

SZACOWANIE I MODELOWANIE TFP W PRZEMYSŁE POLSKIM NA PODSTAWIE DANYCH PANELOWYCH¹

Barbara Dańska-Borsiak

Katedra Ekonometrii Przestrzennej UŁ
e-mail: danska@uni.lodz.pl

Streszczenie: W artykule przedstawiono próbę oszacowania łącznej produktywności czynników produkcji (TFP) według działów sekcji „przetwórstwo”, oraz określenia czynników determinujących jej kształtowanie. Do oszacowania wartości TFP zastosowano dwie alternatywne metody, bazujące na funkcji produkcji Cobba–Douglasa. Następnie skonstruowano i oszacowano dynamiczny model panelowy, opisujący kształtowanie się TFP w działach. Zmienną objaśnianą były wartości oszacowane w pierwszym etapie analizy. Do estymacji zastosowano metody bazujące na GMM.

Słowa kluczowe: dynamiczny model panelowy, funkcja produkcji, łączna produktywność czynników produkcji (TFP), systemowy estymator GMM.

WSTĘP

Łączna produktywność czynników produkcji (TFP) jest definiowana jako produkt, który może być wytworzony z jednostkowych nakładów czynników produkcji. Wzrost TFP jest sposobem oceny zmian efektywności procesu produkcyjnego, wynikających z postępu technicznego.

Zasadniczym celem referatu jest określenie czynników, które determinują kształtowanie się TFP w działach sekcji D „przetwórstwo” w Polsce. Ze względu na niemierzalność TFP, wstępnym zadaniem jest oszacowanie wartości tej zmiennej. W prezentowanym badaniu zastosowano dwie metody, bazujące na funkcji produkcji Cobba – Douglasa, różniące się sposobem oszacowania elastyczności produkcji względem nakładów pracy. Jako narzędzia analizy zastosowano

¹ Praca naukowa finansowana ze środków na naukę w latach 2007-2009, jako projekt badawczy nr N111 0938 33

modele panelowe: model z heteroskedastycznością grupową, oraz model dynamiczny.

METODOLOGIA

Modele panelowe są szacowane na podstawie danych przekrojowo – czasowych, w których liczba obserwowanych obiektów N przekracza, niekiedy znacznie, liczbę punktów w czasie T . Cechą charakterystyczną ich konstrukcji jest wyróżnienie efektu grupowego, stałego w czasie, specyficznego dla danego obiektu². Dynamiczny model panelowy ma postać:

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

dla $i = 1, \dots, N$, $t = 1, \dots, T$. Opóźniona zmienna objaśniana jest skorelowana ze stałymi w czasie efektami grupowymi α_i , co powoduje, że metody stosowane do estymacji statycznych modeli panelowych nie mogą być stosowane do estymacji modelu (1), gdyż estymatory te byłyby niezgodne i obciążone. W literaturze proponuje się alternatywne metody estymacji panelowych modeli dynamicznych. Ich przegląd znaleźć można np. w [Baltagi 2008], [Hsiao 2003]. Metody te bazują na Metodzie Zmiennych Instrumentalnych, Metodzie Największej Wiarygodności lub Uogólnionej Metodzie Momentów (GMM). Zaletą GMM jest między innymi możliwość uwzględnienia alternatywnych założeń odnośnie korelacji zmiennych objaśniających (elementów wektora \mathbf{x}_{it} modelu (1)) ze składnikiem losowym ε_{it} . W szczególności dopuszczona może być endogeniczność zmiennych \mathbf{x}_{it} (wszystkich, lub części z nich), to znaczy ich skorelowanie z wartościami składnika losowego: bieżącą ε_{it} i opóźnionymi $\varepsilon_{i,t-s}$, lub słaba egzogeniczność zmiennych \mathbf{x}_{it} , to znaczy ich korelacja z wartościami $\varepsilon_{i,t-s}$. Pozostałe metody zakładają ścisłą egzogeniczność zmiennych \mathbf{x}_{it} , to znaczy brak korelacji tych zmiennych z ε_{it} , $\varepsilon_{i,t-s}$, i $\varepsilon_{i,t+s}$.

Do estymacji modelu kształtowania się łącznej produktywności czynników produkcji (TFP), prezentowanego w niniejszym referacie zastosowano dwie, alternatywne metody: GMM pierwszych różnic (FDGMM) przedstawioną w [Arellano, Bond 1991], oraz systemową GMM (SGMM) [Blundell, Bond 1998]. Poniżej przedstawiona jest zasadnicza idea tych metod.

Zastosowanie FDGMM wymaga przyjęcia założenia, że składnik losowy ε_{it} w równaniu (1) nie wykazuje autokorelacji. W celu usunięcia efektów grupowych α_i oblicza się pierwsze różnice modelu (1). W tak powstałym modelu, postaci:

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

² Można też wyodrębnić dodatkowo trzecią składową, stałą względem obiektów, zwaną efektem czasowym.

zmienne objaśniające zastępuje się instrumentami, którymi są opóźnione poziomy zmienne słabo egzogeniczne i endogeniczne, oraz pierwsze różnice zmiennych egzogenicznych. Estymator, uzyskany przy zastosowaniu GMM z wykorzystaniem wskazanych powyżej instrumentów zaproponowano w [Arellano, Bond 1991]. Nosi on nazwę estymatora GMM pierwszych różnic (ang. *first-differenced GMM*, FDGMM).

Estymatory FDGMM mogą być silnie obciążone w przypadku, kiedy opóźnione poziomy zmienne są słabymi instrumentami dla zmiennych zróżnicowanych. W takich przypadkach lepsze rezultaty daje stosowanie systemowego estymatora GMM (ang. *system GMM*, SGMM) [Blundell, Bond 1998]. Zasadnicza idea SGMM polega na oszacowaniu systemu równań: modelu (2) i modelu (1), 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 oraz 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, lub testu Sargana (por. [Arellano, Bond 1991]). W części empirycznej niniejszego referatu stosowany jest jedynie pierwszy z nich, gdyż obliczane są odporne błędy szacunku parametrów, a wówczas rozkład statystyki testu Sargana nie jest znany. Hipoteza zerowa testu Arellano - Bonda głosi, że w modelu pierwszych różnic (2) nie występuje autokorelacja składnika losowego drugiego rzędu³, co oznacza, że warunki momentów są spełnione, a więc zastosowane instrumenty 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*⁴. [Nickell 1981] wykazał, że estymator WG parametru autoregresyjnego γ jest, przy ustalonym T , obciążony w dół, a estymator KMNK jest obciążony w górę (np. [Hsiao 2003]). Wartość zgodnego estymatora parametru γ powinna zawierać się zatem pomiędzy wartościami tych dwóch estymatorów.

³ Występowanie w modelu (2) autokorelacji pierwszego rzędu jest zjawiskiem spodziewanym, gdyż jeśli ε_{it} są niezależne, to ich pierwsze różnice są skorelowane rzędu 1.

⁴ 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.

OSZACOWANIE ŁĄCZNEJ PRODUKTYWNOŚCI CZYNNIKÓW PRODUKCJI (TFP)

Jak wspomniano we wstępie, łączna produktywność czynników produkcji (TFP) jest zmienną nieobserwowalną. Jednym ze sposobów oszacowania TFP jest wykorzystanie funkcji produkcji. Poniżej zaprezentowane zostaną wyniki, uzyskane dwiema alternatywnymi metodami. Pierwsza z nich opiera się na propozycji zawartej w [Tokarski 2008], i wymaga oszacowania parametrów funkcji wydajności. Druga metoda opiera się na założeniu o doskonałej konkurencji na rynkach czynników produkcji i założeniu, że elastyczność produkcji względem nakładu pracy jest stała w czasie, a może się różnić między działami. Została ona zaproponowana w [Ascari, Di Cosmo 2004].

Opierając się na propozycji Tokarskiego [2008] wartości TFP dla poszczególnych działów wyznaczono na podstawie zależności:

$$\ln\left(\frac{Y_{it}}{L_{it}}\right) = \left(\sum_{i=15}^{37} \beta_i d_i + gt\right) + \alpha \ln\left(\frac{K_{it}}{L_{it}}\right) + \varepsilon_{it}. \quad (3)$$

Jest to zlogarytmowana funkcja wydajności pracy Cobba-Douglasa gdzie: Y – wartość produkcji sprzedanej w mln. zł.⁵, L – nakłady pracy (w tys. pracujących), K – nakłady kapitału rzeczowego (wartość środków trwałych brutto w mln. zł.), α – elastyczność zmiennej Y względem zmiennej K , i – numer działu, t – numer okresu.

Łączna produktywność czynników produkcji (TFP) jest równa $e^{\sum \beta_i d_i + gt}$, gdzie g – stopa postępu technicznego w sensie Hicksa, d_i – zmienne zero-jedynkowe specyficzne dla działów (i – numer działu). Celem ich wprowadzenia jest dopuszczenie zróżnicowania TFP według działów, a procedura taka nosi nazwę procedury dywersyfikacji stałej⁶.

Model (3) oszacowano na podstawie danych z lat 1998 – 2007, pochodzących z Roczników Statystycznych Przemysłu GUS. Dotyczą one 22 działów sekcji D – „przetwórstwo”, oznaczonych w klasyfikacji PKD numerami 15 – 37. Do estymacji parametrów modelu (3) zastosowano Uogólnioną Metodę Najmniejszych Kwadratów (UMNK), gdyż ze względu na duże zróżnicowanie wydajności i technicznego uzbrojenia pracy między działami dopuszczono występowanie heteroskedastyczności grupowej.

Szczegółowe wyniki estymacji nie są tu prezentowane z braku miejsca; wydają się one jednak zadowalające. Oszacowana stopa postępu technicznego w sensie Hicksa wynosi ok. 4% ($\hat{g} = 0,0439$), a elastyczność wydajności pracy względem

⁵ Oszacowano również model, w którym za Y przyjęto wartość dodaną brutto w mln. zł., ale wyniki były znacznie gorsze, dlatego nie są tu prezentowane.

⁶ por. Pindyck, Rubinfeld [1991].

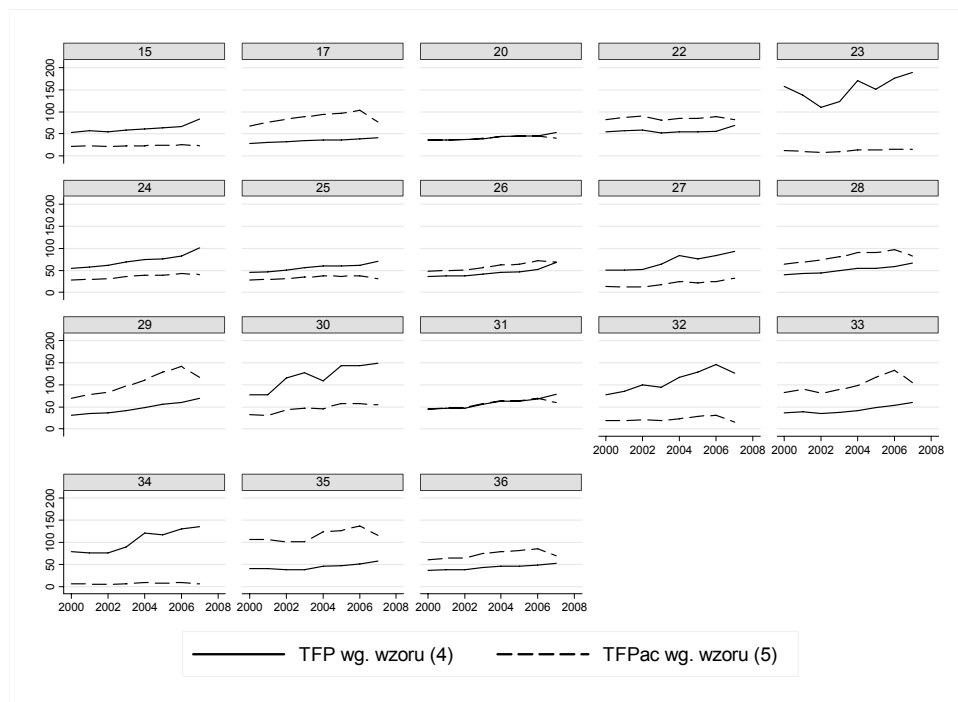
technicznego uzbrojenia pracy jest równa 0,26 ($\hat{\alpha}=0,2632$). Ponadto wszystkie zmienne są statystycznie istotne na każdym poziomie istotności, a bardzo dobre dopasowanie modelu ($R^2=0,9744$) pozwala uznać, że wartości TFP wyznaczone na podstawie modelu (3) są wiarygodne.

Na podstawie wyników estymacji modelu (3) oszacowano następnie wartości TFP w dziale i w roku t według wzoru:

$$TFP_{it} = \frac{(Y_{it} / L_{it})}{(K_{it} / L_{it})^{0,26321}}, \quad (4)$$

gdzie wartość wykładnika w mianowniku jest oceną parametru α modelu (3).

Rysunek 1. Porównanie wartości TFP (wzór (4)) i TFP_{pac} (wzór 5))



Źródło: opracowanie własne

Kolejnym etapem badań była próba ponownego oszacowania TFP przy zastosowaniu podejścia [Ascari, Di Cosmo 2004]. Polega ono na wyznaczeniu oceny parametru α_i , będącego elastycznością produkcji względem nakładu pracy na podstawie zależności $\alpha_i = w_i \cdot L_i / Y_i$, gdzie w_i jest przeciętnym wynagrodzeniem, Y_i – wartością produkcji sprzedanej, L_i – zatrudnieniem. Wszystkie wartości są specyficzne dla działów oraz stałe w czasie i reprezentują średnie dla poszczególnych

działów po czasie. Jest to zgodne z przyjętymi przez autorów założeniami, że α_i jest parametrem technologicznym, który nie powinien się zmienić w okresie objętym próbą, zaś rynki czynników produkcji charakteryzują się konkurencją doskonałą. Następnie wyznacza się łączną produktywność czynników produkcji korzystając z zależności:

$$TFPac_{it} = Y_{it} / (K_{it}^{1-\hat{\alpha}_i} L_{it}^{\hat{\alpha}_i}), \quad (5)$$

gdzie $\hat{\alpha}_i$ jest oszacowaną wartością parametru α_i . Metoda zawarta w [Ascari, Di Cosmo 2004], podobnie jak w [Tokarski 2008], wykorzystuje więc funkcję produkcji Cobba – Douglasa ze stałymi efektami skali.

Wyniki otrzymane na podstawie wzoru (5) różnią się istotnie w porównaniu z wynikami uzyskanymi na podstawie wzoru (4). Porównanie wartości TFP wyznaczonych na podstawie wzorów (4) i (5) przedstawiono na rysunku 1.

Wydaje się, że oszacowania TFP w poszczególnych działach, uzyskane na podstawie wzoru (5) nie są poprawne. Znacznie bardziej prawdopodobne jest, że średnie wartości TFP w działach rozkładają się tak, jak uzyskane na podstawie wzoru (4). Intuicyjnie, efekty postępu technicznego powinny być bardziej widoczne w dynamicznie rozwijających się działach związanych z produkcją sprzętu komputerowego (30), telekomunikacyjnego (32) czy samochodowego (34), niż w działach związanych z włókiennictwem (17), optyką (33) czy pozostałym sprzętem transportowym (35). Dlatego zmienną objaśnianą w modelu kształtowania się łącznej produktywności czynników produkcji będzie zmienna *TFP* wyznaczona ze wzoru (4).

MODEL KSZTAŁTOWANIA SIĘ ŁĄCZNEJ PRODUKTYWNOŚCI CZYNNIKÓW PRODUKCJI

Po oszacowaniu wartości TFP podjęto próbę skonstruowania i oszacowania modelu ekonometrycznego, opisującego kształtowanie się tej zmiennej według działów. W związku z niedostępnością części danych, dotyczących działalności badawczo – rozwojowej (brak danych o nakładach i zatrudnieniu dla działów 16, 18, 19, 21, 37) oraz danych o imporcie i eksporcie dla wszystkich działów w latach 1998 – 1999, zdecydowano się zawęzić próbę. Analiza kształtowania się TFP przeprowadzona została na podstawie danych dla 18 działów ($i=15, 17, 20, 22, \dots, 36$) z lat 2000–2007.

Na podstawie opracowań o charakterze teoretycznym i empirycznym, znanych z literatury światowej⁷, wytypowano czynniki, mogące wpływać na poziom TFP. Są to: kapitał ludzki, kapitał fizyczny, nakłady na działalność badawczo – rozwojową (BiR), transfer technologii, dokonujący się poprzez handel międzyna-

⁷ por. Cameron [2006], Griffith i in. [2003], Coe i in. [1995], Acharya i in. [2007]

rodowy. Oszacowano kilkanaście modeli, w których zmiennymi objaśniającymi były następujące, alternatywne miary wymienionych powyżej czynników:

- dla określenia kapitału ludzkiego: hk – stosunek liczby zatrudnionych na stanowiskach nierobotniczych do liczby zatrudnionych ogółem, $zbrlp$ – stosunek liczby zatrudnionych w działalności BiR do liczby pracujących ogółem;
- dla określenia kapitału fizycznego: $stbh$ – wartość środków trwałych brutto na jedną przepracowaną godzinę w zł/godz.;
- dla określenia wpływu transferu technologii: $imps$ – stosunek wartości importu do wartości produkcji sprzedanej, $ekps$ – stosunek wartości eksportu do wartości produkcji sprzedanej;
- dla określenia wpływu działalności badawczo – rozwojowej: $brinw$ – stosunek nakładów na BiR do nakładów inwestycyjnych.

Wymienione powyżej zmienne wprowadzane były do modelu albo jako wartości bieżące, albo opóźnione o 1 lub 2 okresy. Dodatkowo konieczne okazało się wprowadzenie zmiennych zero-jedynkowych, które dla kolejnych lat próby oznaczono symbolami $r00, r01, \dots, r07$. Ostateczna postać modelu, który charakteryzował się najlepszymi własnościami merytoryczno – statystycznymi jest następująca:

$$\begin{aligned} \ln(TFP_{it}) = & \alpha_0 + \gamma \ln(TFP_{i,t-1}) + \beta_1 \ln(hk_{it}) + \beta_2 \ln(brinw_{i,t-2}) + \\ & + \beta_3 \ln(stbh_{it}) + \beta_4 \ln(imps_{i,t-1}) + \\ & + \beta_5 r02 + \beta_6 r03 + \beta_7 r05 + \varepsilon_{it} \end{aligned} \quad (6)$$

Do estymacji modelu (6) stosowane były FDGMM i SGMM, przy czym przyjmowane były alternatywne założenia o korelacji zmiennych objaśniających ze składnikiem losowym. Ostatecznie uznano, że najlepszą metodą estymacji modelu (6) jest SGMM z założeniem endogeniczności zmiennych $stbh$ i hk . Właściwość instrumentów stwierdzono testem autokorelacji Arellano-Bonda. Ponadto ocena parametru autoregresyjnego (0,673) zawiera się pomiędzy oceną WG (0,505) a oceną KMNK (0,9342), co dodatkowo świadczy o zgodności estymatora.

Najsilniejszy wpływ na wzrost TFP wywiera wzrost kapitału ludzkiego (elastyczność 0,22%). Bardzo znaczący jest również wpływ transferu technologii na TFP, dokonujący się poprzez wymianę międzynarodową. Elastyczność zmiennej $imps$ względem TFP wynosi 0,12%. Nieco mniejsza jest siła wpływu kapitału fizycznego (elastyczność 0,05%) i nakładów na BiR (elastyczność 0,03%). Oddziaływanie transferu technologii i nakładów na BiR jest odroczone w czasie, przy czym długość tego opóźnienia wynosi jeden rok w przypadku zmiennej $imps$, a w przypadku zmiennej $brinw$ – nawet 2 lata. Wysoka wartość oceny parametru autoregresyjnego modelu (6), równa 0,673, świadczy o stabilności łącznej produktywności czynników produkcji w działach.

ZAKOŃCZENIE

Uzyskane wyniki wskazują na duże zróżnicowanie TFP między działami, przy czym nie stwierdzono tendencji do wyrównywania się tych różnic. Wykazano, że istotny wpływ na kształtowanie się TFP wywiera kapitał fizyczny, kapitał ludzki, transfer technologii i nakłady na działalność badawczo-rozwojową.

LITERATURA

- Acharya, R. C., Keller, W. (2007), Technology Transfer through Imports, *NBER-Working Paper* 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* 58, 277–297.
- Ascari, G., Di Cosmo, V. (2004), Determinants of Total Factor Productivity in the Italian Regions, *University of Pavia, Department of Economics, Working Paper # 170 (12-04)*, <http://129.3.20.41/eps/mac/papers/0511/0511009.pdf> (8.03.2009r.).
- Baltagi, B. H. (2008), *Econometric Analysis of Panel Data*, Wiley&Sons, Chichester
- Blundell, R., Bond, S. (1998), Initial Conditions and Moment Restrictions in Dynamic Panel Data Models, *Journal of Econometrics* 87(1), 115–143.
- Cameron, G. (2006), Openness, R&D, and Growth at the Industry Level, str. 137–158, w: Finley, L. A. (ed) *Perspectives on Economic Growth*, Nova Publishers: Hauppauge NY.
- Coe, D., Helpman, E. (1995), International R&D Spillovers, *European Economic Review* 39, 859–887.
- Griffith, R., Redding, S., Van Reen, J. (2003), R&D and Absorptive Capacity: Theory and Empirical Evidence, *Scandinavian Journal of Economics* 105, 99–118.
- Hsiao, C. (2003), *Analysis of Panel Data*, 2nd edn., Cambridge University Press, Cambridge.
- Nickell, S. (1981), Biases in Dynamic Models with Fixed Effects, *Econometrica* 49, 1417–1426.
- Pindyck, R.S., Rubinfeld, D.L. (1991), *Econometric Models and Economic Forecasts*, McGraw-Hills, New York.
- Tokarski, T. (2008), Oszacowanie regionalnych funkcji produkcji, *Wiadomości Statystyczne* 10, 38–53.

Estimating and modeling of TFP in the Polish industry. Panel data analysis

Summary: The paper attempts to estimate total factor productivity (TFP) for sectors included in section „manufacturing”, and then to determine factors influencing it. Two alternative methods, based on the Cobb-Douglas production function were applied. The final step was construction and estimation of dynamic panel data model, describing TFP formation by sector. The explained variable was TFP, which values were estimated in the first step. GMM-based methods were used for estimation of the model.

Keywords: dynamic panel data model, production function, total factor productivity (TFP), system GMM estimator