

DOI: <https://doi.org/10.54937/ssf.2025.24.1.80-97>

## **Panelová analýza emisií CO<sub>2</sub> v kontexte vzdelávania k dosahovaniu cieľov „Net Zero“**

### **Panel Analysis of CO<sub>2</sub> Emissions in the Context of Education to Achieve “Net Zero” Goals**

Eva Litavcová

#### **Abstract**

In the history of applied mathematics, it is possible to find many extraordinary ideas, based on which a lot of new discoveries are currently being made. A great example is panel analysis, first applied to astronomical data by Sir George Biddell Airy (1861). Currently panel analysis is often used in various fields of research in situations where it is necessary to use regression analysis on time series. One such area is the search for solutions for global decarbonisation. Within this, the so-called Net Zero goal is key. However, standard panel analysis method has a huge of prerequisites. If these prerequisites are not met, is necessary use more complex contemporary panel methods. The aim of this paper is to investigate the dependence of carbon dioxide (CO<sub>2</sub>) emissions on various factors, including some so-called smart city indicators. To achieve this objective standard panel models are used, along with more complex estimation techniques such as Common Correlated Effect Estimator (CCE) and Instrumental-Variable Estimation Panel Models with Common Factor (2SIV – two-stage IV approach). The article shows the advantages of using panel analysis on its own example with environmental data, with the possibility of using the obtained results in education for responsible ecological behavior.

**Keywords:** Panel analysis. Environmental education. CO<sub>2</sub> emissions. Common correlated effect. Common factor models.

#### **Úvod**

Emisie skleníkových plynov, ktoré ľudstvo produkuje, Zem ohrievajú a ničia ju tempom, aké v čase začiatkov skúmania tohto pozorovaného javu nepredikovali ani tie najodvážnejšie modely. Prevažujúce spoliehanie sa na fosílné palivá vyvolalo komplexnú súvislosť nielen environmentálnych, ekonomických a zdravotných výziev, ale v neposlednom rade aj pedagogických. Situáciu je potrebné neustále sledovať, analyticky vyhodnocovať a hľadať

riešenia. Súčasťou komplexného riešenia je aj výchovou a vzdelávaním zabezpečiť vytváranie zodpovedného prístupu k Zemi u každého človeka už od detstva. Dobrým príkladom je už 30 rokov praktizovaný Školský program Vzdelávanie pre životné prostredie a udržateľnosť (ESE), ktorý je implementovaný vo viac ako tisícke verejných škôl v Andalúzii v južnom Španielsku (Gracia et al, 2024). Mnohé zo súčasných detí získajú v budúcnosti pozíciu, kde budú mať čo do činenia s rozhodnutiami súvisiacimi s emisiami skleníkových plynov. Ľudské úsilie by sa malo zameriavať na iniciatívy zamerané na znižovanie emisií, nové technológie a prechod na obnoviteľnú energiu. Pod pojmom Net Zero sa skrýva príklad takejto iniciatívy v globálnom meradle. Jedná sa o iniciatívu organizácie World Green Building Council (WorldGBC), ktorá každoročne vydáva report svojej činnosti (worldgbc.org). Net Zero Carbon znamená, že emisie skleníkových plynov počas životného cyklu projektu zo všetkých zdrojov by mali byť nulové alebo menej (www.neso.energy). Iniciatíva mapuje signatárske mestá, ktoré tvoria súčasť siete miest C40 a prijímajú odolné a inkluzívne klimatické akčné plány v súlade s ambíciou zníženia o 1,5 °C podľa Parížskej dohody. Pojem Smart City znamená inteligentné mesto, ktoré využíva technológie a riešenia založené na údajoch na zvýšenie efektívnosti, udržateľnosti a celkovej kvality života, v reakcii na znižujúcu sa odolnosť miest v dôsledku rastúcej urbanizácie, preťaženia a ohrozenia klimatickými zmenami.

Vzdelávacie inštitúcie preberajú vedúcu úlohu vo vývoji a implementácii trvalo udržateľných postupov a iniciatív, pričom rozpoznávajú svoj potenciál urýchliť tento pokrok smerom k trvalo udržateľnému rozvoju (Rocha et al., 2023). Inštitúcie vysokoškolského vzdelávania alebo univerzity zohrávajú dôležitú úlohu pri podpore trvalo udržateľného rozvoja. Zdrojom informácií pre environmentálne vzdelávanie je aj vyhodnocovanie existujúcich údajov z predchádzajúcich období a hľadanie vysvetlení vedúcich k nachádzaniu riešení pre nasledujúce obdobia, ktoré by mohli viesť k znižovaniu, v ideálnom prípade k úplnej eliminácii globálneho otepľovania. Relevantné údaje sú systematicky zbierané takmer v každej krajine a zo štatistického hľadiska majú povahu časových radov. Ak vezmeme v úvahu viac krajín, napr. Európu, a viac rozličných premenných, tak potom získame panel, kde pre každú pozorovanú hodnotu máme tri údaje, čas  $t$ , krajinu  $i$  a veľkosť nameranej hodnoty  $x_{it}$ . Pre  $k$  premenných je to  $(I \times k)$  vektor  $x_{it}$ . V environmentálnom kontexte nás zvyčajne zaujíma, v akom vzťahu je premenná objem CO<sub>2</sub> voči ostatným pozorovaným premenným, pre uvažovanie s ktorými existujú racionálne dôvody. Napr. v práci Sun et al. (2022) sa ukázalo, že rýchla urbanizácia a ekonomický rast prispeli k vyšším uhlíkovým emisiám, pričom sa zistilo, že spotreba obnoviteľnej energie je optimálnym riešením na ich zmiernenie. V práci Osei-Kusi et al. (2024) autori dospeli k záveru, že HDP na obyvateľa pozitívne ovplyvňuje emisie uhlíka a strednú dĺžku života v nimi skúmaných regiónoch.

Cieľom tohto článku je preskúmať závislosť emisií CO<sub>2</sub> od rôznych faktorov, vrátane niektorých indikátorov inteligentných miest a vzdelávania. Na dosiahnutie tohto cieľa sme použili štandardné panelové modely spolu s komplexnejšími technikami odhadu, ako je Common Correlated Effect Estimator (CCE) a Instrumental-Variable Estimation Panel Models so spoločným faktorom (2SIV – dvojestupňový IV prístup). Článok ukazuje výhody použitia panelovej analýzy na vlastnom príklade s reálnymi údajmi environmentálnej povahy, s možnosťou využitia získaných výsledkov vo vzdelávaní, ktorého cieľom je zodpovedné ekologické správanie.

Tento článok je organizovaný nasledovne: po úvode v druhej časti panelovú regresiu najprv stručne predstavíme, popíšeme použité údaje, zdôvodníme racionalitu pre výber premenných a načrtujeme postup analýz. V tretej časti uvedieme jej vlastné použitie na vybraných údajoch, prezentujeme výsledky a zistenia. V závere zosumarizujeme hlavné zistenia a navrhujeme cesty ďalšieho skúmania.

## Údaje a metódy

Panelové štatistické modely sú vo výskume široko používané, napr. v ekonometrii, bioštatistike, geografickej štatistike. Panelové údaje sú kombinované prierezové a časové údaje. Ako uvádzajú Sarafidis a Wansbeek (2021), vysokú popularitu analýzy takýchto údajov za posledné štyri desaťročia možno do značnej miery pripísať dvom hlavným faktorom: 1. schopnosti kontrolovať určité zdroje nepozorovanej heterogenity a endogenity v dôsledku (povedzme) vynechaných premenných a chýb merania; 2. schopnosti odhadnúť dynamické vzťahy z mikroúdajov často s použitím relatívne malého počtu pozorovaní v časových radoch.

Panelová regresia údajov vo svojom najjednoduchšom tvare, vo forme jednosmerného modelu chybovej zložky pre rezíduá je (Baltagi, 2008)

$$y_{it} = \alpha + X_{it}'\beta + \mu_i + v_{it}, \quad t = 1, \dots, T, \quad i = 1, \dots, N \quad (1)$$

pričom  $i$  označuje jednotlivcov (tu krajiny, prierezový rozmer),  $t$  označuje čas (dimenziu časového radu),  $\alpha$  je skalár,  $\beta$  je vektor typu  $K \times 1$  a  $X_{it}$  je  $i$ -té pozorovanie  $K$  vysvetľujúcich premenných. Symbol  $\mu_i$  označuje nepozorovateľný časovo invariantný individuálny špecifický efekt,  $v_{it}$  označuje rezíduum,  $y_{it}$  označuje  $it$ -tú hodnotu závisle premennej. Predpokladom je nezávislosť  $X_{it}$  a  $v_{it}$ . Taktiež náhodné chyby  $v_{it}$  sú nezávislé náhodné premenné s  $IID(0, \sigma_v^2)$ , s konštantným rozptylom. Pre model s fixnými efektmi (FE) sa očakáva splnenie predpokladu korelácie medzi chybovou zložkou entity (individuálny-špecifický) a predikčnými premennými. FE odstraňuje vplyv týchto časovo invariantných charakteristík. Pre model s náhodnými efektmi (RE) musia byť splnené predpoklady:  $\mu_i \sim IID(0, \sigma_\mu^2)$ ,  $v_i \sim IID(0, \sigma_v^2)$ , od seba nezávisia, ani od predikčných premenných. Požadované predpoklady sú

v reálnych situáciách splniteľné iba veľmi vzácné. Ignorujúc ich nedodržanie by viedlo k nekonzistentným záverom. Preto vychádzajúc zo základného tvaru v súčasnosti existuje bohatá paleta ďalších komplexných panelových metód, ktoré túto skutočnosť zohľadňujú.

Nasledujúci príklad je ukážkou vhodnej aplikácie regresných metód určených pre analýzu panelových údajov, čo vychádza z reálnej povahy skúmaných premenných.

Súbor údajov pre analýzu tvorí panel 528 záznamov, ktoré sa týkajú vysvetľovanej premennej - objemu emisií CO<sub>2</sub> na obyvateľa v rámci 24 vybraných krajín Európy a obsahujú aj hodnoty ďalších šiestich vybraných premenných v časovom rozmedzí rokov 2000 – 2021. Jedná sa o krajiny: Belgicko (BEL), Bulharsko (BGR), Česko (CZE), Cyprus (CYP), Dánsko (DNK), Estónsko (EST), Francúzsko (FRA), Fínsko (FIN), Nemecko (GER), Grécko (GRC), Maďarsko (HUN), Írsko (IRL), Taliansko (ITA), Litva (LTU), Lotyšsko (LVA), Luxembursko (LUX), Holandsko (NLD), Poľsko (POL), Portugalsko (PRT), Rumunsko (ROU), Slovensko (SVK), Slovinsko (SVN), Španielsko (ESP) a Švédsko (SWE). Z dôvodu neúplnosti vybraných údajov boli ostatné krajiny z analýz vynechané. Tento prístup bol zvolený z toho dôvodu, že tu použité panelové procedúry síce dokážu pracovať aj s neúplnými premennými, avšak niektoré diagnostické testy nie. Uvažujeme premenné:

CO<sub>2</sub> – ročné emisie CO<sub>2</sub> t na os. (Global Carbon Budget, 2023).

GDP – hrubý domáci produkt (HDP) v tis. USD na os. (World Bank, 2024).

RES – % podiel primárnej spotreby energie, ktorá pochádza z obnoviteľných zdrojov (Energy Institute - Statistical Review of World Energy, 2023).

Urban – % podiel celkového počtu obyvateľov v administratívnych jednotkách klasifikovaných ako mestá, obce a predmestia (European Commission, Joint Research Centre - JRC, 2023).

EDU – miera dosiahnutia terciárneho vzdelania (Eurostat).

HEALTH – domáce výdavky verejnej správy na zdravotníctvo (GGHE-D) ako % HDP (WHO).

LIFE – stredná dĺžka života v rokoch (Our World in Data).

Pre výber uvedených premenných existujú racionálne dôvody. V predchádzajúcej práci (Litavcová et al., 2021) sme sa zaoberali iba vzťahom troch premenných a dospeli sme k zaujímavým výsledkom, čo nás motivovalo preveriť aj vplyv ďalších premenných, v ich výbere inšpirovaní (Sun et al., 2022; Petruška et al., 2022; Chovancová et al., 2024a; Osei-Kusi et al., 2024). Pre určenie „parsimony“ modelu, teda modelu, ktorý by sa v čo najlepšej možnej miere hodil na dané dáta a čo najúspornejšie popisoval závislosť vysvetľovanej premennej CO<sub>2</sub> a šiestich vyššie uvedených vysvetľujúcich premenných boli urobené nasledujúce analýzy:

- popisná štatistika,
- panelové testy stacionarity,

- panelové kointegračné testy,
- panelové testy Grangerovej kauzality,
- panelové testy prierezovej závislosti premenných,
- panelové modely FE a RE,
- panelové modely CCE
- panelové modely 2SIV,
- posttesty diagnostiky modelov.

Postup analýz je v prevažnej miere podobný, ako v predchádzajúcich prácach (Petruška et al., 2022; Chovancová et al., 2024a; Chovancová et al., 2024b). Originalita spočíva v hľadaní motivácie pre výchovu k ekologickému správaniu na báze tvorby príkladov postavených na reálnych údajoch.

### **Panelová analýza vzťahu emisií CO<sub>2</sub> a vybraných premenných**

Základné číselné charakteristiky umožnia získanie stručnej predstavy o uvažovaných premenných. Tab. 1 obsahuje ich elementárnu popisnú štatistiku.

Tab. 1: Popisná štatistika premenných

| Variable | n   | Mean    | Std. dev. | Min.    | Max.     |
|----------|-----|---------|-----------|---------|----------|
| CO2      | 528 | 8.0629  | 3.6412    | 2.9603  | 25.9850  |
| GDP      | 528 | 34.7437 | 18.8935   | 5.8488  | 135.3793 |
| RES      | 528 | 16.8047 | 11.6964   | 1.2800  | 62.6860  |
| Urban    | 528 | 72.4324 | 11.8076   | 50.7540 | 98.1170  |
| EDU      | 528 | 34.7860 | 11.3865   | 9.2000  | 62.6000  |
| HEALTH   | 528 | 5.7879  | 1.6639    | 2.1803  | 10.2243  |
| LIFE     | 528 | 78.2446 | 3.3125    | 69.5031 | 83.5520  |

Zdroj: vlastné spracovanie

#### *Predbežná analýza*

Pre vizuálne posúdenie empirickej hustoty rozdelenia bol pre každú premennú urobený graf kernel density, použijúc algoritmus Epanechnikov. (Grafy neuvádzame). Žiaden z grafov nesvedčal v prospech zhody s rozdelením normálnym, preto bola použitá logaritmická transformácia kladných premenných. Vizualne a subjektívne, najmä čo sa týka šikmosti došlo k miernemu zlepšeniu, avšak Shapiro-Wilk test normalitu zlogaritmovaných premenných zamietol (Tab. 2).

Tab. 2: Shapiro-Wilk test normality

| Variable   | Obs | W       | V      | z     | P <sub>value</sub> |
|------------|-----|---------|--------|-------|--------------------|
| Log_CO2    | 528 | 0.98664 | 4.719  | 3.739 | 0.000              |
| Log_GDP    | 528 | 0.97856 | 7.574  | 4.879 | 0.000              |
| Log_RES    | 528 | 0.97256 | 9.696  | 5.474 | 0.000              |
| Log_Urban  | 528 | 0.97256 | 9.694  | 5.474 | 0.000              |
| Log_EDU    | 528 | 0.93226 | 23.935 | 7.652 | 0.000              |
| Log_HEALTH | 528 | 0.97988 | 7.108  | 4.726 | 0.000              |
| Log_LIFE   | 528 | 0.93262 | 23.808 | 7.639 | 0.000              |

Zdroj: vlastné spracovanie

Korelačná matica (Tab. 3) skúmaných premenných poskytuje prvotnú informáciu o existencii štatistickej lineárnej závislosti dvojíc premenných. Pre každú dvojicu premenných bola vypočítaná p-hodnota. Pre  $p < 0.05$  je lineárny štatistický vzťah potvrdený na hladine významnosti 5% v tabuľke indikovaný \* (analogicky 0.01 \*\* a 0.001 \*\*\*).

Tab. 3: Pearsonove korelácie

|              | 1         | 2        | 3        | 4        | 5        | 6        |
|--------------|-----------|----------|----------|----------|----------|----------|
| 1 Log_CO2    | 1.000     |          |          |          |          |          |
| 2 Log_GDP    | 0.360***  | 1.000    |          |          |          |          |
| 3 Log_RES    | -0.590*** | -0.070   | 1.000    |          |          |          |
| 4 Log_Urban  | 0.334***  | 0.500*** | -0.116** | 1.000    |          |          |
| 5 Log_EDU    | 0.020     | 0.642*** | 0.147**  | 0.411*** | 1.000    |          |
| 6 Log_HEALTH | 0.182***  | 0.534*** | 0.099*   | 0.442*** | 0.172*** | 1.000    |
| 7 Log_LIFE   | 0.257***  | 0.801*** | -0.030   | 0.458*** | 0.504*** | 0.627*** |

Zdroj: vlastné spracovanie

Z tabuľky 3 je zrejmé, že s nežiadúcim rastom emisií CO<sub>2</sub> má významný súvis rast štyroch zo šiestich uvažovaných premenných. Naopak, s vyšším podielom primárnej spotreby energie, ktorá pochádza z obnoviteľných zdrojov (log\_RES) sa emisie (log\_CO2) významne znižujú. Miera terciárneho vzdelávania (log\_EDU) s emisiami nesúvisí. Ak zacielime pozornosť na premennú log\_EDU tak zistíme, že okrem log\_CO2 má štatisticky významný pozitívny vzťah so všetkými ostatnými skúmanými premennými. Tento interpretačný náhľad možno chápať iba ako iniciačný. Je príliš jednoduchý a neodráža panelový charakter údajov a multivariačnú komplexnosť skúmanej a problematiky a to aj v kontexte možných prediktorov do modelu nezariadených.

Tab. 4: Regresné modely

| Dep: Log_CO2 | Pooled                 |        | Panel fixed                          |        | Panel random                      |        |
|--------------|------------------------|--------|--------------------------------------|--------|-----------------------------------|--------|
|              | Coefficient            | pvalue | Coefficient                          | pvalue | Coefficient                       | pvalue |
| Log_GDP      | 0.3446                 | 0.000  | 0.1925                               | 0.000  | 0.1949                            | 0.000  |
| Log_RES      | -0.2609                | 0.000  | -0.2371                              | 0.000  | -0.2582                           | 0.000  |
| Log_Urban    | 0.4417                 | 0.000  | -1.4980                              | 0.000  | -0.9619                           | 0.000  |
| Log_EDU      | -0.2309                | 0.000  | 0.0057                               | 0.866  | -0.0161                           | 0.634  |
| Log_HEALTH   | 0.0171                 | 0.776  | -0.1204                              | 0.002  | -0.0891                           | 0.020  |
| Log_LIFE     | -0.8569                | 0.110  | -2.3370                              | 0.000  | -2.1445                           | 0.000  |
| _cons        | 1.7872                 | 0.065  | 8.1294                               | 0.000  | 6.8005                            | 0.000  |
| Sig.         | F = 84.66              | 0.000  | F = 135.83                           | 0.000  | Wald chi <sup>2</sup> =<br>762.49 | 0.000  |
|              | R <sup>2</sup> = 0.494 |        | F(all u <sub>i</sub> =0) =<br>182.84 | 0.000  |                                   |        |

Zdroj: vlastné spracovanie

V tabuľke 4 sú uvedené výsledky lineárnej regresie (Pooled), nezohľadňujúc panelovú povahu údajov, panelovej regresie s fixnými efektami a panelovej regresie s náhodnými efektami. Okrem koeficientov a ich p hodnôt sú tu aj testy významnosti modelov. Všetky tri regresie sú významne, otázkou je, ktorá z nich, a či vôbec niektorá z nich je správne zvolená na dané údaje. V klasickej regresii je modelom vysvetlených 49.4% variability závisle premennej vysvetľujúcimi premennými v modeli, čo vyplýva z hodnoty R<sup>2</sup>. Následná diagnostika multikolinearity prostredníctvom hodnoty VIF (variance inflation factor) svedčila v prospech zahrnutia všetkých premenných do modelu, pretože u žiadnej premennej VIF neprekročila hranicu 5 (Sheather, 2009). Či zahrnúť do modelu všetky premenné, môže pomôcť rozhodnúť stepwise, ridge, alebo lasso regresia.

Regresné zmršťovanie a selekciu pomocou lasso navrhol Tibshirani (1996). Ako uvádza, lasso minimalizuje reziduálny súčet štvorcov za predpokladu, že súčet absolútnej hodnoty koeficientov je menší ako konštanta. Vytvára interpretovateľné modely, ako je výber podmnožín a vykazuje stabilitu hrebeňovej regresie. Lasso sa nezameriava na podmnožiny, ale skôr definuje spojitú operáciu zmršťovania, ktorá môže produkovať koeficienty, ktoré sú presne 0, čím znižuje počet vysvetľujúcich premenných.

Tab. 5: Odhad lasso

| ID  | lambda | In-sample<br>R-squared | AIC      | Variables (A)dded,<br>(R)emoved, or left<br>(U)nchanged |
|-----|--------|------------------------|----------|---|
| 2   | 0.0942 | 0.0590                 | -368.579 | A Log_RES   |
| 7   | 0.0591 | 0.2367                 | -477.080 | A Log_GDP   |
| 11  | 0.0408 | 0.3510                 | -560.766 | A Log_Urban   |
| 23  | 0.0133 | 0.4536                 | -647.571 | A Log_EDU Log_HEALTH                                    |
| 26  | 0.0101 | 0.4697                 | -665.339 | R Log_HEALTH  |
| 40  | 0.0027 | 0.4895                 | -683.518 | A Log_LIFE  |
| 48  | 0.0013 | 0.4927                 | -684.766 | A Log_HEALTH  |
| 68* | 0.0002 | 0.4936                 | -685.761 | U   |

Zdroj: vlastné spracovanie

Lambda  $\lambda$  je penalizačný parameter, ktorý určuje veľkosť regularizácie, uzly sú hodnoty  $\lambda$ , pri ktorých sa menia premenné v modeli. Postup pridávania premenných do modelu je kontrolovaný minimalizáciou kritériálnej funkcie, čo môže byť napr. CV (cross-validation), Akaikeho informačné kritérium - AIC, Bayesovo informačné kritérium – BIC a adaptívne lasso. V tabuľke 5 sú uvedené  $\lambda$ , koeficient determinácie -  $R^2$ , AIC, a premenné v modeli pri každom uzle, ktorý je výsledkom lasso algoritmu pri použití kritériálnej funkcie CV. ID výsledného kroku algoritmu je označené \*. Výsledok je, že všetky premenné majú opodstatnenie v modeli. Avšak, pri použití kritéria adaptívne lasso by bola vylúčená log\_HEALTH, AIC -687.68 (tab. neuvedená). Proces hľadania minima kritériálnej funkcie a veľkosť štandardizovaných regresných koeficientov bol posúdený graficky (tu neuvedené). Pri rovnakom počte premenných sú výsledné koeficienty zhodné s odhadom Pooled (Tab. 4).

O tom, ktorý z troch regresných modelov z tabuľky 4 je najviac vhodný na dané údaje a či vôbec je vhodný je možné posúdiť na základe výsledkov v tabuľke 6. Vyberáme z modelov Fixed Effects (FE), Least Squares Dummy Variable Model – LSDV, Random effects (RE) a Pooled model (Torres-Reyna, 2007). Na testovanie správnosti výberu modelu (FE, RE, Pooled) použijeme Hausman test a Breusch-Pagan Lagrange multiplier test. Z výsledkov týchto dvoch testov vyplýva, že preferovaný v našom prípade je Fixed effects model. Ďalšie testy v tabuľke 6 sa týkajú overenia vhodnosti vybraného FE modelu na základe vlastností jeho rezíduí. Okrem Born a Breitung testu výsledky ostatných testov nulovú hypotézu zamietajú a svedčia o existencii heteroskedasticity, autokorelácie a prierezovej závislosti v rezíduách modelu. Ani vybraný model FE teda nie je vhodný. V ďalšom je možné pracovať s CCE (Common Correlated Estimation) modelmi, ktoré boli vyvinuté za účelom ošetrovania problému s prierezovou závislosťou rezíduí v panelových modeloch.



Tab. 6: Výber a overenie modelu

| Test                              | H <sub>0</sub>                        | Pvalue |
|-----------------------------------|---------------------------------------|--------|
| Hausman                           | Preferovaný model je RE               | 0.000  |
| Breusch-Pagan Lagrange multiplier | Žiaden panelový efekt                 | 0.000  |
| Modified Wald                     | Homoskedasticita (konštantný rozptyl) | 0.000  |
| Wooldridge                        | Žiadna autokorelácia prvého rádu      | 0.000  |
| Het.-robust Born and Breitung     | Žiadna autokorelácia prvého rádu      | 0.918  |
| Pesaran                           | Žiadna prierezová závislosť           | 0.000  |
| Friedman                          | Žiadna prierezová závislosť           | 0.000  |
| Frees                             | Žiadna prierezová závislosť           | <<0.01 |

Zdroj: vlastné spracovanie

Pred uplatnením panelových modelov je nevyhnutné zistiť, či premenné sú stacionárne, kointegrované a či v sebe majú Grangerovu kauzalitu, prierezovú závislosť, heterogenitu. Pre výber vhodného modelu sa preto musíme venovať vlastnostiam premenných.

#### Stacionarita

Aby sme sa v ďalšej analýze vyhli nekonzistentným výsledkom z časových radov v paneli, je potrebné použiť panelové testy jednotkového koreňa (unit root) testy na zistenie stacionarity premenných a diferencovaných premenných (Choi, 2001; Harris a Tzavalis, 1999). V prípade priaznivého výsledku konštatujeme, že premenné sú nestacionárnym procesom typu I(1) a teda pre analýzu vyhovujúce. Najprv bola testovaná samotná logaritmovaná úrovňová premenná a potom jej prvá diferencia. Bolo urobených 12 testov pre každú z úrovňových aj diferencovaných premenných (rozsiahle výstupné tabuľky tu neuvádzame). Z výsledkov bolo zrejmé, že u úrovňových premenných prevažná väčšina testov rozhodla v prospech existencie jednotkového koreňa, ale ich diferencia je už stacionárna.

#### Kointegrácia

Ďalšia vlastnosť premenných daného typu, ktorú je potrebné prešetriť, je kointegrácia. Ak medzi uvažovanými časovými radmi existuje dlhodobý stabilný vzťah s výnimkou krátkodobých fluktuácií, po ktorých rady vždy opäť konvergujú do pôvodného vzťahu, tak hovoríme, že existuje kointegrácia a má zmysel ju odhadovať. Hypotézou H<sub>0</sub> o neexistencii kointegrácie panelové testy kointegrácie Pedroni (Pedroni, 2004) a Westerlund (Westerlund, 2005) v tabuľke Tab. 7 na hladine významnosti 10% zamietli, ale Kao testy (Kao, 1999) nezamietli. Existencia kointegrácie síce nie je jednoznačná, ale odhadnúť dlhodobý vzťah je potrebné sa pokúsiť.

Tab. 7: Testy kointegrácie; H0: žiadna kointegrácia, predvolená H1: všetky panely sú kointegrované

|                        |   | <b>Panel Cointegration test</b>   | <b>p-value</b> |
|------------------------|---|-----------------------------------|----------------|
| <b>Kao test</b>        | 1 | Modified Dickey-Fuller            | 0.3671         |
|                        | 2 | Dickey-Fuller                     | 0.3411         |
|                        | 3 | Augmented Dickey-Fuller           | 0.2885         |
|                        | 4 | Unadjusted modified Dickey-Fuller | 0.1275         |
|                        | 5 | Unadjusted Dickey-Fuller          | 0.2570         |
| <b>Pedroni test</b>    | 1 | Modified Philips-Perron           | 0.0000         |
|                        | 2 | Philips-Perron                    | 0.0000         |
|                        | 3 | Augmented Dickey-Fuller           | 0.0000         |
| <b>Westerlund test</b> | 1 | H1: All panels are cointegrated   | 0.0620         |
|                        | 2 | H1: Some panels are cointegrated  | 0.0474         |

Zdroj: vlastné spracovanie

#### *Grangerova kauzalita*

Granger (1969) predstavil štatistický koncept kauzality medzi premennými v časových radoch v zmysle: premenná X tzv. Grangerovsky pôsobí na premennú Y, ak zahrnutie minulých hodnôt aj X aj Y do prognostického modelu poskytuje lepšie predpovede pre Y ako použitie iba minulých hodnôt Y. Pre otestovanie tzv. Grangerovej nekauzality bol použitý panelový Half-Panel Jackknife (HPJ) test typu Wald (Juodis et al., 2021; Xiao et al. 2023), kde nulová hypotéza pre premenné Y a X znie: X Grangerovsky nepôsobí na Y, zatiaľ čo alternatívna hypotéza je: X Grangerovsky pôsobí na Y aspoň v jednom paneli. To znamená, že minulé hodnoty X obsahujú informácie, ktoré pomáhajú predpovedať Y lepšie, ako iba s informáciami obsiahnutými v minulých hodnotách Y. Výsledky Grangerovho testu nekauzality sú uvedené v tabuľke 8. Dynamický odhad s použitím maximálne štyroch oneskorení bol urobený na základe Bayesovského informačného kritéria (BIC) osobitne pre každú premennú. Optimálne sa ukázalo byť použitie jedného oneskorenia u každej zo šiestich nezávisle premenných. Z tabuľky 8 je zrejmé, že všetky nezávislé premenné okrem Log\_EDU grangerovsky pôsobia na Log\_CO2.

Tab. 8: Testy Grangerovej kauzality

| Log_CO2    | HRJ-Wald test | P <sub>value</sub> | Coef L1   | P <sub>value</sub> |
|------------|---------------|--------------------|-----------|--------------------|
| Log_GDP    | 5.2480        | 0.0220             | -.0540490 | 0.0220             |
| Log_RES    | 5.6976        | 0.0170             | -.0512428 | 0.0170             |
| Log_Urban  | 5.1673        | 0.0230             | -.6809222 | 0.0230             |
| Log_EDU    | 0.8569        | 0.3546             | -.0320393 | 0.3546             |
| Log_HEALTH | 10.2368       | 0.0014             | -.1078069 | 0.0014             |
| Log_LIFE   | 5.0970        | 0.0240             | -.7999442 | 0.0240             |

Zdroj: vlastné spracovanie

Avšak, odhad s rovnakými podmienkami urobený mnohorozmerne poskytol HRJ-Wald test významný na 0.1 % hladine významnosti pri optimálnom použití dvoch oneskorení. Výsledné koeficienty (tu neuvedené) ukázali, že dve oneskorenia Log\_EDU, Log\_GDP, Log\_RES a jedno oneskorenie Log\_LIFE významne ovplyvňujú Log\_CO2. Naopak, koeficienty oboch oneskorení Log\_HEALTH a Log\_Urban nie sú významné v modeli. Záver, Grangerova kauzalita tu existuje, má zmysel sa snažiť odhadnúť dynamický model.

#### Prierezová závislosť

Problém prierezovej závislosti (CSD – cross-sectional dependence) znamená, že prierezové jednotky sú na sebe závislé, napríklad zdieľaním spoločného faktora. Môže to vyplynúť napríklad z toho, že susedné krajiny sú zvyčajne veľmi prepojené. Presné matematické definície typov prierezovej závislosti je možné nájsť v Sarafidis a Wansbeek (2012). Chudik et al. (2011) uvádza veľkosť meradla sily, tzv. exponenta prierezovej závislosti pre slabú  $\alpha = 0$ , polo-slabú  $0 < \alpha < 0.5$ , polo-silnú  $0.5 \leq \alpha < 1$  a silnú  $\alpha = 1$  prierezovú závislosť. Ak sa táto závislosť ignoruje, výsledky odhadov môžu byť skreslené a nekonzistentné. Preto je potrebné pochopiť rozsah prierezovej závislosti a podľa toho zvoliť metódu odhadu (Ditzen, 2019, 2021). Z toho dôvodu v tabuľke 9 uvádzame odhad veľkosti exponenta prierezovej závislosti, test CD (Pesaran, 2015, 2021) u ktorého H<sub>0</sub> znie, že  $\alpha < 0.5$  a alternatívna hypotéza znamená, že prierezová závislosť je silná. Ďalšie testy sú CDW (Juoris a Reese, 2022), CDW+ (Fan et al, 2015) a CD\* (Pesaran a Xie, 2021). V tabuľke 9 uvedené vysoké výsledné hodnoty exponenta prierezovej závislosti  $\alpha$  a prijatie alternatívnej hypotézy o silnej prierezovej závislosti u väčšiny CD testov okrem CD\* testu pobádajú pri hľadaní výsledného panelového modelu k použitiu algoritmu, ktorý existenciu silnej prierezovej závislosti eliminuje. Avšak, Pesaran a Xie (2021) ukázali, že štandardný test CD zostáva platný, len ak sú latentné faktory slabé, a navrhli jednoduchý test CD s korekciou odchýlky, označený CD\*, ktorý sa ukázal ako asymptoticky normálny, bez ohľadu na to, či sú latentné faktory slabé alebo silné.

Tab. 9: Testy prierezovej závislosti

|            | alpha    | CD       | CDw     | CDw+       | CD*   |
|------------|----------|----------|---------|------------|-------|
| Log_CO2    | 0.994023 | 42.46*** | 0.37    | 901.43***  | 1.40  |
| Log_GDP    | 1.007315 | 75.30*** | 5.41*** | 1256.39*** | -0.20 |
| Log_RES    | 1.007302 | 70.08*** | 4.77*** | 1169.04*** | 0.39  |
| Log_Urban  | 1.007306 | 30.84*** | 1.66    | 1035.04*** | -0.02 |
| Log_EDU    | 1.007310 | 71.53*** | 5.28*** | 1193.62*** | -1.13 |
| Log_HEALTH | 0.982906 | 36.71*** | 2.02*   | 698.02***  | -0.58 |
| Log_LIFE   | 1.007311 | 73.72*** | 5.05*** | 1229.74*** | -0.34 |

Zdroj: vlastné spracovanie

### *Heterogenita koeficientov*

Modely časových radov pokrývajú jednu panelovú jednotku a heterogenita sklonu medzi jednotkami je irelevantná. Panelové modely obsahujú veľa panelových jednotiek a koeficienty dlhodobého alebo krátkodobého dosahu sa môžu medzi nimi líšiť. Homogenita koeficientov sklonu bola preverená testovacou štatistikou Delta (Blomquist a Westerlund, 2013) na základe (Pesaran a Yamagata, 2008). Nulová hypotéza je  $H_0$ : koeficienty sklonu sú homogénne. Testovacia štatistika Delta v hodnote 10.494 a p-hodnote 0.000 túto hypotézu zamietajú. Koeficienty sklonu sú heterogénne.

### *Výsledný panelový model*

V prípade existencie silnej prierezovej závislosti je (Ditzen 2018, 2021) ju možné aproximovať buď metódou hlavných komponentov (Bai a Ng, 2002; Bai, 2009) alebo pridaním prierezových priemerov (Pesaran, 2006).

Prvý spôsob (Norkutė et al., 2021; Cui et al., 2022) nazvaný 2SIV je odhad s inštrumentálnymi premennými, ktoré sú projekciou pôvodných exogénnych kovariát odstránením spoločných faktorov z nich aplikáciou metódy hlavných komponentov. Takto získané parametre v prvom kroku sa v druhom kroku použijú na defaktorizáciu modelu na základe faktorových rezíduí. Potom sa uskutoční ďalšia regresia s použitím inštrumentálnych premenných získaných v prvom stupni (Kripfganz a Sarafidis, 2021).

Druhý spôsob je podľa Ditzena (2021) kvôli jednoduchosti veľmi populárny, jedná sa o aproximáciu spoločných faktorov pridaním prierezových priemerov nezávislých a závislých premenných, v dynamickej verzii aj ich posunutí. Odhad sa nazýva CCE (common correlated effects estimator) a aplikuje sa na statické (Pesaran, 2006) a dynamické (Chudik a Pesaran, 2015; Karabiyik et al., 2017) panelové modely. Odhad CCE sa uskutočňuje dvoma metódami, buď CCE-MG (mean group) (Chudik a Pesaran, 2019) alebo CCE-P (pooled) (Karabiyik et al., 2021).

Kointegračná analýza dynamických modelov umožňuje odhad dlhodobých vzťahov. Zisťuje vplyv vysvetľujúcej premennej na hodnotu ustáleného stavu závislej premennej. Dlhodobý efekt možno odhadnúť pomocou prístupu ARDL (autoregressive distributed lag) (Pesaran a Shin, 1999), DL (distributed lag) a reparametrizáciou ARDL vo forme ECM (error correction model) (Engle a Granger, 1987; Hassler a Wolters, 2006). Všetky tri môžu byť rozšírené o prierezové priemery na aproximáciu prierezovej závislosti (Ditzen, 2021). Prierezovo rozšírený: 1. prístup korekcie chýb (CS-ECM) uviedol Lee et al. (1997) a Pesaran et al. (1999), 2. prístup autoregresných distribuovaných posunutí CS-ARDL a 3. prístup distribuovaných posunutí CS-DL uviedol Chudik et al. (2016).

V prvom a druhom stĺpci tabuľky 10 sú uvedené odhady CCE-MG modelov, v prvom so všetkými premennými, v druhom s vynechanou premennou Log.HEALTH. Použité regresory v oboch modeloch boli všetky vybraté ako „mean group“ a všetky premenné pre medziskupinové priemery. Oba modely sa

s prierezovou závislosťou dobre vysporiadali (alpha je blízke 0.05 a p hodnota CD testu  $>0.05$ ) avšak nie sú významné (p hodnota F testu  $>0.05$ ); v prvom stĺpci sa koeficienty Log.GDP a Log\_LIFE priblížili významnosti ( $p < 0.1$ ) a v druhom koeficient Log.LIFE, koeficient Log.RES je ( $p = 0.001$ ) je významný. Tretí a štvrtý stĺpec obsahuje odhady 2SIV modelov použité vo verzii MG (mean group) z dôvodu zamietnutia nulovej hypotézy o homogenite koeficientov sklonu. V oboch použitých 2SIV modeloch sú významné koeficienty Log.GDP, Log.RES a Log.LIFE, avšak modely nie sú uspokojivé z hľadiska prierezovej závislosti (alpha vysoko prevyšuje 0.05 a p hodnota CD testu je  $< 0.001$ ). Všetky modely v tabuľke 10 sú statické, pre krátkosť časového intervalu nebolo možné pracovať s dynamickými modelmi.

Tab. 10: Modely CCE a 2SIV

|             | CCE-MG    | CCE-MG      | 2SIV (MG)    | 2SIV (MG)    |
|-------------|-----------|-------------|--------------|--------------|
| Log_GDP     | 0.239274  | 0.116693    | 0.272416**   | 0.251746**   |
| Log_RES     | -0.146207 | -0.229777** | -0.196687*** | -0.180591*** |
| Log_Urban   | 6.443673  | 4.597058    | -0.765171    | .202122      |
| Log_EDU     | 0.038411  | -0.031085   | -0.103790    | -0.056467    |
| Log_HEALTH  | 0.134353  |             | -0.073977    |              |
| Log_LIFE    | -2.277540 | -2.219492   | -1.988974**  | -2.165796**  |
| F           | 1.01      | 0.97        |              |              |
| CD (pvalue) | 0.334     | 0.048       | 0.000        | 0.000        |
| Alpha       | 0.529773  | 0.548973    | 0.851694     | .904942      |

Zdroj: vlastné spracovanie

Keďže sa nepodarilo nájsť po každej stránke uspokojivý ani CCE ani 2SIV model, tak bola využitá kointegračná analýza, odhad modelom CS-ECM (Tab. 11). Všetky koeficienty boli vybraté ako heterogénne. Výsledný model je významný (p hodnota F testu  $< 0.001$ ), uspokojivý z hľadiska prierezovej závislosti (alpha je pomerne blízke 0.05 a p hodnota CD testu je tesne  $> 0.05$ ). Koeficienty krátkodobé nie sú významné, z dlhodobého hľadiska sú významné Log.RES a Log.LIFE. Model v tabuľke 11 je možné považovať za korektný výsledný model celého snaženia.

Tab. 11: Model CS-ECM

| ShortRunEst. | Coefficient | pvalue | LongRunEst. | Coefficient | pvalue |
|--------------|-------------|--------|-------------|-------------|--------|
| D.Log_GDP    | 0.177178    | 0.427  | Log_GDP     | 0.027766    | 0.903  |
| D.Log_RES    | 0.101435    | 0.607  | Log_RES     | -0.707595   | 0.041  |
| D.Log_Urban  | -37.13837   | 0.725  | Log_Urban   | -14.41551   | 0.357  |
| D.Log_EDU    | -0.198377   | 0.287  | Log_EDU     | -0.002240   | 0.993  |
| D.Log_LIFE   | 1.864370    | 0.362  | Log_LIFE    | -9.631683   | 0.041  |
| Adjust.Term  |             |        | F           | 4.26        | 0.000  |
| L.Log_CO2    | -1.194721   | 0.000  | CD          |             | 0.051  |
|              |             |        | Alpha       | 0.606136    |        |

Zdroj: vlastné spracovanie

## Záver

Panelová regresia je silný nástroj pre skúmanie vzťahu náhodných premenných, ktoré sú sledované prierezovo aj časovo. Cieľom článku bolo poukázať na výhody jej použitia a hľadať možnosti jej aplikácie v pedagogickom výskume, špeciálne v oblasti environmentálneho vzdelávania. Pracovalo sa so šiestimi regresormi vo vzťahu k produkcii skleníkových plynov sledovanými počas 22 rokov v 24 krajinách Európy. Výsledným zistením je, že v rámci vybraných údajov je z dlhodobého hľadiska žiadúci pokles emisií skleníkových plynov významnou mierou sprevádzaný nárastom % podielu primárnej spotreby energie, ktorá pochádza z obnoviteľných zdrojov a nárastom strednej dĺžky života. Keďže pri výbere dynamických modelov sme boli limitovaní dĺžkou časových radov, v ďalšom skúmaní vyberieme dlhšie časové rady. Uvedený príklad bol ukážkou toho, ako je dôležité dôsledne posúdiť vlastnosti premenných a dodržanie požiadaviek na rezíduá skúmaných modelov pre výber výsledného modelu, ktorý je vhodný na dané údaje. Ak vybraný model navyše poskytne pozoruhodné súvislosti, je výsledok možné ponúknuť záujmovej komunite.

## Bibliografia

- Bai, J. (2009). Panel Data Models With Interactive Fixed Effects. *Econometrica*, 77(4), 1229–1279. <https://doi.org/10.3982/ECTA6135>
- Bai, J., and Ng, S. (2002). Determining the number of factors in approximate factor models. *Econometrica*, 70(1), 191–221. <https://doi.org/10.1111/1468-0262.00273>
- Baltagi, B. H. (2008). *Econometric Analysis of Panel Data*. 4th ed. New York: Wiley.
- Blomquist, J., and Westerlund, J. (2013). Testing slope homogeneity in large panels with serial correlation. *Economics Letters*, 121(3), 374–378. <https://doi.org/10.1016/j.econlet.2013.09.012>
- Choi, I. (2001). Unit root tests for panel data. *Journal of International Money and Finance*, 20(2), 249–272. [https://doi.org/10.1016/S0261-5606\(00\)00048-6](https://doi.org/10.1016/S0261-5606(00)00048-6)
- Chovancová, J., Petruška, I., Cirella, G. T., and Litavcová, E. (2024a). Urbanization and CO2 emissions: Panel data analysis of EU countries. *City Responses to Disruptions in 2020: From Lockdowns to Aftermath*. Springer, Singapore. 2024, pp. 123–175. [https://doi.org/10.1007/978-981-99-7988-2\\_8](https://doi.org/10.1007/978-981-99-7988-2_8)
- Chovancová, J., Petruška, I., Rovňák, M., and Barlák, J. (2024b). Investigating the drivers of CO2 emissions in the EU: Advanced estimation with common correlated effects and common factors models. *Energy Reports*, 11, 937–950. <https://doi.org/10.1016/j.egy.2023.12.057>

- Chudik, A., Pesaran, M. H., and Tosetti, E. (2011). Weak and strong cross-section dependence and estimation of large panels. *The Econometrics Journal*, 14(1), C45–C90. <https://doi.org/10.1111/j.1368-423X.2010.00330.x>
- Chudik, A., and Pesaran, M. H. (2015). Common correlated effects estimation of heterogeneous dynamic panel data models with weakly exogenous regressors. *Journal of Econometrics*, 188(2), 393–420. <https://doi.org/10.1016/j.jeconom.2015.03.007>
- Chudik, A., Mohaddes, K., Pesaran, M. H., and Raissi., M. (2016). Long-Run Effects in Large Heterogeneous Panel Data Models with Cross-Sectionally Correlated Errors. In *Essays in Honor of Aman Ullah (Advances in Econometrics, Vol. 36)*, ed. R. C. Hill, G. González-Rivera, and T.-H. Lee, 85–135. <https://doi.org/10.1108/S0731-905320160000036013>
- Chudik, A., and Pesaran., M. H. (2019). Mean group estimation in presence of weakly cross-correlated estimators. *Economics Letters*, 175, 101–105. <https://doi.org/10.1016/j.econlet.2018.12.036>
- Cui, G., Norkutè, M., Sarafidis, V., and Yamagata, T. (2022). Two-stage instrumental variable estimation of linear panel data models with interactive effects. *The Econometrics Journal*, 25(2), 340–361. <https://doi.org/10.1093/ectj/utab029>
- Ditzen, J. (2018). Estimating dynamic common-correlated effects in Stata. *The Stata Journal*, 18(3), 585–617. <https://doi.org/10.1177/1536867X1801800306>
- Ditzen, J. (2019). XTCSE2: Stata module to estimate the exponent of cross-sectional dependence in large panels. *Statistical Software Components S458670*, Boston College, Department of Economics.
- Ditzen, J. (2021). Estimating long-run effects and the exponent of cross-sectional dependence: An update to xtdcce2. *The Stata Journal*, 21(3), 687–707. <https://doi.org/10.1177/1536867X211045560>
- Engle, R. F., and Granger., C. W. J. (1987). Co-Integration and Error Correction: Representation, Estimation, and Testing. *Econometrica*, 55(2), 251–276. <https://doi.org/10.2307/1913236>
- Fan, J., Liao, Y., and Yao, J. (2015). Power Enhancement in High-Dimensional Cross-Sectional Tests. *Econometrica*, 83(4), 1497–1541. <https://doi.org/10.3982/ECTA12749>
- Gracia, J., Torres-Porrás, J., and Alcántara-Manzanares, J. (2024). Overview of the implementation of a 30-year programme on environmental and sustainability education in Spain. *Environmental Education Research*, 30(2), 265–282. <https://doi.org/10.1080/13504622.2023.2252623>
- Granger, C. W. J. (1969). Investigating causal relations by econometric models and cross-spectral methods. *Econometrica*, 37(3), 424–438. <https://doi.org/10.2307/1912791>

- Harris, R. D. F., and Tzavalis., E. (1999). Inference for unit roots in dynamic panels where the time dimension is fixed. *Journal of Econometrics*, 91(2), 201–226. [https://doi.org/10.1016/S0304-4076\(98\)00076-1](https://doi.org/10.1016/S0304-4076(98)00076-1)
- Hassler, U., and Wolters., J. (2006). Autoregressive distributed lag models and cointegration. *Allgemeines Statistisches Archiv*, 90, 59–74. <https://doi.org/10.1007/s10182-006-0221-5>
- Juodis, A., and Reese, S. (2022). The incidental parameters problem in testing for remaining cross-section correlation. *Journal of Business & Economic Statistics*, 40(3), 1191–1203. <https://doi.org/10.1080/07350015.2021.1906687>
- Juodis, A., Karavias, Y., and Sarafidis, V. (2021). A homogeneous approach to testing for Granger non-causality in heterogeneous panels. *Empirical Economics*, 60, 93–112. <https://doi.org/10.1007/s00181-020-01970-9>
- Kao, C. (1999). Spurious regression and residual-based tests for cointegration in panel data. *Journal of Econometrics*, 90(1), 1–44. [https://doi.org/10.1016/S0304-4076\(98\)00023-2](https://doi.org/10.1016/S0304-4076(98)00023-2)
- Karabiyik, H., Reese, S., and Westerlund., J. (2017). On the role of the rank condition in CCE estimation of factor-augmented panel regressions. *Journal of Econometrics*, 197(1), 60–64. <https://doi.org/10.1016/j.jeconom.2016.10.006>
- Karabiyik, H., Westerlund, J., and Juodis., A. (2021). On the Robustness of the Pooled CCE Estimator. *Journal of Econometrics*, 220(2), 325–348. <https://doi.org/10.1016/j.jeconom.2020.06.002>
- Kripfganz, S., and Sarafidis, V. (2021). Instrumental-variable estimation of large-T panel-data models with common factors. *The Stata Journal*, 21(3), 659–686. <https://doi.org/10.1177/1536867X211045558>
- Lee, K., Pesaran, M. H., and Smith, R. (1997). Growth and Convergence in a Multi-Country Empirical Stochastic Solow Model. *Journal of Applied Econometrics*, 12(4), 357–392. [https://doi.org/10.1002/\(SICI\)1099-1255\(199707\)12:4<357::AID-JAE441>3.0.CO;2-T](https://doi.org/10.1002/(SICI)1099-1255(199707)12:4<357::AID-JAE441>3.0.CO;2-T)
- Litavcová, E., and Chovancová, J. (2021). Economic Development, CO2 Emissions and Energy Use Nexus-Evidence from the Danube Region Countries. *Energies*, 14(11), 3165. <https://doi.org/10.3390/en14113165>
- Norkutė, M., Sarafidis, V., Yamagata, T., and Cui, G. (2021). Instrumental variable estimation of dynamic linear panel data models with defactored regressors and a multifactor error structure. *Journal of Econometrics*, 220(2), 416–446. <https://doi.org/10.1016/j.jeconom.2020.04.008>
- Osei-Kusi, F., Wu, C., Tetteh, S., and Castillo, W. I. G. (2024). The dynamics of carbon emissions, energy, income, and life expectancy: Regional comparative analysis. *PLoS One*, 19(2), e0293451. <https://doi.org/10.1371/journal.pone.0293451>
- Pedroni, P. (2004). Panel cointegration: asymptotic and finite sample properties of pooled time series tests with an application to the PPP hypothesis. *Econometric Theory*, 20(3), 597–625. <https://doi.org/10.1017/S0266466604203073>



- Pesaran, M. H., and Shin., Y. (1999). An autoregressive distributed-lag modelling approach to cointegration analysis. In *Econometrics and Economic Theory in the 20th Century: The Ragnar Frisch Centennial Symposium*, ed. S. Strøm, 371–413. Cambridge: Cambridge University Press. <https://doi.org/10.1017/CCOL521633230.011>
- Pesaran, M. H., Shin, Y., and Smith, R. P. (1999). Pooled Mean Group Estimation of Dynamic Heterogeneous Panels. *Journal of the American Statistical Association*, 94(446), 621–634. <https://doi.org/10.1080/01621459.1999.10474156>
- Pesaran, M. H. (2006). Estimation and inference in large heterogeneous panels with a multifactor error structure. *Econometrica*, 74(4), 967–1012. <https://doi.org/10.1111/j.1468-0262.2006.00692.x>
- Pesaran, M. H., and Yamagata, T. (2008). Testing slope homogeneity in large panels. *Journal of Econometrics*, 142(1), 50–93. <https://doi.org/10.1016/j.jeconom.2007.05.010>
- Pesaran, M. H. (2015). Testing Weak Cross-Sectional Dependence in Large Panels. *Econometric Reviews*, 34(6-10), 1089–1117. <https://doi.org/10.1080/07474938.2014.956623>
- Pesaran, M. H. (2021). General diagnostic tests for cross-sectional dependence in panels. *Empirical Economics*, 60(1), 13–50. <https://doi.org/10.1007/s00181-020-01875-7>
- Pesaran, M. H., and Xie, Y. (2023). *A bias-corrected CD test for error cross-sectional dependence in panel data models with latent factors*. <http://dx.doi.org/10.2139/ssrn.4198155>
- Petruška, I., Litavcová, E., and Chovancová, J. (2022). Impact of Renewable Energy Sources and Nuclear Energy on CO<sub>2</sub> Emissions Reductions—The Case of the EU Countries. *Energies*, 15(24), 9563. <https://doi.org/10.3390/en15249563>
- Rocha, T. A., Silva, L. B., Alves, E., B., B., M., and Jacovine, L., A., G. (2023). Carbon footprint in an educational institution and compensation potential in urban forests. *Environmental Development*, 46, 100860. <https://doi.org/10.1016/j.envdev.2023.100860>
- Sarafidis, V., and Wansbeek, T. (2012). Cross-sectional dependence in panel data analysis. *Econometric Reviews*, 31(5), 483–531. <https://doi.org/10.1080/07474938.2011.611458>
- Sarafidis, V., and Wansbeek, T. (2021). Celebrating 40 years of panel data analysis: Past, present and future. *Journal of Econometrics*, 220(2), 215–226. <https://doi.org/10.1016/j.jeconom.2020.06.001>
- Sheather, S. (2009). *A modern approach to regression with R*. New York, NY: Springer. <https://doi.org/10.1007/978-0-387-09608-7>
- Sun, Y., Li, H., Andlib, Z., and Genie, M. G. (2022). How do renewable energy and urbanization cause carbon emissions? Evidence from advanced panel estimation techniques. *Renewable Energy*, 185, 996–1005. <https://doi.org/10.1016/j.renene.2021.12.112>

- Tibshirani, R. (1996). Regression Shrinkage and Selection via the Lasso. *Journal of the Royal Statistical Society: Series B (Methodological)*, 58(1), 267–288. <https://doi.org/10.1111/j.2517-6161.1996.tb02080.x>
- Torres-Reyna, O. (2007). Panel data analysis fixed and random effects using Stata (v. 4.2). *Data & Statistical Services, Princeton University*, 112(49).
- Westerlund, J. (2005). New simple tests for panel cointegration. *Econometric Reviews*, 24(3), 297–316. <https://doi.org/10.1080/07474930500243019>
- Xiao, J., Juodis, A., Karavias, Y., Sarafidis, V., and Ditzgen, J. (2023). Improved Tests for Granger Noncausality in Panel Data. *The Stata Journal*, 23(1), 230–242. <https://doi.org/10.1177/1536867X231162034>
- 2023 *Advancing Net Zero Status Report*. <https://worldgbc.org/article/2023-advancing-net-zero-status-report/>
- What is net zero and zero carbon? <https://www.neso.energy/energy-101/net-zero-explained/what-net-zero-and-zero-carbon>

*Príspevok vznikol v rámci grantových úloh: KEGA 004KU-4/2025 Osobnosti slovenskej matematiky III - životné vzory pre budúce generácie; KEGA 010KU-4/2025 Štatistická gramotnosť žiaka 21. storočia. Zbierka úloh pre efektívne budovanie a rozvoj štatistickej gramotnosti na základných a stredných školách.*

**Doc. Mgr. Eva Litavcová, PhD.**

Katedra matematiky

Katolícka univerzita v Ružomberku, Pedagogická fakulta

Hrabovská cesta 1, 034 01 Ružomberok

[eva.litavcova@ku.sk](mailto:eva.litavcova@ku.sk)