

Študentská vedecká aktivita

**Vyhodnotenie regionálnych rozdielov na úrovni NUTS 2 v krajinách EÚ:
vybrané sociálno-ekonomické a environmentálne aspekty**

Timotej Šagúl

Mário Moraučík

Sekcia: Verejná ekonomika a regionálny rozvoj

Konzultant: doc. Ing. Stanislav Kološta, PhD.

Banská Bystrica

2026

Abstrakt

Cieľom práce je analýza regionálnych rozdielov v krajinách Európskej únie na úrovni regiónov NUTS 2 v období pred pandémiou COVID-19 a počas tohto obdobia. V práci sa zameriavame na analýzu vývoja viacerých vybraných socio-ekonomických ukazovateľov, ktoré sú dostupné v databázach Eurostatu. Cieľom práce je zistiť, ako sa vyvíjali regionálne rozdiely medzi menej rozvinutými a viac rozvinutými regiónmi krajín Európskej únie. V analytickej časti práce sú používané štatistické metódy beta konvergenca, sigma konvergenca, variačný koeficient a metóda hlavných komponentov. Analýzou sme preukázali postupné, ale nerovnomerné znižovanie regionálnych rozdielov. Analýza potvrdila, že najvýznamnejšími faktormi regionálnych rozdielov sú ekonomická výkonnosť a vzdelanostno-sociálny faktor. Kľúčovou pri ekonomickom rozvoji regiónov je úroveň vzdelania, zamestnanosť v technologických spoločnostiach a investovanie do vedy a výskumu. Tieto opatrenia podporujú rast ekonomiky a znižujú riziko chudoby. Jedným zo zistení je tiež, že menej rozvinuté regióny sú citlivejšie na ekonomické krízy, preto je dôležité posilňovať ich pripravenosť na globálne šoky, avšak nie na úkor investícií do vzdelávania.

Kľúčové slová: regionálne rozdiely, Európska únia, NUTS 2

Abstract

The aim of the work is to analyse regional disparities in the European Union countries at the level of NUTS 2 regions in the period before the COVID-19 pandemic and during this period. In the work, we focus on analysing the development of several selected socio-economic indicators that are available in Eurostat databases. The aim of the work is to find out how regional disparities between less developed and more developed regions of the European Union countries have developed. The analytical part of the work uses statistical methods such as beta convergence, sigma convergence, coefficient of variation and principal components method. The analysis has shown a gradual but uneven reduction in regional disparities. The analysis confirmed that the most significant factors of regional disparities are economic performance and the educational-social factor. The key to the economic development of regions is the level of education, employment in technology companies and investment in science and research. These measures support economic growth and reduce the risk of poverty. One of the findings is also that less developed regions are more sensitive to economic crises, so it is important to

strengthen their preparedness for global shocks, but not at the expense of investments in education.

Key words: regional differences, European Union, NUTS 2

Úvod

Regionálne rozdiely naprieč krajinami Európskej únie (EÚ), ako súčasť ekonomického vývoja, sú prirodzené. Ak sú však regionálne rozdiely príliš veľké, môže to negatívne vplyvať na stabilitu krajiny a tiež na sociálnu súdržnosť. V prostredí EÚ sú regionálne rozdiely veľkým predmetom záujmu kvôli vplyvu na konkurencieschopnosť ekonomík členských krajín EÚ. Znižovanie rozdielov patrí medzi hlavné politiky EÚ. Výrazné regionálne nerovnosti môžu viesť k ekonomickým problémom, ako je znižovanie investícií v niektorých oblastiach, odliv pracovnej sily, vyššia nezamestnanosť a pod.

V práci sa zaoberáme analýzou regionálnych rozdielov v hrubom domácom produkte (HDP) a vybraných sociálno-ekonomických ukazovateľoch v regiónoch NUTS 2. Údaje, ktoré používame, sú verejne dostupné v databázach Eurostatu. Hlavným cieľom práce je zistiť vývoj regionálnych rozdielov založených na vybraných sociálno-ekonomických ukazovateľoch v období pred pandémiou COVID-19, počas pandémie COVID-19 a po pandémii COVID-19 a následne v závere práce navrhnúť opatrenia, ktoré môžu viesť k rovnomernejšiemu rozvoju regiónov bez znižovania životnej úrovne v iných regiónoch.

K dosiahnutiu cieľa a na vyhodnocovanie regionálnych rozdielov používame viaceré analytické a štatistické metódy. V analytickej časti beta konvergenciu a sigma konvergenciu, variačný koeficient, metódu hlavných komponentov (Principal Component Analysis – PCA). V ďalšej časti výskumu tejto oblasti plánujeme vyhodnotenie prostredníctvom kompozitného indexu.

1. Teoretické vymedzenie a metodológia

Na analýzu štruktúry regionálnych rozdielov bola použitá PCA realizovaná v štatistickom softvéri IBM SPSS Statistics 26. PCA bola využitá na redukciiu dimenzionality pôvodného súboru indikátorov a na identifikáciu latentných faktorov, ktoré vysvetľujú spoločnú variabilitu sledovaných sociálno-ekonomických a environmentálnych ukazovateľov.

Zmyslom aplikácie PCA bolo získať menší počet vzájomne nezávislých komponentov, ktoré reprezentujú základné dimenzie regionálnej diferenciácie, a tým umožniť komplexnejšie

hodnotenie rozdielov medzi regiónmi pred pandémiou, počas pandémie a po pandémii. Extrakcia komponentov bola uskutočnená na základe korelačnej matice s použitím Varimax rotácie pre zvýšenie interpretovateľnosti faktorovej štruktúry.

1.1. Nomenclature of Units for Territorial Statistics 2

Nomenclature of Units for Territorial Statistics (NUTS) predstavuje systém štatistických územných jednotiek vytvorených EÚ. Cieľom vytvorenia NUTS bolo zjednotenie geografického rozdelenia štátov EÚ pre potreby štatistického zberu, analýz a plánovania politík. NUTS umožňuje porovnateľné a konzistentné hodnotenie regionálnych údajov, čo je dôležité pre efektívne plánovanie a implementáciu regionálnych politík EÚ. Systém NUTS má tri hlavné úrovne, ktoré reprezentujú rôzne veľké územné celky / regióny. Úroveň NUTS 2 používaná v práci sa využíva na pridelovanie štrukturálnych a investičných fondov EÚ, ktorých cieľom je podporiť regionálny rozvoj, znížiť ekonomické a sociálne rozdiely medzi regiónmi a posilniť súdržnosť v rámci EÚ (Šagúl, Moraučík, 2025).

Regióny NUTS 2 sú definované na základe počtu obyvateľov, pričom ich optimálna veľkosť je medzi 800 000 a 3 000 000 obyvateľov. NUTS 2 zabezpečuje jednotnosť a kompatibilitu medzi jednotlivými štátmi a umožňuje presné meranie sociálno-ekonomických ukazovateľov. V práci analyzujeme 242 regiónov v rámci všetkých členských krajín EÚ. Systém NUTS 2 predstavuje efektívny nástroj nielen na štatistické merania, ale aj na praktickú aplikáciu pri plánovaní politík, ktoré majú za cieľ zlepšiť životné podmienky obyvateľov v rôznych regiónoch EÚ. V analytickej časti práce sa venujeme podrobnej analýze vybraných ukazovateľov v regiónoch NUTS 2.

1.2. Beta a sigma konvergencia

Konvergencia predstavuje ekonomicko-štatistický koncept, používaný na hodnotenie rozdielov HDP na jedného obyvateľa. Pri analýze vývoja HDP používame dva typy konvergenzie – beta a sigma konvergenciu. Zatiaľ čo koncept beta konvergenzie umožňuje posúdiť, či chudobnejšie regióny dohánajú bohatšie, sigma konvergencia slúži na zhodnotenie dosiahnutého stupňa konvergenzie naprieč regiónmi a časom (Babický, Komárek, 2020). Ak regióny s nižšími príjmami dosahujú rýchlejšiu rast ako bohatšie regióny, dochádza k beta konvergencii, čo naznačuje postupné zmenšovanie rozdielov a dobiehanie bohatších regiónov chudobnejšími (Young, Higgins, Levy, 2008).

Koncepciu beta konvergenzie navrhli Barro (1984), Baumol (1986). Vyjadruje predpoklad, že chudobné regióny majú tendenciu v úrovni národného dôchodku na obyvateľa

dostihovať regióny bohaté. Barro, Sala-i-Martin (2004, s. 467) absolútnu β -konvergenciu vyjadrili regresnou rovnicou:

$$(1/T) \cdot \ln(y_{iT} / y_{i0}) = a - [(1 - e^{\beta T}) / T] \ln(y_{i0}) + \omega_{i0,T}, \quad (1)$$

kde ľavá strana rovnice predstavuje priemerné tempo rastu HDP na obyvateľa v čase 0 až T; a je úroveň HDP na obyvateľa, ktorý sa považuje za rovnaký pre všetky regionálne ekonomiky. Regresný koeficient rastu (β_2) je vyjadrený vzťahom $[(1 - e^{\beta T}) / T]$ na počiatočnej úrovni HDP na obyvateľa (y_{i0}). $\omega_{i0,T}$ reprezentuje chybu medzi časovými obdobiami 0 až T. Štatistickú významnosť parametrov a , b nám určuje hodnota p-value, ktorá by mala byť čo najnižšia (štandardne pod 0,05). Na výpočet rýchlosti konvergenzie použijeme odvodený vzťah pre β z (1) (Kološta et al., 2007):

$$\beta = \frac{-\ln(1 - \beta_2 \cdot T)}{T} \quad (2)$$

Na výpočet času potrebného na zníženie rozdielov vyskytujúcich sa v súbore skúmaných entít na polovicu – obdobie polčasu konvergenzie (half-life) sa používa index polčasu rozpadu (Gaczek, Kisiała, 2017):

$$hl = (\ln 2) / \beta \quad (3)$$

Na druhej strane k sigma konvergencii dochádza, ak rozptyl príjmov meraný štandardnou odchýlkou logaritmu HDP na obyvateľa v rámci určitej skupiny krajín časom klesá. Pri absencii šokov v príjme na obyvateľa a pri spoločnom rovnovážnom stave má beta konvergenca tendenciu vyústiť do sigma konvergenzie (Countinho, Turini, 2019).

Sigma konvergenca označuje zmenšovanie rozdielov v príjmoch medzi regiónmi alebo ekonomikami v priebehu času. Sigma konvergenca hodnotí celkovú distribúciu príjmov a to, či sa nerovnosti medzi regiónmi znižujú. Tento jav je ovplyvnený tempom rastu príjmov, ale aj externými faktormi, ktoré môžu zasiahnuť rozloženie bohatstva.

Pre sigma konvergenciu platí, že $s_0^2 > s_t^2$ (smerodajná odchýlka logaritmov HDP na obyvateľa v čase klesá). Smerodajná odchýlka je vyjadrená vzťahom (Hindls, Hronová, Seger, 2004):

$$s_x = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n - 1}} \quad (4)$$

,kde n je počet sledovaných rokov; x_i vyjadruje HDP na obyvateľa v danom roku; $\bar{x}$ je priemerná hodnota HDP na obyvateľa v skúmanom časovom období.

Koncepty beta a sigma konvergenzie použili Magazzino a Mele (2022), ktorí testovali konvergenciu medzi ázijskými krajinami, čím dospeli k záveru, že existujú dôkazy o konvergencii medzi ekonomikami vybraných ázijských krajín, čo naznačuje, že rozdiely v príjmoch sa v priebehu času zmenšovali. Autori tiež uviedli, že medzi krajinami sa variabilita príjmov znižuje, čo je ďalším z indikátorov konvergenzie.

Soukup a Soukupová (2021) použili beta a sigma konvergenciu na zisťovanie rozdielov krajín V4 v porovnaní s priemerom EÚ. Zameriavali sa na HDP na obyvateľa a dospeli k zisteniu, že medzi rokmi 1992 až 2019 krajiny V4 zaznamenali vyšší rast HDP v porovnaní s tými krajinami, ktoré mali vysoký rast HDP na začiatku sledovaného obdobia. V nimi sledovanom období sa krajiny V4 približovali k priemeru EÚ a rozdiely medzi nimi sa postupne znižovali.

1.3. Variačný koeficient

Variačný koeficient predstavuje mieru relatívneho rozptylu (Dodge, 2008). Koeficient sa používa na porovnanie rozptylov kvantitatívnych premenných, ktoré nie sú vyjadrené v rovnakých jednotkách (napríklad mzdy v rôznych menách), alebo rozptylov premenných, ktoré majú veľmi odlišné priemery. Variačný koeficient (δ) predstavuje relatívnu mieru variability alebo neistoty v údajoch (Arora, 2012).

Výpočet variačného koeficienta uviedli Hingls, Hronová a Seger (2004):

$$V = 100 \cdot \left(\frac{\sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}}}{\bar{x}} \right); 0 \leq V < \infty, \quad (5)$$

Variačný koeficient je percentuálny ukazovateľ, čo umožňuje jednoduché porovnanie miery rozptylu medzi rôznymi dátovými súbormi bez ohľadu na ich jednotky. Poskytuje informáciu o miere odlišností hodnôt od priemeru vo vzťahu k veľkosti samotného priemeru.

Variačný koeficient slúži na:

- Porovnateľnosť: umožňuje porovnávať variabilitu rôznych dátových súborov, aj keď majú rozdielne jednotky alebo veľkosti. Napríklad, ak porovnávame variabilitu cien akcií a variabilitu ročných výnosov, koeficient variačnosti zabezpečí, že rozdielne jednotky (eurá vs. percentá) neovplyvnia výsledok.

- Miera neistoty: v štatistike a pravdepodobnosti slúži na posúdenie miery neistoty v predikciách alebo modeloch. Nižšia hodnota δ naznačuje menšiu neistotu a väčšiu konzistenciu údajov, zatiaľ čo vyššia hodnota znamená väčšiu variabilitu.
- Relatívna variabilita: koeficient variačnosti poskytuje informáciu o tom, ako veľmi sa hodnoty odlišujú od priemeru vo vzťahu k veľkosti samotného priemeru.

1.4. Metóda hlavných komponentov PCA

PCA patrí do skupiny metód zameraných na analýzu skrytých vzťahov medzi premennými (Stankovičová, Vojtková, 2007). Cieľom metódy PCA je transformovať vstupné viacrozmerné údaje tak, aby sa na výstupe získali údaje najdôležitejších lineárnych smerov, pričom sa zanedbávajú najmenej podstatné smery (Kráľ et al., 2009) so zámerom vysvetliť maximum variability dát. Preferujú sa údaje, ktoré medzi sebou korelujú (Mishra, 2007), s čím sa často stretávame pri skúmaní rôznych oblastí aj v rámci regionálnych politík (Kološta, 2022). Váhy priradené k získaným novovytvoreným premenným sa používajú na zostavenie kompozitného ukazovateľa (indexu) (Nicoletti et al., 2000). Výsledný agregovaný index by mal byť lineárnou kombináciou pôvodných ukazovateľov:

$$I = c_1In1 + c_2In2 + \dots + c_{10}In10 \quad (6)$$

Po extrakcii faktorov sa často používa rotácia faktorovej štruktúry, ktorej cieľom je zlepšiť interpretovateľnosť výsledkov. Podľa Hair et al. (2019) môžu mať premenné bez rotácie podobné záťaž na viacerých faktoroch, čo komplikuje interpretáciu výsledkov. Jednou z najčastejšie používaných rotačných metód je varimax rotácia, ktorú navrhol v roku 1958 Kaiser. Ide o ortogonálnu rotáciu, ktorá zachováva nekorelovanosť faktorov a zároveň maximalizuje variabilitu štvorcov faktorových záťaží v rámci jednotlivých faktorov.

Rotaru et al. (2024) s použitím korelačnej matice a analýzy hlavných komponentov identifikovali faktory regionálneho rozvoja v Rumunsku. Analyzovali sociálno-ekonomické indikátory (mzdy, HDP, zamestnanosť, zdravotníctvo) a redukovali ich do niekoľkých hlavných komponentov, ktoré vysvetľujú regionálne disparity. Lubyová a Vojtková (2014) využili PCA pri členení vybraných krajín z hľadiska otvorenosti ekonomík. Použité metódy im umožnili zostaviť dve skupiny krajín podľa nimi vybraných ukazovateľov – otvorené ekonomiky a uzavreté ekonomiky.

Hooda et al. (2017) sa pokúsili identifikovať hlavné poľnohospodárske a sociálno-ekonomické faktory v indickom meste Harijána pomocou PCA. Pôvodný súbor premenných transformovali na menší súbor lineárnych kombinácií, ktoré zodpovedajú za väčšinu variácie

pôvodných údajov. Štúdia sa uskutočnila počas troch období, 1991-1992, 2001-2002 a 2011-2012. Okres bol považovaný za jednotku analýzy a analýzu založili na 19 ukazovateľoch z poľnohospodárskeho sektora a 9 ukazovateľoch zo sociálno-ekonomického sektora. Výsledkom je identifikácia hlavných faktorov vysvetľujúcich regionálne disparity.

Chikhladze et al. (2022) využili PCA a tvorbu kompozitného indexu regionálnych rozdielov pri pokuse identifikovať zhľady regiónov podľa matematických výpočtov vrátane rozlíšenia pólov rastu, menej rozvinutých a depresívnych regiónov strednej zóny; určiť stupeň disparity pri klasifikácii z hľadiska fáz divergencie: prípady diferenciácie, asymetrie a polarizácie; zoradiť regióny podľa ich podielu na tejto divergencii; analyzovať, ako sa úroveň divergencie mení v priebehu času pozorovaním dynamiky ukazovateľov.


2. Analýza rozdielov v krajinách EÚ

V krajinách EÚ je stále prítomná dichotómia medzi dynamicky sa rozvíjajúcimi veľkými mestskými aglomeráciami a nerozvinutými industrializovanými odľahlými regiónmi. Pri mnohých malých či stredne veľkých mestách zameraných najmä na výrobu je zaznamenávaný pokles zamestnanosti a príjmov. Naopak, veľké metropolitné oblasti, ktoré zaznamenali úpadok v období 60. až 80. rokov, patria aktuálne k najdynamickejším miestam, pokiaľ ide o príjmy a dostupnosť pracovných miest. Technologický pokrok a inovácie v 70. rokoch minulého storočia viedli ku koncentrácii technológií a znalostných sektorov do metropolitných oblastí, čo viedlo k migrácii vzdelaného obyvateľstva z menších miest práve do týchto oblastí (Rodríguez-Pose et al., 2018). V EÚ je dlhodobo aktuálna téma vyrovnávania regionálnych rozdielov. Tieto sú veľkým problémom, avšak je potrebné ich znižovať bez dôsledku spomalenia rozvoja v stále rýchlo rastúcich metropolitných oblastiach.

2.1 Hrubý domáci produkt

HDP Európska komisia (2025) vysvetľuje ako „súčet všetkých pridaných hodnôt vytvorených v ekonomike. Pridanou hodnotou sa rozumie hodnota vyrobených tovarov a služieb mínus hodnota tovarov a služieb potrebných na ich výrobu, tzv. medzispotreba“. Obrázok 1 znázorňuje výšku HDP na jedného obyvateľa po úprave podľa parity kúpnej sily v roku 2024. Na prvom mieste sa nachádza región Eastern and Midland v Írsku, následne Luxembursko. Na opačnej strane rebríčka sú francúzske regióny ležiace mimo Európy – Mayotte a Guyane, z kontinentálnych regiónov Severozapaden v Bulharsku.

HDP na obyvateľa v regiónoch NUTS 2 2024 (EUR)





Obrázok 1 Hrubý domáci produkt na jedného obyvateľa v regiónoch NUTS 2 v roku 2024 (EUR)

Zdroj: Vlastné spracovanie podľa dát Eurostatu

Obrázok 2 znázorňuje zmenu HDP na obyvateľa v sledovanom období 2014-2024. Najtmavšie regióny sa rozvíjali v sledovanom období najrýchlejšie a ich rozvoj predstavoval najvyššie percento. Naopak najsvetlejšie regióny sa rozvíjali najpomalšie. Toto zobrazenie nám predpovedá predpoklad beta a sigma konvergenzie. Z grafu vyplýva, že regióny, s vyšším HDP na začiatku obdobia rástli pomalšie a naopak. Samostatnú kategóriu tvoria regióny v Írsku, kde je vysoký rast HDP aj napriek tomu, že patria k veľmi rozvinutým. FitzGerald (2015) vysvetlil, že vysoké HDP v írskych regiónoch je spôsobené najmä presunom nadnárodných firiem do Írska kvôli nízkej dani z príjmov právnických osôb. Veľké technologické a farmaceutické firmy registrujú duševné vlastníctvo v Írsku, kde vykazujú produkciu, aj keď reálna výroba alebo predaj prebieha inde. Výsledkom je, že HDP na obyvateľa v írskych regiónoch je umelo nadhodnotené.

Zmena HDP na obyvateľa v regiónoch NUTS 2 medzi rokmi 2014 - 2024 (%)


Zmena HDP na obyvateľa 2014 - 2024 (%)



Obrázok 2 Zmena hrubého domáceho produktu v regiónoch NUTS 2 medzi rokmi 2014 a 2024 (%)

Zdroj: Vlastné spracovanie podľa dát Eurostatu

Graf 1 znázorňuje postupné znižovanie rozdielov v ekonomickej výkonnosti medzi regiónmi členských štátov EÚ. Trendová spojica naznačuje vývoj znižovania regionálnych rozdielov v sledovanom období, čo znamená, že regióny s nižším hrubým domácim produktom dosahovali v tomto období vyšší rast, než regióny s vyšším hrubým domácim produktom, čo naznačuje proces ekonomickej konvergenzie, pri ktorom menej rozvinuté regióny postupne dobiehajú tie vyspelejšie. Výsledky podporujú koncept beta konvergenzie, ktorý predpokladá, že ekonomiky s nižším počiatočným príjmom majú tendenciu rásť rýchlejšie ako bohatšie regióny. Pokračovanie tohto trendu by mohlo viesť k vyrovnanejšiemu ekonomickému rozvoju v rámci EÚ a k posilneniu hospodárskej stability na úrovni celého regiónu.




Graf č. 1 Zmena regionálnych rozdielov v raste HDP na obyvateľa v regiónoch NUTS 2 (2015- 2024)
Zdroj: Vlastné spracovanie podľa Eurostatu

Podľa rovnice $y = - 0,0162x + 0,2045$ možno určiť medziročné tempo znižovania regionálnych rozdielov na približne 1,5 %; čo predstavuje miernu konvergenciu. Výsledky regresnej analýzy (Príloha 1) potvrdzujú existenciu β -konverencie medzi regiónmi NUTS 2 v sledovanom období. Koeficient pri logaritme počiatočného HDP na obyvateľa je negatívny a štatisticky významný ($p\text{-value} < 0,001$). Počas konverencie, teda obdobie potrebné na zníženie rozdielov na polovicu, je približne 46 rokov.

Dáta v grafe 2 poukazujú na pokles štandardnej odchýlky hrubého domáceho produktu na obyvateľa v regiónoch NUTS 2 v sledovanom období, čo predstavuje zmenšovanie rozdielov medzi jednotlivými regiónmi. Tento trend podporuje teóriu sigma konverencie, podľa ktorej zníženie variability príjmov odráža zbližovanie ekonomických podmienok v regióne. Zníženie štandardnej odchýlky môže byť spôsobené rýchlejším ekonomickým rastom menej rozvinutých krajín v porovnaní s rozvinutejšími regiónmi.

Cieľ, ktorý sa postupne EÚ darí naplňať, je ovplyvnený aj inými faktormi, ako sú efektívne hospodárenie, investície do infraštruktúry, vzdelávania či zdravotníctva. V dlhodobom horizonte môže pokračovanie trendu viesť k väčšej rovnováhe v hospodárskom rozvoji regiónov a zlepšeniu celkovej ekonomickej stability v EÚ. Ak si menej rozvinuté krajiny zachovávajú tempo dobiehania bohatších regiónov, môže to znamenať postupnú ekonomickú integráciu a približovanie sa k európskemu priemeru. Tento jav má významné implikácie pre

tvorbu politík, zameraných na podporu rovnomerného rozvoja a minimalizáciu regionálnych rozdielov v EÚ.



Graf č.2 Vývoj štandardnej odchýlky HDP na obyvateľa regiónoch NUTS 2 (2015 - 2024)
Zdroj: Vlastné spracovanie podľa Eurostatu

2.2 Vybrané sociálno-ekonomické ukazovatele

Graf vývoja variačného koeficientu vyjadruje postupné znižovanie alebo zväčšovanie rozdielov v regiónoch a jeho mieru. Aj keď pri niektorých ukazovateľoch môže vyzeráť, že sa rozdiely medzi regiónmi naozaj zmenšujú, niektoré z regiónov v daných ukazovateľoch nezaznamenali zlepšenie, alebo sa ich situácia zhoršila.

Graf 3 znázorňuje vývoj variačného koeficientu disponibilného príjmu v regiónoch NUTS 2. Od začiatku sledovaného obdobia vidno postupné znižovanie regionálnych rozdielov. Približovanie menej rozvinutých krajín k rozvinutejším sa v roku 2022, koncom pandemickej krízy, zrýchlilo. Najvýraznejší nárast disponibilných príjmov bol zaznamenaný v rumunskom regióne București-Ilfov, kde bol počas sledovaného obdobia zaznamenaný nárast o viac ako 125 % (zo 4 700 eur ročne na 10 600 eur ročne). Najnižší nárast zaznamenal región Dytiki Makedonia v Grécku, kde bol disponibilný ročný príjem v roku 2015 na úrovni 13 300 eur a v roku 2024 14 100. V tomto regióne však bol zaznamenaný znateľný pokles v roku 2018.


Ako ďalšie môžeme na grafe 3 vidieť vývoj variačného koeficientu zamestnanosti v technologických (high-tech) spoločnostiach. Zamestnanosť v týchto odvetviach významne koreluje s vyšším príjmom aj s vyšším HDP regiónov a patrí k významným ukazovateľom mapujúcim rozvinutosť regiónov. Počas celého sledovaného obdobia sa rozdiely v regiónoch EÚ pomerne jednoznačne zvyšovali až do roku 2021, kedy začali rozdiely klesať. Kým v regiónoch hlavných miest miera zamestnanosti v high-tech spoločnostiach dosahuje vyššie

čísla, napr. Bratislavský kraj 14,1 %; Budapešť 13 %; Grad Zagreb a Praha 12 %; v regiónoch Sud-Est či Thessalia nedosahuje ani 1 %.

Podľa Pencavela (2014) vzťah medzi počtom odpracovaných hodín a výstupom je nelineárny. Pri nižšom počte hodín je produkcia približne úmerná odpracovanému času. Avšak po prekročení určitej hranice sa produktivita zvyšuje stále pomalšie. Veľmi dlhé pracovné hodiny totiž môžu viesť k nižšej efektívnosti, nárastu chýb a vyššiemu riziku úrazov. K záveru, že s narastajúcim počtom odpracovaných hodín sa efektívnosť práce znižuje, dospeli aj Collewet a Sauermann (2018).

Napriek viacerým štúdiám, ktoré prišli so záverom, že narastajúci počet pracovných hodín zvyšuje efektívnosť len do istej miery, sú stále rozdiely v počte odpracovaných hodín za týždeň v rôznych regiónoch veľké. Kým vo väčšine regiónov EÚ sa priemerný odpracovaný čas zamestnanca znižuje, v priemere o približne 30 minút, najmä v regiónoch Švédska a Holandska sa priemerný odpracovaný čas zvyšuje. Na grafe 3 je znázornené znižovanie rozdielov. Kým v roku 2015 bol rozdiel medzi regiónom s najvyšším pracovným časom a najnižším pracovným časom viac 20,5 hodiny za týždeň, v roku 2024 sa tento rozdiel znížil na 15,3 hodiny týždenne.

Na grafe 3 možno pozorovať vývoj rizika chudobnosti v regiónoch. Až do roku 2021 sa rozdiely v ohrození chudoby znižovali. Počas pandémie nastalo postupné zvyšovanie rozdielov. V sledovanom období sa situácia najviac zlepšila v rumunských regiónoch, ale aj v bohatších regiónoch v Rakúsku, zatiaľ čo regióny Východné Slovensko alebo Strední Čechy zaznamenali zhoršenie.



Graf 3 Vývoj variačného koeficientu disponibilného príjmu, zamestnanosti v high-tech odvetviach, priemerný počet odpracovaných hodín a ohrozenie chudobou v regiónoch NUTS 2 v percentách


Zdroj: Vlastné spracovanie podľa Eurostatu

Graf 4 znázorňuje vývoj variačného koeficientu pre dáta o predčasne ukončenom štúdiu. Variačný koeficient v tomto ukazovateli zaznamenáva klesajúci trend. Nárast obyvateľov, ktorí skončia školu skôr ako získajú vzdelanie, možno pozorovať najmä v niektorých regiónoch Nemecka, Švédska a Českej republiky a naopak najväčší pokles v regiónoch Grécka, Španielska a Portugalska.

Mnohé európske regióny čelia vyludňovaniu a odlivu ľudí, ktorí sa koncentrujú v metropolitných oblastiach, čoho dôsledkom je pokles pracovnej sily v slabších regiónoch. Dôsledkom je nižšia zamestnanosť, ktorá bráni ďalšiemu rozvoju regiónu. Potvrďuje to graf 4, podľa ktorého regióny EÚ zaznamenali do začiatku pandémie COVID-19 veľké zmeny medzi regiónmi. V dôsledku pandémie zmeny poklesli a od skončenia pandémie až po 2024 nebol zaznamenaný opätovný nárast týchto rozdielov. Táto problematika si určite zaslúži ďalšie skúmanie a zisťovanie dôvodov, ktorým však detailne táto práca venovaná nie je.

Graf 4 taktiež zaznamenáva vývoj variačného koeficientu produkcie skleníkových plynov. Jednou z hlavných politík presadzovaných EÚ je boj proti zvyšovaniu emisií skleníkových plynov. Niektoré regióny produkujú viac emisií, čo možno odôvodniť hospodárskou štruktúrou viac zameranou na priemysel.


Od roku 2013 sa EÚ až do vypuknutia pandémie darilo tieto rozdiely znižovať pomerne úspešne. Od obdobia pandémie sa však regióny opätovne začali od seba vzdďaľovať, čo vrátilo v tomto boji EÚ na úroveň regionálnych rozdielov z roku 2018 a sú extrémne vysoké. Rovnako ako počet odpracovaných hodín, aj táto problematika otvára priestor sa hlbšiu analýzu príčin opätovného zvyšovania regionálnych rozdielov.



Graf č. 4 Vývoj variačného koeficientu predčasného ukončenia štúdia, produkcie skleníkových plynov a populácie v regiónoch NUTS 2 v percentách
Zdroj: Vlastné spracovanie podľa Eurostatu

Existuje štatisticky významná korelácia medzi výdavkami na vedu a výskum a zamestnanosťou v high-tech spoločnostiach. Vyššie výdavky na vedu a výskum štatisticky vedú k vyššej životnej úrovni, vyššej zamestnanosti aj k nižšiemu ohrozeniu chudobou. V sledovanom období však vidíme stagnáciu. Regióny, ktoré sú pri výdavkoch na vedu a výskum pod priemerom EÚ nedobiehajú vyspelejšie regióny (graf 5).

Významnú časť celkovej ekonomiky EÚ tiež tvorí cestovný ruch. Podľa Paci a Marrocu (2014) je regionálny rast pozitívne ovplyvnený domácim aj medzinárodným cestovným ruchom. V roku 2019, rok pred pandémiou, podľa Eurostatu (2023) bola pridaná hodnota cestovného ruchu v EÚ 572 miliárd eur. Počet prenocovaní zahraničných turistov v regiónoch EÚ je veľmi rozdielny. Rozdiely v popularite turistických destinácií sa až do začiatku pandémie mierne zvyšovali, z pomedzi skúmaných ukazovateľov sú najvyššie. Po pandémii je vývoj stabilný, no chudobnejšie regióny sa stále významne nepribližujú k tým rozvinutejším.



Graf č. 5 Vývoj variačného počtu prenocovaní zahraničných turistov a výdavkov na vedu a výskum v regiónoch NUTS 2 v percentách

Zdroj: Vlastné spracovanie podľa Eurostatu

2.3. Aplikácia metódy hlavných komponentov

Pred realizáciou PCA sme sa zamerali na aplikáciu korelačnej analýzy s cieľom overiť existenciu vzájomných vzťahov medzi analyzovanými premennými. Korelačná matica umožňuje identifikovať silu a smer vzťahov medzi jednotlivými ukazovateľmi a zároveň posúdiť, či sú medzi nimi dostatočné korelácie, ktoré sú nutné pre aplikáciu tejto metódy. Ak medzi premennými neexistujú významné korelácie, použitie by nebolo opodstatnené. Korelačná analýza bola realizovaná pre tri časové obdobia – pred pandémiou COVID-19, počas

pandémie a po pandémii (Prílohy 2, 3 a 4). Na analýzu vzťahov medzi premennými bol použitý Pearsonov korelačný koeficient, pričom štatistická významnosť bola posudzovaná na hladine 95 % ($p\text{-value} = 0,05$).

- V období pred pandémiou COVID-19 bola zaznamenaná významná pozitívna korelácia medzi HDP a čistým disponibilným príjmom ($r = 0,791$; $p\text{-value} < 0,001$) a medzi HDP a zamestnanosťou v high-tech odvetviach ($r = 0,633$; $p\text{-value} < 0,001$). Zároveň sa potvrdil negatívny vzťah medzi HDP a rizikom chudoby ($r = -0,517$; $p\text{-value} < 0,001$).

- V období počas pandémie COVID-19 sa preukázala silná pozitívna korelácia medzi HDP a zamestnanosťou v high-tech odvetviach ($r = 0,687$; $p\text{-value} < 0,001$) a medzi HDP a čistým disponibilným príjmom ($r = 0,738$; $p\text{-value} < 0,001$), pričom bol identifikovaný aj negatívny vzťah medzi HDP a rizikom chudoby ($r = -0,464$; $p\text{-value} < 0,001$).

- V období po pandémii COVID-19 bola zistená napríklad významná pozitívna korelácia medzi HDP a emisiami skleníkových plynov ($r = 0,621$; $p\text{-value} < 0,001$), ako aj medzi výdavkami na výskum a vývoj a zamestnanosťou v high-tech odvetviach ($r = 0,999$; $p\text{-value} < 0,001$).

Na identifikáciu hlavných faktorov regionálnych rozdielov medzi regiónmi EÚ sme použili PCA. Cieľom metódy bolo zredukovať väčší počet sledovaných sociálno-ekonomických ukazovateľov na menší počet latentných faktorov, ktoré reprezentujú základné dimenzie regionálneho rozvoja. Analýza bola realizovaná pre tri časové obdobia: obdobie pred, počas a po pandémii COVID-19. Takéto porovnanie umožňuje identifikovať, či pandémia ovplyvnila štruktúru regionálnych rozdielov v regiónoch NUTS 2.

Do analýzy boli zahrnuté ukazovatele charakterizujúce ekonomickú výkonnosť regiónov, sociálnu situáciu, vzdelanosť obyvateľstva, environmentálne zaťaženie a cestovný ruch. Konkrétne išlo o ukazovatele HDP, počet prenocovaní zahraničných turistov, podiel zamestnancov v high-tech odvetviach, riziko chudoby, populácia regiónu, emisie skleníkových plynov, výdavky na vedu a výskum, podiel osôb predčasne opúšťajúcich vzdelávací systém, čistý disponibilný príjem domácností, podiel vysokoškolsky vzdelaných obyvateľov a priemerný počet odpracovaných hodín.

Vo všetkých prípadoch bola použitá metóda PCA s využitím rotácie Varimax. Vhodnosť dát bola overená pomocou Kaiser-Meyer-Olkinovho testu (KMO) pre každé analyzované obdobie samostatne (pred COVID-19, počas COVID-19 a po COVID-19). KMO test hodnotí mieru korelácií medzi premennými a vhodnosť dát pre faktorovú analýzu. Minimálna akceptovateľná hodnota KMO je 0,50 (Naseer et al., 2019). Vhodnosť dát bola taktiež pri každom období overená pomocou Bartlettovho testu sféricity, ktorý testuje, či je korelačná

matica štatisticky významná, pričom štatisticky významný výsledok testu je $p\text{-value} < 0,05$ (Sigudla, Maritz, 2023). Tabuľky v prílohách.

KMO Value	Level of Acceptance
Above 0.90	Superb
0.80 to 0.90	Great
0.70 to 0.80	Good
0.50 to 0.70	Mediocre
Below 0.50	Unacceptable

Tabuľka 1 Kaiser-Meyer-Olkinov test
Zdroj: Naseer et al. (2019)

PCA – obdobie pred pandémiou COVID-19

Toto obdobie predstavujú roky 2016-2019. Hodnota KMO testu dosiahla približne 0,56; čo predstavuje nižšiu, ale stále akceptovateľnú úroveň vhodnosti dát. Bartlettov test sféricity bol štatisticky významný ($p\text{-value} < 0,001$).

Analýza poskytla štyri faktory, ktoré spolu vysvetľujú približne 82 % variability sledovaných premenných. Prvý identifikovaný faktor má podobu ekonomicko-technologického faktoru. Pod prvý faktor môžeme zaradiť premenné spojené so zamestnanosťou v high-tech odvetviach, ekonomickou aktivitou a environmentálnymi dôsledkami priemyselnej výroby. Druhý faktor predstavuje faktor cestovného ruchu, ktorý je charakterizovaný najmä premennou počet prenocovaní zahraničných turistov. Tento faktor slúži na poukázanie významu turistického sektora v regionálnom rozvoji pred vypuknutím pandémie COVID-19. Tretí faktor možno interpretovať ako sociálno-demografický, ktorý zahŕňa premenné súvisiace s veľkosťou populácie a sociálnou situáciou obyvateľstva. Štvrtý faktor predstavuje vzdelanostnú štruktúru regionálneho rozvoja, ktorá je charakterizovaná najmä podielom vysokoškolsky vzdelaných obyvateľov.

PCA – obdobie počas pandémie COVID-19

Analyzované obdobie rokov 2020 až 2022. Hodnota KMO testu dosiahla hodnotu približne 0,67; čo predstavuje strednú úroveň vhodnosti dát pre faktorovú analýzu. Bartlettov test sféricity bol štatisticky významný ($p\text{-value} < 0,001$), čo potvrdzuje existenciu korelácií medzi analyzovanými premennými. V tomto období sa vyskytujú štyri faktory, ktoré spolu vysvetľujú približne 78 % variability sledovaných ukazovateľov.

Prvý faktor vysvetľuje približne 35 % variability a môžeme ho interpretovať ako faktor ekonomickej výkonnosti a životnej úrovne regiónov. Tento faktor zahŕňa sledované premenné ako HDP, čistý disponibilný príjem domácností, výdavky na vedu a výskum a zamestnanosť v

high-tech odvetviach. Tento faktor nám teda naznačuje, že ekonomicky rozvinutejšie regióny sa vyznačujú vyššími príjmami, vyššími investíciami do výskumu a vývoja a zároveň nižšou mierou chudoby. Druhý faktor môžeme interpretovať ako sociálno-vzdelanostný faktor. Tento faktor je charakterizovaný najmä premennými súvisiacimi s úrovňou vzdelania obyvateľstva a predčasným ukončením vzdelávania. Regióny s vyšším podielom vysokoškolsky vzdelaných obyvateľov vykazujú zároveň nižší podiel osôb predčasne opúšťajúcich vzdelávací systém a taktiež nižšiu mieru sociálneho rizika. Tretí faktor je demograficko-environmentálny. Najvyššie faktorové záťaže boli zaznamenané pri premenných populácia a emisie skleníkových plynov. Tento faktor poukazuje na súvislosť medzi veľkosťou regiónu, intenzitou ekonomickej aktivity a environmentálnym zaťažením. Štvrtý faktor môžeme interpretovať ako faktor cestovného ruchu. Tento faktor je charakterizovaný ukazovateľom počtu prenocovaní zahraničných turistov. Význam tohto faktora poukazuje na úlohu turistického sektora v regionálnej ekonomike aj počas krízového obdobia COVID-19.

PCA – obdobie po pandémii COVID-19

Obdobie po pandémii COVID-19 zahŕňa roky 2022-2023, resp. 2024 podľa dostupných údajov. Hodnota KMO testu dosiahla približne 0,67 a Bartlettov test sféricity bol opäť štatisticky významný ($p\text{-value} < 0,001$), čo potvrdzuje vhodnosť dát pre faktorovú analýzu aj v tomto poslednom sledovanom období.

V tomto období boli na rozdiel od predchádzajúcich identifikované len tri hlavné faktory, ktoré spolu vysvetľujú približne 72 % variability sledovaných premenných. Tento rozdiel v počte faktorov je pravdepodobne spôsobený absenciou dát v poslednom sledovanom období. Išlo o dáta o priemernom počte odpracovaných hodín, ktoré v dobe písania práce neboli dostupné.

Prvý faktor môžeme interpretovať ako faktor ekonomickej výkonnosti regiónov. Tento zahŕňa premenné HDP, výdavky na vedu a výskum, čistý disponibilný príjem domácností a zamestnanosť v high-tech odvetviach. Výsledok naznačuje, že ekonomická výkonnosť zostáva dominantným determinantom regionálnych rozdielov aj po skončení krízového obdobia. Druhý faktor predstavuje faktor vzdelanosti a sociálnej situácie obyvateľstva. Významné faktorové záťaže vykazujú premenné podiel vysokoškolsky vzdelaných obyvateľov, predčasné opustenie vzdelávacieho systému a riziko chudoby. Faktor poukazuje na význam ľudského kapitálu a vzdelanostnej úrovne populácie pre regionálny rozvoj. Tretí faktor možno interpretovať ako demograficko-environmentálny faktor. Najvyššie faktorové záťaže vykazujú premenné

populácia a emisie skleníkových plynov. Tento faktor odráža koncentráciu ekonomickej aktivity a environmentálne zaťaženie v hustejšie osídlených regiónoch.

Porovnanie výsledkov medzi obdobiami

Porovnanie výsledkov faktorovej analýzy poukazuje na to, že regionálne rozdiely medzi regiónmi zostali do veľkej miery stabilné počas všetkých troch analyzovaných období. Najvýznamnejším faktorom vo všetkých obdobiach bola ekonomická výkonnosť regiónov, ktorá zahŕňa ukazovatele HDP, príjmy domácností, výdavky na výskum a vývoj a zamestnanosť v technologicky náročných odvetviach. Významnú úlohu zohráva aj vzdelanostná úroveň obyvateľstva a sociálna situácia, ktoré sa prejavujú prostredníctvom ukazovateľov ako podiel vysokoškolsky vzdelaných obyvateľov, predčasné ukončenie vzdelávania a riziko chudoby. Tretím významným aspektom regionálnych rozdielov sú demografické a environmentálne charakteristiky regiónov.

Pandémia COVID-19 síce ovplyvnila mnohé aspekty regionálnej ekonomiky, avšak základná štruktúra faktorov zostala do značnej miery zachovaná. Tento výsledok naznačuje, že regionálne rozdiely v EÚ sú determinované najmä dlhodobými faktormi, ako sú ekonomická úroveň, vzdelanosť obyvateľstva a demografická štruktúra regiónov.

Záver

Na základe uskutočnenej analýzy možno konštatovať postupné ale nerovnomerné zmenšovanie rozdielov v regiónoch NUTS 2. Pri väčšine ukazovateľov sme zistili citlivosť znižovania regionálnych rozdielov na neočakávané ekonomické výkyvy. S príchodom viacerých ekonomických kríz si vyspelejšie regióny s ekonomickými výzvami poradili lepšie a začali sa opätovne vzdľať menej rozvinutým regiónom. Prvá päťica najrýchlejšie rastúcich regiónov sú najmä regióny Rumunska (Sud-Vest Oltenia, Nord-Vest, Nord-Est a București-Ilfov), ale aj región Severozapaden v Bulharsku. V regióne Sud-Vest Oltenia vzrástol HDP na obyvateľa z približne 11 300 € v roku 2015 na 24 000 € v roku 2024, čo predstavuje rast približne o 112 %. Ostatné spomenuté regióny zaznamenali nárast medzi 100 až 106 %. Tieto regióny boli pred desiatimi rokmi menej rozvinuté, preto dokázali rásť rýchlejšie vďaka investíciám, fondom EÚ a rozvoju miest a priemyslu.

Výsledky PCA potvrdili vhodnosť použitia tejto metódy pri všetkých sledovaných obdobiach, čo sme preukázali hodnotami KMO testu a štatisticky významným Bartlettovým testom sféricity. Extrahované faktory vysvetľovali významnú časť variability sledovaných

premenných, ktorá sa pohybovala medzi hodnotami 72 % až 82 % v analyzovaných obdobiach. Vo všetkých obdobiach sa ako najvýznamnejší faktor ukázal ekonomický faktor. Tento zahŕňal najmä premenné hrubý domáci produkt na obyvateľa, čistý disponibilný príjem domácností, výdavky na vedu a výskum a podiel zamestnancov v high-tech odvetviach.

Výsledky naznačujú, že ekonomická výkonnosť predstavuje kľúčový determinant regionálnych rozdielov v EÚ. Druhým významným faktorom bola vzdelanostná a sociálna štruktúra obyvateľstva, ktorá bola reprezentovaná premennými zahŕňajúcimi podiel vysokoškolsky vzdelaných obyvateľov, podiel osôb predčasne opúšťajúcich vzdelávací systém a riziko chudoby. Faktor poukazuje na význam ľudského kapitálu a úrovne vzdelania pre regionálny rozvoj a konkurencieschopnosť regiónov. Tretím identifikovaným faktorom bol demograficko-environmentálny faktor, ktorý zahŕňal premenné súvisiace s veľkosťou populácie a emisiami skleníkových plynov. Faktor poukazuje na súvislosť medzi ekonomickou aktivitou regiónov, ich veľkosťou a environmentálnym zaťažením. V niektorých prípadoch sa ako samostatný faktor regionálneho rozvoja objavil aj faktor cestovného ruchu, ktorý bol reprezentovaný ukazovateľom znázorňujúcim počet prenocovaní zahraničných turistov. Tento poukazuje na význam turistického sektora v niektorých regiónoch.

Porovnanie jednotlivých časových období zároveň naznačuje, že pandémie COVID-19 mala pomerne malý vplyv na štruktúru identifikovaných faktorov. Základné determinanty regionálnych rozdielov zostali do značnej miery nezmenené. Ekonomická výkonnosť, úroveň vzdelania obyvateľstva a demografické charakteristiky regiónov tak predstavujú dlhodobé faktory, ktoré významne ovplyvňujú regionálny rozvoj v EÚ. Výsledky empirickej analýzy potvrdzujú, že regionálne rozdiely v rámci EÚ sú determinované najmä dlhodobými štrukturálnymi ekonomickými a sociálnymi faktormi. Tieto zistenia môžu zároveň slúžiť ako podklad pre tvorbu regionálnych politík zameraných na znižovanie regionálnych nerovností a podporu vyváženého regionálneho rozvoja.

Na základe výsledkov výskumu môžeme konštatovať, že ekonomická úroveň regiónov je do veľkej miery ovplyvnená úrovňou dosiahnutého vzdelania, na čo je zároveň nadviazaná zamestnanosť v high-tech spoločnostiach. Tieto majú významný vplyv na ekonomický rozvoj regiónov. Význam vidíme v zvyšovaní výdavkov na vedu a výskum, ktoré sa odzrkadľujú vo vyšších mzdách a tým znižujú riziko ohrozenia chudobou. V prípade obdobia po pandémie sú výsledky vzájomných korelácií do istej miery ovplyvnené pri ukazovateli výdavkov na vedu a výskum nedostatočnými údajmi za rok 2024. Potvrdili sme vzájomnú závislosť medzi narastajúcimi výdavkami na vedu a výskum a rastom HDP.

Zároveň zdôrazňujeme, že vysokým tlakom na dlhé pracovné zmeny zamestnancov zamestnávateľa nedosiahnu vyššiu výkonnosť. Naopak, s nárastom počtu odpracovaných hodín jednotlivca klesá jeho výkonnosť a efektivita, čo sa odzrkadľuje v nižšom ekonomickom rozvoji regiónu. Riziko pri menej rozvinutých regiónoch tiež vidíme v nedostatočnej pripravenosti zvládť globálne krízy, ktorú v našom výskume predstavuje pandémia COVID-19. Napriek trendu znižovania rozdielov v období pred pandémiou, práve obdobie krízy dokázalo vrátiť pozitívny trend niekoľko rokov späť. Odporúčame menej rozvinutým regiónom väčšiu prípravu na neočakávané globálne krízy, najmä v ekonomickej oblasti, s čím práve v období kríz môžu menej rozvinutým regiónom pomôcť rozvinutejšie regióny.

Problém, ktorý sa môže ukázať ako výrazný až niekoľko rokov po kríze, vidíme v tom, že populárne riešenia chudobnejších regiónov je siahť na výdavky na vedu a výskum, ktorými kompenzujú iné straty. Toto považujeme za neracionálne, nakoľko práve výdavky na vedu a výskum sú kľúčové pre ekonomický rozvoj. Nedostatočné pracovné príležitosti v high-tech spoločnostiach súvisiace s nízkou kvalifikáciou zamestnancov súvisia tiež s vyššou produkciou skleníkových plynov. Investície do výskumu a vedy môžu viesť aj k znižovaniu emisií prostredníctvom menej nákladných alternatív, ktoré zároveň budú menšou záťažou pre podnikateľské subjekty.

Zoznam použitej literatúry

1. ARORA. J. S. 2012. *Introduction to Optimum Design (Third Edition)*. [online]. New York : Academic Press. [cit. 2024-11-13]. Dostupné na internete: <https://www.sciencedirect.com/book/9780123813756/introduction-to-optimum-design>.
2. BARRO, R.J. 1984. *Macroeconomics*. New York: Wiley, 596 s. ISBN 978-0471874072.
3. BARRO, R. J., SALA-I-MARTIN, X. 2004. *Economic growth*. London: The MIT Press, 2004. 654 s. ISBN 0-262-02553-1.
4. BAUMOL, W.J. 1986. Productivity Growth, Convergence, and Welfare: What the Long Run Data Show. *American Economic Review*, 76, s. 1072—1085, ISSN 0002-8282.
5. COUTINHO, L., TURRINI, A. 2019. Convergence and macroeconomic imbalances. In: *Quarterly Report on the Euro Area (QREA)*, 2019, vol. 18, issue 1, s. 37-51.
6. DODGE, Y. 2008. Coefficient of Variation. In: *The Concise Encyclopedia of Statistics*. New York : Springer. Dostupné online: https://doi.org/10.1007/978-0-387-32833-1_65.
7. EDWARDS. C. M., WOODS. M. C., 2007. Factor Analysis and Related Methods In: *Handbook of Statistics* vol. 27, s. 174-201. ISSN 0169-7161. Dostupné na internete:

<https://www.sciencedirect.com/science/chapter/edited-volume/abs/pii/B9780444537379500098> .

8. European Commission. 2024. *Cohesion policy*. Dostupné online: https://ec.europa.eu/regional_policy/policy/what/investment-policy_en?wt-search=yes.
9. European Commission. 2025. *HDP – Čo je hrubý domáci produkt (HDP)?* [online]. [cit. 2026-03-08]. Dostupné na internete: <https://ec.europa.eu/eurostat/statistics-explained/index.php?oldid=446833>.
10. Eurostat. 2024. *Dataset*. [online]. [cit. 2025-01-20] Dostupné online: https://ec.europa.eu/eurostat/databrowser/explore/all/all_themes.
11. Eurostat. 2024. *Nomenclature of territorial units for statistics*. [online]. [cit. 2025-01-20]. Dostupné na internete: <https://ec.europa.eu/eurostat/web/nuts>.
12. Eurostat. 2023. *Tourism: €572 billion gross value added in the EU*. [online]. [cit. 2026-03-09]. Dostupné na internete: <https://ec.europa.eu/eurostat/web/products-eurostat-news/w/wdn-20230414-1>.
13. FITZGERALD, J. 2015. Problems Interpreting National Accounts in a Globalised Economy – Ireland. In The Economic and Social Research Institute. Dublin: ESRI. 27 s. Dostupné na internete: https://www.esri.ie/system/files/publications/QEC2015SUM_SA_FitzGerald.pdf.
14. GACZEK, W. M., WOJCIECH, K. 2017. Regional convergence and divergence in Poland. In *Studia Regionalia*, vol. 50, s. 63-85. ISSN 0860-3375. Dostupné na internete: <https://bibliotekanauki.pl/articles/2091983>.
15. HAIR. J. F., et al. 2019. *Eight Edition. Multivariate data analysis*. Hampshire: Cengage Learning, EMEA. 814 s. Dostupné na internete: https://eli.johogo.com/Class/CCU/SEM/_Multivariate%20Data%20Analysis_Hair.pdf.
16. HINDLS. R., HRONOVÁ, S., SEGER, J. 2004. *Statistika pro ekonomy*. Praha: Professional Publishing, 415 s. ISBN 80-86419-59-2.
17. KAISER. F. H. 1958. The varimax criterion for analytic rotation in factor analysis In: *Psychometrika* 23, s. 187-200. ISSN 0033-3123.
18. KOLOŠTA, S. 2022. *Využitie kompozitných ukazovateľov pri hodnotení verejných politík*. Belianum, 102 s. ISBN 978-80-557-1953-5.
19. KOVÁČ, U., KOVÁČ GERULOVÁ, L., BUČEK, M. 2011. Metodologické prístupy k meraniu konverencie. In: *Prognostické práce, 3, 2011, č. 5*. Bratislava : Prognostický ústav Slovenskej akadémie vied. ISSN: 1338-3590. Dostupné online: <https://www.prog.sav.sk/wp-content/uploads/clanok1-PP-5-Kovac.pdf>.

20. KRÁL, P., KANDEROVÁ, M., KAŠČÁKOVÁ, A., NEDELOVÁ, G., VALENČÁKOVÁ, V. 2009. *Viacrozmerné štatistické metódy so zameraním na riešenie problémov ekonomickej praxe*. Banská Bystrica: Ekonomická fakulta UMB, 175 s. ISBN 978-80-8083-840-9.
21. LUBYOVÁ, M., VOJTKOVÁ, M. 2014. Analýza miery atraktívnosti národných ekonomík pre zahraničných investorov v novom globalizovanom prostredí. In *Ekonomický časopis*, 62 (6), s. 557-578. ISSN 0013-3035. Dostupné na internete: <https://www.sav.sk/journals/uploads/0620142806%2014%20Lubyova-Vojtkova%20+%20RS%20+%20F.pdf>
22. MAGAZZINO, C., MELE, M. 2022. Testing the convergence and the divergence in five Asian countries: from a GMM model to a new Machine Learning algorithm. In: *Journal of Economic Studies*, Vol. 49, No. 6, 2022, s. 1002-1016. ISSN: 1443585.
23. MISHRA, S. 2007. A Comparative Study of Various Inclusive Indices and the Index Constructed by the Principal Components Analysis. In *SSRN Electronic Journal*, s. 1-14. ISSN 1556-5068.
24. MULAİK. S. A., 2009. *Foundations of Factor Analysis*, New York ISBN: 9780429132094. Dostupné na internete: <https://www.taylorfrancis.com/books/mono/10.1201/b15851/foundations-factor-analysis-stanley-mulaik>
25. NASEER, M. et al. 2019. Critical Issues at the Upstream Level in Sustainable Supply Chain Management of Agri-Food Industries: Evidence from Pakistan's Citrus Industry. In *Sustainability*, 11 (5), s. 1-19. ISSN 2071-1050. Dostupné online: https://www.researchgate.net/publication/331477844_Critical_Issues_at_the_Upstream_Level_in_Sustainable_Supply_Chain_Management_of_Agri-Food_Industries_Evidence_from_Pakistan's_Citrus_Industry.
26. NICOLETTI, G., SCARPETTA, S., BOYLAUD, O. 2000. *Summary indicators of product market regulation with an extension to employment protection legislation*. Economics Department Working Paper No. 226. OECD. 87 s. ISSN 18151973.
27. PENCABEL, J. H. 2014. The productivity of working hours. In *Economic Journal* 125 (589), s. 2052-2076. ISSN 1468-0297. Dostupné na internete: <https://www.iza.org/publications/dp/8129>.
28. PACI, R., MARROCU, E. 2014. Tourism and regional growth in Europe. In *Papers in Regional Science* 93 (1), s. 25-51. ISSN 1435-5957. Dostupné na internete: <https://www.sciencedirect.com/science/article/pii/S1056819023005535>.

29. RODRÍGUEZ-POSE, A. et. al. 2018. Regional inequality in Europe: evidence, theory and policy implications. In *Journal of Economic Geography*, Volume 19, Issue 2, March 2019, s. 273–298. ISSN 1468-2702. Dostupné online: <https://academic.oup.com/joeg/articleabstract/19/2/273/4989323?redirectedFrom=fulltext>.
30. ROTARU, A. et al. 2024. Assessment of regional development level in Romania through Principal component analysis. In *Journal Central European Agriculture*, 25 (2), s. 588-605. ISSN 1332-9049. Dostupné na internete: <https://jcea.agr.hr/en/issues/article/4176>.
31. SIGUDLA, J., MARITZ, J. E. 2023. Exploratory factor analysis of constructs used for investigating research uptake for public healthcare practice and policy in a resource-limited setting, South Africa. In *BMC Health Services Research* 23:1423, s. 1-8. ISSN 1472-6963. Dostupné na internete: <https://pmc.ncbi.nlm.nih.gov/articles/PMC10724913>.
32. SOUKUP, J., SOUKUPOVÁ, J. 2021. Beta and sigma convergence of V4 countries and the European Union. In: *The 15th International Days of Statistics and Economics*, s. 966-976.
33. STANKOVIČOVÁ, I., VOJTKOVÁ, M. 2007. *Viacrozmerné štatistické metódy s aplikáciami*. Iura Edition. 261 s. 978-80-8078-152-1.
34. ŠAGÚL, T., MORAUČÍK, M. 2025. Vyhodnotenie regionálnych rozdielov v regiónoch NUTS 2 vo vybraných oblastiach a časových obdobiach. In *Študentská vedecká aktivita 2025*. Banská Bystrica: Univerzita Mateja Bela. ISBN 978-80-557-2233-7.
35. ŠUSTER, M. 2024. *Dlhodobé trendy v ekonomickom vývoji* [online]. [cit. 2025-01-22]. Dostupné na internete: https://www.nbs.sk/_img/documents/publik/prednaska_dlhodoby_trend_rastu.pdf.
36. YOUNG, A. T., HIGGINS, M. J., LEVY, D. 2008. Sigma Convergence Versus Beta Convergence: Evidence from U.S. County-Level Data. In: *Journal of Money, Credit and Banking*, vol. 40. Dostupné online: <https://doi.org/10.1111/j.1538-4616.2008.00148.x>.

Prílohy

Príloha 1 Výstup regresnej analýzy SUMMARY OUTPUT

Regression Statistics	
Multiple R	0.48980171
R Square	0.239905716
Adjusted R Square	0.23676483
Standard Error	0.011506191
Observations	244

ANOVA					
	df	SS	MS	F	Significance F
Regression	1	0.01011234	0.01011234	76.38155469	3.97245E-16
Residual	242	0.032038971	0.000132392		
Total	243	0.042151311			

	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%
Intercept	0.204533179	0.018762028	10.90144282	8.98622E-23	0.167575452	0.241490906
ln HDP (2015)	-0.016217151	0.001855583	-8.739654152	3.97245E-16	-0.019872306	-0.012561996

Príloha 2 Korelačná matica - obdobie pred pandémiou COVID-19

Correlations		HDP	PočetPrenocovan (ZahraničníTur stov	ZamestnanecVHi ghTech	RizikoChudoby	Populácia	GHGEmisie	VýdavkyNaVedu AVýskum	EarlyLeavers	ČistýDisponibilný Prijem	VysokoškolskýVz delaniObyvatelia	PriemernýPočetO dpracovanýchHo din
HDP	Pearson Correlation	1	0.115	,633	-,517	,164	0.112	,692	-,314	,791	,250	-,476
	Sig. (2-tailed)		0.081	0.000	0.000	0.011	0.083	0.000	0.000	0.000	0.000	0.000
	N	244	231	227	151	237	241	197	231	239	243	244
PočetPrenocovan (ZahraničníTur stov	Pearson Correlation	0.115	1	0.027	0.037	,372	-,136	-0.043	0.115	0.071	-,225	0.067
	Sig. (2-tailed)	0.081		0.691	0.655	0.000	0.038	0.552	0.088	0.280	0.001	0.312
	N	231	231	217	151	231	231	197	220	231	231	231
ZamestnanecVHi ghTech	Pearson Correlation	,633	0.027	1	-,501	,169	-0.009	,509	-,369	,354	,365	-0.078
	Sig. (2-tailed)	0.000	0.691		0.000	0.012	0.899	0.000	0.000	0.000	0.000	0.245
	N	227	217	227	140	222	225	184	220	224	227	227
RizikoChudoby	Pearson Correlation	-,517	0.037	-,501	1	0.112	-0.006	-,322	,651	-,502	-,559	0.113
	Sig. (2-tailed)	0.000	0.655	0.000		0.173	0.940	0.000	0.000	0.000	0.000	0.167
	N	151	151	140	151	151	151	141	141	151	151	151
Populácia	Pearson Correlation	,164	,372	,169	0.112	1	,733	0.095	0.030	,177	-0.035	-0.050
	Sig. (2-tailed)	0.011	0.000	0.012	0.173		0.000	0.184	0.658	0.006	0.597	0.448
	N	237	231	222	151	237	237	197	225	237	236	237
GHGEmisie	Pearson Correlation	0.112	-,136	-0.009	-0.006	,733	1	0.061	-0.051	,187	0.105	-0.118
	Sig. (2-tailed)	0.083	0.038	0.899	0.940	0.000		0.398	0.447	0.004	0.104	0.066
	N	241	231	225	151	237	241	197	228	239	240	241
VýdavkyNaVeduAVýskum	Pearson Correlation	,692	-0.043	,509	-,322	0.095	0.061	1	-,290	,628	,277	-,522
	Sig. (2-tailed)	0.000	0.552	0.000	0.000	0.184	0.398		0.000	0.000	0.000	0.000
	N	197	197	184	141	197	197	197	186	197	197	197
EarlyLeavers	Pearson Correlation	-,314	0.115	-,369	,651	0.030	-0.051	-,290	1	-,280	-,682	0.018
	Sig. (2-tailed)	0.000	0.088	0.000	0.000	0.658	0.447	0.000		0.000	0.000	0.789
	N	231	220	220	141	225	228	186	231	227	231	231
ČistýDisponibilný Prijem	Pearson Correlation	,791	0.071	,354	-,502	,177	,187	,628	-,280	1	,176	-,571
	Sig. (2-tailed)	0.000	0.280	0.000	0.000	0.006	0.004	0.000	0.000		0.006	0.000
	N	239	231	224	151	237	239	197	227	239	238	239
VysokoškolskýVzdelaniObyvat elia	Pearson Correlation	,250	-,225	,365	-,559	-0.035	0.105	,277	-,682	,176	1	-0.043
	Sig. (2-tailed)	0.000	0.001	0.000	0.000	0.597	0.104	0.000	0.000	0.006		0.504
	N	243	231	227	151	236	240	197	231	238	243	243
PriemernýPočetOdpracovanýc hObyvatelia	Pearson Correlation	-,476	0.067	-0.078	0.113	-0.050	-0.118	-,522	0.018	-,571	-0.043	1
	Sig. (2-tailed)	0.000	0.312	0.245	0.167	0.448	0.066	0.000	0.789	0.000	0.504	
	N	244	231	227	151	237	241	197	231	239	243	244

		Correlations										
		HDP	PočetPrenocovan ZahraničnýchTur istov	ZamestnanecVHi ghTech	RizikoChudoby	Populácia	GHGEmisie	VýdavkyNaVedu AVýskum	EarlyLeavers	ČistýDisponibilný Prijem	VysokoškolskýVz delaniObyvatelia	PriemernýPočetO dpracovanýchHo din
HDP	Pearson Correlation	1	0.067	.687	-.464	.166	0.098	.637	-.303	.738	.257	-.471
	Sig. (2-tailed)		0.302	0.000	0.000	0.010	0.131	0.000	0.000	0.000	0.000	0.000
	N	244	237	226	229	237	241	216	205	244	243	244
PočetPrenocovani Zahraničných Turistov	Pearson Correlation	0.067	1	-0.031	0.003	.312	0.111	-0.028	-0.037	0.033	-.182	0.075
	Sig. (2-tailed)	0.302		0.643	0.963	0.000	0.087	0.678	0.600	0.617	0.005	0.250
	N	237	237	219	229	237	237	216	200	237	236	237
ZamestnanecVHighTech	Pearson Correlation	.687	-0.031	1	-.458	.175	0.014	.559	-.351	.416	.407	-.169
	Sig. (2-tailed)	0.000	0.643		0.000	0.009	0.833	0.000	0.000	0.000	0.000	0.011
	N	226	219	226	213	219	223	201	199	226	226	226
RizikoChudoby	Pearson Correlation	-.464	0.003	-.458	1	-0.032	-0.089	-.313	.570	-.503	-.595	0.094
	Sig. (2-tailed)	0.000	0.963	0.000		0.632	0.181	0.000	0.000	0.000	0.000	0.157
	N	229	229	213	229	229	229	209	194	229	229	229
Populácia	Pearson Correlation	.166	.312	.175	-0.032	1	.744	.134	0.063	.184	-0.066	-0.061
	Sig. (2-tailed)	0.010	0.000	0.009	0.632		0.000	0.050	0.374	0.005	0.315	0.349
	N	237	237	209	229	237	237	216	200	237	236	237
GHGEmisie	Pearson Correlation	0.098	0.111	0.014	-0.089	.744	1	0.057	0.056	.182	0.079	-0.104
	Sig. (2-tailed)	0.131	0.087	0.833	0.181	0.000		0.401	0.425	0.005	0.223	0.108
	N	241	237	223	229	237	241	216	203	241	240	241
VýdavkyNaVeduAVýskum	Pearson Correlation	.637	-0.028	.559	-.313	.134	0.057	1	-.191	.611	.233	-.471
	Sig. (2-tailed)	0.000	0.678	0.000	0.000	0.050	0.401		0.010	0.000	0.001	0.000
	N	216	216	201	209	216	216	216	181	216	216	216
EarlyLeavers	Pearson Correlation	-.303	-0.037	-.351	.570	0.063	0.056	-.191	1	-.184	-.512	-0.028
	Sig. (2-tailed)	0.000	0.600	0.000	0.000	0.374	0.425	0.010		0.008	0.000	0.693
	N	205	200	199	194	200	203	181	205	205	205	205
ČistýDisponibilnýPrijem	Pearson Correlation	.738	0.033	.416	-.503	.184	.182	.611	-.184	1	.177	-.614
	Sig. (2-tailed)	0.000	0.617	0.000	0.000	0.005	0.005	0.000	0.008		0.006	0.000
	N	244	237	226	229	237	241	216	205	244	243	244
VysokoškolskýVzdelaniObyv atelia	Pearson Correlation	.257	-.182	.407	-.595	-0.066	0.079	.233	-.512	.177	1	0.022
	Sig. (2-tailed)	0.000	0.005	0.000	0.000	0.315	0.223	0.001	0.000	0.006		0.736
	N	243	236	226	229	236	240	216	205	243	243	243

Correlations													
		HDP	PočetPrenovacov ZahraničnýchTuristov	ZamestnanecVHighTech	RizikoChudoby	Populácia	GHGEmisie	VýdavkyNaVeduAVýskum	EarlyLeavers	ČistýDisponibilnýPríjem	VysokoškolskýVzdelanýObyvatelia	PriemernýPočetOdppracovanýchIn	
HDP	Pearson Correlation	1	,146"	-,153"	-,190"	,193"	,621"	-,185"	,699"	-,141"	-,168"		°
	Sig. (2-tailed)		0.022	0.021	0.003	0.002	0.000	0.009	0.000	0.027	0.009		°
	N	245	245	229	237	245	228	198	62	244	244		°
PočetPrenovacovZahraničnýchTuristov	Pearson Correlation	,146"	1	-0.032	-0.033	,398"	-0.008	-0.038	,320"	-0.050	-0.030		°
	Sig. (2-tailed)	0.022		0.630	0.618	0.000	0.901	0.596	0.011	0.435	0.643		°
	N	245	245	229	237	245	228	198	62	244	244		°
ZamestnanecVHighTech	Pearson Correlation	-,153"	-0.032	1	,998"	-0.075	0.108	,999"	-,520"	,997"	1,000"		°
	Sig. (2-tailed)	0.021	0.630		0.000	0.261	0.114	0.000	0.000	0.000	0.000		°
	N	229	229	229	223	229	215	192	61	229	229		°
RizikoChudoby	Pearson Correlation	-,190"	-0.033	,998"	1	-0.075	0.084	,999"	-,572"	,992"	,999"		°
	Sig. (2-tailed)	0.003	0.618	0.000		0.250	0.211	0.000	0.000	0.000	0.000		°
	N	237	237	223	237	237	221	192	57	237	237		°
Populácia	Pearson Correlation	,193"	,398"	-0.075	-0.075	1	,150"	-0.084	0.066	-0.076	-0.073		°
	Sig. (2-tailed)	0.002	0.000	0.261	0.250		0.023	0.239	0.612	0.237	0.255		°
	N	245	245	229	237	245	228	198	62	244	244		°
GHGEmisie	Pearson Correlation	,621"	-0.008	0.108	0.084	,150"	1	0.093	,258"	0.118	0.090		°
	Sig. (2-tailed)	0.000	0.901	0.114	0.211	0.023		0.213	0.043	0.076	0.175		°
	N	228	228	215	221	228	228	182	62	228	228		°
VýdavkyNaVeduAVýskum	Pearson Correlation	-,185"	-0.038	,999"	,999"	-0.084	0.093	1	-,533"	,995"	,999"		°
	Sig. (2-tailed)	0.009	0.596	0.000	0.000	0.239	0.213		0.000	0.000	0.000		°
	N	198	198	192	192	198	182	198	57	198	198		°
EarlyLeavers	Pearson Correlation	,699"	,320"	-,520"	-,572"	0.066	,258"	-,533"	1	-,520"	-,522"		°
	Sig. (2-tailed)	0.000	0.011	0.000	0.000	0.612	0.043	0.000		0.000	0.000		°
	N	62	62	61	57	62	62	57	62	62	62		°
ČistýDisponibilnýPríjem	Pearson Correlation	-,141"	-0.050	,997"	,992"	-0.076	0.118	,995"	-,520"	1	,996"		°
	Sig. (2-tailed)	0.027	0.435	0.000	0.000	0.237	0.076	0.000	0.000		0.000		°
	N	244	244	229	237	244	228	198	62	244	244		°
VysokoškolskýVzdelanýObyvatelia	Pearson Correlation	-,168"	-0.030	1,000"	,999"	-0.073	0.090	,999"	-,522"	,996"	1		°
	Sig. (2-tailed)	0.009	0.643	0.000	0.000	0.255	0.175	0.000	0.000	0.000			°
	N	244	244	229	237	244	228	198	62	244	244		°

Príloha 5 KMO štatistika a Bartlettov test - obdobie pred pandémiou

KMO and Bartlett's Test

Kaiser-Meyer-Olkin Measure of Sampling Adequacy.		,561
Bartlett's Test of Sphericity	Approx. Chi-Square	157,539
	df	45
	Sig.	,000

Príloha 6 KMO štatistika a Bartlettov test - obdobie počas pandémie

KMO and Bartlett's Test

Kaiser-Meyer-Olkin Measure of Sampling Adequacy.		,670
Bartlett's Test of Sphericity	Approx. Chi-Square	1033,953
	df	55
	Sig.	,000

Príloha 7 KMO štatistika a Bartlettov test - obdobie po pandémii

KMO and Bartlett's Test

Kaiser-Meyer-Olkin Measure of Sampling Adequacy.		,674
Bartlett's Test of Sphericity	Approx. Chi-Square	832,793
	df	55
	Sig.	,000

Príloha 8 Výstup Varimax rotačnej matice faktorovej analýzy – obdobie pred pandémiou

Component Matrix^a

	Component			
	1	2	3	4
HDP	,844	,395	-,027	,195
PočetPrenocovaníZahraničn ýchTuristov	,201	,592	-,445	,423
ZamestnanecVHighTech	,744	-,153	,478	,306
RizikoChudoby	-,733	,188	,488	,032
Populácia	-,475	,240	,246	,681
GHGEmisie	,731	,232	,475	-,005
VýdavkyNaVeduAVýskum	-,605	,540	-,047	-,179
EarlyLeavers	,546	,605	-,334	-,156
ČistýDisponibilnýPrijem	,710	-,566	-,082	-,063
VysokoškolskýVzdelaníObyv atelia	-,225	-,626	-,426	,468

Príloha 9 Výstup Varimax rotačnej matice faktorovej analýzy – obdobie počas pandémie

Rotated Component Matrix^a

	Component			
	1	2	3	4
HDP	,794	,388	,059	,133
PočetPrenocovaníZahraničn ýchTuristov	,000	-,054	,122	,939
ZamestnanecVHighTech	,504	,615	,087	,041
RizikoChudoby	-,294	-,763	-,029	,042
Populácia	,146	-,049	,879	,279
GHGEmisie	,063	-,039	,942	-,079
VýdavkyNaVeduAVýskum	,803	,248	,013	-,006
EarlyLeavers	,028	-,795	,170	-,168
ČistýDisponibilnýPrijem	,891	,151	,139	,003
VysokoškolskýVzdelaníObyv atelia	,020	,802	-,019	-,320
PriemernýPočetOdpracovan ýchHodín	-,853	,281	-,096	,100

Príloha 10 Výstup Varimax rotačnej matice faktorovej analýzy – obdobie po pandémii

Rotated Component Matrix^a

	Component		
	1	2	3
HDP	,868	,329	,099
PočetPrenocovaníZahraničn ýchTuristov	,225	-,259	,416
ZamestnanecVHighTech	,524	,595	,105
RizikoChudoby	-,323	-,762	,022
Populácia	,060	-,117	,925
GHGEmisie	-,087	,037	,899
VýdavkyNaVeduAVýskum	,807	,230	-,099
EarlyLeavers	-,126	-,845	,128
ČistýDisponibilnýPrijem	,856	,171	,193
VysokoškolskýVzdelaníObyv atelia	-,100	,867	-,188
PriemernýPočetOdpracovan ýchHodín	-,817	,258	,007