

A Contribution to Measuring and Visualizing Regional Disparities in the Czech Republic

¹ Marek SOVA and ² Branimir VUKOSAV

¹ Palacký University of Olomouc, Faculty of Science, Department of Geography, 17. listopadu 12, 779 00 Olomouc, Czech Republic (mareksova1@gmail.com)

² University of Zadar, Department of Geography, Dr. Franje Tuđmana 24i, 23000 Zadar, Croatia (bvukosav@gmail.com)

Abstract. The identification and analysis of regional disparities are increasingly important issues for a better understanding of regions and their socioeconomic development, and the subsequent application of regional policies. The objective assessment of regional disparities is an important step in directing regional policies by individual countries and supranational institutions such as the European Union.

The paper deals with selected indicators of regional socio-economic disparities in the territory of the Czech Republic that were observed, visualized and evaluated to contribute to measuring regional disparities. The indicators were divided into three categories - demographic, economic and infrastructural - and defined and analyzed at the level of the Czech NUTS3 regions (counties), with the data organized as a geodatabase within ArcGIS software. A synthetic index was used to define and analyze the disparities within the three categories. The values for the indicators, along with the results of the regional evaluation, were presented cartographically as a series of cartograms, and the analysis and cartographic visualizations were used to reach conclusions about existing disparities.

Keywords: regional disparities, Czech Republic, indicators, synthetic index, NUTS3 regions, cartogram

1 Introduction

Regarding the overall development of certain areas, regions and countries, regional disparities have lately been among the most discussed and researched issues. They are broadly understood as deviations in socio-geographic, economic, social and environmental developments within a particular spatial/administrative division, and usually manifest as different conditions of life and unequal economic and developmental potentials (Vorauer 2007). In other words, a regional disparity may be defined as a divergence or inequality of characters, phenomena or processes with a specific territorial allocation, occurring in at least two entities of the territorial structure (Kutscherauer et al. 2010).

The importance and relevance of understanding and analyzing regional disparities arises from a holistic view of developmental problems, which sets aside the uniform and single approach to problems and implements a multidimensional one, with the goal of eliminating or mitigating regional divergence. In other words, approaching the geographic and economic issues of an area from the angle of disparities implies widening research and

viewing the set of factors as inter-related. Generally, such an approach demands various, often multidisciplinary methods, to detect and measure differences in features and trends in a region or area, and consequently to apply the results in creating future regional policies. It is, however, important to note that there is no comprehensive view on regional disparities, and each approach is likely to emphasize different dimensions and/or sets of issues (Gajdová 2016).

In researching and measuring regional disparities, several issues must be decided – choosing the relevant features, identifying the spatial units (municipalities, regions, countries, etc.) connected with those features and, finally, comparing and examining them within a defined framework of indicators. Such an approach may focus on the positive and negative roles of certain features and trends, thus producing two sets of results. More precisely, the researcher gains an insight into a spatial unit's strengths and advantages on the one hand, and its weaknesses and vulnerabilities on the other, usually in relation to general trends (national, regional). This can provide a useful starting-point in policy-making, especially through identification,

Prilog mjerenju i vizualiziranju regionalnih dispariteta u Češkoj Republici

¹Marek SOVA i ²Branimir VUKOSAV

¹ Palacký University of Olomouc, Faculty of Science, Department of Geography, 17. listopadu 12, 779 00 Olomouc, Czech Republic (mareksova1@gmail.com)

² Sveučilište u Zadru, Odjel za geografiju, Dr. Franje Tuđmana 24i, 23000 Zadar, Hrvatska (bvukosav@gmail.com)

Sažetak. Prepoznavanje i analiza regionalnih dispariteta sve su prisutnija tema u razumijevanju regija i njihova socioekonomskog razvoja, kao i posljedičnoj primjeni regionalnih politika. Objektivna procjena regionalnih dispariteta postala je, stoga, važan korak u usmjeravanju regionalnih politika i od strane pojedinih država i od strane supranacionalnih institucija poput Europske unije.

U radu se obrađuju odabrani pokazatelji regionalnih dispariteta na teritoriju Češke Republike, te se razmatraju, vizualiziraju i evaluiraju s ciljem doprinosa mjerenju regionalnih dispariteta. Pokazatelji su podijeljeni u tri kategorije – demografske, ekonomske i infrastrukturne – te su analizirani na razini čeških NUTS 3 regija (pokrajina) i organizirani u bazu prostornih podataka u okruženju softwera ArcGIS. Upotrebom sintetičkog indeksa definiraju se i analiziraju dispariteti unutar spomenutih triju kategorija. Vrijednosti pokazatelja i rezultati evaluacije regija kartografski su prikazani u vidu niza kartograma, te se na temelju analize i kartografskih vizualizacija donose zaključci o postojećim disparitetima.

Ključne riječi: regionalni dispariteti, Češka Republika, pokazatelji, sintetički indeks, NUTS3 regije, kartogram

1. Uvod

U okvirima diskursa o razvoju pojedinih područja, regija i država, problematika regionalnih dispariteta u posljednje je vrijeme među temama o kojima se najviše raspravlja ili ih se istražuje. U najširem smislu shvaćeni kao devijacije u sociogeografskom, ekonomskom, društvenom i okolišnom razvoju u okvirima neke prostorno-administrativne podjele, regionalni dispariteti najčešće se manifestiraju kao razlike u uvjetima života, te ekonomskim i razvojnim potencijalima (Vorauer, 2007). Drugim riječima, regionalni disparitet može biti definiran kao divergencija ili nejednakost fenomena i procesa s posebnom teritorijalnom alokacijom, a koja se pojavljuje u barem dva entiteta teritorijalnog ustroja (Kutscherauer et al, 2010).

Važnost i relevantnost razumijevanja i analiziranja regionalnih dispariteta proizlazi iz holističkog pogleda na razvojnu problematiku, uz napuštanje uniformnih i pojedinačnih pristupa problemima te implementiranje onih multidimenzionalnih, s ciljem eliminacije ili smanjivanja regionalne divergencije. Drugim riječima, pristupanje ekonomsko-geografskim problemima nekog

područja sa gledišta dispariteta implicira proširenje istraživanja i sagledavanje šireg skupa čimbenika kao međusobno isprepletenih. Općenito, takav pristup zahijeva različite metode, ponekad multidisciplinarne, kako bi se detektirale i izmjerile razlike u značajkama i trendovima u nekoj regiji ili području, te posljedično primijenili rezultati u kreiranju regionalnih politika. No, pritom je važno naglasiti da ne postoji sveobuhvatni i jedinstveni pogled na regionalne disparitete, te će svaki pristup u većini slučajeva naglašavati različite dimenzije i/ili skupove problema (Gajdová, 2016).

Postoji nekoliko stvari o kojima treba voditi računa prilikom istraživanja i mjerenja regionalnih dispariteta – odabir relevantnih značajki, identificiranje vezanih prostornih jedinica (općine, regije, države, itd.) koje posjeduju te značajke, te u konačnici njihova usporedba i pregled na temelju definiranog okvira pokazatelja. Takav pristup može biti fokusiran na pozitivne i negativne uloge pojedinih značajki i trendova, te proizvesti dva seta rezultata. Preciznije govoreći, istraživač s jedne strane dobija uvid u prednosti i snage neke prostorne jedinice, a s druge strane u njene slabosti, obično u odnosu na neke opće trendove (nacionalne, regionalne).

decision, motivation and operation (Kurtscherauer et al. 2010).

It is the aim of this paper to use the above approach to gain a basic insight into the range of disparities in the Czech counties (NUTS 3 regions), within the framework of several aspects falling into three categories of indicators – demographic (ageing index, proportion of graduates under 25), economic (GDP per capita, unemployment rate) and infrastructural (road density and proportion of electrified tracks). The main idea was to approach the analysis at a basic level, in order to compare a set of indicators from several categories, to acquire a general picture about the differences in the selected regions, and to provide a starting-point for further disparity research and measurements. NUTS 3 regions, i.e. the counties (Figure 1) were chosen as a territorial framework, since at this level it is more convenient to detect and analyze the overall picture of existing disparities. The main hypothesis of the paper is that regional disparities in the Czech Republic tend to increase concentrically with distance from the capital of Prague towards the periphery, as Prague is the main national and supranational centre of socioeconomic activities.

The paper is divided into two sections. The first is introductory and provides general data about the Czech Republic's administrative organization, with a description of the approach and previous research. The second section focuses on defining and measuring regional disparities within this administrative framework. Several indicators were selected that fall into the categories of the three sociogeographic aspects, and were measured using a synthetic index based on a point system. The results obtained are discussed in the conclusion.

2 Previous Research

Many authors have dealt with the issue of regional disparities at various levels and within different disciplines. At the European level, a number of papers and books discuss disparities in European countries and regions, by defining and analyzing disparities and convergence processes. For example, Amendola et al. (2004) define regional disparities in Europe, Ezcurra and Rapún (2006) explore the relationship between regional inequality and economic development in 14 Western European countries from 1980 to 2002, while Vanhove and Klaassen (1987) and more recently Armstrong (2002) discuss European regional policies. There are also a number of works on regional disparities in certain countries, Europe, or other continents, such as those by Ohlan (2012), Fan et al. (2009), Pejnović (2004), Kostel (2010), Magaš (2003) and others.

When focusing on the Czech Republic, several papers and studies stand out. The theoretical basis and definitions regarding the concept of regional disparities is presented in the studies by Kutscherauer et al (2010), and Huček (2007). Among other authors, Horáková (2012) compares the inequalities of the NUTS 2 regions in France by using a synthetic indicator, Vlasák (2013) discusses regional disparities in the former Yugoslavia, and there are also works by Sucháček (2007), Tuleja (2010), Svatošová (2012), Mrosek (2013) and others.

3 Methodology

The regional disparities or inequalities assessed in the paper were found in the 14 counties of the Czech Republic, using data from the 2011 and 2001 population censuses (URL 1, URL 2), the annual data of the Czech Statistical Office (URL 3), EUROSTAT (URL 4), and data from the Ministry of Labour and Social Affairs (URL 5). All data are from 2011–2012.

Indicators of regional disparities were divided into three sets – demographic, economic and infrastructural. The chosen demographic indicators were the ageing index and educational level of the population. The selected economic indicators were the unemployment rate and Gross Domestic Product (GDP) per capita, while the infrastructural indicators focused on roads and railways. The span of the data for the purposes of calculation was from 2011 to 2012, because it was most completely available. Data from other recent years was periodically used solely for the purpose of comparison and/or illustration of trends. Both the discussion and comparison of the selected indicators, and the measurement of disparities based on the available statistical data, were supported by creating a geodatabase, and visualizing cartographically the indicators and results of the final assessment of regions through a series of cartograms and carto-diagrams within ArcGIS software. Mapping of differences between the counties regarding the selected indicators, and the situation as perceived after the methodological procedure was conducted, provided an additional dimension to envisaging regional disparities and identifying their territorial patterns.

The main method used in measuring disparities is the point method (Jílek 2005, Svatošová 2012), which uses a synthetic index to synthesize and evaluate regional disparities and detect the positive and negative roles of each indicator. Six important aspects of regions were valorised and 1,000 points given to the spatial unit with the highest indicator value. The other units were then given points according to the base index, where the base was the highest value. That meant that, with six indicators

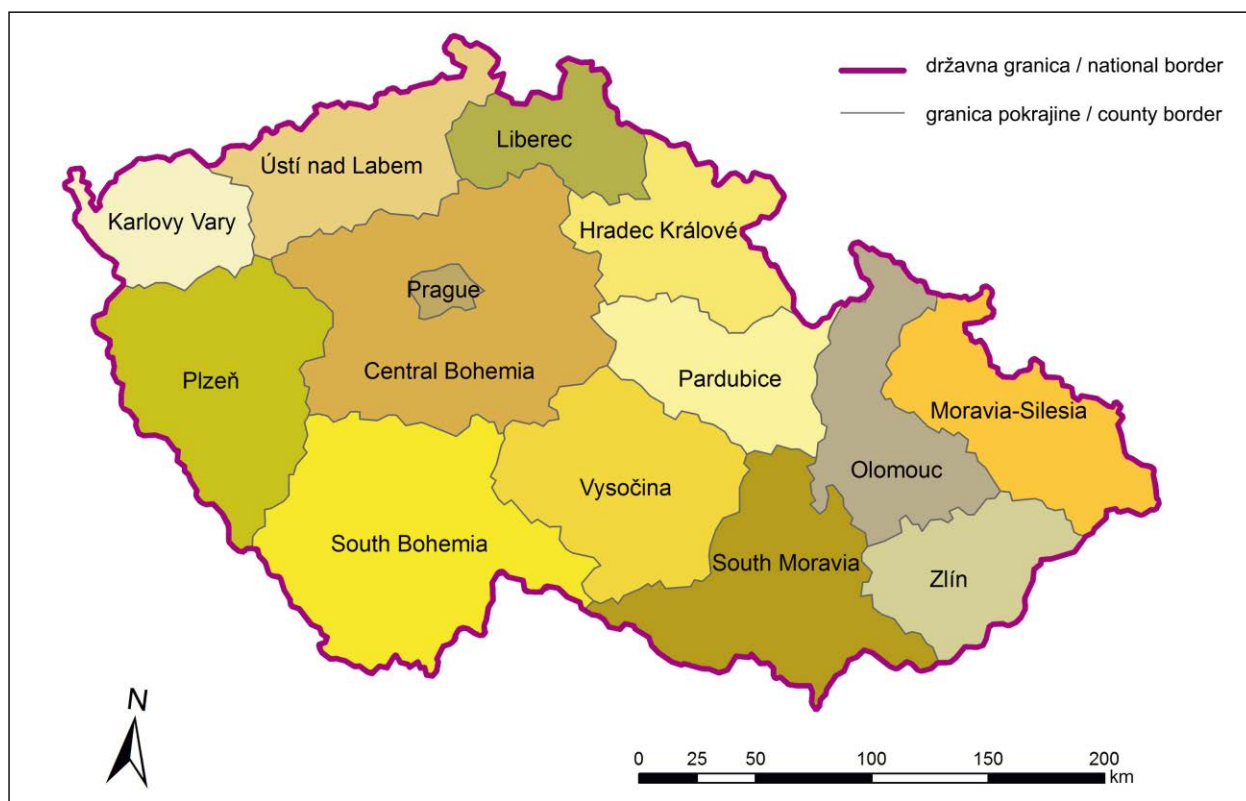


Fig. 1 Counties (NUTS 3 regions) of the Czech Republic

Slika 1. Pokrajine (NUTS 3 regije) Češke Republike

Time je moguće definirati korisnu polazišnu točku u kreiranju politika, osobito kroz prepoznavanje, odlučivanje, motivaciju i djelovanje (Kurtschauer et al, 2010).

Cilj je ovoga rada primijeniti gore spomenuti pristup kako bi se zadobio osnovni uvid u razmjere dispariteta među češkim pokrajinama (NUTS 3 regijama) unutar okvira definiranog s nekoliko aspekata razdijeljenih u tri kategorije pokazatelja – demografsku (indeks starenja, udio osoba sa završenim fakultetom mladih od 25 godina), ekonomsku (BDP po glavi stanovnika, stopa nezaposlenosti) i infrastrukturnu (gustoća cestovnih prometnica, te udio elektrificiranih pruga u ukupnoj duljini željezničkih putova). Temeljna je ideja pristupiti analizi na najosnovnijoj razini, te usporediti skup pokazatelja u nekoliko kategorija s ciljem dobijanja opće slike o glavnim razlikama među regijama, te osnove za daljnje istraživanje i mjerenje dispariteta. Kao teritorijalni okvir istraživanja odabrane su NUTS 3 regije, odnosno pokrajine (slika 1) obzirom da je na ovoj razini upravno-teritorijalnog ustroja prikladnije detektirati i analizirati opće stanje postojećih dispariteta. Temeljna je hipoteza rada da regionalni dispariteti u Češkoj Republici imaju tendenciju koncentričnog porasta s udaljenošću od glavnoga grada Praga prema periferiji zbog uloge Praga kao glavnog nacionalnog i supranacionalnog središta socioekonomskih aktivnosti.

Rad je podijeljen u dvije cjeline. Prva cjelina je uvodna te, uz opise metodološkog pristupa i prethodnih istraživanja, uključuje i opće podatke o upravnom ustroju Češke Republike. U drugoj je cjelini fokus na definiranju i mjerenju regionalnih dispariteta u okvirima spomenutoga upravnog ustroja. Odabrano je nekoliko pokazatelja koji ulaze u kategorije triju sociogeografskih aspekata, te su izmjereni uz pomoć sintetičkog indeksa baziranog na sustavu bodovanja. O rezultatima se raspravlja u zaključku.

2. Prethodna istraživanja

Brojni su se autori bavili problematikom regionalnih dispariteta na različitim razinama i u okvirima različitih znanstvenih disciplina. Na europskoj razini, čitav niz radova i knjiga opisuje disparitete među europskim zemljama, kao i regijama, s pristupima definiranja i analiziranja dispariteta te procesa konvergencije. Primjerice, Amendola i dr. (2004) definiraju regionalne disparitete u Europi; Ezcurra i Rapún (2006) proučavaju vezu između regionalnih nejednakosti i ekonomskog razvoja u 14 zapadnoeuropskih zemalja u razdoblju 1980.-2002.; Vanhove i Klaassen (1987), te u novije vrijeme Armstrong (2002) razmatraju europske regionalne politike. Postoji i veći broj radova vezanih uz problematiku

measured, the theoretical maximum was 6,000 points. Next, the regions were categorized in five groups: very unfavourable (0–3,700 points), unfavourable (3,701–3,900 points), average (3,901–4,100 points), favourable (4,101–4,200 points) and very favourable (4,201 and over).

4 Administrative Structure of the Czech Republic

The Czech Republic is a landlocked country in Central Europe. Its territory covers the historical lands of Bohemia, Moravia and Silesia. With an area of 78,865 km² and a population of 10,538,275 (Census 2011) it is considered a medium to small European country. The Czech Republic borders with four other countries, and its longest border is with Germany (811 km). Its other neighbours are Poland (762 km of border), Austria (466 km) and Slovakia (252 km). Since 2000, the Czech Republic has been organized in 14 new counties – or more precisely, 13 counties (*kraje*) and one capital city (*hlavní město*) (Figure 1). Before this change, the country had 7 counties divided into 77 districts, and the latter had the most local authority competences. The transfer of competences and authority from districts to counties was gradual and completed at the beginning of 2003, while the old districts have remained recognized statistically, and have retained the seats of the judicial system. The lower levels of administrative organization are the division into 206 municipalities that have received some of the districts' former competences, and 6,252 towns.

After the Czech Republic joined the European Union on 1 May 2004, another aspect of administrative organization was implemented – the Nomenclature of Territorial Units for Statistics (or NUTS) – as a geocode standard for referencing the subdivisions of countries for statistical purposes. The standard is developed and regulated by the EU, and thus applies solely to EU members, as a statistical instrument of EU structural fund delivery mechanisms.

The NUTS-region system is based on existing national administrative subdivisions. However, in countries where the size of the existing subdivisions or population is too small, a second and/or even third level of regions is formed. In the case of the Czech Republic, due to the relatively small size of the population, the whole country is considered a region at the NUTS 1 level. The next level of division is NUTS 2 (the 8 regions (*oblasti*) formed through merging existing counties), while the counties themselves represent the third level (NUTS 3). Below the NUTS levels, there are two LAU (Local Administrative Unit) levels.

5 Demographic, Economic and Infrastructural Disparities

5.1. Indicators of demographic disparities

Ageing index. Population ageing is generally perceived to be a problem of developed countries. Changes in age structure are caused by increases in life expectancy and low fertility levels. The Czech Republic is currently among the European countries that have a very low proportion of children in the population, and the birth-rate is far below 'maintenance level'. One of the statistical tools for measuring ageing within a population is the ageing index; the number of people aged 65 and over per 100 young people under the age of 15. The value of 100 (equal numbers of children under 19 and people over the age of 60) was reached in 2007 (Artlová 2010).

In spite of increasing numbers of children being born, the ageing index has continued to rise, and in 2011 it was 110.47 meaning that there were 110 people aged 65 or more for 100 people aged 0–14. Regarding specific regions, the index is highest in the county of Prague (130.85), followed by Hradec Králové and Plzeň (116.29 and 116.69). Only two counties had higher numbers of children than old people in 2011 – Ústí nad Labem and Central Bohemia (96.87 and 95.79). Disparities in the ageing index were visualized and are shown in Figure 2.

Proportion of university graduates. It is very important for any country to have a high proportion of highly educated people. Higher education brings many benefits to individuals and society overall. Individuals can compete better on the labour market, while society is better educated in general, which makes it more competitive.

Comparison of the data from the 2001 and 2011 censuses (URL 1, URL 2) confirm that the population is becoming increasingly more educated. The overall number of people completing secondary and tertiary education is increasing and, consequently, the number of people with only primary education or incomplete secondary education has decreased. The proportion of secondary-level educated individuals in the population aged over 15 in 2001 was 9.01 % and in 2011 it was 13.16 %. In 2011, 46.1 % individuals over the age of 15 completed secondary or tertiary education.

Regarding the distribution of university graduates in the counties, the total number of university graduates in each county was divided by the number of people older than 25. This is because people in this age group are, or were, at a productive age and have the time and opportunity to graduate from university. The proportion of university graduates in population above 25 is 14.48 %. As shown in Fig. 3, Prague (27.08 %) and South

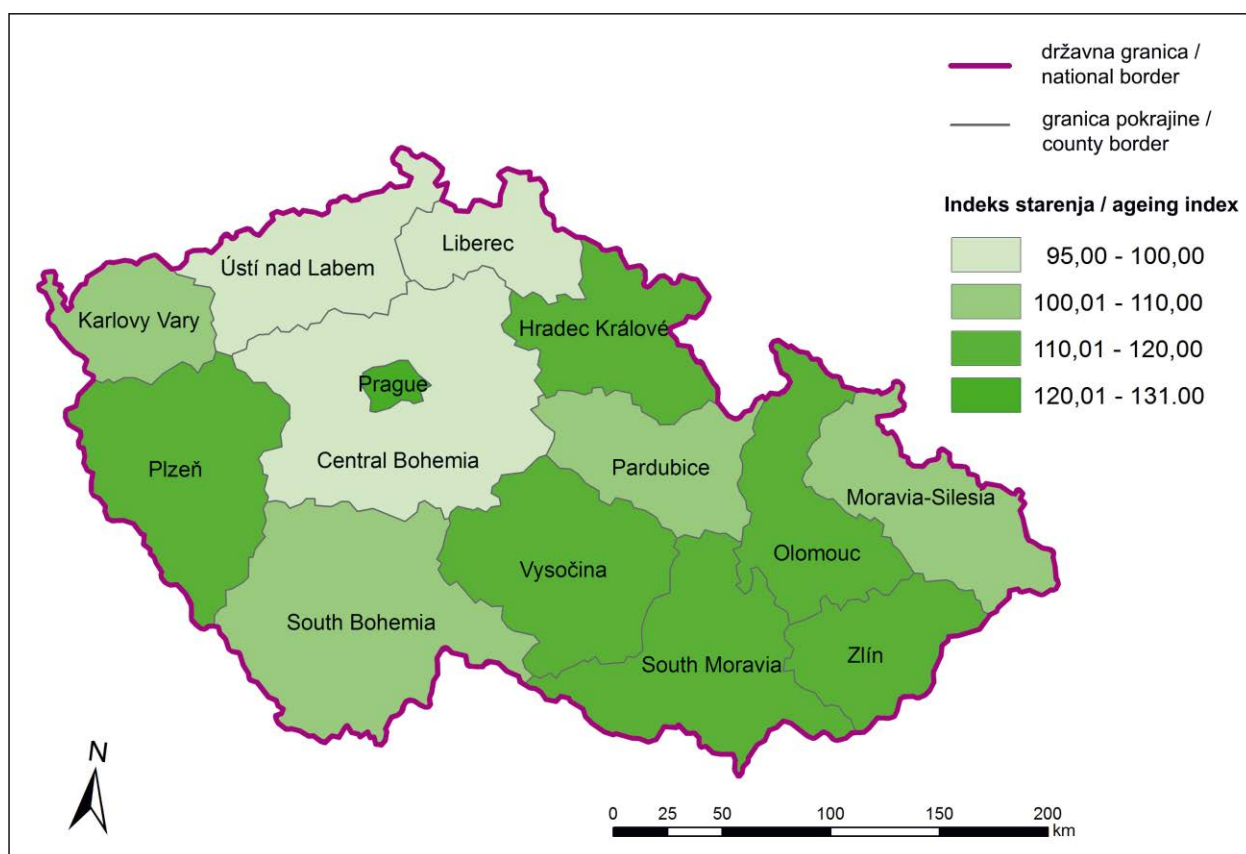


Fig. 2 Ageing index in the Czech Republic's counties (NUTS 3 regions). Source of data: URL 1
Slika 2. Indeks starenja u pokrajinama (NUTS 3 regijama) Češke Republike. Izvor podataka: URL 1

regionalnih dispariteta u pojedinim zemljama Europe i drugih kontinenata, čiji su autori Ohlan (2012), Fan i dr. (2009), Pejnović (2004), Kostel (2010), Magaš (2003) i drugi.

S obzirom na proučavanje problematike u Češkoj Republici, ističe se nekoliko radova i studija. Teorijske osnove i definicije vezane uz koncept regionalnih dispariteta obrađene su u studiji autora Kutscheruera i dr. (2010), kao i u radovima Hučeka (2007). Među drugim autorima su Horáková (2012) koja je usporedila nejednakosti među NUTS 2 regijama Francuske koristeći sintetički indeks, Vlasák (2013) koji razmatra regionalne disparitete u bivšoj Jugoslaviji, te Sucháček (2007), Tuleja (2010), Svatošová (2012), Mrosek (2013) and others.

3. Metodologija

Kao što je već spomenuto, regionalni dispariteti ili nejednakosti koje su u fokusu ovoga rada uspoređuju se među 14 pokrajina Češke Republike koristeći podatke iz popisa stanovništva 2011 i 2001 (URL 1, URL 2), godišnje podatke Češkog Ureda za Statistiku (URL 3), EUROSTAT-a (URL 4), te podatke iz Ministarstva Rada i Socijalnih Pitanja (URL 5). Radi kompatibilnosti, svi podaci su iz razdoblja 2011–2012.

Pokazatelji regionalnih dispariteta podijeljeni su u tri skupine – demografsku, gospodarsku i infrastrukturnu. Odabrani demografski indikatori su indeks starenja i razina obrazovanosti stanovništva; odabrani gospodarski indikatori su stopa nezaposlenosti i brutto domaći proizvod (BDP) po stanovniku, a infrastrukturni ukupna gustoća cesta i udio elektrificiranih željezničkih pruga u ukupnoj duljini po regiji. Korišteni raspon podataka je iz 2011–2012 zbog najveće dostupnosti. Podaci iz drugih, kasnijih razdoblja koriste se tek povremeno, isključivo za potrebe usporedbe ili ilustracije trendova. Razmatranje i usporedba odabranih pokazatelja i mjerenje dispariteta na temelju dostupnih statističkih podataka podržani su izradom baze geopodataka, te kartografskim vizualiziranjem pokazatelja i rezultata krajnje procjene regija nizom kartograma i kartodijagrama u okviru softvera ArcGIS. Kartiranje razlika među pokrajinama u odabranim pokazateljima, te stanja nakon provedenoga metodološkog postupka omogućuje dodatnu dimenziju razmatranja regionalnih dispariteta i prepoznavanja njihovih teritorijalnih uzoraka.

Osnovna metoda koja se u radu koristi za mjerenje dispariteta je tzv. *točkasta metoda* (Jílek et al. 2005, Svatošová 2012) u kojoj se koristi sintetički indeks s ciljem sintetiziranja i evaluiranja regionalnih dispariteta, te

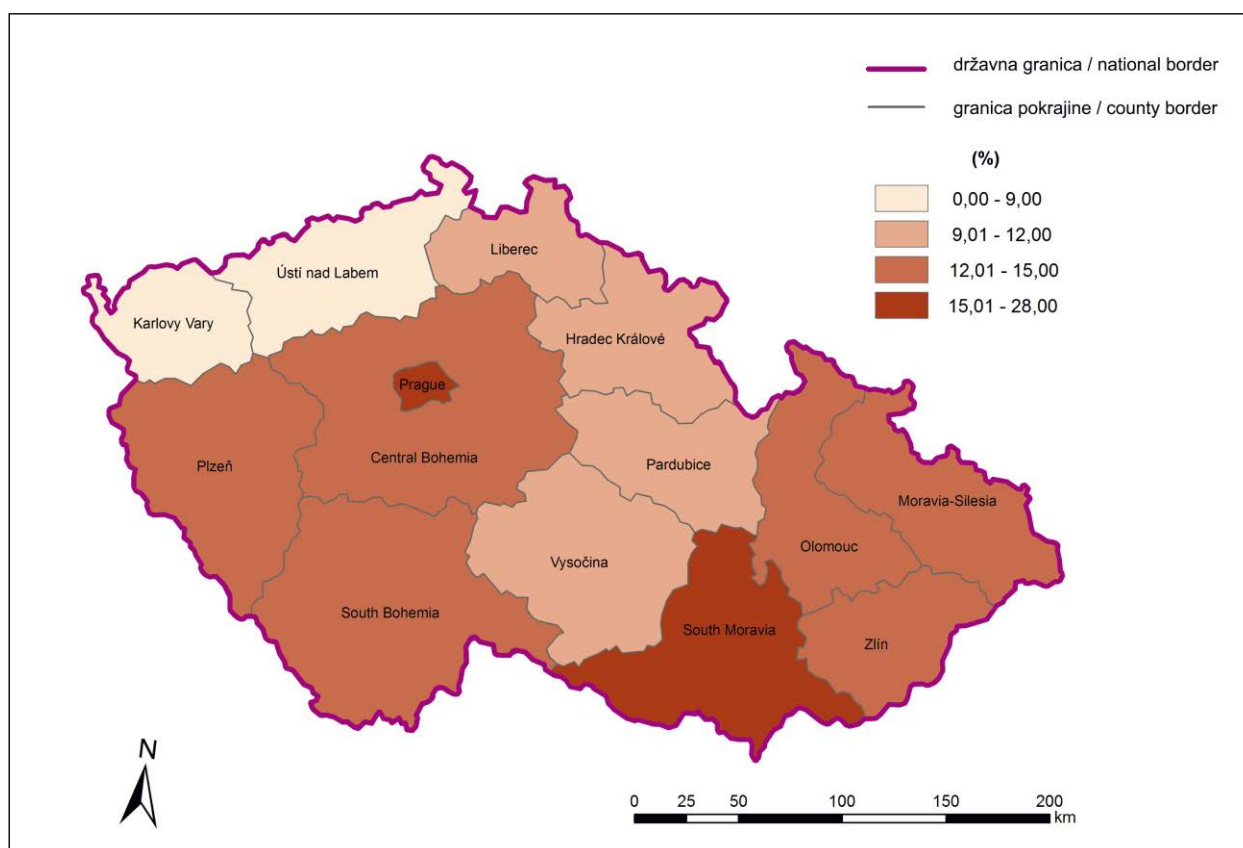


Fig. 3 Proportion of university graduates older than 25 in counties (NUTS 3 regions) in the Czech Republic (in %). Source: URL 1

Slika 3. Udio osoba starijih od 25 sa završenim fakultetom u pokrajinama (NUTS 3 regijama) Češke Republike (u %). Izvor: URL 1

Moravia County (17.05 %) have the highest proportions, followed by Olomouc, Central Bohemia, Moravia-Silesia and Zlín (13.34–13.12 %). The lowest percentage of graduates was calculated in the northwestern counties – Ústí nad Labem (8.83 %) and Karlovy Vary (8.15 %).

5.2. Indicators of economic disparities

Gross domestic product. Gross domestic product (GDP) is the monetary value of all final goods and services produced within a country or region's borders in a specific time period (source: URL 8). It is usually calculated on an annual or quarterly basis, and includes all private and public consumption, government expenditure, investments and exports minus imports within a defined territory. Though GDP per capita is imprecise in regional terms, since it overestimates the economic performance of regions with large urban centres (Kahoun 2007), it is nevertheless widely used as an indicator when evaluating the dynamics and trends of the overall economy and economic performance in an area, including the standard of living. In terms of evaluating the performance of the Czech NUTS3

regions, it is relatively reliable in showing the general economic disparities among them.

Regarding the absolute distribution of GDP per capita in the counties of the Czech Republic (Table 1), the numbers show substantial disparity between Prague and other counties. In 2011, the GDP per capita in Prague was EUR 31,244, while in the other 13 counties it ranged from EUR 10,000 to EUR 14,000, indicating that the economic performance and overall standard of the population in Prague surpassed those in other counties more than twofold. Taking this into account, the average GDP in Czech Republic was EUR 14,815 per capita, which is about EUR 1,000 higher than in South Moravia (EUR 13,871), the county with the second highest GDP per capita after Prague. When comparing these numbers with GDP per capita in 2001 (Fig. 4), it can be seen that it has practically doubled in all counties; however, this implies that the disparities in absolute values between Prague and other counties have also increased.

Unemployment rate. Unemployment is an indicator that usually reflects the actual trends of the economy. The Czech economy has been through several changes

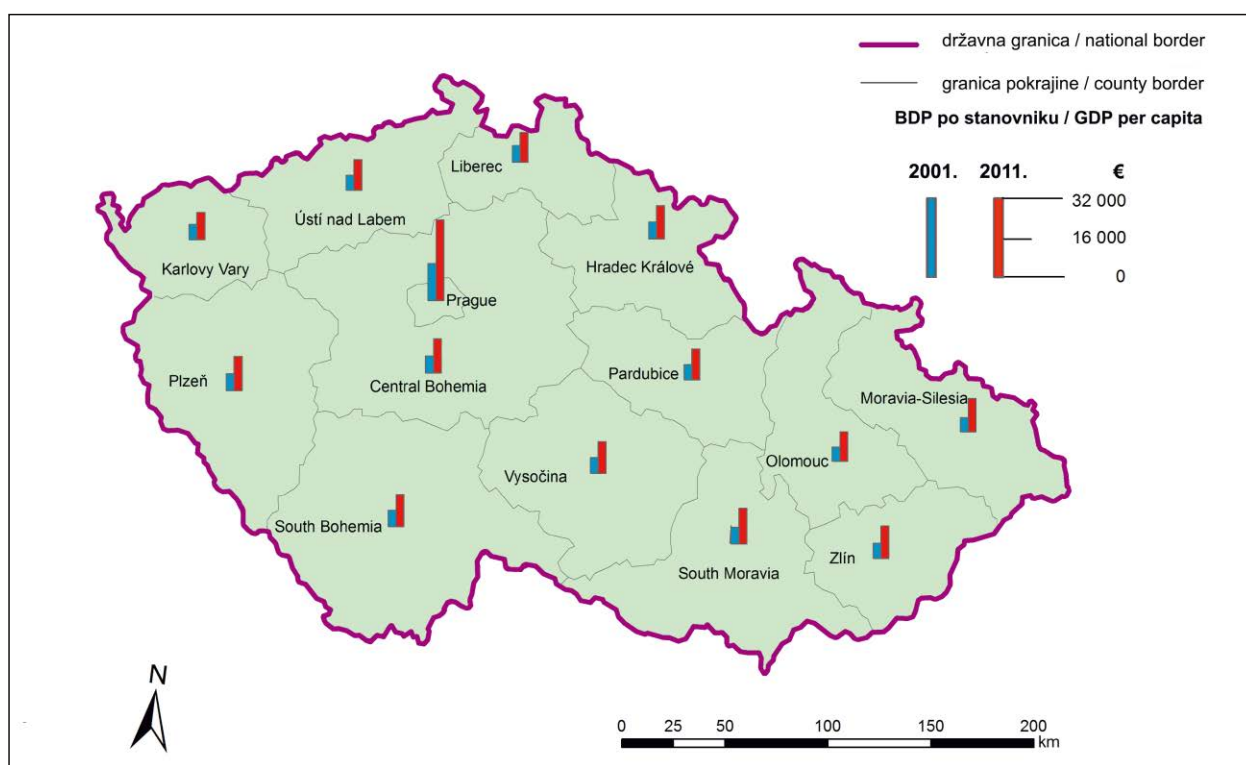


Fig. 4 GDP per capita (in euros) in the Czech Republic counties (NUTS 3 regions) in 2001 and 2011. Source: URL 4

Slika 4. BDP po stanovniku (u eurima) u pokrajinama (NUTS 3 regijama) Češke Republike 2001 i 2011. Izvor: URL 4

detekcije pozitivnih i negativnih uloga svakog pojedinog pokazatelja. Vrednuje se šest važnih aspekata regija, te se 1000 bodova dodjeljuje prostornoj jedinici s najvišom vrijednosti pokazatelja. Ostale jedinice posljedično ostvaruju broj bodova ovisan o baznom indeksu, pri čemu je baza najviša vrijednost. To znači da je teorijski maksimum 6000 bodova. Nakon evaluacije, regije su kategorizirane u pet skupina procjene (stanja): vrlo nepovoljno (0–3700), nepovoljno (3701–3900), srednje povoljno (3901–4100), povoljno (4101–4200) i vrlo povoljno (iznad 4200 bodova).

4. Upravna struktura Češke Republike

Češka Republika je kontinentalna zemlja Srednje Europe. Njen teritorij obuhvaća povijesne zemlje Češke (Bohemia), Moravske i Šleske. S površinom od 78 865 km² i stanovništvom koje broji 10 538 275 (popis 2011) može se smatrati europskom zemljom male ili srednje veličine. Češka Republika graniči sa četiri države, te ima najdulju granicu s Njemačkom (811 km). Ostale zemlje s kojima graniči su Poljska (763 km granice), Austrija (466 km) i Slovačka (252 km). Od godine 2000 Češka Republika sastoji se od 14 pokrajina, odnosno 13 pokrajina (kraje) i glavnog grada (*hlavní město*) (slika 1). Prije ove izmjene država je bila ustrojena u 7 pokrajina i 77

okruža, pri čemu je većina lokalnih ovlasti bila u nadležnosti okruga. Prijenos nadležnosti i vlasti s okruga na pokrajine bio je postupan, te je konačno dovršen početkom 2003 godine, stari okruzi ostali su priznati statistički, te su zadržali funkciju sjedišta pravosudnih tijela. Niža razina upravnog ustroja jest podjela na 206 općina koje su zadobile dio ovlasti okruga, te 6252 naselja.

Nakon pristupanja Češke Europskoj uniji na dan 1. svibnja 2004., još jedan aspekt upravnog ustroja je implementiran – NUTS regije (*Nomenclature of Territorial Units for Statistics*) – kao europski standard za geokodiranje regija za statističke potrebe. Standard je razvijen i reguliran na razini EU, te je primijenjen isključivo na njene članice kao temeljni statistički instrument mehanizama alociranja strukturnih fondova EU.

Sustav NUTS regija utemeljen je na postojećim nacionalnim upravnim potpodjelama. No, u zemljama u kojima prosječna upravna jedinica ima premalen broj stanovnika, formiraju se regije druge ili čak treće razine. U slučaju Češke Republike, čitava država smatra se regijom NUTS 1 razine zbog relativno malog broja stanovnika. Sljedeća razina podjele je NUTS 2 koja sadrži 8 regija (oblasti) dobivenih kohezijom postojećih pokrajina, a pokrajine same po sebi predstavljaju treću razinu (NUTS 3). Ispod NUTS razina postoje i dvije LAU (*Local Administrative Units*) razine.

Table 1 GDP per capita (EUR) in the counties of the Czech Republic in 2011. Source: URL 3

County	GDP per capita 2011 (EUR)
NUTS 3 region	
Prague	31.244
<i>Czech Average</i>	<i>14.815</i>
South Moravia	13.871
Plzen	13.280
Central Bohemia	13.251
Moravia-Silesia	12.927
Hradec Kralove	12.825
Zlin	12.554
South Bohemia	12.470
Vysočina	12.335
Pardubice	12.111
Usti nad Labem	11.789
Olomouc	11.451
Liberec	11.378
Karlovy Vary	10.578

since 1990 and independence. In the first decade after the collapse of Communism and the peaceful dissolution of Czechoslovakia, the Czech Republic underwent a process of transition from a planned to a market economy, which expectedly caused a temporary rise in the unemployment rate, with the steepest recorded from 1996 to 2000. Although the pace of the rise stabilized after 2000, it gradually reached its highest point of 9.69 % in 2004. (URL 2). In 2008, it dropped to 3.95 %, but the decreasing trend was interrupted by the global economic crisis which was reflected in the following years, with the unemployment rate reaching 8.8 % in 2014. In the two following years (2015 and 2016), another declining trend was recorded, and there are relatively good forecasts for the coming period.

Unemployment rates in the counties of the Czech Republic are rather uneven. Based on the available statistical data, a cartogram was made (Figure 5A) showing that the unemployment rate generally increases with the distance from Prague. In 2011, the unemployment rate in Prague was 6.81 %, the lowest in comparison to all other counties. Geographically, a diagonal ENE-WSW line can be drawn across the map of the Czech Republic connecting counties with the lowest unemployment rates.

Besides the general unemployment rate, another helpful (secondary) indicator is the number of people searching for jobs registered by the Czech Ministry of Labour and Social Affairs. The Ministry calculates the number of applicants per job by dividing the number of job seekers by the number of vacancies. This indicates how many unemployed citizens are actively seeking work.

Prague has the lowest number, with 4.15 applicants for each job. In Plzeň and Pardubice Counties the situation is also relatively favourable, with 8.7 and 8.8 applicants per job. The most unfavourable figures are in Ústí and Olomouc Counties (28.6 and 34.5 applicants per job).

5.3. Indicators of infrastructural disparities

Road network. An important indicator of a region's transportation capacity is the overall length of the road network. In 2011, the region with the greatest length of roads and highways was Central Bohemia, at 9,637 km, followed by South Bohemia, at 6,224 km. Although Prague County stands out in terms of other indicators, since its territory consists solely of the city, it has relatively fewer roads and highways (86 km).

Apart from absolute road length, another important statistical indicator is road density (kilometres of road per 100 km²). Overall, higher road density is found in the counties in the north of the Czech Republic (Fig. 6). Disregarding Prague City, the lowest road density is in Zlín County (54 km per 100 km²). The average national density is 66.5 km/km².

Railway network. The Czech railway system is relatively well developed, with a total length of 9,572 km and a density of 12.2 km per 100 km² of tracks in 2011. According to the Czech Statistical office (URL 1), in comparison to other EU countries with similar populations, the Czech railway system is much denser. For example, it is 5.6 times denser than the railway system of Portugal, 5.1 than that of Greece and 2.4 times denser than to the railway system in Belgium.

Apart from overall length and density, an important indicator of railway system development is the proportion of electrified tracks. Although initially more costly and more complex to build, an electrified rail network provides faster journey times, new trains, and 'greener' transport with fewer emissions of greenhouse gases. It is also more suitable for heavy freight compositions and longer routes. Therefore, its size in the overall railway system is an indicator of a region's development in terms of infrastructure.

Around 30% of railway tracks in the Czech Republic are electrified, and this percentage is still increasing. The cartogram (Fig. 7) indicates that the regions with the highest proportion of electrified tracks in the total length are those through which main railway corridors pass: Prague, Central Bohemia, Pardubice, Olomouc and South Moravia. At the other end of the spectrum are counties that are generally less important in terms of international transit – Liberec and Hradec Králové.

5. Demografski, gospodarski i infrastrukturni dispariteti

5.1. Pokazatelji demografskih dispariteta

Indeks starenja. Starenje stanovništva obično se percipira kao problem razvijenih zemalja. Promjene u dobnoj strukturi pritom su uzrokovane povećanjem očekivane životne dobi kao i niskim razinama fertiliteta. Češka Republika jedna je od europskih zemalja koje imaju nizak udio djece u ukupnom stanovništvu zbog činjenice da je fertilitet čeških žena ispod takozvane "održive razine". Jedan od statističkih alata za mjerenje starenja unutar populacije je indeks starenja koji se odnosi na broj stanovnika starih 65 ili više godina na 100 stanovnika mlađih od 15 godina. U tom smislu, vrijednost od 100 (jednakost udjela obiju skupina) u Češkoj je republici ostvarena 2007 (Artlová 2010).

Unatoč rastućem broju novorođene djece, indeks starenja otad se konstantno povećava te je u 2011 dosego 110,47, što znači da je bilo 110 osoba starih 65 ili više godina na 100 osoba starih 0–14. Kad je riječ o pojedinim regijama NUTS 3 razine, indeks je najviši u Gradu Pragu (130,85), a nakon njega u pokrajinama Hradec Králové (116,29) i Plzeň (116,69). Samo dvije pokrajine u 2011 imale su veći broj pripadnika mlade dobne skupine od onih starije – Ústí nad Labem (96,87) i Središnja Češka (95,79). Razlike u indeksu starenja vizualizirane su kartogramom i prikazane na slici 2.

Udio osoba s visokim obrazovanjem. Za svaku je zemlju od osobite važnosti imati visok udio visokoobrazovanih stanovnika. Visoko obrazovanje donosi mnoge prednosti i pojedincu i društvu u cjelini. Primjerice, pojedinac ima veće prilike na tržištu rada, a društvo je općenito bolje obrazovano što ga čini konkurentnijim.

Usporedba popisnih podataka iz 2001 i 2011 (URL 1, URL 2) potvrđuje činjenicu da je stanovništvo sve više obrazovano. Ukupan broj stanovnika s višim i visokim stupnjem obrazovanja se povećava i, posljedično, udio ljudi sa samo osnovnom i srednjom školom opada. Udio visoko obrazovanih pojedinaca u stanovništvu starijem od 15 godina bio je 9,01% godine 2001., dok je deset godina kasnije taj udio iznosio 13,16%. Godine 2011 udio pojedinaca sa završenim srednjim, višim ili visokim obrazovanjem u ukupnom broju osoba starijih od 15 godina bio je 46,1%.

Što se tiče izračuna distribucije visokoobrazovanih osoba po pokrajinama, ukupan broj osoba sa završenim fakultetom u pojedinoj pokrajini odnosno NUTS 3 regiji podijeljen je s brojem stanovnika starijih od 25. To je učinjeno zbog činjenice da su osobe u ovoj skupini u produktivnom razdoblju života, te imaju priliku završiti sveučilište. Udio osoba sa završenim fakultetom kod

Tablica 1. BDP po stanovniku (EUR) u pokrajinama Češke Republike 2011. Izvor: URL 3

Pokrajina NUTS 3 regija	BDP po stanovniku 2011 (EUR)
Prag	31.244
Češki prosjek	14.815
Južna Moravska	13.871
Plzeň	13.280
Središnja Češka	13.251
Moravska-Šleska	12.927
Hradec Kralove	12.825
Zlín	12.554
Južna Češka	12.470
Vysočina	12.335
Pardubice	12.111
Ústí nad Labem	11.789
Olomouc	11.451
Liberec	11.378
Karlovy Vary	10.578

osoba starijih od 25 godina je 14,48%. Kako pokazuje slika 3, Prag (27,08%) i Južna Moravska (17,05%) imaju najveće udjele, a slijede ih Olomouc, Središnja Češka, Moravska-Šleska i Zlín (13,34% – 13,12%). Najniži udio osoba sa završenim fakultetom imaju sjeverozapadne pokrajine Ústí nad Labem (8,83%) i Karlovy Vary (8,15%).

5.2. Pokazatelji gospodarskih dispariteta

Bruto domaći proizvod. Bruto domaći proizvod (BDP) je monetarna vrijednost svih konačnih dobara i usluga proizvedenih u okvirima granica države ili regije u određenom razdoblju (URL 8). Obično se izračunava na godišnjoj ili kvartalnoj bazi, te uključuje cjelokupnu privatnu i javnu potrošnju, državne izdatke, ulaganja, te razliku između uvoza i izvoza u okvirima definiranog teritorija. Iako je, kad je riječ o regijama, BDP po glavi stanovnika neprecizan zbog toga što precjenjuje ekonomski učinak regija s velikim urbanim središtima (Kahoun 2007), on se svejedno naveli-ko koristi kao pokazatelj prilikom evaluacije dinamike i trendova sveukupnog gospodarstva i gospodarskog učinka u nekom području, kao i životnog standarda. Glede vrjednovanja učinka čeških NUTS 3 regija, relativno je pouzdan u ukazivanju na opće gospodarske disparitete među njima.

Što se tiče apsolutne distribucije BDP-a po stanovniku u pokrajinama Češke Republike (tablica 1), brojke ukazuju na značajan disparitet između glavnog grada Praga i drugih pokrajina. Godine 2011. BDP po stanovniku u Pragu iznosio je 31 244 eura, dok je u ostalih 13 pokrajina varirao između 10 000 i 14 000 eura. To pokazuje da su gospodarski učinak i sveukupni standard praške populacije nadilazili one u drugim pokrajinama više od dvostruko.

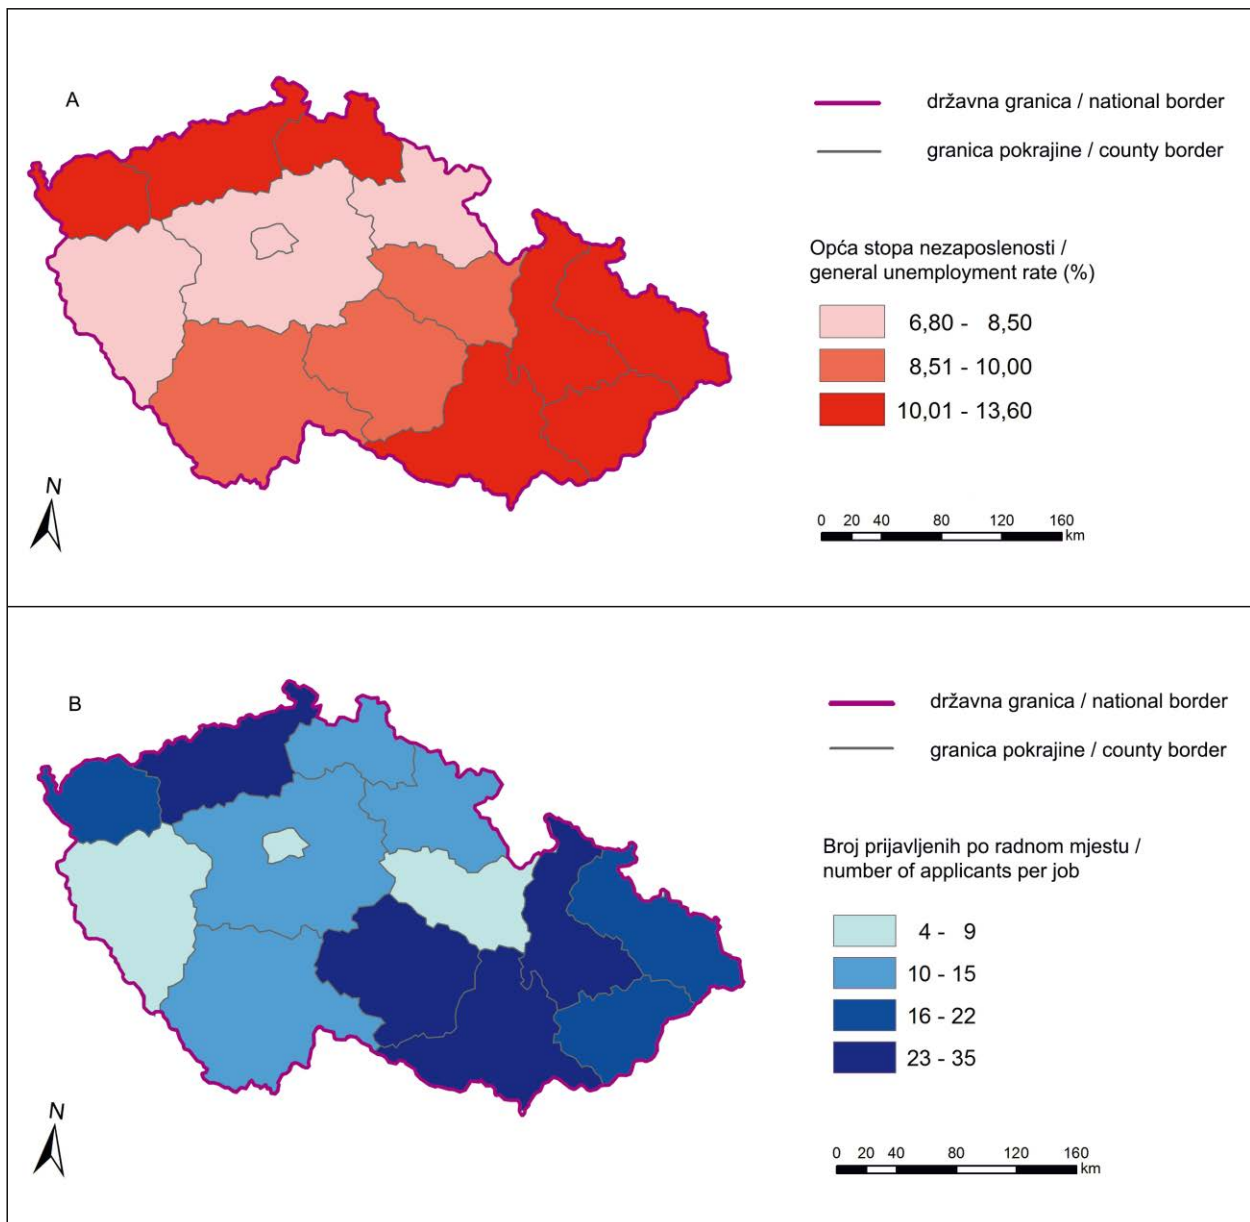


Fig. 5 a) General unemployment rates and
b) numbers of applicants per job in the counties (NUTS 3 regions)
of the Czech Republic. Source: URL 3, URL 5

Slika 5. a) Opće stope nezaposlenosti i
b) broj prijavljenih po radnom mjestu u pokrajinama (NUTS 3 regijama)
Češke Republike. Izvori: URL 3, URL 5

5.4. Measuring disparities

A synthetic index was used to round up and quantify the selected indicators and assess the Czech NUTS 3 regions, to provide a basic insight into the disparities between them. After assigning points to each region as described in the section on methodology, the results were listed in Tables 2 and 3, imported into the ArcGIS-spatial database, and visualized in a cartogram (Fig. 8). The regions were categorized into five classes according to points scored – *very unfavourable*, *unfavourable*, *average*,

favourable and *very favourable*. Besides the overall points per indicator and general distribution of five categories, the tables also include the rankings of regions in terms of individual key indicators and overall ranking.

The analysis of particular categories shows that Prague County was the most favourable region in terms of four indicators – the unemployment rate, proportion of university graduates older than 25 in the total population, GDP per capita and proportion of electrified railway tracks. Thus, it was given a maximum of 1,000 points in each of these four categories (Table 3). On the

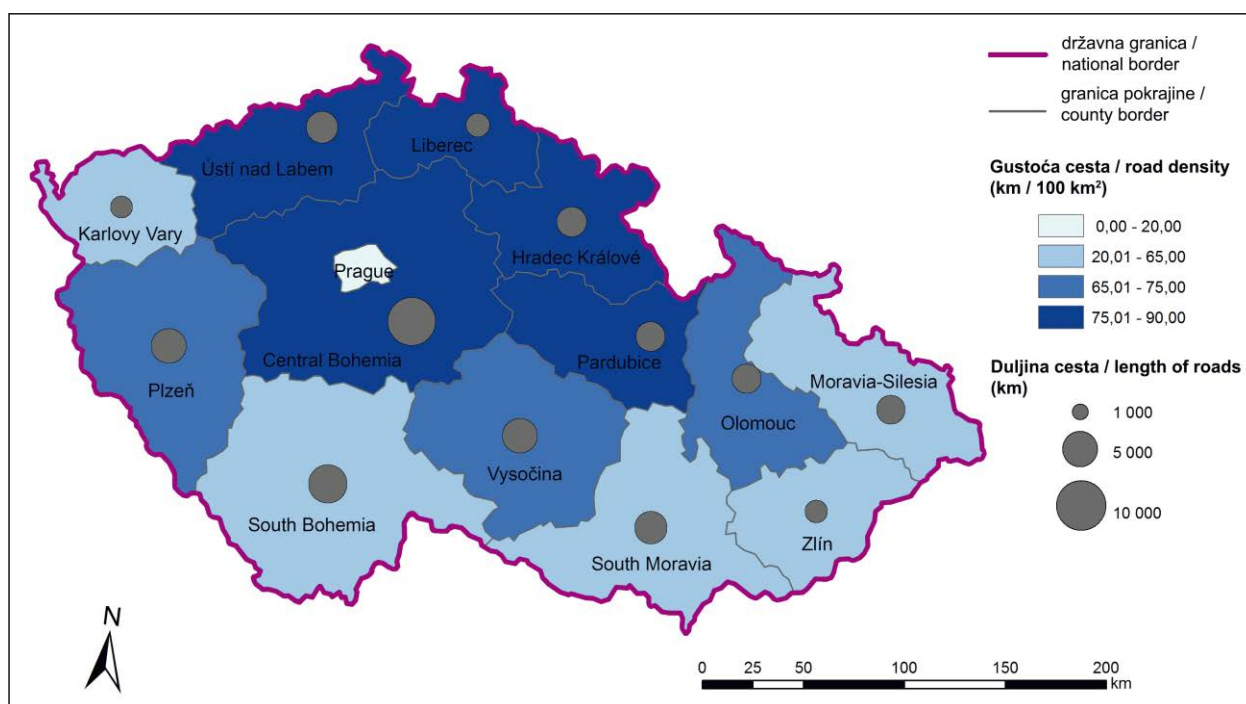


Fig. 6 Length and density of roads and highways in the Czech Republic counties (NUTS 3 regions). Source: URL 7
Slika 6. Ukupna duljina i gustoća cestovne mreže u pokrajinama (NUTS 3 regijama) Češke Republike. Izvor: URL 7

Uzimajući u obzir navedene brojke, prosječni BDP u Češkoj iznosio je 14 815 eura po stanovniku, što je gotovo 1000 eura više od vrijednosti u Južnoj Moravskoj (13 871), pokrajini s drugim najvišim BDP-om po stanovniku (URL 9). To implicira značajan disparitet između Praga i ostalih regija. Kad se uspoređuje te brojke s podacima o BDP-u po stanovniku iz 2001. (sl. 6), može se vidjeti da je praktički udvostručen u svim pokrajinama; no, to implicira da su dispariteti u apsolutnim vrijednostima između Praga i ostalih pokrajina također analogno porasli.

Stopa nezaposlenosti. Nezaposlenost je pokazatelj koji obično odražava postojeće trendove u gospodarstvu. Češko je, pak, gospodarstvo prošlo kroz nekoliko promjena od 1990. do danas, odnosno od početka neovisnosti zemlje. U prvom desetljeću nakon kolapsa komunizma i mirnog raspada Čehoslovačke, Češka je Republika prošla kroz proces tranzicije iz planske u tržišnu ekonomiju, što je neminovno dovelo do privremenog porasta stope nezaposlenosti u zemlji, uz najveći porast broja nezaposlenih zabilježen između 1996. i 2000. Iako se stopa nezaposlenosti stabilizirala nakon 2000., postupno je dosegla najvišu razinu od 9,69% u 2004 (URL 2). Godine 2008. stopa nezaposlenosti pala je na 3,95%, no trend pada broja nezaposlenih prekinut je globalnom ekonomskom krizom koja se u češkom slučaju odrazila u godinama koje su uslijedile, te je godine 2014. stopa opet iznosila relativno visokih 8,8%. U slijedeće dvije godine (2015 i 2016) zabilježen je novi trend opadanja, s razmjerno povoljnim prognozama za nadolazeće razdoblje.

Stope nezaposlenosti u pokrajinama Češke Republike razmjerno su neujednačene. Na temelju dostupnih statističkih podataka izrađen je kartogram (slika 5A) koji pokazuje da se spomenute stope općenito povećavaju s udaljenošću od Praga. Godine 2011. stopa nezaposlenosti u Pragu bila je 6,81%, što je najniža stopa u usporedbi sa svim ostalim pokrajinama. Geografski gledano, preko karte Češke Republike može se povući dijagonalna crta u pravcu istok-sjeveroistok – zapad-jugozapad koja povezuje pokrajine s najnižim stopama nezaposlenosti.

Osim stopa opće nezaposlenosti, još jedan pokazatelj (korišten kao sekundarni pokazatelj) je broj prijavljenih za poslove registriranih od strane češkog Ministarstva Rada i Socijalnih Pitanja. Ministarstvo izračunava broj prijavljenih po dostupnom radnom mjestu dijeleći broj tražitelja posla s brojem dostupnih radnih mjesta. Ovo pokazuje koliki je broj trenutno nezaposlenih građana koji konkuriraju za pojedino radno mjesto.

U ovom kontekstu, Prag je također u najboljem položaju sa samo 4,15 prijavljenih po radnom mjestu. U pokrajinama Plzeň i Pardubice situacija je također razmjerno povoljna s 8,7 i 8,8 prijavljenih po radnom mjestu. Najnepovoljnije brojke su u pokrajinama Ústí nad Labem (28,6) i Olomouc (28,6).

5.3. Pokazatelji infrastrukturnih dispariteta

Cestovna mreža. Važan pokazatelj prometnih mogućnosti pojedine regije je ukupna duljina cestovne

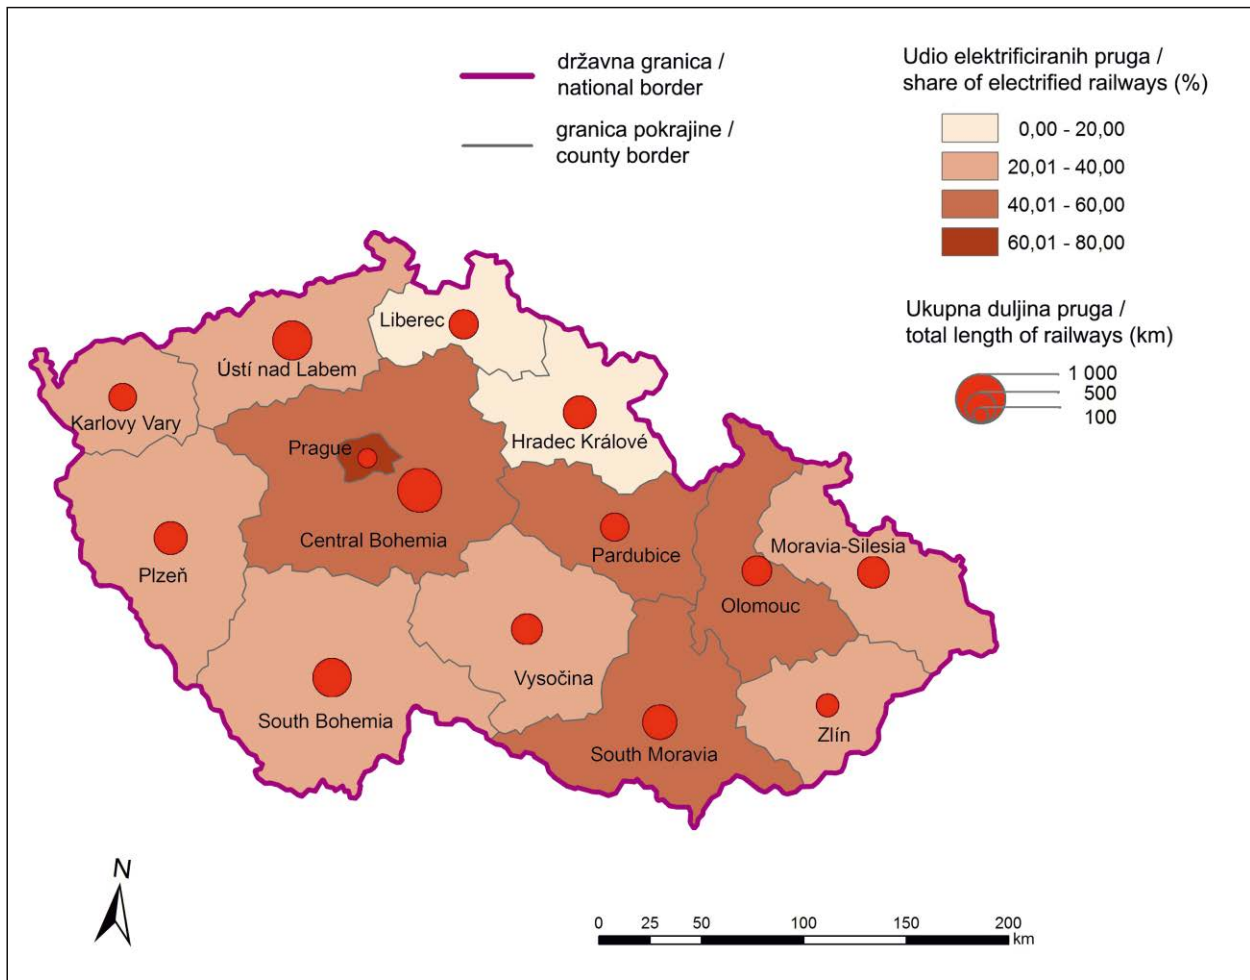


Fig. 7 Total length and proportions of electrified railway tracks in the Czech Republic counties (NUTS 3 regions). Source: URL 6

Slika 7. Ukupna duljina i udjeli elektrificiranih željezničkih pruga u pokrajinama (NUTS 3 regijama) Češke Republike. Izvor: URL 1, URL 6

other hand, it showed the lowest result in terms of the ageing index, at only 695 points. In addition, since the Prague regional unit consists solely of the city and suburbs, its result in terms of road density per 100 km² was also the lowest, at only 196 points. This particular indicator is perhaps not best suited for comparing Prague to other regional units with larger territories. However, it highlights a significant aspect of developmental differences among the other Czech regions, and since it does not influence the overall result significantly, the indicator was retained for data consistency. Overall, Prague was the leading region with a total result of 4,893 points, and one of two counties that were categorized as 'very favourable'.

The second region in the top category was Central Bohemia with a total of 4,461 points, and very good results in all categories. It had the lowest ageing index, the second lowest unemployment rate and the highest road density. The last is due to the fact that Central Bohemia

surrounds the City of Prague, and therefore all the busiest roads and motorways pass through its territory.

The points acquired placed three regions in the next category (favourable) – South Moravia (4,181), Pardubice (4,170) and Olomouc (4,135). All three had relatively high results for most indicators, but Pardubice showed a wide range in the results, which were high for infrastructural indicators (2nd for road density and 3rd for the proportion of electrified railways tracks) and low for of the economic and demographic ones (13th for GDP per capita and 10th for proportion of graduates under 25).

In the 'average' category there were three counties – Ústí nad Labem (4,023 points), Vysočina (3,968) and Plzeň (3,908). Ústí nad Labem is a contrasting region that performed highly in terms of the ageing index (2nd), and was also relatively highly ranked in the context of GDP per capita (4th) and road density (also 4th). On the other hand, the region had the highest

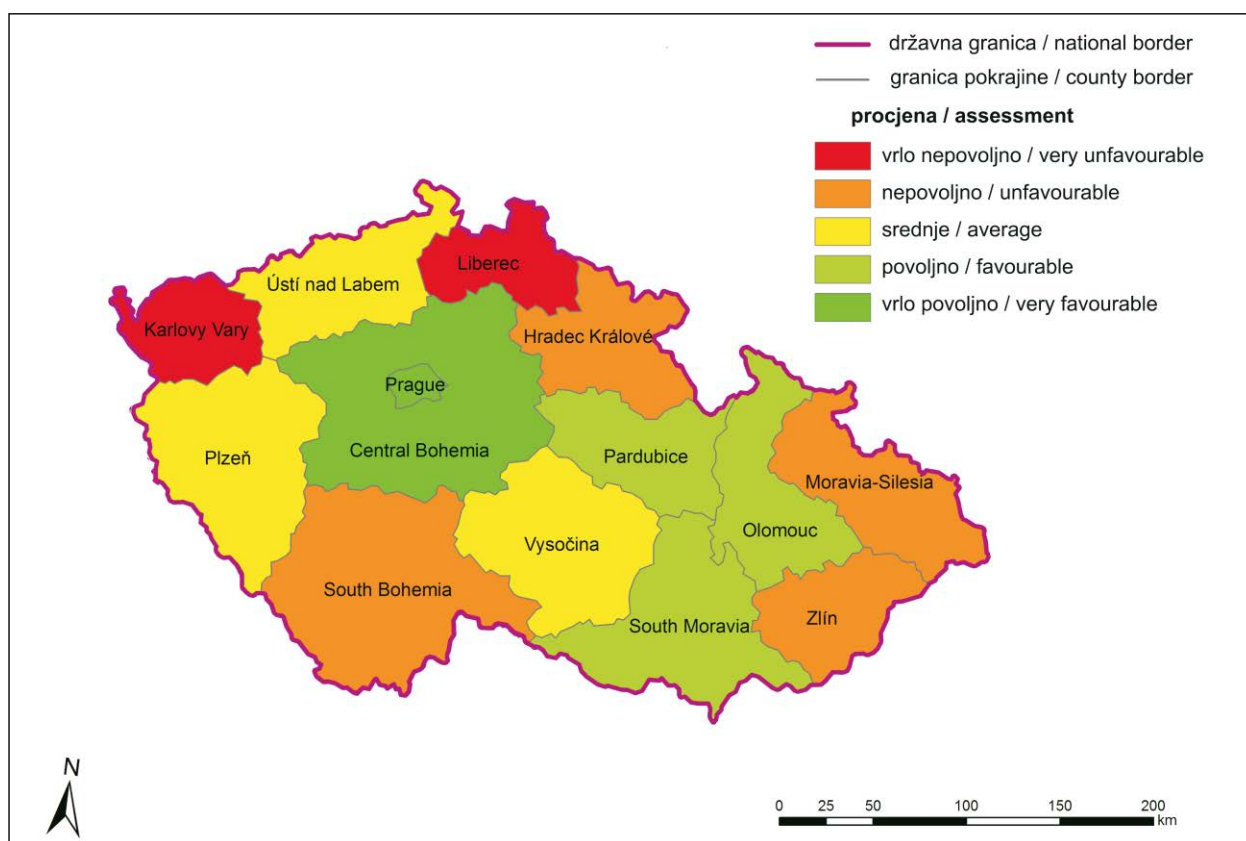


Fig. 8 Cartogram of assessment of the Czech Republic's NUTS 3 regions according to points assigned
Slika 8. Kartogram procjene NUTS 3 regija Češke Republike na temelju ostvarenih bodova

mreže. U 2011. je pokrajina s najvećom duljinom cesta i autocesta bila Središnja Češka (ukupno 9637 km), a nakon nje Južna Češka (6224 km). Iako se Prag ističe kao pozitivan primjer kod svih ostalih pokazatelja, njegova ukupna duljina cesta i autoputova je razmjerno mala (samo 86 km) zbog činjenice da je riječ o malom upravnom teritoriju, tj. isključivo gradskom području.

Osim apsolutne duljine cesta, znakovit statistički pokazatelj je i gustoća cestovne mreže (duljina cesta u km na 100 km²). Općenito, gustoća cesta i autocesta je veća u pokrajinama na sjeveru države (slika 6). Ako se izuzme gradsko područje Praga, najniža gustoća cestovne mreže je u pokrajini Zlín (54 km na 100 km²). Prosječna gustoća cesta u državi je 66,5 kilometara na 100 km².

Željeznička mreža. Sustav željeznica u Češkoj razmjerno je visoko razvijen, s ukupnom duljinom od 9 572 km i gustoćom od 12,2 km željeznica na 100 km². Prema Češkom uredu za statistiku (URL 1), u usporedbi s drugim zemljama Europske unije sa sličnim brojem stanovnika, češki je željeznički sustav mnogo gušći. Primjerice, 5,6 puta je gušći od onoga u Portugalu, 5,1 put od onoga u Grčkoj, te 2,4 puta gušći od željezničke mreže u Belgiji.

Osim ukupne duljine i gustoće, važan pokazatelj razvijenosti željezničkog sustava jest udio elektrificirane željezničke mreže. Iako je inicijalno značajno skuplja te

zahtijeva kompliciraniju izgradnju, elektrificirana željeznička mreža omogućuje kraće vrijeme putovanja, novije vlakove, "zeleniji" prijevoz s manje emisija štetnih stakleničkih plinova. Također je prikladnija za vuču teškog tereta i za duže rute. Stoga udio takvih pruga u ukupnom željezničkom sustavu može biti pokazatelj razvoja neke regije u kontekstu infrastrukture.

Oko 30% željezničkih pruga u Češkoj Republici je elektrificirano, a taj udio i dalje raste. Izrađeni kartogram (slika 7) ukazuje na to da su regije s najvišim udjelom elektrificiranih željezničkih pruga u ukupnoj duljini pruga su one kroz koje prolaze najvažniji željeznički koridori – Prag, Središnja Češka, Pardubice, Olomouc i Južna Moravska. Na drugoj strani spektra su pokrajine koje su općenito manje važne u okvirima međunarodnog tranzita – Liberec i Hradec Králové.

5.4. Mjerenje dispariteta

Kao što je već ranije opisano, sintetički indeks upotrijebljen je za okupljanje i kvantifikaciju izabranih pokazatelja i procjenu čeških NUTS 3 regija, a sa svrhom dobivanja uvida u disparitete među njima. Primjenom sustava dodjele bodova svakoj regiji, kao što je opisano u poglavlju o korištenoj metodologiji, rezultati

Table 2 Rezultati računanja sintetskog indeksa, ostvareni bodovi i rang čeških pokrajina.

Izvori: URL 1, URL 3, URL 4, URL 6, URL 7

Tablica 2. Results of synthetic index calculation, points, and ranking of the Czech counties.

Sources: URL 1, URL 3, URL 4, URL 6, URL 7

Pokrajina County (NUTS 3 regija/region)	Indeks starenja Ageing index			Udio visokoobrazovanih > 25 Share of graduates > 25			Stopa nezaposlenosti Unemployment rate		
	indeks index	bodovi points	rang ranking	vrijed- nost / value	bodovi points	rang ranking	indeks index	bodovi points	rang ranking
Prag / Prague	130,86	695	14.	27,09	1000	1.	6,81	1000	1.
Južna Češka / South Bohemia	109,75	907	7.	12,62	466	7.	8,56	981	5.
Južna Moravska / South Moravia	115,90	846	10.	17,06	630	2.	10,52	960	9.
Karlovy Vary	105,64	949	4.	8,15	301	14.	11,99	944	12.
Hradec Králové	116,29	842	11.	11,76	434	9.	8,37	983	3.
Liberec	100,54	963	3.	11,24	415	11.	10,82	957	10.
Moravska-Šleska / Moravia-Silesia	108,91	916	5.	13,19	487	5.	12,40	940	13.
Olomouc	112,44	880	9.	13,33	492	3.	11,84	946	11.
Pardubice	109,64	909	6.	11,57	427	10.	8,99	977	6.
Plzeň	116,69	838	12.	12,03	444	8.	8,40	983	4.
Središnja Češka / Central Bohemia	95,79	1000	1.	13,21	488	4.	8,18	985	2.
Ústí nad Labem	96,88	974	2.	8,83	326	13.	13,60	927	14.
Vysočina	112,12	884	8.	11,16	412	12.	9,43	972	7.
Zlín	117,18	833	13.	13,12	484	6.	10,21	963	8.

Pokrajina County (NUTS 3 regija/region)	BDP po stanovniku / GDP per capita			Gustoća cestovne mreže / Road density			Udio elektrificiranih pruga / Share of electrified railway		
	indeks index	bodovi points	rang ranking	indeks index	bodovi points	rang ranking	indeks index	bodovi points	rang ranking
Prag / Prague	31200	1000	1.	17,34	198	14.	74,19	1000	1.
Južna Češka / South Bohemia	12500	401	8.	60,85	695	12.	32,01	431	10.
Južna Moravska / South Moravia	13900	446	2.	63,41	725	9.	42,66	575	4.
Karlovy Vary	10600	340	14.	61,89	707	10.	23,08	311	12.
Hradec Králové	12300	394	9.	79,15	905	3.	18,46	249	13.
Liberec	12800	410	6.	76,68	876	5.	0,00	0	14.
Moravska-Šleska / Moravia-Silesia	11400	365	12.	61,64	704	11.	26,26	354	11.
Olomouc	12900	413	5.	69,36	793	7.	45,26	610	2.
Pardubice	11400	365	13.	79,63	910	2.	43,17	582	3.
Plzeň	12100	388	10.	67,79	775	8.	35,63	480	8.
Središnja Češka / Central Bohemia	13300	426	3.	87,50	1000	1.	41,71	562	5.
Ústí nad Labem	13200	423	4.	78,70	899	4.	35,20	474	9.
Vysočina	11800	378	11.	73,65	842	6.	35,69	481	7.
Zlín	12600	404	7.	54,03	617	13.	37,99	512	6.

Table 3 Points acquired, categories, and overall ranking of the Czech counties. Source: own calculations using data from URL 1, URL 3, URL 4, URL 6, URL 7**Tablica 3.** Postignuti bodovi, razredi i ukupno rangiranje čeških pokrajina (NUTS 3 regija). Izvor: vlastiti izračun na temelju podataka iz: URL 1, URL 3, URL 4, URL 6, URL 7

Ranking Poredak	County / pokrajina NUTS 3 regija / region	Points Bodovi	Assessment Procjena
1.	Prague	4893	very favorable
2.	Central Bohemia	4461	vrlo povoljno
3.	South Moravia	4181	favorable povoljno
4.	Pardubice	4170	
5.	Olomouc	4135	
6.	Ústí nad Labem	4023	average srednje
7.	Vysočina	3968	
8.	Plzeň	3908	
9.	South Bohemia	3882	unfavorable nepovoljno
10.	Zlín	3814	
11.	Hradec Králové	3807	
12.	Moravia-Silesia	3767	
13.	Liberec	3621	very unfavorable
14.	Karlovy Vary	3552	vrlo nepovoljno

su navedeni u tablicama 2 i 3, uneseni u bazu prostornih podataka u ArcGIS-u, te kartografski prikazani u vidu kartograma (slika 8). Stanje regija je kategorizirano u pet razreda, na temelju broja bodova koje su postigle – *vrlo nepovoljno, nepovoljno, prosječno, povoljno i vrlo povoljno*. Osim ukupnog broja bodova i opće procjene kroz klasifikaciju u pet kategorija, tablice uključuju i rangiranje regija na temelju pojedinih ključnih pokazatelja, kao i opće rangiranje.

Analiza pojedinih kategorija ukazuje na to da je Prag regija s najpovoljnijim stanjem u okvirima četiriju pokazatelja – stope nezaposlenosti, udjela visokoobrazovanih osoba starijih od 25 godina u ukupnom stanovništvu, BDP-a po stanovniku, te udjela elektrificiranih pruga. U tom kontekstu, u svakoj od četiri kategorije dodijeljen joj je maksimum od 1000 bodova (tablica 2). S druge strane, Prag pokazuje najslabiji rezultat u pogledu indeksa starenja, gdje je ostvario svega 695 bodova. Nadalje, imajući u vidu da je Prag regija koja se sastoji isključivo od grada i njegovih predgrađa, ima i najniži rezultat u okvirima gustoće cestovne mreže na 100 km², svega 196 bodova. Ovo implicira da navedeni pokazatelj nije najprikladniji za statističku usporedbu Praga i drugih regija koje imaju znatno veće ukupne površine. No, imajući u vidu da ukazuje na značajan aspekt razvojnih razlika među ostalim češkim regijama, te da kao takav

ne utječe značajno na ukupni rezultat, uračunan je radi konzistentnosti podataka. Općenito, Prag je vodeća regija s ukupnim rezultatom od 4893 boda te je jedan od dvije pokrajine koje su stoga svrstane u najvišu kategoriju "vrlo povoljno".

Druga regija u najbolje ocijenjenom razredu je Središnja Češka s ukupno ostvarenim 4461 bodom, za koju su utvrđeni vrlo dobri rezultati procjene u svim pokazateljima. Primjerice, ima najniži indeks starenja, drugu najnižu stopu nezaposlenosti i najvišu gustoću cestovne mreže. Povoljnost pokazatelja gustoće cestovne mreže po svojoj prilici rezultat činjenice da regija administrativno okružuje Grad Prag, te kroz njen teritorij prolaze sve najfrekventnije prometnice.

Prema postignutim bodovima, tri su regije u sljedećem razredu ("povoljno") – Južna Moravska (4181), Pardubice (4170) i Olomouc (4135). Sve tri regije ostvaruju razmjerno visoke rezultate većine mjerenih pokazatelja, a kod pokrajine Pardubice utvrđen je i velik kontrast u rezultatima, pri čemu ostvaruje visoke rezultate infrastrukturnih pokazatelja (drugo mjesto po gustoći cestovne mreže i treće po udjelu elektrificiranih pruga), a istodobno niske rezultate pojedinih gospodarskih (na 13. mjestu po BDP-u po stanovniku) i demografskih (10. mjesto po udjelu visokoobrazovanih ispod 25 godina).

unemployment rate and the second lowest proportion of graduates aged below 25. The results for the other two counties were more consistent, though Plzeň stood out with the 4th lowest unemployment rate.

South Bohemia (3,882 points), Zlín (3,814 points), Hradec Králové (3,807 points) and Moravia Silesia (3,767 points) were assessed as 'unfavourable'. Moravia Silesia was relatively highly ranked for both demographic indicators, but showed low results for economic ones, with the second highest unemployment rate and ranking 12th for GDP per capita. South Bohemia showed better results for economic indicators, but obviously needs infrastructural advances in order to keep up with other regions (12th for road density and 10th for proportion of electrified railway tracks). Hradec Králové and Zlín showed the lowest results for demographic indicators.

The counties with the lowest results were Liberec (3,659 points) and Karlovy Vary (3,552 points). Although Liberec had average or above average results for some indicators (3rd for the ageing index and 5th for road density), it scored low overall due to higher than average unemployment (5th highest unemployment rate), a lower than average proportion of graduates under 25, and no electrified railway tracks whatsoever. On the other hand, Karlovy Vary had the overall lowest result due to having the lowest BDP per capita, 3rd highest unemployment rate and the lowest proportion of university graduates under 25.

In the context of cartographic visualization, the results of calculating the synthetic index and points for each region were visualized in the final cartogram (Fig. 8) presenting the five set classes of assessment in different colours, with green indicating the most favourable, yellow the average, and orange and red the least favourable. The map provides a better visual insight into the spatial patterns of disparities in the Czech NUTS 3 regions.

6 Conclusion

The aims of this paper were to make an assessment of regional disparities in the NUTS 3 regions (counties) of the Czech Republic by using the *point method* to measure disparities, and to visualize cartographically the selected indicators and final results in a series of cartograms. The purpose of both procedures was to

make a contribution to assessing regional disparities at the methodological, factual and cartographic levels.

After extracting the data within the framework of six indicators for the Czech counties, and comparing them between the regions, a synthetic index was used to assign points to each region in terms of 'performance'. The final ranking of the Czech counties confirmed the dominance of Prague. Although the selection of two indicators created a bias by reducing the capital's performance (the high ageing index due to the general ageing trend in larger urban areas, and the obviously low road density, since the region consists solely of the city), Prague nevertheless scored the most points in the assessment, exceeding the surrounding region of Central Bohemia by 432 points. On the other hand, Central Bohemia scored 380 points more than South Moravia, the next region in the ranking. This clearly distinguishes Prague and Central Bohemia as 'very favourable', as the sequential difference in the results acquired for the other regions varied from 11 to 69 points, and confirmed the hypothesis that disparities increase concentrically from Prague towards the periphery.

As indicated by the results of the assessment, all three categories of indicators showed a relative territorial imbalance resulting from a high concentration of economic activity and population in Prague. Generally, a high territorial disparity between the national centre and its periphery was reflected in marked inequalities in competitiveness and results in the asymmetrical distribution of human resources, infrastructure and wealth (Kutscherauer et al., 2010). In the Czech Republic, such a trend was more prominent during the 1990s and the country's transition towards a market economy, and has disadvantageously influenced the peripheral regions. However, since the Czech Republic's accession to the EU, the general trend of growing territorial disparities has been alleviated through various programmes of cross-border cooperation (URL 8).

In conclusion, the purpose of this research was to provide an additional contribution to the existing corpus of studies and papers aimed at researching regional disparities. The selected set of criteria and the synthetic index used to assess them may serve as a starting-point for a more comprehensive, detailed study of the Czech NUTS 3 regions and the economic, infrastructural and demographic disparities in them.

U srednjem razredu ("prosječno") tri su pokrajine – Ústí nad Labem (4023 boda), Vysočina (3968) i Plzeň (3908). Ústí nad Labem je vrlo kontrastna regija u smislu regionalnih dispariteta – postiže visok rezultat u indeksu starenja (drugi 2. mjesto), te je razmjerno visoko rangirana s obzirom na BDP po stanovniku (4. mjesto) i gustoće cestovnih prometnica (također 4. mjesto). S druge strane, regija ima najvišu stopu nezaposlenosti, te drugi najniži udio visokoobrazovanih mlađih od 25 godina u odnosu na druge češke pokrajine. Kod drugih dviju pokrajina rezultati su manje kontrastni, a Plzeň se ističe s nešto povoljnijim rezultatom za pokazatelj stope nezaposlenosti (4. najniža stopa).

Južna Češka (3882 boda), Zlín (3814 bodova), Hradec Králové (3807 bodova) i Moravska-Šleska (3767 bodova) ocijenjene su "nepovoljnima". Moravska-Šleska je razmjerno visoko rangirana u pogledu obaju demografskih pokazatelja, ali s niskim rezultatima za gospodarske – drugu najvišu stopu nezaposlenosti, te 12. mjesto po BDP-u po stanovniku od ukupno 14 pokrajina. Južna Češka pokazuje bolje rezultate gospodarskih pokazatelja, ali očigledno joj je potreban dodatni infrastrukturni razvoj da bi se smanjio disparitet u tom smislu u odnosu na druge pokrajine (12. po gustoći cesta i 10. po udjelu elektrificiranih pruga). Hradec Králové i Zlín, pak, pokazuju najslabije rezultate u okvirima demografskih indikatora.

Pokrajine s najslabijim rezultatima su Liberec (3659 bodova) i Karlovy Vary (3552 boda). Iako kod nekih pokazatelja pokazuje prosječne ili natprosječne rezultate (3. najbolji rezultat za indeks starenja, te 5. za gustoću prometnica) Liberec ostvaruje ukupno nizak rezultat radi visoke nezaposlenosti (5. najviša stopa nezaposlenosti), ispodprosječnog udjela visokoobrazovanih mladih ispod 25 godina starosti, te nepostojanja elektrificiranih željezničkih pruga. S druge strane, pokrajina Karlovy Vary ima ukupno najslabiji rezultat zbog najnižeg BDP-a po stanovniku, 3. najviše stope nezaposlenosti i najnižeg udjela visokoobrazovanih mlađih od 25 godina.

U pogledu kartografske vizualizacije, rezultati izračuna sintetskog indeksa i bodova za svaku regiju vizualizirani su u obliku konačnog kartograma (slika 8) koji prikazuje pet definiranih razreda procjene različitim bojama, pri čemu zelene boje označavaju najpovoljnije, žuta boja srednje, te narančasta i crvena najmanje povoljne razrede procjene regija. Karta može poslužiti kao sredstvo za bolji uvid u prostorne uzorke čeških regionalnih dispariteta na razini NUTS 3 regija.

6. Zaključak

Ciljevi ovoga rada bili su napraviti procjenu regionalnih dispariteta NUTS 3 regija (pokrajina) Češke

republike koristeći "točkastu" metodu mjerenja, te kartografski vizualizirati odabrane pokazatelje i krajnje rezultate nizom kartograma. Svrha postupaka bila je dati doprinos razmatranju regionalnih dispariteta na metodološkoj, činjeničnoj i kartografskoj razini.

Nakon izdvajanja podataka u okvirima šest odabranih pokazatelja za češke pokrajine, te njihove međusobne usporedbe, upotrijebljen je sintetski indeks te su izračunati bodovi za svaku regiju na temelju njezine "uspješnosti". Konačno rangiranje čeških pokrajina potvrdilo je prevagu Praga u usporedbi s drugim područjima u zemlji. Iako je odabir dvaju pokazatelja stvorio bias tako što je umanjeno isticanje glavnog grada (visok indeks starenja zbog općeg trenda starenja u velikim urbanim područjima, te prividno statistički niska gustoća cesta zbog neusporedivosti teritorija grada s ostalim regijama), Prag je ipak postigao najviše bodova u procjeni, 432 više od drugorangirane Središnje Češke koja ga okružuje. S druge strane, Središnja Češka postigla je 380 bodova više od Južne Moravske, sljedeće regije po ostvarenom rangiranju. Ovo jasno izdvaja Prag i Središnju Češku kao "vrlo povoljne", s obzirom da je posljednja razlika u postignutim rezultatima među drugim regijama od 11 do 69 bodova, te potvrđuje hipotezu o uglavnom koncentričnom povećavanju dispariteta od glavnog grada Praga prema periferiji.

Kao što pokazuju rezultati procjene, sve tri kategorije pokazatelja upućuju na razmjernu teritorijalnu neravnotežu koja je rezultat visoke koncentracije gospodarskih aktivnosti i stanovništva na prostoru glavnog grada Praga. Općenito, velik teritorijalni disparitet između državnog središta i periferije odražava visoke nejednakosti u konkurentnosti, te rezultira u asimetričnoj alokaciji ljudskih resursa, infrastrukture i bogatstva (Kutscherauer i dr. 2010). U Češkoj je takav trend bio izraženiji tijekom 1990-ih i tranzicije prema tržišnom gospodarstvu, te se negativno odrazio na dinamiku razvoja perifernih regija. No, s integracijom Češke Republike u Europsku uniju, opći trend rastućih teritorijalnih dispariteta olakšan je kroz različite programe prekogranične suradnje (URL 8).

Zaključno, svrha ovoga istraživanja bila je dati doprinos postojećem korpusu istraživanja i radova koji se bave problematikom istraživanja regionalnih dispariteta. Odabrani skup kriterija, kao i rezultati izračuna sintetskog indeksa korištenog za njihovu procjenu te kartografske vizualizacije mogu poslužiti kao polazna točka za daljnja, detaljnija i razrađenija istraživanja čeških NUTS 3 regija, odnosno gospodarskih, infrastrukturnih i demografskih dispariteta među njima.

References / Literatura

- Amendola A, Cardeo F E, Coppola G (2004) Regional Disparities in Europe. Discussion Paper No. 78., Università degli Studi di Salerno, p. 43
- Arltová M, Langhamrová J (2010) Migration and Ageing of the Population of the Czech Republic and the EU Countries, Prague Economic Papers 19/1, 54–73
- Armstrong H W (2002) European Union Regional Policy: Reconciling the Convergence and Evaluation Evidence. Regional Convergence in the European Union (ur.: Cuadrado-Roura J, Pavellada M). Facts, Prospects and Policies, Springer-Verlag, Berlin, 231-272.
- Ellington L (2004) Eastern Europe: An Introduction to the People, Land and Culture; ABC-CLIO. P. 267
- Ezcurra R, Rapún M (2006) Regional Disparities and National Development Revisited – The Case of Western Europe, European Urban and Regional Studies, vol. 13., no. 4, 355–369
- Fan S, Kanbur R, Zhang X (2009) China's Regional Disparities: Experience and Policy, China Economic Research and Advisory Programme, pp. 39
- Gajdová K (2016) Regional Disparity in Selected Regions of the Czech Republic – With New Definition; International Journal of Economic and Statistics, vol. 4, 161–165
- Huček M (2007) Vznik a příčiny územních nerovností. Regionální disparity – Periodikum (seriálová publikace) Working Papers, č. 1 (ed. Kutscherauer A), Ostrava, 13–19
- Jílek J, Fischer J, Hindls R, Hronová S, Moravová J, Zelený M (2005) Nástin sociálněhospodářské statistiky. Oeconomica, VŠE Praha, 265
- Kahoun J (2007) Ukazatele regionální konkurenceschopnosti v České republice [online]. Working Paper CES VŠEM, 5. http://www.vsem.cz/data/data/cessoubory/working-paper/gf_WPNo507.pdf [cit. 2017-03-09]
- Kostel Z (2010) Regionalni dispariteti na području Republike Hrvatske, Završni rad (thesis), Sveučilište Jurja Dobrile u Puli
- Kutscherauer A, Fachinelli H, Hučka M, Skokan K, Sucháček J, Tománek P, Tuleja P (2010) Regional disparities in regional development of the Czech Republic – the occurrence, identification and elimination, VŠB – Technical University of Ostrava, Faculty of Economics, Ostrava, p. 120
- Kutscherauer A (2007) Východiska výzkumu regionálních disparit v územním rozvoji České Republiky. Regionální disparity – Periodikum (seriálová publikace) Working Papers, č. 1 (ed. Kutscherauer A), Ostrava, 6–12
- Magaš D (2003) Suvremeni aspekti geografske regionalizacije i upravno-teritorijalni ustroj Hrvatske, Geoadria, vol. 8, no. 1, 127–147
- Mrosek J (2013) Regionální disparity zemí Visegrádské skupiny. Diplomová práce (Mgr.) Univerzita Palackého v Olomouci, Přírodovědecká fakulta, Olomouc
- Ohlan R (2012) Pattern of Regional Disparities in Socio-economic Development in India: District Level Analysis, Social Indicators Research, Vo., 114, issue 3; 841–873
- Pejnović D (2004) Depopulacija županija i disparitet u regionalnom razvoju Hrvatske, Društvena istraživanja, Vol. 13, no. 4–5; 701–726
- Sucháček J (2007) Regional disparities in the Czech Republic in the realm of infrastructure. Regionální disparity – Periodikum (seriálová publikace) Working Papers, č. 1 (ed. Kutscherauer A), Ostrava, pp. 76
- Svatošová L (2012) The Development of Regional Disparities in Czech Republic over the 2005–2010 Years, Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis, Vol. LX, No. 7, 337–344
- Vanhove N, Klaassen L H (1987) Regional policy, a European approach, Ashgate Publishing Company, pp. 529

Sources / Izvori

- URL 1: CENSUS 2011 <https://www.czso.cz/csu/sldb> Accessed 29 May 2015
- URL 2: CENSUS 2001 https://www.czso.cz/csu/sldb/vysledky_minulych_scitani Accessed 29 May 2015
- URL 3: Czech Statistical Office, CZSO <https://www.czso.cz/> Accessed 29 May 2015
- URL 4: EUROSTAT <http://ec.europa.eu/eurostat> Accessed 29 May 2015
- URL 5: Ministerstvo Práce a Sociálních Věcí <http://www.mpsv.cz/cs/> Accessed 29 May 2015
- URL 6: Správa železniční dopravní cesty <http://www.szdc.cz/index.html> Accessed 29 May 2015
- URL 7: Ředitelství silnic a dálnic ČR <http://www.rsd.cz/> Accessed 29 May 2015
- URL 8: Investopedia <http://www.investopedia.com> Accessed 19 Feb 2017
- URL 9: Trading Economics www.tradingeconomics.com Accessed 19 Feb 2017