ANALÝZA VPLYVU ĽUDSKÉHO KAPITÁLU NA CELKOVÚ PRODUKTIVITU FAKTOROV V REGIÓNOCH EÚ S VYUŽITÍM PRIESTOROVÉHO DURBINOVHO MODELU

Paula Puškárová, Ekonomická univerzita v Bratislave*

DOI: 10.18267/j.polek.1018

Úvod

Výskum znalostného prelievania má silný politický i ekonomický význam. Krajina, región či ekonomický subjekt môže cez dovoz zahraničných znalostí zvyšovať svoju produktivitu bez toho, aby vynakladala vysoké výdavky na výskum a vývoj z vlastných zdrojov. Tvorcov národnej politiky pritom zvyčajne zaujíma predovšetkým sumárny efekt zahraničných znalostí na agregátnu produktivitu, ktorý abstrahuje od potenciálne kompenzačných efektov v mikroprostredí. Agregátnou produktivitou sa predovšetkým myslí reziduálna hodnota medzi agregátnym produktom a vstupmi do produkcie – tzv. celková produktivita faktorov (Total Factor Productivity, TFP).

V súlade so súčasným stavom výskumu problematiky vyvstávajú tak otázky: Aký rozsiahly (ak nejaký) vplyv majú znalosti naakumulované v zahraničí na domácu produktivitu? Ktorými premennými môžeme tieto znalosti zachytiť? Nakoľko je pre domácu produktivitu významný ľudský kapitál? Akú úlohu zohráva pre lokálnu produktivitu úroveň ľudského kapitálu nachádzajúca sa v geografickej blízkosti? Ovplyvňuje vôbec geografická blízkosť k oblastiam koncentrácie znalostí a ľudského kapitálu domácu produktivitu?

Cieľom tohto článku je zodpovedať tieto otázky, konkrétne preskúmať vplyv interného a externého znalostného a ľudského kapitálu na celkovú produktivitu faktorov v Európskej únii (EÚ), ktorej súčasťou sú Česká i Slovenská republika. V snahe odhaliť vplyv geografickej blízkosti, a tým klasterizačné tendencie, ktoré sú na menšom rozsahu štatisticky zreteľnejšie, sme sa rozhodli analyzovať úroveň regionálnu, a nie úroveň štátnu. Dostupnosť dát nás prinútila zostať na úrovni NUTS-2 (Nomenclature of Territorial Units for Statistics – Spoločná nomenklatúra územných jednotiek pre štatistické účely), ohraničiť sledované obdobie na roky 2000–2010 a z analyzovanej vzorky vylúčiť grécke regióny. Vzhľadom na vybrané sledované obdobie sme sa rozhodli rátať so všetkými NUTS-2 regiónmi členských krajín EÚ, ktoré do EÚ vstúpili

* Článok prezentuje názory výhradne autora, ktorý nesie plnú zodpovednosť za všetky možné chyby alebo skreslenia. Článok vznikol v rámci projektov mladých vedeckých pracovníkov (PMVP) č. I-14-101-00 a č. I-15-108-00, financovanými Ekonomickou univerzitou v Bratislave. Veľká vďaka patrí anonymným recenzentom za ich cenné pripomienky a postrehy.

do konca roka 2010 (bez gréckych), a pre ktoré sme získali kompletne časové údaje za obdobie 2000–2010 pre všetky sledované premenné, teda s 251 regiónmi 26 krajín EÚ. Prehľad zahrnutých NUTS-2 regiónov uvádzame v Prílohe.

Článok prináša nové poznatky oproti existujúcej literatúre v niekoľkých aspektoch: V prvom rade, analyzuje prelievanie znalostí za celú EÚ, v ktorej sú zahrnuté aj regióny krajín, ktoré pristúpili k EÚ v rokoch 2004 a 2007. V druhom rade, zameriava sa na prelievanie znalostí cez ľudský kapitál. V treťom rade, navrhuje a testuje model kombinovaného vplyvu ľudského kapitálu na TFP, rešpektujúc dve základné úrovne tohto vplyvu. V neposlednom rade, aplikuje novú metodiku odhadovania priestorového Durbinovho modelu (Spatial Durbin Model, SDM) na panelových dátach vyvinutú Elhorstom (2012).

Zvyšok článku je štruktúrovaný nasledovne: V navádzujúcej časti oboznamujeme so súčasným stavom problematiky. Následne predstavujeme teoretický model a jeho empirickú špecifikáciu. V tretej časti vysvetľuje článok zdroje a zostavenie panelových dát. V štvrtej časti ukazuje a interpretuje výsledky empirických odhadov modelu. Nasleduje kontrola robustnosti empirických výsledkov a v záverečnej časti sú zosumarizované kľúčové závery a prínosy článku.

1. Súčasný stav problematiky

Existencia vplyvu zahraničných znalostí na domácu produktivitu, čo je podstatou znalostného prelievania, bola predmetom štúdií na viacerých úrovniach produkcie – medzi firmami (Barbosa a Eiriz, 2009), sektormi (Jordaan, 2008), ako i na národnej úrovni (Kemeny, 2010). Na úrovni regiónov Európskej únie (EÚ) sa tejto problematike venovali predovšetkým Bottazzi a Peri (2003). Štúdie sa však sústredili na prenos znalostí cez medzinárodné toky tovaru a kapitálu. Argumentovali pritom, že pri usídľovaní priamych zahraničných investícií (PZI) prináša so sebou zahraničný investor znalosti a technológie, ktoré prenáša na zamestnancov, aby zvýšil ich produktivitu. Lokálna konkurencia je v snahe udržať sa na trhu zároveň nútená zvyšovať svoju produktivitu, prípadne zamestnať pracovnú silu z PZI podnikov, a tým benefitovať z tréningu, ktorý tam získal (Čaplánová *et al.*, 2012; Hanousek *et al.*, 2012). Podobne pri importe a exporte nesú výrobky a služby v sebe zabudovanú znalosť zahraničnej firmy (obsahovú, marketingovú, cenovú alebo inú), ktorú sa lokálne subjekty snažia skopírovať alebo vylepšiť pre domáci trh, a tým reštrukturalizujú a zvyšujú svoju produktivitu (Ferreira a Trejos, 2011). Najnovšie štúdie pritom poukazujú na to, že cez zahraničný obchod prichádza do ekonomiky viac znalostí ako cez PZI (Krammer, 2014).

Ekonomická geografia však upozorňuje, že prenos znalostí je silne ovplyvnený exogénne, a to geografickou polohou daného subjektu voči centrárami intenzívnych vedecko-výskumných aktivít. Geografická blízkosť znižuje náklady na pravidelnú interakciu a komunikáciu medzi ekonomickými subjektmi, a zároveň znižuje risk mylného využitia znalosti, resp. vyššiu absorpčnú schopnosť¹. Vo výsledku sa tak prenos

1 Absorpčné schopnosti súvisia napríklad s podobným socio-ekonomickým zázemím, tvorbou dopytu – pre prehľad viď Fagerberg *et al.* (2010).

znalostí lokalizuje. Na tejto perspektíve stavia i tento článok. V literatúre sa mu začala venovať potrebná pozornosť až v poslednom desaťročí. Robbins (2006) sleduje vplyv znalostného kapitálu na rast produktivity firiem v USA. Fischer *et al.* (2009) aplikujú podobnú metodiku na krajiny EÚ 15 a Scherngell *et al.* (2014) na firmy v Číne. Literatúra momentálne nepozná štúdiu priestorového prelievania znalostí v regióne členských krajín EÚ, ktoré pristúpili po roku 2004.

Literatúra sa taktiež málo venuje vplyvu ľudského kapitálu na vývoj TFP. Pravdepodobne je dôvodom viacúrovňový charakter pôsobenia ľudského kapitálu. V tejto práci sa zameriame na dve, z nášho pohľadu kľúčové úrovne vplyvu: Prvou je úroveň agregátnej produkcie (Ishise a Sawada, 2009), druhou je tvorba znalostného kapitálu ako základného determinantu TFP (Jones, 1995). To, že tieto dve úrovne nie sú konfliktné, ba práve naopak – vzájomnou interakciou znásobujú vplyv ľudského kapitálu na TFP, môžeme odôvodniť nasledovne: Na úrovni produkcie znalostí pôsobí ľudský kapitál v prvom rade ako výrobný faktor a častokrát jeho produkt môžeme vyjadriť len vo forme vyprodukovanej technológie (a forme patentu). Iné efekty ľudského kapitálu na tejto úrovni sa nesledujú. Na úrovni agregátnej produkcie však ľudský kapitál vplýva na TFP aj cez vyprodukované nepatentovateľné znalosti, ktorých vplyv podľa Grilicha (1990) je značný, a cez časom nadobudnuté pracovné skúsenosti, ktoré si ľudský kapitál vytvorí mimovoľne alebo cielene (*on-job-training*). Okrem toho vplyv ľudského kapitálu na TFP môže byť znásobený aj povahovými a vôľovými vlastnosťami ľudského kapitálu (akými sú disciplína, pracovné nasadenie, efektívne využívanie času, nálada). Vo výsledku teda tak môžeme badať multiplikovaný efekt ľudského kapitálu na TFP – úžitky z vytvorenej znalosti maximalizuje svojimi vôľovými a povahovými vlastnosťami, ako i predošlou skúsenosťou.

Podobne ako znalostný kapitál, aj ľudský kapitál je schopný produkovať pozitívne externality. Moretti (2004) a Niehaus (2012) naznačujú, že TFP danej ekonomiky je spätá nielen s domácim (lokálnym) ľudským kapitálom, ale i s ľudským kapitálom nachádzajúcim sa v istej (geografickej alebo ekonomickej) blízkosti. Náklady na budovanie vedecko-výskumných aliancií sa zvyšujú s rastúcou vzdialenosťou, preto sa vedecko-výskumné aliancie klasterizujú v okoliach dostatku ľudského kapitálu (Rosenthal a Strange, 2008). Nedostatok ľudského kapitálu totiž nie je len bariérou pre tvorbu znalostí, ale i pre prenos znalostí. Ekonomický subjekt musí byť schopný pochopiť a využiť prenášanú znalosť, a na to musí disponovať istým ľudským kapitálom. Štúdia, ktorá by sa pokúsila ďalej analyzovať a konkretizovať vplyv týchto pozitívnych externalít generovaných ľudským kapitálom, literatúre však zatiaľ nie je známa.

2. Model

Náš model vychádza z klasickej Cobb-Douglasovej produkčnej funkcie, ktorá je aj základným vzorcom pre výpočet celkovej produktivity faktorov (Total Factor Productivity, TFP), a rozširuje ju o ľudský kapitál. Toto rozšírenie je kľúčové pre overenie našej výskumnej otázky, keďže ľudský kapitál ovplyvňuje TFP na dvoch

úrovniah – v rámci procesu tvorby znalostí (Jones, 1995) a na úrovni multiplikátora v agregátnej produkcii (Ishise a Sawada, 2009). Ak označíme regióny $i = 1, \dots, N$ a roky $t = 1, \dots, T$, rozšírená Cobb-Douglasova produkčná funkcia nadobúda tvar:

$$Y_{it} = A_{it} H_{it}^{\psi} L_{it}^{\alpha} C_{it}^{1-\alpha} \exp(\varepsilon_{it}), \quad (1)$$

kde Y_{it} reprezentuje celkový agregátny produkt, ktorý je funkciou práce L_{it} , fyzického kapitálu C_{it} a ľudského kapitálu H_{it} . Oba tieto faktory vstupujú do produkcie s istou produktivitou A_{it} , ktorú literatúra pozná i pod pojmom celková produktivita faktorov TFP. Odchýlka ε_{it} reflektuje vplyv náhodných zmien v modeli. Je v exponenciálnom tvare z praktických dôvodov, aby rovnica (1) po zlogaritmovaní bola lineárna v parametroch. Koeficienty α , $1-\alpha$ a ψ sú elasticity agregátneho produktu v závislosti od práce, fyzického a ľudského kapitálu.

Reorganizáciou rovnice (1) získavame rovnicu (2):

$$A_{it} H_{it}^{\psi} = \frac{Y_{it}}{L_{it}^{\alpha} C_{it}^{1-\alpha}} \exp(\varepsilon_{it}), \quad (2)$$

kde na pravej strane máme štandardný vzorec pre výpočet celkovej produktivity faktorov a na ľavej strane je celková produktivita faktorov rozdelená na A_{it} a multiplikačnú zložku vplyvu ľudského kapitálu H_{it} s elasticitou ψ .

TFP je podľa tradičného modelu endogénneho rastu vnímaná ako odraz znalostného kapitálu v ekonomike. Model tvorby znalostného kapitálu predstavil Jones (1995):

$$\Delta K_{it} = \delta_{it} H_{it}^{\beta} K_{it-1}^{\varphi} \exp(\omega_{it}) \quad (3)$$

a označil tak prírastok znalostí v danom roku ΔK_{it} závislý od už existujúcej zásoby znalostí v ekonomike K_{it-1} (autokorelácia v závislej premennej) a ľudského kapitálu H_{it} . Ľudský kapitál je tak chápaný predovšetkým ako vstup pracovnej sily a existujúca zásoba znalostí ako kapitálový vstup do produkcie nových znalostí – znalostného kapitálu. Odchýlka ω_{it} je opäť z praktických dôvodov v exponenciálnom tvare. β a φ sú elasticity tvorby nových znalostí na ľudský kapitál a na už existujúcu zásobu znalostí. δ_{it} predstavuje produktivitu vedecko-výskumného procesu. Keďže model ráta len s jedným faktorom – ľudským kapitálom, časť literatúry označuje túto produktivitu aj ako produktivitu ľudského kapitálu. Jej základnou charakteristikou je, že je negatívna v dôsledku klesajúcich výnosov z rozsahu vedecko-výskumného procesu (*decreasing returns to R&D scale*), resp. podľa Jonesa (1995) z rozsahu ľudského kapitálu. Tieto klesajúce výnosy vznikajú v prvom rade v dôsledku duplicity vedy a výskumu, zníženej ekonomickej hodnoty inovácií (viaceré nové patenty sú totiž len aktualizáciami či nadstavbou už existujúcich patentov) a redukcie znalostných externalít (v dôsledku napríklad prisnejšej ochrany duševného vlastníctva). Úroveň znalostí v ekonomike nerastie tempom rastu ľudského kapitálu, ale skôr tempom rastu produktivity δ_{it} násobenej ľudským kapitálom; rovnica (4).

$$\frac{K_{it} - K_{it-1}}{K_{it-1}} = \delta_{it} H_{it}^{\beta} \exp(\omega_{it}). \quad (4)$$

V súlade s Grilichom (1979) má platiť, že $A_{it}H_{it}^{\psi}$ je funkciou K_{it} s elasticitou γ . Dosadením $A_{it}H_{it}^{\psi}$ do rovnice (3) a rešpektovaním tempa rastu K_{it} dostaneme rovnicu (5).

$$A_{it}H_{it}^{\psi} = \delta_{it} H_{it}^{\beta} K_{it}^{\gamma} \exp(v_{it}), \quad (5)$$

kde odchýlka $\exp(v_{it})$ vzniká kombináciou odchýlok $\exp(\varepsilon_{it})$ a $\exp(\omega_{it})$ a v súlade s predpokladmi klasického ekonometrického modelu jej priemerná hodnota je 0 a štandardná odchýlka σ . Označením celkovej produktivity faktorov (ošetrenej o multiplikačný efekt ľudského kapitálu) $A_{it} = F_{it}$ a presunutím ľudského kapitálu na pravú stranu rovnice dostávame:

$$F_{it} = \delta_{it} H_{it}^{\beta - \psi} K_{it}^{\gamma} \exp(v_{it}). \quad (6)$$

V modeli je rozdiel $(\beta - \psi)$ kľúčový. Ak je rozdiel pozitívny, priamy vplyv ľudského kapitálu prevažuje nad multiplikačným efektom. Ak je rozdiel negatívny, multiplikačné tenzie dominujú nad priamym (pozitívnym) vplyvom. Toto chápanie kombinovaného vplyvu ľudského kapitálu z dvoch úrovni vplyvu je pre literatúru nové. Abdih a Joutz (2006) síce riešia prepojenie medzi rovnicou agregátnej produkcie a rovnicou tvorby znalostného kapitálu, avšak nezameriavajú sa na ľudský kapitál, ale na produktivitu oboch procesov.

Nadalej v súlade s teóriou znalostného kapitálu (Griliches, 1979) rozlišujeme znalostný kapitál vyprodukovaný v rámci regiónu $K_{it}^{\gamma_1}$ a dovezený (prenesený) z okolitých regiónov $K_{it}^{\gamma_2}$. Podobne k efektom ľudského kapitálu $H_{it}^{\beta - \psi}$ nemôžeme zahrnúť len tie prameniace z ľudského kapitálu daného regiónu $H_{it}^{\beta_1 - \psi_1}$, ale aj externalitu produkované ľudským kapitálom existujúcim v okolí $H_{it}^{\beta_2 - \psi_2}$. Rovnicu (6) tak potom môžeme prepísať do nasledujúceho tvaru:

$$F_{it} = \delta_{it} H_{it}^{\beta_1 - \psi_1} H_{it}^{\beta_2 - \psi_2} K_{it}^{\gamma_1} K_{it}^{\gamma_2} \exp(v_{it}). \quad (7)$$

Rovnicami (1) až (7) sme definovali teoretické základy nášho modelu a môžeme pristúpiť k empirickej transformácii modelu. Základnou otázkou je vyjadrenie zložky ľudského a znalostného kapitálu prináležiacej prelievaniu. Empirická literatúra ponúka viacero možností, my sme sa rozhodli aplikovať pohľad priestorovej ekonometrie. Priestorová ekonometria najprv zadefinuje potenciálne zdroje prelievania, a to tak, že zostaví maticu zo všetkých regiónov a priradí každej dvojici regiónov váhu ich vzájomnej blízkosti (interakcie). Vzájomná blízkosť môže byť ekonomická či geografická, uprednostňuje sa však geografické hľadisko, keďže rešpektuje princíp exogenity pre skúmané premenné. Prvky matice priestorových váh W môžu nadobúdať buď hodnotu z množiny $\{0; 1\}$, pričom 1 je priradená dvojici k -najbližších susediacich regiónov alebo zdieľajúcich spoločnú hranicu a 0 ostatným, alebo inverznú hodnotu k vzdialenosti medzi regiónmi definovanej ako vzdialenosť medzi ich najväčšími či ekonomicky najvýznamnejšími sídlami, prípadne centroidmi (umelo vyrátanými na základe zemepisných koordinátov regiónov). Matice priestorových váh sa zvyčajne riadkovo štandardizujú.

Optikou priestorovej ekonometrie môžeme zapísať externalizovanú (prelievanú) zložku znalostného a ľudského kapitálu nasledovne:

$$K_{it}^{\gamma_2} = \sum_{j \neq i}^N W_{ij} K_{jt} \quad (8)$$

$$H_{it}^{\beta_2 - \psi_2} = \sum_{j \neq i}^N W_{ij} H_{jt} \quad , \quad (9)$$

kde W_{ij} reprezentuje maticu priestorových váh medzi regiónmi i a j a K_{jt} a H_{jt} predstavujú znalostný a ľudský kapitál v regióne j v čase t .

Do empirickej verzie modelu pridávame aj autokorelačný člen $\sum_{j \neq i}^N W_{ij} F_{jt}$ s odhadovaným koeficientom ρ . Vzhľadom na súčasnú dostupnosť dát môžeme znalostný kapitál a ľudský kapitál zachytiť len nedokonalými zástupcami, ako je napríklad počet patentov a počet vysokoškolsky vzdelanej populácie. Je tak nutné rátať s vynechanými vysvetľujúcimi premennými (*omitted variables*), ako sú napríklad kvalita vzdelávania, zručnosti získané mimo akademickej pôdy, či nepatentovateľné znalosti. Tieto premenné sú pravdepodobne tiež priestorovo autokorelované a ako také sa dostanú do nášho empirického modelu buď v priestorovej autokorelácii rezíduí (Spatial Durbin Error Model, SDEM), alebo závislej premennej (Spatial Durbin Model, SDM). Predpokladáme, že všetky vynechané premenné sú endogénne pre znalostný kapitál, rovnako ako pre TFP, a tak SDM bude pravdepodobne vhodnejšou formou.

Napokon predpokladáme, že medzi jednotlivými regiónmi a časovými obdobiami existuje istá heterogenita, ktorú môžeme zachytiť v tzv. priestorových a časových fixných efektoch. Priestorové fixné efekty μ_{it} redukujú v modeli od času nezávislú rôznorodosť medzi regiónmi (podnebie, prístup k moru, existencia veľkých miest, kultúrne a národné tradície, normy a zvyklosti). Časové fixné efekty ξ_{it} zase ošetrojú náš model o vplyvy rozličných šokov v čase (zmena legislatívy, kríza). Vytesnenie fixných faktorov by v našom modeli mohlo viesť k skresleniu odhadovaných parametrov (Elhorst, 2012).

Doplnením rovnice (7) o rovnice (8) a (9), pridaním priestorovej autokorelácie v závislej premennej TFP a fixných efektov, ako i následným zlogaritmovaním oboch strán získame rovnicu (10).

$$\begin{aligned} \ln F_{it} = & \rho \left[\sum_{j \neq i}^N W_{ij} \ln F_{jt} \right] + (\beta_1 - \psi_1) \ln H_{it} + \gamma_1 \ln K_{it} + (\beta_2 - \psi_2) \left[\sum_{j \neq i}^N W_{ij} \ln H_{jt} \right] + \\ & + \gamma_2 \left[\sum_{j \neq i}^N W_{ij} \ln K_{jt} \right] + \mu_{it} + \xi_{it} + \varepsilon_{it} \quad . \end{aligned} \quad (10)$$

Podľa rovnice (10) teda elasticita TFP na domáci ľudský kapitál je daná $(\beta_1 - \psi_1)$, na ľudský kapitál v ostatných regiónoch definovaných W je $(\beta_2 - \psi_2)$, na domáci znalostný kapitál je γ_1 a na znalostný kapitál v ostatných regiónoch definovaných W je γ_2 .

3. Dáta

Z pozície sekundárnej veličiny je TFP citlivá na výber a akúkoľvek manipuláciu s primárnymi veličinami (Katayama *et al.*, 2009). Dujava (2012) aplikuje Montgomeryho dekompozíciu a ráta TFP na základe HDP ako agregátneho produktu a podiely faktorových vstupov do produkcie na základe nákladov na prácu. Fischer *et al.* (2009) však argumentujú, že robustnejšie hodnoty TFP získame, ak rátame s hrubou pridanou hodnotou (HPH) ako agregátnym produktom a podielmi na základe nákladov na kapitál. V tejto práci aplikujeme pre výpočet TFP druhý prístup. TFP definujeme štandardne rovnicou $\ln F = \ln Y - \alpha \Theta \ln L - (1 - \alpha) \Theta \ln C$. Ako agregátny produkt Y použijeme HPH v eurách a cenách roka 2000 a ako α podiel nákladov na výrobný faktor prácu na celkových nákladoch na prácu a kapitál. Symbol Θ reprezentuje Haddamardov produkt NT -krát-1 vektora podielov α , L regionálnu prácu a C fyzický kapitál. Všetky dáta pre výpočet pochádzajú z databáz *Cambridge econometrics*. Prácu L (počet zamestnaných) sme upravili o počet odpracovaných hodín, čím sme očistili medziregionálne rozdiely v pracovnom fonde. C sme vyrátali prostredníctvom metódy stálych zásob z hrubých investícií, pričom sme uplatnili ročnú amortizáciu 12 % navrhovanú Fischerom *et al.* (2009).

Pri výbere zástupcu znalostného kapitálu uprednostníme tiež postup Fischera *et al.* (2009), ktorý ho chápe v prvom rade ako časovo dostupnú zásobu patentovateľných znalostí. Časová dostupnosť patentovateľných znalostí súvisí so zastarávaním znalostí v čase, keď nové znalosti nahrádzajú staršie. Patentovateľnosť je zase jedinečnou vlastnosťou znalostí, ktorá umožňuje znalosť marketizovať, resp. generovať z jej vlastníctva zisky. Znalostný kapitál vypočítame tak ako zásobu počtu patentových prihlášok podaných u Európskeho patentového úradu (*European Patent Office*, EPO) s uplatnením metódy stálych zásob a ročnej amortizácie 12 % navrhovanej Caballerom a Jaffem (1993). Počet EPO patentových prihlášok získame z Regionálnej databázy Eurostatu. Pri patentovej prihláške podanej autormi z viacerých regiónov sa pripíše každému regiónu rovnaký podiel.

Na riziká práce s tradičnými zástupcami ľudského kapitálu upozornili viaceré štúdie (Abdih a Joutz, 2006; Arcand a d'Hombres, 2007). Nasadenie počtu rokov vzdelávania (Barro, 2001) či podielu vysokoškolsky vzdelanej populácie (Temple, 1999) do rastových modelov neprináša signifikantné výsledky. Neustále sa upozorňuje na nutnosť zakomponovania kvalitatívnej zložky ľudského kapitálu. Keďže však tvorba ľudského kapitálu je príliš rôznorodý proces a plnohodnotnejšie dáta jednoducho nie sú k dispozícii, ekonómovia sa naďalej musia uchýľovať k tradičným zástupcom. Táto štúdia sa pokúša riešiť nedokonalosť zástupcov aspoň tým, že ľudský kapitál rozširuje aj o stredoškolsky vzdelanú populáciu. V súčasnom svete totiž vysoká škola už nie je jediným miestom získania potrebných znalostí. S rozvojom informačno-komunikačných technológií sa ľudia čoraz častejšie vzdelávajú aj alternatívne – online. Predpokladáme tak, že už ukončené stredoškolské vzdelanie dáva predpoklady pracovnej sile, aby nové znalosti vytvárala a prenášala, a tak je ľudský kapitál v tejto štúdii zastúpený podielom populácie vo veku 25–64 rokov s minimálne úplným stredo-

školským vzdelaním (ISCED úroveň 3 a vyššia). Potrebne dáta sme prevzali z regionálnych databáz Eurostatu.

Maticu priestorových váh sme zostavili na základe konceptu k -najbližších susedov a za k sme zvolili 6. Blížkosť regiónov bola určená na základe geografickej vzdialenosti medzi centroidmi regiónov. Koordináty centroidov sme určili na základe údajov o zemepisnej dĺžke a šírke jednotlivých regiónov získaných z Eurostat databázy GISCO a prostredníctvom softvéru GeoDa. Maticu sme riadkovo štandardizovali. Šesť centroidovo najbližších regiónov tak získalo v matici váhu $1/6$ a ostatné regióny 0.

Vzhľadom na rozsiahlu literatúru poukazujúcu na nedostatky zástupcov ľudského kapitálu si v tomto bode dovoľujeme ešte skontrolovať vplyv ľudského kapitálu a produktivity vedecko-výskumného procesu z rovnice (3) s našimi zvolenými premennými. Ide len o prvú úroveň vplyvu ľudského kapitálu, tj. vplyv výhradne na tvorbu znalostného kapitálu. Využijeme na to metódu MLE (odhad maximálnej vierohodnosti, *Maximum Likelihood Estimation*) v troch krokoch – bez fixných efektov, s fixnými efektmi časovými a s fixnými efektmi priestorovými a zároveň časovými (Tabuľka 1).

Tabuľka 1

Odhad koeficientov Rovnice 3: SDM model bez a s fixnými efektmi

	SDM bez fixných efektov		SDM s časovými fixnými efektmi		SDM s priestorovými a časovými fixnými efektmi	
konštanta – δ	-0,494295	(0,000000)	-0,514121	(0,000000)	-0,602247	(0,000000)
β (h)	0,117751	(0,000000)	0,121749	(0,000000)	0,145151	(0,000000)
φ (Wk)	0,273462	(0,000000)	0,268442	(0,000000)	0,249527	(0,000000)
R^2	0,7711		0,7705		0,9964	
σ^2	0,0645		0,0649		0,0011	
logL	-273,9942		-212,0783		5516,3682	

Poznámky: p – hodnota v zátvorkách; Wk reprezentuje priestorovú autokoreláciu závislej premennej K – zásoby znalostí obsiahnutých v EPO patentových prihláškach; h reprezentuje podiel populácie s minimálne stredoškolským vzdelaním; $\log L$ – log Likelihood (logaritmus pravdepodobnosti), R^2 reprezentuje štatistickú významnosť modelu.

Zdroj: vlastné výpočty, softvér Matlab, dáta Eurostat a GISCO

Tabuľka 1 nám potvrdzuje, že pri odhade koeficientov rovnice (3) – produktivity δ , elasticity β a vplyvu priestorovej autokorelácie φ je vplyv produktivity ľudského kapitálu (vedecko-výskumného procesu) negatívny.

4. Odhad modelu

Naše dáta sme usporiadali do formy panelu, ktorý je charakteristický dvoma dimenziami – priestorovou a časovou. Na vzorke $N = 251$ NUTS-2 regiónov a $T = 11$ rokov sme odhadli SDM model s priestorovými a časovými fixnými efektmi definovaný rovnicou (10) s pomocou softvéru vytvoreného Paulom Elhorstom

a dostupnom na: <http://www.regroiningen.nl/elhorst/software.shtml>. V snahe ošetriť priestorovú a časovú heterogenitu medzi regiónmi softvér najprv zavádza umelú (*dummy*) premennú pre každý rok a región. Následne spriemeruje závislú a nezávislé premenné a odhadne parametre nášho modelu ρ , $(\beta_1 - \psi_1)$, $(\beta_2 - \psi_2)$, γ_1 a γ_2 metódou MLE. Keďže zakomponovanie súčasne priestorových i časových fixných efektov skresľuje v priestorových modeloch všetky odhadované parametre, naše odhady sme ešte upravili podľa metodiky Lee a Yu (2010). Taktiež sme vyrátali štatistickú významnosť modelu – pseudo R^2 – podľa rovnice:

$$R^2(e, \Omega) = 1 - \frac{e^T \Omega e}{(Y - \bar{Y})^T (Y - \bar{Y})}, \quad (11)$$

kde $\bar{Y}$ reprezentuje priemernú hodnotu závislej premennej, e je vektor rezíduí modelu a Ω je kovariačná matica rezíduí.

Tabuľka 2 poskytuje nasledujúce závery:

1. Vysoká štatistická významnosť a hodnota koeficientu ρ pri priestorovej autokorelácii v TFP sú sprevádzané testami pomeru pravdepodobností (*Likelihood Ratio*, LR) a Waldovým testom, ktoré vykazujú nižšie hodnoty pri SDM verzii ako pri SDEM. To naznačuje, že SDM model výdatnejšie vysvetľuje vzťahy medzi premennými ako model s priestorovou autokoreláciou v reziduách, a teda potvrdzuje náš predpoklad SDM verzie modelu. Okrem toho tieto testy potvrdzujú, že znalostný aj ľudský kapitál vytvárajú štatisticky významné nepriame efekty na okolité regióny, a teda je vedecky korektné použiť SDM, a nie model bez priestorovej autokorelácie v závislých premenných – SAR (Spatial Autocorrelation Model).
2. Test spoločnej významnosti fixných priestorových a fixných časových efektov poukazuje na potrebu zakomponovania oboch fixných efektov.
3. Hodnoty Hausmanovho testu v predposlednom riadku Tabuľky 2 potvrdzujú náš predpoklad, že pre naše dáta existuje skôr fixná ako náhodná heterogenita.

V súlade s LeSagom a Pacom (2009) bodové parametre odhadnuté v Tabuľke 2 a hladiny ich štatistickej významnosti často vedú k mylným záverom o existencii a sile vplyvu nezávislých premenných v modeli na závislú premennú, a to v prípade rovnako tzv. priamych efektov, ako i v prípade tzv. efektov nepriamych. Priamy efekt pri tom predstavuje internalizovaný vplyv vysvetľujúcej premennej, tj. vplyv lokálneho faktora na skúmanú veličinu lokálne, a nepriamy efekt predstavuje externalizovaný vplyv, tj. vplyv lokálnej premennej na hodnoty skúmanej veličiny registrované v okolí, v skratke efekt prelievania. V súlade s touto perspektívou LeSage a Pace odporúčajú vyrátať priame a nepriame efekty z matice parciálnych derivácií pre každú vysvetľujúcu premennú osobitne, a to nasledovne: priame efekty budú zodpovedať priemeru diagonálnych elementov matice a nepriame efekty priemeru mimo diagonálnych elementov matice. Tabuľka 3 sumarizuje výsledky takto vyrátaných priamych a nepriamych efektov.

Tabuľka 2

Výsledky odhadu: SDM s priestorovými a časovými fixnými efektmi, odhad MLE korigovaný o skreslenie

SDM s priestorovými a časovými fixnými efektmi		
ρ (Wf)	0,659944	(0,000000)
γ_1 (k)	0,011943	(0,012235)
$\beta_1 - \psi_1$ (h)	-0,144071	(0,000000)
γ_2 (Wk)	0,019743	(0,004149)
$\beta_2 - \psi_2$ (Wh)	-0,077664	(0,004608)
σ^2	0,0011	
pseudo R ²	0,9965	
logL	5527,5665	
Wald test (for Wf)	14,5567	(0,0007)
LR test (for Wf)	17,1608	(0,0002)
Wald test (for W ϵ)	81,8684	(0,0000)
LR test (for W ϵ)	92,1570	(0,0000)
Hausman t-stat (df = 5)	101,4913	(0,0000)
LR test spoločnej významnosti FE (df=251)	9679,5204	(0,0000)

Poznámky: ρ – hodnota v zátvorkách; df = stupne voľnosti (*degrees of freedom*); FE sú fixné efekty; Wf, Wk, Wh, W ϵ = priestorová autokorelácia v závislej premennej TFP, K (znalostnom kapitále meranom v zásobách patentových prihlášok), H (ľudskom kapitále meranom podielom populácie s minimálne stredoškolským vzdelaním) a chybe odhadu, pseudo R² reprezentuje štatistickú významnosť modelu.

Zdroj: vlastné výpočty, softvér Matlab, dáta Eurostat a GISCO

Ako Elhorst (2012) zdôrazňuje, nepriame efekty vznikajúce z priestorovej autokorelácie v nezávislých premenných majú lokalizačný charakter, keďže matica W obsahuje i nulové elementy, a to v prípade, ak dvojica regiónov nie je definovaná ako susediaca (geograficky blízka). Na strane druhej, nepriame efekty z priestorovej autokorelácie závislej premennej majú charakter globálny, keďže vznikajú i z nesusediacich regiónov. To vyplýva z obsahu Jakobiánskeho prvku $(I - \rho W)^{-1}$, ktorý vzniká prenesením TFP na jednu stranu rovnice modelu. Tento prvok obsahuje totiž iba nenulové elementy.

Tabuľka 3

Odhad priamych a nepriamych efektov v SDM modeli podľa Tabuľky 2

	SDM s priestorovými a časovými fixnými efektmi	
Priame efekty z <i>K</i>	0,016061	(0,004254)
Nepriame efekty z <i>K</i>	0,077719	(0,000000)
Celkové efekty z <i>K</i>	0,093780	(0,000000)
Priame efekty z <i>H</i>	-0,170078	(0,000000)
Nepriame efekty z <i>H</i>	-0,483408	(0,000000)
Celkové efekty z <i>H</i>	-0,653486	(0,000000)

Poznámky: *p* – hodnota v zátvorkách; *K* – znalostný kapitál meraný aktuálnou zásobou znalostí obsiahnutých v EPO patentových prihláškach; *H* – ľudský kapitál zastúpený podielom stredoškolsky vzdelanej populácie.

Zdroj: vlastné výpočty, softvér Matlab, dáta Cambridge, Econometric, Eurostat a GISCO

Negatívne znamienko pri vplyve ľudského kapitálu súvisí, ako už model naznačuje, s výraznejším vplyvom multiplikačnej zložky ľudského kapitálu – ψ_1 a ψ_2 . Vplyv je pozitívny, len transformácia modelu; rovnice (5) a (6) spôsobuje, že znamienko výsledného vplyvu je opačné. Vplyv ľudského kapitálu je výrazne vyšší ako efekty znalostného kapitálu. Kým priame efekty zo znalostného kapitálu zachyteného v EPO patentových prihláškach dosahujú len 0,01 a nepriame (prelievacie) 0,07, na nárast počtu stredoškolsky vzdelanej populácie o 1 % reaguje TFP v regióne EÚ nárastom v priemere až o 0,17 %. Na nárast vzdelanej populácie v okolí 6 najbližších susedov o 1 % pritom reaguje TFP v priemere až o 0,48 %. Tento poznatok zodpovedá predpokladom – ľudský kapitál cez nadobudnuté schopnosti a znalosti (nepatentovateľné) dokáže ovplyvniť TFP silnejšie ako patentovateľné znalosti. Patentovateľné znalosti síce dokazujú dostupnosť novej znalosti, no ľudský kapitál musí poznať, ako novú znalosť aplikovať a čo najlepšie zúročiť. Zároveň naše odhady potvrdzujú, pre rast TFP daného regiónu, i význam dostupnosti patentovateľných znalostí a ľudského kapitálu v blízkosti.

5. Overenie robustnosti

V tejto časti sumarizujeme výsledky testov robustnosti nášho modelu. Najprv sme sa pozreli na konštrukciu celkovej produktivity faktorov TFP. V odhade nášho modelu sme aplikovali odpisovú sadzbu investícií 12 %. Podľa iných odhadov však investície v EÚ zastarávajú výrazne pomalšie – 5,5 % p.a. (napr. Görizig, 2007). V Tabuľke 4 uvádzame výsledky odhadu nášho modelu pre túto odpisovú sadzbu, ako i pre alternatívne špecifikácie priestorovej matice *W*. Predpokladali sme totiž, že prelievanie je lokalizované na 6 najbližších susedov. Testy sme teda vykonali pre 4 a 8 najbližších susediacich regiónov, ako i pre *W* zostavenú na základe inverznej vzdialenosti, a teda predpokladajúcu klesajúcu intenzitu efektov prelievania s rastúcou vzdialenosťou.

Tabuľka 4

Výsledky odhadu SDM modelu s fixnými priestorovými a časovými efektmi, odhad MLE korigovaný o skreslenie

	odpisová sadzba investícií 5,5 %	W – 4 najbližší susedia	W – 8 najbližší susedia	W – inverzná vzdialenosť
ρ (Wf)	0,634438 (0,000000)	0,602722 (0,000000)	0,697835 (0,000000)	0,806907 (0,000000)
γ_1 (K)	0,004498 (0,361290)	0,016606 (0,000447)	0,012902 (0,006136)	0,021152 (0,000018)
β_1 (H)	-0,154740 (0,000000)	-0,154088 (0,000000)	-0,144061 (0,000000)	-0,160995 (0,000000)
γ_2 (Wk)	0,035378 (0,000001)	0,012681 (0,047673)	0,015622 (0,027792)	0,022309 (0,021207)
β_2 (Wh)	-0,076840 (0,006640)	-0,092078 (0,000348)	-0,063422 (0,030173)	-0,140298 (0,000678)
σ^2	0,0012	0,0011	0,0011	0,0012
pseudo R ²	0,9964	0,9964	0,9964	0,9961
logL	5447,2551	5494,874	5511,357	5383,415
Wald test (for Wf)	28,8716 (0,0000)	15,1349 (0,0005)	8,4507 (0,0146)	15,9430 (0,0003)
LR test (for Wf)	32,7907 (0,0000)	17,7133 (0,0001)	10,4343 (0,0054)	23,5210 (0,0000)
Wald test (for Wε)	93,5758 (0,0000)	94,9274 (0,0000)	63,8330 (0,0000)	89,3531 (0,0000)
LR test (for Wε)	102,9308 (0,0000)	106,2725 (0,0000)	71,5831 (0,0000)	116,3167 (0,0000)

Poznámky: ρ – hodnota v zátvorkách, Wf, Wk, Wh, Wε = priestorová autokorelácia v závislej premennej TFP, K (znalostnom kapitále – zásobe EPO patentových prihlášok), H (ľudskom kapitále – podiele populácie so stredoškolským vzdelaním) a chybe odhadu; pseudo R² reprezentuje štatistickú významnosť modelu.

Zdroj: vlastné výpočty, softvér Matlab, dáta Cambridge, Econometric, Eurostat a GISCO

Sumarizáciu priemerných priamych a nepriamych efektov pri uvedených alternatívnych stavbách priestorovej matice a alternatívnej odpisovej sadzbe investícií 5,5 % poskytuje Tabuľka 5. Podľa nej uplatnenie výrazne nižšej odpisovej sadzby na investície či iného výpočtu priestorovo najbližších susedov nemá vplyv na výšku odhadnutých efektov zo znalostného a ľudského kapitálu. Nepriame efekty zo znalostného kapitálu zostávajú na úrovni 0,7–0,9 v % TFP.

Vyšší vplyv na TFP vykazuje ľudský kapitál – ak vzrastie podiel stredoškolsky vzdelanej populácie vo všetkých ostatných regiónoch o 1 %, TFP v danom regióne

vzrastie v priemere o 0,43–0,52 %. V prípade, že predpokladáme pozitívne externality klesajúce s rastúcou vzdialenosťou a neohraničené na istý počet susediacich regiónov, reprezentované v modeli priestorovou maticou na základe inverznej vzdialenosti, efekty znalostného a ľudského kapitálu rastú. To je pochopiteľné vzhľadom na to, že rátame s vyšším počtom regiónov, ktoré ovplyvňujú TFP daného regiónu, a teda s vyšším počtom tokov znalostí.

Tabuľka 5

Odhad priamych a nepriamych efektov v SDM modeli podľa Tabuľky 4

	odpisová sadzba investícií 5,5%	W – 4 najbližší susedia	W – 8 najbližší susedia	W – inverzná vzdialenosť
Priame efekty z K	0,010015 (0,032754)	0,020619 (0,000007)	0,016055 (0,000829)	0,026152 (0,000000)
Nepriame efekty z K	0,099723 (0,000000)	0,053390 (0,000009)	0,078225 (0,000009)	0,200567 (0,000001)
Celkové efekty z K	0,109738 (0,000000)	0,074010 (0,000000)	0,094279 (0,000000)	0,226719 (0,000000)
Priame efekty z H	–0,178941 (0,000000)	–0,185320 (0,000000)	–0,165343 (0,000000)	–0,193623 (0,000000)
Nepriame efekty z H	–0,454432 (0,000000)	–0,435433 (0,000000)	–0,520626 (0,000000)	–1,369592 (0,000000)
Celkové efekty z K	–0,633373 (0,000000)	–0,620753 (0,000000)	–0,685969 (0,000000)	–1,563214 (0,000000)

Poznámky: *p* – hodnota v zátvorkách; *K* – znalostný kapitál meraný aktuálnou zásobou znalostí obsiahnutých v EPO patentových prihláškach; *H* – ľudský kapitál zastúpený podielom minimálne stredoškolsky vzdelanej populácie.

Zdroj: vlastné výpočty, softvér Matlab, dáta Cambridge, Econometric, Eurostat a GISCO

Robustnosť nášho modelu by sme mohli ďalej overiť aj na alternatívnych a dodatočných zastupujúcich premenných znalostného a ľudského kapitálu. Tie sú však v podstate nedostupné, i keď sa do ich tvorby investuje (nedávno napr. zo strany OECD – testovanie kompetencií dospelých populácie PIAAC). Takéto indikátory však nemajú potrebné historické zázemie a neumožňujú tak vytvorenie časovej dimenzie panelových dát. Iné indikátory ako napr. výdavky na vzdelávanie (súkromné, štátne) sú sporné, keďže ich vplyv na tvorbu ľudského kapitálu závisí od viacerých ťažko sledovateľných faktorov (typ výdavkov, korupcia, selekcia cieľovej skupiny a jej schopnosti a predošlé skúsenosti, motivácia cieľovej skupiny). Máme teda za to, že sme model odhadli podľa najlepších možných dostupných zastupujúcich premenných.

6. Zhrnutie a závery

Tento článok sa venoval štúdiu priamych a nepriamych efektov ľudského a znalostného kapitálu na celkovú produktivitu faktorov na vzorke 251 NUTS-2 regiónov EÚ počas obdobia 2000–2010. Vychádza z teoretického modelu Jonesa a Cobb-Douglasovej produkčnej funkcie rozšírenej o vstup ľudského kapitálu a transformuje ju do tvaru priestorového Durbinovho modelu s fixnými časovými i priestorovými efektmi. Do literatúry prináša tento článok viaceré nové poznatky: V prvom rade študuje znalostné prelievanie na vzorke regiónov EÚ rozšírenú o regióny krajín, ktoré pristúpili do EÚ v rokoch 2004 a 2007. Okrem toho sleduje znalostné prelievanie cez model jeho tvorby. Pracuje s dvoma úrovňami vplyvu ľudského kapitálu, čím vysvetľuje výsledné znamienko vplyvu ľudského kapitálu v modeli. Okrem toho testuje znalostné prelievanie novou metodikou – SDM odhadom na panelových dátach.

Na základe výsledkov odhadu prichádzame k záveru, že patentovateľné znalosti sú pre trajektóriu TFP významné, avšak výrazne vyšší vplyv vykazuje ľudský kapitál meraný podielom stredoškolsky vzdelanej populácie. Tieto výsledky zodpovedajú empirickým predpokladom. Vzdelaná populácia je nositeľom širšieho objemu znalostí ako patent a je schopná maximalizovať úžitky z patentovateľných znalostí cez vlastnú efektívnosť, skúsenosti, disciplínu. Nepriame (medziregionálne) efekty z ľudského kapitálu sú tým silnejšie ako nepriame efekty z patentovateľných znalostí. Testy robustnosti vykazujú značnú stabilitu nášho modelu. Model sme odhadli pre alternatívny výpočet TFP, ako i pre alternatívne zostavené priestorové matice. Napriek tomu sme si vedomí limitov nášho modelu, ktoré súvisia s obmedzenou spoľahlivosťou našich zastupujúcich premenných znalostného a ľudského kapitálu. Veľká časť opomenutých faktorov TFP sa tak prejavila v priestorovej autokorelácii závislej premennej TFP.

Prezentované výsledky majú významné politicko-ekonomické závery. Poskytujú opodstatnenie pre investície do tvorby a mobility ľudského kapitálu, ktorý je následne schopný nielen produkovať, ale i importovať viac znalostí. Región tak dokáže rásť znalostným prelievaním bez potreby vlastných investícií do vedy a výskumu. I tu však existujú limity. Absencia znalostného a ľudského kapitálu v susediacich regiónoch prináša averzné efekty na rast produktivity daného regiónu. Región obklopený či vzdialený od centier výskumu je exogénne trvalo znevýhodnený. Toto znevýhodnenie je možné riešiť podporou domáceho znalostného kapitálu, vytváraním aliancií so zahraničím či podporou iných kanálov technologického prelievania (obchod, PZI). Kľúčovým je pritom budovanie ľudského kapitálu vo vhodných odvetviach, v ktorých má región konkurenčnú výhodu, pretože bez vhodných znalostí sa schopnosť absorbovať prinášanú znalosť znižuje.

Referencie

- ABDIH, Y.; JOUTZ, F. 2006. Relating the Knowledge Production Function to Total Factor Productivity: An Endogenous Growth Puzzle. *IMF Staff Papers*. 2005, Vol. 53, No. 2, pp. 242–271.
- ARCAND, J. L.; D'HOMBRES, B. 2007. Explaining the Negative Coefficient Associated with Human Capital in Augmented Solow Growth Regressions [Working Paper No. 0510010 – series *Macroeconomics*]. EconWPA, 2007. <http://128.118.178.162/eps/mac/papers/0510/0510010.pdf>.
- BARBOSA, N.; EIRIZ, V. 2009. Linking corporate productivity to foreign direct investment: An empirical assessment. *International Business Review*. 2009, Vol. 18, No. 1, pp. 1–13.
- ČAPLÁNOVÁ, A.; SIVÁK, R.; HUDSON, J. 2012. The Impact of Foreign Direct Investment on Firms' Innovation Activities. *Politická ekonomie*. 2012, Vol. 60, No. 6, pp. 764–779.
- BOTTAZZI, L.; PERI, G. 2003. Innovation a Spillovers in Regions: Evidence from European Patent Data. *European Economic Review*. 2003, Vol. 47, No. 4, pp. 687–710.
- CABALLERO, R. J.; JAFFE, A. B. 1993. How High are the Giants' Shoulders: An Empirical Assessment of Knowledge Spillovers a Creative Destruction in a Model of Economic Growth. *NBER Macroeconomics Annual*. 1993, Vol. 8, pp. 15–86.
- DUJAVA, D. 2012. Causes of Lagging behind of New Member States of EU: Empirical analysis by Montgomery decomposition. *Politická ekonomie*. 2012, No. 2, pp. 222–244.
- ELHORST, J. P. 2012. *Spatial econometrics: From cross-sectional data to spatial panels*. SpringerBriefs in Regional Science. Heidelberg New York Dordrecht London: Springer, 2012. 119 p. ISBN 978-3-642-40339-2.
- FAGERBERG, J.; SRHOLEC, M.; VERSPAGEN, B. 2010. Innovation and Economic Development. In HALL, B.; ROSENBERG, N. (Eds). *Handbook of the Economics of Innovation – Volume 2*. North-Holland: Elsevier, 2010, pp. 833–872. ISBN 978-0-444-53609-9.
- FERREIRA, P. C.; TREJOS, A. 2011. Gains from trade on measured total factor productivity. *Review of Economic Dynamics*. 2011, Vol. 14, No. 3, pp. 496–510.
- FISCHER, M. M.; SCHERNGELL, T.; REISMANN, M. 2009. Total factor productivity effects of interregional knowledge spillovers in manufacturing industries across Europe. *Geographical Analysis*. 2009, Vol. 41, No. 2, pp. 204–220.
- GRILICHES, Z. 1979. R&D and the productivity slowdown. *American Economic Review*. 1979, Vol. 70, No. 2, pp. 343–348.
- GRILICHES, Z. 1990. Patent Statistics as Economic Indicators: A Survey. *Journal of Economic Literature*. 1990, Vol. 28, No. 4, pp. 1661–1707.
- GÖRZIG, B. 2007. Depreciation in EU Member States: Empirical a Methodological Differences [Working Paper No. 17]. EU KLEMS, April 2007. <http://www.euklems.net/pub/no17%28online%29.pdf>.
- HANOUSEK, J.; KOČENDA, E.; MAŠIKA, M. 2012. Firm efficiency: Domestic owners, coalitions, and FDI. *Economic Systems*. 2012, Vol. 36, No. 4, pp. 471–486.
- ISHISE, H.; SAWADA, Y. 2009. Aggregate returns to social capital: Estimates based on the augmented augmented-Solow model. *Journal of Macroeconomics*. 2009, Vol. 31, No. 3, pp. 376–393.
- JAFFE, A. B. 1986. Technological opportunity and spillovers of R&D: Evidence from firms' patents, profits, and market value. *American Economic Review*. 1986, Vol. 76, No. 5, pp. 984–1001.
- JONES, C. I. 1995. R&D-Based Models of Economic Growth. *Journal of Political Economy*. 1995, Vol. 103, No. 4, pp. 759–784.
- JORDAAN, J. A. 2008. Intra- a Inter-industry Externalities from Foreign Direct Investment in the Mexican Manufacturing Sector: New Evidence from Mexican Regions. *World Development*. 2008, Vol. 36, No. 12, pp. 2838–2854.
- KATAYAMA, H.; LU, S.; TYBOUT, J. R. 2009. Firm-level productivity studies: Illusions and a solution. *International Journal of Industrial Organization*. 2009, Vol. 27, No. 3, pp. 403–413.
- KEMENY, T. 2010. Does Foreign Direct Investment Drive Technological Upgrading? *World Development*. 2010, Vol. 38, No. 11, pp. 1543–1554.

- KRAMMER, S. 2014. Assessing the relative importance of multiple channels for embodied a disembodied technological spillovers. *Technological Forecasting and Social Change*. 2014, Vol. 81, No. 1, pp. 272–286.
- LEE, L. F.; YU, J. 2010. Some recent developments in spatial panel data models. *Regional Science Urban Economics*. 2010, Vol. 40, No. 5, pp. 255–271.
- LESAGE, J. P.; PACE, R. K. 2009. *Introduction to Spatial Econometrics*. Boca Raton: CRC Press Taylor and Francis Group, 2009. ISBN 978-1420064247.
- MORETTI, E. 2004. Workers' education, spillovers, and productivity: Evidence from plant-level production functions. *American Economic Review*. 2004, Vol. 94, No. 3, pp. 656–690.
- NIEHAUS, P. 2012. Education and knowledge spillovers [Working Paper]. UC San Diego (Mimeo), July 2012. <http://econweb.ucsd.edu/~pniehaus/papers/spillovers.pdf>.
- ROBBINS, C. 2006. The impact of gravity-weighted knowledge spillovers on productivity in manufacturing. *Journal of Technology Transfer*. 2006, Vol. 31, pp. 45–60.
- ROSENTHAL, S. S.; STRANGE, W. C. 2008. The attenuation of human capital spillovers. *Journal of Urban Economics*. 2008, Vol. 64, No. 2, pp. 373–389.
- SCHERNGELL, T.; BOROWIECKI, M.; HU, Y. 2014. Effects of knowledge capital on total factor productivity in China: A spatial econometric perspective. *China Economic Review*. 2014, Vol. 29, pp. 82–94.

ANALYSIS OF IMPACTS HUMAN CAPITAL ON THE TOTAL FACTOR PRODUCTIVITY IN THE EU REGIONS USING THE SPATIAL DURBIN MODEL

Paula Puškárová, Institute for Economics and Management, University of Economics in Bratislava, Dolnozemska cesta 1/b, SK – 852 35 Bratislava, Slovakia (paula.puskarova@euba.sk)

Abstract

This study is devoted to explore the role and impact size of human capital for economic growth. We discern two levels of human capital impacts: First, we point to its contribution to knowledge capital production and second, the multiplicative effects of human capital in the aggregate production function are suggested. We employ lately developed methodology for spatial panel estimations with two-way fixed effects. Our results show that throughout the EU NUTS-2 regions over the 2000s human capital spillovers, indeed, account for large total factor productivity variation. Moreover, our results suggest that local effects of human capital are secondary to these human capital spillovers in terms of magnitude and, what might be more compelling, that the multiplicative effects of human capital surmount its impacts attributable to knowledge production.

Keywords

knowledge, human capital, human capital spillover, total factor productivity, spatial panel, SDM

JEL Classification

O330, O470, R120

PRÍLOHA

Prehľad NUTS-2 regiónov a ich kódových označení

Kód	Názov regiónu	Kód	Názov regiónu	Kód	Názov regiónu
BE1	Région de Bruxelles-Capitale/Brussels Hoofdstedelijk Gewest	ES61	Andalucia	PL22	Slaskie
BE21	Prov. Antwerpen	ES62	Región de Murcia	PL31	Lubelskie
BE22	Prov. Limburg (B)	ES7	Canarias (ES)	PL32	Podkarpackie
BE23	Prov. Oost-Vlaanderen	FR1	Île de France	PL33	Świętokrzyskie
BE24	Prov. Vlaams Brabant	FR21	Champagne-Ardenne	PL34	Podlaskie
BE25	Prov. West-Vlaanderen	FR22	Picardie	PL41	Wielkopolskie
BE31	Prov. Brabant Wallon	FR23	Haute-Normandie	PL42	Zachodniopomorskie
BE32	Prov. Hainaut	FR24	Centre	PL43	Lubuskie
BE33	Prov. Liège	FR25	Basse-Normandie	PL51	Dolnoslaskie
BE34	Prov. Luxembourg (B)	FR26	Bourgogne	PL52	Opolskie
BE35	Prov. Namur	FR3	Nord – Pas-de-Calais	PL61	Kujawsko-Pomorskie
BG31	Severozapaden	FR41	Lorraine	PL62	Warmińsko-Mazurskie
BG32	Severen tsentralen	FR42	Alsace	PL63	Pomorskie
BG33	Severozitochén	FR43	Franche-Comté	PT11	Norte
BG34	Yugoiztochen	FR51	Pays de la Loire	PT15	Algarve
BG41	Yugozapaden	FR52	Bretagne	PT16	Centro (PT)
BG42	Yuzhen tsentralen	FR53	Poitou-Charentes	PT17	Lisboa
CZ01	Praha	FR61	Aquitaine	PT18	Alentejo
CZ02	Strední Čechy	FR62	Midi-Pyrénées	RO11	Nord-Vest
CZ03	Jihozápad	FR63	Limousin	RO12	Centru
CZ04	Severozápad	FR71	Rhône-Alpes	RO21	Nord-Est
CZ05	Severovýchod	FR72	Auvergne	RO22	Sud-Est
CZ06	Jihovýchod	FR81	Languedoc-Roussillon	RO31	Sud-Muntenia
CZ07	Strední Morava	FR82	Provence-Alpes-Côte d'Azur	RO32	Bucuresti – Ilfov
CZ08	Moravskoslezsko	FR83	Corse	RO41	Sud-Vest Oltenia
DK01	Hovedstaden	IE01	Border, Midlands and Western	RO42	Vest
DK02	Sjælland	IE02	Southern and Eastern	SI01	Vzhodna Slovenija
DK03	Syddanmark	ITC1	Piemonte	SI02	Zahodna Slovenija
DK04	Midtjylland	ITC2	Valle d'Aosta/Vallée d'Aoste	SK01	Bratislavský kraj
DK05	Nordjylland	ITC3	Liguria	SK02	Západné Slovensko
DE11	Stuttgart	ITC4	Lombardia	SK03	Stredné Slovensko
DE12	Karlsruhe	ITD1	Provincia Autonoma Bolzano-Bozen	SK04	Východné Slovensko
DE13	Freiburg	ITD2	Provincia Autonoma Trento	FI1B	Helsinki-Uusimaa
DE14	Tübingen	ITD3	Veneto	FI1C	Etelä-Suomi
DE21	Oberbayern	ITD4	Friuli-Venezia Giulia	FI19	Länsi-Suomi
DE22	Niederbayern	ITD5	Emilia-Romagna	FI13	Itä-Suomi

Prehľad NUTS-2 regiónov a ich kódových označení – pokračování

DE23	Oberpfalz	ITE1	Toscana	F1A	Pohjois-Suomi
DE24	Oberfranken	ITE2	Umbria	FI20	Åland
DE25	Mittelfranken	ITE3	Marche	SE11	Stockholm
DE26	Unterfranken	ITE4	Lazio	SE12	Östra Mellansverige
DE27	Schwaben	ITF1	Abruzzo	SE22	Sydsverige
DE3	Berlin	ITF2	Molise	SE31	Norra Mellansverige
DE41	Brandenburg-Nordost	ITF3	Campania	SE32	Mellersta Norrland
DE42	Brandenburg - Südwest	ITF4	Puglia	SE33	Övre Norrland
DE5	Bremen	ITF5	Basilicata	SE21	Småland med öarna
DE6	Hamburg	ITF6	Calabria	SE23	Västsverige
DE71	Darmstadt	ITG1	Sicilia	UKC1	Tees Valley and Durham
DE72	Gießen	ITG2	Sardegna	UKC2	Northumberland, Tyne and Wear
DE73	Kassel	CY	Kypros	UKD1	Cumbria
DE8	Mecklenburg-Vorpommern	LV	Latvija	UKD2	Cheshire
DE91	Braunschweig	LT	Lietuva	UKD3	Greater Manchester
DE92	Hannover	LU	Luxembourg	UKD4	Lancashire
DE93	Lüneburg	HU1	Közép-Magyarország	UKD5	Merseyside
DE94	Weser-Ems	HU21	Közép-Dunántúl	UKE1	East Riding and North Lincolnshire
DEA1	Düsseldorf	HU22	Nyugat-Dunántúl	UKE2	North Yorkshire
DEA2	Köln	HU23	Dél-Dunántúl	UKE3	South Yorkshire
DEA3	Münster	HU31	Észak-Magyarország	UKE4	West Yorkshire
DEA4	Detmold	HU32	Észak-Alföld	UKF1	Derbyshire and Nottinghamshire
DEA5	Arnsberg	HU33	Dél-Alföld	UKF2	Leicestershire, Rutland and Northants
DEB1	Koblenz	MT	Malta	UKF3	Lincolnshire
DEB2	Trier	NL11	Groningen	UKG1	Herefordshire, Worcestershire and Warks
DEB3	Rheinhausen-Pfalz	NL12	Friesland	UKG2	Shropshire and Staffordshire
DEC	Saarland	NL13	Drenthe	UKG3	West Midlands
DED1	Chemnitz	NL21	Overijssel	UKH1	East Anglia
DED2	Dresden	NL22	Gelderland	UKH2	Bedfordshire, Hertfordshire
DED3	Leipzig	NL23	Flevoland	UKH3	Essex
DEE	Sachsen-Anhalt	NL31	Utrecht	UKI1	Inner London
DEF	Schleswig-Holstein	NL32	Noord-Holland	UKI2	Outer London
DEG	Thüringen	NL33	Zuid-Holland	UKJ1	Berkshire, Bucks and Oxfordshire

EE00	Eesti	NL34	Zeeland	UKJ2	Surrey, East and West Sussex
ES11	Galicia	NL41	Noord-Brabant	UKJ3	Hampshire and Isle of Wight
ES12	Principado de Asturias	NL42	Limburg (NL)	UKJ4	Kent
ES13	Cantabria	AT11	Burgenland	UKK1	Gloucestershire, Wiltshire and North Somerset
ES21	Pais Vasco	AT12	Niederösterreich	UKK2	Dorset and Somerset
ES22	Comunidad Foral de Navarra	AT13	Wien	UKK3	Cornwall and Isles of Scilly
ES23	La Rioja	AT21	Kärnten	UKK4	Devon
ES24	Aragón	AT22	Steiermark	UKL1	West Wales and The Valleys
ES3	Comunidad de Madrid	AT31	Oberösterreich	UKL2	East Wales
ES41	Castilla y León	AT32	Salzburg	UKM1	Eastern Scotland
ES42	Castilla-la Mancha	AT33	Tirol	UKM2	South Western Scotland
ES43	Extremadura	AT34	Vorarlberg	UKM3	North Eastern Scotland
ES51	Cataluña	PL11	Lódzkie	UKM4	Highlands and Islands
ES52	Comunidad Valenciana	PL12	Mazowieckie	UKN	Northern Ireland
ES53	Illes Balears	PL21	Malopolskie	PL22	Slaskie

Zdroj: Eurostat GISCO