

STUDIA METODOLOGICZNE

Barbara DAŃSKA-BORSIAK

Zróżnicowanie łącznej produktywności czynników produkcji według województw

Postęp techniczny jest we współczesnej gospodarce coraz bardziej istotnym czynnikiem produkcji, ponieważ to właśnie on sprawia, że gospodarka znajduje się na drodze rozwoju. Mianem postępu technicznego określa się zmiany w technologii i organizacji produkcji, prowadzące do zwiększania efektywności procesów gospodarowania.

Efektem działania postępu technicznego jest przyrost produkcji, który nie wynika ze wzrostu zasobów czynników produkcji. Prowadzi on w ostatecznym

efekcie do wzrostu poziomu życia społeczeństw. Syntetycznym sposobem oceny zmian efektywności procesów produkcyjnych, zachodzących pod wpływem postępu technicznego, jest wzrost łącznej produktywności czynników produkcji (*total factor productivity* — TFP).

Głównym celem artykułu jest wskazanie czynników wpływających na kształtowanie się poziomu TFP w województwach. Jest to zmienna niemierzalna, dlatego pierwszym etapem badania było oszacowanie jej wartości według województw. Jako narzędzie analizy zastosowano modele panelowe.

PODSTAWY EKONOMICZNE ANALIZY PRODUKTYWNOŚCI

Definicja postępu technicznego w ujęciu makroekonomicznym, rozumianego jako postęp technologiczno-organizacyjny, została sformułowana w pracy Solowa (1957), w kontekście neoklasycznej, dwuczynnikowej funkcji produkcji, w postaci: $Y = f(K, L)$, gdzie: Y — wielkość produkcji, K — zasoby kapitału, L — nakłady pracy. Z definicji tej¹ wynika, że efektem działania tego postępu jest każdy wzrost strumienia produktu, który nie wynika z akumulacji kapitału ani ze wzrostu nakładów pracy.

W dalszych rozważaniach pojawiać się będzie pojęcie postępu technicznego według Hicksa. Jest to taki typ postępu neutralnego, w którym nie zmienia się krańcowa stopa substytucji pracy kapitałem. Dwuczynnikowa funkcja produkcji z postępem technicznym w sensie Hicksa ma więc postać:

$$Y_t = A(t) f(K_t, L_t) \quad (1)$$

gdzie $A(t)$ — czynnik opisujący technologię produkcji, przy czym $\frac{dA}{dt} \geq 0$.

Efektem postępu technicznego są zmiany efektywności produkcji. Sposób oceny tych efektów jest zależny od skali analizy. W ujęciu mikroekonomicznym ocenia się pojedyncze przedsięwzięcia innowacyjne. W ujęciu makroekonomicznym oceniane są natomiast zmiany efektywności, wyrażające się poprzez zmiany w: strukturze czynników produkcji i relacji między nimi (mierzone najczęściej wzrostem technicznego uzbrojenia pracy), strukturze produkcji, produktywności pojedynczych czynników (np. wydajności, kapitałochłonności itd.) lub produktywności wszystkich czynników (tzn. TFP).

Produktywność pojedynczego czynnika mierzona jest jako wielkość produkcji przypadającej na jednostkę tego czynnika. TFP jest natomiast zmienną nieobserwowalną. Definiowana jest ona jako wielkość produkcji przypadającej na jednostkę kombinacji czynników produkcji. Jest więc, w odróżnieniu od produktywności poszczególnych czynników, syntetycznym miernikiem efektywności

¹ Przytoczonej w pracy Świeczewskiej (2007), s. 59.

procesu produkcyjnego, wynikającej z szeroko rozumianego postępu technicznego.

Wyznaczenia TFP dokonać można jedną z dwóch metod. Jedną z nich wykorzystuje metody indeksowe², a druga — funkcję produkcji. Jeśli funkcja produkcji ma postać Cobba-Douglasa, to poziom TFP (określany jako produkcja wytworzona z jednostki kombinacji czynników produkcji) w okresie t wyraża się jako:

$$TFP_t = \frac{Y_t}{f(K_t, L_t)} \quad (2)$$

Przekształcenie wyrażenia (2) do postaci:

$$Y_t = TFP_t \cdot f(K_t, L_t) \quad (3)$$

i porównanie (3) z (1) prowadzi do wniosku, że poziom TFP odpowiada czynnikowi $A(t)$, opisującemu technologię produkcji w dwuczynnikowej funkcji produkcji z neutralnym postępem technologicznym w sensie Hicksa.

Oszacowanie elastyczności jest możliwe po sprecyzowaniu postaci funkcji produkcji. Zazwyczaj przyjmuje się dwuczynnikową funkcję Cobba-Douglasa w postaci potęgowej:

$$Y_t = A_t K_t^\alpha L_t^{1-\alpha} \quad (4)$$

gdzie:

- Y_t — wielkość produkcji w cenach stałych,
- A_t — łączna produktywność czynników produkcji ($A_t = TFP_t$),
- K_t — wartość kapitału w cenach stałych,
- L_t — nakłady pracy,
- $\alpha, (1 - \alpha)$ — elastyczność produkcji odpowiednio względem nakładów kapitału i pracy.

Zrózniczkowanie (4) względem czasu i przyjęcie założenia, że każdy czynnik produkcji jest opłacany według jego produktu krańcowego prowadzą do równania:

$$\frac{\dot{TFP}_t}{TFP_t} = \frac{\dot{Y}_t}{Y_t} - \alpha_t^K \frac{\dot{K}_t}{K_t} - (1 - \alpha_t^K) \frac{\dot{L}_t}{L_t} \quad (5)$$

² Bliższe informacje na temat metod indeksowych zawarte są np. w pracy Świeczewskiej (2007), s. 68—71.

gdzie:

$\dot{Y}_t$, $\dot{TFP}_t$, $\dot{K}_t$, $\dot{L}_t$ — pochodne po czasie odpowiednich zmiennych,

α_t^K — udział nakładu kapitału w produkcji,

$(1 - \alpha_t^K) = \alpha_t^L$ — udział nakładu pracy w produkcji.

Równanie (5) jest nazywane równaniem reszt Solowa. Wynika z niego, że do oszacowania stopy wzrostu TFP wystarcza znajomość elastyczności produkcji względem poszczególnych jej czynników.

W powyższych rozważaniach postęp techniczny, a zatem również łączna produktywność czynników produkcji traktowane były egzogenicznie. Próby wyjaśnienia źródeł postępu technicznego (wzrostu TFP) są podejmowane na podstawie teorii wzrostu endogenicznego. Szersze omówienie teorii endogenizacji postępu technicznego i światowych badań empirycznych znaleźć można w pracy Świeczewskiej (2007). Z kolei wyniki badań empirycznych dotyczących Polski przedstawiono m.in. w pracach Welfe (2001) i Zienkowskiego (2003).

METODOLOGIA

Modelami panelowymi nazywane są modele szacowane na podstawie szczególnego rodzaju danych przekrojowo-czasowych, w których liczba obserwowanych obiektów N przekracza (niekiedy znacznie) liczbę punktów w czasie T . Cechą charakterystyczną ich konstrukcji jest wyróżnienie stałego efektu grupowego, specyficznego dla danego obiektu³. Dynamiczny model panelowy ma postać:

$$y_{it} = \alpha_0 + \gamma_{i,t-1} + \mathbf{x}_{it}^T \boldsymbol{\beta} + (\alpha_i + \varepsilon_{it}) \quad (6)$$

dla $i = 1, \dots, N$, $t = 1, \dots, T$.

Opóźniona zmienna objaśniana jest skorelowana ze stałymi efektami grupowymi α_i . Powoduje to, że metody stosowane do estymacji statycznych modeli panelowych nie mogą być stosowane do estymacji modelu (6), gdyż estymatory te byłyby niezgodne i obciążone. W literaturze przedmiotu proponuje się alternatywne metody estymacji panelowych modeli dynamicznych. Ich przegląd znaleźć można np. u Baltagi (2008), Hsiao (2003). Metody te oparte są na metodzie zmiennych instrumentalnych, metodzie największej wiarygodności lub uogólnionej metodzie momentów. Zaletą tej ostatniej (GMM) jest m.in. możliwość uwzględnienia alternatywnych założeń korelacji zmiennych objaśniających

³ Można też wyodrębnić dodatkowo trzecią składową, stałą względem obiektów, zwaną efektem czasowym.

(elementów wektora $\mathbf{x}_{it}$ modelu (6) ze składnikiem losowym ε_{it} . Zmienne $\mathbf{x}_{it}$ (wszystkie lub część z nich) można traktować jako:

- endogeniczne, to znaczy $\mathbf{x}_{it}$ są skorelowane z wartością bieżącą ε_{it} i wartością opóźnioną $\varepsilon_{i,t-s}$, ale nieskorelowane z wartością przyszłą $\varepsilon_{i,t+s}$,
- z góry ustalone (słabo egzogeniczne), to znaczy $\mathbf{x}_{it}$ są nieskorelowane z ε_{it} i $\varepsilon_{i,t+s}$, ale skorelowane z $\varepsilon_{i,t-s}$,
- ściśle egzogeniczne, tzn. $\mathbf{x}_{it}$ są nieskorelowane z ε_{it} , $\varepsilon_{i,t+s}$ i $\varepsilon_{i,t-s}$.

Do estymacji modelu kształtowania się TFP, opisaney w artykule, zastosowano dwie (obecnie najpopularniejsze) metody: GMM pierwszych różnic (FDGMM) przedstawioną przez Arellano i Bonda (1991) oraz systemową GMM (SGMM) Blundella i Bonda (1998).

Zastosowanie FDGMM wymaga przyjęcia założenia, że składnik losowy ε_{it} w równaniu (6) nie wykazuje autokorelacji. W celu usunięcia efektów grupowych α_i oblicza się pierwsze różnice modelu (6). W tak powstałym modelu, postaci:

$$y_{it} - y_{i,t-1} = \gamma(y_{i,t-1} - y_{i,t-2}) + (\mathbf{x}_{it}^T - \mathbf{x}_{i,t-1}^T)\boldsymbol{\beta} + (\varepsilon_{it} - \varepsilon_{i,t-1}) \quad (7)$$

zmienne objaśniające zastępuje się instrumentami, którymi są opóźnione poziomy zmiennych z góry ustalonych i endogenicznych oraz pierwsze różnice zmiennych egzogenicznych. Jedno- i dwustopniowy estymator uzyskany przy zastosowaniu GMM z wykorzystaniem wskazanych instrumentów zaproponowali Arellano i Bond (1991). Nosi on nazwę estymatora GMM pierwszych różnic (ang. *first-differenced GMM*, FDGMM). Opracowali oni również odporny estymator wariancji dla metody jednostopniowej⁴.

Estymatory FDGMM mogą być silnie obciążone w przypadku, kiedy opóźnione poziomy zmiennych są słabymi instrumentami dla zmiennych zróżnicowanych. Sytuacja taka ma miejsce m.in. wtedy, gdy liczba obserwacji w czasie jest mała, ocena parametru autoregresyjnego zbliża się do 1 lub gdy stosunek wariancji efektu grupowego do wariancji właściwego składnika losowego jest zbyt duży. W takich przypadkach lepsze rezultaty daje stosowanie systemowego estymatora GMM (ang. *system GMM*, SGMM) Blundella i Bonda (1998).

Zasadnicza idea SGMM polega na oszacowaniu systemu równań: modelu (7) i modelu (6), a więc przyrostów i poziomów tego samego modelu. Dla równań na przyrostach postępowanie jest identyczne, jak w przypadku FDGMM. Natomiast w równaniach na poziomach instrumentami dla z góry ustalonych i endogenicznych zmiennych objaśniających są opóźnione pierwsze różnice odpowiednich zmiennych. Instrumenty te są właściwe przy założeniu, że ε_{it} nie wykazuje autokorelacji i że prawdziwe są warunki początkowe, postaci: $E(\alpha_i \Delta y_{i2}) = 0$ dla $i = 1, \dots, N$.

Oceny jakości modelu oszacowanego FDGMM lub SGMM dokonać można na podstawie testu autokorelacji Arellano-Bonda, testu Sargana lub różnicowego

⁴ Standardowy estymator wariancji dla metody dwustopniowej jest silnie obciążony w dół. Odporny estymator dla metody dwustopniowej zaproponował Windmeijer (2005).

testu Sargana. Są to testy badające, czy warunki momentów, będące w GMM podstawą wyznaczania estymatorów parametrów strukturalnych, są spełnione, a więc czy zastosowane zmienne instrumentalne są właściwe.

Dodatkową możliwość sprawdzenia, czy oceny parametrów uzyskane na podstawie FDGMM lub SGMM są nieobciążone, daje porównanie ich z ocenami wyznaczonymi na podstawie estymatora wewnątrzgrupowego (WG) i estymatora KMNK modelu *pooled*⁵. Nickell (1981) wykazał, że estymator WG parametru autoregresyjnego γ jest, przy ustalonym T , obciążony w dół, a estymator KMNK jest obciążony w górę. Wartość zgodnego estymatora parametru γ powinna zawierać się zatem pomiędzy tymi dwoma estymatorami.

OSZACOWANIE WARTOŚCI TFP WEDŁUG WOJEWÓDZTW

Dane statystyczne wykorzystane w badaniu dotyczą województw w okresie od 2000 r. do 2007 r. Pochodzą z badań GUS.

Do oszacowania wartości TFP wykorzystano dwie alternatywne metody, które zaproponowane zostały przez Tokarskiego (2008) oraz Ascari i Di Cosmo (2004). Obie wykorzystują funkcję produkcji Cobb-Douglasa postaci (4).

Metoda Tokarskiego wymaga oszacowania parametrów modelu wydajności. Model ten ma postać:

$$\ln\left(\frac{Y_{it}}{L_{it}}\right) = \sum_{i=1}^{16} \beta_i d_i + gt + \alpha \ln\left(\frac{K_{it}}{L_{it}}\right) + \varepsilon_{it} \quad (8)$$

gdzie:

Y — wartość produkcji sprzedanej w mln zł⁶,

L — nakłady pracy (wyrażone w tys. pracujących),

K — nakłady kapitału rzeczowego (mierzone wartością środków trwałych brutto w mln zł),

t — zmienna czasowa,

g — stopa postępu technicznego w sensie Hicksa,

α — elastyczność zmiennej Y względem zmiennej K ,

d_i ($i = 1, \dots, 16$) — zmienne zero-jedynkowe, przyjmujące wartość 1 dla i -tego województwa.

TFP dla poszczególnych województw określa wyrażenie: $TFP = \exp\left(\sum_{i=1}^{16} \beta_i d_i + gt\right)$.

⁵ Estymator wewnątrzgrupowy jest stosowany do szacowania modeli statycznych, w których efekty grupowe α_i są nielosowe (modeli FEM). Model *pooled* to model szacowany na podstawie danych panelowych, w którym jednak nie wyróżnia się efektów grupowych ani czasowych i zakłada się, że macierz wariancji-kowariancji składnika losowego jest sferyczna.

⁶ Oszacowano również model, w którym za Y przyjęto wartość dodaną brutto w mln zł, ale wyniki były znacznie gorsze.

Model (8) jest modelem szacowanym na podstawie danych czasowo-przekrojowych, przy założeniu występowania w nim heteroskedastyczności grupowej, będącej efektem zróżnicowania województw pod względem technicznego uzbrojenia pracy. Do estymacji zastosowano uogólnioną metodę najmniejszych kwadratów (UMNK) dla danych czasowo-przekrojowych⁷.

Wyniki estymacji modelu wydajności przedstawiono w tabl. 1. Wydają się one zadowalające. Oszacowana stopa postępu technicznego w sensie Hicksa wynosi prawie 2% rocznie, a elastyczność wydajności pracy względem technicznego uzbrojenia pracy jest równa 0,67. Są to wartości bardzo zbliżone do uzyskanych przez Tokarskiego (1998) dla próby z lat 1995—2005. Ponadto, wszystkie zmienne są statystycznie istotne, a dopasowanie modelu mierzone współczynnikiem determinacji — bardzo dobre. Na podstawie wyników estymacji modelu (8) oszacowano następnie wartości TFP w województwie i w roku t według wzoru:

$$TFP_{it}^{tok} = \frac{(Y_{it} / L_{it})}{(K_{it} / L_{it})^{0,665807}} \quad (9)$$

gdzie wartość wykładnika w mianowniku jest oceną parametru α modelu (8).

TABL. 1. WYNIKI ESTYMACJI MODELU WYDAJNOŚCI DLA WOJEWÓDZTW

Zmienne	Ocena parametru	Średni błąd szacunku	Istotność zmiennej (p-value)	Zmienne	Ocena parametru	Średni błąd szacunku	Istotność zmiennej (p-value)
$\ln(K/L)$	0,6658	0,0267	0,000	d_8	0,1798	0,0673	0,009
t	0,0174	0,0009	0,000	d_9	0,2137	0,0946	0,026
d_1	0,4259	0,1249	0,001	d_{10}	0,2045	0,0951	0,034
d_2	0,4525	0,1187	0,000	d_{11}	0,4282	0,1264	0,001
d_3	0,1550	0,0546	0,005	d_{12}	0,4745	0,1249	0,000
d_4	0,3575	0,1235	0,004	d_{13}	0,2221	0,0979	0,025
d_5	0,3590	0,1160	0,002	d_{14}	0,2939	0,1210	0,015
d_6	0,3461	0,1175	0,003	d_{15}	0,4407	0,1216	0,000
d_7	0,4384	0,1326	0,001	d_{16}	0,3752	0,1273	0,003

$R^2 = 0,986$

Źródło: opracowanie własne.

Zróżnicowanie TFP według województw obliczonego według wzoru (9) przedstawiono na wykresie.

Mimo dobrej jakości ocen TFP uzyskanych metodą Tokarskiego podjęto próbę oszacowania TFP alternatywną metodą, zaproponowaną przez Ascari i Di Cosmo. Wykorzystuje ona również funkcję produkcji Cobba-Douglasa. Ocenę parametru α_i , będącego elastycznością produkcji względem nakładu pracy, wy-

⁷ Idea tej metody została omówiona np. w pracy Dańskiej-Borsiak i Laskowskiej (2006).

znacza się na podstawie zależności $\alpha_i = w_i \cdot L_i / Y_i$, gdzie w_i jest przeciętnym wynagrodzeniem, a L_i — przeciętnym zatrudnieniem w województwie i , zaś Y_i — PKB wytworzonym w i -tym województwie. Tak wyznaczone α_i jest z założenia stałym parametrem technologicznym.

W kolejnym kroku szacuje się TFP, korzystając z zależności:

$$TFP_{it}^{ac} = \frac{Y_{it}}{(K_{it}^{1-\alpha_i} L_{it}^{\alpha_i})} \quad (10)$$

Wykres prezentuje również zróżnicowanie TFP według województw, obliczonej według wzoru (10). Wartości obu zmiennych są niemianowane, przyjęto zatem, że przeciętne TFP dla województwa, w którym poziom tej zmiennej jest najwyższy, równe są 100. Dla zmiennej TFP_{it}^{tok} jest to woj. śląskie, a dla zmiennej TFP_{it}^{ac} — woj. kujawsko-pomorskie.

Wartości TFP wyznaczone na podstawie wzoru (10) są nieco bardziej „spłaszczone” niż uzyskane ze wzoru (9). Współczynnik zmienności, liczony na podstawie wszystkich 128 obserwacji jako stosunek odchylenia standardowego

do średniej arytmetycznej, wynosi 0,097 dla zmiennej TFP_{it}^{ac} , a 0,114 dla zmiennej TFP_{it}^{tok} . Wykres pokazuje, że wartości TFP wyznaczone według wzorów (9) i (10) kształtują się bardzo podobnie. Współczynnik korelacji między tymi zmiennymi $r(TFP_{it}^{tok}, TFP_{it}^{ac}) = 0,894$. Dlatego model ekonometryczny kształtowania się TFP według województw skonstruowany został w dwóch wariantach: dla zmiennej objaśnianej TFP_{it}^{tok} i TFP_{it}^{ac} .

MODEL KSZTAŁTOWANIA SIĘ TFP WEDŁUG WOJEWÓDZTW

Na podstawie opracowań o charakterze teoretycznym i empirycznym, znanych z literatury światowej⁸, wytypowano czynniki mogące wpływać na poziom TFP. Oszacowano kilkanaście modeli, w których w roli zmiennych objaśniających uwzględniano alternatywne miary czynników, mogących mieć wpływ na produktywność. Zbiór potencjalnych zmiennych objaśniających obejmuje cechy wykorzystywanych do określenia:

- wielkości kapitału fizycznego:
tup — techniczne uzbrojenie pracy, mierzone wartością środków trwałych brutto na pracującego, w tys. zł;
- wielkości inwestycji:
sinw — stopa inwestycji, liczona jako udział nakładów inwestycyjnych w PKB,
inwpr — nakłady inwestycyjne na pracującego w zł;
- wielkości nakładów na działalność badawczo-rozwojową (BiR):
snbr — nakłady na BiR w relacji do PKB w %,
nbrpc — nakłady na BiR na mieszkańca w zł,
nbrinw — nakłady na BiR w relacji do nakładów inwestycyjnych;
- kapitału ludzkiego:

hk — kapitał ludzki obliczony według wzoru $hk = \sum_{i=0}^4 \frac{h_i}{h_0} lprac_i$, gdzie:

h_i — liczba lat kształcenia dla *i*-tego poziomu wykształcenia (indeks 0 oznacza wykształcenie podstawowe, 1 — zasadnicze zawodowe, 2 — średnie ogólnokształcące, 3 — policealne oraz średnie zawodowe, 4 — wyższe),

lprac_i — liczba pracujących z *i*-tym poziomem wykształcenia,

edu — kapitał ludzki, obliczony jako suma udziałów pracujących z kolejnymi poziomami wykształcenia, mnożonych przez liczbę lat nauki.

Dane statystyczne, na podstawie których oszacowano model kształtowania się TFP w województwach obejmują okres od 2002 r. do 2007 r. Wcześniejsze lata zostały pominięte ze względu na niedostępność danych wojewódzkich o pracu-

⁸ Cameron (2006); Griffith, Redding, Van Reen (2003); Coe, Helpman (1995); Acharya, Keller (2007).

jących według poziomu wykształcenia. Wszystkie zmienne wyrażone są w cenach stałych z 2000 r.

Zmienną objaśnianą szacowanych modeli była zmienna TFP_{it}^{tok} lub TFP_{it}^{ac} . Model dla zmiennej TFP_{it}^{tok} , który charakteryzował się najlepszymi własnościami statystyczno-merytorycznymi ma postać:

$$\ln(TFP_{it}^{tok}) = \alpha_0 + \gamma \ln(TFP_{i,t-1}) + \beta_1 \ln(edu_{it}) + \beta_2 \ln(nbrinw_{i,t-2}) + \beta_3 \ln(tup_{i,t-1}) + (\alpha_i + \varepsilon_{it}) \quad (11)$$

TABL. 2. WYNIKI ESTYMACJI MODELU KSZTAŁTOWANIA SIĘ ZMIENNEJ TFP_{it}^{tok}

Zmienne objaśniające/testy statystyczne	Metoda estymacji				
	SGMM endo	SGMM egzo	FDGMM endo	WG	KMNK
	1	2	3	4	5
$\ln(TFP_{i,t-1}^{tok})$	0,5609*	0,3136	0,3613*	0,2689*	0,9485*
$\ln(edu_{it})$	0,5020**	1,1075	0,7789	1,1765*	-0,3229
$\ln(nbrinw_{i,t-2})$	0,0291**	0,0671	0,0196	0,0258	0,0075
$\ln(tup_{i,t-1})$	0,4067**	0,209	0,3556**	0,0279	0,0490
cons	-1,0560	-3,2670	-2,0764	-2,7070*	0,6636
m_1 [p-value]	-2,455 [0,014]	-1,458 [0,145]	-1,842 [0,066]	—	—
m_2 [p-value]	-1,166 [0,244]	-1,256 [0,209]	-1,790 [0,073]	—	—
Sargan [p-value]	42,761 [0,237]	24,141 [0,020]	27,693 [0,322]	—	—
dif-Sargan [p-value]	15,068 [0,238]	9,989 [0,041]	—	—	—
R^2	—	—	—	0,792	0,933

U w a g a. Symbol * przy ocenie parametru oznacza, że wartość p dla testu t -Studenta $p < 0,05$; symbol ** oznacza $p \leq 0,1$; pozostałych zmiennych nie można uznać za istotne.

m_1 i m_2 oznaczają wartości empiryczne testu autokorelacji Arellano-Bonda, odpowiednio AR(1) i AR(2), w nawiasach kwadratowych — wartości p dla H_0 : autokorelacja pierwszego (drugiego) rzędu nie występuje.

Sargan i dif-Sargan oznaczają wartości empiryczne testu Sargana i różnicowego testu Sargana, w nawiasach kwadratowych — wartości p dla H_0 : warunki ponadidentyfikujące są spełnione, odczytane dla odpowiedniej liczby stopni swobody, zależnej od liczby wykorzystanych instrumentów.

Ź r ó d ł o: jak przy tabl. 1.

Wyniki estymacji modelu (11) przy zastosowaniu alternatywnych metod na podstawie metody GMM przedstawiono w tabl. 2. Model ten estymowany był za pomocą jednostopniowych FDGMM i SGMM, przy czym przyjmowano alternatywne założenia o endogeniczności (lub egzogeniczności) zmiennych objaśniających. Ostatecznie uznano, że zmiennymi endogenicznymi są zmienne tup i edu . Oznaczenia „endo” i „egzo” przy nazwach SGMM i FDGMM oznaczają sposób traktowania tych zmiennych odpowiednio jako endogeniczne i egzogeniczne.

Analiza wyników estymacji z tabl. 2 wskazuje na poprawę jakości modelu spowodowaną uwzględnieniem nieegzogeniczności zmiennych objaśniających i zastosowaniem SGMM. Widoczna jest ona zarówno we wzroście precyzji estymacji, jak i w wynikach testów statystycznych. Efektywność SGMM wzrasta po uwzględnieniu endogeniczności zmiennych objaśniających (kolumny 1

i 2). Porównanie SGMM i FDGMM z uwzględnieniem endogeniczności (kolumny 1 i 3) pozwala stwierdzić przewagę tej pierwszej metody. Właściwość instrumentów wykorzystanych w SGMM z założeniem egzogeniczności zmiennych objaśniających (kolumna 2) i FDGMM (kolumna 3) jest wątpliwa, ponieważ wyniki testów Arellano-Bonda i Sargana są niejednoznaczne. Wynik testu Sargana w kolumnie 2 świadczy o niepoprawności ponadidentyfikujących warunków momentów wykorzystanych do estymacji GMM modelu pierwszych różnic. Wynik różnicowego testu Sargana również przemawia w tym przypadku za odrzuceniem H_0 . Oznacza to, że dodatkowe warunki momentów, których spełnienie zakłada się stosując SGMM (a więc szacując, oprócz modelu pierwszych różnic, model na poziomach), również nie są spełnione. Natomiast test Arellano-Bonda nie dał podstaw do odrzucenia hipotezy zerowej, co oznacza, że warunki momentów są spełnione. Wydaje się, że opisana niejednoznaczność wyników może być spowodowana niejednorodnością wariancji składnika losowego modelu (11). Test Sargana bywa wówczas obciążony na niekorzyść hipotezy zerowej.

Podobne wątpliwości związane z jakością instrumentów nasuwają się w przypadku FDGMM. O ile wyniki obu testów Sargana w kolumnie 3 nie dają podstaw do odrzucenia H_0 , to test Arellano-Bonda stwierdza występowanie autokorelacji drugiego rzędu w modelu pierwszych różnic. Oznacza to, że warunki momentów są niespełnione.

Z naszych rozważań jednoznacznie wynika, że SGMM z uwzględnieniem endogeniczności zmiennych *tup* i *edu* dała najbardziej poprawne wyniki. Oprócz wyników testów Arellano-Bonda i Sargana świadczy o tym porównanie oceny SGMM parametru autoregresyjnego z ocenami WG i KMNK tego parametru. Zawiera się ona pomiędzy oceną WG a oceną KMNK, co jest zjawiskiem pożądanym. Za wyborem SGMM z uwzględnieniem endogeniczności zmiennych *tup* i *edu* jako najlepszej metody estymacji modelu (11) przemawia również istotność wszystkich zmiennych objaśniających i merytoryczna poprawność ocen parametrów strukturalnych.

Wątpliwości co do pełnej poprawności wyników estymacji przedstawionych w kolumnie 1 może wzbudzić oszacowana wartość parametru autoregresyjnego. Ocena $\hat{\gamma}_{SGMMendo} = 0,56$ może wydawać się zbyt niska. Dla porównania, oceny uzyskane przez wspomnianych już Ascari i Di Cosmo w badaniu dotyczącym 20 regionów Włoch były wyższe — wahały się od 0,79 do 0,86. Przyczyną zaniżonej wartości oceny parametru przy zmiennej $TFP_{i,t-1}^{tok}$ oraz innej niedoskonałości modelu może być m.in. nieuwzględnienie zmiennych odzwierciedlających transfer technologii.

Model zmiennej TFP_{it}^{ac} charakteryzujący się najlepszymi własnościami statystyczno-merytorycznymi ma postać:

$$\ln(TFP_{it}^{ac}) = \alpha_0 + \gamma \ln(TFP_{i,t-1}) + \beta_1 edu_{it} + \beta_2 nbrinw_{i,t-2} + \beta_3 tup_{i,t-1} + (\alpha_i + \varepsilon_{it}) \quad (12)$$

Zbiór zmiennych objaśniających jest identyczny, jak w modelu kształtowania się zmiennej TFP_{it}^{tok} , ale postać funkcyjna musiała ulec zmianie, ponieważ wyniki estymacji modelu potęgowego nie były zadowalające. W modelu (12) jest ona taka sama, jak stosowana przez Ascari i Di Cosmo. Parametry tego modelu nie mają interpretacji ekonomicznej, co jest wadą w stosunku do modelu (11). Do estymacji modelu (12) zastosowano analogiczne metody, jak w przypadku modelu (11), przy czym w wyniku wielu prób uznano, że endogeniczną zmienną objaśniającą jest zmienna tup . Wyniki estymacji modelu (12) przedstawiono w tabl. 3.

TABL. 3. WYNIKI ESTYMACJI MODELU KSZTAŁTOWANIA SIĘ ZMIENNEJ TFP_{it}^{ac}

Zmienne objaśniające/testy statystyczne	Metoda estymacji				
	SGMM endo	SGMM egzo	FDGMM endo	WG	KMNK
	1	2	3	4	5
$\ln(TFP_{i,t-1}^{ac})$	0,4400*	0,2257	0,3733*	0,02539*	0,8948*
edu_{it}	0,0681**	0,0865**	0,0695*	0,0747**	-0,0003
$nbrinw_{i,t-2}$	0,1470**	1,4995	0,5836	0,7569	0,1489
$tup_{i,t-1}$	0,0044*	-0,0025	0,0045**	-0,0007	0,0001
$cons$	-1,0773	-1,6462**	-1,2839	-1,5713*	-0,0631
m_1 [p-value]	-2,096 [0,036]	-2,204 [0,028]	-2,167 [0,030]	—	—
m_2 [p-value]	-1,631 [0,103]	-1,011 [0,312]	-1,471 [0,141]	—	—
Sargan [p-value]	32,207 [0,122]	24,397 [0,018]	25,591 [0,033]	—	—
dif-Sargan [p-value]	6,616 [0,579]	11,141 [0,025]	—	—	—
R^2	—	—	—	0,490	0,900

U w a g a. Oznaczenia jak w tabl. 2.

Ź r ó d ł o: jak przy tabl. 1.

Z punktu widzenia statystycznej jakości modelu stwierdzić trzeba, że wyniki uzyskane na podstawie SGMM z endogenicznością zmiennej tup (tabl. 3, kolumna 1) są akceptowalne. Wyniki testów Arellano-Bonda i Sargana nie dają podstaw do odrzucenia hipotezy zerowej o właściwości zastosowanych instrumentów, a ocena parametru przy zmiennej $TFP_{i,t-1}^{ac}$ zawiera się pomiędzy ocenami WG i KMNK. Podobnie jak w przypadku wyników estymacji modelu (11), w tabl. 2 rezultaty uzyskane na podstawie SGMM z egzogenicznością wszystkich zmiennych objaśniających (kolumna 2) i na podstawie FDGMM (kolumna 3) są gorsze. Efektywność estymatorów jest w obu przypadkach niższa, a wyniki testów Sargana sugerują niewłaściwość użytych instrumentów. Na podstawie rezultatów testu Arellano-Bonda, który w obu przypadkach stwierdza brak podstaw do odrzucenia H_0 , można przypuszczać, że wyniki testu Sargana są obciążone na niekorzyść hipotezy zerowej z powodu niejednorodności wariancji składnika losowego modelu (12).

Z punktu widzenia merytorycznego uzyskane obecnie wyniki są gorsze niż wyniki uzyskane na podstawie modelu (11). Przede wszystkim wartość oceny parametru przy zmiennej $TFP_{i,t-1}^{ac}$ wydaje się zaniżona. Jej wartość (0,44) jest niższa niż wartość (0,56) uzyskana dla parametru przy zmiennej $TFP_{i,t-1}^{tok}$, która już budziła wątpliwości. Poza tym brak możliwości interpretacji ekonomicznej parametrów modelu (12) obniża jego wartość poznawczą.

Zakończenie

W opisanym badaniu analizie poddano TFP według województw i wskazano czynniki, które wpływają na kształtowanie się tej zmiennej. Jako narzędzie analizy zastosowano panelowe modele dynamiczne. Na pierwszym etapie badania oszacowano wartości TFP. Najwyższą wartość TFP stwierdzono w województwach o rozwiniętym przemyśle: śląskim, kujawsko-pomorskim, wielkopolskim, mazowieckim, pomorskim i dolnośląskim. Najmniejsze wartości TFP charakterystyczne były dla województw: świętokrzyskiego, podkarpackiego, podlaskiego, opolskiego i lubelskiego. Te wyniki są spójne z zauważanym od lat podziałem kraju na bardziej i mniej rozwinięty gospodarczo (tzw. Polska A i Polska B).

Po oszacowaniu modelu kształtowania się TFP stwierdzono relatywnie dużą stabilność wartości tej zmiennej (ocena parametru autoregresyjnego wynosiła 0,56). Jest to wynik niepokojący, ponieważ świadczy o utrwalaniu niekorzystnego podziału Polski na obszar gospodarczo efektywny i nieefektywny. Stwierdzono ponadto, że na wartość TFP istotny wpływ mają: kapitał ludzki, opóźniona o 1 okres wartość technicznego uzbrojenia pracy i opóźniona o 2 okresy relacja nakładów na BiR do ogólnych nakładów inwestycyjnych. Ten wynik może być wskazówką, w jakie czynniki należałoby zainwestować, aby przyspieszyć postęp techniczny, a co za tym idzie, zwiększyć efektywność procesu produkcyjnego w województwach słabiej rozwiniętych.

dr Barbara Dańska-Borsiak — Uniwersytet Łódzki

LITERATURA

- Acharya R. C., Keller W. (2007), *Technology Transfer through Imports*, NBER Working Paper, No. 13086
- Arellano M., Bond S. (1991), *Some tests of specification for panel data: Monte Carlo evidence and an application to employment equations*, „Review of Economic Studies”, No. 58
- Ascari G., Di Cosmo V. (2004), *Determinants of Total Factor Productivity in the Italian Regions*, University of Pavia, Department of Economics
- Baltagi B. H. (2008), *Econometric Analysis of Panel Data*, 4th edn., Wiley&Sons, Chichester
- Blundell R., Bond S. (1998), *Initial conditions and moment restrictions in dynamic panel data models*, „Journal of Econometrics”, vol. 87, No. 1

- Cameron G. (2006), *Openness, R&D, and growth at the industry level*, [w:] *Perspectives on Economic Growth*, L. A. Finley (ed), Nova Publishers: Hauppauge NY
- Coe D., Helpman E. (1995), *International R&D Spillovers*, „European Economic Review”, No. 39
- Dańska-Borsiak B., Laskowska I. (2006), *Heteroskedastyczność grupowa i korelacja przekrojowa w analizach wykorzystujących próby czasowo-przekrojowe*, „Prace Naukowe AE we Wrocławiu, Taksonomia”, nr 13, Wrocław
- Dańska-Borsiak B., Laskowska I. (2006), *Wybrane problemy estymacji modeli opartych na danych czasowo-przekrojowych*, „Przegląd Statystyczny”, tom 53 (3), Warszawa
- Griffith R., Redding S., Van Reen J. (2003), *R&D and absorptive capacity: theory and empirical evidence*, „Scandinavian Journal of Economics”, No. 105
- Hsiao C. (2003), *Analysis of Panel Data*, 2nd edn., Cambridge University Press
- Nickel S. (1981), *Biases in dynamic models with fixed effects*, „Econometrica”, No. 49
- Solow R. (1957), *Technical Change and the Aggregate Production Function*, „The Review of Economics and Statistics”, vol. 39, No. 3
- Świeczewska D. (2007), *Łączna produktywność czynników produkcji. Ucieleśniony kapitał wiedzy*, [w:] Welfe W. (red.), *Gospodarka oparta na wiedzy*, PWE, Warszawa
- Tokarski T. (2008), *Oszacowanie regionalnych funkcji produkcji*, „Wiadomości Statystyczne”, nr 10
- Welfe W. (red.) (2001), *Ekonometryczny model wzrostu gospodarczego*, Wydawnictwo Uniwersytetu Łódzkiego, Łódź
- Windmeijer F. (2005), *A finite sample correction for the variance of linear efficient two-step GMM estimators*, „Journal of Econometrics”
- Zienkowski L. (red.) (2003), *Wiedza a wzrost gospodarczy*, Scholar, Warszawa

SUMMARY

Growth analysis of total factor productivity (TFP) is a synthetic method to assess changes in the efficiency of production processes, occurring under the influence of technical progress. The study analyzed the evolution of TFP by voivodships and identified the factors that affect this variable. The first stage of this study was to estimate the immeasurable value of the TFP variable based on a time-transversal sample. The results showed significant differences in estimates of the TFP in the voivodships. The next stage of analysis was to estimate the dynamic panel model describing the evolution of TFP. It was found relatively high stability of the variable value and the significant impact of human capital, delayed by 1 period of the technical equipment of work and delayed by 2 periods of the relationship in R&D to investment.

РЕЗЮМЕ

Анализ роста общей производительности факторов производства (TFP — Total factor productivity) является синтетическим способом оценки изменений эффективности производственных процессов, которые происходят под влиянием технического прогресса.

В обследовании было проанализировано формирование TFP по воеводствам и были указаны факторы, которые влияют на эту переменную. Первый этап обследования касался оценки неизмеряемого значения переменной TFP на основе временно-разрезной выборки. Результаты оценки показали существенную дифференциацию значения TFP в воеводствах. Очередным этапом анализа была оценка динамической панельной модели представляющей формирование TFP. Была обнаружена относительно большая стабильность значения этой переменной, а также существенное влияние человеческого капитала с опозданием времени на 1 период значения технического оснащения труда и на 2 периода отношения затрат на обследования, развитие и по капиталовложениям.