

Jerzy MARZEC*

 0000-0001-8576-1850

Andrzej PISULEWSKI**

 0000-0003-3937-4125

Pomiar efektywności zróżnicowanych technologicznie gospodarstw rolnych w Unii Europejskiej¹

Streszczenie: Celem niniejszego opracowania jest określenie charakterystyk procesu produkcyjnego gospodarstw rolnych specjalizujących się w uprawach polowych w państwach członkowskich Unii Europejskiej. W pracy wykorzystano dane regionalne FADN. W związku z występującym zróżnicowaniem między regionami w pracy wykorzystano modele uwzględniające tę heterogeniczność. W szczególności rozważono dwa sposoby modelowania heterogeniczności: deterministyczny oraz stochastyczny. Odzwierciedleniem pierwszego sposobu jest wykorzystanie w niniejszej pracy modelu funkcji produkcji typu translog, który pozwala, żeby elastyczności produkcji względem nakładów czynników produkcji zależały od wielkości nakładów. Natomiast stochastyczny sposób modelowania heterogeniczności reprezentuje stochastyczny model graniczny z losowymi parametrami. Zastosowanie powyższej koncepcji pozwoliło na zbudowanie modelu funkcji produkcji typu Cobba i Douglasa (C–D) z indywidualnymi parametrami. Estymacji parametrów czterech modeli dokonano za pomocą podejścia bayesowskiego. Otrzymane wyniki jednoznacznie wskazują, że najlepszym modelem okazał się model C–D z indywidualnymi parametrami. Ponadto zaobserwowano, że dla średniej unijnej najwyższa elastyczność produkcji występuje względem nakładów materiałów, a najniższa względem areалу. Natomiast dosyć

* Uniwersytet Ekonomiczny w Krakowie, Polska, e-mail: marzecj@uek.krakow.pl

** Uniwersytet Ekonomiczny w Krakowie, Polska, e-mail: andrzej.pisulewski@uek.krakow.pl

¹ Publikacja została sfinansowana ze środków subwencji przyznanej Uniwersytetowi Ekonomicznemu w Krakowie.

zaskakującym wynikiem jest wysoki poziom średniej efektywności technicznej (0,95) przy bardzo niewielkim rozproszeniu tych ocen.

Słowa kluczowe: funkcja produkcji, stochastyczne modele graniczne, podejście bayesowskie, porównania międzynarodowe, model z losowymi parametrami

Kody klasyfikacji JEL: C23, C51, D24, Q12

Artykuł złożony 7 stycznia 2020 r., w wersji poprawionej nadesłany 2 marca 2020 r.,
zaakceptowany 16 lipca 2020 r.

Measuring the Efficiency of European Union Farms under Heterogeneous Technologies

Abstract: The aim of the present study was to derive the characteristics of the production process for crop farms in the European Union member states. The paper uses regional data on farms taken from the Farm Accountancy Data Network (FADN). Therefore, the models that account for heterogeneity among the analysed regions, were used in the present study. In particular, the paper considers two approaches to modelling heterogeneity: deterministic and stochastic. The deterministic approach is reflected in the paper with the usage of translog production function model, which allows output elasticities to depend on the input levels. The stochastic approach is represented by a stochastic frontier model with random coefficients. The application of the above-mentioned concept allowed to derive the Cobb-Douglas (C–D) production function model with individual parameters. The parameters of the four models were estimated using the Bayesian approach. The obtained results indicate that the C–D model is the best. In addition, it was observed that for the EU average, the highest production elasticity is with respect to materials, while the lowest w.r.t area. Surprisingly, the results suggest a high mean technical efficiency of the analysed regions (0.95), with very small dispersion of these scores.

Keywords: production function, Stochastic Frontier Models, Bayesian approach, international comparison, random coefficients model

JEL classification codes: C23, C51, D24, Q12

Article submitted January 7, 2020, revision received March 2, 2020,
accepted for publication July 16, 2020.

Wprowadzenie

Na gruncie mikroekonomicznej teorii producenta proces produkcyjny jest zdefiniowany jako przetwarzanie nakładów czynników produkcji w produkty. Z kolei planem produkcyjnym jest taka kombinacja nakładów tych czynników i wielkości produkcji, która jest technologicznie osiągalna. Zbiór wszystkich planów produkcyjnych nazywany jest zbiorem możliwości produkcyjnych. W konsekwencji przez technologię rozumie się takie plany produkcyjne, które są fizycznie (technicznie) wykonalne [Varian, 2010]. Griliches [1987] ujął ten termin w formie: “the currently known ways of converting resources into outputs desired by the economy”. Gdy rozważa się technologię, w wyniku której

powstaje jeden produkt, to wówczas brzeg tego zbioru (zbiór efektywnych planów produkcyjnych) można opisać przez funkcję produkcji. W związku z tym, funkcja ta wyraża maksymalną wielkość produkcji możliwą do uzyskania z ustalonych nakładów czynników produkcji [Varian, 2010]. Jednym z głównych założeń w neoklasycznej teorii mikroekonomicznej jest to, że wszystkie jednostki gospodarcze (*decision making units*) wytwarzają wielkość produkcji wynikającą z funkcji produkcji, a zatem są w pełni efektywne technicznie. Jednak w rzeczywistości gospodarczej to założenie rzadko można uznać za spełnione. Jako pierwszy koncepcję pomiaru efektywności technicznej i ekonomicznej zaproponował Farrell [1957]. Dalszy rozwój metodyki empirycznego pomiaru nieefektywności technicznej doprowadził do sformułowania stochastycznych modeli granicznych przez Aignera i in. [1977] oraz Meeusena i van den Broecka [1977]. W ramach tych modeli dokonuje się estymacji parametrów technologii (reprezentowanej przez funkcję produkcji), jednocześnie uwzględniając wpływ czynników czysto losowych i nieefektywności. Zakłada się, że badane jednostki gospodarcze dysponują taką samą technologią (lub przynajmniej mają do niej swobodny dostęp). W takim przypadku przedsiębiorstwa te różnią się tylko ze względu na nieefektywność. W praktyce może jednak występować zróżnicowanie (heterogeniczność) technologii wykorzystywanych przez te przedsiębiorstwa.

Tsionas [2002] zauważa, że często utrzymuje się w mocy założenie o dostępie do jednej technologii, podczas gdy w praktyce przedsiębiorstwa wykorzystują różne techniki wytwórcze. Jednak gdy to założenie nie jest spełnione, to wówczas następuje nakładanie na siebie dwóch różnych efektów, tj. zróżnicowania technologicznego i różnej efektywności w wykorzystaniu istniejącej technologii. Według Tsionasa [2002] może wystąpić sytuacja, że przedsiębiorstwo A stosuje przestarzałą technologię, a przedsiębiorstwo B technologię nową, więc to ostatnie będzie produkować więcej niż to pierwsze przy tych samych nakładach. W konsekwencji jednostka A będzie nieefektywna względem granicy technologicznej charakterystycznej dla przedsiębiorstwa B. Oba przedsiębiorstwa mogą jednak być efektywne względem granic technologicznych, które wynikają ze stosowanych przez nie własnych technologii. Rodzi się zatem pytanie, dlaczego przedsiębiorstwo wykorzystuje przestarzałą technologię. Według Tsionasa [2002] podmiotowi może się nie opłacać wdrażanie nowej technologii, gdy koszty jej wdrożenia są bardzo wysokie. Zatem według tej koncepcji nieefektywność techniczna jest mierzona jako utracona wielkość produkcji wynikająca np. ze złego zarządzania procesem produkcji, co może być wyeliminowane bez ponoszenia wysokich kosztów, podczas gdy zaadaptowanie nowej technologii jest bardzo kosztowne.

Mając na uwadze powyższą dyskusję, warto zauważyć, że często w badaniach empirycznych dokonuje się podziału zbioru danych *ad hoc*, który ma na celu wyodrębnienie homogenicznych grup przedsiębiorstw. Najczęstszym kryterium podziału jest skala prowadzonej działalności. Nawet gdy dysponuje się danymi zagregowanymi na poziomie mezo- lub makroekonomicznym, a więc na poziomie regionu lub państwa, w dalszym ciągu istnieje potrzeba

modelowania heterogeniczności, która tym razem ma inne źródła, np. w położeniu geograficznym lub kulturze organizacyjnej. W obu przypadkach ważną kwestią jest przyjęcie takiego modelu, który opisując rozważane zależności, uwzględni wspomnianą heterogeniczność w pomiarze efektywności gospodarowania. Tsionas [2002] w ślad za koncepcją Kalirajana i Obwona [1994] postuluje wykorzystanie w tym celu stochastycznych modeli granicznych z losowymi (indywidualnymi) parametrami.

W badaniach empirycznych dotyczących efektywności gospodarstw rolnych na poziomie indywidualnym, postępując zgodnie z powyższym postulatem, stosowne analizy wykonali: Karagiannis i Tzouvelekas [2009] dla greckich gajów oliwnych, Emvalomatis [2012] oraz Skevas [2019] dla niemieckich gospodarstw mlecznych. Zaletą analiz przeprowadzanych z wykorzystaniem danych o indywidualnych gospodarstwach jest szczegółowe poznanie charakterystyk technologii badanych obiektów. Niestety w literaturze praktycznie nie ma analiz, które obejmowałyby gospodarstwa pochodzące z kilku czy wielu krajów, tj. zwykle dotyczą one jednostek z jednego państwa. Wyjątkiem jest praca Čechury i in. [2014].

W kwestii opracowań dotyczących międzynarodowych porównań produktywności rolnictwa należy zauważyć, że po pierwsze, tego typu prace są przeprowadzane z wykorzystaniem danych zagregowanych na poziomie kraju lub regionu. Przykładami analiz, w których przez jednostkę gospodarczą rozumiany jest kraj, są: Ball i in. [2001, 2010], Coelli i Rao [2005], Reztis [2010], Heady i in. [2010], Baráth i Fertő [2017]. Porównania na poziomie regionalnym z kolei dokonali: Błażejczyk-Majka i in. [2011], Špička [2014], Špička i Smutka [2014], Martinho [2017]. Analizę efektywności na poziomie regionalnym przeprowadzili również Gerdessen i Pascucci [2013], ale wykorzystując jako nakłady, obok zmiennych ekonomicznych takich jak praca i kapitał, wskaźniki dotyczące poziomu zrównoważenia rolnictwa. Ponadto za wyjątkiem pracy Heady'ego i in. [2010] wymienione badania zostały przeprowadzone z użyciem metody DEA. Pomimo pewnych zalet tego podejścia, np. możliwości analizy technologii wieloproduktowych, w przypadku analizy rolnictwa metoda ta ma wadę, gdyż wszelkie odchylenia od produkcji potencjalnej przypisywane są nieefektywności. Dodatkowo, w powyższych artykułach nie jest uwzględniona heterogeniczność badanych jednostek. Wyjątek w tym zakresie stanowi praca Njuki'ego i in. [2019], którzy dokonali pomiaru efektywności 48 regionów (stanów) Stanów Zjednoczonych Ameryki Północnej, z wykorzystaniem modelu uwzględniającego heterogeniczność.

W niniejszych badaniach wykorzystano koncepcję pomiaru efektywności ekonomicznej zaproponowaną przez Farrella [1957], która została uformowana w ramach neoklasycznej mikroekonomicznej teorii produkcji, kosztu i zysku. Z punktu widzenia rozwoju myśli ekonomicznej teoria ta ma głębokie źródła w rewolucji marginalistycznej (m.in. koncepcji produktywności krańcowej), będącej pomostem między ekonomią klasyczną a ekonomią neoklasyczną. Zmatematyzowane spojrzenie na procesy ekonomiczne, w tym decyzje podejmowane przez podmioty gospodarcze, jest konsekwencją kolejnej rewolucji

formalistycznej, która miała miejsce po II wojnie światowej. Metodyka badań prezentowana w dalszej części pracy, która została zaczerpnięta z literatury przedmiotu, wywodzi się właśnie z tego nurtu ekonomii. Warto zaznaczyć, że w poniższych badaniach zostały uchylone założenia, iż podmioty gospodarcze zachowują się racjonalnie, np. maksymalizują efekty swojej działalności, oraz warunek stałych korzyści skali, który często charakteryzuje neoklasyczne funkcje produkcji. Dodatkowo podejście statystyczne, które zostało użyte do empirycznego opisu zależności między nakładami a uzyskanym efektem, umożliwia uwzględnienie niepewności lub nieokreśloności w podejmowaniu decyzji przez wspomniane podmioty.

Z zaprezentowanego krótkiego przeglądu literatury wynika, że w dotychczasowych badaniach na poziomie regionalnym nie wykorzystywano modeli, które pozwalają uwzględnić występujące zróżnicowanie międzyregionalne w rolnictwie. Niniejszy artykuł stanowi zatem nowość w tym zakresie. Praca składa się z sześciu rozdziałów. Rozdział pierwszy zawiera opis jednostek poddanych badaniu. W rozdziale drugim opisano zastosowaną metodykę, tj. stochastyczne modele graniczne ze szczególnym uwzględnieniem ich wariantu z losowymi parametrami. W rozdziale trzecim przedstawiono szczegółowe informacje dotyczące estymacji parametrów zastosowanych modeli. W rozdziale czwartym podano szczegółową definicję zmiennych ekonomicznych. Rozdziały piąty i szósty zawierają wyniki empiryczne dotyczące odpowiednio charakterystyk procesu produkcyjnego i miernika efektywności technicznej w analizowanych regionach i gospodarstwach o różnej wielkości. Pracę kończy podsumowanie.

Gospodarstwa rolne w krajach UE

W niniejszym artykule przedmiotem badania były gospodarstwa rolne specjalizujące się w uprawach polowych, tj. zakwalifikowane do ogólnego typu rolniczego oznaczonego symbolem 1 według typologii gospodarstw rolnych TF8, która została określona przez FADN (*Farm Accountancy Data Network*). Wartościowym materiałem statystycznym do przeprowadzenia porównawczych, międzynarodowych badań empirycznych są ogólnodostępne dane pochodzące z 28 krajów Unii Europejskiej (UE), udostępnione przez FADN. Dane te mają formę zagregowanych zmiennych reprezentujących szczegółową sytuację ekonomiczną gospodarstw rolnych, które zostały objęte badaniem FADN, aby zapewnić reprezentacyjność próby ze względu na typ produkcyjny (specjalizację), położenie geograficzne oraz wielkość (w ujęciu ekonomicznym).

Pojedyncza obserwacja wykorzystywana w tych badaniach zawiera sumaryczną informację o wszystkich gospodarstwach (z badania FADN) zajmujących się uprawami polowymi, usytuowanych w ustalonym regionie znajdującym się w jednym z krajów UE oraz należących do jednej z sześciu klas wielkości ekonomicznych wyznaczonych przez przeciętną wartość produkcji gospodarstw w regionie. W dalszej części artykułu obserwacje te będą określone mianem gospodarstw przeciętnych albo zagregowanych.

Gospodarstwo przeciętne jest opisane przez zagregowane wartości zmiennych ekonomicznych będące średnią ważoną arytmetyczną wartości zmiennych pochodzących z pojedynczych gospodarstw objętych badaniem FADN. Wagi zostały określone na podstawie liczby gospodarstw w danym kraju, które reprezentuje pojedyncze gospodarstwo. Powoduje to, że gospodarstwa przeciętne także mają przypisane (dziedziczone) wagi, które można wykorzystać przy prezentacji wskaźników ekonomicznych dla bardziej zagregowanych obiektów (np. kraju). Zatem gospodarstwa przeciętne można traktować jako reprezentatywne dla populacji generalnej, która jest w polu obserwacji FADN. Jest to ważne z punktu widzenia interpretacji otrzymanych wyników prezentowanych w dalszej części artykułu. Oczywiście występujące braki w danych, o których jest mowa poniżej, obniżają poziom reprezentatywności badanej grupy gospodarstw. Szczegółowe informacje na temat metodyki badań FADN oraz dane statystyczne znajdują się na stronie https://ec.europa.eu/agriculture/rica/database/database_en.cfm.

Ważną kwestią było objęcie badaniem największej liczby regionów krajów członkowskich UE. Ze względu na marginalny udział upraw polowych w produkcji rolniczej z analizy wyłączono następujące kraje: Cypr, Irlandia, Luksemburg i Chorwacja. Ponadto należy zauważyć, że liczba makroregionów wyznaczonych przez FADN w poszczególnych krajach UE jest zróżnicowana i nie jest zbieżna z klasyfikacją NUTS. Przykładowo w Polsce wyróżniono cztery regiony, tj. Pomorze i Mazury, Wielkopolska i Śląsk, Mazowsze i Podlasie, Małopolska i Pogórze. Szczegóły przyjętych kryteriów w wyodrębnieniu makroregionów podają Osuch i in. [2004]. Ponadto w przypadku państw małych, tj. Czech, Danii, Estonii, Litwy, Łotwy, Malty, Holandii, Austrii, Szwecji, Słowacji i Słowenii, według FADN region był tożsamy z krajem, więc dla tych państw dane regionalne nie są dostępne. W przypadku Węgier i Portugalii również wykorzystano dane na poziomie kraju, co spowodowane było brakiem pełnych danych na poziomie regionalnym.

W niniejszej pracy analizowano gospodarstwa, które oprócz zróżnicowania regionalnego są także odmienne ze względu na swoją wielkość. Według metodyki FADN podmioty te są wyróżnione m.in. według kryterium wielkości ekonomicznej (*economic size* – ES6), mierzonej przez średnią wartość produkcji z określonej działalności roślinnej lub zwierzęcej uzyskiwaną z 1 ha lub od 1 zwierzęcia w ciągu 1 roku, w przeciętnych dla danego regionu warunkach z 5 lat [European Commission, 2009: 8]. Główny podział wyróżnia, jak wspomniano wcześniej, sześć wielkości ekonomicznych tj.: gospodarstwa bardzo małe (2 tys. EUR \leq ES < 8 tys. EUR), małe (8 tys. EUR \leq ES < 25 tys. EUR), średnio-małe (25 tys. EUR \leq ES < 50 tys. EUR), średnio-duże (50 tys. EUR \leq ES < 100 tys. EUR), duże (100 tys. EUR \leq ES < 500 tys. EUR), bardzo duże (\geq 500 tys. EUR) [European Commission, 2009: 30].

Metodyka FADN pozwala na szczegółowy podział gospodarstw zajmujących się uprawami polowymi. Obecnie wyróżnia się trzy podstawowe typy specjalizacji (TF14), tj. uprawy zbóż, roślin oleistych i wysokobiałkowych na nasiona, uprawy polowe różnych gatunków roślin oraz mieszane – różne

uprawy [Floriańczyk i in., 2018]. Niestety dane o przeciętnych gospodarstwach określonych przez kryteria, tj. region, wielkość i specjalizację określoną przez typ rolniczy TF14, nie są ogólnodostępne.

Badania empiryczne przeprowadzono dla 404 przeciętnych gospodarstw z 99 regionów wchodzących w skład 24 krajów UE i należących do jednej z sześciu klas wielkości ekonomicznej. Zbiór danych pochodzących z bazy FADN obejmuje okres 14 lat, tj. lata 2004–2017. Próba ta ma charakter niezbilansowany i łącznie obejmuje 4446 obserwacji, w związku z tym dla każdego gospodarstwa posiadana informacja pochodziła przeciętnie z około 11 lat. Pewną niedogodnością jest brak danych dla wybranych regionów w badanych krajach, który w rezultacie spowodował niezbilansowanie próby. Wynikało to z konieczności zachowania tajemnicy statystycznej, gdyż w każdym okresie liczba gospodarstw reprezentujących daną wielkość ekonomiczną i region w ramach określonego typu rolniczego nie może być mniejsza niż 15. Problem ten w szczególności dotyczył małych regionów, m.in. z Belgii, Bułgarii, Francji i Hiszpanii, ale również bardzo małych i bardzo dużych gospodarstw z pozostałych regionów. Miernikiem wyrażającym skalę braku tych danych jest udział wag reprezentatywności pominiętych podmiotów, który wyniósł około 10,6%. Wydaje się, że dalsza agregacja danych, poprzez usunięcie podziału gospodarstw na sześć grup według ich wielkości, spowodowałaby dużą utratę informacji. Wówczas łączna liczba przeciętnych gospodarstw-regionów wyniosłaby 132 (wobec 404 dla gospodarstw-wielkości-regionów), a wszystkich obserwacji byłoby 1470 w ciągu 14 lat (w tych badaniach będzie ich 4446).

Wykorzystanie w badaniach danych zagregowanych otwiera pole do krytyki. Po pierwsze, agregacja oznacza utratę informacji. Dobrze wyjaśni to następujący przykład. W 2017 r. badaniem FADN objętych było 4049 polskich gospodarstw o różnej wielkości, które specjalizowały się w uprawach polowych [Floriańczyk i in., 2018]. W wyniku agregacji według wielkości i regionalizacji otrzymano 22 przeciętne gospodarstwa (zamiast 24, gdyż w dwóch przypadkach dane uśrednione nie zostały udostępnione, bo liczba rzeczywistych gospodarstw była mniejsza niż 15). Po drugie, z agregacją związane są założenia dotyczące konstrukcji funkcji produkcji. Zakłada się, że obserwowane gospodarstwa charakteryzują się technologią opisaną tym samym modelem. Gdy rozważymy model Cobba i Douglasa, to łączenie danych implikuje średnią geometryczną, gdy zaś funkcję liniową – średnią arytmetyczną dla wartości zmiennych opisujących przeciętny podmiot. Wprowadzenie wag dla gospodarstw zmienia jednak elementy modelu statystycznego funkcji produkcji. Rozważmy podmioty należące do tego ustalonego regionu i klasy wielkości, tzn. do grupy o numerze i o liczebności J_i (gdzie $J_i > 0$), którą reprezentuje zagregowany (przeciętny) podmiot. Funkcja produkcji dla j -tego obserwowanego podmiotu z i -tej grupy ma postać: $q_{i,j} = \alpha_0 + \alpha_1 \cdot x_{i,j} + \varepsilon_{i,j}$ (dla $j = 1, \dots, J_i$), gdzie $q_{i,j}$ i $x_{i,j}$ to odpowiednio wielkość (logarytmu) produkcji i (logarytmu) nakładu, wartość oczekiwana niezależnych składników losowych $\varepsilon_{i,j}$ wynosi 0, a wariancja jest identyczna, tj. $V(\varepsilon_{i,j}) = \sigma^2$. Dodatkowo sumujące się do jedności wagi $w_{i,j}$ oznaczają reprezentatywność j -tego podmiotu. Warto wprowadzić

postać modelu po agregacji danych, czyli dla i -tego przeciętnego gospodarstwa. W wyniku sumowania (po indeksie j) otrzyma się jedno równanie postaci $\bar{q}_i = \alpha_0 + \alpha_1 \cdot \bar{x}_i + \bar{\varepsilon}_i$, gdzie $\bar{q}_i = \sum_{j=1}^{J_i} w_{i,j} \cdot q_{i,j}$, $\bar{x}_i = \sum_{j=1}^{J_i} w_{i,j} \cdot x_{i,j}$ i $\bar{\varepsilon}_i = \sum_{j=1}^{J_i} w_{i,j} \cdot \varepsilon_{i,j}$. Parametry funkcji dla gospodarstwa przeciętnego się nie zmieniają. Zmienia się jednak wariancja składnika losowego, tj. $V(\bar{\varepsilon}_i) = \sigma^2 \sum_{j=1}^{J_i} (w_{i,j})^2$. W konsekwencji w równaniu dla i -tego przeciętnego gospodarstwa wariancja dla $\bar{\varepsilon}_i$ jest inna niż σ^2 i jednocześnie prawie zawsze różni się od wariancji dla innego przeciętnego gospodarstwa. Zatem rozważanie modelu dla zagregowanych danych zamiast indywidualnych powoduje heterogeniczność składnika losowego (zróżnicowanie wariancji dla poszczególnych gospodarstw przeciętnych).

Dla przeciwwagi warto wymienić korzyści ze stosowania zagregowanych danych. Po pierwsze, następuje zmniejszenie wariancji składnika losowego, gdyż generalnie $V(\bar{\varepsilon}_i) < \sigma^2$. Wariancja jest malejącą funkcją liczby podmiotów tworzących gospodarstwo przeciętne (J_i) i przyjmuje wartość minimalną, gdy wagi są równe. Po drugie, sposób pozyskiwania danych ekonomicznych o gospodarstwach rolnych jest jednolity, zestandaryzowany z punktu widzenia wszystkich 28 krajów objętych badaniem FADN. Zatem kategorie ekonomiczne użyte do opisu działalności gospodarstw są identycznie zdefiniowane bez względu na miejsce i czas (dla wybranego kraju od momentu jego przystąpienia do UE). Powoduje to, że uzyskane dane statystyczne stanowią bardzo dobry punkt wyjścia dla obiektywnych analiz porównawczych na poziomie krajów, regionów i według wielkości gospodarstw. W celu przeprowadzenia takiej analizy konieczna jest odpowiednia metodyka badań, która uwzględni m.in. zróżnicowanie tych podmiotów ze względu na te trzy elementy oraz konsekwencje agregacji danych.

Stochastyczny model funkcji produkcji ze zmiennymi parametrami

W niniejszych badaniach wykorzystano koncepcję pomiaru efektywności technicznej stosowaną w ramach stochastycznych modeli granicznych, które zostały zaproponowane przez Aignera i in. [1977] oraz Meeusena i van den Broecka [1977]. Wówczas w przypadku analizy procesu produkcji dopuszcza się to, że produkcja obserwowana może być mniejsza od produkcji maksymalnej (możliwej do uzyskania z ustalonych nakładów w sytuacji pełnej efektywności) z powodu ewentualnej nieefektywności (niesprawności technicznej, marnotrawstwa zasobów).

W niniejszych badaniach zastosowano stochastyczny model graniczny dla danych przekrojowo-czasowych, który wprowadzili Pitt i Lee [1981, model II]. W przypadku funkcji produkcji ma on postać:

$$y_{it} = h(x_{it}; \beta) + v_{it} - u_{it}, \quad (1)$$

gdzie y_{it} jest wartością logarytmu zaobserwowanej produkcji i -tego podmiotu w okresie t ($i=1, \dots, N$; $t=1, \dots, T$), x_{it} to wektor-wiersz k zmiennych egzoge-

nicznych (będących logarytmami nakładów czynników produkcji), h oznacza odpowiednio wyspecyfikowaną dla logarytmu produkcji graniczną funkcję produkcji, zwyczajowo liniową względem k -nieznanych parametrów β , $h(x_{it};\beta) = x_{it} \cdot \beta$, które są podstawą do wnioskowania o zależnościach ekonomicznych. Składniki v_{it} i u_{it} są niezależnymi zmiennymi losowymi, z których pierwszy ma rozkład symetryczny względem zera (tj. rozkład normalny) i oddaje wpływ zakłóceń losowych. Drugi jest efektem losowym przyjmującym wartości nieujemne, który reprezentuje bezpośrednio nieobserwowalną nieefektywność. Miarę efektywności technicznej dla i -tego gospodarstwa w okresie t wyraża formuła $TE_{it} = \exp(-u_{it})$.

W niniejszych badaniach przyjęto takie postacie granicznej funkcji produkcji, które są a) mało restrykcyjne z punktu widzenia charakterystyk opisujących zależność między produktem a nakładami, b) poprzez swoją formę pozwalają ująć heterogeniczność badanych podmiotów, gdy ich zbiór jest zróżnicowany. Niech punktem wyjścia dla konstrukcji granicznej funkcji produkcji będzie powszechnie znana postać potęgowa (Cobba i Douglasa, C–D). W przypadku dwóch nakładów (kapitału i pracy, K , L) ma postać

$$h(K,L;\alpha) = \beta_0 + \alpha_K \ln K + \alpha_L \ln L. \quad (2)$$

Można zauważyć, że gdy elastyczności produkcji względem obu nakładów uczynimy zależnymi od nakładów, co wyrazimy np. w formie $\alpha_K = \alpha_1 + \alpha_2 \ln K + \alpha_3 \ln L$ i $\alpha_L = \alpha_4 + \alpha_5 \ln K + \alpha_6 \ln L$, to po podstawieniu do (2), przekształceniu i wprowadzeniu nowej parametryzacji otrzymamy funkcję translogarytmiczną postaci

$$h(K,L;\beta) = \beta_0 + \beta_1 \ln K + \beta_2 \ln L + \beta_3 \ln K \ln L + \beta_4 (\ln K)^2 + \beta_5 (\ln L)^2, \quad (3)$$

gdzie $\beta_1 = \alpha_1$, $\beta_2 = \alpha_4$, $\beta_3 = \alpha_3 + \alpha_5$ itd. Koncepcja tej postaci funkcji została sformalizowana przez Christensena i in. [1973].

Powyższa propozycja pozwala na to, aby elastyczności i współczynnik efektu skali były zmienne dla badanych podmiotów. Warto zauważyć, że owa zmienność uzyskana poprzez wprowadzenie dodatkowych parametrów może podlegać testowaniu, jednak ma ona charakter deterministyczny. Ponadto w modelach (1) standardowo przyjmuje się, że składniki losowe v_{it} są niezależnymi zmiennymi normalnymi o stałej wariancji, tj. $v_{it} \sim N(0, \sigma_v^2)$ dla każdego i oraz t , więc niekoniecznie propozycja (3) wystarczająco dobrze modeluje heterogeniczność ze względu na inne zróżnicowanie (np. regionalne lub ze względu na wielkość jednostek gospodarczych). W związku z tym, warto również rozważyć modelowanie zróżnicowania technologii w sposób niedeterministyczny. Na gruncie ekonometrycznym problem ten sprowadza się do modelowania zróżnicowania parametrów (*parameter heterogeneity*). W kontekście danych panelowych najprostszym sposobem uwzględnienia zróżnicowania obiektów są modele z efektami stałymi (*fixed effects*) lub losowymi (*random effects*), zob. np. Koop [2003]. Jednak na gruncie stochastycznej

analizy granicznej, poprzez przyjęcie odpowiednich rozkładów dla efektów losowych, mają one już bezpośrednią interpretację ekonomiczną w postaci nieefektywności. W szczególności w modelu (1) składniki u_{it} mogą być stałe w czasie, tj. $u_{it} = u_i$ dla każdego t , wówczas nieefektywność pełni rolę efektu indywidualnego występującego zwykle w regresji dla danych panelowych, zob. Pitt i Lee [1981, model I], Marzec i Osiewalski [2008].

Jednym z rozwiązań problemu heterogeniczności obserwacji są modele z losowymi parametrami (*random parameters*²), które pierwotnie zostały zaproponowane przez Hildretha i Houcka [1968] oraz Swamy'ego [1970]. Modele te w zależności od obszaru zastosowania funkcjonują też pod nazwą modeli mieszanych (*mixed models*), modeli wielopoziomowych (*multilevel models*) lub modeli hierarchicznych (*hierarchical models*)³. Innym typem modeli, które pozwalają na wprowadzenie heterogeniczności parametrów, są modele z klasami ukrytymi (*latent class models*). Nie będą one jednak przedmiotem rozważań w niniejszej pracy, natomiast ich zastosowanie w stochastycznej analizie granicznej proponują Orea i Kumbhakar [2004], a przykładem zastosowania w ekonomice rolnictwa jest np. praca Alvareza i del Corrala [2008].

W ramach stochastycznych modeli granicznych Kalirajan i Obwona [1994] jako pierwsi wprowadzili losowe parametry w celu zdefiniowania funkcji produkcji. W przypadku modelu (1) i funkcji postaci C–D proponowany model hierarchiczny z indywidualnymi (losowymi) parametrami (elastycznościami), jako uogólnienie (1) i (2) może przyjąć następującą postać:

$$y_{it} = \beta_0 + x_{it} \cdot \beta_i + v_{it} - u_{it}, \quad (4)$$

gdzie wektor β_i ($i=1, \dots, N$) ma k -wymiarowy (w tym przypadku czterowymiarowy) rozkład normalny o wektorze wartości oczekiwanej równej β i macierzy kowariancji Ω , która jest symetryczna i dodatnio określona. Wówczas parametry β_i są traktowane jako zmienne ukryte, które nie podlegają estymacji. Natomiast w niniejszych badaniach x_{it} jest wektorem wierszowym zawierającym logarytmy czterech nakładów ($k=4$), tj. $x_{it} = [\ln K_{it} \ \ln L_{it} \ \ln M_{it} \ \ln A_{it}]$, gdyż w analizach dotyczących gospodarstw rolnych przyjmuje się obok kapitału i pracy także inne czynniki produkcji, np. materiały (M) i areal użytków rolnych (A). Ponadto w tym równaniu (4) dopuszcza się występowanie pewnych parametrów odpowiadających wybranym zmiennym objaśniającym, które nie podlegały randomizacji. Przykładowo, mogą to być wspólny wyraz wolny (β_0) lub parametr przy trendzie – jak w tych badaniach empirycznych.

Cechą wyróżniającą model (4) jest dopuszczenie, aby parametry opisujące funkcję produkcji (β) były indywidualne dla każdego podmiotu. W przypadku

² W literaturze angielskojęzycznej określane również mianem *random coefficient (s)* lub *varying parameter (s)/coefficient (s) model*.

³ Termin *hierarchical models* jest używany przede wszystkim na gruncie bayesowskim, gdyż *random coefficient model* nie pozwala uchwycić specyfiki tej klasy modeli, ponieważ w modelach bayesowskich parametry są zmiennymi losowymi z samej swej natury, bo są nieznanymi wielkościami.

funkcji produkcji typu Cobba i Douglasa oznacza to, że elastyczności względem czynników produkcji są zróżnicowane dla gospodarstw. Innymi słowy, na poziomie konstrukcji modelu gospodarstwo ma indywidualne charakterystyki wydajności nakładów, a w konsekwencji także współczynnik efektu skali. Trzeba jednak zaznaczyć, że estymacja i wnioskowanie o tych charakterystykach na podstawie danych odbywają się na podstawie próbek w ramach jednego modelu. Zaproponowane uogólnienie tradycyjnego modelu funkcji produkcji C–D będzie podlegać ocenie zasadności w kontekście informacji płynących z danych. Zindywidualizowanie parametrów powyższej regresji podlega pewnej regulacji i ograniczeniu. Przyjęcie, że β_i ($i=1, \dots, N$) posiadają identyczne (i niezależne) rozkłady normalne, a więc o wspólnej wartości oczekiwanej i nieosobliwej macierzy kowariancji, stanowi probabilistyczny opis stwierdzenia, że gospodarstwa mogą być opisywane przez indywidualne charakterystyki, których wartości jednak powinny być zbliżone do siebie. Wektor β i macierz Ω , które definiują rozkład prawdopodobieństwa dla β_i , są nieznane, więc ich elementy podlegają estymacji. Liczba tych parametrów (elementów w β i Ω) rośnie wraz z wartością k . Warto jeszcze nadmienić, że w niniejszych badaniach nie przyjęto restrykcyj, aby macierz Ω była diagonalna (lub skalarna). Diagonalność tej macierzy wyklucza inne niż niezależne zmiany poszczególnych parametrów. Ponadto technologia opisana funkcją C–D zakłada wyłącznie substytucyjność nakładów. Zmniejszenie nakładu jednego z nich wymaga wzrostu innego, gdy produkcja ma być ustalona. Jeśli rozważamy co najmniej cztery czynniki produkcji, to w celu skorelowania technicznych stóp substytucji dla różnych par czynników konieczne jest skorelowanie składowych wektora β_i .

Formuła modelu (4) jest równoważna modelowi z heteroscedastycznością składnika losowego, który w przypadku i -tego podmiotu można zapisać:

$$y_i = \beta_0 \cdot \mathbf{1}_T + X_i \cdot \beta + e_i - u_i \text{ i } e_i \sim N^{(T)}(0, \sigma_v^2 \cdot I_T + X_i \Omega X_i'), \quad (5)$$

gdzie m.in. y_i i X_i to wektor i macierz, które zawierają wartości zmiennej objaśnianej i k -zmiennych objaśniających pochodzące z T okresów, I_T i $\mathbf{1}_T$ są to odpowiednio macierz identycznościowa o wymiarze $T \times T$ i wektor o wymiarze $T \times 1$ zawierająca wartości 1, a u_i i e_i to T -elementowe wektory reprezentujące nieefektywność i składnik losowy w poszczególnych okresach. Standardowo zakłada się, że decyzje pomiotów są podejmowane niezależnie od siebie, co powoduje, że struktura stochastyczna modelu (4) sformułowanego dla $N \cdot T$ obserwacji ma postać blokowo-diagonalną. W efekcie wariancja zmiennej losowej y_i jest podwyższona w odniesieniu do przypadku homoscedastyczności, gdy $X_i \Omega X_i' = 0$, co w naturalny sposób wynika z tego, że dopuszcza się losowość wektora parametrów β_i . Skala wzrostu tej wariancji zależy od postaci macierzy Ω . Wraz ze wzrostem ujemnego (dodatniego) skorelowania składowych wektora β_i ($i=1, \dots, N$) zmniejsza (zwiększa) się przyrost wariancji ($X_i \Omega X_i'$) w stosunku do przypadku referencyjnego, gdy Ω jest diagonalna.

Warto nadmienić, że gdy w (5) macierz X_i zawiera kolumnę zawierającą wartość 1 (dla każdego i oraz t) i w celu zapewnienia identyfikowalności przyjmie się, że np. $\beta_0 = 0$, to otrzymuje się szczególny przypadek modelu z losowymi parametrami, w którym jedynie wyraz wolny jest losowy. Model ten zaproponowany przez Greenego [2005] znany jest obecnie w literaturze jako *True Random Effects Model*. Przymiotnik *true* oznaczający prawdziwy może się odnosić do faktu, że w modelu Pitta i Lee [1981] nie ma rozróżnienia na nieefektywność i heterogeniczność, natomiast ta propozycja pozwala na uwzględnienie zróżnicowania badanych jednostek gospodarczych. W praktyce odseparowanie tych dwóch efektów może jednak być trudne do zrealizowania, zob. Pisulewski i Marzec [2019].

W niniejszych badaniach spośród wielu propozycji dotyczących analizy zależności w ramach modeli funkcji produkcji w przypadku heterogenicznych (zróżnicowanych) jednostek gospodarczych wykorzystano szczegółowe rozwiązanie zaproponowane przez Tsionasa [2002], a następnie rozwijane lub aplikowane przez m.in. Huanga [2004], Karagiannisa i Tzouvelekasa [2009], Emvalomatasa [2012] i Skevasa [2019].

Uwagi dotyczące estymacji i założenia dla modelu empirycznego

W badaniach empirycznych prezentowanych w dalszej części artykułu zostaną wykorzystane dwie koncepcje funkcji produkcji. Pierwsza to funkcja Cobba i Douglasa z parametrami (elastycznościami względem czynników produkcji), które są indywidualne dla gospodarstw rolnych; zob. wzór 4. Drugą jest funkcja translogarytmiczna, która poprzez swoją konstrukcję (wzór 3) co prawda dopuszcza zależność elastyczności od nakładów, ale jednocześnie elastyczności wykazują jedynie deterministyczną zmienność po gospodarstwach. W odniesieniu do tych założeń modelu (1), które dotyczą rozkładu dla nieefektywności (u_{it}), rozważono dwa najczęściej stosowane przypadki: rozkład wykładniczy o wartości oczekiwanej λ oraz rozkład półnormalny (tj. rozkład normalny o zerowej wartości oczekiwanej i nieznannej wariancji σ_u^2 poddany ucięciu przez restrykcję, że nieefektywność jest zmienną nieujemną). Zatem w analizie empirycznej zostaną wykorzystane cztery modele, które różnią się wyżej wymienionymi dwoma elementami (zob. tabela 3).

W modelach opartych na postaci C–D liczba parametrów funkcji produkcji wynosi odpowiednio 4, a w translogu jest równa 14, gdyż liczba czynników produkcji będzie wynosić cztery. Dodatkowo w każdym z nich wprowadzono trend liniowy i oczywiście występuje wyraz wolny. Liczba parametrów struktury stochastycznej w modelu z funkcją C–D jest równa 12, a w modelu z funkcją translogarytmiczną – 2. W konsekwencji liczba parametrów we wszystkich modelach jest tak sama.

Jedną ze standardowych technik estymacji parametrów modelu (1) jest metoda największej wiarygodności (MNV), alternatywną metodą estymacji

jest Monte Carlo Łańcuchów Markowa (*Markov Chain Monte Carlo* – MCMC)⁴, które w latach 90. XX wieku zostały zaadaptowane w tej klasie modeli [Koop i in., 1997]. Zwięzłe omówienie koncepcji wnioskowania bayesowskiego w tej klasie modeli prezentuje m.in. Osiewalski [2000].

W przypadku wprowadzenia indywidualnych parametrów β_i ($i = 1, \dots, N$) w równaniu (4) MNW nie ma już bezpośredniego zastosowania. Wówczas Greene [2005] zaproponował wykorzystanie symulowanej metody największej wiarygodności (SMNW, *maximum simulated likelihood*). Metoda ta ma jednak pewne ograniczenia. Mianowicie poważne problemy natury obliczeniowej towarzyszące jej stosowaniu pojawiają się szczególnie, gdy wymiar wektora β jest duży lub gdy macierz Ω jest niediagonalna. Nawet w zastosowaniu modelu regresji liniowej, gdy liczba elementów wektora β jest niewielka, estymatory niebayesowskie dla macierzy Ω mogą generować oceny, które nie gwarantują dodatniej określoności Ω . Przykładowo taki wynik, gdy wymiar β wynosi trzy, uzyskano w pracy Czyżewski i in. [2018: 52].

Z formalnego punktu widzenia adekwatną metodą estymacji i wnioskowania statystycznego w modelu (4) jest podejście bayesowskie, które przedstawił Tsionas [2002]. Dalszego uogólnienia tego modelu dokonał Huang [2004], wykorzystując model z rozkładem gamma dla nieefektywności. Głównymi argumentami za stosowaniem podejścia bayesowskiego w stochastycznym modelu granicznym z indywidualnymi parametrami są hierarchiczna budowa modelu oraz natura nieefektywności. Oba składniki u_{it} i β_i , wyróżniające ten model, są zmiennymi ukrytymi, więc w tym podejściu są traktowane równorzędnie z parametrami, a zatem są zmiennymi losowymi. Wówczas wnioskowanie o zmiennych ukrytych na podstawie danych odbywa się zgodnie z zasadami rachunku prawdopodobieństwa, na których oparte jest podejście bayesowskie.

W podejściu bayesowskim model statystyczny składa się z dwóch równorzędnych elementów: modelu próbkowego i rozkładu *a priori* dla parametrów. Istnieje zatem możliwość wprowadzenia wstępnej informacji dotyczącej parametrów, aby m.in. uwzględnić wiedzę wynikającą z teorii ekonomii lub innych badań dotyczących omawianego zagadnienia. W rozważanych modelach dla parametrów β przyjęto taki rozkład *a priori*, że dla przeciętnego gospodarstwa wartość oczekiwana elastyczności produkcji względem każdego z czterech czynników wynosi 0,25, a więc w konsekwencji występują stałe korzyści skali. Jednocześnie, przyjmując dużą wariancję (np. 10) dla składowych wektora β , zapewniono, że taki rozkład *a priori* jest bardzo rozproszony wokół wartości 0,25, czyli niepewność statystyczna dotycząca elastyczności i współczynnika efektu skali jest bardzo duża. W przypadku parametrów definiujących rozkład *a priori* dla nieefektywności u_{it} , opisaną rozkładem wykładniczym albo półnormalnym, przyjęto koncepcję z pracy Koop i in. [1997]. Zakłada się, że

⁴ Obliczenia prezentowane w dalszej części artykułu otrzymano, korzystając z oprogramowania własnego opracowanego w środowisku Gauss Aptech oraz programu BayES™ (Bayesian Econometrics Software), stworzonego przez dr. G. Emvalomatisa; zob. <http://www.bayeconsoft.com>

odwrotności tych parametrów, λ^{-1} i σ_u^{-2} , posiadają rozkłady gamma tak określone, iż w konsekwencji mediana rozkładu *a priori* dla miernika efektywności technicznej, $TE_{it} = \exp(-u_{it})$, wynosi np. 0,8 (dla każdego i oraz t) [Tsionas, 2002]. Założenie, że dla połowy obserwacji produkcja uzyskana stanowi co najmniej 80% produkcji maksymalnej, wydaje się być racjonalne. Uzasadnieniem może być fakt, że badane gospodarstwa wytwarzaną produkcję kierują na wspólny rynek, a ich produkcja jest częściowo dotowana przez programy wspólnej polityki rolnej UE. Ponadto przepływ technologii w ramach Europejskiego Obszaru Gospodarczego oparty na swobodzie przepływu ludzi, kapitału, towarów i usług, powinien zacierać różnice w efektywności działalności gospodarczej poszczególnych regionów i podmiotów tam działających (bez względu na ich wielkość). Przeprowadzona tutaj analiza wrażliwości odpowie na pytanie, w jakim stopniu założenie to ma faktyczny wpływ na wyniki *a posteriori*. Ostatnim wspólnym parametrem obu modeli jest precyzja (odwrotność wariancji σ_v^2) składnika v_{it} . W literaturze standardowo przyjmuje się rozkład gamma w takiej postaci, która gwarantuje jego nikłą informacyjność [Koop i in., 1997; Tsionas, 2002]. W literaturze dla macierzy Ω^{-1} przyjmuje się rozkład Wisharta, co na etapie estymacji zapewnia jej dodatnią określoność – takie podejście zastosowano również w niniejszych badaniach. W przypadku bayesowskich modeli dla danych panelowych szczegółowe propozycje rozkładów *a priori* można znaleźć np. w pracach Koop [2003], Rossi i in. [2005], Koop i in. [2007], Gelman i Hill [2007]. Rolą wstępnej wiedzy o parametrach, ujętej w formie rozkładów *a priori*, jest także uwzględnienie dodatkowej informacji spoza próby (np. pochodzącej z teorii), aby to dane miały wpływ decydujący na wyniki estymacji. Oczywiście przez konstrukcję rozkładu *a priori* można formułować konkretne hipotezy badawcze, które wówczas w naturalny sposób podlegają testowaniu. Analiza wrażliwości jest standardowym podejściem, które umożliwia kontrolę wyników estymacji w zależności od struktury modelu.

Definicja czynników i pomiar produkcji

Gospodarstwa rolne zajmujące się uprawami są kojarzone przede wszystkim z produkcją zbóż, ale w rzeczywistości zakres ich działalności jest szerszy. Model funkcji produkcji nie pozwala jednak na analizę produkcji wieloasortymentowej, więc rozważano produkcję łączną. Definicja produktu oraz czynników wytwórczych została określona na podstawie literatury, w której wykorzystano dane FADN [Zhu, Lansink, 2010; Latruffe i in., 2004; Marzec, Pisulewski, 2019]. Na produkcję całkowitą (Q) gospodarstw zajmujących się uprawami polowymi składa się przede wszystkim produkcja roślinna (zmienna SE135 wg FADN), która w badanych 24 krajach w 2017 roku, tj. w ostatnim okresie obserwacji, miała udział 81% oraz produkty pochodzenia zwierzęcego (zmienna SE206 i pozostałe (zmienna SE256) – udział łączny 19%. Wśród tych pierwszych dominowały zboża (44%), rośliny oleiste (14%), warzywa i owoce (13%), ziemniaki (12%), buraki cukrowe (7%), uprawy pastewne (3%), a resztę

stanowiły rośliny białkowe, przemysłowe (m.in. chmiel, tytoń) i inne (7%)⁵. Bardzo interesujący byłby szczegółowy podział krajów ze względu na uzyskiwane płody rolne, ale ten aspekt wykracza poza główne cele badań.

Wyróżniono cztery czynniki produkcji, tj. kapitał rzeczowy (budynki, maszyny, urządzenia i środki transportu, *K*, zmienne SE450 i SE455), pracę (*L*, SE011), materiały (*M*) i użytki rolne (*A*, w hektarach, SE025). Nakład pracy został określony przez całkowity godzinowy czas pracy (własnej lub najemnej, SE016 i SE021) w skali roku. Nakład materiałów został określony poprzez koszty bezpośrednie produkcji roślinnej i zwierzęcej (SE281), bez zużycia wewnętrznego produktów roślinnych. Produkcję oraz czynniki *K* i *M* wyrażono w jednostkowych cenach stałych z lat 2004–2006. W tym celu wykorzystano indeksy cen: a) uzyskiwanych przez producentów w przypadku dominujących produktów roślinnych (osobno dla każdego, tj. zbóż, roślin oleistych, ziemniaków, warzyw i owoców), b) całkowitej produkcji roślinnej oraz c) produkcji zwierzęcej. Źródłem danych były statystyki The Food and Agriculture Organization (FAO) [<http://www.fao.org/faostat/en/#data>]. W przypadku wspomnianych obu nakładów z braku szczegółowych danych przyjęto deflator, tj. indeks PPI (*producer prices in industry, total*). Dla okresów rocznych został on obliczony na podstawie danych miesięcznych, publikowanych przez Eurostat [<https://ec.europa.eu/eurostat/data/database>]. Powyższe wskaźniki dotyczyły każdego spośród 24 badanych krajów.

Tabela 1. Charakterystyki opisowe badanych gospodarstw w 2017 r.

Zmienna*	Kwantyle rozkładu empirycznego				
	5%	25%	50%	75%	95%
Produkcja (w tys. EUR)	8	31	71	204	1157
Kapitał (w tys. EUR)	11	32	61	166	849
Praca (w godz.)	1587	2311	3112	5041	27 020
Materiały (w tys. EUR)	2	7	22	62	388
Areal (w ha)	7	25	59	138	992

* Wyniki otrzymano na podstawie informacji pochodzących z przeciętnych gospodarstw w 24 krajów. Źródło: opracowano na podstawie danych bezpośrednio pozyskanych z FADN Europa.

W tabeli 1 przedstawiono syntetyczne informacje, w formie rozkładu kwantylowego, o wielkości produkcji i nakładach czynników w badanych przeciętnych gospodarstwach w 2017 roku. Połowa gospodarstw uprawia obszar o powierzchni co najmniej 59 ha, a roczna produkcja (bez dotacji) wynosi około 71 tys. EUR, co wskazuje, że roczna wydajność wynosi 1,22 tys. EUR/ha. Ponadto wydajność kapitału (maszyn i urządzeń) jest na poziomie 1,18 EUR z jednej jego jednostki (EUR), a wydajność pracy to ponad 22,9 EUR na godzinę.

⁵ Prezentowane wyniki zostały obliczone jako średnie arytmetyczne ważone (wagi określone każdego z 404 gospodarstw przeciętnych).

Materiały do produkcji rolnej stanowiły około 31% wielkości uzyskanej produkcji. Wartości kwantyli rozkładu, w tym rozstęp międzykwartyłowy, świadczą o bardzo dużym zróżnicowaniu badanych jednostek. Największe różnice w skali wykorzystanych nakładów dotyczą materiałów, a najmniejsze pracy. Mimo że w badaniach wykorzystano dane zagregowane, to heterogeniczność obserwacji jest zauważalna, co wskazuje na potrzebę stosowania omówionych wcześniej modeli.

Tabela 2. Charakterystyki opisowe dla regionów w Polsce w 2017 r.

Region*	Produkcja (w tys. EUR)	Budynki, maszyny (w tys. EUR)	Praca (w godz.)	Materiały (w tys. EUR)	Areal (w ha)
Pomorze i Mazury	37,5	66,2	3238	14,8	45
Wielkopolska i Śląsk	27,9	55,1	2865	10,6	27
Mazowsze i Podlasie	14,0	50,3	3033	4,2	15
Małopolska i Pogórze	15,2	46,6	3155	4,5	14

* Wyniki otrzymano na podstawie ważonych informacji pochodzących z przeciętnych 22 gospodarstw, zróżnicowanych ze względu na ich wielkość.

Źródło: opracowano na podstawie danych bezpośrednio pozyskanych z FADN Europa.

Interesującą kwestią było porównanie, jak na tle badanych krajów wygląda sytuacja polskich gospodarstw rolnych. W tabeli 2 przedstawiono informacje dotyczące produkcji i nakładów dla przeciętnych gospodarstw określonych na poziomie czterech regionów (zastosowano średnią ważoną dla sześciu klas wielkości ekonomicznej). Stwierdzono różnice między regionami w zakresie wartości produkcji i struktury nakładów. Uzyskane wyniki wskazują, że na tle tych czterech regionów uprawy polowe dominują na Pomorzu i Mazurach oraz w Wielkopolsce i na Śląsku. Wydajność pierwszych trzech czynników produkcji była tam bardzo zbliżona i jednocześnie odmienna od pozostałych dwóch regionów. Mazowsze i Podlasie oraz Małopolska i Pogórze angażują relatywnie mało materiałów przy jednocześnie wysokim zaangażowaniu kapitału. W 2017 r. wydajność ziemi użytkowanej rolniczo waha się między 0,83 (Pomorze i Mazury) a 1,09 tys. EUR/ha (Małopolska i Pogórze). Analizę wykorzystania zasobów produkcyjnych, ich produktywności oraz rachunek kosztów i dochodowości w polskich gospodarstwach specjalizujących się w uprawach polowych przedstawia m.in. Komorowska [2017]. Autorka ta prezentuje wyniki dla okresu 2013–2015, ale oparte na tradycyjnych wskaźnikach ekonomicznych i bez podziału regionalnego.

Z wyników z tabeli 1 można wnioskować, że rozważane polskie gospodarstwa-regiony są małe ze względu na nakłady czynników i produkcję oraz charakteryzują się niższą wydajnością. Jedynie gospodarstwa z regionu Pomorze i Mazury prowadzą na tyle dużą produkcję, że można je zakwalifikować do tych gospodarstw w UE, których wartość produkcji kształtuje się między 25. a 50. percentylem w 2017 roku. Ponadto w polskich gospodarstwach relatywnie dużą wartość (w stosunku do uzyskiwanego efektu) stanowią budynki

i maszyny. Na szczególną uwagę zasługuje wysokie zaangażowanie pracy ludzkiej, która w polskim rolnictwie oscyluje wokół mediany rozkładu, gdy tymczasem uzyskiwana produkcja jest dużo mniejsza niż w regionach pozostałych 23 krajów Europy.

Ekonomiczne charakterystyki procesu produkcji gospodarstw

W dalszej części artykułu zaprezentowano wybrane wyniki uzyskane na podstawie estymacji czterech modeli, które różniły się między sobą sposobem opisu granicznej funkcji produkcji (postać C–D z indywidualnymi parametrami albo translogarytmiczna) i typem rozkładu dla nieefektywności (z rozkładem wykładniczym albo półnormalnym). W celu porównania adekwatności rozważanych modeli w kontekście danych wykorzystano czynnik Bayesa (*Bayes factor* – BF) i prawdopodobieństwo *a posteriori* poszczególnych modeli [Osiewalski, 2000]. W hierarchicznych stochastycznych modelach granicznych występuje para zmiennych ukrytych (nieefektywność u_{it} i indywidualne dla gospodarstw parametry technologii β_i), co powoduje, że nie można określić rozkładu próbkowego dla y warunkowego wyłącznie względem parametrów (wycalkowując wcześniej obie zmienne ukryte). Powoduje to, że w celu wyznaczenia BF należy wykorzystać odpowiednio zmodyfikowane estymatory. W niniejszych badaniach zastosowano dwie aproksymacje BF, m.in. zaproponowaną przez Lewisa i Raftery’ego [1997], które dały zgodne wskazania co do wyboru najlepszego modelu statystycznego.

Tabela 3. Wyniki bayesowskiego porównywania modeli empirycznych

M_r	Specyfikacja modeli	Czynnik Bayesa (BF)	$p(M_r y)$	Ranking modeli
M_1	C–D z indywidualnymi β_i i rozkład wykładniczy dla nieefektywności	≈ 1	≈ 1	1
M_2	C–D z indywidualnymi β_i i rozkład półnormalny dla nieefektywności	$5.15 \cdot 10^{-12}$	$5.15 \cdot 10^{-12}$	2
M_3	Translog i rozkład wykładniczy dla nieefektywności	≈ 0.000	≈ 0.000	3
M_4	Translog i rozkład półnormalny dla nieefektywności	≈ 0.000	≈ 0.000	4

Źródło: opracowanie własne na podstawie wyników otrzymanych z programu BayES (na podstawie propozycji Lewisa i Raftery’ego [1997]).

Poniżej zaprezentowano wyniki bayesowskiego porównywania czterech modeli. Liczba parametrów, czyli ich złożoność, we wszystkich modelach jest taka sama, więc można przyjąć, że są tak samo prawdopodobne *a priori*. Deterministyczna koncepcja zindywidualizowania elastyczności dla gospodarstw w formie funkcji translogarytmicznej została bezwzględnie odrzucona przez dane. Model funkcji Cobba i Douglasa z indywidualnymi elastycznościami (formuły 2 i 4) i nieefektywnością opisaną rozkładem wykładniczym okazał się tym, który znajduje zdecydowane poparcie w danych, gdyż jego prawdo-

podobieństwo *a posteriori*, $p(M_1 | y)$, wynosi prawie jeden. Zatem w dalszej części artykułu zaprezentowano głównie wyniki pochodzące z modelu M_1 . Rezultaty z pozostałych będą stanowiły uzupełnienie.

Na podstawie rozważanych modeli uzyskano zgodne rezultaty dotyczące podstawowych charakterystyk, które opisują zależność między produkcją a nakładami, tj. elastyczności i wartość współczynnika efektu skali (*Returns to Scale*, RTS), przedstawiono w kolejnych tabelach. W tabeli 4 zaprezentowano dla badanych krajów wartości uśrednione tych charakterystyk w modelu M_1 .

W pierwszej kolejności zaobserwowano, że część otrzymanych rezultatów nie spełnia warunków regularności ekonomicznej. W szczególności dla siedmiu spośród 24 krajów (Węgry, Finlandia, Litwa, Holandia, Słowacja, Łotwa, Estonia) zaobserwowano, że średnia elastyczność produkcji względem areалу jest ujemna. Podobnie w przypadku Danii stwierdzono ujemną elastyczność względem pracy. Wynik ten może wskazywać, że w tych krajach nakłady czynników są nieoptymalne, gdyż są one angażowane w zbyt dużej ilości w stosunku do pozostałych [Marzec i in., 2019]. W tym kontekście ujemną wartość elastyczności względem areálu dla Holandii wyjaśnia fakt, że choć jest ona obszarowo małym krajem, to badane zagregowane gospodarstwa, zajmujące się przede wszystkim produkcją ziemniaków lub warzyw (przodujący producent w UE), są średnio-duże lub większe, czyli należą wyłącznie do 4, 5 i 6 klasy wielkości. Zatem dalszy wzrost ich areálu upraw nie jest uzasadniony ekonomicznie.

Dalsza analiza wyników wskazuje, że badane kraje różnią się wydajnością krańcową czynników produkcji. Przykładowo, 1% wzrostu kapitału w Estonii i na Węgrzech spowoduje wzrost produkcji odpowiednio o 0,31% i 0,29%, gdy tymczasem w Polsce prawie nie wywołuje zmian w wielkości produkcji. W Finlandii i na Węgrzech wzrost zatrudnienia o 1% skutkuje wzrostem produkcji aż o 0,57% i 0,45%, co jest najwyższą wartością w badanych krajach, a w Polsce ten efekt wynosi zaledwie 0,07%. Rola materiałów jako czynnika wytwórczego jest największa w takich krajach jak Łotwa, Holandia i Litwa, gdyż elastyczność względem tego czynnika jest rzędu 0,8–0,78. W Polsce jest mniejsza, ale dość wysoka, bo wynosi 0,67. Słowenia, Malta i Finlandia mają najniższe wartości średniej elastyczności względem materiałów, równe odpowiednio 0,31, 0,29 i 0,26. Średnia elastyczność produkcji względem areálu jest największa w następujących krajach: Słowenia (0,46), Polska (0,32) i Malta (0,32).

W większości krajów za wyjątkiem wcześniej wspomnianych, tj.: Łotwy, Słowacji, Estonii, Danii oraz dodatkowo Bułgarii, obserwuje się rosnące korzyści skali. Produkcja, która jest wyraźnie zbyt mała w stosunku do optymalnej (gdy $RTS = 1$), występuje w Słowenii ($RTS = 1,21$) i na Węgrzech ($RTS = 1,19$). W Polsce średnia wartość współczynnika efektu wynosi 1,06, a zbliżone wartości charakteryzują Rumunię i Litwę. Większe zróżnicowanie ocen RTS gospodarstw występuje w wynikach w podziale regionalnym lub według wielkości ekonomicznej.

Tabela 4. Średnie elastyczności produkcji i efektu skali w badanych krajach (model M_1)*

Kraj	Elastyczności				
	Kapitał	Praca	Materiały	Areał	Efekt skali
Austria	0,19	0,37	0,54	0,06	1,16
Belgia	0,23	0,08	0,70	0,04	1,04
Bułgaria	0,17	0,09	0,59	0,10	0,96
Czechy	0,07	0,32	0,61	0,12	1,12
Dania	0,06	-0,19	0,51	0,09	0,48
Estonia	0,31	0,25	0,56	-0,29	0,82
Finlandia	0,27	0,57	0,26	-0,07	1,03
Francja	0,13	0,23	0,60	0,17	1,13
Grecja	0,05	0,27	0,63	0,09	1,04
Hiszpania	0,13	0,17	0,53	0,18	1,01
Holandia	0,24	0,18	0,79	-0,11	1,10
Litwa	0,14	0,24	0,78	-0,09	1,06
Łotwa	0,15	0,11	0,80	-0,18	0,87
Malta	0,06	0,42	0,29	0,32	1,09
Niemcy	0,23	0,23	0,38	0,23	1,07
Polska	0,00	0,07	0,67	0,32	1,06
Portugalia	0,09	0,13	0,75	0,04	1,00
Rumunia	0,16	0,11	0,65	0,15	1,06
Słowacja	0,24	0,13	0,59	-0,12	0,85
Słowenia	0,17	0,26	0,31	0,46	1,21
Szwecja	0,21	0,28	0,45	0,17	1,12
Węgry	0,29	0,45	0,46	-0,01	1,19
Wielka Brytania	0,15	0,37	0,48	0,14	1,15
Włochy	0,11	0,27	0,57	0,07	1,02

* Wyniki te są wartościami średnimi z okresu 2004–2017, obliczonymi dla przeciętnych gospodarstw zróżnicowanych ze względu na ich wielkość i region.

Źródło: opracowanie własne.

Średnie wartości elastyczności produkcji względem nakładów czynników produkcji dla 24 krajów UE zostały zaprezentowane w tabeli 5. Wyniki te dla modeli opartych na funkcji Cobba i Douglasa (M_1 i M_2) są takie same. Podobnie wyniki uzyskane na podstawie funkcji translogarytmicznej z obu modeli (M_3 i M_4) są prawie identyczne. Natomiast zasadnicze różnice występują między obiema grupami modeli. Przede wszystkim przejawiają się one w wartościach elastyczności względem materiałów i areału. W modelach M_3 i M_4 średnia elastyczność względem areału jest ujemna i jednocześnie elastyczność względem materiałów jest relatywnie wysoka. Zatem analityczna postać funkcji produkcji wpływa na wnioski dotyczące ekonomicznych charakterystyk procesu produkcji, nawet na poziomie średnich wyników dla 24 krajów UE.

W uzupełnieniu można dodać jeszcze jeden argument przeciwko stosowaniu tradycyjnej funkcji C–D z parametrami β , które są wspólne dla wszystkich obserwacji (jak we wzorze 2). W tym szczególnym przypadku modelu M_1 elastyczności względem nakładów znacząco różnią się od tych prezentowanych w tabeli 5. Wówczas elastyczności produkcji względem kapitału, pracy, materiałów i areалу wynoszą odpowiednio: 0,06, 0,14, 0,86 i –0,09. Pokazuje to jeszcze jedną przewagę zastosowania modelu z indywidualnymi parametrami (M_1). Otrzymane na jego podstawie oceny elastyczności (na poziomie wartości uśrednionych dla obserwacji) spełniają warunki regularności ekonomicznej.

Dalsza szczegółowa analiza na poziomie krajów pokazała, że w rozważanych modelach wartości średnie charakterystyk procesu produkcji (elastyczności i efekt skali) nie zmieniały się istotnie w badanych 14 latach i są identyczne z tymi prezentowanymi w tabeli 5.

Tabela 5. Charakterystyki procesu produkcji – wartości średnie dla 24 krajów UE (modele M_1 i M_2)

Elastyczność względem	M_1 i M_2	M_3 i M_4
	Ocena (średni błąd szacunku)	Ocena (średni błąd szacunku)
Budynki i maszyny	0,14 ($\pm 0,01$)	0,10 ($\pm 0,01$)
Praca	0,21 ($\pm 0,02$)	0,15 ($\pm 0,01$)
Materiały	0,57 ($\pm 0,02$)	0,84 ($\pm 0,01$)
Areál	0,12 ($\pm 0,02$)	–0,07 ($\pm 0,01$)
Efekt skali	1,04 ($\pm 0,02$)	1,01 ($\pm 0,01$)

Źródło: opracowanie własne.

W tabeli 6 zaprezentowano szczegółowe rezultaty dotyczące czterech regionów w Polsce. W przypadku Pomorza i Mazur elastyczność względem kapitału fizycznego (reprezentowanego przez budynki i maszyny) jest ujemna, a więc nie jest bezpośrednio interpretowalna z punktu widzenia teorii ekonomii, ale może być to efektem nadmiernego zaangażowania (nieadekwatnego wykorzystania) tego czynnika. Taki sam wynik otrzymali Marzec i in. [2019], gdy analizowano efektywność upraw polowych na podstawie danych indywidualnych pochodzących z gospodarstw objętych badaniem FADN. W pozostałych regionach współczynnik korzyści skali jest wyższy niż średnia w badanych 24 krajach i wskazuje, że poprzez wzrost produkcji można obniżyć koszty jednostkowe jej wytworzenia. Wartości elastyczności są bardzo zróżnicowane między regionami, bo zapewne zależą silnie od poziomu i struktury nakładów (tabela 2). Wyniki te są zbliżone dla Mazowsza i Podlasia oraz Małopolski i Pogórza, bo oba regiony uzyskują bardzo podobną wielkość produkcji otrzymaną ze zbliżonych nakładów. Ponadto dla wszystkich regionów można zauważyć wymiennosc między wydajnością materiałów a wydajnością areálu upraw. Przykładowo, na Pomorzu i Mazurach warto było zwiększyć zaangażowanie materiałów, gdy tymczasem korzyści ze zwiększenia powierzchni upraw są niewielkie, co może wynikać z faktu,

że w tym regionie areal przeciętnego gospodarstwa jest relatywnie największy (45 ha w 2017 r.). Rola budynków, maszyn i pracy ludzkiej jest mniejsza od nakładów materiałów i areалу upraw.

Powyższa analiza wskazuje bez wątpienia, że w celu opisanja zależności między nakładami a produkcją konieczne jest zastosowanie takiej postaci funkcji produkcji, która dopuszcza zróżnicowanie charakterystyk procesu produkcji badanych gospodarstw. Tradycyjna funkcja Cobba i Douglasa ze wspólnymi (dla wszystkich obserwacji) elastycznościami nie spełnia tego postulatu.

Tabela 6. Charakterystyki procesu produkcji – wartości średnie dla regionów w Polsce (model M_1)*

Region	Elastyczność względem Budynki i maszyny	Praca	Materiały	Areał	Efekt skali
Pomorze i Mazury	-0,11	0,04	0,95	0,10	0,99
Wielkopolska i Śląsk	0,03	0,06	0,47	0,53	1,09
Mazowsze i Podlasie	0,06	0,07	0,64	0,34	1,11
Małopolska i Pogórze	0,02	0,13	0,60	0,33	1,08

* Wyniki te są wartościami średnimi z okresu 2004–2017, obliczonymi dla przeciętnych gospodarstw zróżnicowanych ze względu na ich wielkość.

Źródło: opracowanie własne.

W rozważanych modelach występował trend liniowy jako dodatkowy komponent (zmienna kontrolna). Ocena parametru przy trendzie, wspólnym dla wszystkich gospodarstw bez względu na ich zróżnicowanie, zgodnie wyniosła od $-0,012$ (M_3 i M_4) do $-0,008$ z błędem $\pm 0,001$ (M_1 i M_2), co świadczy o niewielkim, ale istotnym statystycznie regresie techniczno-organizacyjnym, który wynosi około 1% w skali roku. Wynik ten jest zgodny z rezultatami uzyskanymi we wcześniejszych badaniach autorów, przeprowadzonych na podstawie zbioru danych o pojedynczych gospodarstwach.

Pomiar efektywności technicznej

Syntetyczne informacje dotyczące miernika efektywności technicznej (TE) dla badanych gospodarstw z 24 krajów i 99 regionów zaprezentowano w tabeli 7. Szczególną uwagę zwracają dwie kwestie. Po pierwsze, na ten pomiar wpływa typ rozkładu dla nieefektywności. Po drugie, uzyskano wysoki poziom i małe rozproszenie ocen efektywności zagregowanych gospodarstw. Ważną kwestią jest znalezienie uzasadnienia dla tego faktu. Porównując rezultaty pochodzące z różnych modeli, można sformułować wniosek, że fakt ten nie wynika z odmiennych postaci funkcji produkcji (funkcja potęgowa a translogarytmiczna) czy też z uwzględnienia albo pominięcia heterogeniczności w stochastycznym modelu granicznym (1). Czynnikiem decydującym jest wykorzystanie w badaniach obserwacji dotyczących wielkości nakładów i produkcji na poziomie przeciętnym, obliczonych na podstawie pewnej grupy indywidu-

alnych gospodarstw. Należy jednak podkreślić, że nie jest regułą, iż agregacja prowadzi do upodabniania się pomiędzy obiektami wyników dla TE. Wczesniejsze badania innych autorów stosujących metodę DEA i dane zagregowane dla regionów lub krajów UE dawały bardzo zróżnicowane oceny TE, np. Błażejczyk-Majka i in. [2011], Martinho [2017]. W niniejszym artykule pokazano, że bez wątplenia wybór rozkładu dla nieefektywności ma decydujący wpływ na poziom ocen efektywności, co pokazują wnioski prezentowane poniżej. Stąd wnioskuje się, że agregacja danych wpływa raczej na zmniejszenie rozproszenia ocen efektywności gospodarstw, ale nie na wysoki jej poziom. Bez wątplenia kwestia ta wymaga dalszej pogłębionej analizy.

W modelach z rozkładem wykładniczym oceny efektywności są wyższe niż w przypadku rozkładu półnormalnego, choć wartości median obu rozkładów *a priori* są takie same, tj. 0,8. Na podstawie wyników estymacji wnioskuje się, że w najlepszym modelu M_1 50% gospodarstw ma efektywność co najmniej 0,95, a w przypadku zaledwie 5% iloraz produkcji obserwowanej do maksymalnej możliwej do uzyskania z zaobserwowanych nakładów jest nie wyższy niż 0,92. W modelu M_2 wartość mediany jest niższa i wynosi 0,91, kwantyl rzędu 5% wynosi 0,88. Wyniki z tych modeli są wyraźnie różne. W celu dalszego porównania wyników dodatkowo obliczono współczynnik korelacji rang Spearmana dla rankingów efektywności gospodarstw, utworzonych na podstawie modeli M_1 i M_2 . Ocena tego współczynnika jest równa 0,999. Zatem występuje bardzo istotna korelacja dodatnia rankingów jednostek gospodarczych mimo różnic w poziomie nieefektywności. Potwierdza to częsty wynik z wielu badań, że mimo różnic w pomiarze stopnia nieefektywności modele, które różnią się założeniami, w zbliżony sposób pozycjonują obiekty w rankingu.

Tabela 7. Kwantyle rozkładu empirycznego oceny miernika efektywności technicznej*

M_i	Model	Kwantyle rozkładu empirycznego				
		5%	25%	50%	75%	95%
M_1	C-D z indywidualnymi β_i i rozkład wykładniczy dla nieefektywności	0,92	0,94	0,95	0,96	0,97
M_2	C-D z indywidualnymi β_i i rozkład półnormalny dla nieefektywności	0,84	0,88	0,91	0,93	0,94
M_3	Translog i rozkład wykładniczy dla nieefektywności	0,95	0,96	0,96	0,96	0,97
M_4	Translog i rozkład półnormalny dla nieefektywności	0,83	0,87	0,89	0,90	0,92

* Wyniki uzyskano na podstawie ocen TE dla 4446 obserwacji (404 gospodarstw i lat 2004–2017).
Źródło: opracowanie własne.

W odniesieniu do pozycji polskich regionów w rankingu najefektywniejszym regionem jest Mazowsze i Podlasie, które znalazło się w 43. centylu rozkładu empirycznego dla TE, następnie Małopolska i Pogórze, które są w 39. centylu, Wielkopolska i Śląsk plasują się w 38. centylu, a Pomorze i Mazury w 27. Wybór modelu nie wpływa na miejsce tych regionów w rankingu. Szcze-

gólowa analiza pokazuje, że jednostkami o najwyższej efektywności są te duże z Mazowsza i Podlasia, należące do piątej klasy wielkości ekonomicznej (100 tys. EUR \leq ES < 500 tys. EUR), a następnie gospodarstwa bardzo duże z Wielkopolski i Śląska (ES \geq 500 tys. EUR). Na tle wszystkich wyników z 24 krajów dla zagregowanych gospodarstw (określonych przez region i wielkość) obie te jednostki zajmują pozycję dopiero w 49. centylu rozkładu dla TE. Natomiast na dole rankingu są gospodarstwa z Pomorza i Mazur, te średnio-duże (50 tys. EUR \leq ES < 100 tys. EUR) i średnio-małe (25 tys. EUR \leq ES < 50 tys. EUR). Pozycja tego ostatniego gospodarstwa, które wyraźnie odstaje od pozostałych, to 10. centyl. Podsumowując, przeciętne gospodarstwa w Polsce są relatywnie mniej efektywne od konkurencyjnych, pochodzących z innych krajów UE.

Kolejne wyniki pokazały także, że w badanym okresie średnie dla obserwacji wartości miernika efektywności nie wykazywały wyraźnych zmian w poszczególnych okresach, mimo że konstrukcja modelu dopuszcza swobodną zmienność nieefektywności w czasie. W badanych 14 latach wartości średnie miernika TE dla każdego okresu przyjmowały wartości z przedziału 0,94–0,96, więc można wnioskować, że na poziomie makro (upraw polowych 24 krajów UE) efektywność była stała. Podobnie nie zauważono istotnego zróżnicowania wartości efektywności ze względu na wielkość ekonomiczną gospodarstw rolnych.

Podsumowanie

W niniejszej pracy przedmiotem analizy były zagregowane gospodarstwa rolne specjalizujące się w uprawach polowych w regionach 24 krajów Unii Europejskiej. Analizę przeprowadzono z wykorzystaniem zagregowanych danych dotyczących wielkości produkcji i nakładów czynników produkcji. Mając na uwadze zróżnicowanie gospodarstw, wykorzystano modele z indywidualnymi parametrami [Tsionas, 2002] i przetestowano ich zasadność w świetle heterogenicznej próby. W szczególności rozważono dwie postaci funkcji produkcji opisujące technologię wytwarzania, tj. funkcję Cobba i Douglasa z indywidualnymi parametrami i funkcję translogarytmiczną. Modele te różniły się też ze względu na przyjęty rozkład dla nieefektywności, tj. wykładniczy lub półnormalny. W ostateczności zatem przetestowano cztery konkurencyjne modele, spośród których najlepszym okazał się model z funkcją produkcji typu Cobba i Douglasa z indywidualnymi parametrami i wykładniczym rozkładem dla nieefektywności.

Otrzymane wyniki wskazują, że najwyższą elastycznością produkcji charakteryzuje się elastyczność względem nakładów materiałów, natomiast najniższą względem areалу. Polskie gospodarstwa charakteryzują się w zdecydowanej większości rosnącymi korzyściami skali. Jednocześnie warto zauważyć, że w niniejszej pracy nie narzucono restrykcji diagonalności na macierz kowariancji, oznaczającej brak skorelowania pomiędzy parametrami. Restrykcja taka występuje w większości prac wykorzystujących ten model i podejście

niebayesowskie. Warto zauważyć, że zarówno na poziomie gospodarstw przeciętnych, jak i po ich agregacji w formie regionów lub krajów, wykorzystanie zagregowanych danych nie spowodowało ujednoczenia charakterystyk technologii. Przykładowo elastyczności względem nakładów są bardzo zróżnicowane pomiędzy państwami, jak i regionami (tabele 4 i 6).

Oryginalnym wynikiem jest uzyskanie pomiaru efektywności, który wskazuje na bardzo zbliżony i wysoki poziom efektywności gospodarstw we wszystkich badanych regionach i bez względu na klasę wielkości ekonomicznej. Ponadto należy zauważyć, że typ rozkładu dla nieefektywności wpływał na poziom wartości miernika efektywności, tj. przy użyciu modelu z rozkładem wykładniczym uzyskano wyższe wartości efektywności niż przy założeniu rozkładu półnormalnego. Rankingi gospodarstw według efektywności zbudowane na podstawie obu modeli okazały się jednak prawie identyczne. Dodatkowo średnia wartość miernika efektywności nie zmieniała się w badanym okresie. Na tle krajów Unii Europejskiej polskie gospodarstwa zajmujące się uprawami polowymi są relatywnie nieefektywne. W rankingu znajdują się one na odległych pozycjach, a dwa najlepsze gospodarstwa zajmują dopiero miejsca w połowie rankingu (tj. w 49. centylu rozkładu ocen efektywności).

Ważnym wnioskiem o charakterze metodycznym jest pokazanie, że konieczne jest uwzględnienie heterogeniczności w budowie i estymacji parametrów modelu na podstawie danych zagregowanych, gdy te ostatnie powstały poprzez ważenie oryginalnych zmiennych ekonomicznych charakteryzujących obserwowane podmioty gospodarcze.

Bibliografia

- Aigner D., Lovell C.A.K., Schmidt P. [1977], Formulation and estimation of stochastic frontier production function models, *Journal of Econometrics*, 6(1): 21–37.
- Alvarez A., del Corral J. [2010], Identifying different technologies using a latent class model: extensive versus intensive dairy farms, *European Review of Agricultural Economics*, 37(2): 231–250.
- Ball V.E., Bureau J-C., Butault J-P, Nehring R. [2001], Levels of farm sector productivity: an international comparison, *Journal of Productivity Analysis*, 15(1): 15–29.
- Ball V.E., Butault J-P, San Juan C., Mora R. [2010], Productivity and international competitiveness of agriculture in the European Union and the United States, *Agricultural Economics*, 41(6): 611–627.
- Baráth L., Fertó I. [2017], Productivity and convergence in European agriculture, *Journal of Agricultural Economics*, 68(1): 228–248.
- Błażejczyk-Majka L., Kala R., Maciejewski K. [2011], Productivity and efficiency of large and small field crop farms and mixed farms of the old and new EU regions, *Agricultural Economics – Czech*, 58(2): 61–71.
- Bocian M., Cholewa I., Tarasiuk R. [2017], *Współczynniki Standardowej Produkcji „2013” dla celów Wspólnotowej Typologii Gospodarstw Rolnych*, IERiGŻ-PIB, Warszawa.

- 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, 9, Halle.
- Christensen L., Jorgenson D., Lau L. [1973], Transcendental logarithmic production frontiers, *Review of Economics and Statistics*, 55(1): 28–45.
- Coelli T.J., Rao D.S.P. [2005], Total factor productivity growth in agriculture: a Malmquist index analysis of 93 countries, 1980–2000, *Agricultural Economics*, 32(1): 115–134.
- Czyżewski B., Matuszczak A., Brelik A. [2018], Endogeniczna wartość dóbr publicznych na obszarach wiejskich: przypadek Pomorza Zachodniego, *Roczniki Naukowe Stowarzyszenia Ekonomistów Rolnictwa i Agrobiznesu*, 5: 48–54.
- Emvalomatis G. [2012], Productivity growth in German dairy farming using a flexible modelling approach, *Journal of Agricultural Economics*, 63(1): 83–101.
- European Commission [2009], Typology handbook, RI/CC 1500 rev. 3, 05/10/2009 Brussels.
- Farrell M. [1957], The measurement of productive efficiency, *Journal of the Royal Statistical Society, Seria A*, 120(3): 253–281.
- Floriańczyk Z., Osuch D., Płonka R. [2018], *Wyniki Standardowe 2017 uzyskane przez gospodarstwa rolne uczestniczące w Polskim FADN, Część I. Wyniki Standardowe*, IERiGŻ-PIB, Warszawa.
- Gelman A., Hill J. [2007], *Data analysis using regression and hierarchical/multilevel models*, Cambridge University Press, Cambridge.
- Gerdessen J.C., Pascucci S. [2013], Data envelopment analysis of sustainability indicators of European agricultural systems at regional level, *Agricultural Systems*, 118: 78–90.
- Greene W.H. [2005], Reconsidering heterogeneity in panel data estimators of the stochastic frontier model, *Journal of Econometrics*, 126(2): 269–303.
- Griliches Zvi [1987], Productivity: measurement problems, in: J. Eatwell, M. Milgate and P. Newman (eds.), *The New Palgrave A Dictionary of Economics*, Stockton Press, New York, 3: 1010–1013.
- Heady D., Alauddin M., Rao D.S.P. [2010], Explaining agricultural productivity growth: an international perspective, *Agricultural Economics*, 41(1): 1–14.
- Hildreth C., Houck J.P. [1968], Some estimators for a linear model with random coefficients, *Journal of the American Statistical Association*, 63(322): 584–595.
- Huang H. [2004], Estimation of technical inefficiencies with heterogenous technologies, *Journal of Productivity Analysis*, 21(3): 277–296.
- Kalirajan K.P., Obwona M.B. [1994], Frontier production function: the stochastic coefficients approach, *Oxford Bulletin of Economics and Statistics*, 56(1): 87–96.
- Karagiannis G., Tzouvelekas V. [2009], Measuring technical efficiency in the stochastic varying coefficient frontier model, *Agricultural Economics*, 40(4): 389–396.
- Komorowska D. [2017], Wyniki produkcyjne i ekonomiczne gospodarstw specjalizujących się w uprawach polowych, *Roczniki Naukowe Stowarzyszenia Ekonomistów Rolnictwa i Agrobiznesu*, 6: 135–140.
- Koop G. [2003], *Bayesian Econometrics*, Wiley John & Sons, New York.

- Koop G., Osiewalski J., Steel M. [1997], Bayesian efficiency analysis through individual effects: hospital cost frontiers, *Journal of Econometrics*, 76, 1–2: 77–105.
- Koop G., Poirier D., Tobias J. [2007], *Bayesian econometric methods*, Cambridge University Press, Cambridge.
- Latruffe L., Balcombe K., Davidova S., Zawalińska K. [2004], Determinants of technical efficiency of crop and livestock farms in Poland, *Applied Economics*, 36(12): 1255–1262.
- Lewis S., Raftery A. [1997], Estimating Bayes factors via posterior simulation with the Laplace-Metropolis estimator, *Journal of the American Statistical Association*, 92(438): 648–655.
- Martinho V.J.P.D. [2017], Efficiency, total factor productivity and returns to scale in a sustainable perspective: an analysis in the European Union at farm and regional level, *Land Use Policy*, 68: 232–245.
- Marzec J., Osiewalski J. [2008], Bayesian inference on technology and cost efficiency of bank branches, *Bank i Kredyt*, 9: 29–43.
- Marzec J., Pisulewski A. [2019], The Measurement of time-varying technical efficiency and productivity change in Polish crop farms, *German Journal of Agricultural Economics*, 68(1): 15–27.
- Marzec J., Pisulewski A., Prędko A. [2019], Efektywność techniczna i produktywność polskich gospodarstw rolnych specjalizujących się w uprawach polowych, *Gospodarka Narodowa*, 298(2): 95–125.
- Meeusen W., van den Broeck J. [1977], Efficiency estimation from Cobb-Douglas production functions with composed error, *International Economic Review*, 18(2): 435–444.
- Njuki E., Bravo-Ureta B.E., O'Donnell Ch.J. [2019], Decomposing agricultural productivity growth using a random-parameters stochastic production frontier, *Empirical Economics*, 57(3): 839–860.
- Orea L., Kumbhakar S.C. [2004], Efficiency measurement using a latent class stochastic frontier model, *Empirical Economics*, 29(1): 169–183.
- Osiewalski J. [2000], *Ekonometria bayesowska w zastosowaniach*, Wydawnictwo Akademii Ekonomicznej w Krakowie.
- Osuch D., Goraj L., Skarżyńska A., Grabowska K. [2004], *Plan wyboru próby gospodarstw rolnych polskiego*, FADN.
- Pisulewski A., Marzec J. [2019], Heterogeneity, transient and persistent technical efficiency of Polish crop farms, *Spanish Journal of Agricultural Research*, 17(1). e0106.
- Pitt M., Lee L. [1981], Measurement of sources of technical inefficiency in the Indonesian weaving industry. *Journal of Development Economics*, 9(1): 43–64.
- Rezitis A., [2010], Agricultural productivity and convergence: Europe and the United States, *Applied Economics*, 42(8): 1029–1044.
- Rossi P., Allenby G., McCulloch R. [2005], *Bayesian statistics and marketing*, John Wiley & Sons, Chichester.
- Skevas I. [2019], A hierarchical stochastic frontier model for efficiency measurement under technology heterogeneity, *Journal of Quantitative Economics*, 17(3): 513–524.
- Špička J., Smutka L. [2014], The technical efficiency of specialised milk farms: a regional view, *The Scientific World Journal*, ID: 985149.
- Špička J. [2014], The regional efficiency of mixed crop and livestock type of farming and its determinants, *Agris on-line Papers in Economics and Informatics*, 1: 99–109.

- Swamy P.A. [1970], Efficient inference in a random coefficient regression model, *Econometrica*, 38(2): 311–323.
- Tsionas E.G. [2002] Stochastic frontier models with random coefficients. *Journal of Applied Econometrics*, 17(2): 127–147.
- Varian H.R. [2010] *Intermediate microeconomics. A modern approach*. Eight Edition, W.W. Norton and Company, New York.
- Zhu X., Lansink A. [2010], Impact of CAP subsidies on technical efficiency of crop farms in Germany, the Netherlands and Sweden, *Journal of Agricultural Economics*, 61(3): 545–564.

