

Jerzy MARZEC, Andrzej PISULEWSKI, Artur PRĘDKI\*

## Efektywność techniczna i produktywność polskich gospodarstw rolnych specjalizujących się w uprawach polowych<sup>1</sup>

**Streszczenie:** W niniejszym artykule zaprezentowano analizę porównawczą wyników dotyczących efektywności technicznej oraz produktywności polskich gospodarstw rolnych, uzyskanych przy wykorzystaniu stochastycznych modeli granicznych (SFM) oraz nieparametrycznej metody DEA. Zastosowanie alternatywnych podejść dostarcza nowych informacji na temat procesu produkcyjnego oraz wskazuje na konsekwencje stosowania konkretnych metod w analizach produktywności i efektywności. Średnia ocena unormowanego miernika efektywności (TE) dla obiektów i czasu wynosi 0,63 w podejściu SFM, a w ramach DEA jedynie 0,52. Analiza determinant efektywności wskazuje, że wg DEA najsilniej na zróżnicowanie efektywności wpływa powierzchnia użytków rolnych, a wg SFM – niekorzystne warunki gospodarowania. Z kolei przy badaniu procesu produkcji gospodarstw okazuje się, że najsilniejszy wpływ na produkcję upraw polowych mają materiały, a następnie zaangażowanie czynnika pracy (wskazują na to oba wykorzystane podejścia). W odniesieniu do zmian produktywności obie metody wskazują na jej spadek w badanym okresie, jednak z różnych przyczyn. Wyniki uzyskane w ramach SFM wskazują na silny spadek efektywności technicznej niezrekompensowany postępem technicznym. Natomiast w ramach DEA spadek produktywności wynika przede wszystkim z regresu technicznego, przy jednoczesnym wzroście efektywności technicznej.

**Słowa kluczowe:** funkcja produkcji, metoda otoczki danych, stochastyczne modele graniczne

**Kody klasyfikacji JEL:** C23, C51, D24, Q12

\* Uniwersytet Ekonomiczny w Krakowie; e-mail: marzecj@uek.krakow.pl, andrzej.pisulewski@gmail.com, predkia@uek.krakow.pl

<sup>1</sup> Badanie zostało sfinansowane a) ze środków przyznanych Wydziałowi Zarządzania Uniwersytetu Ekonomicznego w Krakowie, w ramach dotacji na utrzymanie potencjału badawczego – dotyczy pierwszego i trzeciego autora), b) ze środków Narodowego Centrum Nauki, przyznanych na podstawie decyzji nr DEC-2013/09/N/HS4/03833 drugiemu autorowi.

---

Artykuł nadesłany 17 grudnia 2018 r., zaakceptowany 17 kwietnia 2019 r.

---

## Wprowadzenie

W ekonomii, zgodnie z koncepcją M. Farrella [1957] wypracowaną na podstawie wcześniejszych, ogólniejszych rozważań V. Pareto, T. Koopmansa i G. Debreua, nieefektywność techniczna występuje, gdy produkcja obserwowana jest niższa od produkcji potencjalnej, czyli maksymalnej, możliwej do osiągnięcia z danych nakładów czynników produkcji. Ta ważna publikacja stała się inspiracją do poszukiwań metod empirycznego pomiaru efektywności jednostek gospodarczych. W końcu lat 70. XX w. wyodrębniły się ostatecznie dwa główne nurty. Pierwszym są parametryczne stochastyczne modele graniczne (*Stochastic Frontier Models – SFM*), natomiast drugim jest nieparametryczna deterministyczna metoda obwiedni danych (*Data Envelopment Analysis – DEA*).

Jak zauważa Coelli [1995], obie metody mają wady i zalety. Wśród zalet podejścia parametrycznego wyróżnia: uwzględnienie działania czynników czysto losowych, możliwość testowania hipotez dotyczących zarówno nieefektywności, jak i charakterystyk procesu produkcji, natomiast wadą tego podejścia jest konieczność przyjęcia ustalonych założeń dotyczących postaci funkcji produkcji oraz rozkładu dla składnika reprezentującego nieefektywność. Z kolei zaletami podejścia nieparametrycznego są brak założeń odnośnie do: technologii produkcji, z wyjątkiem własności wypukłości zbioru produkcyjnego, oraz typu rozkładów dla składnika losowego i nieefektywności. Powoduje to jednak, że zakłócenia czysto losowe są ignorowane, więc każde zróżnicowanie produkcji obserwowanej, przy ustalonych nakładach, jest interpretowane jako nieefektywność techniczna.

Ponadto Coelli [1995] stwierdził, że pomimo, iż metoda parametryczna jest bardziej preferowana dla rolnictwa ze względu na uwzględnienie działania czynników czysto losowych, to metoda DEA również znajduje zastosowanie w analizach tego sektora ze względu na możliwość analizy technologii wieloproduktowych.

Prawdopodobnie pierwszą pracą, w której wykorzystano metodę DEA do analizy wspomnianego sektora, był artykuł Färe i in. [1985]. Wskazanie przez Coelliego na możliwość zastosowania metody DEA do analiz rolnictwa zapoczątkowało analizy porównawcze za pomocą obu metod. Za pierwszą taką pracę z zakresu rolnictwa uważa się Sharmy i in. [1997; 1999], w której dokonano porównania wyników efektywności uzyskanych obiema metodami. Pokazano, że pomimo powszechnej opinii, iż metoda DEA jest bardziej wrażliwa na błędy w danych oraz na obserwacje nietypowe, to w przypadku konkretnego zbioru danych metoda DEA okazała się odporniejsza na te problemy niż metoda parametryczna [Sharmy i in., 1999].

W ekonomii rozważa się pojęcie produktywności, które ma szersze znaczenie niż efektywność. Produktywność jest definiowana jako relacja całko-

witego produktu do całkowitego zużycia nakładów. W przypadku, gdy rozważana jest technologia produkcji, w wyniku której powstaje jeden produkt z jednego nakładu, analiza jest bardzo prosta. W praktyce rozważane są jednak zwykle technologie wielonakładowe i wieloproduktowe. W związku z tym, w pomiarze produktywności wyzwaniem jest odpowiednia agregacja nakładów i efektów (produktów) procesu produkcyjnego. Uzyskany w ten sposób wynik określany jest mianem całkowitej produktywności czynników produkcji (*Total Factor Productivity* – TFP). W literaturze przedmiotu istnieje wiele sposobów wspomnianej agregacji, dokonywanej za pomocą tzw. indeksów produktywności. Wśród nich najczęściej wykorzystywany jest indeks Mälmuquista, który służy do analizy zmian produktywności w czasie (*Total Factor Productivity Change* – TFPC). Następnie można dokonać dekompozycji tego wskaźnika, pokazując, jaka część zmiany produktywności wynika z postępu technicznego (*Technical Change* – TC), zmian efektywności technicznej (*Efficiency Change* – EC) oraz zmian efektu skali (*Scale Change* – SC) [Coelli i in., 2005]. W celu oszacowania indeksu Mälmuquista oraz jego składowych wykorzystuje się głównie SFM i metodę DEA.

Jednym z sektorów gospodarki narodowej, dla którego najczęściej dokonuje się analiz produktywności, jest rolnictwo. Z racji silnego dotowania tego sektora podejmowane analizy mogą dostarczyć praktycznych rekomendacji w kształtowaniu właściwej polityki rolnej, ukierunkowanej na zrównoważone wykorzystanie zasobów naturalnych. Ponadto produktywność jest jednym z czynników decydujących o konkurencyjności danego sektora. W związku z tym sektor polskich gospodarstw rolnych był przedmiotem wielu analiz empirycznych, w szczególności w okresie transformacji gospodarczej. Prace te skupiały się głównie na wskazaniu czynników decydujących o powodzeniu transformacji oraz tych, które blokowały szybsze przejście do gospodarki rynkowej.

Kolejna fala analiz produktywności polskiego rolnictwa nastąpiła w okresie przedakcesyjnym do Unii Europejskiej (UE). Wówczas zainteresowanie skupiało się na odpowiedzi na pytanie, na ile gospodarstwa rolne są w stanie podjąć konkurencję z gospodarstwami ze „starej” UE. Z kolei w okresie poakcesyjnym do UE w analizach produktywności polskiego rolnictwa rozważano, na ile polskie rolnictwo upodabnia się do modelu rolnictwa unijnego.

Należy jednak zauważyć, że większość tych analiz była dokonywana na podstawie danych zagregowanych dla całego rolnictwa (wszystkich działów). Ponadto analizy te dotyczyły porównań międzynarodowych, podczas gdy, jak zauważają Swinnen i Vranken [2010], najpełniejszy obraz oddają badania wykonane na podstawie danych mikroekonomicznych. W związku z tym, celem niniejszej pracy jest ponowna ocena produktywności polskich gospodarstw rolnych, specjalizujących się w uprawach polowych, w pierwszych ośmiu latach członkostwa w Unii Europejskiej. Ponadto w artykule wskazano czynniki, które w największym stopniu wpływają na poziom produktywności. Określono również implikacje teoretyczne i praktyczne stosowania dwóch różnych metod obliczania indeksów produktywności Mälmuquista. W pracy dokonano także wszechstronnej analizy porównawczej wyników uzyskanych

za pomocą alternatywnych metod, tj. SFM i DEA, dla polskich gospodarstw rolnych, specjalizujących się w uprawach polowych.

Podsumowując, niniejsze badania mają charakter analizy porównawczej, w ramach której sprawdzono, w jaki sposób zastosowanie dwóch podstawowych metod badawczych dla ustalonego zbioru danych prowadzi do zgodnych albo rozbieżnych wniosków ekonomicznych o rozważanym zjawisku.

### Przegląd literatury

Jedną z pierwszych prac dotyczących analizy zmian produktywności w czasie w polskim rolnictwie jest opracowanie Macoursa i Swinnena [2000], które dotyczy gospodarstw rolnych, specjalizujących się w uprawach polowych. Wykorzystując rachunek wzrostu (*growth accounting*) oraz dane za lata 1989–1995 autorzy ci wskazali, że w pierwszych latach transformacji ustrojowej w polskich gospodarstwach rolnych, specjalizujących się w uprawach polowych, występował spadek TFP do 1993 r.

W badaniach empirycznych dotyczących produktywności polskiego rolnictwa dominują prace, w których analizowano zmiany TFP dla całego rolnictwa, bez podziału na typy specjalizacji rolniczej. Przykładami takich prac są Rusielik i Świtłyk [2009], Świtłyk [2011], Rusielik [2012] oraz Baran [2014]. We wszystkich wyżej wymienionych pracach ich autorzy wskazywali na wzrost produktywności całkowitej. W szczególności Rusielik i Świtłyk [2009] wskazali na średnioroczny wzrost TFP w polskim rolnictwie rzędu 11,8% w latach 1998–2006. Podobnie Świtłyk [2011] podaje średnioroczny wzrost TFP w latach 1998–2009 na poziomie 9,4%. Również w pracy Rusielika [2012] obliczone indeksy produktywności świadczą o wzroście TFP w latach 2004–2012. Wyniki uzyskane przez Baran [2014] także wskazują na średnioroczny wzrost TFP (około 11%) w latach 2005–2012.

Jak zauważają Swinnen i Vranken [2010], wskaźnikiem, który w pełni odzwierciedla zmiany w produktywności, jest jednak indeks TFP obliczony na podstawie danych mikroekonomicznych (*micro-TFP*). Analizę TFP na podstawie danych mikroekonomicznych prezentuje opracowanie Latruffe i in. [2008]. Autorzy tej pracy, wykorzystując metodę DEA, wykazali spadek produktywności polskiego rolnictwa w latach 1996–2000, który w największym stopniu był spowodowany regresem technicznym.

Z punktu widzenia metodologicznego trudno utrzymać założenie, że gospodarstwa rolne z różnych typów rolniczych dysponują taką samą technologią. W związku z tym właściwszy jest pomiar produktywności względem granicy możliwości produkcyjnych zbudowanej na podstawie obiektów należących do jednej branży. Pracą przedstawiającą wyniki dotyczące produktywności jednostek gospodarczych wybranego typu rolniczego jest artykuł Makieli i in. [2017]. Przedstawione przez autorów rezultaty dla gospodarstw mlecznych w latach 2004–2011 informują o niewielkim wzroście produktywności (średniorocznie o 0,51%). W innych badaniach Marca i Pisulewskiego [2019]

wykazano brak zmian TFP w sektorze upraw polowych w latach 2004–2011. W tej ostatniej pracy zostały zaprezentowane także wyniki dotyczące pomiaru efektywności technicznej.

Obszernym badaniem obejmującym także okres poakcesyjny, w którym analizowano produktywność i efektywność poszczególnych typów rolniczych krajów członkowskich Unii Europejskiej, jest praca Čechury i in. [2014]. Autorzy przedstawili wyniki świadczące o wzroście TFP zarówno w grupie polskich gospodarstw rolnych zajmujących się głównie uprawą zbóż, jak i gospodarstw, w których dominowała produkcja mleka.

W niniejszych badaniach zastosowano dwie metody: DEA i SFM, które silnie ze sobą konkurują w obszarze badań nad efektywnością ekonomiczną. Z raportu bibliometrycznego przygotowanego przez Lampe i Hilgersa [2015] wynika, że od początku rozwoju tej ścieżki badań modele DEA były częściej stosowane niż SFM. W ostatniej dekadzie ta tendencja pogłębiła się, tj. w 2010 r. liczba zastosowań pierwszej metody, prezentowanych na łamach światowych czasopism, była co najmniej pięciokrotnie większa od liczby aplikacji drugiego podejścia. W literaturze przedmiotu można znaleźć artykuły, w których dokonano porównania i analizy wyników pochodzących z obu metod. W przypadku badań dotyczących rolnictwa (upraw polowych, produkcji mleka lub całego sektora) rezultaty te znajdziemy m.in. w pracach Bayarsaihan i Coelli [2003], Odeck [2007], Headey i in. [2010] oraz Rezek i in. [2011].

### **Podejście SFM – translogarytmiczny model funkcji produkcji**

Ekonometryczny pomiar efektywności ekonomicznej dokonywany jest za pomocą stochastycznych modeli granicznych, zaproponowanych przez Aignera i in. [1977] oraz Meeusena i van den Broecka [1977]. Uogólnienie powyższego modelu dla danych przekrojowo-czasowych przedstawili Pitt i Lee [1981, model II], w następującej postaci:

$$y_{jt} = h(\mathbf{x}_{jt}; \beta) + v_{jt} - u_{jt}, \quad (1)$$

gdzie  $y_{jt}$  jest wartością logarytmu zaobserwowanej produkcji  $j$ -tej jednostki gospodarczej w okresie  $t$  ( $j=1, \dots, J$ ;  $t=1, \dots, T$ ),  $\mathbf{x}_{jt}$  to wektor-wiersz zmiennych egzogenicznych (będących logarytmami nakładów czynników produkcji),  $h$  oznacza odpowiednio wyspecyfikowaną dla logarytmu produkcji graniczną funkcję produkcji (najczęściej liniową względem nieznanymi parametrów tworzących wektor  $\beta$ ). Składniki  $v_{jt}$  i  $u_{jt}$  są niezależnymi zmiennymi losowymi, z których pierwszy ma rozkład symetryczny względem zera (tj. rozkład normalny o wartości oczekiwanej równej zero i nieznannej wariancji) i oddaje wpływ zakłóceń losowych. Drugi jest efektem losowym przyjmującym wartości nieujemne, który modeluje bezpośrednio nieobserwowalną nieefektywność. Nieefektywność ta jest rozumiana jako negatywny efekt marnotrawstwa, złego zarządzania procesem produkcji itp. W produkcji roślinnej nieefektywność

mogą wyrażać m.in. błędy w zarządzaniu gospodarstwem, np. wykorzystanie niskiej jakości materiału siewnego, w tym własnego, zebranego w poprzednim roku; niska wydajność maszyn; występowanie czynników ograniczających (brak nawożenia lub brak ochrony przed szkodnikami). Natomiast zmienna losowa  $v_{jt}$  reprezentuje te efekty, które znajdują się poza kontrolą gospodarstwa, takie jak czynniki środowiskowe, warunki pogodowe itp.

Pomiar efektywności ma zawsze charakter względny, tzn. efektywność danego obiektu jest wyznaczana z użyciem funkcji produkcji  $h(\mathbf{x}_{jt}; \boldsymbol{\beta})$ , reprezentującej sytuację pełnej efektywności. Następnie dla tego obiektu dokonuje się pomiaru względnego odchylenia obserwowanej produkcji od produkcji hipotetycznie maksymalnej, przy danych nakładach. Oczywiście parametry funkcji  $h$  są estymowane na podstawie próby (danych o wszystkich obiektach). Miarę efektywności technicznej zorientowaną na produkt dla  $j$ -tego gospodarstwa w okresie  $t$  wyraża formuła  $TE_{jt} = \exp(-u_{jt})$ .

Szczegółowe założenia, dotyczące m.in. składnika  $u_{jt}$ , są podstawą wyodrębnienia różnych typów stochastycznych modeli granicznych. W oryginalnie zaproponowanych przez Aignera i in. [1977] modelach przyjęto rozkłady jednoparametryczne dla  $u_{jt}$ , tj. normalny z parametrem położenia równym zero, a następnie poddany ucięciu w zerze (*half-normal distribution*) oraz wykładniczy (*exponential*). Uogólnienie tych modeli zostało przedstawione w pracy Stevenzona [1980], który zaproponował wykorzystanie rozkładu gamma lub normalnego z niezerowym parametrem położenia (*truncated-normal*), co czyni analizę bardziej zaawansowaną pod względem statystycznym.

Ogólne ramy modelu granicznego postaci (1) umożliwiają różne parametryzacje rozkładu dla nieefektywności. Obszerny przegląd w tym zakresie można znaleźć w pracach Kumbhakar, Lovell [2000], Greene, 2008, Kumbhakar, Tsionas [2011], Parmeter, Kumbhakar [2014]. Zapewniając zmienność nieefektywności w czasie i jednocześnie wykorzystując panelowy charakter danych, Battese i Coelli [1992] zaproponowali następującą specyfikację dla nieefektywności:  $u_{jt} = \exp(-\eta(t-T)) \cdot u_j$ , gdzie tzw. efekt indywidualny ma rozkład ucięty normalny  $u_j \sim N(\mu, \sigma_u^2) \cdot I(u_j > 0)$ , a  $\eta$ ,  $\mu$  i  $\sigma_u^2$  to parametry. Przypadek  $\eta > 0$  ( $\eta < 0$ ) oznacza systematyczny wzrost (spadek) miary efektywności  $TE_{jt}$  w czasie. W niniejszych badaniach zostanie wykorzystany ten model.

W badaniu empirycznym, obejmującym liczną grupę podmiotów gospodarczych, ważną kwestią jest przyjęcie odpowiedniej postaci granicznej funkcji produkcji, tzn. takiej, która jest a) mało restrykcyjna z punktu widzenia charakterystyk opisujących zależność między produktem a nakładami, b) uwzględnia heterogeniczność badanych podmiotów, gdy ich zbiór jest liczny. W literaturze przedmiotu stosuje się powszechnie postać translogarytmiczną, a w niniejszych badaniach przyjęto wersję z dodatkowym trendem:

$$f(\mathbf{x}_{jt}; \boldsymbol{\beta}) = \beta_0 + \sum_{g=1}^G \beta_g^{(t)} x_{jt,g} + \sum_{g=1}^G \sum_{h \neq g}^G \beta_{g,h} x_{jt,g} x_{jt,h} + \beta_{trend} t, \quad (2)$$

$$\beta_g^{(t)} = \beta_g + \beta_{g,trend} \cdot t,$$

gdzie  $x_{jt,g}$  to logarytm nakładu  $g$ -tego czynnika produkcji (dla  $g=1, \dots, G$ ). Postać tej funkcji z wbudowanym trendem została wykorzystana np. w pracach Orea [2002], Coelli i in. [2005], Odeck [2007], Zhu i Lansink [2010], Kellermann i in. [2011], w celu modelowania zmiany parametrów w czasie. Zaletą tej propozycji jest to, że elastyczności i współczynnik efektu skali są zmienne w czasie. Dalsze uogólnienie tej koncepcji można znaleźć np. w pracach Battese i Broca [1997] oraz Koop i in. [1999; 2000]. Uwzględnienie trendu pozwala na rozważanie zmian produktywności wywołanych zmianami wydajności czynników produkcji, które mogą wystąpić w badanym okresie.

Przyjęcie szczegółowego założenia  $\beta_{g,trend} = 0$ , dla  $g=1, \dots, G$  oznacza stałość w czasie elastyczności produkcji względem nakładów. Wówczas inny parametr  $\beta_{trend}$  oddaje tzw. neutralny postęp techniczno-organizacyjny (wg Hicksa). Oznacza to, że właściwa organizacja pracy i produkcji oraz zarządzanie są źródłem wzrostu produktywności, który nie wymaga żadnych zmian ilości nakładów. Wówczas poniesione nakłady czynników produkcji mogą być wykorzystywane bardziej efektywnie, tzn. mogą generować autonomiczny wzrost dotychczasowych efektów.

W ramach modeli SFM miernikiem zmian produktywności całkowitej (TFP) jest iloczyn trzech składowych, danych wzorami (3), (4) i (6). Jest to odpowiednik dekompozycji indeksu Malmquista w metodzie DEA przedstawionej we wzorze (15) [Orea, 2002, Coelli i in., 2005]. Bardziej szczegółową dekompozycję TFP, wraz z przykładem zastosowań dla gospodarstw mlecznych w Polsce, proponują m.in. Makieła i in. [2017].

Indeks zmiany efektywności (*efficiency change – EC*) informuje o względnej zmianie nieefektywności z jednego okresu ( $t$ ) na drugi ( $t+1$ ):

$$EC_{j,t/t+1} = \exp(u_{j,t+1} - u_{j,t}) = TE_{j,t+1} / TE_{j,t} \quad (3)$$

Kolejny czynnik, indeks zmiany technologii (*technical change – TC*), informuje o zmianie (przesunięciu) granicznej funkcji produkcji w czasie. Ma on postać średniej geometrycznej [Coelli i in., 2005: 301]:

$$TC_{j,t/t+1} = \exp \left[ \frac{1}{2} \left( \frac{\partial y_{j,t+1}}{\partial t} + \frac{\partial y_{j,t}}{\partial t} \right) \right], \quad (4)$$

gdzie pochodne cząstkowe (elastyczności produkcji względem czynnika czasu) są określone wzorem:

$$\frac{\partial y_{j,t}}{\partial t} = \beta_{trend} + \sum_{g=1}^G \beta_{g,trend} x_{jt,g}. \quad (5)$$

Ostatni z omawianych w pracy czynników mierzy wpływ na produktywność zmiany wydajności czynników produkcji, wywołanej zmianą skali działalności (wpływ korzyści skali). Indeks zmiany skali (*scale change – SC*) jest zdefiniowany jako ważona średnia geometryczna zmian nakładów w rozważanych okresach [Coelli i in., 2005]:

$$SC_{j,t/t+1} = \exp \left[ \frac{1}{2} \sum_{g=1}^G C_{j,t/t+1,g} (x_{j,t+1,g} - x_{j,t,g}) \right], \quad (6)$$

gdzie

$$C_{j,t/t+1,g} = Elast_{j,t,g} + Elast_{j,t+1,g} - \frac{Elast_{j,t,g}}{RTS_{j,t}} - \frac{Elast_{j,t+1,g}}{RTS_{j,t+1}}. \quad (7)$$

Ponadto element składający się na wagę  $Elast_{j,t,g} = \partial y_{jt} / \partial x_{j,t,g}$  to elastyczność produkcji względem  $g$ -tego czynnika produkcji, a  $RTS_{jt}$  to współczynnik efektu skali, czyli suma tych elastyczności. Punktem odniesienia pomiaru wpływu tego komponentu jest sytuacja stałych korzyści skali, bo wówczas indeks  $SC$  wynosi jeden.

### Podejście DEA – model BCC w postaci multiplikatywnej

W ramach metodyki DEA przegląd alternatywnych podejść do modelowania zależności na podstawie danych przekrojowo-czasowych można znaleźć np. w pracy Cullinane i Wang [2010]. W literaturze przedmiotu zasadniczo wyróżnia się cztery podejścia: równoczesne, międzyokresowe, sekwencyjne i analizę okna.

W podejściu międzyokresowym zakłada się m.in. wspólną technologię dla wszystkich okresów, co jest mało realnym założeniem, uniemożliwiającym np. badanie postępu (bądź regresu) techniczno-organizacyjnego [Lovell, 1996: 336]. Z kolei w podejściu sekwencyjnym, na mocy konstrukcji, wyklucza się możliwość występowania regresu techniczno-organizacyjnego, a dane nie są zbilansowane. W analizie okna problemem jest wyznaczenie jego sensownej, uzasadnionej szerokości. Ponadto ponownie zakłada się występowanie tej samej technologii dla okresów wchodzących w skład danego okna.

W tej sytuacji zdecydowano się na przyjęcie podejścia równoczesnego, tzn. proces produkcji modeluje się osobno dla każdego okresu, za pomocą odpowiednich danych przekrojowych. Można wówczas analizować zarówno zmiany efektywności technicznej, jak i postęp albo regres techniczno-organizacyjny. W przeciwieństwie do podejścia parametrycznego nie narzuca się tu jednak z góry żadnych zależności o charakterze dynamicznym w ramach modelu.

Metoda analizy obwiedni danych (DEA), w kontekście teorii procesu produkcyjnego, polega na konstrukcji nieparametrycznej granicy produkcyjnej wokół punktów danych tak, że wszystkie obserwacje znajdują się na niej lub poniżej, czyli w zbiorze możliwości produkcyjnych. Granica ta ma więc charakter empiryczny i deterministyczny, czyli jest ona jednoznacznie wyznaczona na podstawie danych i jednocześnie jej kształt zależy od przyjętego zbioru danych. Na mocy konstrukcji składa się ona z wielu hiperpłaszczyzn rozpiętych na punktach danych [Prędko, 2012], które odpowiadają obiektom efektywnym technicznie.



Ze względu na porównanie uzyskanych wyników z metodyką alternatywną (SFM) przyjęto orientację na produkty (maksymalizacja produkcji przy danych nakładach) oraz jeden produkt działalności<sup>2</sup>. Metoda DEA posłuży w pracy m.in. do oszacowania efektywności technicznej  $J$  gospodarstw rolnych oraz obliczenia charakterystyk procesu produkcyjnego w punktach danych  $(x_j, y_j)$ ,  $j = 1, \dots, J$ , gdzie  $x_j = [x_{j,1}, \dots, x_{j,G}]$  i  $y_j$  to odpowiednio wektor zaobserwowanych nakładów oraz zaobserwowany produkt  $j$ -tego gospodarstwa<sup>3</sup>.

W ramach DEA, w niniejszych badaniach wykorzystano jedną z wersji modelu BCC w formie multiplikatywnej [Banker, Charnes, Cooper, 1984], zorientowaną na produkty, podobnie zresztą jak w poprzedniej pracy wspólnej autorów [Marzec i in., 2015], dotyczącej gospodarstw mlecznych w Polsce.

$$\begin{aligned}
 & \sum_{g=1}^G x_{j,g} \mu_{j,g} + \omega_j \rightarrow \min \\
 & \sum_{g=1}^G x_{1,g} \mu_{j,g} + \omega_j \geq y_1 \\
 & \dots \\
 & \sum_{g=1}^G x_{j,g} \mu_{j,g} + \omega_j \geq y_j \\
 & \mu_{j,g} \geq 0, \quad \omega_j \in R \quad \text{dla } g = 1, \dots, G \quad (\text{zmiennne decyzyjne})
 \end{aligned} \tag{8}$$

Korzystając z interpretacji zadania dualnego do programu (8), można wykazać, że optymalna wartość funkcji celu tego programu liniowego to produkcja maksymalna przy danych nakładach, określona formułą:

$$f(x_j) = \sum_{g=1}^G x_{j,g} \mu_{j,g}^* + \omega_j^* \tag{9}$$

gdzie gwiazdką oznaczono wartości optymalne zmiennych decyzyjnych zadania (8). Zatem wzór (9) przedstawia postać funkcji produkcji dla danych charakteryzujących  $j$ -te gospodarstwo.

Miernikiem efektywności technicznej  $j$ -tego obiektu jest iloraz produkcji zaobserwowanej i maksymalnej:

$$TE_j = \frac{y_j}{\sum_{g=1}^G x_{j,g} \mu_{j,g}^* + \omega_j^*} \tag{10}$$

<sup>2</sup> W ramach metodyki DEA można analizować również dane wieloproduktowe. W przypadku SFM jest to możliwe, jednak znacząco utrudnione poprzez konieczność określenia analitycznej postaci tzw. transformaty produkcji, będącej wieloproduktowym odpowiednikiem funkcji produkcji.

<sup>3</sup> Przy przyjętym podejściu równoczesnym można opuścić indeks czasu  $t$ , gdyż odpowiednią analizę przeprowadza się dla każdego okresu osobno.

Miara ta jest unormowana i równa jeden dla jednostki gospodarczej efektywnej technicznie<sup>4</sup>.

Obliczenie wartości charakterystyk dla obiektów efektywnych za pomocą tradycyjnego, marginalnego podejścia nie jest możliwe. Jednak dla jednostek nieefektywnych jest to wykonalne, ponieważ funkcja produkcji (9) zachowuje wtedy w otoczeniu wartości zaobserwowanych nakładów niezmienną postać<sup>5</sup>. Szczegółowe rozważania w tym zakresie, pod kątem analizy efektywności ekonomicznej, można znaleźć w pracy Prędkiej [2015].

Ze wzoru (9) wynika, że produktywność krańcowa  $g$ -tego nakładu w danym punkcie  $\mathbf{x}_j$  ma postać:

$$\frac{\partial f(\mathbf{x}_j)}{\partial x_g} = \mu_{j,g}^*, \quad (11)$$

w konsekwencji, elastyczność  $g$ -tego czynnika produkcji i współczynnik efektu skali wyrażają się odpowiednio wzorami:

$$Elast_{j,g} = \frac{x_{j,g} \mu_{j,g}^*}{f(\mathbf{x}_j)}, \quad (12)$$

$$RTS_j = \frac{\sum_{g=1}^G x_{j,g} \mu_{j,g}^*}{f(\mathbf{x}_j)}. \quad (13)$$

Warto zaznaczyć, że zwykle pewien odsetek jednostek gospodarczych charakteryzuje się zerowymi wartościami produktywności i elastyczności, w przypadku występowania nieoptymalnych (nieefektywnych) wielkości nakładów<sup>6</sup> [Marzec i in., 2015: 11].

Ze względu na przekrojowo-czasowy charakter danych oraz to, że zastosowano podejście równoczesne, dla każdego okresu osobno obliczono średnią wartość efektywności technicznej oraz średnie wartości elastyczności poszczególnych czynników produkcji (dla obiektów). Następnie w części empirycznej pracy porównano je z odpowiednimi wartościami średnimi, uzyskanymi za pomocą metodyki alternatywnej. Należy jednak podkreślić, że przy obliczaniu średnich elastyczności dla poszczególnych okresów pominięto obiekty efektywne, dla których nie da się ich wyznaczyć jednoznacznie.

<sup>4</sup> Formalnie, w metodologii DEA do pomiaru efektywności technicznej używa się odwrotności tego miernika. Jednak ze względu na zgodność ze sposobem pomiaru w ramach SFM, autorzy zdecydowali się na przyjęcie takiej jego postaci.

<sup>5</sup> Sytuacja taka wynika z faktu, że wartości optymalne zmiennych decyzyjnych programu (8) są jednoznacznie wyznaczalne jedynie dla obiektów nieefektywnych.

<sup>6</sup> W SFM również występuje taka sytuacja, przy braku narzuconych restrykcji na parametry, lecz wtedy ocena elastyczności względem czynnika produkcji w punkcie danych jest ujemna. W DEA nie ma takiej możliwości, gdyż jednym z założeń, leżących u podstaw metody, jest wklęsłość empirycznej funkcji produkcji.

W ramach metodyki DEA, do pomiaru zmian produktywności całkowitej z okresu  $t$  na  $t+1$  wykorzystano tzw. indeks Mälmqvista dla obiektu  $j$  [Färe i in., 1994: 70]:

$$M_{j,t/t+1} = \sqrt{\frac{TE_{j,t+1}^t}{TE_{j,t}^t} \frac{TE_{j,t+1}^{t+1}}{TE_{j,t}^{t+1}}}, \quad (14)$$

gdzie nakłady i produkt dla  $j$ -tej jednostki gospodarczej w obu tych okresach oznaczono przez  $(x_{j,t}, y_{j,t})$  i  $(x_{j,t+1}, y_{j,t+1})$ .

Miary efektywności technicznej  $TE_{j,t}^t$  i  $TE_{j,t+1}^{t+1}$ , zrealizowanej odpowiednio dla danych z okresu  $t$  i  $t+1$ , można obliczyć ze wzoru (10) i za pomocą modelu (8). Natomiast międzyokresowe miary efektywności technicznej  $TE_{j,t+1}^t$  i  $TE_{j,t}^{t+1}$  uzyskuje się na podobnej zasadzie<sup>7</sup>. Mianowicie dane odnoszące się do obiektu, którego efektywność jest obliczana, pochodzą z innego okresu niż dane jednostek, z którymi jest on porównywany w ramach programu (8).

Wartość omawianego indeksu mniejsza/większa/równa jedności oznacza odpowiednio pogorszenie/polepszenie/brak zmian całkowitej produktywności czynników z okresu  $t$  na  $t+1$ <sup>8</sup>. W empirycznej części pracy nastąpi więc jakościowe porównanie zmian produktywności uzyskanych za pomocą obu, alternatywnych metod.

W literaturze przedmiotu spotyka się wiele różnych sposobów dekompozycji indeksu Mälmqvista, reprezentującego zmiany produktywności w czasie – interesujący przegląd możliwości w tym zakresie można znaleźć w pracy Zofio [2007]. W niniejszym artykule autorzy zdecydowali się wykorzystać dekompozycję zaproponowaną po raz pierwszy w pracy Ray i Desli [1997], która jest najbliższa tej zaproponowanej w ramach metodyki alternatywnej.

Postać omawianej dekompozycji jest następująca:

$$M_{j,t/t+1}^{CRS} = EC_{j,t/t+1} \cdot TC_{j,t/t+1} \cdot SC_{j,t/t+1}, \quad (15)$$

gdzie

$$EC_{j,t/t+1} = \frac{TE_{j,t+1}^{t+1}}{TE_{j,t}^t}, \quad (16)$$

$$TC_{j,t/t+1} = \sqrt{\frac{TE_{j,t+1}^t}{TE_{j,t+1}^{t+1}} \frac{TE_{j,t}^t}{TE_{j,t}^{t+1}}}, \quad (17)$$

$$SC_{j,t/t+1} = \frac{M_{j,t/t+1}^{CRS}}{M_{j,t/t+1}}. \quad (18)$$

<sup>7</sup> Należy zaznaczyć, że miary te nie zawsze istnieją dla wszystkich obiektów objętych analizą.

<sup>8</sup> W literaturze przedmiotu dokonuje się tu jedynie interpretacji jakościowej uzyskanych rezultatów, ze względu na trudności z jednoznaczną interpretacją samej wartości indeksu.

Należy zaznaczyć, że ogólnie znaczenie tych trzech czynników jest analogiczne jak w metodyce SFM; wzór na czynnik  $EC$  jest identyczny (por. wzór 3), a czynnik  $SC$  również wynosi jeden dla stałych korzyści skali.

Wadą przyjętej dekompozycji jest fakt, że dotyczy ona indeksu Mälmqvista  $M_{j,t/t+1}^{CRS}$ , liczonego przy restrykcyjnym założeniu stałych korzyści skali (*Constant Returns to Scale* – CRS). Jego obliczanie przebiega analogicznie jak indeksu  $M_{j,t/t+1}$ , jednak w programie (8) pomija się zmienną  $\omega_j$ . Warto jednak zwrócić uwagę, że w odniesieniu do dwóch pierwszych czynników o kluczowym znaczeniu, założenie to nie obowiązuje, co spowodowało przyjęcie tej właśnie wersji dekompozycji<sup>9</sup>.

Interpretacja wszystkich trzech czynników przebiega analogicznie jak samego indeksu, tzn. ich wartość mniejsza/większa/równa jedności oznacza odpowiednio ich niekorzystny/korzystny/neutralny wpływ na zmiany produktywności w czasie. Ponownie analiza porównawcza będzie tu miała jedynie charakter jakościowy.

Ponadto ze względu na multiplikatywny charakter wybranej dekompozycji wartości średnie poszczególnych czynników oraz samego indeksu Mälmqvista dla obiektów będąc liczone za pomocą średniej geometrycznej. Umożliwi to zachowanie struktury dekompozycji przy uśrednianiu dla czasu, celem określenia zmian całkowitej produktywności czynników w całym analizowanym przedziale czasowym. Należy jednak pamiętać, że w DEA, przy liczeniu średnich w poszczególnych okresach, pominięto nieliczne obiekty, dla których indeks  $M_{j,t/t+1}$  nie istnieje. W przypadku SFM wyżej wymienione charakterystyki można policzyć dla każdego obiektu.

Na koniec warto zaznaczyć, że istnieje tzw. statystyczne podejście w DEA, opisane m.in. w monografii Prędkiego [2015], które umożliwia w szczególności wyznaczenie błędów średnich zarówno ocen efektywności, jak i wartości indeksu Mälmqvista i jego składowych<sup>10</sup>. Jednak własności statystyczne tych ocen są słabe (zgodność, przy występowaniu jedynie składnika losowego modelującego nieefektywność), a w przypadku uwzględnienia symetrycznego składnika losowego praktycznie żadne (tzw. metoda StoNED – *Stochastic Non-Smooth Envelopment of Data*).

## Definicja czynników i pomiar produkcji

Definicja produktu oraz czynników wytwórczych została określona na podstawie literatury, w której wykorzystuje się dane FADN (*Farm Accountancy Data Network*) i proponowane metody (zob. np. Zhu, Lansink [2010], Latruffe i in. [2004]). Na produkcję całkowitą ( $Q$ ) gospodarstw zajmujących się uprawami polowymi składa się przede wszystkim produkcja pochodzenia roślin-

<sup>9</sup> Niestety ze względu na istnienie czynnika  $SC$ , związanego z wpływem korzyści skali na zmiany produktywności, nie jest możliwe wyeliminowanie założenia o stałych korzyściach skali w odniesieniu do wszystkich czynników objętych analizą.

<sup>10</sup> Modele DEA mają tu charakter statystyczny, a nie deterministyczny.

nego oraz ewentualnie pochodzenia zwierzęcego i pozostała. Wyróżniono cztery czynniki produkcji: kapitał rzeczowy (budynki, maszyny, urządzenia i środki transportu,  $K$ ), pracę ( $L$ ), materiały ( $M$ ) i użytki rolne ( $A$ , w hektarach). Praca została określona przez całkowity godzinowy czas pracy w skali roku. Produkcję oraz czynniki  $K$  i  $M$  wyrażono w jednostkowych cenach stałych z 2004 r. Szczegółową definicję produktu i czynników zaprezentowali Marzec i Pisulewski [2019], natomiast opis zastosowanych indeksów Marzec i Pisulewski [2015].

Zbiór danych pochodzących z bazy FADN obejmował 660 gospodarstw rolnych i dotyczył lat 2004–2011. W tabeli 1 przedstawiono syntetyczny opis charakterystyk rozkładu empirycznego dla poszczególnych zmiennych występujących w funkcji produkcji. Przeciętny rolnik uprawia 43 ha ziemi, jego roczna produkcja (bez dotacji) to prawie 122 tys. PLN, co wskazuje, że wydajność kapitału wynosi około 0,53 PLN z jednej jego złotówki, a wydajność pracy to ponad 30 PLN na godzinę. Materiały do produkcji rolnej stanowią zaś około 69% wielkości uzyskanej produkcji.

**Tabela 1. Charakterystyki opisowe danych z lat 2004–2011**

| Zmienna*               | Średnia** | Kwantyle rozkładu empirycznego |       |       |
|------------------------|-----------|--------------------------------|-------|-------|
|                        |           | 25                             | 50    | 75    |
| Produkt (w tys. PLN)   | 122       | 63                             | 118   | 233   |
| Kapitał (w tys. PLN)   | 232       | 124                            | 232   | 431   |
| Praca (w godz.)        | 4 056     | 2 900                          | 3 938 | 5 214 |
| Materiały (w tys. PLN) | 84        | 42                             | 78    | 150   |
| Areał (w ha)           | 43        | 21                             | 40    | 83    |

\* Wielkości w PLN zostały wyrażone w cenach z 2004 r.

\*\* Wartość średnia to średnia geometryczna, tj. średnia arytmetyczna dla logarytmu zmiennej w próbie, która następnie została poddana transformacji odwrotnej.

Źródło: opracowanie własne oraz Marzec i Pisulewski [2019].

## Pomiar efektywności technicznej

Parametry mikroekonomicznej funkcji produkcji danej wzorem (2) przy różnych założeniach dotyczących nieefektywności zostały uzyskane metodą największej wiarygodności, a szczegółowe wyniki zostały zaprezentowane w pracy Marzec i Pisulewski [2019]. Na podstawie dokonanego tam porównania najlepszy okazał się model Battese i Coelli [1992], gdzie nieefektywność jest zmienną losową o rozkładzie normalnym uciętym, której wartość oczekiwana i wariancja zmieniają się w czasie. W związku z tym w niniejszych badaniach wykorzystano wyniki uzyskane dla tego właśnie modelu.

Średnie oceny mierników efektywności technicznej dla gospodarstw w poszczególnych latach zaprezentowano w tabeli 2. W badanym okresie zaobserwowano, że średnia wartość (ocena) wskaźnika efektywności technicznej

(*TE*) dla gospodarstw jest zawsze mniejsza w przypadku wyników uzyskanych za pomocą metodyki DEA. Przekłada się to na średnią wartość tego wskaźnika dla obiektów i czasu, która wynosi 0,63 w podejściu SFM, a w ramach DEA jedynie 0,52. Wynika to z różnic metodycznych, a konkretnie z faktu, że w ramach SFM uwzględnia się również błędy czysto losowe, a nie tylko nieefektywność, jak w przypadku DEA. Warto podkreślić, że dla wykorzystanych danych, dotyczących upraw polowych, wyniki uzyskane w ramach DEA były niewrażliwe na wartości odstające. Przy prezentacji syntetycznych informacji nie zachodziła zatem konieczność wykorzystania mediany zamiast średniej z próby (por. wyniki dla gospodarstw mlecznych w artykule Marzec i in. [2015]).

Średnia efektywność techniczna w SFM maleje wraz z upływem czasu, co wynika po części z faktu, że rozważa się model dla danych panelowych i dodatkowo dopuszcza się w założeniach modelowych występowanie odpowiednich trendów czasowych dla efektywności (w tym przypadku jest to trend malejący, bo ocena parametru  $\eta$  jest ujemna). Natomiast zmiany w czasie średnich ocen *TE*, uzyskane za pomocą DEA, nie wykazują żadnej tendencji w czasie. Jest to z kolei po części spowodowane przyjęciem podejścia równoczesnego do analizy danych panelowych w ramach DEA (niezależne obliczenie wartości miar efektywności w poszczególnych okresach).

**Tabela 2.** Średnie oceny miar efektywności technicznej i współczynniki korelacji liniowej Pearsona oraz rang Spearmana – porównanie obu metod

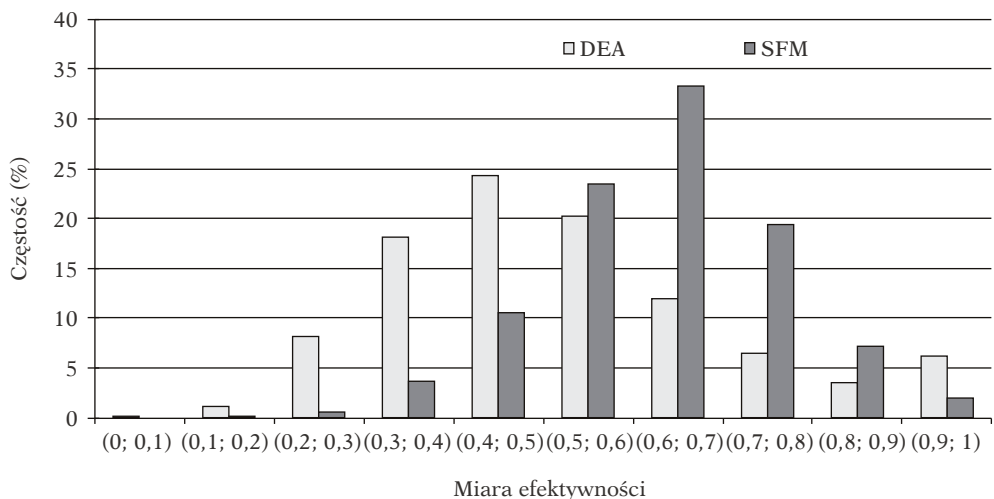
| –<br>Okres | Średnie oceny miar efektywności ( <i>TE</i> ) |      | Współczynniki korelacji |         |
|------------|---|------|-------------------------|---------|
|            | SFM   | DEA  | Oceny <i>TE</i>         | Ranking |
| 2004       | 0,67  | 0,53 | 0,47                    | 0,50    |
| 2005       | 0,66  | 0,56 | 0,51                    | 0,52    |
| 2006       | 0,65  | 0,56 | 0,60                    | 0,62    |
| 2007       | 0,64  | 0,56 | 0,55                    | 0,57    |
| 2008       | 0,63  | 0,51 | 0,59                    | 0,62    |
| 2009       | 0,62  | 0,48 | 0,61                    | 0,66    |
| 2010       | 0,60  | 0,44 | 0,50                    | 0,57    |
| 2011       | 0,59  | 0,55 | 0,54                    | 0,59    |
| Średnia    | 0,63  | 0,52 | –                       | –       |

Źródło: obliczenia własne oraz Marzec i Pisulewski [2019].

Co więcej, histogramy rozkładów empirycznych miernika *TE* uzyskane w ramach obu podejść, a przedstawione na rysunku 1, wskazują, że również wspomniane rozkłady różnią się znacząco od siebie. Aby to formalnie potwierdzić, wykonano dwa standardowe testy statystyczne zgodności rozkładów empirycznych, tj. test Andersona-Darlinga (A-D) oraz test chi-kwadrat Pearsona. Wartość statystyki testowej A-D wynosi 3,19, co wskazuje na odrzucenie hipotezy o podobieństwie obu rozkładów na poziomie istotności 0,05. Jesz-

cze mocniejszy wniosek o tej samej treści uzyskano na podstawie drugiego testu, opartego na porównaniu częstości zdarzeń wynikających z rozkładu badanego z częstością pochodzącą z rozkładu referencyjnego. Wartość statystyki chi-kwadrat Pearsona o 9 stopniach swobody wynosi aż 582, więc hipoteza zerowa o zgodności obu rozkładów empirycznych jest odrzucana przy niższym niż wcześniej empirycznym poziomie istotności (*p-value*). Należy zaznaczyć, że sposób konstrukcji obu rozkładów dyskretnych nie miał wpływu na te zgodne konkluzje.

**Rysunek 1. Histogramy rozkładów empirycznych ocen miary efektywności technicznej gospodarstw uzyskane w ramach obu metod (łącznie okres 2004–2011)**



Źródło: obliczenia własne.

W celu dalszego porównania wyników w tabeli 2 zaprezentowano dodatkowo współczynniki korelacji Pearsona i Spearmana, odpowiednio dla ocen efektywności i rankingów gospodarstw pochodzących z obu metod, obliczone dla każdego roku osobno. W tym przypadku, z uwagi na sposób konstruowania rang oraz małą frakcję (4,3%) gospodarstw z identycznym miejscem w rankingu (wg DEA), współczynnik korelacji Spearmana dla rang, podobnie jak współczynnik korelacji Pearsona, mierzy siłę i kierunek zależności liniowej. Z przeprowadzonej analizy wynika, że występuje bardzo istotna korelacja dodatnia (empiryczne poziomy istotności są numerycznie bliskie zeru), zarówno dla ocen *TE*, jak i rankingów gospodarstw ze względu na wartości *TE*. Oceny współczynników korelacji są jednak dalekie od jedności, co oznacza, że zbieżność wyników pochodzących z rozważanych podejść nie jest zbyt silna. Naturalnie korelacje dla rankingów są wyższe od korelacji dla ocen, które były podstawą do ich stworzenia. Jednak te różnice nie są duże w porównaniu np. z gospodarstwami mlecznymi, analizowanymi w pracy Marzec i in. [2015].

## Ekonomiczny opis procesu produkcji gospodarstw

Mikroekonomiczne charakterystyki technik wytwórczych badanych gospodarstw zostały określone przez elastyczności produkcji względem czterech czynników produkcji oraz przez wartość współczynnika efektu skali. W przypadku DEA pominięto gospodarstwa efektywne technicznie, dla których – z przyczyn metodologicznych – nie da się wyznaczyć jednoznacznie wartości elastyczności. Wyniki uśrednione dla gospodarstw, które otrzymano za pomocą obu metod, przedstawiono w tabelach 3 i 4.

Widoczne jest pewne podobieństwo rezultatów uzyskanych w ramach obu podejść – zarówno ranking wydajności czynników produkcji jest taki sam, jak i typ oraz wartość efektu skali. Kapitał ma bardzo niewielki (w SFM) lub mały (w DEA) wpływ na produkcję gospodarstw w badanym okresie (mierzony wartościami odpowiedniej elastyczności). Na produkcję upraw polowych najsilniejszy wpływ mają materiały, a następnie zaangażowanie czynnika pracy.

Generalnie w przypadku zastosowania DEA oceny elastyczności i współczynnika efektu skali charakteryzują się silnym zróżnicowaniem, dużo większym niż w SFM. Jest to konsekwencją tego, że w tym podejściu parametry modelu były kalibrowane dla każdego okresu osobno, czyli przy założeniu, że dla ustalonego gospodarstwa charakter zależności między produkcją a czynnikami wytwórczymi nie jest powiązany w czasie. Innymi słowy, w każdym okresie granica technologiczna jest konstruowana niezależnie. Ponadto, w ramach SFM pojawił się problem ujemnych elastyczności względem kapitału. Jednocześnie czynnik ten dla wielu gospodarstw okazał się jednak nieistotny statystycznie, więc wynik ten należy traktować z dużą ostrożnością. Przykładowo, w przypadku typowego gospodarstwa (o nakładach równych średnim geometrycznym z próby), elastyczność względem kapitału wynosi  $-0,001$  z błędem szacunku  $\pm 0,01$ , co wskazuje na brak statystycznej roli tego czynnika produkcji na empirycznym poziomie istotności nie większym niż  $0,94$ . W ogólności funkcja translogarytmiczna nie narzuca globalnych restrykcji na znaki charakterystyk procesu produkcji, bo jest aproksymacją lokalną nieznaną funkcji produkcji, co tłumaczy tę sytuację. Na etapie estymacji *a priori* nie narzucono restrykcji monotoniczności funkcji produkcji dla każdej obserwacji, gdyż przeczyłoby to idei tzw. giętkich form funkcyjnych (*flexible functional forms*), której przykładem jest translog. Z kolei w DEA część elastyczności przyjmuje wartość zerową dla wielu gospodarstw, co związane jest z nieefektywną ilością zużywanych nakładów [Marzec i in., 2015]. Zatem DEA tłumaczy nieistotność elastyczności względem kapitału jako efekt nadmiernego zaangażowania (nieadekwatnego wykorzystania) tego czynnika. Jeżeli nakład kapitału jest za duży w stosunku do produkcji obserwowanej, to niewielkie jego zmiany *in plus* albo *in minus* nie zwiększają produkcji, analogicznie jak w przypadku technologii Leontiefa.

Obie metody zgodnie wskazują, że w badanym okresie większość gospodarstw specjalizujących się w uprawach polowych charakteryzuje się rosna-



cymi efektami skali. Średnia wartość współczynnika efektu skali wynosi około 1,19 i 1,16 odpowiednio w DEA i SFM.

**Tabela 3. Średnie elastyczności produkcji i efektu skali w badanych okresach w SFM**

| –       | Elastyczności |       |           |       | –           |
|---------|---------------|-------|-----------|-------|-------------|
| Okres   | Kapitał       | Praca | Materiały | Areał | Efekt skali |
| 2004    | 0,036         | 0,277 | 0,648     | 0,197 | 1,158       |
| 2005    | 0,026         | 0,279 | 0,653     | 0,202 | 1,160       |
| 2006    | 0,015         | 0,276 | 0,666     | 0,201 | 1,158       |
| 2007    | 0,006         | 0,273 | 0,672     | 0,204 | 1,156       |
| 2008    | -0,006        | 0,269 | 0,683     | 0,209 | 1,155       |
| 2009    | -0,020        | 0,269 | 0,695     | 0,212 | 1,156       |
| 2010    | -0,029        | 0,273 | 0,702     | 0,211 | 1,157       |
| 2011    | -0,040        | 0,269 | 0,714     | 0,212 | 1,154       |
| Średnia | -0,001        | 0,273 | 0,679     | 0,206 | 1,157       |

Źródło: Marzec i Pisulewski [2019].

**Tabela 4. Średnie elastyczności produkcji i efektu skali w badanych okresach w DEA**

| –       | Elastyczności |       |           |       | –           |
|---------|---------------|-------|-----------|-------|-------------|
| Okres   | Kapitał       | Praca | Materiały | Areał | Efekt skali |
| 2004    | 0,144         | 0,347 | 0,410     | 0,208 | 1,109       |
| 2005    | 0,114         | 0,311 | 0,687     | 0,086 | 1,198       |
| 2006    | 0,070         | 0,374 | 0,565     | 0,108 | 1,117       |
| 2007    | 0,167         | 0,254 | 0,685     | 0,098 | 1,205       |
| 2008    | 0,039         | 0,298 | 0,792     | 0,077 | 1,206       |
| 2009    | 0,074         | 0,370 | 0,671     | 0,167 | 1,280       |
| 2010    | 0,068         | 0,205 | 0,835     | 0,110 | 1,218       |
| 2011    | 0,108         | 0,180 | 0,654     | 0,234 | 1,176       |
| Średnia | 0,098         | 0,292 | 0,662     | 0,136 | 1,189       |

Źródło: obliczenia własne.

### Identyfikacja determinant efektywności technicznej

W analizach dotyczących efektywności ekonomicznej ważną kwestią jest identyfikacja źródeł nieefektywności w tym zakresie. Mowa tu o czynnikach swoistych, oddających szczególne cechy gospodarstw i decyzji przez nie podejmowanych.

Z punktu widzenia metodyki użytej w pracy można to zrobić na dwa sposoby. W prostszym (dwuetapowym) podejściu, po estymacji granicznej funkcji produkcji, niezawierającej potencjalnych determinant efektywności,

buduje się model przyczynowo-skutkowy, w którym zmiennymi niezależnymi są owe determinanty, a zmienną zależną są oceny miary efektywności (lub ich transformacja) [Kumbhakar, Lovell, 2000: 263, Coelli i in., 2005]. W drugim podejściu (jednoetapowym), które jest bardziej zaawansowane i właściwe z punktu widzenia logiki wnioskowania statystycznego, wspomniane determinanty wprowadza się na etapie konstrukcji rozkładu prawdopodobieństwa dla nieefektywności – (zob. np. Battese i Coelli [1995], Caudill i in. [1995], Koop i in. [1997], Wang i Schmidt [2002]). Ten drugi sposób możliwy jest jednak do zastosowania tylko w ramach SFM, gdzie nieefektywność jest zmienną losową. W DEA stosuje się podejście dwustopniowe. W związku z tym, w celu porównania wyników otrzymanych za pomocą alternatywnych metod zastosowano pierwsze podejście. Ten sam sposób analizy wpływu czynników egzogenicznych na efektywność wykorzystują m.in.: Sharma i in. [1999], Wadud i White [2000], Iráizoz i in. [2003], Odeck [2007], Kellermann i in. [2011].

Kolejną kwestią wymagającą rozwiązania jest sposób budowy modelu regresji dla ocen miary efektywności, które charakteryzują gospodarstwa w badanym okresie ośmiu lat. W ramach stochastycznego modelu granicznego powinna to być regresja panelowa, bo efektywność jest szacowana łącznie dla całego okresu. Natomiast w ramach metody DEA efektywność szacowana jest dla każdego okresu osobno, więc możliwe jest skonstruowanie regresji ze względu na te determinanty zarówno dla każdego okresu osobno, jak i dla danych przekrojowo-czasowych. Ta ostatnia możliwość jest o tyle wskazana, że nie można wykluczyć, iż charakter wpływu tych czynników na nieefektywność w DEA ma charakter przestrzenno-czasowy.

Ostatecznie zdecydowano się wykorzystać model regresji panelowej, wspólny dla obu podejść, następującej postaci:

$$g(r_{jt}) = \alpha_j + \lambda_t + \sum_{h=1}^H \delta_h w_{jt,h} + \xi_{jt}, \quad (19)$$

gdzie  $r_{jt}$  to ocena  $TE_{jt}$ ,  $g$  to znana funkcja transformacji,  $w_{jt,h}$  to determinanty nieefektywności (dla  $h=1, \dots, H$ ), parametry oznaczone przez  $\delta_h$ ,  $\xi_{jt}$  to zwykły składnik losowy, a efektami indywidualnymi i czasowymi są odpowiednio  $\alpha_j$  i  $\lambda_t$  dla  $j=1, \dots, 660$ ,  $t=1, \dots, 8$ . Wprowadzenie efektu czasowego wynika z faktu, że w obu podejściach nieefektywność była zmienna w czasie. Oba efekty mają zatem charakter zmiennych kontrolnych. Ponadto wyniki przeprowadzonego testu Hausmana zdecydowanie wskazują na model o efektach ustalonych.

Wybór postaci  $g(r_{jt})$ , w standardowym przypadku, czyli zwykłej regresji dla danych panelowych, sprowadza się do przyjęcia  $g(r_{jt}) = r_{jt}$ . W rozważanej sytuacji taka postać transformacji zmiennej zależnej jest jednak wykluczona ze względu na unormowanie wskaźników  $TE$ . Ponadto z uwagi na fakt, że w DEA  $r_{jt}$  przyjmują wartości z przedziału domkniętego prawostronnie  $(0; 1]$ , nie można zastosować transformacji logistycznej  $g(r_{jt}) = \ln(r_{jt}/(1-r_{jt}))$ , która jest możliwa do zastosowania w SFM.

Należy zaznaczyć, że z samej natury DEA wynika, iż w każdym okresie analizy występuje frakcja obiektów efektywnych, dla których odpowiedni miernik jest równy jedności. Oznacza to, że co do zasady powinno się stosować w takiej sytuacji pewien model regresji cenzurowanej, a najbardziej powszechny jest tu model tobitowy. Z kolei w ramach SFM nie ma potrzeby stosowania tego typu modeli ze względu na fakt, że wartości skrajne miary efektywności nie są w praktyce osiąmane.

Jednak w okresie objętym analizą odsetek jednostek, dla których oceny efektywności wg DEA są równe jeden, wynosi średnio zaledwie 4,3% (z niewielkim odchyleniem od średniej w poszczególnych podokresach). W takiej sytuacji wyniki estymacji regresji tobitowej (dla danych panelowych z losowymi efektami) najprawdopodobniej sprowadziłyby się do tych uzyskanych w ramach zwykłego modelu regresji panelowej, określonego równaniem (19).

Ostatecznie więc dla obu podejść przyjęto, że  $g(r_{jt}) = \ln(r_{jt})$  w modelu (19). Przyjęcie różnych definicji zmiennej zależnej zrodziłoby problem metodyczny, która z nich jest tą właściwą, czyli bardziej adekwatną do opisu badanych zależności. Należy jednak zaznaczyć, że powyższa transformacja logarytmiczna jest pewnym kompromisem, godzącym różnice metodyczne, ale również nie jest pozbawiona wad<sup>11</sup>. W związku z tym na końcu tego podrozdziału przeprowadzono analizę wrażliwości uzyskanych rezultatów na wybór postaci funkcji  $g$ .

Wyróżniono siedem potencjalnych determinant zróżnicowania efektywności, wyrażonych w formie zmiennych zero-jedynkowych, co pozwoliło na stworzenie grup jednostek. Podział ten uwzględniał: specjalizację (1 – gospodarstwo ma przychody przede wszystkim z produkcji rolnej, 0 – w przeciwnym razie), informacje o tym, czy gospodarstwo działa w niekorzystnych warunkach gospodarowania (1 – tak, 0 – nie), czy angażuje tylko pracę własną, czyli bez najmu obcej (tak/nie), czy wykorzystuje tylko ziemię własną (bez dzierżawy obcej) oraz czy otrzymuje dopłaty do inwestycji. Wyróżniono też podział gospodarstw na duże (1) i małe (0), określony w dwojaki sposób: poprzez wielkość ekonomiczną oraz powierzchnię użytków rolnych. Zastosowanie zmiennych zero-jedynkowych oznacza utratę części informacji, ale jednocześnie umożliwia zbudowanie rankingu determinant ze względu na siłę ich oddziaływania na efektywność gospodarstw.

Syntetyczne wyniki dotyczące determinant efektywności zaprezentowano w tabeli 5. Dla wybranych determinant progowa wartość empirycznego poziomu istotności była niższa niż 0,05, z wyjątkiem zmiennej „tylko praca własna” w SFM, dla której wyniosła trochę więcej, tj. 0,08. Efekty czasowe i indywidualne okazały się składnikami statystycznie istotnymi ( $p$ -value było

<sup>11</sup> Przykładowo, zbiór wartości wybranej transformacji miernika efektywności to przedział  $(-\infty, 0)$  lub  $(-\infty, 0]$  odpowiednio dla SFM i DEA, a więc niezbyt nadający się do modelowania za pomocą składnika losowego o nośniku  $(-\infty, \infty)$ . Ponadto, w przypadku DEA, w dalszym ciągu pozostaje w każdym podokresie frakcja obiektów, gdzie ocena  $\ln(r_{jt})$  wynosi zero, czyli problem, czy należy korzystać z jakiejś postaci regresji cenzurowanej, nadal pozostaje.

równe praktycznie zero), co jest zgodne z założeniem, które przyjęto, definiując nieefektywność.

Oba podejścia zgodnie wskazują, że podział gospodarstw ze względu na to, czy wykorzystują one tylko ziemię własną, nie ma wpływu na zróżnicowanie efektywności. Ponadto gospodarstwa o dużej wielkości użytków rolnych lub o braku silnej specjalizacji w uprawach polowych mają wyższą efektywność od tych należących do przeciwnych grup. Według SFM niższą efektywność wykazują gospodarstwa o niekorzystnych warunkach gospodarowania lub wykorzystujących tylko pracę własną. Natomiast wg DEA duże gospodarstwa (mierzone wielkością ekonomiczną) są bardziej efektywne od małych. Obie metody różnią się też odmienną identyfikacją kierunku wpływu dopłat do inwestycji oraz co do rankingu oddziaływania rozważanych determinant. Przykładowo, wg DEA najsilniej na zróżnicowanie efektywności wpływa powierzchnia użytków rolnych, a wg SFM – niekorzystne warunki gospodarowania.

**Tabela 5. Wpływ typu gospodarstw na oceny efektywności  $ln(r_{it})$  – porównanie obu metod**

| –<br>Zmienna                  | SFM             |         | DEA             |         |
|-------------------------------|-----------------|---------|-----------------|---------|
|                               | Kierunek wpływu | Ranking | Kierunek wpływu | Ranking |
| Specjalizacja                 | Negatywny       | 2       | Negatywny       | 4       |
| Niekorzystne warunki          | Negatywny       | 1       | Brak            | –       |
| Dopłaty do inwestycji         | Pozytywny       | 3       | Negatywny       | 2       |
| Duża wielkość ekonomiczna     | Brak            | –       | Pozytywny       | 3       |
| Duża wielkość użytków rolnych | Pozytywny       | 4       | Pozytywny       | 1       |
| Tylko praca własna            | Negatywny       | 5       | Brak            | –       |
| Tylko ziemia własna           | Brak            | –       | Brak            | –       |

Źródło: obliczenia własne.

Dopasowanie oszacowanego modelu (19) do danych było dużo lepsze w przypadku SFM niż DEA – współczynnik determinacji  $R^2$  dla estymatora wewnątrzgrupowego przyjął odpowiednio wartość 0,84 i 0,14. Wynika to m.in. z tego, że w tym drugim podejściu jest wiele jednostek posiadających pełną efektywność, przy zróżnicowanych wartościach nakładów. Dodatkowo warto wspomnieć, że wartości bezwzględne ocen parametrów  $\delta_{it}$  w równaniu (19) były wielokrotnie wyższe w DEA niż SFM. Jednocześnie oceny efektów indywidualnych ( $\alpha_i$ ) były bardzo zróżnicowane w DEA. Można to interpretować w ten sposób, że oceny dla  $TE$  w relacji do determinant były bardziej zróżnicowane w DEA niż w SFM.

Zbadano również odporność uzyskanych wyników na wybór formy transformacji  $g(r_{it})$ . Jeżeli zmienną objaśnianą w równaniu (19) jest  $r_{it}$ , to w ramach obu podejść otrzymuje się jakościowo praktycznie te same rezultaty (dot. kierunku wpływu i rankingu). Zastosowano też transformację logistyczną. Wówczas dla SFM także uzyskano rezultaty zbliżone jakościowo do tych przedstawionych w tabeli 5. W przypadku DEA, o czym wspomniano wcześniej,

pominięto obserwacje, dla których  $r_{jt} = 1$ . Wówczas otrzymano wyniki zgodne z tymi dla  $\ln(r_{jt})$  z zastrzeżeniem, że specjalizacja okazała się nieistotna (empiryczny poziom istotności równy 0,14) i ranking determinant był trochę inny. Reasumując, silne i faktyczne zależności między rozważanymi kategoriami oraz duża liczba obserwacji implikują uzyskanie tych samych konkluzji jakościowych w ramach różnych modeli (ze względu na definicję zmiennej objaśnianej).

### Pomiar i dekompozycja zmian produktywności łącznej w czasie

Niniejsze badania obejmują działalność gospodarstw w ciągu ośmiu lat. W związku z tym istotna jest również kwestia produktywności całkowitej, która może zmieniać się wraz z absorpcją dopłat bezpośrednich otrzymywanych przez rolników w ramach wspólnej polityki rolnej i postępem procesu dostosowania się polskiego rolnictwa do warunków jego funkcjonowania w państwach starej UE. W tabelach 6 i 7 zaprezentowano dekompozycję *TFP*, w formie średnich geometrycznych wartości odpowiednich wskaźników dla gospodarstw. W uśrednieniu tym nie uwzględniono wag różnicujących obiekty, które można by skonstruować, np. na podstawie udziału wartości produkcji gospodarstw w produkcji łącznej.

Tabela 6. Dekompozycja *TFP* w ramach SFM

| Okresy    | Zmiana efektywności (EC)* | Zmiana technologii (TC) | Zmiana skali produkcji (SC) | TFP   |
|-----------|---------------------------|-------------------------|-----------------------------|-------|
| 2004/2005 | -1,76                     | 1,64                    | 0,06                        | -0,09 |
| 2005/2006 | -1,83                     | 1,67                    | 0,27                        | 0,08  |
| 2006/2007 | -1,91                     | 1,74                    | 0,18                        | -0,02 |
| 2007/2008 | -1,99                     | 1,78                    | 0,01                        | -0,23 |
| 2008/2009 | -2,07                     | 1,77                    | 0,00                        | -0,34 |
| 2009/2010 | -2,16                     | 1,76                    | 0,39                        | -0,05 |
| 2010/2011 | -2,25                     | 1,81                    | 0,12                        | -0,37 |
| Średnia   | -1,99                     | 1,74                    | 0,15                        | -0,14 |

\* Indeksy sprowadzone do zmian względnych (wyrażonych w %)

Źródło: obliczenia własne, zob. też Marzec i Pisulewski [2019].

Model wykorzystany w ramach SFM wskazuje, że zmiany produktywności łącznej w rozważanych ośmiu latach są raczej negatywne lub nie występują. Wyniki cząstkowe dla kolejnych lat wykazują zbliżone wartości, oscylujące wokół zera. Natomiast DEA wskazuje na większe zróżnicowanie zmian produktywności, od -9,03% do +9,3%, ale średnioroczne tempo wynosi zaledwie -0,43%, wobec -0,14% według SFM. Zatem w tym zakresie oba podejścia są jakościowo zgodne.

Tabela 7. Dekompozycja *TFP* w ramach DEA

| Okresy    | Zmiana efektywności<br>( <i>EC</i> ) * | Zmiana technologii<br>( <i>TC</i> ) | Zmiana skali<br>produkcji ( <i>SC</i> ) | <i>TFP</i> |
|-----------|--|-------------------------------------|---|------------|
| 2004/2005 | 7,60                                   | -13,97                              | -0,35                                   | -7,76      |
| 2005/2006 | -0,92                                  | 1,88                                | 0,07                                    | 1,01       |
| 2006/2007 | 0,54                                   | 8,74                                | 0,16                                    | 9,50       |
| 2007/2008 | -9,48                                  | 1,09                                | -0,59                                   | -9,03      |
| 2008/2009 | -7,25                                  | 10,22                               | -0,38                                   | 1,84       |
| 2009/2010 | -10,06                                 | 19,55                               | 0,35                                    | 7,91       |
| 2010/2011 | 28,57                                  | -25,56                              | -0,57                                   | -4,84      |
| Średnia   | 0,57                                   | -0,81                               | -0,19                                   | -0,43      |

\* Indeksy sprowadzone do zmian względnych (wyrażonych w %)

Źródło: obliczenia własne.

Bardziej interesującą kwestią jest jednak analiza źródeł tych zmian. W tym zakresie oba podejścia dają rozbieżne rezultaty. W ramach SFM uzyskano zgodne wyniki w całym analizowanym okresie, które wskazują na spadek efektywności gospodarowania (*EC*), średnio o 1,99%, a towarzyszą mu systematyczne, pozytywne zmiany rzędu 1,74%, wywołane usprawnieniem technologii produkcji (*TC*), np. postępem techniczno-organizacyjnym. Malejące wartości składnika *EC* wynikają z ujemnego znaku oceny parametru  $\eta$ . *EC*. Drugim elementem, który także neutralizuje obniżkę efektywności, ale w mniejszym stopniu, jest zmiana skali produkcji (*SC*). Korzyści z tego płynące są średnio rzędu 0,15% rocznie. Negatywne zmiany efektywności technicznej mogą częściowo wynikać z wpływu dopłat otrzymywanych przez gospodarstwa w ramach wspólnej polityki rolnej. Negatywny wpływ tych dopłat na poziom efektywności technicznej został wykazany m.in. w pracach Zhu i Lansinka [2010] oraz Marca i Pisulewskiego [2017].

W przypadku DEA łączna siła wpływu zmian efektywności i technologii na całkowitą produktywność (mierzona w skali ośmiu lat) jest mniejsza niż w przypadku SFM, a jej kierunek przeciwny. Uśrednione efekty *EC* i *TC* wynoszą odpowiednio 0,57% i -0,81%. Podobnie kierunek wpływu efektu *SC* jest przeciwny niż w SFM, lecz jego siła wpływu na produktywność łączną nieco większa niż ta wynikająca z metody alternatywnej. Należy jednak zaznaczyć, że czynnik ten ma najsłabszy wpływ na produktywność i pod tym kątem wyniki z obu metod są zgodne.

W przeciwieństwie do SFM w ramach DEA nie ma widocznych tendencji zmian omawianych efektów w czasie. Widoczną jest za to silna fluktuacja w czasie indeksów *EC* i *TC*, tzn. przyjmują one skrajnie odmienne wartości, szczególnie w latach 2009–2011. Takie duże wahania międzyokresowe są charakterystyczne dla tej metody. Wynika to z tego, że jak już wspomniano, mikroekonomiczna funkcja produkcji jest kalibrowana osobno dla każdego okresu, inaczej niż w SFM. W tym ostatnim podejściu zmiany w czasie składników produktywności łącznej są opisywane z pomocą zależności funkcyjnych

(funkcji co najmniej ciągłych), więc ich oceny na podstawie danych są wygładzone i nie podlegają aż tak dużym fluktuacjom w czasie (por. rzędy wielkości w odpowiednich kolumnach tabel 6 i 7).

Z praktycznego punktu widzenia słabością rozważań dotyczących *TFP* jest ich prezentacja, w formie wyników zagregowanych, uśrednionych po wszystkich gospodarstwach. Uśrednianie powoduje utratę informacji, gdy badane gospodarstwa są zróżnicowane ze względu na pewne jakościowe decyzje dotyczące organizacji procesu produkcji.

Przyjęte metody dopuszczają, aby każde gospodarstwo było charakteryzowane przez indywidualne mierniki, które zostały zaprezentowane wcześniej. W tym kontekście szczególnie interesującym zagadnieniem jest identyfikacja grup gospodarstw, które znacząco różnią się między sobą ze względu na dekompozycję *TFP*. Kluczem do tworzenia tych grup mogą być charakterystyki wykorzystane we wcześniej przeprowadzonych badaniach zależności między miarą efektywności a jej determinantami [Marzec i Pisulewski, 2019].

**Tabela 8. Dekompozycja *TFP* dla grup gospodarstw w podziale ze względu na nakład pracy**

| Okresy    | Wielkość nakładu pracy (w tys. godzin) |           |           |           |       |        |
|-----------|--|-----------|-----------|-----------|-------|--------|
|           | 0 < L < 3                              | 0 < L < 3 | 3 ≤ L < 6 | 3 ≤ L < 6 | L ≥ 6 | L ≥ 6  |
|           | SFM                                    | DEA       | SFM       | DEA       | SFM   | DEA    |
| 2004/2005 | -0,20*                                 | -11,75    | -0,31     | -6,10     | 0,85  | -6,39  |
| 2005/2006 | -0,14                                  | 0,07      | 0,22      | 0,57      | -0,01 | 3,54   |
| 2006/2007 | -0,05                                  | 13,13     | -0,03     | 10,05     | 0,02  | 4,98   |
| 2007/2008 | -0,61                                  | -9,36     | -0,33     | -9,84     | 0,62  | -6,85  |
| 2008/2009 | -0,65                                  | -3,21     | -0,48     | 1,50      | 0,60  | 9,04   |
| 2009/2010 | -0,22                                  | 7,76      | 0,01      | 10,42     | 0,07  | 3,32   |
| 2010/2011 | -0,89                                  | 2,48      | -0,28     | -4,46     | 0,16  | -14,04 |
| Średnia   | -0,39                                  | -0,46     | -0,17     | 0,05      | 0,33  | -1,22  |

\* Indeksy sprowadzone do zmian względnych (wyrażonych w %)

Źródło: obliczenia własne.

Jednym z ważnych czynników różnicujących jest podział gospodarstw ze względu na wielkość nakładu pracy (tabela 8). W przypadku SFM gospodarstwa o niewielkim zatrudnieniu (liczba przepracowanych roboczogodzin mniejsza niż 3 tys. rocznie) charakteryzują się ciągłym spadkiem *TFP*, łącznie o 0,39% w skali ośmiu lat. Gospodarstwa o średnim zatrudnieniu cechują się wartościami *TFP* oscylującymi wokół zera w ramach tej metody. Natomiast największe gospodarstwa (o nakładach pracy w wysokości co najmniej 6 tys. godzin rocznie) wykazują relatywnie wzrost *TFP*, średnio o 0,33% rocznie w badanym okresie. Wyniki uzyskane w ramach DEA nie są spójne z tymi otrzymanymi w ramach SFM. Są one bardzo zróżnicowane w czasie i trudno jest zauważyć występowanie określonych tendencji, jak w przypadku SFM. W większości podokresów rezultaty są jednak dość zróżnicowane ze względu

na wielkość gospodarstwa i w tym sensie potwierdzono wnioski o ważności wpływu tego czynnika na zmiany *TFP*.

W pracy Marzec i Pisulewski [2019], w której zastosowano wyłącznie metodykę SFM, przedstawiono dekompozycję *TFP* dla grup gospodarstw, w podziale ze względu na ich wielkość, która mierzona była na dwa różne sposoby. Wyróżniono podział ze względu na wielkość ekonomiczną (wartość przychodów) oraz powierzchnię użytków rolnych. Wnioski z tych badań były takie same – małe jednostki charakteryzują się negatywnym *TFP*, duże zaś dodatnim.

Innymi czynnikami, tworzącymi odmienne grupy jednostek ze względu na *TFP*, okazały się: dopłaty do obszarów o niekorzystnych warunkach oraz fakt, czy gospodarstwo korzysta z ziemi dzierżawionej lub pracy obcej (tabele 9–11). W pierwszej kolejności omówiono wyniki uzyskane za pomocą metody SFM. Brak wzrostu produktywności łącznej występuje w sytuacji, gdy rolnicy nie korzystają z tej formy dopłat. Natomiast w przeciwnym przypadku pojawia się ujemna zmiana produktywności w każdym z okresów – jej średni spadek to 0,54%. Analogiczne wnioski otrzymano dla drugiego podziału, opartego na informacji o dzierżawie ziemi. Zbliżony wynik uzyskano również dla trzeciego podziału gospodarstw. Produkcja rolna prowadzona wyłącznie z użyciem pracy własnej charakteryzuje się ujemnymi zmianami produktywności we wszystkich okresach (średni jej spadek to 0,41%), natomiast ta wspierana pracą obcą wykazuje niewielkie dodatnie zmiany, określone średnioroczną stopą wzrostu 0,11%.

**Tabela 9. Dekompozycja *TFP* dla grup gospodarstw, w podziale ze względu na dopłaty do obszarów o niekorzystnych warunkach**

| –         | Czy były dopłaty do obszarów o niekorzystnych warunkach? |       |       |        |
|-----------|--|-------|-------|--------|
|           | Nie  | Nie   | Tak   | Tak    |
| Okresy    | SFM  | DEA   | SFM   | DEA    |
| 2004/2005 | -0,07*   | -7,55 | -0,93 | -14,40 |
| 2005/2006 | 0,24   | 2,19  | -0,28 | -1,87  |
| 2006/2007 | 0,06   | 9,34  | -0,20 | 10,91  |
| 2007/2008 | -0,11  | -8,81 | -0,51 | -10,03 |
| 2008/2009 | -0,05  | 1,72  | -0,87 | 1,26   |
| 2009/2010 | 0,21   | 7,83  | -0,55 | 9,77   |
| 2010/2011 | -0,33  | -3,17 | -0,43 | -7,29  |
| Średnia   | -0,01  | 0,01  | -0,54 | -2,07  |

\* Indeksy sprowadzone do zmian względnych (wyrażonych w %)

Źródło: obliczenia własne.

Wyniki uzyskane za pomocą DEA potwierdzają powyższe wnioski, w odniesieniu do średniego wpływu w całym analizowanym okresie, a nawet je wzmacniają, ponieważ pokazują znacznie większe różnice między średniookresowymi wartościami *TFP* w podziale gospodarstw ze względu na te trzy czynniki.



W pracy zaprezentowano oceny punktowe dla *TFP* i jego składowych, które nie zostały uzupełnione średnimi błędami estymacji. Te ostatnie pozwoliłyby na weryfikację hipotez, czy otrzymane oceny są istotnie różne od zera, a w szczególności, czy różnice między *TFP* dla dwóch grup jednostek są statystycznie istotne. Wymaga to dalszych pogłębionych badań, w tym wykorzystania stochastycznych wersji metody DEA.

**Tabela 10. Dekompozycja *TFP* dla grup gospodarstw, w podziale ze względu na użytkowanie tylko ziemi własnej albo nie (dodatkowa dzierżawa ziemi)**

| –         | Ziemia własna i obca | Ziemia własna i obca | Tylko ziemia własna | Tylko ziemia własna |
|-----------|----------------------|----------------------|---------------------|---------------------|
| Okresy    | SFM                  | DEA                  | SFM                 | DEA                 |
| 2004/2005 | -0,09*               | -8,29                | -0,08               | -6,43               |
| 2005/2006 | 0,28                 | 0,59                 | -0,35               | 1,85                |
| 2006/2007 | 0,15                 | 12,43                | -0,41               | 4,16                |
| 2007/2008 | -0,01                | -9,77                | -0,75               | -7,67               |
| 2008/2009 | -0,12                | 0,92                 | -0,89               | 3,27                |
| 2009/2010 | -0,08                | 9,24                 | 0,05                | 6,39                |
| 2010/2011 | -0,14                | -4,05                | -0,97               | -5,95               |
| Średnia   | 0,00                 | -0,15                | -0,49               | -0,77               |

\* Indeksy sprowadzone do zmian względnych (wyrażonych w %)

Źródło: obliczenia własne.

**Tabela 11. Dekompozycja *TFP* dla grup gospodarstw w podziale ze względu na charakter nakładu pracy**

| –         | Praca własna i obca | Praca własna i obca | Tylko praca własna | Tylko praca własna |
|-----------|---------------------|---------------------|--------------------|--------------------|
| Okresy    | SFM                 | DEA                 | SFM                | DEA                |
| 2004/2005 | 0,28*               | -5,30               | -0,47              | -10,14             |
| 2005/2006 | 0,06                | 2,44                | 0,11               | -0,56              |
| 2006/2007 | 0,21                | 7,40                | -0,26              | 12,41              |
| 2007/2008 | 0,25                | -9,78               | -0,77              | -8,43              |
| 2008/2009 | -0,02               | 6,33                | -0,65              | -3,11              |
| 2009/2010 | 0,11                | 6,96                | -0,20              | 9,97               |
| 2010/2011 | -0,11               | -8,07               | -0,60              | -1,29              |
| Średnia   | 0,11                | -0,25               | -0,41              | -0,47              |

\* Indeksy sprowadzone do zmian względnych (wyrażonych w %)

Źródło: obliczenia własne.

## Podsumowanie

W wyniku przeprowadzonej analizy stwierdzono, że ranking gospodarstw rolnych specjalizujących się w uprawach polowych ze względu na poziom efektywności technicznej, ustalony w ramach obu podejść, okazał się w znacznym stopniu podobny. Zbieżność rezultatów nie dotyczy jednak poziomów efektywności obiektów. Ranking siły wpływu poszczególnych czynników na produkcję również jest podobny w ramach obu podejść. Jednak siła wpływu w przypadku czynników najważniejszych, tj. materiałów i zwierząt, jest różna. Kwestia znaczenia i wpływu użytków rolnych jest dyskusyjna i wymaga dalszych badań o charakterze zarówno metodycznym, jak i empirycznym. Technologia gospodarstw rolnych specjalizujących się w uprawach polowych charakteryzuje się w większości przypadków rosnącymi efektami skali, o czym zgodnie informują oba podejścia.

W wyniku przeprowadzonej analizy produktywności gospodarstw rolnych należy po pierwsze zauważyć, że wyniki z obu metod wskazują na spadek produktywności w pierwszych ośmiu latach członkostwa Polski w UE. Inne są jednak czynniki wpływające na ten efekt. W wyniku dekompozycji produktywności za pomocą metod parametrycznych stwierdzono, że spadek ten jest głównie spowodowany spadkiem efektywności technicznej. Natomiast wyniki uzyskane w ramach podejścia nieparametrycznego wskazują, że to regres techniczny wywołuje spadek produktywności. Wpływ zmian skali produkcji jest odmienny w obu podejściach. Rezultaty otrzymane w ramach SFM wskazują na wzrost produktywności w wyniku zmian skali produkcji, natomiast w ramach DEA stwierdzono, że zmiany skali produkcji przyczyniają się do spadku produktywności.

Pogłębiona analiza zmian produktywności gospodarstw rolnych wskazuje, że zarówno w ramach SFM, jak i DEA gospodarstwa otrzymujące dopłaty do obszarów o niekorzystnych warunkach gospodarowania charakteryzują się większym spadkiem produktywności całkowitej niż gospodarstwa, które takich dopłat nie otrzymywały.

Kolejnym kryterium podziału gospodarstw była forma użytkowania ziemi. Gospodarstwa, które korzystały jedynie z ziemi własnej, charakteryzowały się silniejszym spadkiem *TFP* niż gospodarstwa dodatkowo korzystające z ziemi dzierżawionej. Wynik ten jest potwierdzony w ramach obu podejść.

Ostatnim analizowanym kryterium było wykorzystanie pracy najemnej przez gospodarstwa. Wyniki otrzymane w ramach SFM wskazują na wyższy wzrost produktywności wśród gospodarstw rolnych wykorzystujących zarówno pracę własną, jak i najemną. W ramach DEA stwierdzono spadek produktywności zarówno wśród gospodarstw rolnych wykorzystujących tylko pracę własną, jak i tych wykorzystujących oba typy pracy. Spadek produktywności był jednak silniejszy wśród gospodarstw wykorzystujących jedynie pracę własną. Reasumując, powyższe wyniki wskazują, że zidentyfikowano charakterystyki gospodarstw wynikające z przyjętych przez nie strategii, a które stanowią barierę dla ich rozwoju.

Niniejsze badania pokazały także, że mimo swych naturalnych ograniczeń, metoda DEA dostarcza w wielu aspektach bardzo podobne do SFM wyniki dotyczące upraw polowych. W analizie produktywności i efektywności technicznej tego typu rolniczego, ze względu na występowanie czynników losowych, przydatna okazuje się SFM. Jednak z drugiej strony, szczególnie w przypadku rozważania technologii wieloproduktowej, również zastosowanie DEA przynosi wymierne korzyści.

## Bibliografia

- Aigner D., Lovell C.A.K., Schmidt P. [1977], Formulation and estimation of stochastic frontier production function models, *Journal of Econometrics*, vol. 6, no. 1: 21–37.
- Banker R., Charnes A., Cooper W. [1984], Some Models for Estimating Technical and Scale Inefficiencies in DEA, *Management Science*, vol. 30, no. 9: 1078–1091.
- Baran J. [2014], Changes in the Productivity of Agriculture After Polish Accession to the European Union, *Acta Scientiarum Polonorum – Oeconomia*, vol. 13, no. 3: 5–15.
- Battese G.E., Coelli T.J. [1992], Frontier Production Functions, Technical Efficiency and Panel Data: With Application to Paddy Farmers in India, *Journal of Productivity Analysis*, vol. 3, no. 1–2: 153–169.
- Battese G.E., Broca S.S. [1997], Functional Forms of Stochastic Frontier Production Functions and Models for Technical Inefficiency Effects: A Comparative Study for Wheat Farmers in Pakistan, *Journal of Productivity Analysis*, vol. 8, no. 4: 395–414.
- Battese G.E., Coelli T. [1995], A Model for Technical Inefficiency Effects in a Stochastic Frontier Production Function for Panel Data, *Empirical Economics*, vol. 20, no. 2: 325–332.
- Bayarsaihan T., Coelli T. [2003], Productivity Growth in pre-1990 Mongolian Agriculture: Spiralling Disaster or Emerging Success?, *Agricultural Economics*, vol. 28: 121–137.
- Caudill S.B., Ford J.M., Gropper D.M. [1995], Frontier Estimation and Firm Specific Inefficiency Measures in the Presence of Heteroscedasticity, *Journal of Business and Economic Statistics*, vol. 13, no. 1: 105–111.
- Čechura L., Grau A., Hockmann H., Kroupova Z., Levkovich I. [2014], Total Factor Productivity in European Agricultural Production, *International Comparison of Product Supply Chains in the Agri-Food Sector: Determinants of their Competitiveness and Performance on EU and International Markets*, Compete Working Paper no. 9, Halle.
- Coelli T.J., [1995], Recent Developments in Frontier Modelling and Efficiency Measurement, *Australian Journal of Agricultural Economics*, vol. 39, no. 3: 219–245.
- Coelli T.J., Rao D.S.P., O'Donnell C.J., Battese G.E. [2005], *An Introduction to Efficiency and Productivity Analysis*, Springer, New York.
- Cullinane K., Wang T. [2010], The Efficiency Analysis of Container Port Production Using DEA Panel Data Approaches, *OR Spectrum*, vol. 32, no. 3: 717–738.
- Färe R., Grabowski R., Grosskopf S. [1985], Technical Efficiency of Philippine Agriculture, *Applied Economics*, vol. 17, no. 2: 205–214.
- Färe R., Grosskopf S., Norris M., Zhang Z. [1994], Productivity Growth, Technical Progress, and Efficiency Change in Industrialized Countries, *American Economic Review*, vol. 84, no. 1: 66–83.

- Farrell M. [1957], The Measurement of Productive Efficiency, *Journal of the Royal Statistical Society, Seria A*, vol. 120, no. 3: 253–281.
- Greene W.H. [2008], The Econometric Approach to Efficiency Analysis, w: Fried H.O., Lovell C.A.K., Shelton S.S. (red.): *The Measurement of Productivity Efficiency and Productivity Growth*, Oxford University Press, Oxford: 92–250.
- Headey D., Alauddin M., Rao D.P. [2010], Explaining Agricultural Productivity Growth: An International Perspective, *Agricultural Economics*, vol. 41: 1–14.
- Iráizoz B., Rapún M., Zabaleta I. [2003], Assessing the Technical Efficiency of Horticultural Production in Navarra, Spain, *Agricultural Systems*, vol. 78, no. 3: 387–403.
- Kellermann M., Salhofer K., Wintzer W., Stockinger C. [2011], Der Zusammenhang zwischen technischer Effizienz und wirtschaftlichem Erfolg: eine Analyse für bayerische Milchviehbetriebe, *German Journal of Agricultural Economics*, vol. 60, no. 4: 230–242.
- Koop G., Osiewalski J., Steel M.F.J. [1997], Bayesian Efficiency Analysis Through Individual Effects: Hospital Cost Frontiers, *Journal of Econometrics*, vol. 76, no. 1–2: 77–105.
- Koop G., Osiewalski J., Steel M.F.J. [1999], The Components of Output Growth: A Stochastic Frontier Analysis, *Oxford Bulletin of Economics and Statistics*, vol. 61, no. 4: 455–487.
- Koop G., Osiewalski J., Steel M.F.J. [2000], A Stochastic Frontier Analysis of Output Level and Growth in Poland and Western Economies, *Economics of Planning*, vol. 33, no. 3: 185–202.
- Kumbhakar S.C., Lovell C.A.K. [2000], *Stochastic Frontier Analysis*, Cambridge University Press.
- Kumbhakar S.C., Tsionas E.G. [2011], Some Recent Developments in Efficiency Measurement in Stochastic Frontier Models, *Journal of Probability and Statistics*, Article ID 603512: 1–25.
- Lampe H.W., Hilgers D. [2015], Trajectories of Efficiency Measurement: A Bibliometric Analysis of DEA and SFA, *European Journal of Operational Research*, vol. 240, no. 1: 1–21.
- Latruffe L., Balcombe K., Davidova S., Zawalińska K. [2004], Determinants of Technical Efficiency of Crop and Livestock Farms in Poland, *Applied Economics*, vol. 36, no. 12: 1255–1262.
- Latruffe L., Davidova S., Balcombe K. [2008], Productivity Change in Polish Agriculture: An Illustration of Bootstrapping Procedure Applied to Malmquist Indices, *Post-Communist Economies*, vol. 20, no. 4: 449–460.
- Lovell C.A.K. [1996], Applying Efficiency Measurement Techniques to the Measurement of Productivity Change, *The Journal of Productivity Analysis*, vol. 7, no. 2–3: 329–340.
- Macours K., Swinnen J.F.M. [2000], Causes of Output Decline in Economic Transition: The Case of Central and Eastern European Agriculture, *Journal of Comparative Economics*, vol. 28, no. 1: 172–206.
- Makieła K., Marzec J., Pisulewski A. [2017], Productivity Change Analysis in Dairy Farms Following Polish Accession to the EU – An Output Growth Decomposition Approach, *Outlook on Agriculture*, vol. 46, no. 4: 295–301.
- Marzec J., Pisulewski A. [2015], Analiza działalności ekonomicznej gospodarstw mlecznych w Polsce – wyniki uzyskane na podstawie krótkookresowej funkcji kosztu, w: *Roczniki Kolegium Analiz Ekonomicznych*, M. Bernardelli, B. Witkowski (red.), Oficyna Wydawnicza SGH, Warszawa, z. 39: 167–181.
- Marzec J., Pisulewski A. [2019], The Measurement of Time-Varying Technical Efficiency and Productivity Change of Polish Crop Farms, *German Journal of Agricultural Economics*, vol. 68, no. 1: 15–27.

- Marzec J., Pisulewski A., Prędko A. [2015], Efektywność techniczna gospodarstw mlecznych w Polsce – analiza porównawcza za pomocą DEA i BSFA, *Metody Ilościowe w Badaniach Ekonomicznych*, SGGW, Warszawa, t. 16, nr 4: 7–23.
- Meeusen W., van den Broeck J. [1977], Efficiency Estimation from Cobb-Douglas Production Functions with Composed Error, *International Economic Review*, vol. 18, no. 2: 435–444.
- Odeck J. [2007], Measuring Technical Efficiency and Productivity Growth: A Comparison of SFA and DEA on Norwegian Grain Production Data, *Applied Economics*, vol. 39, no. 20: 2617–2630.
- Orea L. [2002], Parametric Decomposition of a Generalized Malmquist Productivity Index, *Journal of Productivity Analysis*, vol. 18, no. 1: 5–22.
- Parmeter C.F., Kumbhakar S. C [2014], Efficiency Analysis: A Primer on Recent Advances, *Foundations and Trends® in Econometrics*, vol. 7, no. 3–4: 191–385.
- Pitt M., Lee L. [1981], Measurement of Sources of Technical Inefficiency in the Indonesian Weaving Industry. *Journal of Development Economics*, vol. 9, no. 1: 43–64.
- Prędko A. [2012], Geneza zbiorów możliwości produkcyjnych wykorzystywanych w DEA, *Zeszyty Naukowe Uniwersytetu Ekonomicznego w Poznaniu*, nr 241: 126–137.
- Prędko A. [2015], Analiza kosztowa polskich bibliotek publicznych za pomocą metody DEA oraz porównanie z wynikami uzyskanymi przy użyciu stochastycznej granicznej funkcji kosztu, *Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu*, nr 386: 276–296.
- Ray S.C., Desli E. [1997], Productivity Growth, Technical Progress, and Efficiency Change in Industrialized Countries: Comment, *The American Economic Review*, vol. 87, no. 5: 1033–1039.
- Rezek J.P., Campbell R.C., Rogers K.E. [2011], Assessing Total Factor Productivity Growth in Sub-Saharan African Agriculture, *Journal of Agricultural Economics*, vol. 62: 357–374.
- Rusielik R. [2012], Zmiany produktywności rolnictwa Polski po wstąpieniu do Unii Europejskiej – analiza z wykorzystaniem indeksów TFP Hicksa-Moorsteena, *Roczniki Naukowe Stowarzyszenia Ekonomistów Rolnictwa i Agrobiznesu*, t. 16, nr 4: 246–252.
- Rusielik R., Świtłyk M. [2009], Zmiany efektywności technicznej rolnictwa w Polsce w latach 1998–2006, *Roczniki Nauk Rolniczych*, Seria G, t. 96, nr 3: 20–27.
- Sharma K.R., Leung P., Zaleski H.M. [1997], Productive Efficiency of the Swine Industry in Hawaii: Stochastic Frontier vs. Data Envelopment Analysis, *Journal of Productivity Analysis*, vol. 8, no. 4: 447–459.
- Sharma K.R., Leung P., Zaleski H.M. [1999], Technical, Allocative and Economic Efficiencies in Swine Production in Hawaii: A Comparison of Parametric and Nonparametric Approaches, *Agricultural Economics*, vol. 20, no. 1: 23–35.
- Stevenson R.E. [1980], Likelihood Functions for Generalized Stochastic Frontier Estimation, *Journal of Econometrics*, vol. 13, no. 1: 57–66.
- Swinnen J.F.M., Vranken L. [2010], Reforms and Agricultural Productivity in Central and Eastern Europe and the Former Soviet Republics: 1989–2005, *Journal of Productivity Analysis*, vol. 33, no. 3: 241–258.
- Świtłyk M. [2011], Efektywność polskiego rolnictwa w latach 1998–2009, *Zagadnienia Ekonomiki Rolnej*, vol. 329, no. 4: 59–75.
- Wadud A., White B. [2000], Farm Household Efficiency in Bangladesh: A Comparison of Stochastic Frontier and DEA Methods, *Applied Economics*, vol. 32, no. 13: 1665–1673.

- Wang H.J., Schmidt P. [2002], One-Step and Two-Step Estimation of the Effects of Exogenous Variables on Technical Efficiency Levels, *Journal of Productivity Analysis*, vol. 18, no. 2: 129–144.
- Zhu X., Lansink A.O. [2010], Impact of CAP Subsidies on Technical Efficiency of Crop Farms in Germany, the Netherlands and Sweden, *Journal of Agricultural Economics*, vol. 61, no. 3: 545–564.
- Zofio J. [2007], Malmquist Productivity Index Decompositions: A Unifying Framework, *Applied Economics*, vol. 39, no. 16–18: 2371–2387.

## Technical Efficiency and Productivity Growth of Polish Crop Farms

**Abstract:** The study offers data on the technical efficiency (TE) and productivity growth of Polish crop farms. The data was obtained using Stochastic Frontier Models (SFM) and Data Envelopment Analysis (DEA).

The application of these alternative approaches makes it possible to provide new information about production processes and indicates the consequences of using each method in efficiency and productivity analysis.

The average TE scores obtained from SFM and DEA are 0.63 and 0.52 respectively. An analysis of exogenous factors affecting efficiency revealed that the size of agricultural area utilised has the strongest impact on efficiency in the DEA, while subsidies for less favoured areas have the strongest impact on efficiency in the SFM. In both methods, production elasticity with respect to materials was the highest, followed by elasticity with respect to labour. Moreover, both approaches indicate a productivity decline in the analysed period, though the causes of the decrease are different. The results obtained from SFM indicate that the TFP decline is attributed mainly to a decrease in technical efficiency not compensated by strong technical progress and small but positive scale growth. The opposite result was obtained using DEA, which indicates that the TFP decline was mainly caused by technical regress accompanied by small but positive scale growth.

**Keywords:** Data Envelopment Analysis, production function, Stochastic Frontier Models

**JEL classification codes:** C23, C51, D24, Q12

---

Article submitted Decemebr 17, 2018, accepted for publication April 17, 2019.

---

