do regresních modelů byla zkoumána distribuce hodnot indexu kriminality. Grafy 5 a 6 ukazují, že hodnoty indexu kriminality nevykazují normální rozdělení. Quantile plot (Q-Q plot) umožňuje graficky posoudit, zda data pocházejí z nějakého známého rozložení. Histogram umožňuje porovnat tvar hustoty četnosti s tvarem hustoty pravděpodobnosti vybraného teoretického rozložení. Vzhled diagnostického histogramu identifikuje pro data indexu kriminality rozložení četností s kladnou šikmostí (z důvodů obcí s nulovou hodnotou indexu kriminality). Mezi termíny, popisující nezáporné spojité proměnné, které jsou pravostranně zkosené a vykazují shlukování u nuly, se často používají výrazy jako “zero-inflated” či “floor effect” (Boulton et Williford, 2018). Oba grafy tedy nasvědčují tomu, že data nepocházejí z normálního rozdělení. Data byla dále podrobena analýze odlehlých hodnot, tzv. „outliers“ neboli území, která vybočují z trendu v jejich okolí. Analýza odlehlých hodnot odhalila velkou variabilitu v indexu kriminality (10 obcí), která způsobuje výrazné rozdíly ve srovnání s ostatními obcemi. Nicméně po pečlivém zvážení nedošlo k odstranění žádných obcí, které by mohly působit jako odlehlé hodnoty dle statistického průzkumu, jelikož autor práce předpokládá, že se ve skutečnosti o odlehlé hodnoty v tomto případě nejedná, tzn. mohou přibližně odrážet skutečný stav kriminality v obcích.




Graf 5 Q-Q plot indexu kriminality. Zdroj: vlastní.




Graf 6 Histogram indexu kriminality. Zdroj: vlastní.

Normální rozdělení je základním požadavkem pro mnoho statistických metod a přispívá ke kvalitě výsledků. Nicméně, u reálných dat je často porušen. Porušení normality u indexu kriminality bylo graficky prokázáno. Jedno z možných řešení odchylky od normálního rozdělení je transformace dat. Transformace dat byla realizována logaritmicí dat (přirozeným logaritmem) indexu kriminality v rozhraní ArcGIS Pro na základě empirických znalostí. V rámci testování různých typů transformací (odmocninová, Box-Cox, inverzní Box-Cox, arcsine aj.) se jevila logaritmicí jako optimální volba. Avšak před samotnou transformací dat bylo nutno vyloučit obce, které se potýkají s absencí trestných činů pro rok 2021 (tzn. hodnota indexu kriminality odpovídá nule). Logaritmicí zajistila u indexu kriminality pozitivní změnu normality (grafy 7 a 8). Histogram je víceméně symetrický. Z výsledků experimentu tedy vyplývá, že transformace vstupních dat přinesla významné zlepšení a v budoucích regresních analýzách lze počítat se splněním předpokladu normality. Podle Horáka a Orlikové (2020) je důležité dbát na správnou interpretaci výsledků vysvětlujících regresních modelů po transformaci dat. Autoři upozorňují, že interpretace původních veličin, zejména s využitím standardizovaných regresních koeficientů, je mnohem jednodušší než u transformovaných dat. Proto je třeba na interpretaci výsledků transformovaných dat nahlížet s opatrností a kritickým pohledem.





Graf 7 Q–Q plot logaritmizovaných hodnot indexu kriminality. Zdroj: vlastní.



Graf 8 Histogram logaritmizovaných hodnot indexu kriminality. Zdroj: vlastní.

### 4.3 Regresní modelování

Cílem regresního modelování je popsat vztah vysvětlované závislé proměnné k jedné nebo více nezávislých proměnných (prediktorů). Lze takto vyhodnotit a vypočítat vliv prediktorů na sledovanou proměnnou. Podle Horáka a Orlikové (2020) je během příprav před regresním modelováním je nezbytné pečlivě zvážit, co bude závislou proměnnou  $Y$  a jaké budou nezávislé proměnné  $X_1$  až  $X_n$  (vysvětlující proměnné). Klíčovým rozhodnutím je také volba typu regresního modelu, které lze rozlišit na:

- 1) *Exploratorní (vysvětlující) modely*, kde jsou proměnné pevně dané a zajímá nás jejich vzájemný vztah a vliv na závislou proměnnou  $Y$ .
- 2) *Prediktivní (předpovědní) modely*, kde je cílem co nejlépe odhadnout hodnotu závislé proměnné  $Y$  na základě sady proměnných  $X_1$  až  $X_n$ .

Práce je zaměřená na hledání vztahů mezi kriminalitou (vyjádřenou čistým indexem kriminality) a vybranými socioekonomickými ukazateli (prediktory), a proto byly dále vybrány *exploratorní modely* prostorového i neprostorového typu.

Podle Horáka a Orlikové (2020) se na začátku prostorového regresního modelování obvykle provádí standardní mnohonásobně lineární regresní modelování, které je optimalizováno metodou nejmenších čtverců, zkráceně označovanou jako OLS (Ordinary Least Squares). OLS umožňuje získat přehled o celkovém (globálním, neprostorovém) chování proměnných v regresní rovnici a na základě kterého lze porovnávat výsledky prostorového regresního modelování. Předpokládá se, že prostorový regresní model (Geograficky vážená regrese – GWR) bude výrazně přesnější oproti OLS, jinak nelze prokázat přidanou hodnotu prostorového regresního modelu.

### **Volba scénářů**

Závislou proměnnou je index kriminality, který má být vysvětlen nezávislými proměnnými (prediktory) za použití regresních modelů. Vzhledem k časové aktuálnosti a dostupnosti dat prediktorů bylo regresní modelování provedeno pro rok 2021. Z důvodu absence trestných činů (index kriminality roven nule) v 1 010 obcích byly vytvořeny dva scénáře (modely), jak doporučují autoři Boulton et Williford (2018).

V prvním modelu, označeným jako MODEL 1 (M1), jsou zahrnuty veškeré obce (6 254), tedy i obce s nulovou hodnotou indexu kriminality. V případě prvního modelu je pracováno s předpokladem, že všechny existující hodnoty jsou s jistou mírou spolehlivosti správné, tzn. existující odlehle hodnoty nevznikly chybou měření nebo záznamu, ale popisují skutečný stav v obcích. Není proto vhodné provádět odstranění obcí z datové sady, protože by to mělo několik negativních dopadů. Zaprvé by se značně zredukoval rozměr datového souboru, což by mohlo ovlivnit statistickou výpovědnost a spolehlivost analýz provedených na zbývajících datech. Zadruhé by mohlo dojít ke ztrátě důležité informace popisující reálnou situaci v daném regionu, která přispívá k celkovému obrazu o vybraných indikátorech ve sledované oblasti. Tato informace je klíčová pro správnou interpretaci a hodnocení výsledků analýz.

Ve druhém modelu MODEL 2 (M2) byl zvolen protichůdný přístup, a sice obce s nulovým indexem kriminality byly eliminovány. Výsledný počet obcí s nenulovou hodnotou kriminality odpovídá 5 244. Horák a Orliková (2020) konstatují, že neexistuje jednoznačné doporučení, zda (a jaké) odlehle hodnoty odstranit z modelu či nikoliv. Obecně platí, že odstranění odlehle hodnot je více vhodné u prediktivních modelů než u exploratorních. Samozřejmě, při velkých objemech dat je vyloučení několika hodnot méně citlivé než u malého souboru dat. Po odstranění nulových záznamů bylo pro MODEL 2 tak možno realizovat transformaci dat indexu kriminality užitím logaritmické funkce, jelikož data byla očištěna o nulové hodnoty. Transformovaná data tak vykazují normální rozdělení, což je základním požadavkem pro metody regresního modelování a přispívá k lepší kvalitě výsledků. Na MODEL 2 je v této práci nahlíženo jako na testovací scénář za účelem porovnání kvality výsledky s MODELEM 1. Interpretace výsledných hodnot regresních koeficientů MODELU 2 by mohla být předmětem podrobnějšího vyšetřování. Tento detailní průzkum výsledků však již nebyl v práci řešen.

#### **4.3.1 OLS**

Pro určení vztahu mezi indexem kriminality a socioekonomickými ukazateli byl nejdříve použit lineární model OLS (Ordinary Least Squares) regrese pro oba scénáře. Tento proces byl proveden v programech ArcGIS Pro a GeoDa na sestavené datové sadě. Použití ukazatelé jsou obsaženy v tabulce 6. Pro výpočty byla použita polygonová vrstva obcí obsahující hodnoty závislé proměnné a hodnoty 25 prediktorů. Pro výpočet byl použit nástroj *Spatial Statistics Tools/Modeling Spatial Relationships/Ordinary Least Squares*.

Tab. 6 Seznam prediktorů vstupujících do OLS. Zdroj: vlastní.

<b>Demografické</b>	<b>Ekonomické</b>
Hustota zalidnění	Podíl obyv. v exekuci
Index stáří	Podíl obyv. v insolvenční
Přirozený přírůstek	Podíl příjemců příspěvků na bydlení (PnB)
Hrubá míra migrační saldo	Podíl uchazečů o zaměstnání
Podíl obyv. s náb. vyznáním	
Podíl obyv. bez náb. vyznání	
Podíl Romů	
Podíl předčasných odchodů ze ZŠ	
Podíl obyv. bez vzdělání	
Podíl obyv. – ZŠ	
Podíl obyv. – SŠ vč. vyučení	
Podíl obyv. – úplné střední, vč. nástavbového studia	
Podíl obyv. - vyšší odbor. vzdělání	
Podíl obyv. - VŠ	
Podíl rozvedených	
Podíl svobodných	
Podíl sezdaných	
Volební účast	
Demografické	
Hustota zalidnění	
Index stáří	
Přirozený přírůstek	
Hrubá míra migrační saldo	
Podíl obyv. s náb. vyznáním	
Podíl obyv. bez náb. vyznání	

Výsledné reporty z programu ArcGIS Pro jsou pro MODEL 1 obsaženy v příloze 59 a pro MODEL 2 v příloze 60. Reporty software GeoDa jsou pro MODEL 1 obsaženy v příloze 68 a pro MODEL 2 v příloze 69. Tyto reporty poskytují podrobné výsledky a analýzy pro každý model v každém softwaru. Hlavní výhodou reportů OLS z programu ArcGIS Pro oproti OLS reportům z programu GeoDa je jejich schopnost poskytnout podrobnější statistické informace o vztahu mezi proměnnými, včetně míry významnosti vztahu a koeficientu determinace. Navíc reporty OLS z programu ArcGIS Pro umožňují vizualizaci výsledků v podobě grafů, což usnadňuje interpretaci vztahů mezi proměnnými a umožňuje rychlejší odhalení vzorců a trendů.

Poznatky z výsledných reportů shrnuje příloha 79. Hodnoty koeficientu determinace  $R^2$  regresních modelů je relativně velmi nízká. Pro MODEL 1 se pohybují kolem hodnoty 0,17, což naznačuje, že změny hodnot chyb nelze vysvětlit pomocí hodnot zkoumaných parametrů z více než 17 %. V případě použití MODELU 2 je možno vysvětlit téměř 15 % rozptylu závislé proměnné. Stále tedy zůstává nezodpovězena přibližně šestina proměnlivosti indexu kriminality. Horák et Orliková (2020) uvádí, že čím je menší datový soubor a čím více nezávisle proměnných, tím snadněji lze získat vysoké  $R^2$ . Proto záleží na kontextu výzkumu, velikosti datového souboru a počtu nezávisle proměnných. V souvislosti s těmito okolnostmi se lze v této práci spokojit s modelem, který vysvětluje 17 % rozptylu závislé proměnné.

Oba MODEL 1 a MODEL 2 vykazují vysokou multikolinearitu. Ta byla ověřována pomocí výpočtu faktoru VIF (Variance Inflation Factor). Pokud byla některá z vysvětlujících proměnných ohodnocena  $VIF > 7,5$ , byla z modelu eliminována. Limitní hodnota je dle doporučení

ArcGIS Resource Center. Proces výpočtu každého regresního modelu se tedy několikrát opakoval dle principu *postupné zpětné regrese* (angl. backward stepwise regression). V rámci hledání optimálních sestav prediktorů byl v rozhraní ArcGIS Pro dále použit nástroj *Exploratory Regression*. Výsledné návrhy tohoto nástroje jsou k dispozici v tabulkovém formátu v příloze 65. Jedná se o nástroj pro vyhledávání dat, který vyzkouší všechny možné kombinace prediktorů za účelem zjištění, které modely projdou všemi potřebnými diagnostickými testy OLS na základě uživatelem zvolených parametrů (obrázek 9). Vyhodnocením všech možných kombinací prediktorů lze výrazně zvýšit šance na nalezení nejlepšího modelu dle zadaných parametrů. Nástroj *Exploratory regression* je sice podobný *stepwise regresi*, avšak namísto toho, aby hledal pouze modely s vysokými hodnotami  $R^2$ , hledá modely splňující veškeré požadavky a předpoklady metody OLS.

Search Criteria	Value
Maximum Number of Explanatory Variables	5
Minimum Number of Explanatory Variables	1
Minimum Acceptable Adj R Squared	0,5
Maximum Coefficient p value Cutoff	0,05
Maximum VIF Value Cutoff	7,5
Minimum Acceptable Jarque Bera p value	0,1
Minimum Acceptable Spatial Autocorrelation p value	0,1

Obr. 9 Volba parametrů v *Exploratory regression* (ArcGIS Pro). Zdroj: vlastní.

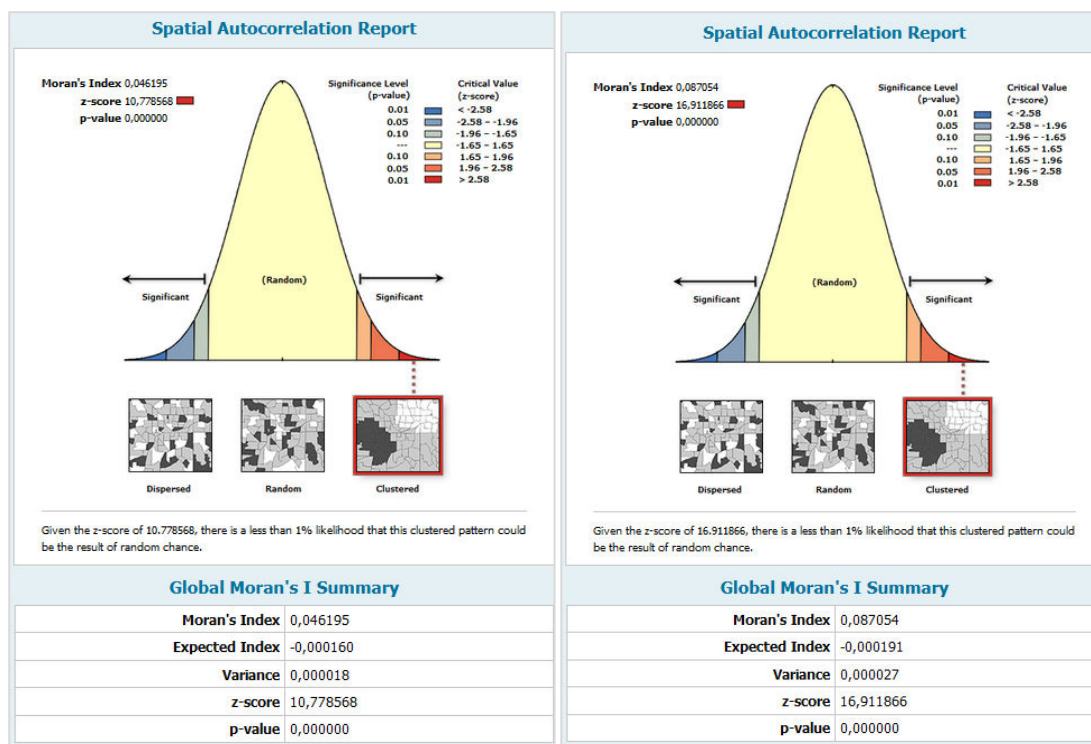
Z důvodu multikolinearity byly z výpočtu odstraněny parametry, které se rovněž potýkaly s absencí statistické významnosti ( $p$  value  $< 0,05$ ) – podíl předčasných odchodů ze ZŠ; podíl obyv. – ZŠ; podíl obyv. – SŠ vč. vyučení; podíl obyv. – úplně střední, vč. nastavbového studia; podíl obyv. – VŠ; hustota zalidnění; potratovost; porodnost; přirození přírůstek; migrační saldo; podíl Romů; podíl příjemců příspěvků na bydlení; podíl uchazečů o zaměstnání.

Po eliminaci prediktorů, na základě vysokého faktoru hodnot VIF, byly získán výsledný výběr prediktorů (výjimkou představují prediktory, týkajícího se podílu obyvatel náboženského vyznání za účelem zjištění vztahu k míře kriminality). O'Brien (2007) konstatuje, že VIF nelze interpretovat izolovaně a je třeba jej chápat v celém kontextu. Nicméně ani přes odstranění parametrů nedošlo k dalšímu výraznému snížení hodnoty koeficientu determinace  $R^2$  oproti hodnotám před odstraněním (snížení číselných hodnot bylo řádově v desetitisícinách). Během přidávání, resp. odebrání prediktorů během modelování byla rovněž pozornost soustředěna na dosažení co nejlepších kritéria hodnocení modelu pomocí Akaikeho informační kritérium (Akaike Information Criterion – AICc), které je založeno na odpovídající funkci pravděpodobnosti standardního regresního modelu a na předpokladu vícerozměrné normality (Akaike, 1974). Hodnoty AIC v praxi slouží k relativnímu porovnání více modelů mezi sebou – čím nižší hodnoty, tím model lépe vyhovuje datům. Čím nižší hodnoty AIC dosahuje, tím je model kvalitnější. Ve všech případech MODEL 2 vykazuje výrazně nižší hodnoty oproti MODELU 1. Během testování optimálního nastavení prediktorů byly sledovány rovněž Breusch-Paganův test pro o testování homoskedasticity, resp. heteroskedasticity; testy normality reziduí (Kolmogorov-Smirnov, Shapiro-Wilk, Jarque-Bera), které mají potvrdit normalitu reziduí modelu; stacionarita (Koenker Statistic); Schwartz kritérium; Likelihood ratio test, zhodnocení prostorové autokorelace reziduálních odchylek (pomocí shlukování) a další

parametry. Z výsledků těchto testů bylo zjištěno, že všechny vytvořené modely lze považovat za statisticky signifikantní, avšak nestacionární a zkreslené (ve všech případech byla p-value < 0,05). Z důvodu nestacionarity modelu je tedy vhodnější použít prostorový typ regrese – geograficky váženou regresi (GWR), která zohledňuje nestacionární změny hodnot proměnných v prostoru. Srovnání výsledků vybraných parametrů a regresních koeficientů jsou obsaženy společně s výsledky modelů SEM a SLM v příloze 78.

Poté byla provedena prostorová analýza reziduí pomocí vizualizace modelu založeného na metodách nejmenších čtverců (OLS). Příloha 81 ukazuje přítomnost prostorové závislosti, kde jsou predikované hodnoty v některých částech zájmového území nadhodnoceny, zatímco v jiných částech jsou naopak podhodnoceny. Z výsledků reziduí vyplývá, že chyby jsou významně ovlivněny distribucí a hustotou vstupních dat. S rostoucí vzdáleností mezi vstupními body roste také vliv dat.

V závěru diagnostiky byla provedena analýza prostorové autokorelace diskutovaných regresních modelů (pro oba scénáře), a to na globální úrovni prostřednictvím Moranova I kritéria, za účelem potvrzení odstranění prostorové závislosti reziduí – obr. 10. Tento model je implementován v programu ArcGIS Pro *Spatial Statistics / Spatial Autocorrelation/ Global Moran's I*. V této práci je využito Moranovo I kritérium, které je analogií Pearsonova korelačního koeficientu a slouží k vyhodnocení podobnosti vybraných proměnných v oblastech, které jsou prostorově příbuzné (Moran, 1950). Hodnota Moranova indexu popisuje převládající vzor prostorové autokorelace v území. Proměnná vykazuje pozitivní, resp. negativní prostorovou autokorelaci. Globální Moranovo I prokázalo statisticky významnou autokorelaci. Na rozdíl od MODELU 2, který vykazuje vyšší hodnoty, naznačující tendenci ke shlukování, MODEL 1 má hodnoty reziduí bližší nule a oproti MODELU 2 naznačuje poloviční tendenci ke shlukování.



Obr. 10 Report Moranova I kritéria reziduí z OLS pro MODEL 1 (vlevo) a MODEL 2 (vpravo). Zdroj: vlastní.

## Hodnocení kriminality užitím OLS

Při hledání vztahu mezi indexem kriminality a jejími prediktory je vhodné nejen kvantifikovat výsledky, ale také provádět následnou interpretaci. Interpretace výsledků regresních koeficientů metody OLS pro MODEL 1 je zaměřena na anomálie nebo na dříve zmíněné předpoklady. MODEL 2 obsahuje mnoho regresních koeficientů, jejichž hodnoty kolísají mezi zápornými a blízkými čísly blízko nule.

Variabilita indexu kriminality je nejlépe vysvětlena hustotou zalidnění. Regresní koeficient vykazující pozitivní hodnotu značí, že s vyšší hustotou zalidnění v dané oblasti roste i celkový index kriminality. Tímto byl potvrzen předpoklad o vlivu tohoto faktoru na celkovou kriminalitu. Výsledek naznačuje, že vyšší kriminalita je typická pro městské oblasti, kde je vyšší koncentrace lidí, zatímco ve venkovských oblastech je nižší. Regresní koeficienty vykazující hodnoty blízké nule, nebyly detailně interpretovány.

Významný vliv na variabilitu závislé proměnné má také podíl obyvatel s vyšším odborným vzděláním (VOŠ). Beta koeficient má zápornou hodnotu, tzn. že oblasti s vyšším podílem těchto studentů mají nižší index kriminality. Obdobně se tak děje i u ostatních kategorií vzdělání. Tyto výsledky potvrdili předpoklad, že vyšší podíl vzdělaných obyvatel bude mít nižší kriminalitu. Oproti tomu předpoklad, týkající se vyšší kriminality v souvislosti s vyšším podílem obyv. bez vzdělání nebyl splněn (očekávala se kladná hodnota regresního koeficientu).

Míry porodnosti, potratovosti a přirozeného přírůstku mají na index kriminality nízký vliv, což je potvrzeno kladnou hodnotou koeficientu. To naznačuje, že s rostoucími mírami porodnosti, potratovosti a přirozeného přírůstku roste i index kriminality, což je v souladu s předpokladem.

Variabilitu indexu kriminality podmiňují rovněž podíly romské populace, obyvatel v exekuci a příjemců PnB. Kladné hodnoty koeficientů vyjadřují nepřímou úměru mezi nezávisle proměnnou a prediktory. S rostoucími podíly romské populace, obyvatel v exekuci a příjemců PnB roste i index kriminality, čímž byl splněn předpoklad.

Dle modelu se s rostoucím počtem obyvatel v insolvenční situaci klesá index kriminality. Jedním z vysvětlení může být, že lidé v insolvenční situaci mohou být více zapojeni do procesu řešení svých finančních problémů, jako je splácení dluhů nebo hledání nového zaměstnání. Tím se mohou stát více sociálně integrovanými a méně náchylnými k zapojení se do kriminálních aktivit.

Výsledné koeficienty rodinného stavu jsou různé. Je překvapivé, že model odhalil situaci, že s rostoucím počtem svobodných, sezdaných a rozvedených roste i míra kriminality. Důvodů může být několik, obecně však platí, že stabilní a podpůrné rodinné prostředí může snížit riziko, že jedinec se zapojí do kriminálního chování. Rodiny, které poskytují lásku, péči, pozitivní hodnoty, disciplínu a vzdělání, mohou vytvářet prostředí, které podporuje zdravý vývoj a prevenci kriminality. Dobrý rodinný stav může také zahrnovat stabilní finanční podmínky a dostupnost základních potřeb, které mohou snížit potřebu nelegálních aktivit jako způsobu zajištění těchto potřeb. Na druhou stranu, jsou například rodiny s nízkým sociálním postavením, rodiny s absencí rodičů nebo rodiny s vysokou mírou konfliktu, může zvýšit riziko, že jedinec se stane obětí nebo pachatelem kriminality (Tyleček, 2006).

Koeficienty podílu osob s náboženským vyznáním vyjadřují, že s rostoucím podílem obyvatel náboženského vyznání roste také index kriminality. Předpoklad byl tímto splněn. Oproti tomu hodnoty koeficientů prediktoru podílu obyvatel bez náboženského vyznání nebyly uspokojivé dle předpokladu. Praktikovaná náboženská víra může mít pozitivní vliv na prevenci kriminality. Náboženství může poskytovat morální a etický rámec, který může

vést k dodržování zásad správného chování a omezení nelegálního jednání. Náboženské komunity mohou také poskytovat sociální podporu, která může snižovat riziko sociálního vyloučení a kriminálního chování. Více se tomuto tématu věnuje např. Uhrovičová (2016). Kladné hodnoty koeficientu volební účasti do Poslanecké sněmovny prokazují pozitivní vztah k indexu kriminality, avšak s nízkým vlivem. Důvod může být spojen s vyšší mírou zapojení občanů do politického procesu a vytvářením silnějšího občanského vědomí a angažovanosti. Může také znamenat větší důvěru občanů ve vládní instituce a procesy, což může vést k nižší míře pocitu beznaděje nebo frustrace, které jsou někdy spojeny s kriminálním chováním. Volební účast může také přispět k vyšší míře sociální soudržnosti a společenského začlenění, což může snižovat riziko kriminálního chování (Vojáčková, 2018).

Je však nezbytné konstatovat, že míra kriminality je multifaktoriální jev, který je ovlivněn mnoha různými faktory, a jednoznačné spojení mezi jedním prediktorem a kriminalitou není vždy jasně definovatelné. Je třeba provádět další výzkumy, které by lépe porozuměly této složité dynamice a vzájemnému vztahu mezi náboženstvím a kriminalitou.

#### **4.3.2 Spatial Lag Model (SLM) a Spatial Error Model (SEM)**

V regresním modelování je jedním z posledních předpokladů nekorelovanost reziduí s konstantním rozptylem. Při práci s agregovanými prostorovými daty však může být tento předpoklad narušen prostorovou heterogenitou a nestacionaritou (Fotheringham, 1997), což má za následek nevhodnost aplikace klasických statistických metod (Anselin, 1988). Prostorová závislost může být zahrnuta do regresních modelů různými způsoby, například jako doplňující prediktor Spatial Lag Model (SLM) nebo ve struktuře reziduí Spatial Error Model (SEM) (Anselin, 2002). Zatímco chybový model může být kompenzován pouze vložením prvku prostorové chyby do komponenty reziduí, intervalový model je komplexnější systém, kde jsou hodnoty prediktoru v obci  $n$  ovlivňovány hodnotami sousedících obcí, čímž vzniká prostorově zatížený model. Problém lze kompenzovat vysvětlujícím prediktorem, který tyto vazby popisuje (Macků, 2020).

Signifikantním parametrem prostorových regresních modelů je způsob, kterým bude zahrnut prostorový vliv, jenž se projevuje vymezením sledovaného okolí. Velikost a způsob vymezení sousedství mají významný vliv na podobu výsledků.

Následovala aplikace prostorových autoregresní model SLM a SEM v programu GeoDa pro oba scénáře, tj. MODEL 1 a MODEL 2. Datová sada prediktorů byla před použitím SLM a SEM upravena na základě předchozích zkušeností (VIF hodnota  $> 7,5$  a statistická nevýznamnost). V důsledku opakovaných předešlých analýz byly vyloučeny prediktory: hustota zalidnění, míra potratovosti, porodnosti, přirozeného přírůstku, migračního salda, podíl obyv. – SŠ vč. vyučení; podíl obyv. – úplné střední, vč. nástavbového studia; podíl obyv. – VŠ vzdělání, podíl příjemců PnB, UoZ, obyv. v insolvenční a podíl předčasných odchodů ze ZŠ.

Výsledné vygenerované reporty jsou k dispozici v přílohách 61 a 62 pro MODEL 1 a pro MODEL 2 přílohy 63 a 64. Poté byly porovnány modely SLM a SEM, avšak žádný z nich nebyl vybrán z důvodu nenaplnění předpokladů výrazného zlepšení v kontextu  $R^2$  a AIC). Výsledné modely stále bohužel vykazují heteroskedasticitu, kterou prostorový přístup nedokázal eliminovat. Výhodou je, že není zřejmá významná role prostorového autokorelačního faktoru Lambda  $\lambda$  (čím vyšší, tím lepší model). Testy normality reziduí (Kolmogorov-Smirnov, Shapiro-Wilk, Jarque-Bera) nepotvrdily normalitu reziduí modelů.

Další charakteristikou je provedení Likelihood Ratio testu (čím vyšší hodnota, tím lepší model), který porovnává významnost rozdílu mezi neprostorovou a prostorovou variantou. V obou případech nebyl zaznamenán významný vliv prostoru. Výsledný prostorové regresní modely SEM je z hlediska hodnoty AIC nepatrně kvalitnější než neprostorové varianty či SLM. Výsledky modelů jsou uvedeny v příloze 78. Z důvodu nenaplnění předpokladů nebyly výsledky SLM a SEM autorem blíže textově interpretovány.

Pro lepší představu a případnou kontrolu prostorové distribuce vybraných prediktorů byly vytvořeny mapy. Prostorová vizualizace dat dílčích použitých ukazatelů je patrná z příloh 26–48. Popularita map ukazatelů spočívá zejména v jejich schopnosti podat rychlý vizuální přehled jinak velmi komplexních geografických informací, jejichž správná interpretace může vést k objevení prostorových vzorů a souvislostí, které nejsou z tabelárních dat patrné. Primárním účelem těchto map je distribuce jevů v prostoru, což pomáhá detekovat sledované oblasti a odhalit dříve neznámé kriminogenní faktory. Ačkoliv mapy dílčích ukazatelů mohou být vizuálně přesvědčivé a intuitivní, je stále žádoucí věnovat zvýšenou pozornost při jejich interpretaci v souvislosti s mapou indexu kriminality.

### **Interpretace koeficientů logaritmická transformace**

Logaritmická transformace je užitečným nástrojem pro řešení běžného typu asymetrie hodnot, který se reálně vyskytuje. Použitím logaritmování na pozitivně zešikmené rozložení lze získat normální rozložení, které umožňuje použít standardní statistické metody pro odhad aritmetického průměru. Zpracované hodnoty lze následně publikovat přímo v logaritmickém tvaru. Je však důležité jasně uvést tuto informaci transformace v textu, aby bylo zřejmé, že se jedná o logaritmický tvar dat. Autor práce se domnívá, že je žádoucí prezentovat primární data v „čisté“ podobě, a proto po provedení potřebných výpočtů byly výstupy výpočtů transformovaných dat zpětně převedeny na původní jednotky exponenciální funkcí. Jelikož byla transformována pouze závislá proměnná (index kriminality) došlo k exponentizování koeficientu a od tohoto čísla byla odečtena jednička. V případě dalšího způsobu interpretace by bylo možné následně provést vynásobení hodnotou 100, tím lze získat procentuální nárůst (nebo pokles) odpovědi na každé zvýšení nezávislé proměnné o jednu jednotku. Příklad: Koeficient je 0,198.  $(\exp(0,198) - 1) * 100 = 21,9$ . Při každém zvýšení nezávislé proměnné o jednu jednotku se závislá proměnná zvýší přibližně o 22 %. Logaritmická transformace dat, která je součástí MODELU 2, přinesla výrazné zlepšení. Srovnání výsledných hodnot regresních koeficientů OLS, SLM a SEM po logaritmické, resp. exponenciální transformaci je patrný z přílohy 80.



### 4.3.3 Geograficky vážená regrese (GWR)

Pro hledání prostorových vztahů mezi mírou kriminality a socioekonomickými ukazateli na lokální úrovni bylo řešeno prostřednictvím lokálně proměnných parametrů modelu Geograficky vážená regrese (GWR). Celý proces GWR byl prováděn v prostředí ArcGIS Pro užitím nástroje *Spatial Statistics Tools/Modeling Spatial Relationships/Geographically Weighted Regression*. V rámci výběru prediktorů vstupujících do GWR bylo testováno velké množství kombinací prediktorů tak, aby bylo dosaženo co největší přesnosti modelu. Zvoleným nastavením bylo docíleno nejlepších hodnot AIC a  $R^2$ . Do výpočtu vstupovala polygonová vrstva obcí vrstva obsahující hodnoty atributů indexu kriminality coby závislá proměnná a dále celkem osm prediktorů (index stáří, podíl svobodných a rozvedených obyvatel, podíl obyv. bez vzdělání, s náboženským vyznáním, podíl osob v insolventi, exekuci a volební účast). Výběr prediktorů byl založen na základě vyloučení prediktorů, které v rámci OLS výsledků vykazovali hodnoty VIF > 7,5, dále dle doporučení optimální kombinace prediktorů užitím nástroje *Exploratory Regression*, a také podle autorova vlastního uvážení s ohledem na předešlé výzkumy ze zahraničí. Pro výpočet byl zvolen fixní typ spojitého (Gaussovského) prostorového jádra a šířka pásma (Distance Band) byla vybrána na základě experimentování s různými hodnotami a porovnání výsledků. Výsledná optimální hodnota Distance Band odpovídá 15 km.

GWR bylo spočítáno na vybraných prediktorech MODELU 1 i MODELU 2. V případě MODELU 2 hodnota  $R^2$  překvapivě nepřinesla lepší výsledek ve srovnání s MODELEM 1. (hodnota  $R^2$  pro MODEL 1 byla 0,37;  $R^2$  u MODELU bylo zaznamenáno o 0,06 horší). Podle hodnoty AIC je MODEL 2 výrazně lepší než MODEL 1. Tabulka 7 obsahuje výsledné zprůměrované hodnoty lokálních regresních koeficientů, koeficientu determinace  $R^2$  a AIC, které byly získány pomocí metody GWR pro oba scénáře. Hodnoty koeficientů MODELU 2 jsou v tabulce 7 z logaritmické transformace transformovány zpětně do původních hodnot užitím exponenciální transformace za účelem snadnější interpretace.

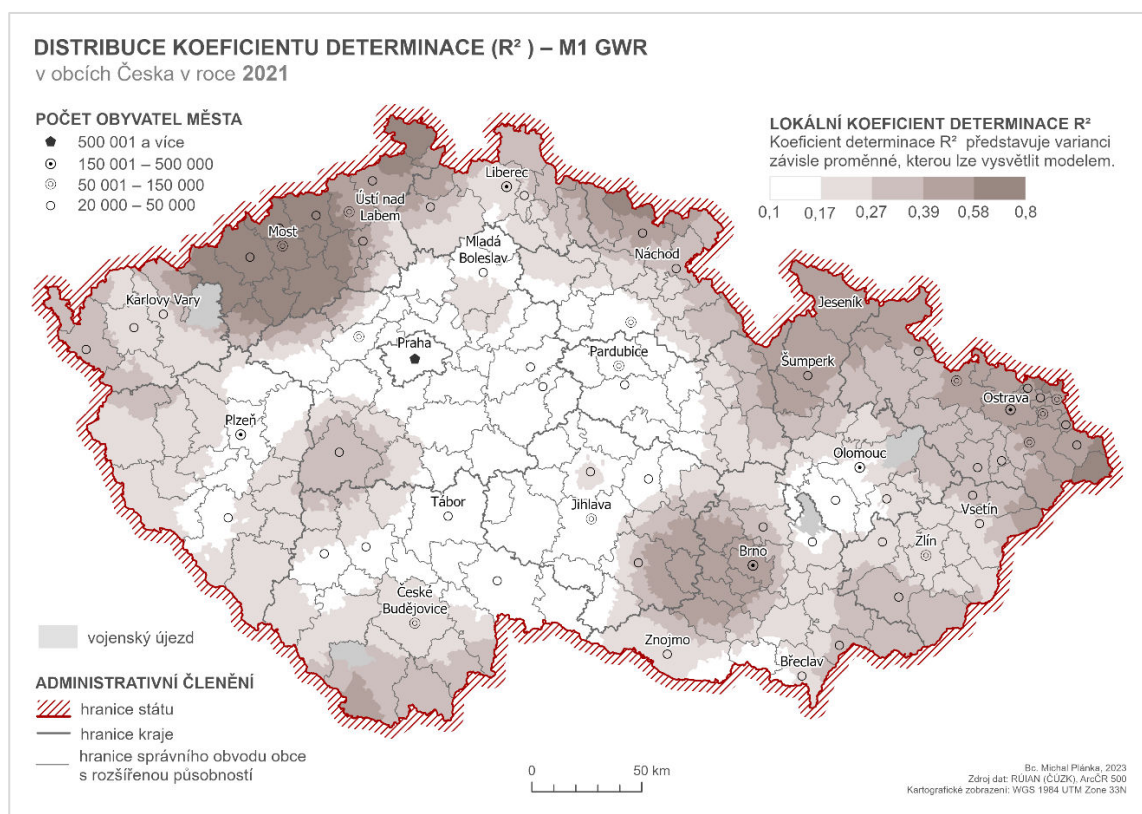
Tab. 7 Srovnání zprůměrovaných lokálních regresních koeficientů MODELU 1 a 2. Zdroj: vlastní.

KOEFIICIENT $\beta$		
	MODEL 1	MODEL 2
Index stáří	9,16	0,05
Podíl obyv. bez vzdělání	-3,02	-0,007
Podíl obyv. v exekuci	5,95	0,02
Podíl obyv. v insolventi	-3,45	-0,006
Podíl obyv. s náb. vyzn.	0,31	0,0005
Podíl svobodných	1,95	0,003
Podíl rozvedených	3,28	0,01
Volební účast	0,63	0,005
$R^2$	0,37	0,31
AIC	75 687	1 774

Srovnatelnou mírou kvality výsledných prostorových a neprostorových modelů je AIC, které dosahuje nejnižší hodnoty v případě GWR. GWR přináší výrazné zlepšení ve srovnání s běžnou lineární regresí s nezávislými pozorováními (OLS) i prostorově chybovým modelem. Je však třeba poznamenat, že výsledky koeficientů v GWR vykazují přirozeně velkou variabilitu, která by si zasluhovala důkladnějšího zkoumání. Nicméně,

v této práci bude interpretace výsledků zaměřena pouze pro MODEL 1. Výsledky MODELU 2 nebudou v této práci dále podrobněji rozebírány.

Zajímavým výstupem z GWR je provedení prostorové vizualizace regresních koeficientů (obr 14 až 21) nebo lokálního indexu determinace (obrázek 11). Tato vizualizace lokálního  $R^2$  ukazuje prostorovou variabilitu míry vysvětleného rozptylu, kde v pohraničních oblastech Česka je tato míra nejvyšší (58–80 %), naopak v některých částech území, zejména v okolí geografického středu Česka, je lokální  $R^2$  (a tedy i kvalita modelu) výrazně nižší. Velké změny  $R^2$  ukazují na podstatné rozdíly ve výkonnosti modelu. Z vizualizace je tedy patrné, že model lépe vysvětluje (vysoké)  $R^2$  zejména v blízkosti hranic, kde je méně geografických sousedů. Nejlepší výkonnost modelu (40 % a více), se předpokládá na Mostecku, Brněnsku, Moravskoslezsku a v okolí státních hranic Česka.



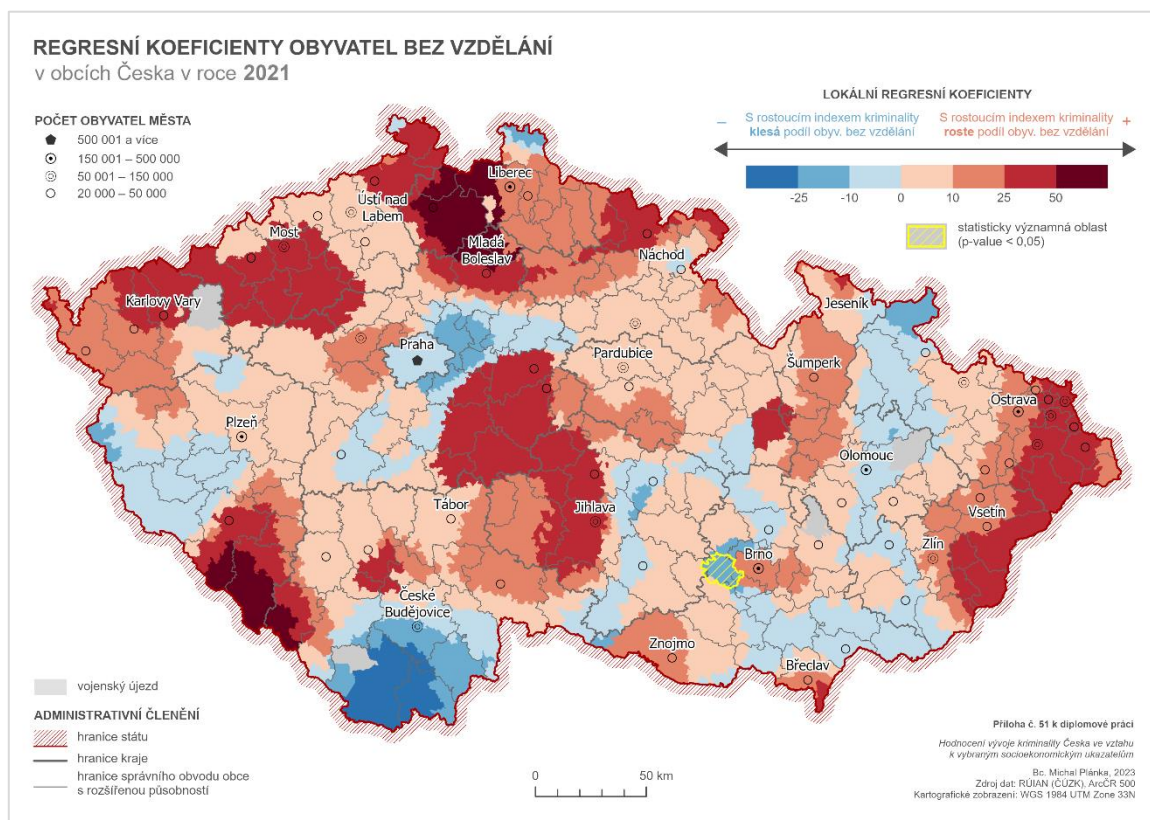
Obr. 11 Lokální index determinace vypočtený GWR pro MODEL 1. Zdroj: vlastní.

Lokální index determinace představuje kombinaci dvou problémů, a sice jak efektivně model reflektuje data a jak stabilní jsou procesy, které model popisuje. Zatímco první z těchto problémů je relativně snadno popsitelný, druhý z nelze jednoznačně charakterizovat. Z tohoto důvodu není možné interpretovat  $R^2$  (koeficient determinace) stejným způsobem jako v případě neprostorových modelů (Fotheringham, Brunson, et Charlton, 2002).

### Hodnocení kriminality užitím GWR

S ohledem na rozsah a kvalitu výzkumu je dále předmětem hodnocení kriminality pouze MODEL 1. Za účelem demonstrace výhod modelu GWR pro zkoumání geografické variability jsou uvedeny mapy lokálních koeficientů GWR (obr 14 až 21) pro jednotlivé prediktory (index stáří, podíl obyv. bez vzdělání, podíl obyv. v exekuci, podíl obyv. v insolvenční, podíl obyv. s náb. vyzn., podíl svobodných, podíl rozvedených, volební účast).

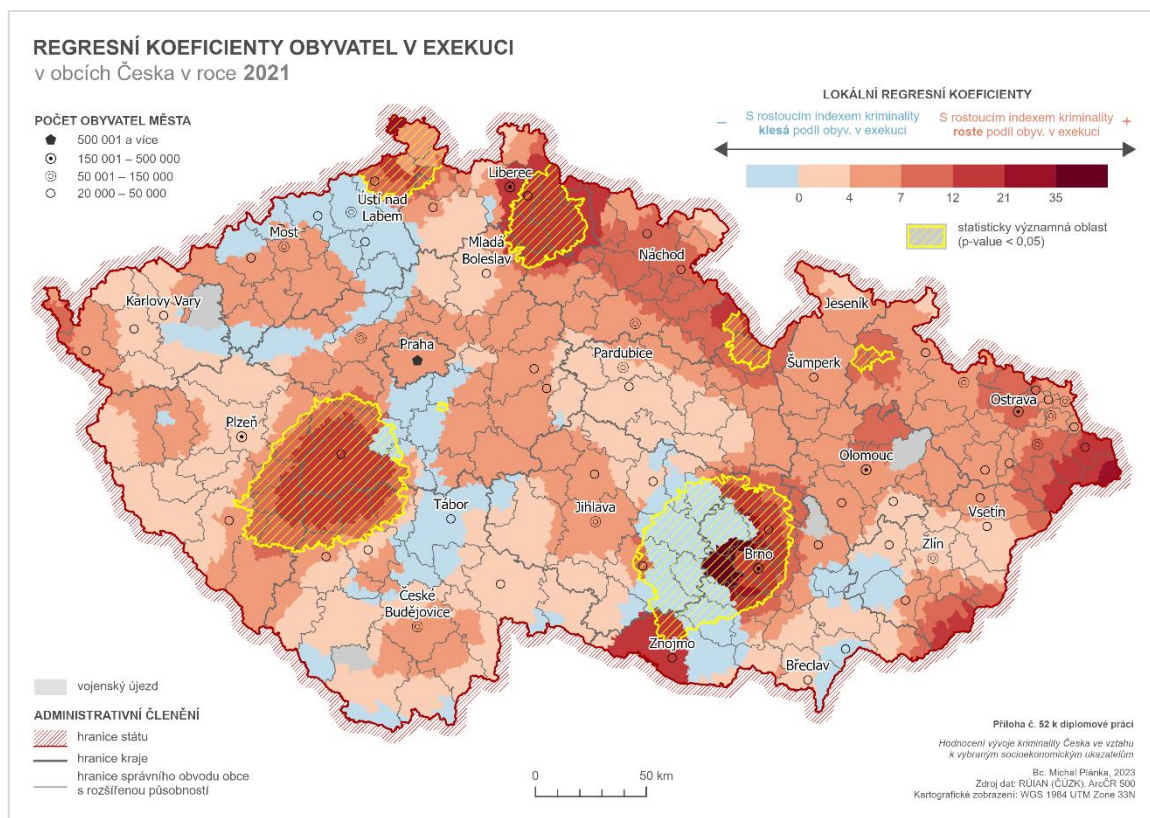
Pro zlepšení interpretace byly vypočteny signifikance (p-hodnoty) pro všechny lokální koeficienty, aby se odlišila místa, kde model poskytuje vysoce jisté výsledky. Na tyto statisticky významné oblasti je soustředěna pozornost v kontextu interpretace výsledků regresních koeficientů GWR.



Obr. 12 GWR regresní koeficienty obyvatel bez vzdělání (viz příloha 51). Zdroj: vlastní.

Výsledné regresní lokální koeficienty GWR (obrázek 12) vykazují v Česku velké regionální rozdíly s velmi vysokou pozitivní korelací i s opačným vztahem. Koeficienty indikují východně v okolí Brna záporné hodnoty poměrně vysokých hodnot koeficientů, což značí, že s rostoucím indexem kriminality v této oblasti klesá podíl obyvatel bez vzdělání.

Je důležité si uvědomit, že existuje mnoho faktorů, které mohou ovlivnit jak kriminalitu, tak i vzdělání v dané oblasti, a tyto faktory mohou být navzájem provázány různými způsoby. Autor práce se domnívá, že zlepšení vzdělání může mít pozitivní dopad na kriminalitu. Lepší vzdělání může lidem pomoci najít si lepší práci v Brně, a tím se můžou zlepšit jejich životní podmínky. Lepší vzdělání může také pomoci lidem rozvíjet své schopnosti a dovednosti, které mohou snížit pravděpodobnost, že budou zapojeni do kriminální činnosti. Nicméně, bez dalších informací je těžké zjistit, jaké faktory přesně ovlivňují vzdělání a kriminalitu v této oblasti, a jak jsou tyto faktory propojeny. Proto by bylo potřeba provést detailnější analýzu, aby bylo zjištěno, co přesně se děje v této oblasti.

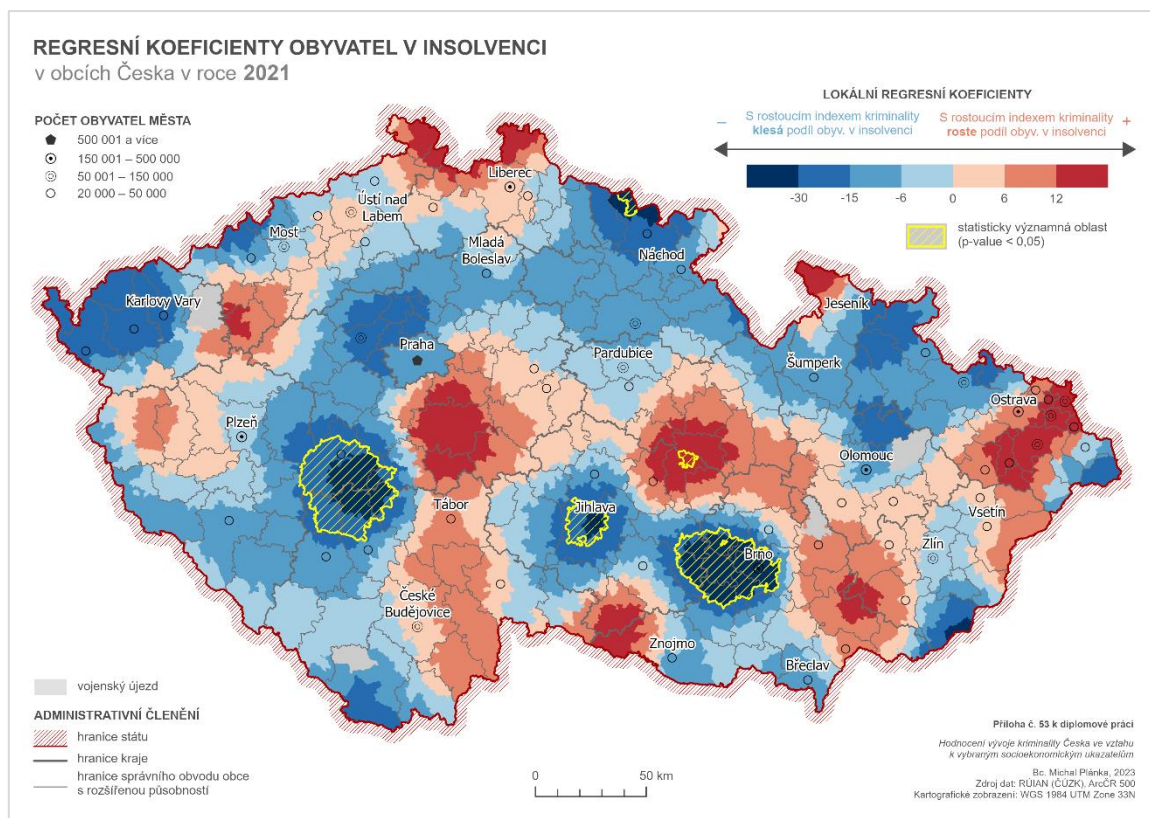


Obr. 13 GWR regresní koeficienty obyvatel v exekuci (viz příloha 52). Zdroj: vlastní.

Metoda GWR (obrázek 13) vyhodnotila pět statisticky významných oblastí ( $p\text{-value} < 0,05$ ). Frýdlantsko, Krkonoše a Podkrkonoší, okolí Příbrami, Bruntálsko a oblast severovýchodně od Ústí nad Orlicí registrují situaci, že s rostoucím indexem kriminality roste podíl obyvatel v exekuci. V okolí Brna se vyskytují rozdílné vztahy mezi indexem kriminality a podílem obyvatel v exekuci. Na západ od Brna dochází ke klesání podílu obyvatel v exekuci s rostoucím indexem kriminality, zatímco na východ od Brna lze pozorovat opačný vztah.

Existuje řada faktorů, které mohou ovlivňovat vztah mezi indexem kriminality a podílem obyvatel v exekuci v různých regionech. Podle autora práce existuje několik klíčových faktorů, které by mohly vysvětlit pozorované rozdíly mezi jednotlivými regiony.

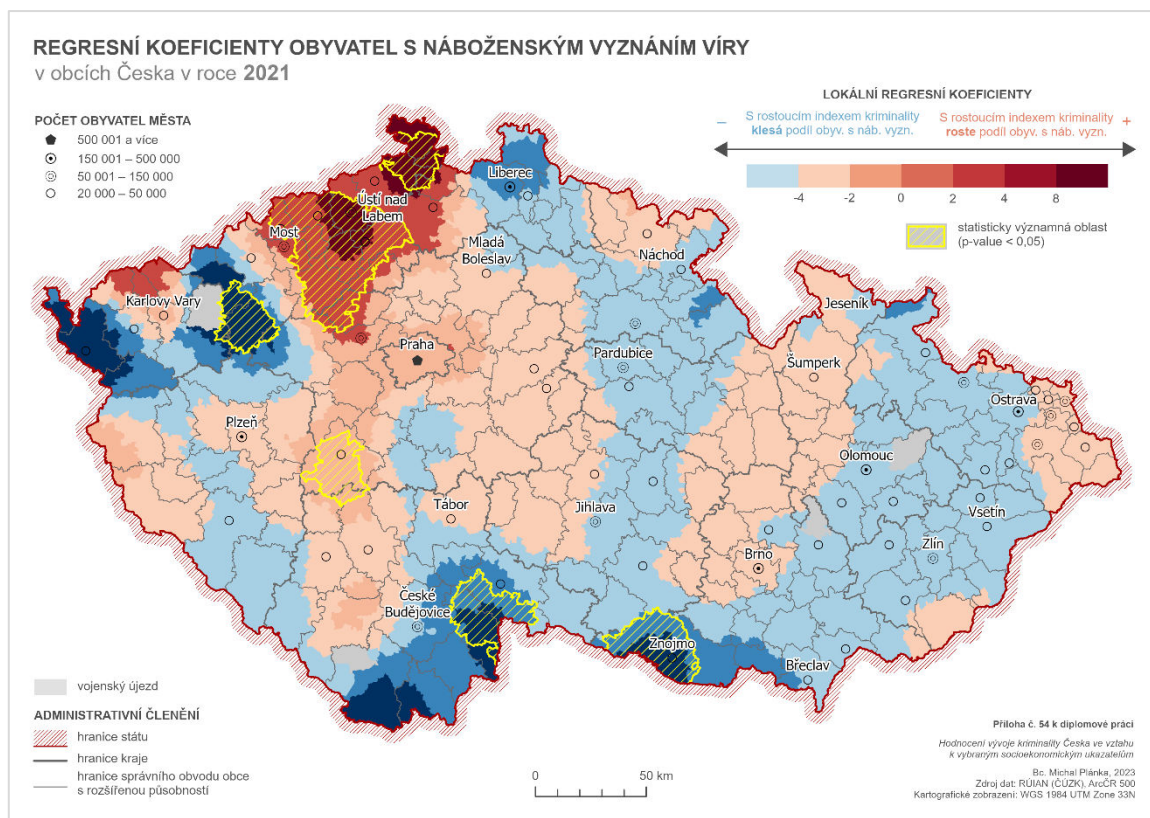
Mezi tyto faktory může patřit ekonomická situace v jednotlivých regionech. Pokud jsou některé oblasti ekonomicky slabší a mají vysokou míru nezaměstnanosti, mohou lidé častěji upadat do dluhů a exekucí. Zároveň mohou mít tendenci více se angažovat v kriminální činnosti jako způsobu, jak si přivydělat, což by mohlo vysvětlit pozorovaný vzestup kriminality. Dalším faktorem může být úroveň vzdělání a kvalifikace obyvatelstva v jednotlivých oblastech. Pokud jsou lidé v určité oblasti lépe vzdělaní a mají lepší pracovní příležitosti, mohou mít tendenci méně upadat do dluhů a exekucí. Zároveň mohou být méně náchylní k trestné činnosti, což by mohlo vysvětlit pozorovaný pokles kriminality v regionech s vyšší úrovní vzdělání.



Obr. 14 GWR regresní koeficienty obyvatel v insolvenční (viz příloha 53). Zdroj: vlastní.

GWR (obrázek 14) identifikovala oblasti, kde existuje statisticky významný vztah mezi kriminalitou a osobním bankrotem (insolvenční). Regresní koeficienty ukazují, že v různých regionech existují rozdílné vztahy mezi kriminalitou a insolvenční. Na západ od Brna, v blízkém okolí Jihlavy a v okolí Příbrami jsou překvapivě vysoké hodnoty záporných koeficientů. Zde platí relativně silný vztah, že s rostoucím indexem kriminality klesá podíl obyvatel v insolvenční. Dále byly identifikovány další oblasti poměrně malých rozloh s podobnými prostorovými vztahy. Rozbor v těchto malých oblastech však nebyl proveden.

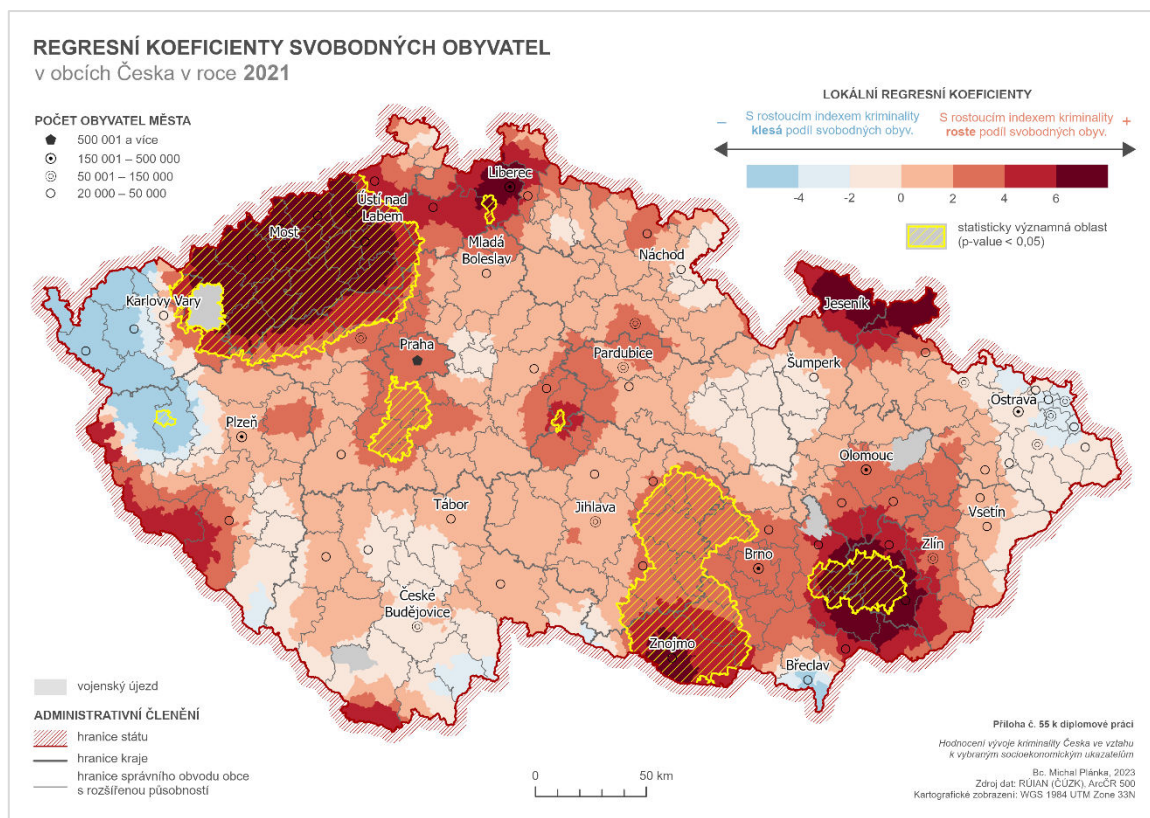
Existuje několik možných důvodů, proč by mohlo docházet ke klesajícímu podílu obyvatel v insolvenční s rostoucím indexem kriminality ve sledovaných oblastech. Jedním z možných důvodů může být to, že v oblastech s vysokou kriminalitou žije více lidí s vyššími příjmy, kteří jsou méně náchylní k insolvenční. Tento vztah by však mohl být závislý na charakteru kriminality v dané oblasti a dalších faktorech, jako je například míra nezaměstnanosti a dostupnost úvěrů.



Obr. 15 GWR regresní koeficienty obyvatel s náboženským vyznáním. (viz příloha 54). Zdroj: vlastní.

Výsledky GWR (obrázek 15) naznačují, že na území Frýdlantska, oblasti mezi Mostem a Ústím nad Labem směrem na jih a v Příbrami pozorujeme přímou úměru vztahu mezi mírou kriminality a podílem obyvatel s náboženským vyznáním. Je však třeba přistoupit k tomuto tvrzení kriticky a brát v úvahu faktory, jako jsou rozdíly v náboženském vyznání v různých regionech, sociální a ekonomická struktura populace a další proměnné, které mohou ovlivnit vztah mezi kriminalitou a náboženským vyznáním. Jedním z možných vysvětlení může být, že ve vyšších rizikových oblastech se lidé více utvrzují v náboženských přesvědčeních a cítí se větší potřebu držet se svých hodnotových zásad a tradic. Nicméně, takové vysvětlení je spekulativní a vyžaduje další výzkum. Další možností je, že v oblastech s větším podílem věřících je kriminalita vnímána jako závažnější problém a mohou být tak lépe vyvíjeny úsilí na její snižování. Opět se jedná pouze o spekulaci a vyžaduje další ověření. Proto je třeba brát tvrzení s dostatečnou rezervou, že rostoucí kriminalita má přímý vliv na náboženské vyznání obyvatel v daných oblastech.

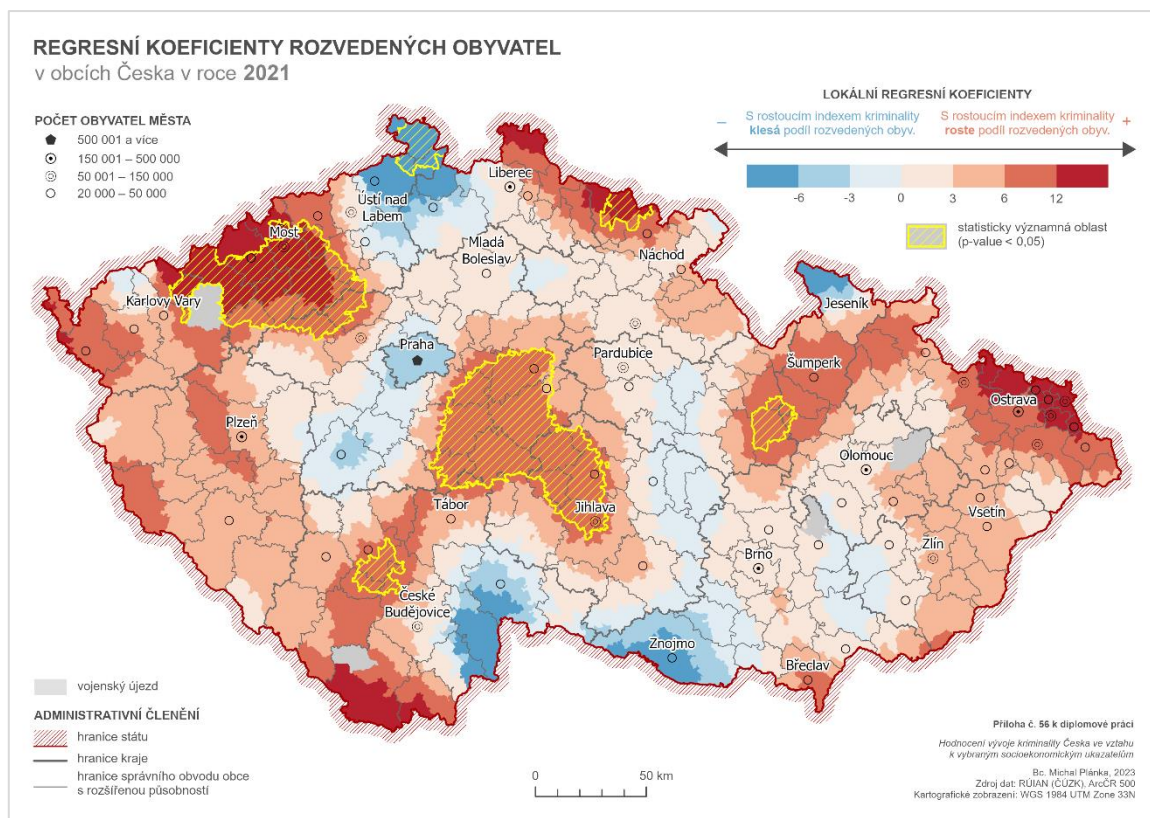
V Podbořanech, Jindřichově Hradci a na Znojemsku platí opačný vztah, a sice, že s rostoucí kriminalitou klesá podíl obyvatel s náboženským vyznáním. K vypočítanému trendu v těchto oblastech může přispívat několik faktorů. Autor práce uvažuje o tom, že v regionálních rozdílech může také hrát důležitou roli typ náboženského vyznání víry. Například v oblastech s vysokým podílem katolického vyznání může být nižší míra kriminality, protože katolické vyznání vyzdvihuje morální hodnoty a dodržování zákona.



Obr. 16 GWR regresní koeficienty svobodných obyvatel (viz příloha 55). Zdroj: vlastní.

Výsledky GWR (obrázek 16) naznačují, že téměř ve všech statisticky významných oblastech existuje pozitivní vztah mezi indexem kriminality a podílem svobodných obyvatel, tj. že s rostoucími hodnotami indexu kriminality dochází k nárůstu podílu svobodných obyvatel.

Autor práce se domnívá, že jedním z důvodů může být skutečnost, že mladí lidé bez dětí mají tendenci žít v městských oblastech s větší mírou kriminality. Tyto oblasti často nabízejí více příležitostí pro zaměstnání, zábavu a kulturní aktivity, které přitahují zejména mladé lidi. Na druhé straně se rodiny s dětmi často usazují na předměstích a v menších městech, které mají nižší míru kriminality. Je důležité zdůraznit, že uvedené vysvětlení jsou spekulativní a mohou být ovlivněny mnoha dalšími faktory.

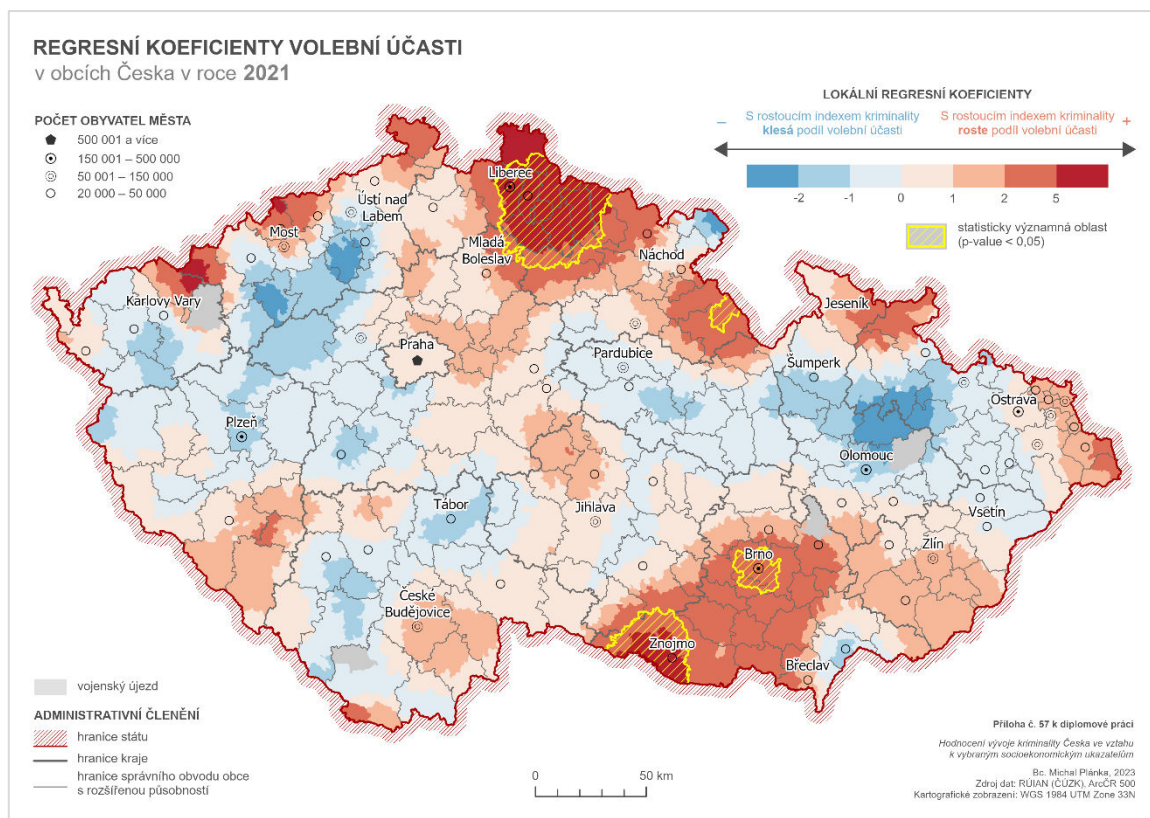


Obr. 17 GWR regresní koeficienty rozvedených obyvatel (viz příloha 56). Zdroj: vlastní.

Výsledky regresní analýzy (obrázek 17) naznačují, že na Frýdlantsku existuje negativní vztah mezi indexem kriminality a podílem rozvedených obyvatel, zatímco v ostatních statisticky významných oblastech je tento vztah pozitivní. Tento pozitivní vztah naznačuje, že s rostoucími hodnotami indexu kriminality se zvyšuje podíl rozvedených obyvatel v dané oblasti. Jedním z možných důvodů pro tento vztah může být skutečnost, že v oblastech s vyšší mírou kriminality může být větší pravděpodobnost výskytu rodinných konfliktů, což může vést k rozvodu. Navíc mohou být tato místa spojována s určitými sociálními problémy, jako jsou například chudoba, nezaměstnanost nebo zdravotní problémy, které mohou mít negativní dopad na stabilitu vztahů.

Podle autora je dalším důvodem sociální dezorganizace, která může mít za následek rozvod obyvatelstva, což může souviset s mírou kriminality. Rozvod může vést k rozpadu rodiny a sociálního soudržnosti v určitých komunitách, což může vést ke ztrátě důvěry mezi obyvateli a k menší míře spolupráce. To může vést k vyšší míře kriminality v daných oblastech. Tento faktor je zvláště důležitý v městských oblastech, kde je větší hustota obyvatel a vztahy mezi lidmi mohou být méně osobní a stabilní.



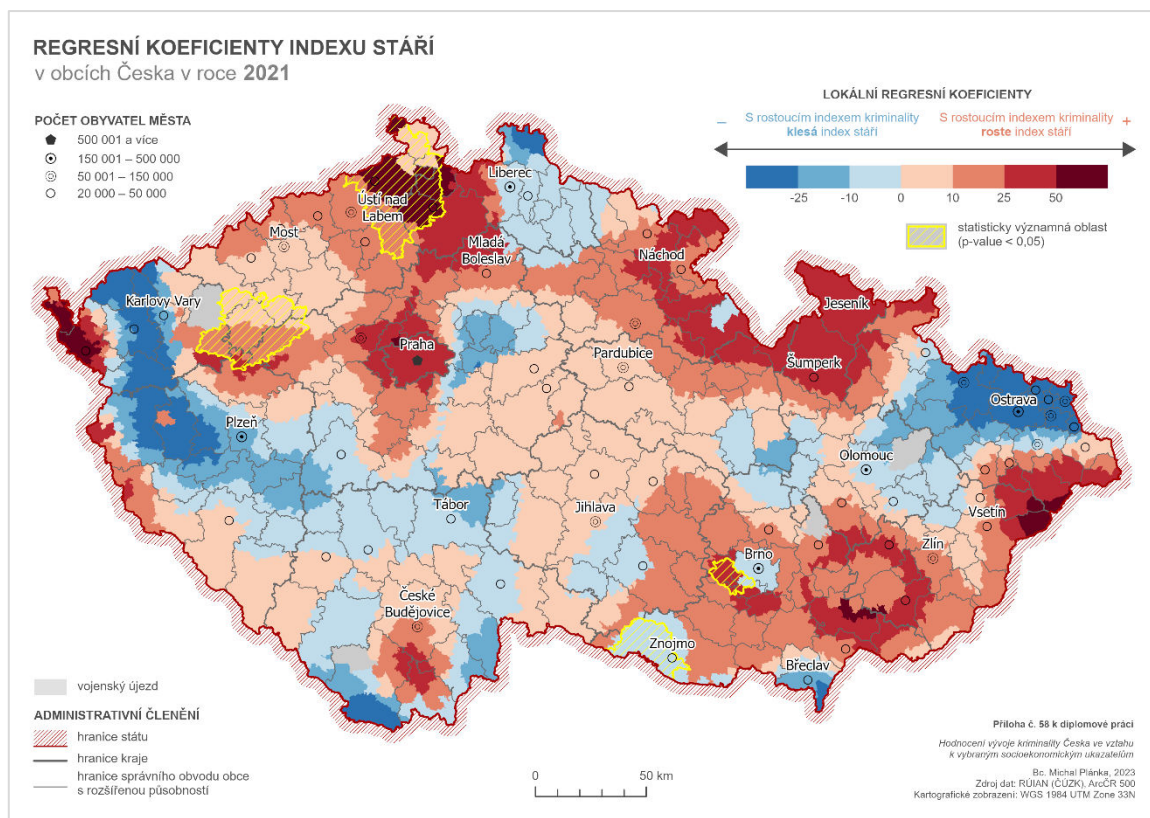


Obr. 18 GWR regresní koeficienty volební účasti (viz příloha 57). Zdroj: vlastní.

Z pohledu regresních koeficientů volební účasti (obrázek 18) se v oblastech Krkonoš, Podkrkonoší, Znojemska a Brněnska vyskytuje pozoruhodná tendence, kdy s narůstající mírou kriminality stoupá také podíl lidí účastnících se voleb do Poslanecké sněmovny. Je obtížné jednoznačně vysvětlit, proč lze v daných oblastech pozorovat souvislost mezi rostoucí mírou kriminality a zvyšujícím se podílem účastníků voleb.

Jednou z možností může být, že zvýšená kriminalita v daných oblastech vede k většímu pocitu nejistoty a obavy mezi lidmi. Tento pocit může motivovat více lidí k účasti v demokratickém procesu, jako jsou volby, a snaží se tak ovlivnit situaci v této oblasti prostřednictvím demokratických prostředků. Někteří lidé by tak mohli využít svého volebního práva, aby prosadili politické změny, které by mohly pomoci snížit kriminalitu v této oblasti.

Další možností může být, že v oblastech s vyšší mírou kriminality se může rozvíjet silnější komunitní duch a solidarita. Pokud se lidé v dané oblasti cítí ohroženi kriminalitou, mohou se snažit vybudovat silnější síť v komunitě, což by mohlo vést k většímu zapojení do veřejného života, jako jsou volby. Někteří lidé také mohou využít volby jako prostředek pro změnu politického směřování dané oblasti. Pokud se například cítí, že současná politika je příliš tvrdá vůči kriminalitě, mohou hledat kandidáty, kteří by prosazovali jiný přístup, například zaměřený na prevenci kriminality nebo zlepšení podmínek v sociálně vyloučených oblastech.



Obr. 19 GWR regresní koeficienty indexu stáří (viz příloha 58). Zdroj: vlastní.

Regresní koeficienty (obrázek 19) signifikantních míst identifikují v oblastech Podbořan, Frýdlantska směrem na jih a východně od Brna vztah, který ukazuje, že s rostoucí mírou kriminality se zvyšuje také index stáří. Naopak na Znojemsku byla tato souvislost pozorována opačně, tj. s rostoucí mírou kriminality klesá index stáří.

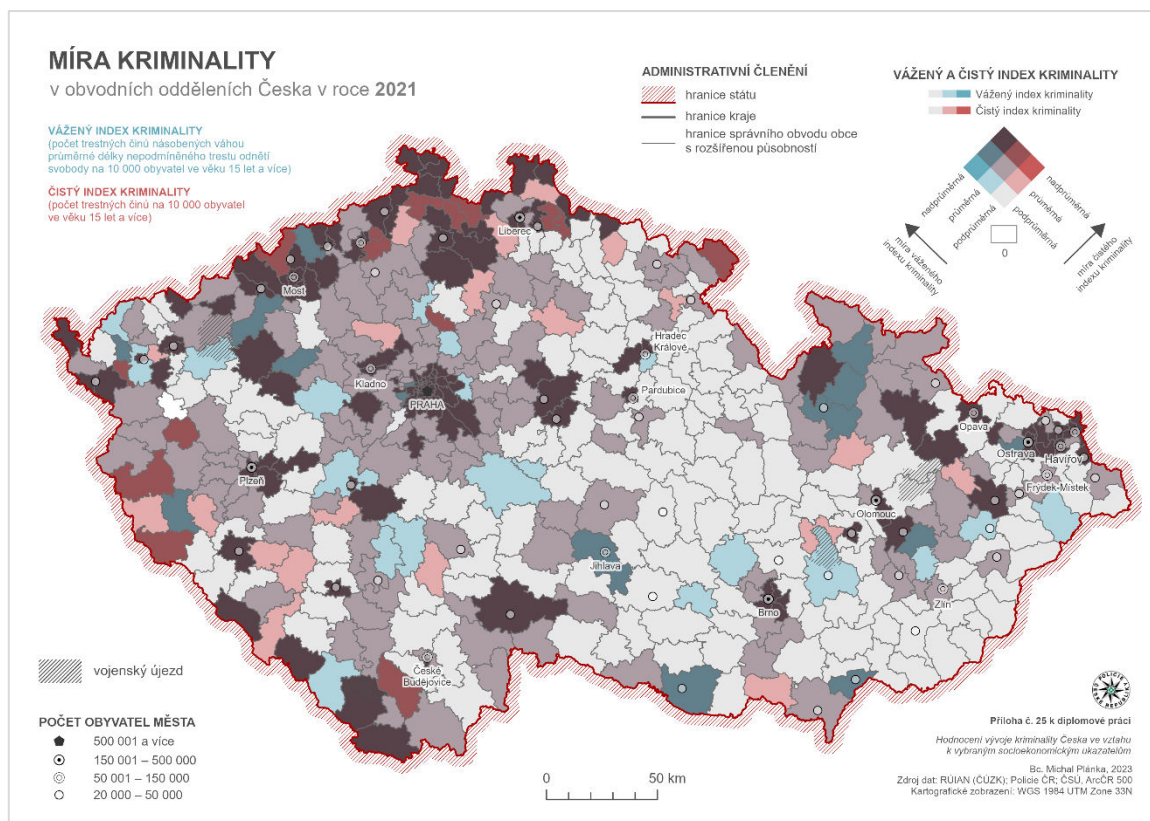
Důvody, proč může docházet k souvislosti mezi mírou kriminality a věkovou strukturou populace, mohou být různé. Jedním z možných vysvětlení může být to, že v oblastech s vyšší kriminalitou žijí převážně starší obyvatelé, kteří zde již delší dobu pobývají a mohou mít menší motivaci k odchodu do jiných regionů. Starší populace může být také více ovlivněna kriminalitou a může mít z ní větší obavy než mladší populace.

Dalším možným vysvětlením může být skutečnost, že starší obyvatelé většinou disponují s drahým majetkem a jsou také častěji obětmi majetkové trestné činnosti. To by mohlo vést k zvýšené obavě z kriminality a zvýšenému hlášení těchto trestných činů. Nicméně, uvedená vysvětlení nejsou univerzálně platná a mohou být ovlivněna různými faktory. Je tedy nutné pečlivě analyzovat data a brát v úvahu kontext a specifika jednotlivých oblastí, aby bylo možné lépe porozumět souvislosti mezi indexem stáří a mírou kriminality.

## 5 VÝSLEDKY

Prvním z významných výstupů práce je hodnocení míry kriminality prostřednictvím výpočtů (souhrnného) čistého a hrubého indexu kriminality v obcích Česka v letech 2016–2021. Jednotlivé mapy jsou součástí příloh 1–12. Vizualizací pomocí animace lze zachytit dynamiku vývoje míry kriminality ve sledovaném období (přílohy 71 a 72). Výpočet indexů byl realizován užitím geografického informačního systému (GIS) ArcGIS Pro. Autor práce se inovativně zaměřil na využití dat trestných činů z webové aplikace *Mapy kriminality*. V rámci testování této datové sady bylo zjištěno, že data v letech 2012–2015 pravděpodobně neobsahují kompletní informace evidovaných trestných činů, a proto byla z analýz vyloučena. Některé typy trestných činů nemohou být s ohledem na interní pravidla Policie ČR veřejnosti poskytnuta. Snahou bylo zachytit prostorovou koncentraci míry kriminality v maximálně nejpodrobnějším detailu. Tato práce reflektuje potřebu výzkumu kriminality v detailním prostředí, a sice na úrovni obcí, což činí tuto práci v českém kontextu výjimečnou a dosud unikátní i z hlediska použitých metod a datové sady. Na základě výsledných map vypočteného souhrnného indexu kriminality za dílčí roky sledovaného období lze konstatovat, že míra kriminality je nejvíce koncentrována v Praze, na Mostecku, Ostravsku, velkých městech s vysokým počtem obyvatel, a poté v některých místech při pohraničí (s výjimkou JV Česka). Dalšími důležitými výstupy jsou mapy indexů míry kriminality dílčích kategorií trestných činů za jednotlivé roky 2016–2021. Matice map je obsažena v příloze 24 a animace jsou k dispozici v přílohách 13–23. Souhrnné statistiky dílčích kategorií trestných činů jsou obsaženy v příloze 73. Bližší interpretace výsledků analýzy časového vývoje typů trestných činů je součástí podkapitoly 4.1.3. Změny v trestní politice, tj. zákonodárné změny v oblasti trestních zákonů a předpisů na ně navazujících nebyly brány v úvahu během analýzy kriminality.

Dílčí částí výsledků práce je autorem navržený jedinečný a inovativní postup výpočtu váženého indexu kriminality (viz podkapitola 4.1.2). Autor navrhl a následně realizoval výpočet váženého indexu kriminality pro rok 2021 v obvodních odděleních Česka. K tomu byla využita data Policie ČR všech registrovaných typů trestných činů dle takticko-statistické klasifikace (TSK). Ve výpočtu jsou zahrnuty váhy, které byly vypočítány na základě průměrné délky trestu nepodmíněného odnětí svobody (v měsících) pro každý typ trestné činnosti klasifikovaných podle trestního zákona (TZ). Dané hodnoty vah byly následně vynásobeny počtem příslušných trestných činů (klasifikovaných podle TSK, kde je současně obsažen i příslušný paragraf skutku v TZ), vyděleny počtem trestně právních obyvatel (ve věku 15 let a více) a vynásobeny hodnotou 10 000. Výsledná mapa váženého indexu kriminality je patrná z obrázku 5. Pro zajímavost byl v obvodních odděleních Česka v roce 2021 vypočten i čistý index kriminality (obr 6). Dílčím výsledkem práce je pokročilá vizualizace váženého a čistého indexu kriminality v obvodních odděleních užitím metody *Bivariate colors* (obr. 7). Z mapy je patrné, že kriminalitou jsou nejvíce zatíženy Praha, Mostecký okres, Jindřichohradecký okres, Českolipský okres, Bruntálský okres, Ostrava a další velkoměsta s počtem obyvatel přesahujícím 150 tisíc. Naopak nejnižší hodnoty indexu kriminality jsou zaznamenány na pohraničí se Slovenskem, ve východní části Vysočiny a v Pardubickém kraji až po střední oblast Karlovarského kraje. Charakteristika dosažených výsledků prostorové koncentrace míry kriminality potvrzuje skutečnost, že kriminalita není v geografickém prostoru distribuována náhodně (Brantingham et Brantingham, 1981).



Obr. 7 Kombinace váženého a čistého indexu kriminality (příloha 25). Zdroj: vlastní.

Další signifikantní část výsledků představuje nalezení vztahů mezi kriminalitou a socioekonomickými ukazateli na úrovni obcí v roce 2021, čehož bylo docíleno užitím regresního modelování ve spolupráci s GIS ArcGIS Pro a GeoDa. Bylo zjištěno, že hodnoty indexu kriminality nevykazují normální rozdělení. S ohledem na velké množství obcí (1 010) vykazující nulovou hodnotu indexu kriminality bylo regresní modelování realizováno pro dva scénáře, označené jako MODEL 1 a MODEL 2. V MODELU 1 je pracováno s předpokladem, že všechny existující hodnoty jsou s jistou mírou spolehlivosti správné, tzn. existující odlehle hodnoty nevznikly chybou měření nebo záznamu, ale popisují skutečný stav kriminality v 6 254 obcích (bez vojenských újezdů). Oproti tomu v MODELU 2 došlo k eliminaci obcí (5 244) s nulovým indexem kriminality. Logaritmizace dat zajistila v indexu kriminality pozitivní změnu normality v případě MODELU 2.

Před hlavní analytickou částí tvořenou aplikací neprostorové metody Ordinary least squares (OLS) byl proveden výběr demografických (19) a ekonomických (4) ukazatelů na základě předešlých tuzemských i zahraničních vědeckých výzkumů, dostupnosti, podrobnosti a časové aktuálnosti a podle autora vlastního uvážení po konzultaci s odborníky. Poté byla provedena základní exploratorní analýza vstupní datové sady. Cílem tohoto kroku bylo odhalit a shrnout statistické charakteristiky použité datové sady, což zahrnuje rozložení hodnot jednotlivých ukazatelů, identifikaci odlehle hodnot a vyhodnocení vztahů mezi indikátory. Vzhledem k tomu, že většina ukazatelů není charakterizována normálním rozdělením dat, byl pro všechny kombinace ukazatelů obou scénářů vypočten Spearmanův korelační koeficient (přílohy 49 a 50). Podrobné výsledky OLS poskytují reporty z programu ArcGIS Pro pro MODEL 1 (příloha 59) a pro MODEL 2 (příloha 60). Obsah reportů z programu GeoDa je pro MODEL 1 obsažen v příloze 68 a pro MODEL 2 v příloze 69. Hodnota koeficientu determinace ( $R^2$ ) regresních modelů je

relativně velmi nízká. Pro MODEL 1 se pohybují kolem hodnoty 0,17, což naznačuje, že změny hodnot chyb nelze vysvětlit pomocí hodnot zkoumaných parametrů z více než 17 %. V případě použití MODELU 2 je možno vysvětlit téměř 15 % rozptylu závislé proměnné.

Následně došlo k sestavení několika regresních modelů pro oba scénáře, kde byly postupně odstraněny ukazatelé prokazující vysokou multikolinearitu, aby bylo dosaženo co nejpřesnějších výsledků. Finální model byl optimalizován pomocí *stepwise regrese*. Při diagnostice modelu bylo odhaleno narušení některých předpokladů regresního modelování, a to především přítomností heteroskedasticity a prostorové autokorelace reziduí. Ta poukazuje na prostorovou heterogenitu a nestacionaritu (Fotheringham, 1997), což má za následek nevhodnost aplikace klasických statistických metod (Anselin, 1988). Užitím OLS bylo zjištěno, že s rostoucím podílem obyvatel náboženského vyznání roste také index kriminality. Z hlediska rodinného stavu model potvrdil, že s rostoucím počtem svobodných a rozvedených roste i míra kriminality. Dle modelu platí, že s rostoucím podílem obyvatel v insolvenční situaci klesá index kriminality. OLS vyhodnotil, že s rostoucími hodnotami indexu kriminality roste podíl obyvatel v exekuci, romské populace a příjemců PnB. Výsledkům OLS je podrobněji věnována pozornost v podkapitole 4.3.1. Zajímavým dílčím výsledkem práce je prostorová vizualizace vybraných dílčích socioekonomických ukazatelů v podobě map (přílohy 26 až 48).

Poté byly aplikovány a porovnány modely Spatial lag model (SLM) a Spatial error model (SEM), avšak žádný z nich nebyl vybrán z důvodu nenaplnění předpokladů výrazného zlepšení v kontextu  $R^2$  a Akaike informačního kritéria (AIC). Výsledné modely stále bohužel vykazují heteroskedasticitu, kterou prostorové modely nedokázaly eliminovat. Srovnání regresních koeficientů OLS, SLM a SEM pro oba scénáře shrnuje příloha 75.

Aplikace lokální prostorové metody Geographically weighted regression (GWR) pro oba scénáře přináší efektivnější, kvalitnější a přesnější výsledky regresních koeficientů ve srovnání s metodami SLM, SEM či neprostorovou metodou OLS. Pro srovnání bylo využito několik statistik, mezi které náleží hodnota koeficientu determinace  $R^2$  a AIC. V tomto případě platí, že vyšší explanační sílu modelu GWR před modely OLS, SEM a SLM indikuje nižší hodnota AIC (MODEL 1 – 75 687; MODEL 2 – 1 774). Metoda GWR posloužila ke hledání vztahů mezi indexem kriminality a osmi prediktory –index stáří, podíl obyv. bez vzdělání, podíl obyv. v exekuci, podíl obyv. v insolvenční situaci, podíl obyv. s náboženským vyznáním, podíl svobodných, podíl rozvedených, volební účast). Regresní koeficienty byly vizualizovány prostřednictvím map (obr 12 až 19). Interpretace výsledků regresních koeficientů GWR je zaměřena především na statisticky významné oblasti MODELU 1, viz podkapitola 4.3.3.

## 6 DISKUZE

Policie České republiky poskytuje veřejně prostorová data registrovaných trestných činů z webové mapové aplikace *Mapy kriminality*, která mohou sloužit jako jeden ze zdrojů informací o kriminalitě v Česku. Datová sada je omezena polohovým zkrácením z důvodu ochrany osobních údajů poškozených a prevence jejich sekundární viktimizace a dále z důvodu ochrany osobních údajů osob podezřelých ze spáchání trestného činu, které by mohly být zejména v malých obcích nebo v řídké obydlených oblastech identifikovány. K dispozici jsou druhy trestné činnosti, u nichž může mít zveřejnění preventivní charakter a jejichž zveřejnění nebrání taktické hledisko. Typově se jedná např. o násilnou trestnou činnost, majetkovou trestnou činnost, extremismus, drogovou kriminalitu atd. I přes uvedený výčet omezení, data obsahují velké množství informací o kriminalitě. Přesto však může mezi odborníky panovat případná nedůvěra k samotným prostorovým analýzám, kde jsou data trestných činů použita. Velkou výhodou je, že data z *Mapy kriminality* jsou k dispozici v podrobném měřítku až na úroveň obcí. Autor práce doporučuje zaujmout kritický postoj a opatrnost při interpretaci analýz s použitím těchto dat kriminality.

Na konferenci projektu *Mapy budoucnosti II* v Národní technické knihovně v Praze konané dne 9. června 2022 ředitel projektu *Mapy budoucnosti II – využití prostorových dat pro vytvoření a pilotní ověření nástrojů a postupů pro analýzu a predikci kriminality za účelem jejího předcházení a potírání* JUDr. Michal Barbořík (ředitel odboru prevence kriminality Ministerstva vnitra) konstatoval, že zveřejněná data deliktů v Mapě kriminality nejsou statisticky relevantní, tj. nejsou vhodná pro zpracování relevantních statistických výpočtů. Jedná se spíše o zveřejněná data za účelem informovanosti veřejné společnosti a obecních úřadů.

Podle autorova kritického názoru nelze užitím datové sady *Mapy kriminality* produkovat realistické a vědecky střízlivé analýzy kriminality a závěry z nich učiněné. Autor se přesto domnívá, že data o kriminalitě mají velký potenciál k praktickému využití. Obce a Policie České republiky mohou sbírat data o kriminalitě a tím získat informovaný přehled o distribuci a intenzitě trestní činnosti páchané v dané lokalitě. Kompletní evidovaná data o výskytu trestné činnosti by mohla být v budoucnu na žádost poskytnuta odborníkům, což by mohlo přispět k rozvoji výzkumu prostorové analýzy kriminality. Autorovou intenzivní snahou bylo taková data s prosbou o žádost získat od PČR, avšak neúspěšně.

Vhodnějším zdrojem pro analýzy a hodnocení kriminality v Česku je statistika Policejního prezidia ČR (PP ČR), protože poskytuje data evidovaných trestných činů až na úroveň obvodních oddělení (což přibližně odpovídá členění na úrovni okresů). Statistická data představují nejpřesnější a nejucelenější obraz registrované kriminality. Nicméně, nevýhodou je, že data nejsou členěna na podrobnější administrativní jednotky, jako jsou například obce, což je rozdíl ve srovnání s daty z *Mapy kriminality*. V této práci jsou použita statistická data kriminality v případě výpočtu váženého indexu kriminality, což přináší inovativní pohled na rozmístění míry kriminality v Česku v roce 2021.

Je důležité poznamenat, že informace z kriminalistických statistik mohou mít omezenou vypovídací hodnotu kvůli různým faktorům. Nejvýznamnější z nich je skutečnost, že tyto statistiky se týkají pouze registrované kriminality a nezohledňují kriminalitu latentní. Dále, demografické faktory mohou ovlivnit statistiky, například změna v počtu obyvatel nebo baby boom může způsobit náhlé zvýšení kriminality. Změny legislativy, kdy dochází ke kriminalizaci nebo dekriminalizaci činů nebo ke změně jejich přísnosti, také mohou ovlivnit strukturu kriminality nebo četnost jednotlivých trestných činů. Pokud dojde k amnestii, může dojít k náhlému nárůstu kriminality způsobené

amnestovanými osobami. Důležitým faktorem je také změna trestní politiky státu, která může ovlivnit to, kam je zaměřena pozornost policie, případně preventivních a nápravných programů. Kromě toho mohou statistiky zkreslovat umělá latence, což je časová prodleva mezi spácháním trestného činu a dobou jeho statistického zaznamenání, nebo zkreslení při zadávání dat. Podle Trnkové (2019) by zmíněné faktory měly být brány v úvahu při analýze a hodnocení kriminality v Česku. Mohou tedy vznikat otázky ohledně možnosti míry hodnocení bezpečnosti Česka na základě statistických dat Policie ČR, která zahrnují pouze kriminalitu evidovanou. Je nutno zvážit, zda jsou tyto statistiky dostatečně vypovídající o vývojových trendech kriminálních jevů v posledních 20 letech a zda jsou schopny dokumentovat skutečný stav a příčiny změn v těchto jevech. Dále je nutné zvážit, zda jsou tyto statistiky schopny vysvětlit vývoj kriminality a připravit odpovídající orgány na očekávané změny v této oblasti. Tato problematika se týká absencí dat o latentní kriminalitě.

Výpočet indexu kriminality je různorodý. Může se lišit v závislosti na účelu studie. V práci je autorem věnována pozornost různým přístupům výpočtu indexu kriminality. Autor práce konstatuje, že pro kvalitnější interpretaci jednotlivých území by bylo vhodnější posoudit počty trestných činů ve vztahu k počtu trestně odpovědných osob, které se v daném prostoru skutečně vyskytují, tedy nejen k trvale či přechodně bydlícím. Avšak taková data v současné době pro Česko nejsou k dispozici.

Až 1 010 obcí Česka v roce 2021 dle dat z *Mapy kriminality* obsahuje nulové hodnoty indexu kriminality. Autor v práci navrhuje řešení použitím dvou odlišných scénářů v rámci modelového regresního přístupu. V kontextu regresního modelování by mohlo být vhodnějším řešením použít data trestných činů za delší časový úsek (např. za 5 let), což může přinést více údajů a méně extrémů. V kontextu práce však nebylo s tímto přístupem operováno, jelikož zdroj dat (Sčítání lidu, domů a bytů) vybraných socioekonomických ukazatelů je k dispozici po desetiletých intervalech. Dalším případným řešením eliminace problému s obcemi, které se potýkají s absencí trestných činů, může být agregace obcí na hierarchicky vyšší administrativní jednotky (např. okresy). Základní nevýhodou zmíněného řešení je ztráta prostorového detailu, na který se autor práce v analýzách zaměřil z důvodu inovativního řešení a přínosu výsledků práce. Podle autorova názoru je nula reálná hodnota a nulovou kriminalitu nelze považovat za extrém či dokonce chybu. Proto by měly být takové obce v analýze zachovány. Autor se domnívá, že zajímavým alternativním řešením by mohl být návrh třetího scénáře s použitím odmocninové transformace původních dat indexu kriminality se všemi obcemi. Nulové hodnoty indexu kriminality by byly zachovány a zbylé hodnoty by transformací přibližně vytvořili tvar normálního rozdělení.

Kvalita výsledků regresních modelů je ovlivněna nejenom volnou metody, konfigurací parametrů, ale také kvalitou vstupních dat. Vzhledem k tomu, že data kriminality z *Mapy Kriminality* nelze považovat za statisticky relevantní (tzn. nejsou zcela vhodná k použití statistických analýz), je třeba být k interpretaci výsledků kritický a brát je s určitou rezervou a v kontextu práce. Jistě by bylo vhodné provést validaci výsledků, nejen s použitím dat o míře kriminality, ale také porovnáním s jinými studii podobného charakteru. Vzhledem k tomu, že představená práce patří svým rozsahem a podrobnostmi mezi ojedinělé svého druhu, není v Česku k dispozici referenční práce, která by umožnila porovnání dosažených výsledků.

Zahrnutí interpretace výsledků MODELU 2 by bylo mimo rozsah této práce. Autor se tedy v práci zaměřil na základní interpretaci výsledků pouze pro MODEL 1. Kriminalita je velmi komplexní jev, a proto je interpretace výsledků analýz zaměřena pouze na místa, která byla metodou Geograficky vážené regrese (GWR) identifikována jako statisticky

významná. Přestože výsledky regresních koeficientů GWR MODELU 2 nebyly blíže interpretovány, může tento přístup sloužit jako inspirativní návod řešení a mohou na něj navázat další výzkumy, které by případně ověřily jeho vhodnost použití. Interpretace výsledků regresních modelů a hodnocení kriminality není v rámci práce v pokročilejší úrovni, jelikož k hlubšímu porozumění vzájemných vztahů mezi kriminalitou a kriminogenními faktory je zapotřebí spolupráce s dalšími odborníky, protože kriminalita je komplexní jev a vyžaduje multidisciplinární spolupráci. Znalost vztahu mezi kriminalitou a socioekonomickými ukazateli může tedy pomoci při plánování a implementaci politik zaměřených na prevenci kriminality a zlepšení bezpečnosti a ochrany občanů.



## 7 ZÁVĚR

Práce se zabývá hodnocením kriminality v obcích Česka v letech 2016–2021. V práci byla použita především data trestných činů z *Mapy kriminality*. Míra kriminality byla hodnocena v geografickém kontextu prostřednictvím výpočtu hrubého a čistého indexu kriminality za pomoci geografických informačních systémů. Čistý index kriminality oproti hrubému zahrnuje pouze trestně právní obyvatele. Inovativním a unikátním přístupem byl autorův návrh a výpočet váženého indexu kriminality pro rok 2021 v obvodních odděleních Česka. K tomu byla využita data Policie ČR všech registrovaných typů trestných činů dle takticko-statistické klasifikace. Ve výpočtu jsou zahrnuty váhy, které byly vypočítány na základě průměrné délky trestu nepodmíněného odnětí svobody (v měsících) pro každý typ trestné činnosti klasifikovaných podle trestního zákona. Výsledky vypočteného váženého indexu kriminality v podobě map mají širší vypovídací hodnotu, mohou přinést nové perspektivy a přiblížit se co nejvíce k reálnému stavu kriminality v dané oblasti na základě zohlednění různých vah trestných činů. Vše ale závisí na kvalitě vstupních dat kriminality.

Míra kriminality je v prostoru variabilní. Identifikace kriminality byla zaměřena především na místa vykazující anomálie a na místa s vyšší, resp. nižší koncentrací míry kriminality. Z výsledků všech souhrnných indexů kriminality napříč sledovanými roky vyplývá, že nejvyšší míra kriminality v Česku je nejvíce koncentrována v Praze, v obcích na Mostecku, Ostravsku, velkých městech s vysokým počtem obyvatel (50 000 a více), a poté v obcích při pohraničí (s výjimkou JV Česka). Dalšími důležitými výstupy hodnocení míry kriminality jsou animace a matice map indexů míry kriminality dílčích kategorií trestných činů v obcích Česka za jednotlivé roky 2016–2021.

Nutno podotknout, že diplomová práce reflektuje potřebu výzkumu kriminality v detailním prostředí, a sice na úrovni obcí, což činí tuto práci v Českém kontextu výjimečnou a dosud unikátní i z hlediska použitých metod a datové sady. Výsledky hodnocení míry kriminality jsou do určité míry překvapivé, nicméně nelze je srovnávat s jinými tuzemskými studiemi, jelikož se jedná o první studii, která byla realizována v kontextu použitých dat na úrovni obcí Česka. Mapové výstupy poskytují užitečné informace o trendech a vzorcích kriminality v různých oblastech. Mapování prostorového rozložení míry kriminality může pomoci Policii České republiky a dalším orgánům činným v trestním řízení lépe pochopit příčiny a vytvářet strategie pro řešení kriminality.

Ke stanovení vztahu mezi čistým indexem kriminality a vybranými demografickými a ekonomickými ukazateli byl použit jak neprostorový lineární model regrese Ordinary Least Squares (OLS), tak i prostorové regresní modely – Spatial Lag Model (SLM), Spatial Error Model (SEM) a Geograficky vážené regrese (GWR). Regresní modelování bylo realizováno pro dva scénáře – MODEL 1 zahrnující obce s nulovou hodnotou indexu kriminality a MODEL 2, které tyto obce nezahrnuje. Přestože logaritmická transformace dat indexu kriminality v MODELU 2 přispěla k pozitivní změně normality dat, byla autorova pozornost věnována interpretaci MODELU 1 z důvodu hodnocení bližšího skutečného stavu kriminality. Hodnocení MODELU 2 by bylo nad rámec této diplomové práce a může představovat potenciální téma pro další výzkumy.

Užitím OLS bylo zjištěno, že s rostoucím podílem obyvatel náboženského vyznání roste také index kriminality. Z hlediska rodinného stavu model potvrdil, že s rostoucím podílem svobodných a rozvedených roste i míra kriminality. Dle modelu platí, že s rostoucím podílem obyvatel v insolvenční klesá index kriminality. OLS vyhodnotil, že s rostoucími hodnotami indexu kriminality roste podíl obyvatel v exekuci, romské populace a příjemců příspěvků na bydlení.

Dílčí část práce se věnuje aplikaci prostorových autoregresních modelů. Podle Akaike informačního kritéria (AIC) přináší prostorové modely SLM a SEM mírné zlepšení oproti neprostorovým. Vzhledem k tomu, že nedošlo k výraznému zlepšení výsledků ve srovnání s OLS, žádný z těchto prostorových modelů nebyl zvolen pro další interpretaci.

Použití metody GWR vedlo k lepším výsledkům než využití metody OLS. Pro srovnání bylo využito několik statistik, mezi které náleží hodnota koeficientu determinace  $R^2$  a AIC. V tomto případě platí, že vyšší explanační sílu modelu GWR před modelem OLS indikuje nižší hodnota AIC (Anselin, 2005). Šírka fixního Gaussovského pásma byla optimalizována podle AIC a  $R^2$  na 15 km. Výsledný model obou scénářů má nadále problémy s vysokou lokální multikolinearitou. Oba scénáře v žádném případě neodstranily prostorovou autokorelaci reziduí. V rámci interpretace výsledných regresních koeficientů GWR MODELU 1 je autorova pozornost soustředěna především na modelem identifikovány statisticky významné lokality. Metoda GWR posloužila ke hledání vztahů mezi indexem kriminality a osmi prediktory – index stáří, podíl obyvatel bez vzdělání, podíl obyvatel v exekuci, podíl obyvatel v insolvenční, podíl obyvatel s náboženským vyznáním, podíl svobodných, podíl rozvedených a volební účast).

Dosažené výsledky lokálních regresních koeficientů GWR mohou pomoci porozumět specifikům statistických a prostorových vztahů kriminality vzhledem k vybraným ekonomickým a demografickým ukazatelům v kontextu geoinformatiky a geografie. Tyto výsledky mohou být užitečné pro podporu prevence kriminality v konkrétních oblastech Česka a ke zlepšení různých opatření a strategií. Nicméně, je třeba mít na paměti, že kriminalita je komplexní a multidisciplinární téma, které zahrnuje sociální, psychologické a environmentální faktory. Proto by měly být výsledky regresních koeficientů interpretovány s opatrností a s ohledem na další relevantní faktory. Multidisciplinární přístup umožní získat komplexní a celkovější pohled na problematiku kriminality v dané oblasti.

## POUŽITÁ LITERATURA A INFORMAČNÍ ZDROJE

AKAIKE, H. (1974). A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, 19(6), 716–723. <https://doi.org/10.1109/TAC.1974.1100705>

RODGER, A., VEZEVICIUS, A., PAPIES, E. K. (2023). Can a simple plan change a complex behavior? Implementation intentions in the context of water drinking, *Appetite* 183.

ANSELIN L. (1988). *Spatial Econometrics: Methods and Models*. London: Kluwer. 284.

ANSELIN L. (2002). Under the Hood: Issues in the Specification and Interpretation of Spatial Regression Models. *Agricultural Economics* 27(3). 247-267.

ARGUN, U.; DAĞLAR, M. (2016). Crime Mapping and Geographical Information Systems in Crime Analysis. *Journal of Human Sciences*. 13.

AZ LEGAL, advokátní kancelář, s.r.o., Praha [online]. 2022 [cit. 2022-12-12]. <https://azlegal.cz/faq/jaky-je-rozdil-mezi-prestupkem-spravnim-deliktem-a-trestnym-cinem/>.

BALDWIN, J. (1979). *Ecological and Areal Studies in Great Britain and the United States*. *Crime and Justice*, 1, s. 29–66.

BARTOŇOVÁ, D. (1996). Regionální diference sociálně-demografických znaků obyvatelstva. In: Hampl, M. et al.: *Geografická organizace společnosti a transformační procesy v České republice*. Přírodovědecká fakulta Univerzity Karlovy v Praze, Praha, 127–154.

BAXTER, J.; EYLES, J. (1997). Evaluating qualitative research in social geography: establishing 'rigour' in interview analysis. *Transactions of the Institute of British Geographers*, 22, č. 4, 505–525.

BERAN, V.; ŘÍHOVÁ, L. (2017): Dostupnost dat mezi zainteresovanými institucemi v oblasti exekucí. *VÚPSV, v. v. i. Praha*, s36.

BERKA, P (2003): *Dobývání znalostí z databází*. Vyd. 1. Praha: Academia. 366 s. ISBN 80-200-1062-9.

BIVARIATE COLORS. ArcGIS Online Help [online]. 2023 [cit. 2023-4-01]. <https://pro.arcgis.com/en/pro-app/latest/help/mapping/layerproperties/bivariate-colors.htm>.

BLOCK, C. R. (1995). STAC Hot-Spot Areas: A Statistical Tool for Law Enforcement Decisions. C. R. Block, M. Dabdoub, and S. Fregly (eds), *Crime Analysis through Computer Mapping*, Police Executive Research Forum Washington DC, 15-32.

- BOULTON, A. J.; WILLIFOWD, A. (2018). Analyzing skewed continuous outcomes with many zeros: A tutorial for social work and youth prevention science researchers. *Journal of the Society for Social Work and Research*, 9(4), 721–740. <https://doi.org/10.1086/701235>.
- BRANTINGHAM, P. J.; BRANTINGHAM, P. L. (1984). *Patterns in crime*. New York: Macmillan.
- BRANTINGHAM, P. J.; BRANTINGHAM, P. L. (1981). *Environmental Criminology*. Beverly Hills, CA: Sage Publications.
- BRUNSDON C, FOTHERINGHAM AS, CHARLTON M. (1996). Geographically weighted regression: A method for exploring spatial nonstationarity. *Geogr Anal* 28(4). 281–298.
- CECCATO V. (2009). Crime in a City in Transition: The Case of Tallinn, Estonia. *Urban Studies*, 46 (8), 1611–1638.
- CECCATO, V., LUKYTE, N. (2011). Safety and sustainability in a city in transition: The case of Vilnius, Lithuania. *Cities*, 28 (1), 83–94.
- CECCATO, V.; DOLMEN, L. (2011). Crime in rural Sweden. *Applied Geography*. Vol. 31 (1), 119-135. <<http://www.sciencedirect.com/science/article/pii/S0143622810000287>>.
- CLEMENTE, F., KLEIMAN, M. B. (1977). Fear of Crime in the United States: A Multivariate Analysis. *Social Forces*, 56 (2), 519–531.
- CULLEN, T. F., WILCOX, P. (2010). *Encyclopedia of Criminological Theory*. University of Cincinnati, SAGE Publications, Inc., Los Angeles, ISBN 978-1-4129-5918-6.
- DE VAUS, D. (2002). *Analyzing social science data*. London: SAGE Publications Ltd.
- DEMOMBYNES, G., ÖZLER, B. (2005). Crime and local inequality in South Africa. *Journal of Development Economics*, 76 (2), 265–292.
- ELHORST, J.P. (2010). Spatial Panel Data Models. In Fischer, M.M. and Getis, A., Eds., *Handbook of Applied Spatial Analysis: Software Tools, Methods and Applications*, Springer Berlin Heidelberg, Berlin.
- ELLIS, L., BEAVER, K., WRIGHT, J. (2009). *Handbook of Crime Correlates*. San Diego: Academic Press, 264.
- FOTHERINGHAM, A. S. (1997). Trends in quantitative methods I: stressing the local. *Progress in Human Geography*, 21(1), 88–96.

FOTHERINGHAM, A. S., BRUNSDON, C., CHARLTON, M. (2002). Geographically weighted regression – the analysis of spatially varying relationships. John Wiley et Sons, London, 269.

FRIENDLY, M. (2008). The Golden age of statistical graphics *Statistical Science.*, 23 (4), 502–535.

GAROFALO, J. (1979). Victimization and the fear of crime. *Journal of Research in Crime and Delinquency*, 16 (1), 80–97.

GEOPORTÁL ČÚZK [online]. 2010–2022 [cit. 2022-9-15]. Český úřad zeměměřický a katastrální. <http://geoinformatics.upol.cz/aktual.php>.

GRIFFITH, D.; ARBIA, G. (2010). Detecting negative spatial autocorrelation in georeferenced random variables. *International Journal of Geographical Information Science*, 24 (3), 417–437.

GUERRY, A.-M., LACROIX, S. F., de SILVESTRE, A.-F., GIRARD, P.-S. (1833). *Essai sur la statistique morale de la France*. University of Gent, Crochard.

HAGAN, F. E. (2011). *Introduction to Criminology: Theories, Methods, and Criminal Behavior*. Los Angeles: SAGE Publications, 576.

HAINING, R. (2003). *Spatial Data Analysis Theory and Practice*. Cambridge University Press, Cambridge. 432.

HAINING, R. (2009). The special nature of spatial data. In *The Sage handbook of spatial analysis*, upraveno podle A. S. Fotheringham, et P. A. Rogerson, 4–21. Thousand Oaks, CA: Sage.

HARRIES, K. D. (1968). The Geography of American Crime. *Journal of Geography*. Vol. 70 (4), 204-213.

HART, L.; Xiao, B.; Jensen, S. (2022). Spatial Analysis of the Association between School Proximity and Crime in Philadelphia. 10.48550/arXiv.2206.03387.

HART, T. C.; Lersch, K. M. (2015). *Space, time, and crime*. Durham, NC: Carolina Academic.

HENDL, J. (2005). *Kvalitativní výzkum. Základní metody a aplikace*. Portál, Praha, 408. ISBN 80-7367-040-2.

HENDL, J. (2012). *Přehled statistických metod zpracování dat: analýza a metaanalýza dat*. Portál, Praha, 736. ISBN: 978-80-262-0200-4.

- HERBERT, D. T. (1982). *The Geography of Urban Crime*. Longman, New York, 120.
- HOFERKOVÁ, S. (2014). *Úvod do kriminologie*. Univerzita Hradec Králové, 1. vydání, 65.
- HOJMAN, D. E. (2004). Inequality, unemployment and crime in Latin American cities. *Crime, law and social change*, 41 (1), 33–51.
- HORÁK, J. (2014). *Sborník příspěvků. Mapy budoucnosti – moderní nástroj ke zvýšení efektivity a kvality výkonu veřejné správy v oblasti prevence kriminality založený na analýze a predikci kriminality: Problémy a výzvy mapování, analýz a predikce kriminality*. Policejní akademie ČR v Praze.
- HORÁK, J. (2015). *Metodika tvorby multidimenzionální databáze pro prevenci kriminality*. Certifikovaná metodika. MV ČR 2015.
- HORÁK, J. (2016a). *Metodika harmonizace, agregace a anonymizace dat kriminality*. GIS Ostrava 2016 - Geoinformatika pro společnost.
- HORÁK, J. (2016b). *Metodika tvorby multidimenzionální databáze pro prevenci kriminality*. GIS Ostrava 2016 - Geoinformatika pro společnost.
- HORÁK, J. (2019). *Prostorové analýzy dat*. Ostrava: VŠB-TU Ostrava. 181. ISBN 978-80-248-4368-1.
- HORÁK, J.; ORLÍKOVÁ, L. (2020). *Prostorové regresní modelování s příklady*. GIS Ostrava 2020 - Prostorová data pro Smart City a Smart Region.
- HRUŠKA, L.; FUJAK, R.; ŠEVČÍK, J. et al. (2015). *Mapy budoucnosti – moderní nástroj ke zvýšení efektivity a kvality výkonu veřejné správy v oblasti prevence kriminality založený na analýze a predikci kriminality*. Ostrava: ACCENDO – Centrum pro vědu a výzkum, z.ú. ISBN 978-80-87955-06-2.
- CHANEY S., RATCLIFFE J. (2005). *GIS and Crime Mapping*. ISBN: 978-0-470-86099-1.
- CHANEY, S. (2015). *Sborník příspěvků, 2. odborný workshop Mapy budoucnosti – moderní nástroj ke zvýšení efektivity a kvality výkonu veřejné správy v oblasti prevence kriminality založený na analýze a predikci kriminality, 39–47*. Pro Ministerstvo vnitra vydalo: Accendo – Centrum pro vědu a výzkum, z.ú. [www.prevencekriminality.cz](http://www.prevencekriminality.cz)
- CHRIS, Ch.; SHALENDRA SINGH, O.; GCINA, B. (2008). *Crime mapping and analysis: filling the gaps*. *PositionIT*. 1–4.
- INGILEVICH, V.; IVANOV, S. (2018). *Crime rate prediction in the urban environment using social factors*. *Procedia Computer Science*. 136. 472–478. 10.1016/j.procs.2018.08.261.

IVAN I.; HORÁK, J (2012). Analýza kriminality v Ostravě. In Růžička, J. ed.: Symposium GIS Ostrava 2012: Současné výzvy geoinformatiky. Ostrava: VŠB-TU, 1–7.

IVAN, I. (2014). Kvantitativní metody v geografii. VŠB-TU Ostrava, 2014. 110.

IVAN, I.; HORÁK, J. (2016). Metodika identifikace anomálních lokalit kriminality pomocí jádrových odhadů. GIS Ostrava 2016 - Geoinformatika pro společnost.

IVAN, I.; ORLÍKOVÁ, L.; PÁNEK, J.; MACKOVÁ, L. (2020). Metodika identifikace a hodnocení bezpečnostně rizikových lokalit ve městě. Vysoká škola báňská – Technická univerzita Ostrava.

JENKS, George F (1967). The Data Model Concept in Statistical Mapping. International Yearbook of Cartography 7. 186–190.

JÍCHOVÁ, J. (2013). Kriminalita a její percepce v městském prostředí. Disertační práce. Katedra sociální geografie a regionálního rozvoje, PřF UK, Praha, 69.

JÍCHOVÁ, J. (2014). Výzkum zločinu v Česku z pohledu geografie. Historická geografie, 40(1), 73–93.

JÍCHOVÁ, J. (2017a). Kriminalita. In: Ouředníček, M. – Jíchová, J. – Pospíšilová, L. (eds.): Historický atlas obyvatelstva českých zemí. Praha: Karolinum, 101–107.

JÍCHOVÁ, J. (2017b). Kriminalita v Praze: měřítková diferenciaci a možnosti měření. In: Ouředníček, M. – Jíchová, J. (eds.): Sociální prostředí Prahy: město na prahu 21. století. Praha: Academia, 63–91.

JÍCHOVÁ, J.; NEMEŠKAL, J. (2012a). Kriminalita v Česku. Specializovaná mapa. Atlasobyvatelstva.cz. Praha: Přírodovědecká fakulta Univerzity Karlovy v Praze.

JÍCHOVÁ, J.; NEMEŠKAL, J. (2012b). Struktura kriminality v Česku. Specializovaná mapa. Atlasobyvatelstva.cz. Praha: Přírodovědecká fakulta Univerzity Karlovy v Praze.

JÍCHOVÁ, J.; NETRDOVÁ, P. (2017). Mapování kriminality jako téma i činnost při výuce. Geografické rozhledy 27/2. 6.

JÜTTNER, A. (1968). O kriminologii a kriminalitě. Orbis, Praha, 214.

KALANTARI, M.; RAHMATY, A; TOOMANIAN, A.; DERO, Q. (2016). A New Methodological Framework for Crime Spatial Analysis Using Local Entropy Map. Modern Applied Science. 10. 231. 10.5539/mas.v10n9p231.

KALLAB, J. (1913). Dvě studie o významu kriminální statistiky pro reformu trestního práva. Sborník věd právních a státních (8). K. Kadlec, Praha, 375.

KAMENICKÝ, J. (2007). Vývoj kriminality v územích ČR po roce 2000. Praha: Český statistický úřad.

KANKANHALLI, A., HAHN, J., TAN, S. et al. (2016). Big Data and analytics in healthcare: Introduction to the special section. *Inf Syst Front* 18, 233–235. <https://doi.org/10.1007/s10796-016-9641-2>.

KARABEC, Z. (1973). Vývoj kriminality v ČSSR. Výzkumný ústav kriminologický při Generální prokuratuře ČSSR, Praha.

KOČVAROVÁ, B (2020). Možnosti publikování prostorových dat Katedry geoinformatiky UP. Diplomová práce. Olomouc: Univerzita Palackého v Olomouci. Přírodovědecká fakulta, 86.

KOLAŘÍKOVÁ, M. (2017). Mapy kriminality. Diplomová práce. Zlín: Univerzita Tomáše Bati ve Zlíně. Fakulta aplikované informatiky, 93.

KOLBÁBEK, F. (2007). Vývoj kriminality na území České republiky. Diplomová práce. Olomouc: Univerzita Palackého v Olomouci, 151.

KUCHTA, J.; VÁLKOVÁ, H (2005). Základy kriminologie a trestní politiky. 1. vyd. Praha: C.H. Beck, 544. Beckovy mezioborové učebnice. ISBN 80-7179-813-4.

LEIVA, M.; LAVÍN, F.; PONCE, R. (2020). Do immigrants increase crime? Spatial analysis in a middle-income country. *World Development*. 10.1016/j.worlddev.2019.104728.

LESAGE J. P. (1998). *The Theory and Practice of Spatial Econometrics*. University of Toledo, 273.

LEVINE, N. (2004). CrimeStat III: A spatial statistics program for the analysis of crimeincident locations. (Version II, III). [Computer software]. Houston, Texas/ National Institute of Justice, Washington, DC. London, 269.

MA, Y., GOPAL, S. (2018). Geographically Weighted Regression Models in Estimating Median Home Prices in Towns of Massachusetts Based on an Urban Sustainability Framework. *SUSTAINABIL-ITY* 10(4), 1026, DOI: 10.3390/su10041026.

MACKŮ, K. (2020). Multidisciplinární hodnocení kvality života v Evropě na regionální úrovni. Disertační práce. Olomouc: Univerzita Palackého v Olomouci. Přírodovědecká fakulta.

Mapa kriminality: Interaktivní přehledová mapa kriminality zobrazující vybranou přestupkovou a trestnou činnost evidovanou Policií České republiky. [online]. [cit. 2022-10-12]. <https://kriminalita.policie.cz>



MAPAKRIMINALITY.CZ: Projekt otevření společnosti, o.p.s. [online]. [cit. 2022-10-11].  
<https://www.mapakriminality.cz/o-aplikaci/>

MAREK, L. (2015). Prostorové a vícerozměrné statistické analýzy epidemiologických dat. Disertační práce. Olomouc: Univerzita Palackého v Olomouci, 168.

MAREŠOVÁ, A. (2011). Resortní statistiky – základní zdroj informací o kriminalitě v České republice. Vybrané metody kriminologického výzkumu (2), Praha.

MAREŠOVÁ, A., SCHEINOST, M. (2001). Trendy kriminality v ČR z pohledu roku 2000. Sociologický časopis/Czech Sociological Review, 37 (1), 23–41.

MARTINKOVÁ, M. (2007). Zkušenosti obyvatel České republiky s některými delikty – výsledky viktimologického výzkumu. Praha: IKSP. 87. ISBN 978-7338-064-9.

MENNIS, J., HARRIS, P. W.; OBRADOVIC, Z. et al. (2011). The Effect of Neighborhood Characteristics and Spatial Spillover on Urban Juvenile Delinquency and Recidivism. The Professional Geographer. 63 (2), 174–192.

MICHÁLEK, A. (2009). Priestorová diferenciácia kriminality. Geografický časopis. 61 (2), 111-120.

MUSIL, S., TICHÁ, B. (1977). Přehled dynamiky kriminality 1970–1974 a prognóz 1975–1980. Výzkumný ústav kriminologický, SEVT, Praha.

NEMEŠKAL, J.; JÍCHOVÁ, J. (2018). Prostorový vzorec kriminality v Česku. Demografie, 2018, 60, 124–139.

NOLD, CH. (2009). Emotional Cartography: Technologies of the Self.  
<http://emotionalcartography.net/EmotionalCartography.pdf>.

NOVOTNÝ, O. a ZAPLETAL, J. (2004). Kriminologie. 2., přeprac. vyd. Praha: ASPI, 451. ISBN 80-7357-026-2.

NOVOTNÝ, O.; ZAPLETAL, J. (1996). Kriminologie, Univerzita Karlova, Praha.

O'BRIAN (2007). A Caution Regarding Rules of Thumb for Variance Inflation Factors. Quality & Quantity 41. 673–690. DOI 10.1007/s11135-006-9018-6.

O'BRIAN (2007). A Caution Regarding Rules of Thumb for Variance Inflation Factors. Quality & Quantity 41. 673–690. DOI 10.1007/s11135-006-9018-6.

OPENSHAW S. (1996). Developing GIS-relevant zone-based spatial analysis methods. Spatial analysis: Modeling in a GIS environment, editoři P. Longley, and M. Batty, 55–73. New York: Wiley.

- PACIONE, M. (2005). Quality-of-life Research in Urban Geography. In: Berry, B., Wheeler, J. (eds.): *Urban Geography in America, 1950-2000: Paradigms and Personalities*. New York, Routledge, s233-264.
- PÁNEK, J.; IVAN, I.; MACKOVÁ, L. (2019). Comparing Residents' Fear of Crime with Recorded Crime Data—Case Study of Ostrava, Ostrava. *ISPRS Int. J. Geo-Inf.* 2019, 8, 401. <https://doi.org/10.3390/ijgi8090401>
- PERKINS, CH. (2009). Performative and Embodied Mapping. *International Encyclopedia of Human Geography*, edited by Rob Kitchin and Nigel Thrift. Oxford: Elsevier. 126–132.
- POCITOVÁ MAPA OLOMOUCE [online]. 2022 [cit.2022-10-05]. Univerzita Palackého v Olomouci. <https://www.pocitovemapy.cz/olomouc/nahled>.
- POLICIE ČESKÉ REPUBLIKY. Statistické přehledy kriminality za rok 2021 [online]. 2022 [cit. 29.12.2022]. <https://www.policie.cz/clanek/statisticke-prehledy-kriminality-za-rok-2021.aspx>.
- QUETELET, A. (1833). *Recherches sur le Penchant au Crime aux Différens Ages*. Hayes, Brusel. 92. ISBN: 978-1167439506.
- RACHEL, B. S. (2017). *Crime analysis with crime mapping*. 4. vydání. Los Angeles, CA: SAGE.
- RAWSON, W. (1841). *Journal of the Statistical Society of London* 3, 1841, 331–352.
- REID, L. W., KONRAD, M. (2004). The Gender Gap in Fear: Assessing the Interactive Effects of Gender and Perspectived Risk on fear of Crime. *Sociological Spectrum*, 24 (4), 399–425.
- RIGER, S., GORDON, M. T. (1981). The Fear of Rape: A study of Social Control. *Journal of Social Issues*, 37 (4), 71–92.
- ROSSMO, D. K. (2000). *Geographic profiling*. Boca Raton, FL: CRC Press.
- RUSSNÁK, J. (2018). *Pokročilé metody datové analýzy a kartografické vizualizace*. Disertační práce. GEOGRAFICKÝ ÚSTAV, PřF MUNI, Brno. *Science*, 24 (3), 417–437.
- SHERMAN, L.; WEISBURD, D. (1995). General deterrent effects of police patrol in crime “hot spots”: a randomized, controlled trial. *Justice Quarterly*, 12(4), 625-648.
- SCHEINOST, M et al. (2021). *Analýza trendů kriminality v České republice v roce 2020*. Institut pro kriminologii a sociální prevenci. Praha.

SIMIONESCU, M. (2014). Predicting the National Unemployment Rate in Romania using a Spatial Auto-Regressive Model that includes Random Effects. Proceedings of International Conference Economic Scientific Research - Theoretical, Empirical and Practical Approaches (ESPERA). Pro-cedia Economics and Finance, 22, 663-671. DOI: 10.1016/S2212-5671(15)00281-6.

SINGH, S. (2012). Community engagement of local space in crime mapping and policing of informal settlements: A study of cato crest informal settlement. University of Kwazulu-Nata.

SKOGAN, W. G. (1987). The impact of victimization on fear. Crime & Delinquency, 33 (1), 135–154.

SKOGAN, W. G. (1995). Crime and the Racial fears of White Americans. The Annals of the American Academy, 539, 59–71.

SMITH M.J., Goodchild M.F., Longley P.A. (2018). Geospatial Analysis. <http://www.spatialanalysisonline.com>.

SMITH, S. J. (1987). Fear of crime: beyond a geography of deviance. Progress in Human Geography, 11 (1), 1–23.

SPURNÁ, P. (2008). Prostorová autokorelace – všudypřítomný jev při analýze prostorových dat? / Spatial Autocorrelation – A Pervasive Phenomenon in the Analysis of Spatial Data? Sociologický Časopis / Czech Sociological Review, 44 (4), s. 767–787. <http://www.jstor.org/stable/41132620>.

SURMAŘ, V. (2013). Geografie trestné činnosti v ČR. Bakalářská práce. Brno: Masarykova univerzita. Přírodovědecká fakulta, 17.

SVATOŠ, R. (2014). Prevence kriminality. České Budějovice: Vysoká škola evropských a regionálních studií. ISBN 978-80-87472-76-7.

SYSTÉM TRESTŮ [online]. 2006-2022 [cit. 15.11.2022]. Trestní právo a trestní řízení pro laiky. Dostupné z WWW: <<http://www.trestni-rizeni.com/vyklad-pojmu/system-trestu>>.

ŠIMON, M.; JÍCHOVÁ, J. (2018a). Zveřejnění dat o kriminalitě na úrovni ulic - návrh řešení pro města v Česku | Publishing the crime data at the level of street segments – a proposal of solution for cities in Czechia. Kriminologické Dny 2018. Sborník z VI. Ročníku Mezinárodní Konference Kriminologické Dny Pořádaný Ve dnech 18.–19. 1. 2018 Českou Kriminologickou Společností Ve Spolupráci s Právnickou Fakultou Univerzity Palackého v Olomouci., 1(1), 186–204.

ŠIMON, M.; JÍCHOVÁ, J. (2018b). Jsou místa koncentrace kriminality společensky nejškodlivější? Nový analytický přístup pro prevenci kriminality a policejní praxi. | Does crime hotspots overlap with crime harmspots? New analytical approach for crime prevention and policing.

T-MAPY spol. s r.o. [online]. Copyright © 2022 [cit. 14.10.2022].  
<https://www.tmapy.cz/>

TOMÁŠEK, J. (2010). Úvod do kriminologie: jak studovat zločin. 1. vyd. Praha: Grada, 214. ISBN 978-80-247-2982-4.

TRESTNÍ ZÁKONÍK Č. 40/2009 Sb.

TRNKOVÁ, M. (2019). Vývoj a struktura kriminality v ČR. Diplomová práce. Praha: Univerzita Karlova. Přírodovědecká fakulta.

TYLEČEK, V. (2006). Vliv rodinného prostředí na kriminalitu mládeže. Diplomová práce. Brno: Masarykova univerzita. Pedagogická fakulta.

UHROVIČOVÁ, E. (2016). Souvislost kriminality s religiozitou. Bakalářská práce. Olomouc: Univerzita Palackého v Olomouci. Filozofická fakulta.

VÁLKOVÁ, H., KUČHTA, J. et al. (2012). Základy kriminologie a trestní politiky. 2. vydání. Praha: C. H. Beck, 132. ISBN 978-80-7400-429-2.

VOJÁČKOVÁ, K. (2010). Politická participace mladých lidí. Diplomová práce. Brno: Masarykova univerzita. Fakulta sociálních studií.

VONDRÁŠEK, M. (2022). Brífink k projektu Mapa kriminality. <https://ct24.ceskatelevize.cz/domaci/3542879-lide-si-mohou-delikty-ve-svem-meste-najit-v-line-mape>.

VOŽENÍLEK, V.; KAŇOK, J. (2011). Metody tematické kartografie: vizualizace prostorových jevů. Olomouc: Univerzita Palackého v Olomouci pro katedru geoinformatiky. ISBN 9788024427904.

WANG, H.; KIFER, D.; GRAIF, C.; Li, Z. (2016). Crime rate inference with big data. In KDD 2016 - Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (635-644). (Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining; 13-17, 10.

WEBSTER, C. (2003). Race, space and fear: imagined geographies of racism, crime, violence and disorder in Northern England. *Capital & Class*, 27 (2), 95-122.

WEISBURD, D.; BERNASCO, W.; BRUINSMA, G. J. N. (2009). Units of analysis in geographic criminology: historical development, critical issues, and open questions. In: Weisburd, D., Bernasco, W., Bruinsma, G.J. (eds). Putting Crime in its Place. Units of Analysis in Geographic Criminology. Springer Science+Business Media, LLC, New York, 3–34.

WEISENT, J., ROHRBACH, B., DUNN, J., ODOI, A (2012). Socioeconomic determinants of geographic disparities in campylobacteriosis risk: a comparison of global and local modeling approaches. International Journal of Health, Geographics, 11 (45). DOI:10.1186/1476-072X-11-45.

WILL, J. A., MCGRATH, J. H. (1995). Crime, Neighborhood Perceptions, and the Underclass". The Relationship between Fear of Crime and Class Position. Journal of Criminal Justice, 23 (2), 163–176.

WORTLEY, R., MAZEROLLE, L. (2011). Environmental Criminology and Crime Analysis. New York, Routledge.

ZOUBKOVÁ, I.; MOULISOVÁ, M. (2004). Kriminologie a prevence kriminality. Vyd. 1. Praha: Armex. 146. ISBN 80-86795-05-5.

ZUCKER, A. (1894). Kriminologické črty zejména se zřetelem ke zločinné a zpustlé mládeži. Bursík & Kohout, Praha, 44.

## **PŘÍLOHY**

# SEZNAM PŘÍLOH

## Vázané přílohy:

- Příloha 75 Srovnání regresních koeficientů obou scénářů
- Příloha 76 Požité socioekonomických indikátorů
- Příloha 77 Základní popisné statistiky nezávisle proměnných
- Příloha 78 Srovnání regresních koeficientů SLM a SEM obou scénářů
- Příloha 79 Srovnání regresních koeficientů OLS obou scénářů
- Příloha 80 Srovnání regresních koeficientů MODELU 2 po logaritmické a exponenciální transformaci
- Příloha 81 Rezidua regresního modelu pro MODEL 1 (nahore) a MODEL 2 (dole)

## Elektronické přílohy

- Příloha 1 Mapa čistého index kriminality 2016
- Příloha 2 Mapa čistého index kriminality 2017
- Příloha 3 Mapa čistého index kriminality 2018
- Příloha 4 Mapa čistého index kriminality 2019
- Příloha 5 Mapa čistého index kriminality 2020
- Příloha 6 Mapa čistého index kriminality 2021
- Příloha 7 Mapa hrubého index kriminality 2016
- Příloha 8 Mapa hrubého index kriminality 2017
- Příloha 9 Mapa hrubého index kriminality 2018
- Příloha 10 Mapa hrubého index kriminality 2019
- Příloha 11 Mapa hrubého index kriminality 2020
- Příloha 12 Mapa hrubého index kriminality 2021
- Příloha 13 Mapová animace indexu trestné činnosti Jiná majetková
- Příloha 14 Mapová animace indexu trestné činnosti Extremismus
- Příloha 15 Mapová animace indexu trestné činnosti Násilná
- Příloha 16 Mapová animace indexu trestné činnosti Toxikománie
- Příloha 17 Mapová animace indexu trestné činnosti Zbraně
- Příloha 18 Mapová animace indexu trestné činnosti Podvody
- Příloha 19 Mapová animace indexu trestné činnosti Obecně nebezpečná
- Příloha 20 Mapová animace indexu trestné činnosti Krádeže
- Příloha 21 Mapová animace indexu trestné činnosti Krádeže vloupáním
- Příloha 22 Mapová animace indexu trestné činnosti Dopravní nehody
- Příloha 23 Mapová animace indexu trestné činnosti Požáry a výbuchy
- Příloha 24 Matice map indexů kriminality podle typů trestných činů
- Příloha 25 Mapa váženého a čistého indexu kriminality (bivariate metoda)
- Příloha 26 Mapa indexu stáří
- Příloha 27 Mapa hustoty zalidnění stáří
- Příloha 28 Mapa hrubé míry přirozeného přírůstku stáří
- Příloha 29 Mapa hrubé míry migračního salda
- Příloha 30 Mapa podílu obyvatel bez vzdělání

Příloha 31	Mapa podílu obyvatel se základním vzděláním
Příloha 32	Mapa podílu obyvatel se středním vzděláním
Příloha 33	Mapa podílu obyvatel se středním vzděláním a nástavby
Příloha 34	Mapa podílu obyvatel s vyšším odborným vzděláním
Příloha 35	Mapa podílu obyvatel s vysokoškolským vzděláním
Příloha 36	Mapa podílu romské populace
Příloha 37	Mapa podílu obyvatel v exekuci
Příloha 38	Mapa podílu příjemců příspěvků na bydlení (PnB)
Příloha 39	Mapa podílu obyvatel ucházejících se o práci (UoZ)
Příloha 40	Mapa podílu obyvatel v insolvenční
Příloha 41	Mapa podílu obyvatel s nedokončeným základním vzděláním
Příloha 42	Mapa podílu obyvatel s náboženským vyznáním
Příloha 43	Mapa podílu obyvatel bez náboženského vyznání
Příloha 44	Mapa podílu svobodných
Příloha 45	Mapa podílu sezdáných
Příloha 46	Mapa podílu rozvedených
Příloha 47	Mapa podílu ovdovělých
Příloha 48	Mapa volební účasti
Příloha 49	Korelační matice MODELU 1
Příloha 50	Korelační matice MODELU 2
Příloha 51	Mapa GWR regresních koeficientů obyvatel bez vzdělání
Příloha 52	Mapa GWR regresních koeficientů obyvatel v exekuci
Příloha 53	Mapa GWR regresních koeficientů obyvatel v insolvenční
Příloha 54	Mapa GWR regresních koeficientů obyvatel s náboženským vyznáním
Příloha 55	Mapa GWR regresních koeficientů svobodných obyvatel
Příloha 56	Mapa GWR regresních koeficientů rozvedených obyvatel
Příloha 57	Mapa GWR regresních koeficientů volební účasti
Příloha 58	Mapa GWR regresních koeficientů indexu stáří
Příloha 59	OLS report MODELU 1 z programu ArcGIS Pro
Příloha 60	OLS report MODELU 2 z programu ArcGIS Pro
Příloha 61	SLM report MODELU 1 z programu GeoDa
Příloha 62	SEM report MODELU 1 z programu GeoDa
Příloha 63	SEM report MODELU 2 z programu GeoDa
Příloha 64	SLM report MODELU 2 z programu GeoDa
Příloha 65	Exploratory Regression report MODELŮ 1 a 2 z programu ArcGIS Pro
Příloha 66	Číselník paragrafů Trestního zákoníku
Příloha 67	Průměrné délky dob nepodmíněných trestů odnětí svobody
Příloha 68	OLS report MODELU 1 z programu GeoDa
Příloha 69	OLS report MODELU 2 z programu GeoDa
Příloha 70	Průměrné délky dob nepod. trestů odnětí svobody dle vl. klasifikace
Příloha 71	Mapová animace čistého indexu kriminality
Příloha 72	Mapová animace hrubého indexu kriminality
Příloha 73	Statistika typů trestných činů



Příloha 74 Statistická data trestných činů

**Volné přílohy**

Příloha 82 Poster

**Příloha 75: Srovnání regresních koeficientů obou scénářů**

	KOEFCIENT $\beta$					
	MODEL 1			MODEL 2		
	OLS	SLM	SEM	OLS	SLM	SEM
Index stáří	0,04	0,04	0,04	0,04	0,04	0,04
Zalidnění	5 299,11	3 675,71	-1 263,2	16,71	23,78	8,92
Potratovost	0,81	0,75	0,77	-0,0002	-0,0007	-0,0006
Porodnost	0,06	0,11	0,13	0,001	0,001	0,001
Přirozený přírůstek	0,06	0,03	0,03	-0,0007	-0,0006	-0,0007
Migrační saldo	-0,02	-0,02	-0,01	0,0003	0,0003	0,0003
Podíl obyv. bez vzdělání	-2,8	-2,68	-2,63	-0,009	-0,009	-0,009
Podíl obyv. – ZŠ	-0,36	-0,43	-0,41	-0,006	-0,006	-0,007
Podíl obyv. – vyuč,	-2,51	-2,28	-2,38	-0,007	-0,007	-0,007
Podíl obyv. – SŠ + návstava	-0,68	-0,53	-0,55	-0,004	-0,004	-0,004
Podíl obyv. – VOŠ	-4,67	-4,33	-4,5	-0,01	-0,01	-0,01
Podíl obyv. – VS	-1,3	-1,37	-1,31	-0,005	-0,006	-0,006
Podíl romské národnosti	1,13	0,99	1,06	0,008	0,006	0,007
Podíl obyv. v exekuci	4,32	3,86	3,99	0,013	0,01	0,01
Podíl obyv. – PNB	7,62	7,64	7,81	0,01	0,01	0,01
Podíl obyv. – UOZ	-0,08	-0,17	-0,13	0,003	0,002	0,003
Podíl obyv. v insolvenční	-3,56	-3,12	-2,98	-0,006	-0,004	-0,003
Podíl obyv. předčasného odchodu ze ZŠ	0,21	0,15	0,11	0,001	0,001	0,001
Podíl obyv. s náb. vyzn.	-1,53	-1,4	-1,54	-0,004	-0,003	-0,004
Podíl obyv. bez náb. vyzn.	-0,98	-1,10	-1,02	-0,001	-0,001	-0,001
Podíl svobodných	3,58	3,61	3,61	0,003	0,003	0,003
Podíl sezdáných	2,96	2,91	2,91	-6,57	-0,0005	-0,0008
Podíl rozvedených	5,98	5,83	5,81	0,014	0,01	0,01
Podíl ovdovělých	3,04	3,14	3,07	0,007	0,007	0,006
Volební účast	0,69	0,65	0,63	0,006	0,005	0,006
R <sup>2</sup>	0,17	0,19	0,18	0,15	0,15	0,18
F-statistic	54	×	×	37	37	×
Log likelihood	-38 230	-38 181	38 195	-953	-953	-888
AIC	76 509	76 414	76 441	1 957	1 957	1 828
Schwartz kritérium	76 677	76 589	76 610	2 128	2 128	1 999
Jarque-Bera	1 245 076	×	×	36	×	×
Breusch-Pagan test	11 636	12 160	12 000	148	148	154
Koenker-Bassett test	331	×	×	124	123	×
Lambda ( $\lambda$ )	×	×	0,17	×	×	0,23

## Příloha 76: Požité socioekonomických indikátorů

Demografické	Charakteristika	Ekonomické	Charakteristika
Hustota zalidnění	Poměr počtu trvale žijících obyvatel a rozlohy obce (km <sup>2</sup> )	Podíl obyv. v exekuci	% podíl osob v exekuci (přepočten na obyvatelstvo 15+ let)
Index stáří	Poměr počtu obyvatel ve věku 65 a více let k počtu obyvatel ve věku 0–14 let	Podíl obyv. v insolvenci	% podíl osob v osobním bankrotu (k 31. 12. 2020) (přepočten na obyvatelstvo 18+ let)
Hrubá míra potratovosti	Počet potratů (umělých přerušeni těhotenství, samovolných potratů) na 1000 obyvatel středního stavu	Podíl příjemců příspěvků na bydlení (PnB)	% podíl příjemců PnB v průměrném měsíci r. 2021 (přepočten na obyvatelstvo 15+ let)
Hrubá míra porodnosti	Počet živě narozených dětí, připadající na 1000 obyvatel středního stavu	Podíl uchazečů o zaměstnání (UoZ)	% podíl uchazečů o zaměstnání (prosinec 2021) (přepočten na obyvatelstvo 15-64 let)
Hrubá míra přirozeného přírůstku	Rozdíl mezi počtem živě narozených dětí a počtem zemřelých osob na 1000 obyvatel		
Hrubá míra migrační saldo	Rozdíl mezi počtem přistěhovalých a vystěhovalých na 100 obyvatel		
Podíl obyv. s náb. vyznáním	% podíl obyvatel s náboženským vyznáním		
Podíl obyv. bez náb. vyznání	% podíl obyvatel bez náboženského vyznání		
Podíl Romů	% podíl obyvatel – česká výhradně, česká v kombinaci (2021)		
Podíl předčasných odchodů ze ZŠ	% podíl předčasných odchodů ze ZŠ – běžné třídy (školní rok 2020/21)		
Podíl obyv. bez vzdělání	% podíl obyvatel ve věku 15 a více let – bez vzdělání		
Podíl obyv. – ZŠ	% podíl obyvatel ve věku 15 a více let		
Podíl obyv. – SŠ vč. vyučení	% podíl obyvatel ve věku 15 a více let – střední vč. vyučení		
Podíl obyv. – úplné střední, vč. nástavbového studia	% podíl obyvatel ve věku 15 a více let – úplné střední, vč. nástavbového studia		
Podíl obyv. - vyšší odbor. vzdělání	% podíl obyvatel ve věku 15 a více let – vyšší odbor. vzdělání		
Podíl obyv. - VŠ	% podíl obyvatel ve věku 15 a více let – vysokoškolské		
Podíl rozvedených	% podíl obyvatel (s obvyklým pobytem) ve věku 15 a více let		

Podíl svobodných	% podíl svobodných osob (přepočet na obyvatelstvo 18+ let)
Podíl sezdaných	% podíl rozvedených osob (přepočet na obyvatelstvo 18+ let)
Procentuální volební účasť	Poměr odevzdaných hlasovacích lístků a voličů

---

## Příloha 77: Základní popisné statistiky nezávisle proměnných

Indikátor	Min	Max	Rozsah	Medián	SD	Var. koeficient	Šikmost	Špičatost
Hustota zalidnění	0	23	23	1,21	0,75	0,56	10,6	222,85
Index stáří	1,16	0,002	0,002	5,4	0,00	1,5	6,13	62,64
Hrubá míra potratovosti	0	66,66	66,66	1,45	3,10	1,44	4,94	62,48
Hrubá míra porodnosti	0	64,51	64,51	10,27	6,48	0,59	1,37	8,83
Hrubá míra přirozeného přírůstku	-125	64,51	189,51	-1,9	10,52	-4,34	-0,72	10,4
Hrubá míra migrační saldo	-129	200	329,03	6,57	24,30	2,63	1,002	9,05
Podíl obyv. bez vzdělání	0	37,67	37,67	0,42	1,27	1,96	12,94	269,93
Podíl obyv. – ZŠ	0	44	44	13,21	3,77	0,27	1,1	6,78
Podíl obyv. – SŠ vč. vyučení	9,8	66,66	56,86	38,78	6,55	0,17	-0,31	3,91
Podíl obyv. – úplné střední, vč. nástavbového studia	1,74	61,03	59,28	29,29	5,01	0,17	-0,32	4,21
Podíl obyv. - vyšší odbor. vzdělání	0	19,09	19,09	1,31	0,91	0,65	2,17	28,1
Podíl obyv. - VŠ	0	40,90	40,9	10,91	5,23	0,44	1,17	5,51
Podíl Romů	0	10,50	10,5	0	0,38	4,25	12,84	265,22
Podíl obyv. v exekuci	0	51,69	51,69	4,54	4,34	0,76	2,88	18,65
Podíl příjemců příspěvků na bydlení (PnB)	0	10,39	10,39	0,51	0,80	1,14	3,05	20,93
Podíl uchazečů o zaměstnání (UoZ)	0	21,75	21,75	3,06	2,23	0,64	1,83	10,08
Podíl obyv. v insolvenční	0	13,79	13,79	1,01	1,02	0,85	1,9	11,73
Podíl předčasných odchodů ze ZŠ	0	73,33	73,33	0	3,13	4,19	8,03	105,3
Podíl obyv. s náb. vyznáním	1,36	289	287,63	20,58	13,60	0,57	2,18	27,01
Podíl obyv. bez náb. vyznání	1,61	417	415,38	45,38	14,93	0,33	2,59	67,58
Podíl svobodných	12,9	539	526,09	40,36	9,52	0,23	29,14	1327,37
Podíl sezdaných	10,26	91	80,73	41,66	4,96	0,11	-0,1	6,82
Podíl rozvedených	0	128	128	9,54	3,51	0,36	7,87	227,49
Procentuální volební účast	26,57	104	77,42	69,04	7,58	0,11	-0,3	4,4

**Příloha 78: Srovnání regresních koeficientů SLM a SEM obou scénářů**

	<b>KOEFICIENT <math>\beta</math></b>			
	<b>MODEL 1</b>		<b>MODEL 2</b>	
	<b>SLM</b>	<b>SEM</b>	<b>SLM</b>	<b>SEM</b>
Index stáří	0,04	0,04	0,04	0,04
Zalidnění	3 675,71	-1 263,2	23,78	8,92
Potratovost	0,75	0,77	-	-0,0006
Porodnost	0,11	0,13	0,001	0,001
Přirozený přírůstek	0,03	0,03	-	-0,0007
Migrační saldo	-0,02	-0,01	0,0003	0,0003
Podíl obyv. bez vzdělání	-2,68	-2,63	-0,009	-0,009
Podíl obyv. – ZŠ	-0,43	-0,41	-0,006	-0,007
Podíl obyv. – vyuč,	-2,28	-2,38	-0,007	-0,007
Podíl obyv. – SŠ + nástavba	-0,53	-0,55	-0,004	-0,004
Podíl obyv. – VOŠ	-4,33	-4,5	-0,01	-0,01
Podíl obyv. – VS	-1,37	-1,31	-0,006	-0,006
Podíl romské národnosti	0,99	1,06	0,006	0,007
Podíl obyv. v exekuci	3,86	3,99	0,01	0,01
Podíl obyv. – PNB	7,64	7,81	0,01	0,01
Podíl obyv. – UOZ	-0,17	-0,13	0,002	0,003
Podíl obyv. v insolvenční Podíl obyv. předčasného odchodu ze ZŠ	-3,12	-2,98	-0,004	-0,003
Podíl obyv. s náb. vzn.	0,15	0,11	0,001	0,001
Podíl obyv. bez náb. vzn.	-1,4	-1,54	-0,003	-0,004
Podíl svobodných	-1,10	-1,02	-0,001	-0,001
Podíl sezdaných	3,61	3,61	0,003	0,003
Podíl rozvedených	2,91	2,91	-	-0,0008
Podíl ovdovělých	5,83	5,81	0,0005	0,01
Volební účast	3,14	3,07	0,007	0,006
R <sup>2</sup>	0,65	0,63	0,005	0,006
F-statistic	0,19	0,18	0,15	0,18
Log likelihood	×	×	37	×
AIC	-38 181	38 195	-953	-888
Schwartz kritérium	76 414	76 441	1 957	1 828
Jarque-Bera	76 589	76 610	2 128	1 999
Breusch-Pagan test	×	×	×	×
Koenker-Bassett test	12 160	12 000	148	154
Lambda ( $\lambda$ )	×	×	123	×
	×	0,17	×	0,23

**Příloha 79: Srovnání regresních koeficientů OLS obou scénářů**

	KOEFIČIENT $\beta$	
	MODEL 1	MODEL 2
Index stáří	0,04	0,04
Zalidnění	5 299,11	16,71
Potratovost	0,81	-0,0002
Porodnost	0,06	0,001
Přirozený přírůstek	0,06	-0,0007
Migrační saldo	-0,02	0,0003
Podíl obyv. bez vzdělání	-2,8	-0,009
Podíl obyv. – ZŠ	-0,36	-0,006
Podíl obyv. – vyuč,	-2,51	-0,007
Podíl obyv. – SŠ + nástavba	-0,68	-0,004
Podíl obyv. – VOŠ	-4,67	-0,01
Podíl obyv. – VS	-1,3	-0,005
Podíl romské národnosti	1,13	0,008
Podíl obyv. v exekuci	4,32	0,013
Podíl obyv. – PNB	7,62	0,01
Podíl obyv. – UOZ	-0,08	0,003
Podíl obyv. v insolvenční	-3,56	-0,006
Podíl obyv. předčasného odchodu ze ZŠ	0,21	0,001
Podíl obyv. s náb. vyzn.	-1,53	-0,004
Podíl obyv. bez náb. vyzn.	-0,98	-0,001
Podíl svobodných	3,58	0,003
Podíl sezdaných	2,96	-6,57
Podíl rozvedených	5,98	0,014
Podíl ovdovělých	3,04	0,007
Volební účast	0,69	0,006
R <sup>2</sup>	0,17	0,15
F-statistic	54	37
Log likelihood	-38 230	-953
AIC	76 509	1 957
Schwartz kritérium	76 677	2 128
Jarque-Bera	1 245 076	36
Breusch-Pagan test	11 636	148
Koenker-Bassett test	331	124
Lambda ( $\lambda$ )	×	×

**Příloha 80: Srovnání regresních koeficientů MODELU 2 po logaritmické a exponenciální transformaci**

	KOEFCIENT $\beta$					
	MODEL 2 (Log. transformace)			MODEL 2 (Zpětná exp. transformace)		
	OLS	SLM	SEM	OLS	SLM	SEM
Index stáří	0,04	0,04	0,04	0,04	0,04	0,04
Zalidnění	16,71	16,71	16,71	18074 270,12	212580 18450	7479
Potratovost	-0,0002	-0,0002	-0,0002	-0,0002	-0,0007	-0,0006
Porodnost	0,001	0,001	0,001	0,001	0,001	0,001
Přirozený přírůstek	-0,0007	-0,0007	-0,0007	-0,0007	-0,0006	-0,0007
Migrační saldo	0,0003	0,0003	0,0003	0,0003	0,0003	0,0003
Podíl obyv. bez vzdělání	-0,009	-0,009	-0,009	-0,009	-0,009	-0,009
Podíl obyv. – ZŠ	-0,006	-0,006	-0,006	-0,006	-0,006	-0,007
Podíl obyv. – vyuč.,	-0,007	-0,007	-0,007	-0,007	-0,007	-0,007
Podíl obyv. – SŠ + nástavba	-0,004	-0,004	-0,004	-0,004	-0,004	-0,004
Podíl obyv. – VOŠ	-0,01	-0,01	-0,01	-0,01	-0,01	-0,01
Podíl obyv. – VS	-0,005	-0,005	-0,005	-0,002	-0,006	-0,005
Podíl romské národnosti	0,008	0,008	0,008	0,008	0,006	0,007
Podíl obyv. v exekuci	0,013	0,013	0,013	0,01	0,01	0,01
Podíl obyv. – PNB	0,01	0,01	0,01	0,01	0,01	0,01
Podíl obyv. – UOZ	0,003	0,003	0,003	0,003	0,002	0,003
Podíl obyv. v insolvenční	-0,006	-0,006	-0,006	-0,006	-0,004	-0,002
Podíl obyv. předčasného odchodu ze ZŠ	0,001	0,001	0,001	0,001	0,001	0,001
Podíl obyv. s náb. vyzn.	-0,004	-0,004	-0,004	-0,004	-0,003	-0,003
Podíl obyv. bez náb. vyzn.	-0,001	-0,001	-0,001	-0,0009	-0,0009	-0,0009
Podíl svobodných	0,003	0,003	0,003	0,003	0,003	0,003
Podíl sezdaných	-6,57	-6,57	-6,57	-0,99	-0,0005	-0,0007
Podíl rozvedených	0,014	0,014	0,014	0,01	0,02	0,01
Podíl ovdovělých	0,007	0,007	0,007	0,007	0,007	0,006
Volební účast	0,006	0,006	0,006	0,006	0,005	0,006



**Příloha 81: Rezidua regresního modelu pro MODEL 1 (nahore) a MODEL 2 (dole)**

