

N A U K A
I SZKOLNICTWO
W Y Ż S Z E

2(52)/2018

N A U K A
I SZKOLNICTWO
W Y Ż S Z E

2(52)/2018

BADANIA NAD EFEKTYWNOŚCIĄ I PRODUKTYWNOŚCIĄ SZKÓŁ WYŻSZYCH

NAUKA I SZKOLNICTWO WYŻSZE

2(52)/2018

Badania nad efektywnością i produktywnością szkół wyższych

REDAKCJA NAUKOWA NUMERU

dr hab. Joanna Wolszczak-Derlacz, prof. PG

ZESPÓŁ REDAKCYJNY

prof. dr hab. Marek Kwiek (redaktor naczelny)
dr Krystian Szadkowski (redaktor wykonawczy), dr Krzysztof Czarnecki
mgr Jakub Krzeski (sekretarz redakcji)

RADA NAUKOWA

dr hab. Dominik Antonowicz (Uniwersytet Mikołaja Kopernika w Toruniu),
prof. dr hab. Ireneusz Bialecki (Uniwersytet Warszawski), dr Dorota Dakowska (Université
Lumière Lyon-II), prof. Michael Dobbins (Uniwersytet Johanna Wolfganga Goethego
we Frankfurcie nad Menem), dr hab. Krzysztof Leja, prof. PG (Politechnika Gdańska),
prof. Peter Maassen (Uniwersytet w Oslo), dr Marta Shaw (Uniwersytet Jagielloński),
prof. Pavel Zgaga (Uniwersytet Lublański)

KOREKTA

Piotr Juskowiak

SKŁAD

Maciej Mikulewicz

Wersją pierwotną czasopisma (referencyjną) jest wydanie on-line
publikowane na stronie <http://pressto.amu.edu.pl/index.php/nsw>

Teksty do kolejnych numerów redakcja przyjmuje w trybie ciągłym.
Prosimy o nadsyłanie propozycji na adres korespondencyjny redakcji: nisw@amu.edu.pl

Pismo wydawane jest na licencji Creative Commons BY-NC-ND 4.0

ISSN 1231-0298

WYDAWCA

Centrum Studiów nad Polityką Publiczną
Uniwersytet im. Adama Mickiewicza
ul. Szamarzewskiego 89
60-568 Poznań
Tel. (+48 61) 829 22 80
Fax (+48 61) 829 21 47

Nakład: 100 egz.

Spis treści

JOANNA WOLSZCZAK-DERLACZ // Wprowadzenie. Badania nad efektywnością i produktywnością szkół wyższych	7
--	---

TŁUMACZENIE

JILL JOHNES // Pomiar efektywności	17
--	----

ARTYKUŁY

ANDRZEJ SZUWARZYŃSKI // Ocena efektywności procesu dyplomowania na studiach pierwszego stopnia w polskich publicznych uczelniach technicznych	85
PIOTR GRZEGORZ PIETRZAK, JOANNA BARAN // Efektywność i skuteczność kształcenia w publicznym szkolnictwie wyższym w Polsce	113
ŁUKASZ BRZEZICKI // Efektywność studiów Master of Business Administration (MBA) w Polsce	131
JOANNA WOLSZCZAK-DERLACZ // Efektywność szkół wyższych w Polsce na tle uczelni europejskich – analiza dla dziewiętnastu krajów	147
JACEK LEWICKI // Nowy algorytm podziału dotacji podstawowej dla uczelni akademickich. Pierwsze skutki zmian i wstępne wnioski	171

WYWIAD

JOANNA WOLSZCZAK-DERLACZ // Otwarty dostęp do statystyk uczelni powinien być czymś normalnym! Wywiad z Benedetto Leporim, koordynatorem European Tertiary Education Register (ETER)	191
---	-----

RECENZJA

ANNA MARIA KOLA // <i>Glauben schenken wollen...</i> czyli akredytować po niemiecku ...	205
---	-----

Table of contents

JOANNA WOLSZCZAK-DERLACZ // Introduction. Research on efficiency and productivity of higher education institutions	7
--	---

TŁUMACZENIE

JILL JOHNES // Efficiency measurement	17
---	----

ARTYKUŁY

ANDRZEJ SZUWARZYŃSKI // Assessment of the graduation process efficiency on the first degree studies in Polish public technical universities	85
PIOTR GRZEGORZ PIETRZAK, JOANNA BARAN // Efficiency and Effectiveness of Academic Teaching in Public Higher Education in Poland	113
ŁUKASZ BRZEZICKI // Efficiency of the Master of Business Administration (MBA) in Poland	131
JOANNA WOLSZCZAK-DERLACZ // Efficiency of Polish higher education institutions in comparison to European universities – an analysis for 19 countries ...	147
JACEK LEWICKI // A new algorithm of allocation for basic subsidy for universities in Poland. First results of changes and preliminary conclusions	171

WYWIAD

JOANNA WOLSZCZAK-DERLACZ // Open access to universities' data should be something normal! Interview with Benedetto Lepori, coordinator of the European Tertiary Education Register (ETER)	191
---	-----

RECENZJA

ANNA MARIA KOLA // <i>Glauben schenken wollen...</i> or accreditation in Germany ...	205
--	-----

Wprowadzenie. Badania nad efektywnością i produktywnością szkół wyższych

Tematyka numeru

Najnowszy numer *Nauki i Szkolnictwa Wyższego* poświęcony jest zagadnieniom związanym z efektywnością i produktywnością instytucji działających w sektorze edukacji ze szczególnym uwzględnieniem szkół wyższych. Problematyka dotycząca efektywności i produktywności funkcjonowania szkolnictwa wyższego jest obecna w debacie toczącej się zarówno na arenie międzynarodowej, jak i w Polsce. Presja na szkoły wyższe, aby efektywnie gospodarowały zasobami (głównie publicznymi), jest wywierana przez coraz większe gremia: przedstawiciele innych sektorów publicznych (Kwiec 2015), Ministerstwo Nauki i Szkolnictwa Wyższego oraz pozostałych interesariuszy. Bonaccorsi i Daraio (2007) ponad dziesięć lat temu stwierdzili, że posiadamy bardzo ograniczone informacje na temat „produkcji” wiedzy przez szkoły wyższe, jakie są czynniki ją determinujące i sprawdzające jej efektywność. Co się zmieniło od tego czasu, zwłaszcza biorąc pod uwagę, że obecnie badacze mają do dyspozycji coraz bardziej zaawansowane i różnorodne narzędzia pomiaru oraz bazy danych? Niewątpliwie badania nad efektywnością i produktywnością szkół wyższych są niezwykle istotne z punktu widzenia prowadzonej przez państwo polityki w stosunku do sektora szkolnictwa wyższego. Z drugiej strony podstawowe kwestie związane z samym definiowaniem efektywności i produktywności szkół wyższych, opomiarowaniem nakładów i wyników działalności prowadzonej przez jednostki oraz odpowiednim zastosowaniem metod służących do oceny efektywności i interpretacją wyników analiz budzą duże wątpliwości i wciąż napotykają trudności.

Dlatego numer otwiera tłumaczenie tekstu Jill Johnes pt. *Pomiar efektywności*, który został oryginalnie opublikowany jako rozdział w klasycznej pozycji: *International Handbook on the Economics of Education* (Johnes i Johnes 2004). W tekście

tym autorka wyprowadza pojęcie efektywności z teorii produkcji, przyjmując, że takie podejście może zostać zastosowane do instytucji działających na rynku edukacji. Tekst może sprawiać wrażenie technicznego, sporo w nim wykresów oraz wzorów, ale wydaje się, że jest to niezbędne przy precyzyjnym definiowaniu miar efektywności wraz z założeniami, które przyjmuje się do ich wyprowadzenia, a potem interpretowania. Można powiedzieć, że jest to konieczna i podstawowa baza wiedzy dla badaczy, którzy chcą się zajmować pomiarem efektywności i produktywności sektora edukacji. Nieznajomość założeń wykorzystywanych metod albo ich niepoprawne zastosowanie może skutkować jakością wniosków, które są całkowicie nieuzasadnione albo wręcz błędne. Było to niestety udziałem części tekstów przysłanych do tego numeru *Nauki i Szkolnictwa Wyższego*, które z tego powodu nie mogły zostać zaakceptowane do publikacji. W dalszej kolejności autorka przybliży różne metody wykorzystywane do pomiaru efektywności i produktywności uczelni i szkół oraz przedstawia pierwsze badania empiryczne z ich użyciem. Jak zauważa Johnes, mocną stroną badań nad efektywnością wykorzystujących metody wyprowadzone z teorii produkcji jest nie tylko możliwość stworzenia na ich podstawie rankingów instytucji, ale i dostarczenie bogatego zasobu informacji, które mogą zostać wykorzystane przez zarządzających uczelniami w celu poprawy ich funkcjonowania. Ponadto autorka przewidziała, że metody pomiaru efektywności będą w przyszłości rozwijane, a to wywoła zapotrzebowanie na badania empiryczne w zakresie ich zastosowań w kontekście jednostek z sektora edukacji. Sama autorka w późniejszych pracach rozwijała badania nad efektywnością szkół wyższych, poruszając m.in. kwestie istnienia ekonomii skali i różnorodności w sektorze szkolnictwa wyższego (Johnes i Johnes 2016) czy też wpływu fuzji uniwersytetów na efektywność sektora (Papadimitriou i Johnes 2018).

Badania nad efektywnością szkół wyższych prowadzone są także przez badaczy z Polski. Łukasz Brzezicki (2018) w sporządzonym zestawieniu badań polskiego szkolnictwa wyższego prowadzonych za pomocą metod nieparametrycznych wyszczególnia w sumie 60 pozycji. Do wszystkich autorów z listy zostało wysłane zaproszenie do składania tekstów do niniejszego specjalnego numeru *Nauki i Szkolnictwa Wyższego*. W drugiej części numeru zaprezentowano oryginalne artykuły naukowe. Pierwszy autorstwa Andrzeja Szuwarzyńskiego pt. *Ocena efektywności procesu dyplomowania na studiach pierwszego stopnia w polskich publicznych uczelniach technicznych* przedstawia analizę i ocenę funkcjonowania polskich uczelni technicznych, uwzględniając, wedle mojej wiedzy po raz pierwszy w badaniach tego typu dla polskich uczelni, problem rezygnacji ze studiów w trakcie pierwszego roku oraz terminowe uzyskanie dyplomów. W celu przybliżenia czytelnikom skali problemu warto przywołać statystyki podawane przez Szuwarzyńskiego, który stwierdza, że „około 40% publicznych środków inwestowanych w stacjonarne studia pierwszego

stopnia to raczej chybiona inwestycja” (Szuwarzyński 2018). Marnotrawstwo środków związane jest z tym, że inwestycja środków publicznych nie przynosi oczekiwanego zwrotu, bo studenci zrezygnowali ze studiów lub zwrot ten będzie odłożony w czasie w odniesieniu do studentów, którzy nie ukończyli studiów w terminie.

W kolejnym artykule autorstwa Piotra Pietrzaka i Joanny Baran, *Efektywność i skuteczność kształcenia w publicznym szkolnictwie wyższym w Polsce* (Pietrzak i Baran 2018), poruszana jest kwestia nie tylko samej efektywności procesu kształcenia, rozumianej tutaj jako stosunek wyników (liczba absolwentów drugiego stopnia) do nakładów (liczba nauczycieli akademickich, liczba pracowników niebędących nauczycielami akademickimi oraz wartość rzeczowych aktywów trwałych), ale także skuteczności dydaktyki. W pomiarze skuteczności procesów kształcenia, autorzy za zmienne diagnostyczne przyjęli: względny wskaźnik zarobków absolwentów, czas poszukiwania pracy etatowej przez absolwentów oraz względny wskaźnik bezrobocia absolwentów, które pochodzą z bazy Ekonomicznych Losów Absolwentów szkół wyższych – ELA. Autorzy na podstawie przeprowadzonych analiz stwierdzili, że przy tak zdefiniowanych nakładach i wynikach działalności uczelni nie istnieje zależność między efektywnością procesu kształcenia a jego skutecznością.

Kolejny artykuł dotyczy bardziej specjalistycznej kwestii. Łukasz Brzezicki w artykule pt. *Efektywność studiów Master of Business Administration (MBA) w Polsce* (Brzezicki 2018) zbadał efektywność 28 programów prestiżowych studiów MBA, które wedle mojej wiedzy nie były do tej pory oceniane w tego typu krajowych badaniach. W swoich analizach na temat wyników działalności studiów MBA autor zacerpnął informacje z rankingu studiów MBA prowadzonego przez *Perspektywy*. Stwierdza na ich podstawie, że studia tego typu charakteryzują się generalnie relatywnie niską efektywnością, a co za tym idzie, ich koszty funkcjonowania są względnie wysokie.

Natomiast w artykule mojego autorstwa pt. *Efektywność szkół wyższych w Polsce na tle uczelni europejskich – analiza dla dziewiętnastu krajów* przedstawiam analizę empiryczną efektywności szkół wyższych wraz z estymacją determinujących ją czynników w ujęciu międzynarodowym, porównując szkoły wyższe z Polski ze szkołami działającymi na rynku europejskim (Wolszczak-Derlacz 2018a). Wykorzystałam w tym celu metodę dwustopniową: w pierwszym kroku oszacowałam wskaźniki efektywności, a następnie zbadałam relację pomiędzy wybranymi zmiennymi a wskaźnikami efektywności. Na podstawie uzyskanych wyników wskazałam na pewne generalne mechanizmy i zależności. W szczególności na to, że uczelnie większe i starsze są bardziej efektywne, a porównując uczelnie o tej samej wielkości i roku założenia, można wyciągnąć wniosek, że te, które mają większy odsetek pracowników niebędących nauczycielami akademickimi i niższy udział przychodów zewnętrznych w budżecie charakteryzują się niższą efektywnością.

W kolejnej części czasopisma zaprezentowano wyniki badań autorstwa Jacka Lewickiego, który w artykule *Nowy algorytm podziału dotacji podstawowej dla uczelni akademickich: Pierwsze skutki zmian i wstępne wnioski* porusza kwestie związane ze skutkami wprowadzenia w 2016 roku nowego algorytmu podziału dotacji podstawowej dla uczelni akademickich (Lewicki 2018). Autor pokazuje w nim, jak zmiany w składowych algorytmu wpłynęły na dystrybucję środków finansowych pomiędzy poszczególnymi uczelniami oraz jakie działania „dostosowawcze” podejmują jednostki w celu uzyskania wyższej dotacji.

W numerze publikujemy również wywiad z Benedettem Leporim (koordynatorem European Tertiary Education Register (ETER)) pt. *Otwarty dostęp do statystyk uczelni powinien być czymś normalnym!*, w którym poruszona została kwestia wyzwań związanych z tworzeniem publicznie dostępnej i zharmonizowanej bazy obejmującej dane na temat poszczególnych instytucji szkolnictwa wyższego z krajów europejskich: European Tertiary Education Register (ETER) oraz możliwości wykorzystania jej do porównań międzynarodowych (Wolszczak-Derlacz 2018b). Benedetto Lepori przekonuje, że ogólny dostęp do danych na poziomie indywidualnych uczelni powinien być czymś normalnym.

Dyskusja uzyskanych wyników w świetle wykorzystanych danych i metod

Artykuły naukowe zamieszczone w niniejszym numerze poświęcone były głównie zagadnieniom związanym z pomiarem efektywności i produktywności szkół wyższych. Prezentują one różne aspekty ich funkcjonowania. Na podstawie zamieszczonych analiz widać, jakie wyzwania stoją przed badaczami szkolnictwa wyższego w zakresie pomiaru efektywności jednostek. Przede wszystkim szkoły wyższe prowadzą wieloraką działalność: są powołane do kształcenia studentów, prowadzenia badań naukowych oraz współpracy z szeroko rozumianym otoczeniem. Nie wszystkie z rezultatów działalności uczelni są łatwe do zmierzenia i opomiarowania, a co za tym idzie, utrudniona jest ocena efektywności działalności uczelni w tych sferach. Część z badaczy skupia się wyłącznie na działalności związanej z kształceniem studentów (np. Szuwarzyński 2018; Pietrzak i Baran 2018), inni starają się uchwycić także wyniki działalności naukowej prowadzonej przez pracowników, np. poprzez dodanie do zbioru wyników liczby publikacji (Wolszczak-Derlacz 2018a). Autorzy świadomi są, że wskaźniki czysto ilościowe powinny być zubożone o miary jakościowe (Szuwarzuński 2018; Brzezicki 2018). Już na podstawie tych kilku prac widać, że zbiór miar nakładów i wyników funkcjonowania szkół wyższych może być bardzo różny. Autorzy zamieszczonych w numerze prac zgodnie stwierdzają, że miary nakładów i wyników szkół

wyższych, które przyjmują w swoich analizach, są zgodne z praktykami stosowanymi w analogicznych badaniach oraz wyznaczone także przez dostępność danych. Za nakłady przyjmuje się przede wszystkim zasoby osobowe wyrażone za pomocą liczby nauczycieli akademickich oraz pracowników niebędących nauczycielami akademickimi (Pietrzak i Baran 2018; Szuwarzyński 2018; Wolszczak-Derlacz 2018a), zasoby finansowe takie jak: wartość przychodów (Wolszczak-Derlacz 2018a), koszty (Brzezicki 2018), wartość rzeczowych aktywów trwałych (Pietrzak i Baran 2018), ale także liczbę godzin zajęć (Brzezicki 2018). Pomiar wyników działalności szkół wyższych nie jest łatwy. Pietrzak i Baran (2018) oraz niżej podpisana (Wolszczak-Derlacz 2018a) jako wyniki działalności uczelni przyjmują liczbę absolwentów, Szuwarzyński (2018) traktuje w ten sposób wskaźniki na temat ukończenia studiów w terminie i wskaźnik rezygnacji ze studiów (jako wynik niepożądany), a Brzezicki (2018) wykorzystuje w tym samym celu miejsce programu studiów w rankingu *Perspektyw*, w których brane są pod uwagę takie aspekty jak preferencje pracodawców czy opinie absolwentów.

Autorzy zamieszczonych prac do oceny efektywności jednostek (szkół wyższych/programów studiów) zastosowali w głównej mierze metody nieparametryczne. W metodach tych efektywność rozumiana jest jako stosunek ważonej sumy wyników do ważonej sumy nakładów i ma ujęcie relatywne, gdzie poszczególne jednostki porównywane są do tych o najwyższej (wzorcowej) efektywności. Nieefektywność rozumiana jest jako możliwość uzyskania wyższych wyników przy danych nakładach lub tych samych wyników przy niższych nakładach. Wykorzystanie metod nieparametrycznych przez autorów omawianych tu prac nie jest zaskakująca, jeżeli weźmie się pod uwagę, że są to metody które „radzą” sobie z problemem wielu nakładów i wielu wyników – charakterystycznych dla działalności szkół wyższych. Niewątpliwą zaletą użytych metod nieparametrycznych jest to, że nie zakładają one *a priori*, jaka powinna być zależność pomiędzy nakładami a wynikami. Warto zauważyć, że autorzy są świadomi ograniczeń stosowanej metody, która, jak punktuje jej adwersarze, jest metodą ilościową, w której można zatracić aspekt wewnętrznego funkcjonowania uczelni, a tym samym specyfikę samego sektora. Z drugiej strony należy pamiętać, że szkoły wyższe pomimo cech specyficznych nie funkcjonują w oderwaniu od ekonomicznej rzeczywistości, zatrudniają bowiem czynniki wytwórcze, dostarczając usług i produktów, nawet jeżeli są one trudne do zmierzenia.

Badania zamieszczone w niniejszym numerze *Nauki i Szkolnictwa Wyższego* dostarczyły szeregu nowych informacji na temat funkcjonowania szkół wyższych w Polsce, np. odnośnie skali problemu nieukończenia studiów przez studentów w terminie i rezygnacji ze studiów (Szuwarzyński 2018), możliwości wykorzystania względnych wskaźników zarobków i bezrobocia absolwentów z bazy Ekonomicznych Losów

Absolwentów (Pietrzak i Baran 2018) czy też danych z bazy ETER do porównań międzynarodowych (Wolszczak-Derlacz 2018a). Jest to niewątpliwie wartość dodana przeprowadzonych analiz.

Warto zauważyć, że w zamieszczonych w niniejszym numerze artykułach naukowych każdy z autorów poruszał kwestie związaną z utrudnionym dostępem do danych. Jak widać, problem z gromadzeniem, dostępem i przetwarzaniem danych na poziomie indywidualnych uczelni stanowi wciąż istotne wyzwanie dla badaczy szkolnictwa wyższego.

Mam nadzieję, że niniejszy numer *Nauki i Szkolnictwa Wyższego* przybliży większemu gronu badaczy szkolnictwa wyższego rozmaite aspekty związane z metodami pomiaru efektywności i produktywności szkół wyższych oraz spopularyzuje badania empiryczne prowadzone w tym zakresie.

Joanna Wolszczak-Derlacz

Podziękowania

Prezentowany numer pisma nie ukazałby się bez wsparcia udzielonego w ramach kierowanego przez prof. Marka Kwieka projektu Ministerstwa Nauki i Szkolnictwa Wyższego „Doskonałość naukowa: konkurencyjność, mierzalność, umiędzynarodowienie (od badań empirycznych do reform szkolnictwa wyższego) (EXCELLENCE)” (Dialog umowa: 0021/DLG/2016/10).

Literatura

- Bonaccorsi A. i Daraio C. (red.) (2007). *Universities and Strategic Knowledge Creation: Specialization and Performance in Europe*. Cheltenham–Northampton, MA: Edward Elgar Publishing.
- Brzezicki, Ł. (2018). Efektywność studiów Master of Business Administration (MBA) w Polsce. *Nauka i Szkolnictwo Wyższe*. 2(52): 131–146.
- Brzezicki Ł. (2018). Zestawienie badań polskiego szkolnictwa wyższego prowadzonych za pomocą metody DEA i indeksu Malmquista w latach 2005–2017. https://www.researchgate.net/profile/Lukasz_Brzezicki [30.09.18].
- Johnes, J. (2018). Pomiar efektywności, przeł. J. Wolszczak-Derlacz i J. Krzeski. *Nauka i Szkolnictwo Wyższe*. 2(52): 17–81.
- Johnes G. i Johnes J. (red.) (2004). *International Handbook on the Economics of Education*, Cheltenham–Northampton, MA: Edward Elgar Publishing Ltd
- Johnes, G., Johnes, J. (2016). Costs, efficiency, and economies of scale and scope in the English higher education sector. *Oxford Review of Economic Policy*. 32(4): 596–614.

- Kwiek, M. (2015). Competing for Public Resources: Higher Education and Academic Research in Europe: A Cross-Sectoral Perspective (6–24). W: J.C. Brada, W. Bienkowski i W. Kuboniwa (red.), *International Perspectives on Financing Higher Education*. London: Palgrave Macmillan.
- Lewicki, J. (2018). Nowy algorytm podziału dotacji podstawowej dla uczelni akademickich. Pierwsze skutki zmian i wstępne wnioski. *Nauka i Szkolnictwo Wyższe*. 2(52): 171–187.
- Papadimitriou, M. i Johnes, J. (2018). Does merging improve efficiency? A study of English universities. *Studies in Higher Education*: 1-21.
- Pietrzak, P.G. i Baran, J. (2018). Efektywność i skuteczność kształcenia w publicznym szkolnictwie wyższym w Polsce. *Nauka i Szkolnictwo Wyższe*. 2(52): 113–130.
- Szuwarzyński, A. (2018). Ocena efektywności procesu dyplomowania na studiach pierwszego stopnia w polskich publicznych uczelniach technicznych. *Nauka i Szkolnictwo Wyższe*. 2(52): 85–111.
- Wolszczak-Derlacz, J. (2018a). Efektywność szkół wyższych w Polsce na tle uczelni europejskich – analiza dla dziewiętnastu krajów. *Nauka i Szkolnictwo Wyższe*. 2(52): 147–170.
- Wolszczak-Derlacz J. (2018b). Otwarty dostęp do statystyk uczelni powinien być czymś normalnym! Wywiad z Benedetto Leporim, koordynatorem European Tertiary Education Register (ETER). *Nauka i Szkolnictwo Wyższe*. 2(52): 191–202.

CYTOWANIE: Wolszczak-Derlacz, J. (2018). Wprowadzenie: Badania nad efektywnością i produktywnością szkół wyższych. *Nauka i Szkolnictwo Wyższe*. 2(52): 7–13. DOI: 10.14746/nisw.2018.2.0.

JOANNA WOLSZCZAK-DERLACZ – doktor habilitowany nauk ekonomicznych, profesor nadzwyczajny Politechniki Gdańskiej, kierownik Katedry Nauk Ekonomicznych na Wydziale Zarządzania i Ekonomii PG. Prowadziła badania naukowe m.in. na Katolickim Uniwersytecie w Leuven (Belgia) – pobyt w ramach stypendium Marie Curie, na Uniwersytecie w Glasgow (Wielka Brytania) – stypendium Dekaban Junior Fellowship, na Europejskim Instytucie Uniwersyteckim (European University Institute) we Florencji jako beneficjentka stypendium podoktorskiego Max Weber Fellowship oraz na Uniwersytecie Kalifornijskim w Berkeley w ramach programu „Mobilność Plus”. Jej zainteresowania naukowe skupiają się na teorii konwergencji gospodarczej, analizach produktywności i efektywności, ekonomii edukacji i rynkach pracy. Wyniki badań nad efektywnością i produktywnością szkół wyższych publikowała m.in. w *Research Policy*, *Journal of Productivity Analysis*, *Scientometrics*.

E-mail: jwo@zie.pg.gda.pl

TŁUMACZENIE

Jill Johnes

Pomiar efektywności*

STRESZCZENIE: Celem niniejszego rozdziału jest przede wszystkim identyfikacja i przedstawienie różnych metod pomiaru efektywności stosowanych w kontekście oceny funkcjonowania instytucji edukacyjnych w tym szkół wyższych. Ponadto dokonano przeglądu badań empirycznych wykorzystujących te metody na wszystkich poziomach edukacji.

SŁOWA KLUCZOWE: efektywność, szkolnictwo wyższe, edukacja, pomiar, metody nieparametryczne, DEA

1. Wstęp

W ostatnich latach coraz większym zainteresowaniem cieszą się badania związane z pomiarem funkcjonowania instytucji działających w sektorze edukacji. Dane, które odzwierciedlają różne aspekty funkcjonowania szkół i uniwersytetów, są coraz częściej regularnie publikowane w wielu krajach, zarówno na poziomie lokalnym, jak i krajowym. Dane te często wyrażone są w formie relacji przedstawiających efektywność uzyskiwanych rezultatów (np. stosunek uczniów, którzy uzyskali w danym roku minimalny poziom wymaganych osiągnięć do ogólnej liczby uczniów) lub efektywność wykorzystanych nakładów (np. koszt na studenta). W taki sposób łatwo

* Praca ukazała się oryginalnie jako: Johnes, J. (2004). Efficiency measurement. W: G. Johnes i J. Johnes (red.) *International Handbook on the Economics of Education* (613-742), Cheltenham–Northampton, MA: Edward Elgar Publishing Ltd. Dziękujemy autorce i wydawcy za zgodę na tłumaczenie. W nawiasach dla wybranych terminów podano także terminy i skróty w języku angielskim (przyp. tłum.).

jest stworzyć „tabele ligowe” szkół i uczelni, które będą wskazówką do dokonania wyborów oraz będą informować o alokacji zasobów.

Zagrożenia z używaniem takich wskaźników wydajności są obecnie dobrze znane. Po pierwsze, instytucje takie jak szkoły czy uniwersytety działają w różnych warunkach i w różnym środowisku, co nie jest należycie odzwierciedlone w prostych wskaźnikach. Po drugie, instytucje edukacyjne wytwarzają szereg rezultatów, zużywając wiele nakładów. Dlatego stosunek jednego wyniku do jednego nakładu nie obrazuje w pełni funkcjonowania organizacji, która prowadzi wieloraką działalność i może być stosowany tylko jako wskaźnik cząstkowy.


W konsekwencji opracowano wiele technik, które są stosowane w kontekście instytucji działających na rynku edukacji w celu zmierzenia rzeczywistej efektywności ich funkcjonowania. Narzędzia statystyczne przeszły od etapu estymacji za pomocą metody najmniejszych kwadratów (MNK) do analizy z użyciem stochastycznej metody granicznej, a proste wskaźniki wyrażone jako stosunek jednego wyniku do jednego nakładu zostały zastąpione poprzez złożone wskaźniki efektywności uzyskane dzięki metodzie programowania liniowego (ang. *linear programming* LP). Celem tego rozdziału jest przede wszystkim identyfikacja i przedstawienie różnych metod pomiaru efektywności stosowanych w kontekście edukacji oraz dokonanie przeglądu badań empirycznych wykorzystujących te metody na wszystkich poziomach edukacji w celu oceny ich użyteczności dla usługobiorców, menadżerów i decydentów. Rozdział składa się z sześciu części, a pierwszą z nich jest wstęp. W drugiej zaprezentowano niektóre z definicji efektywności wywodzące się z teorii produkcji. Części trzecia i czwarta zostały poświęcone metodom pomiaru efektywności, a piąta wadom stosowanych metod oraz przedstawieniu przykładów badań, w których zostały one wykorzystywane do oceny funkcjonowania instytucji edukacji. Wnioski przedstawiono w części szóstej.

2. Definicja efektywności

Przydatnym punktem wyjścia do dyskusji na temat pomiaru efektywności jest praca Farrella (1957) definiująca trzy typy efektywności, które zostaną przedstawione poniżej. Weźmy pod uwagę firmę, która używa nakładów x_1 i x_2 , aby wyprodukować wynik y w wielkości opisanej przez punkt P na Rysunku 1.1. W kontekście edukacji firmą może być szkoła, która produkuje absolwentów (y) zużywając nakłady: pracowników (x_1) oraz uczniów (x_2). Krzywa SS' przedstawia izokwantę łączącą wszystkie kombinacje x_1 i x_2 , z których efektywna firma może wybrać poziom produkcji przy zastosowaniu stałych korzyści skali (ang. *constant returns to scale* CRS). Efektywność techniczna (TE) firmy wytwarzającej w punkcie P jest zdefiniowana jako procent nakładów wykorzystywanych przez firmę, który jest niezbędny do wyprodukowania wyników w punkcie P , i można ją zapisać jako:

$$TE = \frac{OQ}{OP}.$$

Rysunek 1.1 Pomiar efektywności technicznej zorientowanej na nakłady



Wielkość $1-TE$ jest miarą nieefektywności technicznej i oznacza procent, o jaki mogłyby zostać zmniejszone nakłady bez zmniejszania poziomu produkcji w punkcie P (Worthington 2001). Kolejna miara efektywności może zostać zdefiniowana przez wprowadzenie cen nakładów. Na rysunku zostały one zaznaczone jako prosta AA' , która przedstawia stosunek cen dwóch nakładów¹. Punkt Q' reprezentuje zarówno efektywność techniczną, jak i efektywność alokacyjną (lub cenową), przedstawia ideę, że nakłady są używane w optymalnych (minimalizujących koszty) proporcjach przy danych cenach nakładów. Ponieważ koszty produkcji w punkcie Q' są także reprezentowane przez punkt R , który znajduje się na prostej AA' , miara efektywności alokacyjnej (ang. *allocative efficiency AE*) firmy jest zdefiniowana jako:

$$AE = \frac{OR}{OQ}.$$

Punkty Q i Q' są efektywne technicznie, ale koszty produkcji w punkcie Q' są częścią OR/OQ kosztów w punkcie Q . Dlatego redukcja kosztów produkcji (przy danych cenach nakładów), która mogłaby zostać osiągnięta przy użyciu kosztowo efektywnych proporcji nakładów, jest prezentowana przez odcinek RQ . Wreszcie,


¹ Zakładamy, że ceny nakładów są dane, a firma nie działa w warunkach monopsonu.

efektywność całkowita (ekonomiczna) (ang. *overall efficiency OE*) danej firmy jest definiowana jako:

$$OE = \frac{OR}{OP}.$$

Efektywność całkowita jest wynikiem efektywności technicznej i alokacyjnej. Wielkość $1-OE$ jest miarą nieefektywności, a odcinek RP prezentuje zmniejszenie kosztów produkcji, które mogłyby zostać osiągnięte przez firmę przy przejściu z punktu P do punktu, gdzie następuje minimalizacja kosztów: Q' .

Rysunek 1.2 Pomiar efektywności technicznej zorientowanej na wyniki



Podjęcie przyjęte przez Farrell'a (1957) jest zorientowane na nakłady, ponieważ ma na celu odpowiedzieć na pytanie: o ile firma może proporcjonalnie zmniejszyć nakłady bez zmiany ilości wyprodukowanych wyników? Można także zastosować podejście zorientowane na wyniki, w którym szuka się odpowiedzi na pytanie: o ile można proporcjonalnie zwiększyć produkcję dla danej wielkości nakładów? Podejście nakierowane na wyniki jest zilustrowane na Rysunku 1.2. W tym wypadku firma produkuje dwa wyniki: y_1 i y_2 z danego nakładu x . Przykładowo może to być uniwersytet, którego wynikami są rezultaty działalności związanej z kształceniem studentów (y_1) oraz wyniki działalności naukowej (y_2), a nakładem jest czas pracy pracowników uczelni (x). Krzywa ZZ' jest krzywą możliwości produkcyjnych, a efektywność techniczna jest stosunkiem uzyskanej produkcji do tej, która jest maksymalnie możliwa do uzyskania:

$$TE = \frac{OP}{OM}.$$

W tym przypadku $1-TE$, który jest miarą nieefektywności, określa, o ile może wzrosnąć produkcja bez zwiększania poziomu nakładów obserwowanych w punkcie produkcji P . Efektywność alokacyjna jest wyznaczona przez określenie linii tych samych przychodów: DD^2 . Punkt M' jest zarówno efektywny technicznie, jak i alokacyjny. Ponieważ w punkcie M' mamy takie same przychody jak w punkcie N wzdłuż linii DD' , efektywność alokacyjna może zostać zmierzona jako:

$$AE = \frac{OM}{ON}.$$

Punkty M i M' są efektywne technicznie, ale przychody z produkcji w punkcie N są stosunkiem OM/ON części przychodów w punkcie M' . Zwiększenie przychodów, które firma mogłaby osiągnąć poprzez produkcję właściwej (maksymalizującej przychody) proporcji wyników jest opisana jako odcinek MN . Efektywność całkowita jest zatem:

$$OE = \frac{OP}{ON},$$

i jest wynikiem efektywności technicznej i alokacyjnej. Zatem $1-OE$ to miara nieefektywności, a odległość PN wskazuje, o ile firma mogłaby zwiększyć przychody poprzez przesunięcie punktu produkcji z punktu P do punktu M' – maksymalizacji przychodów.


W przypadku stałych korzyści skali miary efektywności technicznej uzyskane przy orientacji na nakłady oraz przy orientacji na wyniki są takie same. Różnią się one jednak w warunkach zmiennych korzyści skali (ang. *variable returns to scale* VRS).

Miary efektywności określone za pomocą Rysunków 1.1 i 1.2 nie zawierają żadnej informacji na temat preferencji. W celu zdefiniowania efektywności społecznej (ang. *social efficiency* SE) należy dodać funkcję dobrobytu społecznego przeprowadzoną przez dwa wyniki. Dokonano tego na Rysunku 1.3, na którym dodano krzywą JJ' , która opisuje preferencje pomiędzy dwoma rezultatami. Idealny punkt produkcji z punktu widzenia dobrobytu społecznego znajduje się w punkcie L' . Jednak użyteczność przy zestawieniu wyników w punkcie L' jest równa użyteczności pochodzącej z produktów w punkcie L , więc miara efektywności społecznej dla firmy znajdującej się w punkcie P , która jest zdefiniowana jako stosunek obserwowanego produktu do poziomu produkcji oczekiwanej przez społeczeństwo, jest równa:

² Zakładamy, że ceny wyników są dane, a firma nie jest monopolistą.

$$SE = \frac{OP}{OL}.$$

Rysunek 1.3 Pomiar efektywności społecznej zorientowanej na wyniki




Zauważmy, że z tej definicji wynika, że możliwa jest efektywność społeczna bez efektywności alokacyjnej lub efektywność alokacyjna bez efektywności społecznej.

Wszystkie dotychczasowe definicje efektywności zostały oparte na założeniu stałych korzyści skali. Założenie to jest dość restrykcyjne, ponieważ firma może być nieefektywna z powodu nieodpowiedniej wielkości. Każdy rodzaj nieefektywności wynikający z nieodpowiedniej skali produkcji stanowił do tej pory część nieefektywności technicznej. Na Rysunku 1.4 firma, która produkuje jeden rezultat y z jednego nakładu x znajduje się w punkcie P , gdzie granica produkcji wynosi OT . Dla porównania granica produkcji CRS jest również zaznaczona na rysunku jako prosta OT' .

W modelu zorientowanym na nakłady (gdzie wyniki są stałe, a nakłady ulegają zmianie) efektywność techniczna jest mierzona przy użyciu poziomej odległości danego punktu od granicy produkcji. Efektywność techniczna jest wyrażona jako: $TE_{CRS}^I = y'B'/y'P$. Dla przypadku zorientowania na wyniki (gdzie nakłady są stałe, a wyniki mogą się zmieniać) efektywność techniczna jest wyznaczona jako pionowa odległość od granicy produkcji. W tym wypadku efektywność techniczna jest liczona jako stosunek: $TE_{CRS}^O = x'P/x'A'$. Miary te mogą zostać porównane do tych

wyznaczonych przy zmiennych korzyściach skali (VRS). Dla wariantu orientacji na nakłady efektywność techniczna wynosi teraz: $TE_{VRS}^I = y'B/y'P$, a dla zorientowanego na wyniki: $TE_{VRS}^O = x'P/x'A$.

Rysunek 1.4 Mierzenie efektywności skali produkcji



Dwie rzeczy stają się teraz oczywiste. Po pierwsze, dla wariantu VRS wartość efektywności technicznej zależy, czy została zastosowana orientacja na wyniki, czy na nakłady. Miary te są takie same w przypadku CRS. Po drugie, przy danej orientacji efektywność techniczna firmy jest wyższa przy przyjęciu założenia VRS niż ta obliczona przy założeniu funkcji produkcji o stałych korzyściach skali. Prawdliwość ta jest niezależna od orientacji i dla wszystkich możliwych punktów produkcji znajdujących się wewnątrz lub na granicy funkcji produkcji VRS z wyjątkiem punktu C (gdzie dwie miary będą takie same). Dlatego można stwierdzić, że przy założeniu CRS techniczna nieefektywność wynika z nieodpowiedniego rozmiaru firmy (odcinek $B'B$ dla orientacji na nakłady i AA' dla orientacji na wyniki dla firmy w punkcie P). Dalej można wykazać, że dla firmy w punkcie P :

$$TE_{CRS}^I = \frac{y'B'}{y'P} = \frac{y'B}{y'P} * \frac{y'B'}{y'B},$$

gdzie pierwszy komponent: $\frac{y'B}{y'P} = TE_{VRS}^I$ wyznacza efektywność techniczną zorientowaną na nakłady przy założeniu VRS, a drugi jest miarą efektywności przy założeniu CRS i zorientowaniu na nakłady dla hipotetycznej firmy znajdującej się w punkcie B . Jest to zatem miara nieefektywności wynikająca z rozbieżności między

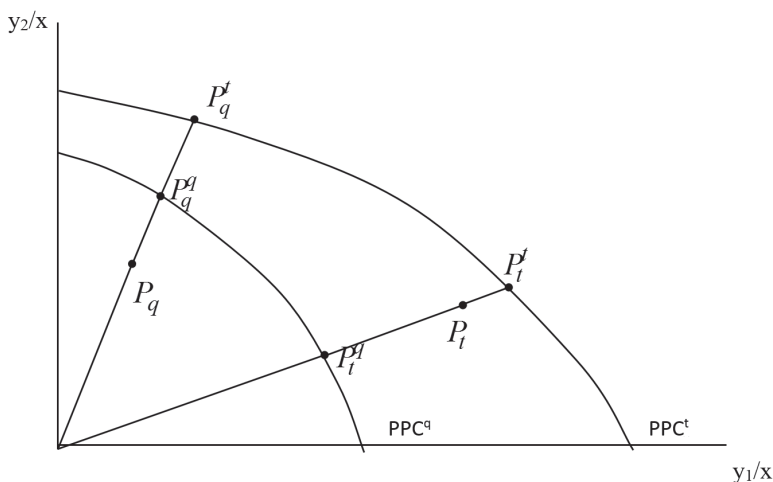
rzeczywistą skalą działalności jednostki w punkcie B i najbardziej produktywną. Może być ona stosowana do oceny efektywności skali produkcji. Dlatego dla orientacji na nakłady całkowita efektywność techniczna firmy w punkcie P jest wyznaczona przez stosunek $y'B'/y'P$, co może być podzielone na efektywność czysto techniczną – $y'B'/y'P$ i efektywność skali produkcji – $y'B'/y'B$. Podobnie przy orientacji na wyniki:

$$TE_{CRS}^O = \frac{x'P}{x'A'} = \frac{x'A}{x'A'} * \frac{x'P}{x'A},$$

całkowita efektywność techniczna firmy jest wyznaczona przez stosunek $x'P/x'A'$, co może być podzielone na efektywność czysto techniczną – $x'P/x'A$ i efektywność skali produkcji – $x'A/x'A'$.

Dotychczas analizowaliśmy efektywność firmy w danym punkcie czasu, dla których różnice w osiąganych wynikach były konsekwencją różnic w efektywnościach. Nie uwzględniano do tej pory roli różnych technologii produkcji. W tym celu rozważmy firmę P , która produkuje dwa wyniki y_1 i y_2 z danego poziomu nakładu x w dwóch okresach czasu, gdzie q to okres początkowy, a t – okres końcowy. Na rysunku 1.5 PPC^q i PPC^t przedstawiają odpowiednio możliwości produkcyjne firmy P w dwóch okresach czasu. W rozważanym okresie nastąpił postęp technologiczny (PPC^t jest przesunięta na zewnątrz w stosunku do PPC^q) w sposób nieneutralny, ponieważ nastąpiło nierównoległe przesunięcie krzywej. Punkt produkcji firmy P przesunął się z P_q do P_t . Ponieważ żaden z tych punktów nie leży na krzywej możliwości produkcyjnych, oznacza to, że firma jest technicznie nieefektywna w obu okresach czasu.

Rysunek 1.5 Pomiar zmian efektywności w czasie, orientacja na wyniki



Rozważmy najpierw oba punkty w czasie oddzielnie. Efektywność techniczna firmy (zorientowana na wyniki według definicji Farella przedstawionej w części 2) w okresie q (TEq) i t (TEt) może zostać zapisana odpowiednio jako: $TE_q = OP_q / OP_q^q$ oraz $TE_t = OP_t / OP_t^t$. Zdefiniujmy funkcję odległości wyników dla okresu q ($D_O^q(x_q, y_{1q}, y_{2q})$), gdzie subskrypt q przy nakładach i wynikach oznacza wielkości z okresu q jako odwrotność maksymalnej wielkości, o którą mogą być zwiększone wyniki (przy stałych nakładach) tak, aby wciąż znajdowały się w zbiorze możliwych do osiągnięcia kombinacji. Jest to wartość mierzona przez TE_q , gdzie $TE_q = D_O^q(x_q, y_{1q}, y_{2q})$. Podobnie dla TEt jest to $TE_t = D_O^t(x_t, y_{1t}, y_{2t})$, gdzie $D_O^t(x_t, y_{1t}, y_{2t})$ oznacza funkcję odległości wyników w okresie t , a indeks t oznacza wielkość nakładów i wyników w okresie t .

Zbadanie, w jaki sposób produktywność firmy zmieniła się w danym okresie czasu, może zostać dokonane na dwa sposoby: dwa punkty produkcji można porównać przy użyciu technologii z okresu q jako technologii bazowej albo technologii z okresu t jako bazowej. Przy pierwszym podejściu efektywność techniczna firmy w punkcie P_t jest mierzona przez porównanie uzyskanych wyników produkcji w okresie t do wyników maksymalnych, jakie mogłyby zostać osiągnięte przy założeniu technologii q (OP_t / OP_t^q , które może być wyrażone jako $D_O^q(x_t, y_{1t}, y_{2t})$) i jest porównane do technicznej efektywności firmy w punkcie, gdzie uzyskany wynik produkcji w okresie q do wyniku, jaki mógłby zostać uzyskany przy założeniu technologii z okresu q (co może zostać zapisane jako: OP_q / OP_q^q i wyrażone: $D_O^q(x_q, y_{1q}, y_{2q})$). Wzrost produktywności w tych dwóch okresach czasu przy użyciu technologii q jako bazowej jest w literaturze nazywany indeksem Malmquista (Malmquist 1963) zorientowanym na wyniki, zdefiniowanym w stosunku do technologii bazowej (M_O^q) i który może zostać zapisany jako:

$$M_O^q = \frac{D_O^q(x_t, y_{1t}, y_{2t})}{D_O^q(x_q, y_{1q}, y_{2q})} = \frac{OP_t / OP_t^q}{OP_q / OP_q^q} . \quad (1.1)$$

Alternatywnie techniczna efektywność firmy w punkcie Pt jest mierzona jako wynik w okresie t w stosunku do maksymalnej produkcji, jaka mogłaby zostać uzyskana przy założeniu technologii z okresu t (może to zostać zapisane jako OP_t / OP_t^t i wyrażone przez odległość: $D_O^t(x_t, y_{1t}, y_{2t})$). Jest on porównywany do efektywności technicznej firmy w punkcie Pq mierzonej jako uzyskane wyniki w okresie q w stosunku do tych, które mogłyby zostać osiągnięte przy technologii z okresu t (OP_q / OP_q^t wyrażone jako: $D_O^t(x_q, y_{1q}, y_{2q})$). Miara wzrostu produktywności pomiędzy dwoma punktami w czasie przy użyciu technologii t jako bazowej jest znana jako indeks Malmquista zorientowany na wyniki, zdefiniowany w stosunku do okresu końcowego (M_O^t) i który może być wyrażony równaniem:

$$M'_O = \frac{D'_O(x_t, y_{1t}, y_{2t})}{D'_O(x_q, y_{1q}, y_{2q})} = \frac{OP_t / OP'_t}{OP_q / OP'_q} . \quad (1.2)$$

Dysponujemy dwoma sposobami pomiaru zmian produktywności w czasie, ale nie wiadomo która miara powinna zostać użyta, ponieważ wybór technologii z danego okresu czasu jest arbitralny. Problem ten zostaje rozwiązany poprzez zastosowanie indeksu Malmquista (Mo), który jest średnią geometryczną z indeksów M^q_O i M^t_O (Färe i in. 1994):

$$\begin{aligned} M_O &= \left[M^q_O \cdot M^t_O \right]^{\frac{1}{2}} = \left[\frac{D^q_O(x_t, y_{1t}, y_{2t})}{D^q_O(x_q, y_{1q}, y_{2q})} \cdot \frac{D^t_O(x_t, y_{1t}, y_{2t})}{D^t_O(x_q, y_{1q}, y_{2q})} \right]^{\frac{1}{2}} \\ &= \left[\frac{OP_t / OP^q_t}{OP_q / OP^q_q} \cdot \frac{OP_t / OP^t_t}{OP_q / OP^t_q} \right]^{\frac{1}{2}} . \quad (1.3) \end{aligned}$$

Indeks może zostać przekształcony do postaci:


$$\begin{aligned} M_O &= \frac{D^t_O(x_t, y_{1t}, y_{2t})}{D^q_O(x_q, y_{1q}, y_{2q})} \left[\frac{D^q_O(x_t, y_{1t}, y_{2t})}{D^t_O(x_t, y_{1t}, y_{2t})} \cdot \frac{D^q_O(x_q, y_{1q}, y_{2q})}{D^t_O(x_q, y_{1q}, y_{2q})} \right]^{\frac{1}{2}} \\ &= \frac{OP_t / OP^t_t}{OP_q / OP^q_q} \left[\frac{OP_t / OP^q_t}{OP_t / OP^t_t} \cdot \frac{OP_q / OP^q_q}{OP_q / OP^t_q} \right]^{\frac{1}{2}} . \quad (1.4) \end{aligned}$$

Pierwszym składnikiem równania (1.4) jest stosunek efektywności technicznej w okresie t (okres końcowy) do efektywności technicznej z okresu q (okres początkowy), mierzy on zatem zmianę w efektywności technicznej między tymi dwoma okresami. Jeżeli indeks wynosi 1, oznacza to, że brak jest zmian efektywności technicznej w omawianym czasie. Jeżeli indeks jest większy (mniejszy) od 1, to nastąpił wzrost (spadek) produktywności.

Drugi składnik równania mierzy zmianę w technologii produkcji (tzn. przesunięcie granicy produkcji) między dwoma okresami q i t . Jest średnią geometryczną zmian technologii między dwoma ocenianymi okresami odpowiednio w punktach x_t i x_q . Ten składnik ma wartość 1, gdy nie nastąpiły zmiany w technologii produkcji. Jest większy niż 1 (mniejszy niż 1), jeśli zmiana technologii produkcji miała pozytywny (negatywny) efekt.

Indeks produktywności Malmquista można również obliczyć dla modelu zorientowanego na nakłady. Musimy wtedy najpierw zdefiniować funkcję odległości zorientowaną na nakłady, która przedstawia, o ile maksymalnie można zmniejszyć nakłady (przy stałych wynikach), pozostając w obrębie możliwego do osiągnięcia zbioru kombinacji produkcji. Na Rysunku 1.6 firma używa teraz dwóch nakładów – x_1 i x_2 do produkcji wyniku, y , I_q i I_t odnoszą się do izokwant odpowiednio z okresu q i t . W omawianym okresie czasu nastąpił postęp technologiczny zobrazowany przez różne położenie: izokwanty I_q i I_t . Produkcja w okresie q i t oznaczona punktami P_q i P_t nie jest efektywna technicznie, ponieważ w obu przypadkach punkty są poza odpowiednimi izokwantami. Odległość funkcji nakładów dla firmy w okresie q wynosi: $D^q_l(x_{1q}, x_{2q}, y_q) = OP_q / OP^q_q$. Jest to odwrotność miary technicznej efektywności Farrella orientowanej na nakłady dla firmy P w okresie q . Podobnie funkcja odległości dla firmy P w okresie t jest wyrażona jako: $D^t_l(x_{1t}, x_{2t}, y_t) = OP_t / OP^t_t$.

Rysunek 1.6 Pomiar zmian efektywności w czasie, orientacja na nakłady



Podobnie jak w przypadku podejścia zorientowanego na wyniki pomiar zmian produktywności w czasie może być rozpatrywany dwojako: dwa punkty produkcji mogą być porównywane przy założeniu technologii z okresu q lub z okresu t jako technologii bazowej. W pierwszym przypadku techniczna nieefektywność firmy w punkcie P_q jest obliczana poprzez porównanie nakładu z okresu q w stosunku do minimalnego nakładu przy założeniu technologii z okresu q (tj. $OP_q / OP^q_q = D^q_l(x_{1q}, x_{2q}, y_q)$), a następnie odniesiona do technicznej nieefektywności w punkcie P_t mierzonej jako porównanie

nakładów z okresu t w stosunku do minimalnych nakładów przy założeniu technologii q (tj. OP_t/OP_q^q zapisany jako $D_I^q(x_{1q}, x_{2q}, y_q)$). Pomiar zmian produktywności w czasie przy użyciu technologii z okresu q jako technologii bazowej określony jest indeksem Malmquista (M_I^q), który obliczamy jako:

$$M_I^q = \frac{D_I^q(x_{1q}, x_{2q}, y_q)}{D_I^q(x_{1t}, x_{2t}, y_t)} = \frac{OP_q/OP_q^q}{OP_t/OP_t^q}. \quad (1.5)$$

Natomiast w drugim wariancie nieefektywność firmy w punkcie P_q jest obliczana poprzez porównanie rzeczywiście poniesionych nakładów w okresie q względem wymaganych minimalnych nakładów przy założeniu technologii z okresu t , tj. OP_q/OP_t^q zapisane jako odległość $D_I^t(x_{1q}, x_{2q}, y_q)$. Jest to porównywane z nieefektywnością techniczną firmy w punkcie P_t wyznaczoną przez porównanie nakładów z okresu t do minimalnej wartości nakładów przy zastosowaniu technologii z okresu t (tj. $OP_t/OP_t^t = D_I^t(x_{1t}, x_{2t}, y_t)$). Indeks Malmquista zorientowany na nakłady wyrażony w stosunku do technologii z okresu t (M_I^t) jest dany jako:

$$M_I^t = \frac{D_I^t(x_{1q}, x_{2q}, y_q)}{D_I^t(x_{1t}, x_{2t}, y_t)} = \frac{OP_q/OP_t^q}{OP_t/OP_t^t}. \quad (1.6)$$

Z racji wątpliwości w związku z odpowiedzią na pytanie, z którego okresu powinna być użyta technologia jako bazowa, czy to z okresu początkowego, czy z końcowego, podobnie jak w poprzednim przypadku oblicza się indeks Malmquista, tym razem zorientowany na nakłady M_I jako średnią geometryczną z indeksów M_I^q i M_I^t :

$$M_I = \left[M_I^q \cdot M_I^t \right]^{\frac{1}{2}} = \left[\frac{D_I^q(x_{1q}, x_{2q}, y_q)}{D_I^q(x_{1t}, x_{2t}, y_t)} \cdot \frac{D_I^t(x_{1q}, x_{2q}, y_q)}{D_I^t(x_{1t}, x_{2t}, y_t)} \right]^{\frac{1}{2}} \\ = \left[\frac{OP_q/OP_q^q}{OP_t/OP_t^q} \cdot \frac{OP_q/OP_t^q}{OP_t/OP_t^t} \right]^{\frac{1}{2}}. \quad (1.7)$$

Co może zostać zapisane jako:

$$M_I = \frac{D_I^q(x_{1q}, x_{2q}, y_q)}{D_I^t(x_{1t}, x_{2t}, y_t)} \left[\frac{D_I^t(x_{1t}, x_{2t}, y_t)}{D_I^q(x_{1t}, x_{2t}, y_t)} \cdot \frac{D_I^t(x_{1q}, x_{2q}, y_q)}{D_I^q(x_{1q}, x_{2q}, y_q)} \right]^{\frac{1}{2}}$$

$$= \frac{OP_q / OP_q^q}{OP_t / OP_t^t} \left[\frac{OP_t / OP_t^t}{OP_t / OP_t^q} \cdot \frac{OP_q / OP_q^t}{OP_q / OP_q^q} \right]^{\frac{1}{2}}. \quad (1.8)$$

Składowe tego indeksu są interpretowane w sposób odwrotny do komponentów indeksu zorientowanego na wyniki z równania 1.4. W szczególności $D_I^q(x_q, y_q) / D_I^t(x_t, y_t)$ oznacza zmianę technicznej efektywności pomiędzy okresem q i t i wynosi 1. Jeżeli zmiana nie nastąpiła dla wartości mniejszej (większej) od 1 oznacza odpowiednio wzrost (spadek) efektywności technicznej.

Drugi składnik:

$$\left[\frac{D_I^t(x_t, y_t)}{D_I^q(x_t, y_t)} \cdot \frac{D_I^t(x_q, y_q)}{D_I^q(x_q, y_q)} \right]^{\frac{1}{2}},$$

odpowiada zmianom w technologii produkcji pomiędzy okresem q i t , wynosi 1 dla braku zmian, a jest większy niż 1 (mniejszy niż 1), gdy zmiany były pozytywne (negatywne).

W tej części rozdziału przedstawione zostały definicje efektywności, które mogą znaleźć zastosowanie w pomiarze działalności instytucji z sektora edukacji. W praktyce dane potrzebne do analizy funkcji produkcji w kontekście instytucji edukacji dostępne są bądź na poziomie zagregowanym (np. dla szkół, uniwersytetów, na poziomie lokalnych władz odpowiedzialnych za funkcjonowanie sektora edukacji, regionów), bądź na poziomie zdezagregowanym, na poziomie uczniów i studentów. Przedstawione metody mogą być wykorzystywane w każdej z opisanych sytuacji (zarówno przy wykorzystaniu danych zagregowanych i zdezagregowanych), dlatego zostaną one przedstawione oddzielnie w kolejnych dwóch częściach.

3. Techniki pomiaru efektywności: analiza na poziomie jednostki produkcyjnej

Istnieją dwa podstawowe podejścia do pomiaru efektywności: statystyczne (lub ekonometryczne) oraz podejście niestatystyczne (programowanie). Rozróżnienie między tymi dwoma podejściami związane jest z przyjętymi założeniami. Po pierwsze, podejście statystyczne zakłada, że efektywność (różnica pomiędzy osiąganymi przez firmę wynikami a tymi, które mogłyby zostać uzyskane, gdyby firma znajdowała się na granicy produkcji) jest rozłożona według specyficznego rozkładu (Førsund i in. 1980). Podejście statystyczne jest często (ale nie zawsze) podejściem

parametrycznym, dla którego przyjmuje się funkcję produkcji, dla przykładu funkcję produkcji typu Cobba-Douglasa (Sengupta 1999). Parametryczne metody statystyczne za pomocą zapisów matematycznych opisują technologię produkcji i szacują parametry danej funkcji produkcji, których statystyczna istotność wyznaczana jest przy użyciu błędów standardowych (Schmidt 1985/1986). Jednakże w podejściu tym dochodzi do tego, że wszelkie błędy związane np. z nieprawidłową specyfikacją funkcji czy też z błędnymi założeniami co do rozkładu nieefektywności włączone są do miar efektywności (Lovell 1993). Ponadto podejście parametryczne nie jest łatwe do zastosowania w sytuacji, gdy mamy do czynienia z produkcją wielu wyników z wielu nakładów.

W podejściu niestatystycznym nie przyjmuje się założeń na temat rozkładu nieefektywności. Ponadto często (ale nie zawsze) jest ono nieparametryczne, co oznacza, że dane na temat nakładów i wyników są używane do wyznaczenia (poprzez programowanie liniowe) wypukłej powierzchni odpowiadającej granicy efektywności (Sengupta 1999). Podejście niestatystyczne, nieparametryczne pozwala uniknąć problemów związanych z błędną specyfikacją (zarówno funkcji produkcji, jak i rozkładów efektywności), ponieważ w metodach tych rozkłady nie są określane. Dodatkowo metody programowania z łatwością można wykorzystać w sytuacjach, w których występuje zarówno wiele nakładów, jak i wiele wyników. Wadą metod niestatystycznych, nieparametrycznych jest to, że nie dostarczają one oszacowań statystycznej istotności parametrów (Geva-May 2001). Inną wadą jest to, że wypukła powierzchnia jest wyznaczana na podstawie informacji dotyczących ograniczonej liczby obserwacji znajdujących się w próbie.

Wreszcie rozróżnienie między metodami dotyczy ich stochastycznej lub deterministycznej natury (Schmidt 1985/1986; Lovell 1993). Podejście stochastyczne opiera się na założeniu, że odchylenia od funkcji produkcji są wynikiem nie tylko nieefektywności, ale także błędów pomiaru, losowych szoków i zakłóceń statystycznych (Lovell 1993; Ondrich i Ruggiero 2001). Dlatego celem modeli stochastycznych jest podzielenie reszt na dwa składniki: jeden związany z nieefektywnością, drugi będący składnikiem czysto losowym. W praktyce wiąże się to z założeniem określonego rozkładu dla każdego ze składników. Dlatego też metody stochastyczne mają zaletę, że pomiar efektywności nie obejmuje losowych szoków ani błędów pomiarów, ale mogą na nie wpływać błędy złej specyfikacji modelu. Natomiast w metodach deterministycznych przyjmuje się, że każde odchylenie obserwowanego wyniku od granicy produkcji jest wyłącznie konsekwencją nieefektywności (Lovell 1993; Ondrich i Ruggiero 2001). Podczas gdy w metodach deterministycznych brak jest błędów związanych z błędną specyfikacją (ponieważ nie ma w ogóle specyfikacji), to ich wadą jest to, że wszelkie błędy w pomiarze lub błędy stochastyczne są włączone do pomiaru efektywności

Podsumowując, metody pomiaru efektywności mogą być podzielone na statystyczne lub niestatystyczne, parametryczne lub nieparametryczne, deterministyczne lub stochastyczne. Z możliwych wariantów najczęściej występujące to: parametryczne metody statystyczne (deterministyczne lub stochastyczne) i deterministyczne niestatystyczne metody nieparametryczne. W dalszej części tekstu przedstawione zostaną metody najczęściej wykorzystywane wraz z ich rozwojem w kontekście pomiaru efektywności podmiotów edukacji.

Parametryczne metody statystyczne

Odchylenia od granicy są deterministyczne. Załóżmy, że producent i zamienia m nakładów (x) w wynik (y), a proces ten jest opisany równaniem (1.9):

$$y_i = f(x_{i1}, \dots, x_{im}) e^{-u_i} \quad (1.9)$$

dla technologii typu Cobba-Douglasa, można zapisać jako:

$$\ln(y_i) = \ln[f(x_{i1}, \dots, x_{im})] - u_i = \alpha_0 + \sum_{j=1}^m \alpha_j \ln x_{ij} - u_i \quad (1.10)$$

gdzie reszty $-u_i$ spełniają warunek $-u_i \geq 0$ i wyznaczają efektywność producenta i .

Techniczna efektywność producenta i w warunkach zorientowania na wyniki pokazana jest na Rysunku 1.2 i wyznaczona jest jako stosunek aktualnych wyników producenta i do maksymalnych możliwych do osiągnięcia i pokazanych przez granicę produkcji. Dlatego z równania 1.9 efektywność techniczna jest liczona jako:

$$TE_i = \frac{y_i}{f(x_{i1}, \dots, x_{im})} = e^{-u_i} \quad (1.11)$$


Przy założeniu, że reszty są deterministyczne, istnieją różne możliwe sposoby szacowania granicy produkcji w równaniu (1.9), a tym samym szacowania efektywności technicznej. Po pierwsze, zakładając rozkład dla danej funkcji produkcji (np. Cobba-Douglasa jak w przykładzie powyższym), parametry są szacowane przy użyciu metody najmniejszych kwadratów (MNK). Punkt przecięcia jest następnie przesuwany, do czasu aż wszystkie reszty (oznaczone jako $-u_i$) nie będą dodatnie (tak aby u_i były nieujemne) i co najmniej jedna będzie równa zero³. To podejście jest określane jako metoda najmniejszych kwadratów z korektą (ang. *corrected OLS* – COLS). Podkreślić należy, że w podejściu tym nie określa się rozkładu reszt, a całkowite odstępstwo od granicy produkcji dla danego producenta przypisuje się nieefektywności.

³ W praktyce w pierwszych badaniach na temat edukacji nie dostosowywano wartości reszt, zamiast tego używano estymacji na temat „średniej” funkcji produkcji z niedostosowanymi resztami (np. Johnes 1996; Gray i in. 1984).

W alternatywnych podejściach zakłada się rozkład dla u_i . Najczęściej jest to rozkład półnormalny, chociaż rozkład wykładniczy może być alternatywnie wykorzystany (Lovell, 1993). Parametry równania (1.9) są szacowane przy użyciu MNK i szacowany jest też dodatkowy parametr, a mianowicie średnia z u_i , który jest używany do przesunięcia przecięcia MNK w górę. To podejście jest określane również jako COLS, co jest dość mylące (Førsund i in. 1980) lub jako zmodyfikowana MNK (ang. *modified OLS* – MOLS) (Lovell 1993). Oprócz wad związanych z deterministycznym charakterem reszt podejście MOLS ma taką wadę, że funkcja produkcji może nie być przesunięta wystarczająco daleko, tak żeby wszystkie obserwacje znajdowały się wewnątrz granicy lub na niej. W konsekwencji niektóre reszty mogą mieć odwrotny znak (Førsund i in. 1980; Lovell 1993).

Jako alternatywny estymator można użyć metody największej wiarygodności (ang. *maximum likelihood estimations* – MLE) do oszacowania rozkładu u_i oraz parametrów równania (1.9) (dla przyjętej postaci funkcji produkcji). W konsekwencji funkcja produkcji MLE obejmuje wszystkie obserwacje, ale szacowane parametry różnią się od tych uzyskanych metodą najmniejszych kwadratów (ponieważ związek pomiędzy nakładami i wynikami jest teraz nieliniowy), co pozwala na to, żeby obserwacje efektywne (czyli te, które leżą na granicy produkcji) różniły się pod względem technologii w stosunku do tych, które są wewnątrz granicy (Lovell 1993).

Rysunek 1.7 Porównanie różnych granic produkcji



Wszystkie z tych metod posiadają wady parametrycznych modeli statystycznych. Ponadto należy podkreślić, że COLS i MOLS dają identyczny ranking producentów

co metoda OLS. W końcu, powyżej przedstawione metody są nieodpowiednie do zastosowania w warunkach, gdzie mamy do czynienia z wieloma nakładami i wynikami produkcji⁴. Porównanie tych trzech deterministycznych metod można znaleźć w Lovell (1993) i są one zilustrowane dla przypadku pojedynczego nakładu i pojedynczego wyniku na Rysunku 1.7.

Odległości od granicy są stochastyczne. Dla stochastycznych reszt równanie 1.9 jest zmodyfikowane do następującej formuły:

$$y_i = f(x_{i1}, \dots, x_{im}) e^{\varepsilon_i}, \quad (1.12)$$

gdzie: $\varepsilon_i = v_i - u_i$ a więc równanie (1.10) może zostać zapisane jako:

$$\ln(y_i) = \ln[f(x_{i1}, \dots, x_{im})] + \varepsilon_i = \alpha_0 + \sum_{j=1}^m \alpha_j \ln x_{ij} + \varepsilon_i, \quad (1.13)$$

gdzie $v_i \sim N(0, \sigma_v^2)$, u_i i v_i są statystycznie niezależne, a $u_i \geq 0$ (Aigner in. 1977). Reszty są podzielone na dwa składniki. Jeden jest związany z błędem pomiaru i zmianami losowymi (v_i), podczas, gdy drugi składnik, najczęściej o rozkładzie wykładniczym lub pół normalnym, odpowiada technicznej nieefektywności (u_i). Parametry funkcji produkcji mogą być oszacowane metodą MOLS (Førsund i in. 1980; Lovell 1993) lub MLE. Technika ta zwana jest stochastyczną metodą graniczną. Jeżeli (u_i) ma rozkład półnormalny, to przykładowo logarytm funkcji największej wiarygodności (ang. *log-likelihood function*) jest zapisany jako:

$$\ln L = -n \ln \sigma - \frac{n}{2} \ln \frac{2}{\pi} - \frac{1}{2} \sum_i \frac{\varepsilon_i^2}{2\sigma^2} + \sum_i \ln \Phi \left(\frac{-\varepsilon_i \lambda}{\sigma} \right), \quad (1.14)$$

gdzie: $\sigma^2 = \sigma_u^2 + \sigma_v^2$, $\lambda = \sigma_u / \sigma_v$ i Φ jest dystrybucją standardowego rozkładu normalnego.

Możliwe jest obliczenie błędów ε_i jako odchyłeń między wynikami obserwowanymi a wynikami estymowanymi. Dla warunku: $u_i \sim N(0, \sigma_u^2)$ średnia techniczna nieefektywność wynosi $\sigma_u \sqrt{(2/\pi)}$ i może zostać wyznaczona na podstawie oszacowanego σ_u . Metoda stochastycznej granicy pozwala uzyskać informację na temat technicznej efektywności każdej jednostki za pomocą metody zapoczątkowanej przez Jondrow i in. (1982). Dla normalnego i półnormalnego rozkładu reszt szacunki dla jednostek są otrzymywane w następujący sposób⁵.

⁴ Zobacz np. Lovell (1993), jak zaadaptować te metody do przypadku wielu nakładów i wielu wyników.

⁵ Jondrow i in. (1982) podają także rozwiązanie dla rozkładu normalno-wykładniczego.

Zauważmy, że ε_i jest obserwowane $\forall i$, a więc zadanie polega na podziale oszacowanego ε_i , dla każdego i na składnik u_i oraz v_i^6 . Można wykazać, że warunkowy rozkład u_i dla ε_i to $N(\mu_{*i}, \sigma_*^2)$ odcięty w punkcie 0, gdzie $\mu_{*i} = -\varepsilon_i \sigma_u^2 / \sigma^2$ i $\sigma_*^2 = \sigma_u^2 \sigma_v^2 / \sigma^2$. Punktowy estymator u_i jest dany przez średnią rozkładu normalnego:

$$E(u_i / \varepsilon_i) = \frac{\sigma_u^2 \sigma_v^2}{\sigma^2} \left[\frac{\phi(\varepsilon_i \lambda / \sigma)}{1 - \Phi(\varepsilon_i \lambda / \sigma)} - \frac{\varepsilon_i \lambda}{\sigma} \right], \quad (1.15)$$

gdzie Φ jest standardowym rozkładem normalnym. Ponieważ μ_{*i} i σ_*^2 są nieznanymi, zastosowanie tej metody wymaga użycia ich wartości estymowanych, błąd wynikający z tego przybliżenia zanika asymptotycznie i dlatego dla wystarczająco dużych prób można go nie brać pod uwagę.

Analiza granicy stochastycznej jest atrakcyjna ze względu na jej charakter statystyczny i ugruntowanie w teorii ekonomii. Jej krytyka wiąże się z dość szerokimi przedziałami ufności odnośnie oszacowanych wskaźników nieefektywności. Przedziały te mogą być zbyt szerokie, aby metoda ta zyskała przychylność praktyków, analitycy mogą zadać także pytania na temat poprawności rozróżnienia pomiędzy dwoma składnikami reszt. Oczywiście jest to kwestia do rozstrzygnięcia w badaniach empirycznych. Dodatkowo przyjęcie danej funkcji rozkładu dla reszt (czy to półnormalnego, czy wykładniczego) w przypadku składnika określającego nieefektywność techniczną jest założeniem, które nie ma swojego umocowania w teorii. Nie ma więc powodu, aby preferować jeden rodzaj rozkładu nad drugi, a błędy specyfikacji stają się częścią miary efektywności. W przypadku, w którym efektywność organizacji jest wynikiem działalności wielu osób o różnej efektywności, można się spodziewać, że rozkład efektywności instytucji będzie rozkładem normalnym. Jednak analiza granicy stochastycznej nie może być używana do oceny efektywności, jeżeli rozkład u_i jest normalny, ponieważ w takim przypadku nie będzie go można odróżnić od v_i .

Deterministyczne niestatystyczne metody nieparametryczne


W części tej zostaną opisane deterministyczne, niestatystyczne metody nieparametryczne. Wśród nich metoda najczęściej stosowana do pomiaru efektywności technicznej, czyli analiza obwiedni danych (ang. *data envelopment analysis*, DEA). Podstawowe założenia metody DEA przedstawiono poniżej.

DEA ze stałymi korzyściami skali. Celem metody DEA opracowanej przez Charnes i in. (1978) w oparciu o prace Dantzig (1951) i Farrell (1957) jest

⁶ Pierwszy ze składników jest miarą nieefektywności technicznej (oznaczonej przez u_i w równaniu (1.3)) i może posłużyć do znalezienia technicznej efektywności dla każdego producenta poprzez wprowadzenie do równania (1.12).

oszacowanie granicy możliwości produkcyjnych, a tym samym dokonanie oceny technicznej efektywności każdej firmy lub jednostki decyzyjnej (ang. *decision making unit*, DMU) w stosunku do granicy możliwości produkcyjnych. W najprostszej wersji DEA zakłada stałe korzyści skali (CRS).

Rysunek 1.8 Ilustracja metody DEA



Rozważmy najpierw prosty przykład pięciu uniwersytetów (A, B, C, D, E) produkujących dwa rezultaty – y_1 (liczba absolwentów osiągających wystarczająco „dobre” stopnie) i y_2 (liczba absolwentów wchodzących na rynek pracy) z jednego nakładu x (liczba studentów). Stosunek wyników y_1 do nakładu można zilustrować względem ilorazu: wynik y_2 do nakładu jak na Rysunku 1.8. Prosta, która łączy uniwersytety A, B, C i D, jest granicą efektywności, ponieważ żadna z jednostek znajdujących się na granicy nie jest w stanie wytworzyć więcej rezultatów (przy danym nakładzie), a więc wszystkie uniwersytety znajdujące się na granicy są efektywne technicznie. Jednak uniwersytet E jest położony wewnątrz granicy. Promień wyprowadzony ze środka układu współrzędnych przez punkt E i przeciągnięty do granicy, którą przecina w punkcie E', wskazuje, że DMU z połączonych jednostek B i C mógłby wyprodukować więcej obu wyników (przy danym nakładzie) niż jednostka E. W rzeczywistości wyniki osiągnięte przez uniwersytet E mogą być proporcjonalnie zwiększone (bez zwiększania nakładu) o wartość: $1 - OE/OE'$, gdzie OE/OE' ukazuje względny

poziom efektywności jednostki E w stosunku do innych jednostek w próbie, a miara zgodna jest z definicją efektywności technicznej zorientowanej na wyniki Farella. W alternatywnym podejściu, gdzie wyznaczono stosunek nakładów do wyników, granica efektywności pokazana jako SS' na Rysunku 1.1, można wyliczyć efektywność techniczną zorientowaną na nakłady. Dla CRS miary efektywności technicznej zorientowane na nakłady i wyniki są tożsame.

W praktyce DMU mogą wytwarzać wiele wyników z wielu nakładów, dlatego wykorzystuje się techniki programowania w celu wyznaczenia granicy, która łączy wszystkie efektywne DMU, granica SS' na Rysunku 1.1 (jeżeli zastosowano orientację na nakłady) lub DD' z Rysunku 1.2 (orientacja na wyniki). Techniczna efektywność jednostki k jest zdefiniowana jako stosunek ważonej sumy nakładów do ważonej sumy wyników (Charnes i in. 1978):

$$TE_k = \frac{\sum_{r=1}^s u_r y_{rk}}{\sum_{i=1}^m v_i x_{ik}}, \quad (1.16)$$

gdzie s to wyniki, a m nakłady; y_{rk} to r -ty wynik osiągnięty przez k -tą jednostkę decyzyjną; x_{ik} to i -ty nakład wykorzystany przez k -tą jednostkę decyzyjną, u_r oznacza wagę dla r -tego wyniku; a v_i to waga użyta w stosunku do i -tego nakładu. TE_k odpowiada efektywności technicznej zdefiniowanej w części 2, ale należy zauważyć, że jest to miara relatywna, liczona w stosunku do pozostałych jednostek decyzyjnych z próby.

Jednostka decyzyjna k maksymalizuje swój wskaźnik efektywności z zastrzeżeniem pewnych ograniczeń: (i) wagi są uniwersalne: co oznacza, że waga użyta w stosunku do jednostki k , kiedy jest zastosowana do każdego innego DMU z próby, to uzyskany na ich podstawie wskaźnik efektywności nie może być większy od 1; (ii) wagi dla nakładów i dla rezultatów są dodatnie⁷. Dla każdej n -tej jednostki decyzyjnej następujący problem programowania liniowego musi zostać rozwiązany:

$$\text{maksymalizacja: } \frac{\sum_{r=1}^s u_r y_{rk}}{\sum_{i=1}^m v_i x_{ik}} \quad (1.17)$$

⁷ Warunek, aby wagi były dodatnie (w odróżnieniu od nieujemnych), został wprowadzony przez Charnesa i in. (1979), gdzie badacze ci rozwinęli wcześniejszy model (Charnes i in. 1978), w którym wymagali żeby wagi były nieujemne. Wymóg dodatniości wag gwarantuje, że efektywne DMU (ze wskaźnikiem efektywności równym 1) nie ma luzów ani na nakładach, ani na wynikach.

przy ograniczeniach:

$$\frac{\sum_{r=1}^s u_r y_{rj}}{\sum_{i=1}^m v_i x_{ij}} \leq 1 \quad j = 1, \dots, n \quad (1.18)$$

$$u_r, v_i > 0 \quad \forall r = 1, \dots, s; i = 1, \dots, m .$$

Ten problem programowania liniowego może zostać przekształcony w ramach maksymalizacji ważonej sumy wyników przy stałych wartościach nakładów (podejście zorientowane na wyniki) lub przez minimalizację ważonej sumy nakładów przy stałych wynikach (podejście zorientowane na nakłady). Zadanie pierwotne⁸ dla każdego z podejść podano poniżej:

**Orientacja na wyniki (CRS)
zadanie pierwotne:**

Minimalizacja $\sum_{i=1}^m v_i x_{ik}$ (1.19a)

przy warunkach (1.20a)

$$\sum_{i=1}^m v_i x_{ij} - \sum_{r=1}^s u_r y_{rj} \geq 0 \quad j = 1, \dots, n$$

$$\sum_{r=1}^s u_r y_{rk} = 1$$

$$u_r, v_i > 0 \quad \forall r = 1, \dots, s; i = 1, \dots, m$$

**Orientacja na nakłady (CRS)
zadanie pierwotne:**

Maksymalizacja $\sum_{r=1}^s u_r y_{rk}$ (1.19b)

przy warunkach (1.20b)

$$\sum_{i=1}^m v_i x_{ij} - \sum_{r=1}^s u_r y_{rj} \geq 0 \quad j = 1, \dots, n$$

$$\sum_{i=1}^m v_i x_{ik} = 1$$

$$u_r, v_i > 0 \quad \forall r = 1, \dots, s; i = 1, \dots, m$$

W praktyce często wykorzystuje się zadanie dualne (równania dla każdego z podejść są podane poniżej), które jest prostsze do obliczenia niż równanie pierwotne, posiada $s+m$ warunków ograniczających w stosunku do $n+1$ w równaniu pierwotnym.

⁸ Terminologia zadania pierwotnego odpowiada pracy Charnesa i in. (1978). Należy jednak zauważyć, że maksymalizacja rezultatów przy danych nakładach (tj. zorientowanie na wyniki) jest osiągnięta poprzez pierwotne zadanie minimalizacji funkcji celu (Norman i Stoker 1991).

Orientacja na wyniki
zadanie dualne (CRS):

Maksymalizacja ϕ_k (1.21a)
przy warunkach (1.11a)

$$\phi_k y_{rk} - \sum_{j=1}^n \lambda_j y_{rj} \leq 0 \quad r = 1, \dots, s$$

$$x_{ik} - \sum_{j=1}^n \lambda_j x_{ij} \geq 0 \quad i = 1, \dots, m$$

$$\lambda_r \geq 0 \quad \forall r = 1, \dots, s$$

Orientacja na nakłady
zadanie dualne(CRS):

Minimalizacja θ_k (1.21b)
przy warunkach (1.22b)

$$y_{rk} - \sum_{j=1}^n \lambda_j y_{rj} \leq 0 \quad r = 1, \dots, s$$

$$\theta_k x_{ik} - \sum_{j=1}^n \lambda_j x_{ij} \geq 0 \quad i = 1, \dots, m$$

$$\lambda_r \geq 0 \quad \forall r = 1, \dots, s$$

W poprzednich zapisach nie braliśmy pod uwagę luzów w pomiarach efektywności. Problem luzów powstaje, ponieważ część granicy efektywności przebiega równolegle do osi pionowej i poziomej (odcinki GA i DH na Rysunku 1.8). Załóżmy, że dodano dodatkową jednostkę decyzyjną: F , która na Rysunku 1.8 znajduje się na odcinku DH . Punkt ten znajduje się na granicy, a więc jest efektywny z wynikiem równym 1. Jednakże w próbie istnieje np. jednostka D , która wytwarza ten sam poziom wyników y_2 , ale więcej wyników y_1 w stosunku do tych samych nakładów. Jednostka decyzyjna F może zatem zwiększyć swoją efektywność pod względem jednego z produktów, a więc mówi się, że posiada luzy rezultatów. Dla orientacji na nakłady luz będzie oznaczał, że jest możliwym zmniejszenie chociaż jednego nakładu bez zmian osiągniętych wyników. Powyższe równanie może zostać zapisane, biorąc pod uwagę luzy nakładów i wyników (odpowiednio oznaczone jako s_r i s_i):

Orientacja na wyniki
zadanie dualne z luzami (CRS):

Maksymalizacja $\phi_k - \varepsilon \sum_{r=1}^s s_r - \varepsilon \sum_{i=1}^m s_i$
(1.23a)

przy warunkach (1.24a)

$$\phi_k y_k - \sum_{j=1}^n \lambda_j y_j + s_r = 0 \quad r = 1, \dots, s$$

$$x_{ik} - \sum_{j=1}^n \lambda_j x_{ij} - s_i = 0 \quad i = 1, \dots, m$$

$$\lambda_j, s_r, s_i \geq 0$$

$$\forall j = 1, \dots, n; r = 1, \dots, s; i = 1, \dots, m$$

Orientacja na nakłady
zadanie dualne z luzami (CRS):

Minimalizacja $\theta_k - \varepsilon \sum_{r=1}^s s_r - \varepsilon \sum_{i=1}^m s_i$
(1.23b)

przy warunkach (1.24b)

$$y_{rk} - \sum_{j=1}^n \lambda_j y_{rj} + s_r = 0 \quad r = 1, \dots, s$$

$$\theta_k x_{ik} - \sum_{j=1}^n \lambda_j x_{ij} - s_i = 0 \quad i = 1, \dots, m$$

$$\lambda_j, s_r, s_i \geq 0$$

$$\forall j = 1, \dots, n; r = 1, \dots, s; i = 1, \dots, m$$


Jednostka decyzyjna k jest efektywna, jeżeli wskaźnik efektywności $TE_k = \frac{1}{\phi_k} = 1$ (równocześnie $TE_k = \theta_k = 1$), a luzy: $s_r, s_i = 0$.

DEA ze zmiennymi korzyściami skali. Założenie CRS może zostać zdjęte, a model DEA można łatwo zmodyfikować, aby uwzględnić zmienne korzyści skali (VRS) (Banker i in. 1984). Założenie VRS w przeciwieństwie do CRS wpływa na wartości wskaźników efektywności DMU, jak pokazano na Rysunku 1.9. Granica efektywności CRS (linia przerywana) i granica efektywności VRS (linia ciągła $BACD$) odpowiada sytuacji, gdzie jest tylko jeden nakład i jeden wynik. Rozważmy jednostkę E , której wskaźnik efektywności jest równy stosunkowi OE/OE' przy VRS i jest wyższy od wskaźnika dla CRS wynoszącego: OE/OE'' ⁹.

Należy zauważyć, że zbiór DMU zidentyfikowanych jako nieefektywne w ramach VRS będzie taki sam bez względu na orientację modelu: czy to zorientowany na nakłady, czy na wyniki. Jednak wartość wskaźnika efektywności dla nieefektywnego DMU będzie się różniła w zależności od wyboru orientacji modelu (orientacja na nakłady czy na wyniki), co pokazano na Rysunku 1.4. Jest to odmienne od sytuacji CRS, gdzie wybór orientacji nie wpływa na wynik efektywności nieefektywnego DMU.

W warunkach VRS dla każdego DMU należy rozwiązać poniższe równania programowania liniowego:

Rysunek 1.9 Granice DEA: stałe korzyści skali versus zmienne korzyści skali



⁹ Wskaźniki efektywności są otrzymywane na podstawie pionowej odległości od granicy i dlatego oznaczają orientację na wyniki. Wskaźniki efektywności mogłyby zostać wyznaczone na podstawie odległości poziomej od granicy i oznaczałyby zorientowanie na nakłady.

**Orientacja na wyniki (VRS)
zadanie pierwotne:**

$$\text{Minimalizacja } \sum_{i=1}^m v_i x_{ik} - c_k \quad (1.25a)$$

przy warunkach (1.26a)

$$\sum_{i=1}^m v_i x_{ij} - \sum_{r=1}^s u_r y_{rj} \geq 0 \quad j = 1, \dots, n$$

$$\sum_{r=1}^s u_r y_{rk} = 1$$

$$u_r, v_i > 0 \quad \forall r = 1, \dots, s; i = 1, \dots, m$$

**Orientacja na nakłady (VRS)
zadanie pierwotne:**

$$\text{Maksymalizacja } \sum_{r=1}^s u_r y_{rk} \quad (1.25b)$$

przy warunkach (1.26b)

$$\sum_{i=1}^m v_i x_{ij} - \sum_{r=1}^s u_r y_{rj} \geq 0 \quad j = 1, \dots, n$$

$$\sum_{i=1}^m v_i x_{ik} = 1$$

$$u_r, v_i > 0 \quad \forall r = 1, \dots, s; i = 1, \dots, m$$

gdzie c_k jest miarą zwrotu ze skali produkcji dla jednostki k , a dualne zadanie przedstawiono poniżej:

**Orientacja na wyniki (VRS)
zadanie dualne:**

$$\text{Maksymalizacja } \phi_k \quad (1.27a)$$

przy warunkach (1.28a)

$$\phi_k y_{rk} - \sum_{j=1}^n \lambda_j y_{rj} \leq 0 \quad r = 1, \dots, s$$

$$x_{ik} - \sum_{j=1}^n \lambda_j x_{ij} \geq 0 \quad i = 1, \dots, m$$

$$\sum_{j=1}^n \lambda_j = 1$$

$$\lambda_r \geq 0 \quad \forall r = 1, \dots, s$$

**Orientacja na nakłady (VRS)
zadanie dualne:**

$$\text{Minimalizacja } \theta_k \quad (1.27b)$$

przy warunkach (1.28b)

$$y_{rk} - \sum_{j=1}^n \lambda_j y_{rj} \leq 0 \quad r = 1, \dots, s$$

$$\theta_k x_{ik} - \sum_{j=1}^n \lambda_j x_{ij} \geq 0 \quad i = 1, \dots, m$$

$$\sum_{j=1}^n \lambda_j = 1$$

$$\lambda_r \geq 0 \quad \forall r = 1, \dots, s$$

Po dodaniu luzów, otrzymujemy:

**Orientacja na wyniki (VRS)
zadanie dualne:**

$$\text{Maksymalizacja: } \phi_k - \varepsilon \sum_{r=1}^s s_r - \varepsilon \sum_{i=1}^m s_i \quad (1.29a)$$

przy warunkach (1.30a)

$$\phi_k y_{rk} - \sum_{j=1}^n \lambda_j y_{rj} + s_r = 0 \quad r = 1, \dots, s$$

$$x_{ik} - \sum_{j=1}^n \lambda_j x_{ij} - s_i = 0 \quad i = 1, \dots, m$$

$$\sum_{j=1}^n \lambda_j = 1$$

$$\lambda_j, s_r, s_i \geq 0$$

$$\forall j = 1, \dots, n; r = 1, \dots, s; i = 1, \dots, m$$

**Orientacja na nakłady (VRS)
zadanie dualne:**

$$\text{Minimalizacja } \theta_k - \varepsilon \sum_{r=1}^s s_r - \varepsilon \sum_{i=1}^m s_i \quad (1.29b)$$

Przy warunkach (1.30b)

$$y_{rk} - \sum_{j=1}^n \lambda_j y_{rj} + s_r = 0 \quad r = 1, \dots, s$$

$$\theta_k x_{ik} - \sum_{j=1}^n \lambda_j x_{ij} - s_i = 0 \quad i = 1, \dots, m$$

$$\sum_{j=1}^n \lambda_j = 1$$

$$\lambda_j, s_r, s_i \geq 0$$

$$\forall j = 1, \dots, n; r = 1, \dots, s; i = 1, \dots, m$$

Całkowita efektywność techniczna jednostki k jest mierzona jako $TE_k = 1/\phi_k$ (dla orientacji na wyniki) oraz $TE_k = \theta_k$ (dla orientacji na nakłady), a efektywność skali może być obliczona dla jednostki k jako:

$$SCE_k = \frac{TE_{k,CRS}}{TE_{k,VRS}} \quad (1.31)$$

Ponadto można określić czy dana jednostka działa w obrębie rosnących lub malejących korzyści skali poprzez oszacowanie, oprócz modeli CRS i VRS, modelu z nierosnącymi korzyściami skali (ang. *non-increasing returns to scale* – NIRS)¹⁰ i porównanie ich rezultatów (Coelli i in. 1998).

DEA i efektywność alokacyjna. Powyżej przedstawione założenia metody DEA skupiały się na pomiarze efektywności technicznej. Jednak metoda DEA może dostarczyć informacji o całkowitej efektywności, efektywności alokacyjnej dla każdego DMU zgodnie z definicją z części 2. W celu wyznaczenia efektywności alokacyjnej niezbędna jest wiedza na temat cen wszystkich nakładów (w_j) i wszystkich wyników (p_j). W przypadku szkół i instytucji szkolnictwa wyższego takie informacje są rzadko

¹⁰ Jest to VRS, z tym że warunek równości $\sum_{j=1}^n \lambda_j = 1$ jest zastąpiony przez nierówność $\sum_{j=1}^n \lambda_j \leq 1$.

dostępne, a zatem metodologia określania efektywności alokacyjnej zostanie przedstawiona w sposób bardzo zwięzły.

Efektywność alokacyjna związana jest z efektywnością całkowitą i efektywnością techniczną w następujący sposób:

$$AE_k = \frac{OE_k}{TE_k} \quad (1.32)$$

i może zostać wyznaczona albo przez orientację na nakłady (minimalizacja kosztów), albo przez orientację na wyniki (maksymalizacja przychodów) – zobacz część 2. Dla maksymalizacji przychodów pierwszym etapem jest obliczenie technicznej efektywności (TE_k) przy użyciu orientacji na wyniki (CRS albo VRS). W kolejnym kroku rozwiązuje się maksymalizację przychodów DEA. Poniżej przedstawiono równania dla wariantu VRS (równania od (1.33a) do (1.34a)):

Orientacja na wyniki (VRS):

Maksymalizacja: $\sum_{r=1}^s p_{rk} y_{rk}^*$ (1.33a)

przy warunkach: (1.34b)

$$y_{rk}^* - \sum_{j=1}^n \lambda_j y_{rj} \leq 0 \quad r = 1, \dots, s$$

$$x_{ik} - \sum_{j=1}^n \lambda_j x_{ij} \geq 0 \quad i = 1, \dots, m$$

$$\sum_{j=1}^n \lambda_j = 1$$

$$\lambda_r \geq 0 \quad \forall r = 1, \dots, s$$

gdzie p_{rk} jest ceną rezultatu r -tego ($r = 1, \dots, s$) dla jednostki k , y_{rk}^* jest obliczone na podstawie programowania liniowego i jest wielkością maksymalizującą przychód dla rezultatu r ($r = 1, \dots, s$) dla DMU k , gdzie nakłady wynoszą x_{ik} , a ceny rezultatów: p_{rk} .

Orientacja na nakłady (VRS):

Maksymalizacja: $\sum_{i=1}^m w_{ik} x_{ik}^*$ (1.33b)

przy warunkach: (1.34b)

$$y_{rk} - \sum_{j=1}^n \lambda_j y_{rj} \leq 0 \quad r = 1, \dots, s$$

$$x_{ik}^* - \sum_{j=1}^n \lambda_j x_{ij} \geq 0 \quad i = 1, \dots, m$$

$$\sum_{j=1}^n \lambda_j = 1$$

$$\lambda_r \geq 0 \quad \forall r = 1, \dots, s$$

gdzie w_{ik} jest ceną nakładu i -tego ($i = 1, \dots, m$) dla jednostki k , x_{rk}^* jest obliczone na podstawie programowania liniowego i jest wielkością minimalizującą koszty dla nakładu i ($i = 1, \dots, m$) i jednostki k , gdzie wyniki y_{rk} , a ceny nakładów: w_{ik} .

Całkowita efektywność jednostki k , tak jak zdefiniowano ją w części 2, może zostać obliczona jako:

$$OE_k = \frac{\sum_{r=1}^s p_{rk} y_{rk}}{\sum_{r=1}^s p_{rk} y_{rk}^*} \quad (1.35)$$

Efektywność alokacyjną można obliczyć za pomocą równania (1.32).

W przypadku minimalizacji kosztów pierwszym etapem jest obliczenie technicznej efektywności (TE) przy użyciu orientacji na nakłady (CRS albo VRS). W kolejnym kroku rozwiązuje się minimalizację kosztów DEA. Równania dla wariantu VRS przedstawiono powyżej (równania od (1.33b) do (1.34b)). Całkowita efektywność dla DMU k , jak zdefiniowano ją w części 2, jest obliczana jako:

$$OE_k = \frac{\sum_{i=1}^m w_i k x_{ik}}{\sum_{i=1}^m w_i k x_{ik}^*} \quad (1.36)$$


Efektywność alokacyjna może być znów wyznaczona za pomocą równania (1.32).

DEA i preferencje. Podejmowano różne próby w celu włączenia informacji dotyczących preferencji do metody DEA. Najprostszą metodą jest nałożenie ograniczeń na wagi przypisane poszczególnym nakładom i wynikom. Na przykład przy ustawianiu celów na rezultaty (dla danych nakładów) można określić, żeby jeden z wyników miał znaczenie priorytetowe. W efekcie oznacza to utrzymywanie nakładów i niektórych (ale nie wszystkich) wyników na stałym poziomie w procedurze ustawiania celu (zob. np. Thanassoulis i Dunstan 1994). Taka procedura idzie w pewnym sensie w kierunku parametryzacji funkcja produkcji.

Ostatnio Halme i in. (1999) dostosowali DEA w celu włączenia preferencji „decydenta” (ang. *decision maker* DM). Procedura jest zilustrowana dla wariantu orientacji na wyniki na Rysunku 1.10, gdzie pięć jednostek produkuje dwa wyniki z pojedynczego nakładu. Pierwszym etapem jest standardowa DEA w celu identyfikacji granicy (ABCD na rysunku 1.10). A zatem jednostka w punkcie P ma efektywność techniczną mierzoną przez stosunek $TE=OP/OP_1$. Następnym krokiem jest zidentyfikowanie dla jednostki najkorzystniejszej kombinacji nakładów i wyników zwanych najbardziej preferowanym rozwiązaniem (ang. *most preferred solution* – MPS), które leży na granicy efektywności. Halme i in. (1999) użyli procedury szukania w formie

wieloobiekowego programowania liniowego w celu lokalizacji MPS, ale możliwe jest użycie alternatywnych procedur.

Rysunek 1.10 Pomiar efektywności wartości



Ostatnim krokiem jest obliczenie miary efektywności, która obejmuje preferencje jednostki nazwanej przez Halme i in. (1999) „efektywnością wartości” (ang. *value efficiency* – VE). Zakłada się, że MPS leży również na (nieznanej) krzywej obojętności odzwierciedlającej wszystkie punkty jednakowej użyteczności (oznaczone przez IC na Rysunku 1.10). Prawdziwa wartość efektywności, która zawiera preferencje jednostki, wyrażona jest stosunkiem: $VE = OP/OP_4$, ale ponieważ krzywa obojętności nie jest obserwowana, nie można wyznaczyć tego ilorazu. Zakłada się, że wszystkie punkty na krzywej obojętności znajdują się powyżej linii, która jest styczną do granicy efektywności w MPS (linia styczna jest oznaczona jako IC' na Rysunku 1.10). Styczna ta może zostać wykorzystana do oszacowania efektywności wartości – OP/OP_3 (Korhonen i in. 2001). W praktyce nie można oszacować efektywności wartości, zamiast tego należy użyć prostej IC'' na Rysunku 1.10, aby oszacować przybliżenie efektywności wartości jako – $VE^* = OP/OP_2$, która daje wartość zawyżoną w górę¹¹. Oszacowanie VE^* dla wszystkich DMU wymaga znalezienia rozwiązania równań programowania liniowego podobnych do tych stosowanych w standardowej procedurze DEA (zob. Korhonen i in. 2001).

¹¹ Alternatywnie prosta IC'' wprowadzona z DC przecina promień OP w punkcie P_4 i $VE^{**} = OP/OP_4$ daje bardziej konserwatywne (ale tak samo poprawne) miary.

DEA, efektywność techniczna i zmiany technologii produkcji. W części 2 opisano, w jaki sposób indeks produktywności Malmquista (zorientowany na nakłady lub na wyniki) może być wykorzystany do wyznaczenia zmian efektywności w czasie w podziale na zmiany efektywności technicznej i na zmiany w technologii produkcji. DEA może być łatwo dostosowana do obliczania wymaganego indeksu produktywności Malmquista. Dla przykładu bliższe przyjrzenie się indeksowi Malmquista zorientowanemu na wyniki¹² (zob. równanie 1.37) wskazuje, że trzeba obliczyć cztery funkcje odległości:

$$M_O(x_t, y_t, x_q, y_q) = \frac{D_O^t(x_t, y_t)}{D_O^q(x_q, y_q)} \left[\frac{D_O^q(x_t, y_t)}{D_O^t(x_t, y_t)} \cdot \frac{D_O^q(x_q, y_q)}{D_O^t(x_q, y_q)} \right]^{\frac{1}{2}}, \quad (1.37)$$

gdzie: x_q i x_t to wektory nakładów użyte odpowiednio w okresie q i t , a y_q i y_t to wektory wyników z okresu q i t . $D_O^q(x_q, y_q)$ i $D_O^t(x_t, y_t)$ są znajdowane przez rozwiązanie DEA dla wariantu zorientowania na wyniki CRS oddzielnie dla poszczególnych punktów w czasie. W szczególności:

Obliczanie $D_O^t(x_t, y_t)$:

$$\frac{1}{D_O^t(x_t, y_t)} = \text{Maksymalizacja } \phi_k \quad (1.38a)$$

przy warunkach (1.39a)

$$\phi_k y_{rkt} - \sum_{j=1}^n \lambda_j y_{rjt} \leq 0 \quad r = 1, \dots, s$$

$$x_{ikt} - \sum_{j=1}^n \lambda_j x_{ijt} \geq 0 \quad i = 1, \dots, m$$

$$\lambda_r \geq 0 \quad \forall r = 1, \dots, s$$

Obliczanie $D_O^q(x_q, y_q)$:

$$\frac{1}{D_O^q(x_q, y_q)} = \text{Maksymalizacja } \phi_k \quad (1.38b)$$

przy warunkach (1.39b)

$$\phi_k y_{rkq} - \sum_{j=1}^n \lambda_j y_{rjq} \leq 0 \quad r = 1, \dots, s$$

$$x_{ikq} - \sum_{j=1}^n \lambda_j x_{ijq} \geq 0 \quad i = 1, \dots, m$$

$$\lambda_r \geq 0 \quad \forall r = 1, \dots, s$$

¹² W tekście przedstawiona została tylko metoda do obliczenia indeksu Malmquista zorientowanego na wyniki. DEA zorientowana na nakłady może zostać użyta w celu obliczenia indeksu Malmquista zorientowanego na nakłady.

gdzie subskrypty q i t dotyczą odpowiednio okresu q i t . Ostatnie dwie odległości przy orientacji na wyniki zostają znalezione poprzez rozwiązanie następujących równań programowania liniowego:

Obliczanie $D_O^t(x_q, y_q)$:

$$\frac{1}{D_O^t(x_q, y_q)} = \text{Max } \phi_k \quad (1.40a)$$

przy warunkach (1.41a)

$$\phi_k y_{rkq} - \sum_{j=1}^n \lambda_j y_{rjt} \leq 0 \quad r = 1, \dots, s$$

$$x_{ikq} - \sum_{j=1}^n \lambda_j x_{ijt} \geq 0 \quad i = 1, \dots, m$$

$$\lambda_r \geq 0 \quad \forall r = 1, \dots, s$$

Obliczanie $D_O^q(x_t, y_t)$:

$$\frac{1}{D_O^q(x_t, y_t)} = \text{Max } \phi_k \quad (1.40b)$$

przy warunkach (1.41b)

$$\phi_k y_{rkt} - \sum_{j=1}^n \lambda_j y_{rjq} \leq 0 \quad r = 1, \dots, s$$

$$x_{ikt} - \sum_{j=1}^n \lambda_j x_{ijq} \geq 0 \quad i = 1, \dots, m$$

$$\lambda_r \geq 0 \quad \forall r = 1, \dots, s$$

Należy zauważyć, że ϕ s i λ s nie muszą mieć takich samych wartości w przedstawionych zestawach równań. Ponadto wartość optymalizacji wynikająca z dwóch ostatecznych LP nie może być większa lub równa 1, podobnie jak w standardowej procedurze DEA nakierowanej na wyniki. W przypadku tych dwóch programowań liniowych punkt produkcji z danego okresu czasu jest porównywany z granicą produkcji z innego okresu (mającą inną technologię), a zatem może znajdować się poza osiągalnym zestawem produkcji w danym okresie. Jest to szczególnie prawdopodobne, gdy punkt produkcji dla końcowego okresu czasu (w tym przypadku t) jest porównywany z granicą z początkowego okres (w tym przypadku q).

Bootstrapping. Jednym z głównych zastrzeżeń dotyczących metody DEA jest jej niezdolność do zapewnienia tradycyjnych metod wnioskowania statystycznego. Jednak dzięki procedurze *bootstrappingu* możliwym jest przewyciężenie tych mankamentów poprzez zapewnienie szacunkowych przedziałów ufności dla wskaźników efektywności uzyskanych za pomocą DEA. Jedną z takich metod (Simar i Wilson 1998, 2004) działa w następujący sposób. Oznaczmy wektor s wyników osiągniętych przez jednostkę j ($j=1, \dots, n$) jako y_j i wektor m nakładów używanych przez jednostkę j jako x_j . Etap 1 obejmuje oszacowanie wskaźników efektywności dla zbioru danych.

Wykorzystujemy metodę DEA przy danych nakładach i wynikach w celu oszacowania wskaźników efektywności oznaczonych jako: $\widehat{D}(x_j, y_j)$. Oszacowania te muszą znajdować się w obrębie jedynki, co zapewnia się przez obliczenie: $2 - \widehat{D}(x_j, y_j)$ dla każdego $\widehat{D}(x_j, y_j)$, $j=1, \dots, n$, dostarczając w sumie $2n$ obserwacji (n obserwacji dla $\widehat{D}(x_j, y_j)$ i n obserwacji dla $2 - \widehat{D}(x_j, y_j)$).

W drugim kroku wyznacza się wartości bootstrapowe, a krok ten złożony jest z wielu etapów. Po pierwsze, wyznaczone zostaje pasmo (ang. *bandwith*) h . Może ono zostać ustalone arbitralnie np. $h=0.05$ (z późniejszymi niewielkimi zmianami w celu oceny wpływu wielkości h na szacowany przedział ufności) albo może zostać wyznaczone według innych kryteriów (przykładowe są omówione w pracy Simara i Wilsona (1998)). Następnie losowana jest n -elementowa próbka niezależnych i identycznie rozłożonych obserwacji (zapisanych jako: $e_j, j=1, \dots, n$) z funkcji gęstości w formie rozkładu kernala. Po trzecie, losuje się n niezależnych wartości (oznaczonych jako $d_j, j=1, \dots, n$) ze zbioru $2n$ odzwierciedlających funkcje odległości. Na ich podstawie oblicza się średnią:

$$\bar{d} = \sum_{j=1}^n d_j / n \quad (1.42)$$

a potem oblicza się wartość:

$$d_j^* = \bar{d} + \sqrt{\left(1 + \frac{h^2}{s^2}\right)} (d_j + h e_j - \bar{d}) \quad (1.43)$$

gdzie s^2 jest wariancją próby dla \bar{d} . W końcu następuje obliczenie wartości bootstrapowej (D_j^*) jako:

$$D_j^* = \begin{cases} d_j^* & \text{jeżeli } d_j^* \leq 1 \\ 2 - d_j^* & \text{dla pozostałych} \end{cases} \quad (1.44)$$

W kroku 3 otrzymuje się bootstrapowe oszacowania wskaźnika efektywności. Posiadając próbę bootstrapową, określa się wektory nakładów i wyników (x_j^*, y_j^*) jako:

$$y_j^* = D_j^* y_j / \widehat{D}(x_j, y_j), \quad (1.45)$$

$$x_j^* = x_j, \quad (1.46)$$

Otrzymuje się daną liczbę np. B bootstrapowych wskaźników efektywności dla każdej jednostki j ($j=1, \dots, n$) poprzez zastosowanie metody DEA dla próby bootstrapowej B -razy. Te oszacowania bootstrapowe mogą być oznaczone dla jednostki k jako $\{\widehat{D}_b^*(x_k, y_k)\}_{b=1}^B$.

W czwartym kroku oblicza się przedziały ufności dla rzeczywistych wartości wskaźników efektywności. Przedział ufności $100(1-\alpha)\%$ dla wskaźnika efektywności jednostki k jest obliczany poprzez znalezienie wartości b_α, a_α jako:

$$\Pr(-b_\alpha \leq \widehat{D}(x_j, y_j) - D(x_j, y_j) \leq -a_\alpha) = 1 - \alpha. \quad (1.47)$$

Wartości b_α, a_α nie są znane, ale mogą zostać wyestymowane przy użyciu bootstrapowych szacowań: $\{\widehat{D}_b^*(x_k, y_k)\}_{h=1}^B$ poprzez uszeregowanie wartości $\widehat{D}_b^*(x_k, y_k) - \widehat{D}(x_j, y_j)$ od najmniejszej do największej i odcięcie $(100\alpha/2)\%$ obserwacji z każdego końca. Estymatory: $-b_\alpha$ i $-a_\alpha$ (oznaczone jako: $-\widehat{b}_\alpha$ i: $-\widehat{a}_\alpha$) są końcami pozostałego przedziału tak, że: $\widehat{a}_\alpha \leq \widehat{b}_\alpha$. Przybliżenie równania (1.47) wynosi:

$$\Pr(-\widehat{b}_\alpha \leq \widehat{D}(x_j, y_j) - D(x_j, y_j) \leq -\widehat{a}_\alpha) \approx 1 - \alpha, \quad (1.48)$$

A przedział ufności $100(1-\alpha)\%$ dla wskaźnika efektywności jednostki k jest znaleziony poprzez obliczenie:

$$[\widehat{D}(x_j, y_j) + \widehat{a}_\alpha \widehat{D}(x_j, y_j) + \widehat{b}_\alpha]. \quad (1.49)$$

Dodatkowe informacje dostarczone przez DEA. Warto na tym etapie rozważyć zalety i wady metody DEA w porównaniu do statystycznych metod parametrycznych w kontekście badań nad funkcjonowaniem instytucji edukacji. Powyżej zostało wykazane, że standardowa metoda DEA może dostarczać informacji na temat efektywności (technicznej i skali produkcji) dla wszystkich jednostek decyzyjnych w próbie. Ponadto kolejne procedury mogą dostarczyć informacji na temat efektywności alokacyjnej, a nawet efektywności wartości. Trzeba jednak zauważyć, że DEA oferuje nie tylko prostą miarę efektywności technicznej. Dzięki rozwiązaniu problemu DEA otrzymujemy bardzo dużo informacji odnośnie zarządzania jednostką, które mogą zostać wykorzystane do działań mających na celu zwiększenie efektywności jednostki. Będzie to rozwinięte w poniższej części rozdziału.

Po pierwsze, wyniki DEA mogą być wykorzystywane do identyfikacji dla każdej technicznie nieefektywnej jednostki w odniesieniu do jednostek efektywnych, które powinna naśladować. Są one określane jako jednostki referencyjne. Te ostatnie dla danej jednostki nieefektywnej nie muszą składać się ze wszystkich jednostek znajdujących się na granicy, a raczej obejmują producentów, którzy dominują w nieefektywnej jednostce decyzyjnej¹³. W prostym przykładzie zilustrowanym na Rysunku 1.8

¹³ Oznacza to, że liniowa kombinacja wektorów ich nakładów i wyników jest bardziej efektywna aniżeli w przypadku producentów nieefektywnych.

nieefektywna jednostka E mogłaby stać się efektywna, przesuwając się do punktu E' znajdującego się na granicy produkcji, który jest kombinacją nakładów i wyników osiąganych przez jednostki B i C . One właśnie są jednostkami referencyjnymi dla nieefektywnej jednostki E . Dla jednostki nieefektywnej wyznaczenie jednostek referencyjnych może być przydatne w podjęciu decyzji, które jednostki naśladować w celu zwiększenia efektywności.

Po drugie, granica efektywności może być wykorzystana do wyznaczenia celów do osiągnięcia przez jednostki nieefektywne (Färe i in. 1989; Pedraja-Chaparro i in. 1999). Punkty te mogą leżeć w dowolnym miejscu wzdłuż granicy efektywności. Przydatnym okazuje się często wyznaczenie celu jako wyników, które są konieczne, aby przybliżyć jednostkę do granicy efektywności technicznej, jeśli nakłady pozostają niezmiennione (punkt E' na Rysunku 1.8 odzwierciedla poziom wyników, jakie nieefektywna jednostka E musi osiągnąć, aby stała się efektywna). Alternatywnie można nałożyć wymogi odnośnie poziomów nakładów bez zmian wyników. Możliwa jest dowolna kombinacja tych podejść. Tak ustalone cele są osiągalne i realistyczne w tym sensie, że odzwierciedlają one aktualnie najlepszą stosowaną praktykę. Celem jest wskazanie nieefektywnym jednostkom dokładnie tego, co mają zrobić, aby osiągnąć wyniki uzyskiwane przez najlepszych producentów. Nieefektywne jednostki mogą same na siebie nakładać wymogi lub mogą one zostać narzucone przez organizacje zewnętrzne.

Po trzecie, łatwość, z jaką DEA jest aplikowana do jednostek z wieloma nakładami i wynikami (Banker i in. 1984, 1989; Färe i in. 1989; McCarty i Yaisawarng 1993; Pedraja-Chaparro i in. 1999; Mante, 2001), jest poważnym atutem tej metody w kontekście badań instytucji edukacji, gdzie dochodzi do wytwarzania wielu wyników z wielu nakładów. Przykładowo uniwersytety prowadzą działalność dydaktyczną i badania naukowe. Wyniki ich działalności mogą być mierzone poprzez np. sukces absolwentów na rynku pracy (wynik działalności dydaktycznej), jak i przez książki, artykuły i prezentacje konferencyjne (wynik prowadzonych badań naukowych). Wyniki te są osiągane przy wykorzystaniu wielu nakładów np. studentów (dla których powinna być dostępna informacja o ich ilości, jak i jakości), pracowników i innych materiałów¹⁴.

Po czwarte, nieparametryczny charakter metody DEA pozwala każdej jednostce na wybór własnych wag dla nakładów i wyników, zamiast opierać się na ich relatywnym znaczeniu (Pedraja-Chaparro i in. 1999). Dla instytucji z sektora edukacji jest to duża wartość dodana, ponieważ dla tego sektora nie posiadamy najczęściej informacji o cenach, które mierzą względne znaczenie wyników i nakładów. Taka

¹⁴ Miary nakładów i wyników dla instytucji sektora edukacji będą analizowane bardziej szczegółowo w części 5.

elastyczność pozwala więc jednostce mieć różne cele w różnych warunkach (Pedraja-Chaparro i in. 1999).

Wreszcie, wszystkie warianty DEA mają wspólną cechę – efektywność jest mierzona w stosunku do jednostek wzorcowych o najlepszych praktykach. W modelach tych nie ma absolutnego, z góry narzuconego standardu efektywności. To podejście ma tę zaletę, że wiadomym jest, że osiągalna jest najlepsza praktyka stosowana przez jednostkę wzorcową. Nie można jednak zapominać o wadach metody DEA. Najprawdopodobniej największą z nich jest jej niestochastyczny charakter. Tak więc pominięte zmienne, błędy pomiaru nakładów i wyników oraz wszelkie inne zakłócenia statystyczne spowodują obciążenie wskaźników efektywności. W kontekście edukacji specyfikacja i pomiar zmiennych opisujących nakłady i wyniki działalności jednostek są szczególnie trudne (temat rozwinięty w części 5). Błędy w obliczonych wskaźników efektywności wynikające z pominięcia zmiennych, użycia próbki mniejszej niż populacja, związanych z obserwacjami odstającymi i błędów pomiaru są wysoce prawdopodobne, chociaż zakres problemów jest nieznan. Rozwój stochastycznej metody DEA (Lovell 1993) i wprowadzenie innych adaptacji DEA w celu zmniejszenia problemu błędów pomiarowych w zmiennych nakładów i wyników (Thanassoulis, 1999) są technikami niezmiernie ważnymi dla rozwoju metody DEA. Pozostałe problemy związane z funkcjonowaniem tej metody wynikają z wcześniej opisanych zalet. Chociaż DEA opiera się na wielu nakładach i wynikach, to ich specyfikacja, w szczególności ich liczba, może wpływać na wartość wskaźników efektywności (Pedraja-Chaparro i in. 1999). Ponadto ponieważ DEA ma charakter niestatystyczny i nieparametryczny, nie ma znanych testów parametrycznych na podstawie których można sprawdzić poprawność modelu. Dlatego zaleca się rozważenie wyników uzyskanych za pomocą różnych specyfikacji w celu oceny wrażliwości wyników na ich zmiany. Po drugie, duża liczba wyników i/lub nakładów może prowadzić do współliniowości, której wpływ na wyniki DEA jest stosunkowo niedostateczny rozpoznany. Będzie to tematem części 5. Po trzecie, założenie VRS, w którym faktycznie nie ma efektów skali, może wpływać na wskaźniki efektywności. Jak zostało pokazane na Rysunku 1.9, granica VRS obejmuje dane bardziej przyległe aniżeli granica CRS. W konsekwencji jeżeli zostanie zastosowany model VRS, a prawdziwym modelem jest CRS, to wskaźniki efektywności dla jednostek ekstremalnych (najmniejszych i największych jednostek) będą przeszacowane (Dyson i in. 2001).

4. Techniki pomiaru efektywności: analiza na poziomie indywidualnym

Istnieją różne argumenty krytyczne w stosunku do metod, w których pomiar jednostek produkcyjnych jest dokonywany na danych zagregowanych. Woodhouse i Goldstein (1988) podają argumenty przeciw stosowaniu reszt z modeli regresji

do użycia dla danych zagregowanych jako pomiaru efektywności jednostek takich jak szkoły, lokalne jednostki nadzoru edukacji (ang. LEA) czy uniwersytety. Argumenty te mogą zostać podniesione w stosunku do wszystkich statystycznych metod pomiaru efektywności.

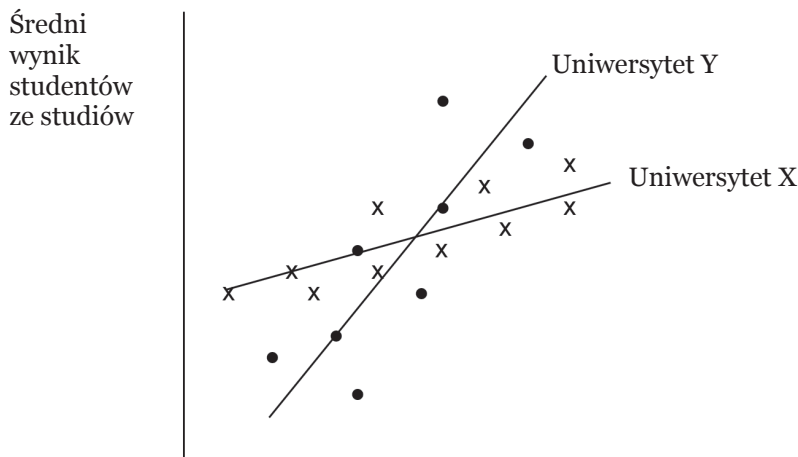
Po pierwsze, wykorzystanie danych mierzonych na poziomie organizacji nie pozwala na wychwycenie zmienności relacji wewnątrz jednostki. Na przykład w analizie uniwersytetów wyniki działalności mogą zostać ukazane jako średni wynik osiągnięty przez wszystkich studentów, a nakłady jako średnia ilość punktów uzyskanych w czasie rekrutacji. Analiza na poziomie uniwersytetu nakłada taką samą zależność pomiędzy uzyskiwanymi średnimi wynikami a ponoszonymi średnimi nakładami dla wszystkich uniwersytetów. Uniwersytet X może uzyskiwać wyższe wyniki niż uniwersytet Y dla studentów o niskich punktach na wejściu, ale sytuacja może wyglądać odwrotnie dla studentów o wysokich punktach na wejściu (zob. Rysunek 1.11). Idealnie byłoby, gdyby zależności pomiędzy wynikami a nakładami, jakie istnieją wewnątrz uniwersytetu (jeżeli są znane), były wzięte pod uwagę podczas mierzenia efektywności. Dotychczasowe badania oparte o dane zagregowane nie miały takiej możliwości¹⁵.

Po drugie, reszty z modeli regresji mogą się znacznie różnić w zależności od zmiennych uwzględnionych w modelu. Zmiana reszty może powodować, że rankingi jednostek będą się różnić w zależności od różnych modeli statystycznych. Ponadto wybór konkretnego modelu może być trudny z uwagi na to, że to, co bierzemy za dobre odzwierciedlanie danych na jego gruncie, jest najczęściej ograniczane przez małą liczebność próby.

Pomiar efektywności jednostek za pomocą DEA na poziomie zagregowanym budzi poważne zastrzeżenia (Woodhouse i Goldstein 1988). Wynik wskaźnika efektywności dla jednostki jest obliczany jako stosunek ważonych wyników do ważonych nakładów. W prostym przykładzie, gdzie mamy jeden wynik (y) i jeden nakład (x) (y – średni z uzyskanych rezultatów, a x – średnia z uzyskanej ilości punktów na wejściu np. średnia ilość punktów z rekrutacji) efektywność jednostki k jest mierzona jako iloraz: $\theta_k = y_k/x_k$. Jakkolwiek istnieje związek pomiędzy wynikami uzyskanymi na koniec studiów a nakładami na wejściu np. punktami z rekrutacji, zakładając, że zależność ta ma formę $y_k = a + bx_k$, to efektywność jednostki k jest wyrażona jako: $\theta_k = a/x_k + b$ i jest odwrotnie proporcjonalna do miar nakładów. Przykład ten może zostać rozszerzony na sytuacje z wieloma nakładami i wieloma wynikami. Dlatego DEA przy użyciu danych zagregowanych może mierzyć efektywność jednostki w sposób niedokładny.

¹⁵ Thanassoulis (1996) rozwinął metodę opartą o DEA w celu wyznaczenia odpowiednich celów dla szkół o różnych efektywnościach tak, aby zidentyfikować jednostki wzorcowe do naśladowania przez szkoły nieefektywne.

Rysunek 1.11 Efektywność dwóch uniwersytetów



Średnia punktacja studentów uzyskana przy przyjęciu na studia

Dlatego w tej sekcji omówiono niektóre metody mierzenia efektywności organizacji wykorzystujących dane dla indywidualnych jednostek wchodzących w jej skład.

Statystyczne metody parametryczne. Istnieje wiele metod statystycznych, które mogą zostać zastosowane w stosunku do indywidualnych uczniów i studentów w celu uzyskania oceny efektywności instytucji, do której uczęszczają. To jaka metoda będzie zastosowana, zależy od natury zmiennej zależnej. Tak więc regresja MNK jest odpowiednia, jeśli zmienna zależna jest zmienną ciągłą (na przykład zarobki absolwentów), modele logitowe lub probitowe są właściwe dla zmiennych binarnych (np. czy student ukończył studia), a uporządkowane modele logitowe lub probitowe mogą być stosowane, gdy zmienna zależna jest zmienną przyjmującą jedną ze skończonych uporządkowanych liczby możliwości (np. wynik uzyskany przez absolwenta na dyplomie albo wynik egzaminu ucznia). Modele statystyczne, które wykorzystują dane na poziomie indywidualnych jednostek w celu oceny związku między wynikami procesów kształcenia a nakładem, ale które nie uwzględniają efektów instytucjonalnych, mogą być uznane za niezadowalające z dwóch powodów. Po pierwsze, statystyczne testy istotności mogą być obciążone i przeszacowane. Po drugie, jeśli efekty instytucjonalne nie są wzięte pod uwagę, model nie mówi nic na temat wpływu instytucji na wyniki uzyskiwane przez uczestników procesu edukacji (Goldstein 1997); oznacza to, że taki model nie mówi nic na temat efektywności samej instytucji.

Jednak modele wielopoziomowe (ang. *multi level*) uwzględniają efekty instytucjonalne w ocenie związku pomiędzy indywidualnymi nakładami i wynikami.

W modelach tych zakłada się, że dane do analizy są hierarchiczne; na przykład uczniowie są częścią szkoły, do której chodzą, a studenci uniwersytetów, do których uczęszczają. Są to przykłady danych pochodzących z dwóch poziomów: studenci (uczniowie) to poziom 1, a uniwersytety (szkoły) to poziom 2. Można dodać dodatkowe poziomy do analizy; na przykład uczniowie są częścią szkoły, a ta podlega lokalnym władzom oświaty. Poniżej przedstawiony zostanie krótki przegląd metod wielopoziomowych ze szczególnym uwzględnieniem jego zastosowania w pomiarze efektywności. Zainteresowanych czytelników kierujemy do prac: Aitkina i Longforda (1986) i Goldsteina (1995), gdzie zamieszczone są bardziej szczegółowe informacje oraz dodatkowe rozszerzenia. Na początku rozważmy prosty model w kontekście szkolnictwa wyższego. Niech y_{ij} oznacza wynik osiągnięty przez i -tego studenta uczęszczającego na j -ty uniwersytet, model zapisać można jako:

$$y_{ij} = \beta_j + e_{ij} = \beta_0 + u_j + e_{ij} \quad (1.50)$$

Wynik uzyskiwany przez indywidualnego studenta może zostać rozbity na związany z jednostką do której uczęszcza (β_j) oraz odchyleniem od wpływu instytucji (e_{ij}). Wkład uniwersytetu (β_j) może być dalej podzielony na wartość średnią dla wszystkich uniwersytetów (β_0) oraz na odchylenie od średniej (u_j). Dlatego u_j jest często określane jako efekt (efekt uniwersytetu) i zostanie omówione poniżej.

Należy przyjąć kilka założeń. Najpierw zakłada się, że uniwersytety są losową próbą pochodzącą z całej populacji uniwersytetów. Składnik u_j wśród uniwersytetów ma rozkład normalny o średniej zero i wariancji σ_u^2 . Reszty dla indywidualnych studentów (e_{ij}) też mają rozkład normalny o średniej zero i wariancji σ_e^2 . Odpowiednie programy komputerowe są w stanie oszacować nieznanne parametry β_0 , σ_u^2 , σ_e^2 na podstawie, których można obliczyć u_j (zapisany jako \hat{u}_j) przy użyciu poniższego równania:

$$\hat{u}_j = \frac{n_j \sigma_u^2}{n_j \sigma_u^2 + \sigma_e^2} \cdot \frac{\sum_i (y_{ij} - \hat{y}_{ij})}{n_j}, \quad (1.51)$$

gdzie n_j – liczba studentów na uniwersytecie j . Efekt dla każdego uniwersytetu \hat{u}_j ma obliczony błąd próbkowy na podstawie, którego można obliczyć przedziały ufności. Na podstawie oszacowań i przedziałów ufności można ocenić działalność uniwersytetów. Instytucje szereguje się najczęściej według wartości \hat{u}_j od najmniejszej do największej z zaznaczeniem dolnej i górnej granicy przedziału ufności. Przyjmuje się, że jeżeli przedziały się nakładają, to brak jest zróżnicowania w działalności instytucji.

Prosty model może zostać rozszerzony poprzez włączenie kolejnych determinant zmiennej zależnej. Na przykład najlepszym wyznacznikiem osiągnięć studentów uzyskanych na dyplomie jest wynik uzyskany w momencie rekrutacji (x_{ij}). Model można teraz zapisać jako:

$$y_{ij} = \beta_0 + \beta_1 x_{ij} + u_j + e_{ij} \quad . \quad (1.52)$$

W modelu tym współczynnik dla zależności pomiędzy y_{ij} i x_{ij} jest stały, podczas gdy punkt przecięcia jest zmienny dla uniwersytetów. Dlatego parametry β_0 i β_1 są stałe, a u_j i e_{ij} są losowymi składowymi modelu. Dodanie zmiennej objaśniającej prowadzi do interpretacji reszty \hat{u}_j jako wskaźnika efektywności uniwersytetu w kontekście wartości przez niego dodanej. Odpowiednio można dodać kolejne zmienne objaśniające do modelu. Na końcu przedstawiamy model, w którym zarówno stała, jak i nachylenie pomiędzy y_{ij} i x_{ij} mogą być zmienne dla uniwersytetów, co można zapisać jako:

$$y_{ij} = \beta_0 + \beta_{1j} x_{ij} + u_j + e_{ij}, \quad (1.53a)$$

$$\beta_{1j} = \beta_1 + v_j \quad . \quad (1.53b)$$


Wynika z tego, że średnie nachylenie dla populacji uniwersytetów jest równe parametrowi β_1 , a odchylenie dla poszczególnych uniwersytetów wynosi v_j . Składniki u_j i v_j posiadają wielowymiarowy rozkład normalny (tutaj jest to dwuwymiarowy rozkład normalny, gdyż są tylko dwie zmienne losowe na poziomie drugim) o wariancji oczekiwanej równej zero. Wariancja u_j mierzy odchylenie dla stałych, punktów przecięcia $\text{var}(u_j) = \sigma_u^2$; a wariancja v_j zmienność nachylenia i wynosi $\text{var}(v_j) = \sigma_v^2$. Kowariancja pomiędzy u_j i v_j odpowiada kowariancji pomiędzy stałą a nachyleniem i wynosi $\text{cov}(u_j, v_j) = \sigma_{u,v}$. Wyniki dla poszczególnych studentów odchylają się od linii o e_{ij} . W modelu tym parametry β_0 i β_1 są stałe, a v_j , u_j i e_{ij} są współczynnikami losowymi.

Problemem modeli wielopoziomowych jest to, że w celu modelowania złożonych procesów edukacji same muszą być bardzo skomplikowane, przez co ich interpretacja staje się utrudniona. Ponadto bardziej złożone modele (na przykład te z udziałem nieciągłych zmiennych zależnych) mogą być trudne do wyliczenia.

Metody niestatystyczne i nieparametryczne. Alternatywą dla metod statystycznych jest DEA, gdzie jednostka decyzyjna, zamiast być szkołą, uniwersytetem, wydziałem lub regionem, jest w rzeczywistości indywidualnym uczniem lub studentem

(Thanassoulis 1999; Portela i Thanassoulis 2001; Thanassoulis i Portela 2002). Rozważyć można, dla przykładu, sytuację, w której rezultatami są wyniki uzyskiwane przez poszczególnych studentów, a nakładami są ich kwalifikacje wyrażone jako wynik punktów uzyskanych w momencie przyjęcia na studia. Dla każdego studenta można obliczyć jego efektywność poprzez zastosowanie metody DEA, ale wynik ten będzie miał w sobie dwa komponenty: jeden związany z wysiłkami studentów, a drugi odpowiadający efektywności nauczycieli, którzy go uczyli. Aby ocenić efektywność instytucji szkolnictwa wyższego, trzeba na początku rozbić wskaźniki efektywności studentów na te dwie składowe – metoda taka została zaproponowana przez Portelę i Thanassoulisa (2001, 2002). Rozważmy hipotetyczny zestaw danych dla studentów z dwóch uniwersytetów. Każdy z nich produkuje absolwentów, których jakość jest mierzona za pomocą wyników uzyskanych na dyplomie przy użyciu początkowych umiejętności studenta mierzonych punktami z rekrutacji. Dane na temat nakładów i wyników dla wszystkich studentów zostały zobrazowane na Rysunku 1.12.

Rysunek 1.12 Dekompozycja efektywności za pomocą DEA



Granica *EFCD* obejmuje wszystkich studentów i można ją nazwać granicą efektywności studenta w stosunku do wszystkich instytucji. Studenci leżący w obszarze *EF* i *CD* znajdują się na granicy, ale nie są efektywni (z powodu luzów). Stosując tradycyjną definicję efektywności DEA (zorientowaną na wyniki), student *F*, który leży na granicy ma wskaźnik efektywności równy 1, natomiast student *Y*, który znajduje się wewnątrz granicy, ma ogólny poziom efektywności równy OY/OY'' , który jest mniejszy niż 1. Innymi słowy, OY/OY'' oznacza stosunek wyników uzyskanych przez studenta *Y* do najlepszych osiągnięć uzyskanych w grupie studentów ze wszystkich uniwersytetów przy wzięciu pod uwagę kwalifikacji na wejściu studenta *Y*.

Jednakże wskaźnik efektywności wyznaczony przez porównanie osiągnięć studentów ze wszystkich uniwersytetów nie bierze pod uwagę wpływu danej instytucji na wyniki osiągane przez studentów. Przykładowo studenci z uniwersytetu *T* mają swoją własną granicę (nazywaną granicą efektywności studenta w ramach własnej instytucji) wyznaczoną przez *ABCD*. Podobnie granica dla uniwersytetu *S* wynosi *EFGH*. Dlatego student *Y* (z uniwersytetu *T*) osiąga efektywność w stosunku do własnej instytucji w wysokości OY/OY' , która oznacza stopień wyników uzyskanych przez studenta w odniesieniu do najlepszego wyniku uzyskanego przez studentów z jego uczelni, biorąc pod uwagę jego wejściowe kwalifikacje. Odległość YY'' mierzy wpływ uniwersytetu na wyniki osiągane przez studenta *Y*. Ocena efektywności pomiędzy instytucjami dla studenta *Y* wynosi OY'/OY'' i jest zmienna w zależności od nakładów.

Podsumowując, student *Y* charakteryzuje się wskaźnikiem efektywności OY/OY'' , z czego OY/OY' jest wynikiem jego własnych wysiłków, a OY'/OY'' jest konsekwencją efektywności uniwersytetu, na który uczęszcza. Można go skontrastować ze studentem *G* z uniwersytetu *S*, który charakteryzuje się wskaźnikiem efektywności w ramach własnej instytucji równym 1 (student osiąga najlepsze wyniki w porównaniu do studentów z tej samej uczelni, biorąc pod uwagę jego kwalifikacje na wejściu), ale jego wskaźnik efektywności w ramach wszystkich instytucji w wysokości $OG'/OG'' = OG/OG''$ jest mniejszy niż 1, ponieważ jego własny uniwersytet nie jest efektywny.

Efektywność każdej z instytucji może zostać zbadana poprzez porównanie wskaźników efektywności uczelni ze wskaźnikami efektywności własnych studentów. Komponent ten jest miarą efektywności samej instytucji i nie zawiera w sobie efektów związanych z różnymi wysiłkami studentów. Porównanie wszystkich trzech składników może być przydatne, w szczególności dla zarządzających organizacjami w celu określenia o ile można zwiększyć efektywność danej instytucji (Portela i Thanassoulis 2001; Thanassoulis i Portela 2002).

5. Badania empiryczne

Dokładne omówienie wszystkich empirycznych zastosowań metod opisanych w poprzednich częściach w kontekście edukacji i szkolnictwa wyższego wykracza poza zakres niniejszego opracowania. Dlatego też odnosimy się do ograniczonej liczby badań w celu uwypuklenia niektórych problemów i zastosowań technik pomiaru efektywności w kontekście edukacji. Bardziej kompletne podsumowanie wyników badań empirycznych można znaleźć w aneksie do niniejszego tekstu¹⁶.

Jednostka analizy

W studiach nad efektywnością wykorzystuje się rozmaite jednostki analizy. W ramach sektora szkolnego taką jednostką może być uczeń, szkoła, region i lokalne władze odpowiedzialne za edukację (Goldstein i Thomas 1996; Bradley i in. 2001; Engert 1996; Mayston i Jesson 1988). W przypadku szkolnictwa wyższego dotychczasowe badania starały się ocenić jego działanie, posługując się jako jednostką analizy pojedynczymi studentami, wydziałami tego samego typu w ramach różnych uniwersytetów, centrami, w których generowane są koszty w ramach różnych uniwersytetów, różnymi wydziałami w ramach jednego uniwersytetu, jak również samymi uniwersytetami (Johnes 1996, 2003; Beasley 1995; Friedman i Sinuany-Stern 1997). Badania prowadzone na poziomie indywidualnym dostarczają znaczną ilość informacji, ale ich rezultaty mogą być skomplikowane i trudne w interpretacji. Z drugiej strony badania prowadzone na poziomie danych zagregowanych są na ogół proste w interpretacji, co osiąga się jednak kosztem utraty informacji w procesie agregacji. Być może należy postawić pytanie: czy analizy prowadzone na różnych poziomach danych dostarczają takich samych, czy różnych miar efektywności?

Zwolennicy i osoby stosujące modelowanie wielopoziomowe twierdzą, że wyłącznie zastosowanie tego podejścia do danych z indywidualnego poziomu jest jedyną metodą, która jest zdolna właściwie uchwycić złożone efekty poszczególnych instytucji wpływających na wyniki studentów (Aitkin i Longford 1986). Pokazano, że wnioski na temat efektów działalności szkół uzyskane za pomocą modelowania wielopoziomowego prowadzą do innych rankingów szkół niż te, które są uzyskane za pomocą wykorzystania danych zagregowanych (Sammons i in. 1993). Podobne wyniki osiąga się przy zastosowaniu modeli regresji probitowej zastosowanych do danych na temat studentów i absolwentów (Baratti 2002; Naylor i in. 2000; Smith i Naylor 2001a; Smith i in. 2000). Dotychczas jednak żadne z badań nie porównywało ze sobą rankingów instytucji opartych na efektach modelowania

¹⁶ Z powodów ograniczonej liczby stron czasopisma odsyłamy zainteresowanych czytelników do oryginalnego tekstu (przyp. tłum.).

wielopoziomowego, efektach marginalnych z modelu probitowego czy rankingu opartego na danych zagregowanych.

Posługiwanie się metodą DEA w przypadku indywidualnych obserwacji, a nie całych instytucji, jest stosunkowo niedawno wprowadzoną innowacją. Pomimo sugestii, że zastosowanie DEA do poszczególnych uczniów może być pożyteczne pod kątem dostarczania nauczycielom informacji, którzy uczniowie nieefektywnie wykorzystują zasoby (Bessent i in. 1982), większość badań prowadzonych na polu edukacji wykorzystuje dane na temat wydziałów, instytucji czy poziomu administracyjnego. Bez wątplenia jest to związane z ogromnymi wymogami obliczeniowymi, które są potrzebne przy zastosowaniu metody DEA na poziomie indywidualnym: liczba obserwacji warunkuje zarówno liczbę i złożoność programowania liniowego, które muszą zostać rozwiązane. Dotychczas metoda DEA była wykorzystana na poziomie indywidualnym do bardzo różnej liczby obserwacji i obejmowała od ponad 2500 jednostek (Johnes 2003) do ponad 6500 jednostek (Portela i Thanassoulis 2001). Wstępne ustalenia sugerują, że rankingi uniwersytetów opartych na metodzie DEA zastosowanej do poziomu indywidualnego różnią się od tych, które powstały w oparciu o metodę DEA zastosowaną do tych samych danych, ale zagregowanych do poziomu uniwersytetu (Johnes 2003). Z pewnością potrzeba więcej badań w tym zakresie, dzięki którym będzie można wyznaczyć kierunki badań nad efektywnością jednostek sektora edukacyjnego.

Pytanie, które jest być może istotniejsze w kontekście szkolnictwa wyższego niż szkół, dotyczy tego, czy dane powinny być agregowane na poziomie różnych dyscyplin. Istnieją dowody na to, że czynniki determinujące wyniki prowadzonej działalności badawczej przez szkoły wyższe, oceny uzyskiwane przez studentów oraz procent osób, które nie kończą studiów, różnią się w zależności od wydziału i reprezentowanej dyscypliny. Świadczy to o tym, że badania efektywności w kontekście uniwersytetów powinny być przynajmniej zdezagregowane na poziomie dyscyplin i podaje się w wątpliwość sensowność porównań różnych wydziałów w ramach jednego uniwersytetu.

Na poziomie szkół istnieją pewne dowody na to, że rola czynników związanych z pochodzeniem uczniów czy ich początkowymi umiejętnościami odgrywa większą rolę w wyjaśnianiu różnic w umiejętności czytania niż w zakresie zdolności matematycznych i że wpływ działalności szkoły jest większy na osiągnięcia z matematyki niż z czytania (Sammons i in. 1993). Co więcej, korelacja rankingów szkół opartych na dwóch modelach efektów wytwarzanych przez szkołę – jeden wyprowadzony z wyników w umiejętności czytania, drugi z wyników w matematyce – nie jest szczególnie wysoka (Sammons i in. 1993). Może to zatem świadczyć o tym, że nawet na poziomie szkoły ewaluując funkcjonowanie instytucji, powinno przykładać się wagę do badania różnic pomiędzy wykładanymi przedmiotami.

Wyniki

Podobnie jak w przypadku poziomu, na którym prowadzona jest analiza efektywności, na specyfikę wyników również oddziałują względy dotyczące cech danych. W sytuacji idealnej powinno się uwzględnić miary wszystkich wyników działalności instytucji. Problem (poza ograniczeniami samych danych) polega na tym, że nie jest do końca jasne, czym są wyniki procesu edukacyjnego. Wynik prowadzonej działalności dydaktycznej może zostać podzielony na szereg składników, z których wszystkie można zaklasyfikować jako rezultaty procesu edukacyjnego. Wśród nich wymienić można: osiągnięcia studentów, wzrost produktywności siły roboczej, obecne i przyszłe dodatkowe korzyści konsumpcyjne.

Osiągnięcia studentów często udaje się przybliżyć, gdyż ocenianie odbywa się na wielu szczeblach edukacji, a tym samym często dostępne są dane na temat wyników różnych testów i egzaminów. Dane na temat liczby uczniów/studentów kończących naukę albo uzyskujących daną ocenę są często używane jako miary kształcenia w zagregowanych analizach szkół (Bessent i Bessent 1980; Kirjavainen i Loikkanen 1998) i zagregowanych badaniach uniwersytetów (Athanasopoulos i Shale 1997; El-Mahgary i Lahdelma 1995; Engert 1996; Madden i in. 1997). Miary te nie biorą jednak w wystarczający sposób pod uwagę jakości osiągnięć, tym samym średnie wyniki z egzaminów uzyskane w danej instytucji i procentowy wskaźnik sukcesu są często preferowane w analizach na poziomie zagregowanym, a zdobyte punkty na egzaminie są oczywistą miarą wyników w analizach prowadzonych na poziomie indywidualnym (zob. np. Chalos i Cherian 1995; Bradley i in. 2001; Johnes i Taylor 1990 w kwestii badania przy wykorzystaniu danych na poziomie zagregowanym dla szkół podstawowych, gimnazjów i uniwersytetów; zob. Goldstein i Spiegelhalter 1996; Smith i Naylor 2001b na temat badań dla szkół gimnazjalnych i szkół wyższych prowadzonych przy użyciu danych na poziomie indywidualnym).

Pojawiają się wątpliwości, co do używania danych na temat wyników z egzaminów jako rezultatów działalności dydaktycznej, ponieważ egzaminy nie weryfikują wszystkich umiejętności, które mogą być rozpatrywane jako pożądane wyniki edukacji (Bifulco i Bretschneider 2001), a osiągnięcia akademickie są tylko jednym wynikiem procesu nauczania (Bessent i in. 1982). Miary efektywności odzwierciedlające wpływ instytucji na zwiększenie produktywności absolwentów na rynku pracy zawierałyby ten dodatkowy rezultat działalności dydaktycznej, jednak dane dotyczące sukcesu absolwentów na rynku pracy nie zawsze są dostępne. Pierwsza ankieta dotycząca ekonomicznych losów absolwentów w Wielkiej Brytanii (ang. *The First Destinations Survey*), która dostarczała informacji na temat losów absolwentów po sześciu miesiącach od zakończenia studiów, pozwoliła na stworzenie miar opartych na wynikach, które odzwierciedlają sukces na rynku pracy w badaniach efektywności brytyjskich uniwersytetów (Johnes i Taylor 1989b, 1990; Johnes 1996; Bratti i in. 2004; Smith

i in. 2000). Kolejne bazy danych pozwoliły również na stworzenie miar odnoszących się do zarobków uzyskiwanych przez absolwentów (Naylor i in. 2000, 2002; Belfield i Fielding 2001).

W procesie nauczania instytucje edukacyjne produkują również jednostki, które ponoszą porażkę w procesie nabywania kwalifikacji. Marnotrawstwo spowodowane porażką w kontekście egzaminów, absencji (na poziomie edukacji szkolnej) czy niekończenia edukacji (w przypadku szkół średnich czy szkolnictwa wyższego) są efektami ubocznymi procesu nauczania, a ich zakres jest często niewidoczny, np. jeśli używa się liczby absolwentów, liczby przyjętych studentów lub miar sukcesu na rynku pracy absolwentów jako sposobu odzwierciedlenia wyników nauczania. Dlatego w badaniach szkół i szkolnictwa wyższego do analiz włącza się też procent osób, które nie dokończyły edukacji lub procent obecności, by oddać ten aspekt związany z działalnością dydaktyczną (Bradley i in. 2001; Harrison i Rouse 2002; Ruggiero 1996; Johnes i Taylor 1989a; Johnes 1996; Mante 2001; Ramanathan 2001).

Ograniczenia związane z dostępnością danych na temat miar osiągnięć, sukcesu na rynku pracy oraz procent osób niekończących edukację sprawiły, że alternatywnie używa się danych dotyczących nakładów w celu odzwierciedlenia poziomu wyników. Przyjmując, że celem badań nad efektywnością jest ustalenie relacji pomiędzy nakładami a wynikami w celu oceny funkcjonowania instytucji, istnieje duża liczba analiz, w których wyniki działalności dydaktycznej są przybliżane przez miary nakładów takie jak całkowita liczba studentów czy liczba studentów nowoprzyjętych (Abbott i Doucouliagos 2003; Ahn i Seiford 1993; Avkiran 2001; Beasley 1990, 1995; Tomkins i Green 1988) czy liczba godzin prowadzonych zajęć dydaktycznych (Ahn i in. 1989; Friedman i Sinuany-Stern 1997).

Miary dodatkowych korzyści konsumpcyjnych (obecnych lub przyszłych) wynikające z edukacji czy innych efektów zewnętrznych procesu nauczania (takich jak rozwój pożądanых nawyków pracowniczych, korzyści dla firm w postaci ułatwienia procesu rekrutacyjnego i doradztwa zawodowego dla studentów) są trudne do skonstruowania. W żadnych z dotychczasowych badań miary tego typu nie zostały w sposób satysfakcjonujący włączone do analizy jako odzwierciedlenie wyników działalności instytucji.

Wyniki działalności instytucji szkolnictwa wyższego są zarówno związane z procesem kształcenia, jak i prowadzenia badań naukowych, tym samym analiza efektywności uniwersytetów nie byłaby kompletna bez wzięcia pod uwagę wydajności w produkowaniu wyników w kontekście działalności badawczej. Podobnie jak z wynikami kształcenia miary oparte na nakładach, takie jak przychód z badań czy wydatki na badania, są popularnymi miarami, które zastępują wyniki prowadzonej działalności badawczej (Beasley 1990, 1995; Friedman i Sinuany-Stern 1997; Johnes i Johnes 1993; Tomkins i Green 1988; Hashimoto i Cohn 1997). Bardziej satysfakcjonujące

miary wyników związane z prowadzoną działalnością badawczą, uwzględniające zarówno ilość, jak i jakość, oparte są o wskaźniki, do których informacje dostarczane są w procesie oceny eksperckiej. Dane te są dostępne obecnie dla uniwersytetów z Australii i Wielkiej Brytanii (Abbott i Doucouliagos 2003; Avkiran 2001; Sarrico i Dyson 2000; Tomkins i Green 1988; Johnes i Taylor 1990, 1992; Johnes 1996; Johnes i in. 1993). W obliczu braku danych z ocen eksperckich alternatywną miarę produktywności naukowej stanowi liczba publikacji (Johnes i Johnes 1992, 1993; Madden i in. 1997; Tomkins i Green 1988) lub np. liczba publikacji w czołowych czasopismach naukowych, która ma uwzględniać zarówno ilości, jak i jakości (Johnes i Johnes 1992, 1993; Madden i in. 1997).

Problemy w badaniach efektywności związane są często z opomiarowaniem rezultatów prowadzonej działalności. Generalnie zakłada się, że w ramach procesu edukacyjnego z wielu nakładów produkuje się wiele wyników. Jednak brakuje jednej spójnej metody mierzenia efektywności przy braniu pod uwagę zarówno wielości nakładów, jak i wielości wyników. Atrakcyjnym rozwiązaniem tego problemu jest metoda DEA, gdyż łatwo radzi sobie z obiema tymi kwestiami. Niewiele jednak wiadomo o tym, jak na wskaźniki efektywności uzyskiwane metodą DEA wpływa (jeśli w ogóle) współliniowość pomiędzy wynikami i sama natura produkcji (np. rezultaty produkowane mogą być łącznie, symultanicznie lub osobno).

Z drugiej strony metody statystyczne są zwykle stosowane, gdy mamy jedną zmienną zależną i wiele zmiennych objaśniających. Dlatego też metody te mogą z łatwością poradzić sobie z sytuacjami, w których mamy do czynienia z jednym nakładem i wieloma wynikami lub wieloma nakładami i jednym wynikiem. W stosunku do sektora edukacji z typowym dla niego procesem, w którym z wielu nakładów uzyskuje się wiele wyników, metody statystyczne nie są satysfakcjonujące¹⁷. Najczęściej spotykanym podejściem używanym w obliczaniach efektywności, gdy mamy do czynienia z wieloma nakładami i wieloma wynikami przy użyciu metod statystycznych, jest obliczanie osobnego równania dla każdego z wyników (Gray i in. 1984; Johnes i Taylor 1990; Yang i in. 1999; Johnes 1996; Sammons i in. 1993; Goldstein 1997; Goldstein i in. 1993). Alternatywnie oblicza się złożone miary wyników i używa się ich jako zmiennej zależnej (Sengupta i Sfeir 1986; Bates 1997). Podejście to może jednak powodować liczne problemy.

Po pierwsze, jeśli wyniki są produktem łącznym, efektywność może nie być poprawnie oszacowana za pomocą oddzielnych równań dla każdego z wyników, co powoduje problem polegający na niewzięciu pod uwagę możliwych zmian pomiędzy uzyskiwanymi wynikami działalności edukacyjnej pod wpływem różnej relokacji nakładów. Tym samym instytucja może zostać uznana za nieefektywną na podstawie

¹⁷ Stochastyczna metoda graniczna może zostać jednak zaadaptowana do oceny procesów z użyciem wielu nakładów i wielu wyników. Zob. Sickles i in. (2002), gdzie zastosowano ją w sektorze lotniczym.

oceny tylko jednego z uzyskiwanych wyników z sugestią zmiany nakładów w celu wzrostu wydajności. Z kolei w przypadku oddzielnych obliczeń brak jest informacji na temat tego, jak zmiana w nakładach przeznaczonych na poprawienie jednego z wyników oddziałuje (pozytywnie lub negatywnie) na inne wyniki procesu produkcyjnego (Maystone i Jesson 1998). Chizmar i Zak (1983) stwierdzają, że modelowanie wielu wyników w formie produktu łącznego jest lepszym rozwiązaniem pod względem empirycznym i teoretycznym od modelowania ich przy użyciu oddzielnych równań. Po drugie, jeśli otrzyma się wiele oddzielnych miar efektywności, to powstają problemy w ich interpretacji. Powyższe problemy mogą zostać rozwiązane np. za pomocą analizy głównych składowych (Johnes 1996).

Nakłady

Nakład pracy i kapitału ludzkiego wykorzystywanego w procesie edukacji często mierzy się przez liczbę studentów i kadry. Dane tego typu powinny być bez problemu dostępne na poziomie szkoły, obszaru administracyjnego czy szkolnictwa wyższego (zob. np. Ahn i Seiford 1993; Athanassopoulos i Shale 1997; Chalos 1997; Barrow 1991; Avkiran 2001; Grosskopf i Moutray 2001). Używano także bardziej wyrafinowanych miar nakładów pracy takich jak czas poświęcany przez uczniów na odrobienie pracy domowej czy liczba odbytych zajęć (Lovell i in. 1994), takie dane są jednak rzadko dostępne. Alternatywą dla uwzględniania danych zarówno o liczbie studentów, jak i kadry jest łączenie ich w jedną miarę złożoną np. stosunek studentów do kadry (Bradley i in. 2001; Belfield i Fielding 2001; Johnes i Taylor 1990; Mancebon i Mar Molinero 2000; Mante i O'Brien 2002).

Próby zmierzenia jakości nakładów osobowych polegają zazwyczaj na włączaniu do analizy informacji na temat zarobków pracowników lub zmiennych obrazujących kwalifikacje akademickie, wiek i doświadczenie pracowników (zob. np. Sengupta i Sfeir 1986; Ahn i Seiford 1993; Chalos 1997; Friedman i Sinuany-Stern 1997; Ruggiero 1996, 2000; Bradlay i in. 2001; Soteriou i in. 1998). Jakość studentów ukazywana jest w badaniach efektywności prowadzonych na poziomie zagregowanym za pomocą średniej z wyników osiągnięć w populacji studentów zaczynających naukę lub proporcji osób z daną kwalifikacją w populacji studentów zaczynających naukę (Athanassopoulos i Shale 1997; Bessent i Bessent 1980; Chalos 1997; Johnes i Taylor 1990; Johnes 1996; Barrow 1991; Thanassoulis i Dunstan 1994), a w badaniach prowadzonych na poziomie indywidualnym przez średnią wyniku uzyskanego w procesie rekrutacji (zob. np. Johnes 2003; Portela i Thanassoulis 2001; Aitkin i Longford 1986; Yang i in. 1999; Bratti i in. 2004; Smith i Naylor 2001b). Miary związane z początkowymi osiągnięciami studentów oraz liczba studentów są często ze sobą łączone, by uwzględnić wpływ wywierany zarówno przez jakość studentów, jak i wielkość instytucji na produkowane wyniki (Athanassopoulos i Shale 1997).

Publikowanie danych finansowych dla instytucji edukacyjnych stwarza możliwość konstruowania miar nakładów, które obrazują nakład kapitału rzeczowego wykorzystywanego w procesie działalności edukacyjnej. W wielu badaniach jako miarę kapitału fizycznego stosuje się wydatki związane z różnymi nakładami (takie jak biblioteka czy sale informatyczne), przychód przeznaczony na różne cele, wartość aktywów czy poziom inwestycji (np. Harrison i Rouse 2002; Abbott i Doucouliagos 2003; Mante 2001; Mayston i Jesson 1988). Gdy dane te są dostępne, używa się również liczby książek czy komputerów jako alternatywy dla danych finansowych (Lovell i in. 1994; Ruggiero 1996, 2000).

Co więcej, poza już omówionymi nakładami pracy i kapitału ważnymi nakładami w procesie edukacji są również inne zmienne: pochodzenie społeczno-ekonomiczne, rasa, płeć, jak również zawód wykonywany przez rodziców oraz uzyskiwane przez nich dochody. Zmienne mające odzwierciedlać te cechy są tym samym często włączane na wszystkich poziomach analizy (zob. Bessent i Bessent 1980; Johnes i Taylor 1990 będące przykładami analiz prowadzonych na zagregowanym poziomie szkoły czy uniwersytetu; z kolei Goldstein (1997) oraz Bratti i in. (2004) przeprowadzili badania na poziomie indywidualnych – odpowiednio – szkół i uniwersytetów). Instytucje charakteryzują się dodatkowo własnym programem nauczania, zajęciami odbywającymi się poza lekcjami, lokalizacją, przepisami administracyjnymi i tymi dotyczącymi rekrutacji, jak również praktykami dydaktycznymi, które powinny być uznane za nakłady (Lovell i in. 1994; Goldstein i in. 1993; Goldstein i Thomas 1996; Yang i in. 2002; Johnes i Taylor 1990; Johnes 1996; Barrowe 1991).

Próba włączenia tak wielu miar nakładów i wyników w badania nad efektywnością instytucji powoduje kilka problemów. Po pierwsze, przy tak szerokim wachlarzu potencjalnych miar nakładów, z których wszystkie są *a priori* istotne, istnieje prawdopodobieństwo, że wystąpi między nimi problem współliniowości. Wiadomo, że problem ten pojawia się, gdy używa się metod statystycznych. Istnieją też pewne dowody na to, że może on wystąpić w metodach nieparametrycznych takich jak DEA, a jego konsekwencje różnią się w zależności od rozmiarów próby i poziomu analizy (Pedraja-Chaparro i in. 1999).

Konsekwencją wynikającą z trudności mierzenia nakładów jest to, że część z istotnych zmiennych obrazujących nakłady może zostać pominięta. Jako że w kontekście edukacji istnieje prawdopodobieństwo, że uwzględnione nakłady są skorelowane z tymi nieuwzględnionymi, pominięcie zmiennych będzie skutkowało w obciążonym wyniku w badaniach statystycznych (Bifulco i Bretschneider 2001). Pominięcie istotnych zmiennych nakładów może oddziaływać również na wartości wskaźników efektywności uzyskanych w ramach metody DEA.

Kolejny problem związany jest z wyborem, które zmienne obrazujące nakłady powinny zostać uwzględnione podczas konstruowania miar efektywności. Przyjęte

w ramach metod statystycznych praktyki polegają na użyciu wyłącznie tych nakładów, które są statystycznie istotne (choć może to być trudne do stwierdzenia, gdy występuje problem współliniowości). W przypadku metody DEA statystyczne testy istotności nie są możliwe do przeprowadzenia. Uwzględnienie wszystkich możliwych nakładów (istotnych i nieistotnych) byłoby poprawne tylko, jeśli na wyniki uzyskiwane metodą DEA nie oddziaływałaby liczba uwzględnionych nakładów. Tak się jednak nie dzieje (zob. np. Athanassopoulos i Shale 1997), a dodatkowe potencjalne problemy spowodowane przez współliniowość sprawiają, że strategia ta jest jeszcze mniej adekwatna. Jedno z rozwiązań polega na wybraniu zmiennych w oparciu o opinie eksperckie i wcześniejsze analizy statystyczne. Chalos i Cherian (1995) zaproponowali szereg kryteriów, które powinny zostać spełnione, by móc uwzględnić dany nakład w ramach metody DEA.

Po pierwsze, powinny istnieć empiryczne dowody przemawiające za włączeniem danej zmiennej. Po drugie, panel „ekspertki” powinien uznawać dany nakład za istotny. Po trzecie, analiza statystyczna powinna wykazywać istotny związek pomiędzy nakładami a określonymi wynikami. Wreszcie, nakłady nie mogą mieć wartości brakującej ani wynoszącej zero. Alternatywne i łatwiejsze w zastosowaniu podejście (Mancebon i Bandrés 1999; Mancebon i Mar Molinero 2000) polega na zaadoptowaniu strategii, z której wyprowadza się test statystyczny, analogiczny do testu F dla podzbioru zmiennych w regresji wielokrotnej. Po pierwsze, wszystkie możliwe nakłady i wyniki włączone w DEA muszą zostać wyszczególnione. Następnie wybiera się jedną zmienną (nakład lub wynik) i oblicza się efektywność DEA zarówno z uwzględnieniem tej zmiennej (model całkowity), jak i z jej wyłączeniem (model ograniczony). Trzeci krok polega na obliczeniu stosunku (oznaczonego przez ρ) efektywności modelu ograniczonego do efektywności modelu całkowitego dla wszystkich jednostek decyzyjnych. Na końcu, jeśli ρ różni się znacząco od 1 w dużej ilości jednostek, zmienna powinna zostać uwzględniona w metodzie DEA. Mancebon i Mar Molinero przyjęli zasadę, która mówi o tym, że: jeżeli mniej niż 15% jednostek decyzyjnych ma wartość $\rho \leq 0.9$, to dana zmienna może być usunięta z DEA.

Dalsze wątpliwości dotyczące doboru nakładów wynikają z rozróżnienie na nakłady, które mogą być pod kontrolą instytucji, i te, które się pod nią nie znajdują (np. czynniki środowiskowe). Istnieją dwa przeciwstawne podejścia do tego problemu. Pierwsze polega na uwzględnieniu w analizowaniu efektywności wszystkich nakładów niezależnie od tego, czy jednostka ma wpływ na ich kontrolowanie, czy nie (Cubbin i Tzanidakis 1998; Grosskopf 1996). Problem z takim podejściem polega na tym, że trudno jest uwzględnić fakt, że niektóre instytucje działają w niesprzyjających warunkach, tym samym instytucje te mogą zostać uznane za nieefektywne, gdy w rzeczywistości ich działanie jest konsekwencją otoczenia, w którym się znajdują. Dlatego w modelach, w których wszystkie nakłady są uwzględnione od początku,

nieefektywność może być przeszacowana¹⁸. Drugie podejście polega na zastosowaniu dwuetapowej procedury, w ramach której uzyskuje się wskaźniki efektywności dla danego zbioru instytucji przy użyciu odpowiednich metod (zob. część 4), a następnie efektywność ta jest w drugim etapie analizowana w odniesieniu do niekontrolowanych nakładów przy pomocy odpowiednich metod statystycznych¹⁹.

W wielu analizach efektywności przejęto drugie podejście (Bratti 2002; Bradley i in. 2001; Duncombe i in. 1997; Kirjavainen i Loikkanen 1998; Lovell i in. 1994; Mancebon i Mar Moliero 2000; McCarty i Yaisawarng 1993; Ramanathan 2001; Ray 1991; Grosskopf i Moutray 2001), jednak wciąż istnieje szereg zastrzeżeń, o których trzeba pamiętać w kontekście stosowania procedury dwuetapowej. Po pierwsze, metoda ta wymaga określenia funkcji opisującej zależności między niekontrolowanymi nakładami a funkcją produkcji (Ruggiero 1996). Tym samym błędy związane z błędną specyfikacją mogą pojawić się w drugim etapie.

Po drugie, wyniki efektywności mają zakres od 0 do 1, a więc albo powinny być odpowiednio przekształcone, albo na drugim etapie powinno użyć się odpowiednich metod, które rozwiązują problem tego, że zmienna zależna jest ograniczona np. analiza tobitowa (Lovell 1993).

Po trzecie, rozróżnienie, które z nakładów powinny zostać uwzględnione na pierwszym, a które na drugim etapie może być trudne. Lovell (1993) sugeruje, że zmienne uwzględniane w drugim etapie to wyłącznie te, nad którymi instytucja nie ma kontroli. Jednak definicja niekontrolowanej zmiennej może różnić się ze względu na kontekst analizy, dlatego decyzja odnośnie tego, które zmienne mają zostać użyte tylko w drugim etapie, musi uwzględniać ten aspekt.

Wreszcie, decyzja o zastosowaniu jedno- czy dwuetapowej procedury zależy od założenia odnośnie określonego stosunku między niekontrolowanymi nakładami a procesem produkcji i efektywnością. Dwuetapowa procedura zakłada, że zmienne (zazwyczaj niekontrolowane) nakładów w drugim etapie mają wpływ na efektywność przekształcania nakładów w wyniki. W przeciwieństwie do tego założenia procedura jednoetapowa zakłada, że wszystkie nakłady, włączając w to nakłady niekontrolowane, oddziałują na proces produkcji wyników z nakładów (ibid.).

¹⁸ Problem ten rozwiązał Ruggiero (1996), opracowawszy podejście w kontekście metody DEA, w którym każda jednostka decyzyjna posiada zbiór jednostek referencyjnych funkcjonujących w podobnych warunkach środowiskowych.

¹⁹ Równania dla dwóch etapów (pierwszy etap to wyznaczenie wskaźników efektywności, w drugim etapie dotyczy to determinant efektywności) mogą być szacowane osobno lub łącznie. Przykłady pierwszego z podejść są wymienione w tekście. Drugie podejście zostało niedawno rozwinięte i obejmuje zastosowanie metody opracowanej przez Battese i Coelli (1995), w której wykorzystuje się metodę największej wiarygodności do jednoczesnego oszacowania efektywności w pierwszym etapie według SFA i równania z drugiego etapu, gdzie uprzednio wyznaczona efektywność jest powiązana ze zmiennymi, które mogą wyjaśniać różnice wewnątrzinstytucjonalne. Przykład zastosowania tej metody w kontekście kosztów szkolnictwa wyższego w Wielkiej Brytanii przedstawiono w Stevens (2001).

Badacze powinni być zatem świadomi tego rozróżnienia i wybierać tę metodę, która odpowiada ich założeniom. W rzeczywistości o wyborze metody często decydują względy praktyczne. Na przykład, gdy występuje współliniowość między kontrolowanymi a niekontrolowanymi nakładami, jednoetapowa procedura jest bardziej adekwatna, jeśli w pierwszym kroku używa się metod statystycznych.

Istnieje niewiele porównań rezultatów otrzymanych w wyniku zastosowania jedno- i dwuetapowej procedury. Wyjątkiem jest badanie przeprowadzone przez McCarty'ego i Yaisawarnga (1993), którzy zaadaptowali dwuetapowe podejście, by przy użyciu modelu tobitowego w drugim etapie powiązać wskaźniki efektywności DEA ze zmiennymi, które są poza kontrolą jednostek decyzyjnych. Obliczyli w tym kontekście nowy zbiór efektywności w oparciu o drugi etap i pokazali, że wskaźniki efektywności uzyskane za pomocą podejścia dwuetapowego w niewielkim stopniu różnią się od tych uzyskanych za pomocą metody jednoetapowej, w której od początku w zbiorze nakładów były zarówno zmienne kontrolowane, jak i niekontrolowane.

Czasami głównym celem analizy jest ocena wpływu zmiennych środowiskowych, takich jak lokalizacja instytucji czy skutki zmian polityki wobec sektora, na wskaźniki efektywności. Jeśli używa się metod statystycznych, można włączyć odpowiednie zmienne zero-jedynkowe w celu ocenienia tych efektów. Natomiast jeśli używa się metody DEA, to nie jest do końca jasne, w jaki sposób zbadana być może siła tych zależności. Soterou i in. (1998) przeprowadzili badania na temat wpływu lokalizacji szkoły (region miejski czy wiejski) na efektywność jej działalności. W pierwszym kroku oszacowano wskaźniki efektywności DEA dla dwóch grup szkół podzielonych według lokacji. Następnie nakłady wszystkich nieefektywnych jednostek zostały dostosowane do postaci, którą przyjęłyby, znajdując się na granicy produkcji charakterystycznej dla swojej lokalizacji, podczas gdy dla efektywnych jednostek nie wprowadzano żadnych zmian. Dla tak zmodyfikowanych danych przeprowadzono ponowne obliczenia wskaźników efektywności metodą DEA. Na końcu porównano wskaźniki efektywności uzyskane za pomocą DEA dla każdej z grup szkół i oceniono istotność ich różnic za pomocą testów nieparametrycznych Manna-Whitneya. Posługując się tą metodą, Soteriou i in. (1998) nie stwierdzili istotnych różnic w efektywności szkół wynikających z ich odmiennych lokalizacji. Podobna metoda użyta została do określenia wpływu programów wprowadzanych do szkół mających na celu podniesienie efektywności kształcenia (Diamond i Madewitz 1990).

Z pewnością zidentyfikowanie nakładów i wyników w kontekście edukacji rodzi poważne problemy. W dalszej części niniejszego tekstu przedstawimy wyniki badań empirycznych, pokazując, jaki wpływ na wyniki w zakresie wskaźników efektywności mają różne specyfikacje modeli oraz wybór metody analizy.

Wiarygodność wyników analiz efektywności

Sukces prowadzonych analiz efektywności zależy od dostarczenia wiarygodnych i spójnych rankingów instytucji, które nie są wrażliwe na specyfikę nakładów i wyników, ilość włączonych obserwacji, założenia co do efektu skali czy metody użyte do obliczenia wskaźników efektywności. Jest to niezmiernie istotne dla wiarygodności analiz i stało się przedmiotem badań. Niektóre z ich wyników opiszemy poniżej.

Badania na poziomie indywidualnym wykorzystujące metody statystyczne (takie jak modele wielopoziomowe czy modele probitowe) dowiodły, że większość instytucji nie może być wyodrębniana na gruncie wartości wskaźników efektywności. W badaniach z wykorzystaniem danych dla uczniów ze szkół przedziały ufności dla efektów wytwarzanych przez szkołę są bardzo szerokie, niewiele szkół może być zatem wyodrębnionych w oparciu o ich działanie (Goldstein i in. 1993; Goldstein i Spiegelhalter 1996; Goldstein i Thomas 1996), a znacząca różnica występuje jedynie między szkołami najmniej i najbardziej produktywnymi. W badaniach dotyczących nieukończenia studiów przez studentów efekty wytwarzane przez uniwersytet są znacząco różne od mediany tylko dla 6 najniżej i 12 najwyżej sklasyfikowanych uniwersytetów (Smith i Naylor 2001a). Podobne wyniki otrzymano, gdy wyniki działalności uniwersytetu były mierzone za pomocą wskaźników dla rynku pracy (Smith i in. 2000). Na podstawie tego można stwierdzić, że tworzenie rankingów instytucji w oparciu o efekty ich działalności, które nie różnią się pomiędzy poszczególnymi jednostkami, nie jest poprawne (Yang i in. 1999).

Przeprowadzono liczne badania, w których sprawdzono jak specyfikacja nakładów i wyników wpływa na wartość wskaźników efektywności. Badania te były prowadzone głównie z użyciem metody DEA w odróżnieniu od zastosowania metod statystycznych, dla których istotność zbioru nakładów i wyników może być testowana. W kontekście szkolnictwa wyższego wnioski obejmują zarówno twierdzenie, że uzyskane rankingi są w wystarczającym stopniu stabilne bez względu na specyfikę nakładów i/lub wyników (Tomkins i Green 1988; Abbot i Doucouliagos 2003; Johnes 2003), jak również, że na wyniki oddziałuje specyfikacja nakładów i wyników (Ahn i Seiford 1993; Johnes i Johnes 1992). W badaniach efektywności działalności naukowej prowadzonej na wydziałach ekonomii na brytyjskich uniwersytetach porównano wyniki otrzymane przy użyciu 192 różnych specyfikacji nakładów i wyników i na podstawie analizy skupień wykazano istnienie zaledwie dwóch odrębnych grup rezultatów (Johnes i Johnes 1993). Głównym czynnikiem różniącym obie grupy, w których uzyskano odmienne wyniki, było włączenie (lub brak takiego włączenia) do zbioru nakładów grantów badawczych *per capita*.

W badaniach funkcjonowania Training and Enterprise Councils (TECs) w Wielkiej Brytanii włączenie kolejnych zmiennych okazało się zwiększać liczbę TECs uznanych

za efektywne (Cubbin i Zamani 1996), pomimo że wyniki okazały się nie być wrażliwe na orientację (na nakłady lub na wyniki) modelu DEA.

W przypadku szkół średnich wyniki są również niejednoznaczne (Färe i in. 1989; Harrison i Rouse 2002; Smith i Mayston 1987; Kirjavainen i Loikkanen 1998; Man- te 2001; Engert 1996). Z badania fińskich szkół średnich wyłania się interesujące spostrzeżenie, a mianowicie szkoły średnie zajmujące najwyższe i najniższe pozycje (pod względem wskaźników efektywności) są mniej podatne na zmianę specyfikacji modelu niż te plasujące się w środku stawki (Kirjavainen i Loikkanen 1998). Nie jest to zaskakujące, jeśli pod uwagę weźmiemy, że wyniki analizy przeprowadzonej na poziomie indywidualnym nie wykazały rozróżnienia pod względem efektywności między instytucjami zajmującymi miejsca w połowie stawki.

Te niejednoznaczne wnioski dotyczące wpływu specyfikacji modelu na ostateczne wyniki mogą być konsekwencją tego, co było celem przeprowadzonych badań: czy było nim zmierzenie tego samego typu efektywności w ramach różnych modeli (zob. np. Johnes 2003, w kwestii analizy efektywności wydziałów ekonomii pod kątem produkcji najwyższych stopni przy pomocy różnego zbioru nakładów i wyników), czy też mierzenie różnego rodzaju efektywności (dla przykładu, dwa modele wyszczególnione przez Athanassopoulou i Shale mierzą odpowiednio efektywność kosztową i efektywność wyników). Lovell i in. (1994) badają efektywność szkół w osiąganiu krótko-, średnio- i długoterminowych celów. Wskaźniki efektywności wyprowadzone z modelu dla celów krótkookresowych są w znacznej mierze różne od tych uzyskanych odpowiednio dzięki modelowi średnio- i długookresowemu. Co więcej, czynniki determinujące każdy z tych zbiorów wskaźników efektywności również się między sobą różnią. Podobna różnica w uzyskiwanych wskaźnikach efektywności zachodzi, gdy rozważa się różne typy efektywności. Wyniki pomiaru efektywności technicznej i efektywności wartościowej ukazują, że liczba jednostek efektywnych w drugim przywołanym sensie jest mniejsza niż liczba jednostek efektywnych technicznie (Korhonen i in. 2001).

Wyniki badań statystycznych również potwierdzają hipotezę, że wskaźniki efektywności różnią się, gdy wyprowadzane są na podstawie ewaluacji efektywności instytucji w osiąganiu różnych celów. W badaniu, w którym wzięto pod uwagę cztery różne miary działania uniwersytetu, wykorzystując kolejno dane na temat losów ekonomicznych absolwentów, wyników na dyplomach, odsetka osób niekończących edukacji (zauważmy, że wskaźniki nieukończenia edukacji przedstawiane są w odwrotnej formie, tak by umożliwić spójną interpretację pomiędzy wskaźnikami wydajności) i wskaźnika badań naukowych, współczynnik korelacji rang wynosił od -0.40 do 0.13²⁰,

²⁰ W rzeczywistości wskaźnik efektywności oparty na sukcesie absolwentów na rynku pracy jest negatywnie skorelowany z pozostałymi trzema wskaźnikami, z r od -0.07 do -0.40. Pozostałe wskaźniki efektywności są ze sobą skorelowane pozytywnie.

wskazując tym samym na duże zróżnicowanie uzyskanych wskaźników efektywności (Johnes 1996). Podobnie w badaniach przeprowadzonych na poziomie indywidualnym dzieci w wieku szkolnym wskaźniki efektywności otrzymane na podstawie wyników testów z czytania i wyników testów z matematyki są ze sobą skorelowane ($r = 0.62$), ale stopień tej korelacji nie jest wysoki (Sammons i in. 1993). Co więcej, w badaniu efektywności szkół publicznych w Nowym Jorku, które wykorzystywało stochastyczną metodę graniczną, średnia efektywność była uzależniona od definicji wyniku (zdefiniowano pięć miar wyników i średnia efektywność była w zakresie od 0.55 do 0.91). Ponadto pokazano, że różnice w przyjętych miarach nakładów odgrywają rolę w każdym z modeli (Kang i Greene 2002).

Nie ma dużo dowodów dotyczących wpływu pominięcia instytucji na stabilności funkcji produkcji, a co za tym idzie, wpływu na wskaźniki efektywności. Smith i Mayston (1987) pokazali zresztą, że nie jest to zaskakujące – wrażliwość wyników na pominięcie jednostek decyzyjnych zależy od tego, czy pominięta jednostka jest lub nie jest obserwacją odstającą. Jeżeli jest obserwacją odstającą, to jej pominięcie wpływa na wyniki. Jedną z metod oceny wpływu obserwacji jest posłużenie się metodą *jackknife*, w której dla określonego modelu DEA po kolei pomija się jedną jednostkę decyzyjną, a średni wskaźnik efektywności uzyskany z $(n-1)$ obliczeń porównuje się z wynikiem uzyskanym dla wszystkich n -jednostek. W badaniach rejonów szkolnych w Missouri i szkół średnich z Finlandii wyniki uzyskane za pomocą metody *jackknife* wskazują, że wskaźniki efektywności są stabilne (Färe i in. 1989; Bonesrønning i Rattsø 1994).

Badania na temat wpływu przyjętych korzyści skali na pomiar efektywności nie są liczne. W kontekście DEA Cubbin i Zamani (1996) zauważyli, że ilość efektywnych jednostek decyzyjnych zwiększa się (zgodnie z przewidywaniami) wraz z przyjęciem założenia o VSR niż CRS. Ahn i Seiford (1993) uważają, że otrzymane wyniki są niewrażliwe na założenie co do korzyści skali, ale są uzależnione od tego, czy użyje się modelu addytywnego, czy modelu multiplikatywnego. Athanassopoulos i Shale (1997) zauważyli, że wyniki dotyczące założeń korzyści skali różnią się w zależności od modelu: wyniki dla efektywności kosztowej mierzonej metodą DEA różnią się w zależności od tego, czy użyje się modelu CRS, czy modelu VRS; z kolei istnieje niewielki wpływ wyboru co do założeń korzyści skali na wskaźniki efektywności uzyskane metodą DEA zorientowaną na wyniki.

Badania wskazują, że wybór metody analizy ma wpływ na wartość wskaźników efektywności i rankingów instytucji, z których znaczna część dotyczy badań porównujących uzyskane wyniki za pomocą metody DEA i metod statystycznych (metody deterministyczne i stochastyczne). Banker i in. (1993) posługując się danymi pochodzącymi z symulacji w celu porównania COLS (z błędem deterministycznym) i DEA, odkryli, że skuteczność jednej metody w porównaniu z drugą zależy przede

wszystkim od rzeczywistego rozkładu wskaźników nieefektywności i wielkości próby. Wydaje się, że ta metoda jest bardziej skuteczna niż COLS dla małych prób ($n=25$). Jednak w sytuacji, w której pojawiają się istotne błędy pomiaru, żadna z metod nie działa szczególnie dobrze. Wyniki te potwierdzają Bifulco i Bretschneider (2001), którzy również wykorzystali symulowane dane. Pokazali, że dla złożonych zestawów danych, które charakteryzują się endogenicznością i zawierają błędy pomiaru (cechy, które w szczególności mogą się pojawić w zbiorach danych dotyczących edukacji) ani COLS, ani DEA nie są w stanie poprawnie wyznaczyć wskaźników dla więcej niż 31% szkół tak, żeby odpowiadały one wartościom rzeczywistym.

Szereg badań empirycznych został poświęcony porównaniom wyników otrzymanych przy użyciu MNK (z błędem deterministycznym) i metody DEA. W badaniach odnoszących się do kształcenia ekonomii w amerykańskich szkołach stwierdzono wysoką korelację pomiędzy wskaźnikami efektywności otrzymanymi dzięki trzem różnym modelom MNK i wskaźnikom efektywności otrzymanym przy użyciu DEA (r jest w zakresie od 0.712 do 0.822) (Diamond i Medewitz 1990). Bates (1993) stwierdza, że wskaźniki efektywności otrzymane dzięki MNK i DEA dla LEA w Wielkiej Brytanii są szczególnie podobne na szczycie i na dole rankingów efektywności. Jednak inne badanie dotyczące LEA w Wielkiej Brytanii wskazuje na raczej niski stopień korelacji (r jest w zakresie od 0.32 do 0.53) pomiędzy wskaźnikami efektywności uzyskanymi za pomocą dwóch modeli MNK i tymi otrzymanymi dzięki metodzie DEA. Dalsze dowody na to, że wybór metody (MNK czy DEA) oddziałuje na ranking efektywności, możemy znaleźć u Cubbina i Zamaniego (1996), którzy badali TEC.

DEA była również porównywana do stochastycznej metody granicznej. Gong i Sickles (1992), posługując się symulowanymi danymi, wskazują, że im bardziej niepoprawne określenie specyfikacji funkcji w stochastycznej metodzie granicznej i im wyższy stopień korelacji pomiędzy wskaźnikami nieefektywnością i zmiennymi objaśniającymi, tym bardziej atrakcyjna staje się metoda DEA. Badania empiryczne dostarczają niejednoznacznych wyników na spójność szacowanej efektywności w obu modelach, która waha się od niskiego stopnia korelacji w kontekście TEC w Wielkiej Brytanii (Cubbin i Zamani 1996) i brytyjskich uniwersytetów (Johnes 1998a) po stosunkowo wysoki stopień korelacji w kontekście LEA w Wielkiej Brytanii (Bates 1997). Chakraborty i in. (2001) pokazali, że rankingi dzielnic, w których zlokalizowane są szkoły wynikające z reszt uzyskanych z modelu tobitowego zastosowanego na drugim etapie analizy do powiązania wskaźników efektywności DEA z niekontrolowanymi nakładami, są podobne do tego, który został otrzymany przy użyciu stochastycznej metody granicznej z półnormalnym rozkładem błędów.

Metoda DEA zastosowana na poziomie indywidualnym została niedawno porównana z modelowaniem wielopoziomowym. Wstępna analiza wyników ujawnia wysoki stopień korelacji pomiędzy efektywnością uczniów w ramach jednej szkoły

oszacowanej odpowiednio przy użyciu metody DEA na poziomie indywidualnym i wielopoziomowego modelowania (Thanassoulis i in. 2003). Podobnie wysoki stopień korelacji występuje pomiędzy efektywnością uczniów w ramach wszystkich szkół oszacowaną na podstawie obu metod. Istnieje jednak potrzeba określenia zależności pomiędzy efektywnością instytucji uzyskaną dzięki wielopoziomowemu modelowaniu i DEA na poziomie indywidualnym.

Podobne niejednoznaczne wyniki zostały uzyskane przez porównanie wyników uzyskanych za pomocą metod statystycznych. Gdy porównuje się różne funkcje oszacowane przy pomocy MNK, podobieństwa były znacznie większe, gdy badano efektywność zajęć z ekonomii w Stanach Zjednoczonych (r od 0.31 do 0.956) niż w kontekście LEA w Wielkiej Brytanii (r od 0.21 do 0.60). Niemniej MNK i stochastyczna metoda graniczna wydają się dostarczać podobnych rankingów efektywności w kontekście LEA (Barrow 1991) i TEC (Cubbin i Zamani 1996), chociaż pierwsze z wymienionych badań (zgodnie z oczekiwaniami) wskazuje, że rzeczywiste wskaźniki efektywności są znacząco wyższe, gdy obliczane są za pomocą COLS, a nie modelu stochastycznego.

6. Zakończenie

Sposoby pomiaru efektywności w edukacji znacznie się rozwinęły od czasów, gdy brano pod uwagę tylko jeden wynik działalności instytucji. Przyjmuje się obecnie, że instytucje edukacyjne wytwarzają szereg wyników przy użyciu wielu nakładów, dlatego musi to zostać uwzględnione w tworzonych rankingach instytucji, które mają zobrazować ich efektywność.

Zaprezentowany w niniejszym rozdziale przegląd literatury jasno pokazuje, że każda osoba zainteresowana mierzaniem efektywności instytucji edukacyjnych ma przed sobą do wyboru cały wachlarz metod analizy i różnych sposobów podejścia do tematu. Ponadto otoczenie produkcyjne w sektorze edukacji różni się od tego, które spotykamy w bardziej tradycyjnych sektorach produkcji, co niewątpliwie sprawia problem przy próbach analizy efektywności. Przegląd empirycznych badań, w których zastosowano metody pomiaru efektywności w kontekście edukacji, wskazuje, że wyniki studiów nad efektywnością w postaci rankingów ocenianych instytucji mogą się różnić w zależności od doboru metod (na przykład: parametryczna i nieparametryczna); specyfikacji i pomiaru nakładów i wyników (jak również sposobu uwzględnienia nakładów, które nie znajdują się pod bezpośrednią kontrolą analizowanej instytucji); poziomu używanych danych (indywidualna jednostka, dyscyplina czy instytucja); założeń przyjętego modelu (postać funkcji produkcji lub kwestia tego, czy przyjmuje się istnienie korzyści skali produkcji). Ważne jest, aby pamiętać o tych kwestiach, analizując i interpretując jakiegokolwiek wyniki badań nad efektywnością instytucji.

Mocną stroną badań nad efektywnością stanowią nie tyle dostarczane przez nie „rankingi”, ale raczej bogaty zasób dostarczanych informacji. Informacje te zależą od zastosowanych metod. Metoda statystyczna może wskazywać na istotne czynniki warunkujące uzyskane rezultaty działalności edukacyjnej; metoda nieparametryczna może dostarczać informacji na temat realnych celów, jakie są do osiągnięcia przez nieefektywną instytucję, jak również informacji o podobnych (pod względem nakładów i wyników), ale lepiej funkcjonujących instytucjach, których praktyki nieefektywna organizacja może starać się naśladować.

Metody mierzenia efektywności są wciąż rozwijane i poszerzane, co z kolei gwarantuje zapotrzebowanie na ciągłe badania empiryczne w zakresie ich zastosowań w kontekście edukacji.

Tłumaczenie: Joanna Wolszczak-Derlacz i Jakub Krzeski

Literatura

- Abbott, M. i Doucouliagos, C. (2003). The efficiency of Australian universities: A data envelopment analysis. *Economics of Education Review*. 22(1): 89–97.
- Ahn, T. i Seiford, L.M. (1993). Sensitivity of data envelopment analysis to models and variable sets in a hypothesis test setting: the efficiency of university operations (191–208). W: Y. Ijiri (red.), *Creative and Innovative Approaches to the Science of Management*. Westport, CT: Quorum Books.
- Ahn, T., Arnold, V., Charnes, A. i Cooper, W.W. (1989). DEA and ratio efficiency analyses for public institutions of higher learning in Texas. *Research in Governmental and Nonprofit Accounting*. 5: 165–185.
- Aigner, D.J., Lovell, C.A.K. i Schmidt, P. (1977). Formulation and estimation of stochastic frontier production function models. *Journal of Econometrics*. 6(1): 21–37.
- Aitkin, M. i Longford, N. (1986). Statistical modelling in school effectiveness studies. *Journal of the Royal Statistical Society, Series A*. 149: 1–43.
- Arceus, F.J. i Coleman, D.F. (1997). An efficiency review of university departments. *International Journal of Systems Science*. 28(7): 721–729.
- Athanassopoulos, A.D. i Shale, E. (1997). Assessing the comparative efficiency of higher education institutions in the UK by means of data envelopment analysis. *Education Economics*. 5(2): 117–34.
- Avkiran, N.K. (2001). Investigating technical and scale efficiencies of Australian universities through data envelopment analysis. *Socio-Economic Planning Sciences*. 35(1): 57–80.
- Banker, R.D., Charnes, A. i Cooper, W.W. (1984). Some models for estimating technical and scale inefficiencies in data envelopment analysis. *Management Science*. 30(9): 1078–1092.

- Banker, R.D., Charnes, A., Cooper, W.W., Swarts, J. i Thomas, D. (1989). An introduction to data envelopment analysis with some of its models and their uses. *Research in Governmental and Nonprofit Accounting*. 5: 125–163.
- Banker, R.D., Gadh, V.M. i Gorr, W.L. (1993). A Monte Carlo comparison of two production frontier estimation techniques: corrected ordinary least squares and data envelopment analysis. *European Journal of Operational Research*. 67: 332–343.
- Barrow, M. (1991). Measuring the Local Education Authority performance: A frontier approach. *Economics of Education Review*. 10(1): 19–27.
- Bates, J.M. (1993). The efficiency of Local Education Authorities. *Oxford Review of Education*. 19(3): 277–289.
- Bates, J.M. (1997). Measuring predetermined socio-economic “inputs” when assessing the efficiency of educational outputs. *Applied Economics*. 29(1): 85–93.
- Battese, G.E. i Coelli, T.J. (1995). A model for technical inefficiency effects in a stochastic frontier production function for panel data. *Empirical Economics*. 20: 325–332.
- Beasley, J.E. (1990). Comparing university departments. *Omega*. 18: 171–183.
- Beasley, J.E. (1995). Determining the teaching and research efficiencies’, *Journal of the Operational Research Society*. 46(4): 441–452.
- Belfield, C.R. i Fielding, A. (2001). Measuring the relationship between resources and outcomes in higher education in the UK. *Economics of Education Review*. 20: 589–602.
- Bessent, A.M. i Bessent, E.W. (1980). Determining the comparative efficiency of schools through data envelopment analysis. *Educational Administration Quarterly*. 16(2): 57–75.
- Bessent, A.M., Bessent, E.W., Kennington, E.W. i Reagan, B. (1982). An application of mathematical programming to assess the productivity in the Houston independent school district. *Management Science*. 28: 1355–1367.
- Bifulco, R. i Bretschneider, S. (2001). Estimating school efficiency: A comparison of methods using simulated data. *Economics of Education Review*. 20: 417–429.
- Bonesrønning, H. i Rattsø, J. (1994). Efficiency variation among the Norwegian high schools: Consequences of equalization policy. *Economics of Education Review*. 13(4): 289–304.
- Bradley, S., Johnes, G. i Millington, J. (2001). The effect of competition on the efficiency of secondary schools in England. *European Journal of Operational Research*. 135: 545–568.
- Bratti, M. (2002). Does the choice of university matter? A study of the differences across UK universities in life sciences students’ degree performance. *Economics of Education Review*. 21: 431–443.
- Bratti, M., McKnight, A., Naylor, R. i Smith, J. (2004). Higher education outcomes, graduate employment and university performance indicators. *Journal of the Royal Statistical Society: Series A*. 167: 475–496.
- Breu, T.M. i Raab, R.L. (1994). Efficiency and perceived quality of the nation’s ‘Top 25’ national universities and national liberal arts colleges: An application of data envelopment analysis to higher education. *Socio-Economic Planning Sciences*. 28(1): 33–45.

- Chakraborty, K., Biswas, B. i Lewis, W.C. (2001). Measurement of technical efficiency in public education: A stochastic and nonstochastic production frontier approach. *Southern Economics Journal*. 67(4): 889–905.
- Chalos, P. (1997). An examination of budgetary inefficiency in education using data envelopment analysis. *Financial Accountability and Management*. 13(1): 55–69.
- Chalos, P. i Cherian, J. (1995). An application of data envelopment analysis to public sector performance measurement and accountability. *Journal of Accounting and Public Policy*. 14: 143–160.
- Charnes, A., Cooper, W.W. i Rhodes, E. (1978). Measuring the efficiency of DMUs. *European Journal of Operational Research*. 2: 429–444.
- Charnes, A., Cooper, W.W. i Rhodes, E. (1979). Measuring the efficiency of decision making units: A short communication. *European Journal of Operational Research*. 3(4): 339
- Chizmar, J.F. i Zak, T.A. (1983). Modeling multiple outputs in educational production functions. *American Economic Review, Papers and Proceedings*. 73(2): 18–22.
- Coelli, T., Rao, D.S.P. i Battese, G.E. (1998). *An Introduction to Efficiency and Productivity Analysis*. Norwell, MA: Kluwer Academic.
- Cubbin, J. i Tzanidakis, G. (1998). Regression versus data envelopment analysis for efficiency measurement: An application to the England and Wales regulated water industry. *Utilities Policy*. 7: 75–85.
- Cubbin, J. i Zamani, H. (1996). A comparison of performance indicators for Training and Enterprise Councils in the UK. *Annals of Public Choice and Cooperative Economics*. 67(4): 603–632.
- Dantzig, G.B. (1951). Maximization of a linear function of variables subject to linear inequalities. W: T.C. Koopmans (red.), *Activity Analysis of Production and Allocation*. New York: Wiley.
- Deller, S.C. i Rudnicki, E. (1993). Production efficiency in elementary education: The case of Maine public schools. *Economics of Education Review*. 12(1): 45–57.
- Diamond, A. i Medewitz, J.N. (1990). Use of data envelopment analysis in an evaluation of the efficiency of the DEEP program for economic education. *Journal of Economic Education*. 21: 337–354.
- Duncombe, W., Miner, J. i Ruggiero, J. (1997). Empirical evaluation and bureaucratic models of inefficiency. *Public Choice*. 93: 1–18.
- Dyson, R.G., Allen, R., Camanho, A.S., Podinovski, V.V., Sarrico, C.S. i Shale, E.A. (2001). Pitfalls and protocols in data envelopment analysis. *European Journal of Operational Research*. 132(2): 245–259.
- El-Mahgary, S. i Lahdelma, R. (1995). Data envelopment analysis: Visualizing the results. *European Journal of Operational Research*. 85: 700–710.
- Engert, F. (1996). The reporting of school district efficiency: The adequacy of ratio measures. *Public Budgeting and Financial Management*. 8(2): 247–271.

- Färe, R., Grosskopf, S. i Lovell, C.A.K. (1988). An indirect efficiency approach to the evaluation of producer performance. *Journal of Public Economics*. 37(1): 71–89.
- Färe, R., Grosskopf, S., Norris, M. i Zhang, Z. (1994). Productivity growth, technical progress and efficiency change in industrialized countries. *American Economic Review*. 84(1): 66–83.
- Färe, R., Grosskopf, S. i Weber, W.L. (1989). Measuring school district performance. *Public Finance Quarterly*. 17(4): 409–428.
- Farrell, M. (1957). The measurement of productive efficiency. *Journal of the Royal Statistical Society, Series A*. 120: 253–281.
- Førsund, F.R., Lovell, C.A.K. i Schmidt, P. (1980). A survey of frontier production functions and of their relationship to efficiency measurement. *Journal of Econometrics*. 13: 5–25.
- Friedman, L. i Sinuany-Stern, Z. (1997). Scaling units via the canonical correlation analysis in the data envelopment analysis context. *European Journal of Operational Research*. 100: 629–637.
- Ganley, J.A. i Cubbin, J.S. (1992). *Public Sector Efficiency Measurement: Applications of Data Envelopment Analysis*. Amsterdam: North-Holland.
- Geva-May, I. (2001). Higher education and attainment of policy goals: Interpretations for efficiency indicators in Israel. *Higher Education*. 42(3): 265–305.
- Goldstein, H. (1995). *Multilevel Statistical Models*. London: Wiley and Sons.
- Goldstein, H. (1997). Methods in school effectiveness research. *School Effectiveness and School Improvement*. 8(4): 369–395.
- Goldstein, H. i Sammons, P. (1997). The influence of secondary and junior schools on sixteen year examination performance: A cross-classified multilevel analysis. *School Effectiveness and School Improvement*. 8(2): 219–230.
- Goldstein, H. i Spiegelhalter, D.J. (1996). League tables and their limitations: Statistical issues in comparisons of institutional performance. *Journal of the Royal Statistical Society, Series A*. 159(3): 385–443.
- Goldstein, H. i Thomas, S. (1996). Using examination results as indicators of school and college performance. *Journal of the Royal Statistical Society, Series A*. 159(1): 149–163
- Goldstein, H., Rabash, J., Yang, M., Woodhouse, G., Pan, H., Nuttall, D. i Thomas, S. (1993). A multilevel analysis of school examination results. *Oxford Review of Education*. 19(4): 425–433.
- Gong, B.-H. i Sickles, R.C. (1992). Finite sample evidence on the performance of stochastic frontiers and data envelopment analysis using panel data. *Journal of Econometrics*. 51: 259–284.
- Gray, J., Jesson, D. i Jones, B. (1984). Predicting differences in examination results: Does school organisation matter? *Oxford Review of Education*. 10: 45–68.
- Grosskopf, S. (1996). Statistical inference and nonparametric efficiency: A selective survey', *Journal of Productivity Analysis*. 7: 161–176.

- Grosskopf, S. i Moutray, C. (2001). Evaluating performance in Chicago public high schools in the wake of decentralization. *Economics of Education Review*. 20: 1–14.
- Häkkinen, I., Kirjavainen, T. i Uusitalo, R. (2003). School resources and student achievement revisited: New evidence from panel data. *Economics of Education Review*. 22(3): 329–335.
- Haksever, C. i Muragishi, Y. (1998). Measuring value in MBA programmes. *Education Economics*. 6(1): 11–25.
- Halme, M., Joro, T., Korhonen, P., Salo, S. i Wallenius, J. (1999). A value efficiency approach to incorporating preference information in data envelopment analysis. *Management Science*. 45: 103–115.
- Harrison, J. i Rouse, P. (2002). Measuring the performance of Auckland secondary schools: A pilot study using data envelopment analysis. <http://orsnz.org.nz/conf37/Papers/Rouse.pdf> [30.06.2018].
- Hashimoto, K. i Cohn, E. (1997). Economies of scale and scope in Japanese private universities. *Education Economics*. 5(2): 107–115.
- Izadi, H., Johnes, G., Oskrochi, R. i Crouchley, R. (2002). Stochastic frontier estimation of a CES cost function: The case of higher education in Britain. *Economics of Education Review*. 21: 63–71.
- Jesson, D., Mayston, D. i Smith, P. (1987). Performance assessment in the education sector: Educational and economic perspectives. *Oxford Review of Education*. 13: 249–267.
- Johnes, G. (1996). Multi-product cost functions and the funding of tuition in UK universities. *Applied Economics Letters*. 3(9): 557–561.
- Johnes, G. (1997). Costs and industrial structure in contemporary British higher education. *Economic Journal*. 107: 727–737.
- Johnes, G. (1998a). The costs of multiproduct organizations and the heuristic evaluation of industrial structure. *Socio-Economic Planning Sciences*. 32(3): 199–209.
- Johnes, G. (1998b). Corrigendum: Costs and industrial structure in contemporary British higher education. *Economic Journal*. 108: 1275.
- Johnes, G. (1999). The management of universities: Scottish Economic Society/Royal Bank of Scotland Annual Lecture. *Scottish Journal of Political Economy*. 46: 505–522.
- Johnes, G. i Johnes, J. (1992). Apples and oranges: The aggregation problem in publications analysis. *Scientometrics*. 25(2): 353–365.
- Johnes, G. i Johnes, J. (1993). Measuring the research performance of UK economics departments: An application of data envelopment analysis. *Oxford Economic Papers*. 45: 332–347.
- Johnes, J. (1990). Unit costs: Some explanations of the differences between UK universities. *Applied Economics*. 22: 853–862.
- Johnes, J. (1996). Performance assessment in higher education in Britain. *European Journal of Operational Research*. 89: 18–33.

- Johnes, J. (2003). Measuring teaching efficiency in higher education: An application of data envelopment analysis to graduates from UK universities 1993. Discussion paper EC7/03. Department of Economics, Lancaster University.
- Johnes, J. i Taylor, J. (1987). Degree quality: An investigation into differences between universities. *Higher Education*. 16: 581–602.
- Johnes, J. i Taylor, J. (1989a). Undergraduate non-completion rates: Differences between UK universities. *Higher Education*. 18: 209–225.
- Johnes, J. i Taylor, J. (1989b). The first destination of new graduates: Comparisons between universities. *Applied Economics*. 21(3): 357–374.
- Johnes, J. i Taylor, J. (1990). *Performance Indicators in Higher Education: UK Universities*. Milton Keynes: Open University Press and The Society for Research into Higher Education.
- Johnes, J. i Taylor, J. (1992). The 1989 research selectivity exercise: A statistical analysis of differences in research rating between universities at the cost centre level. *Higher Education Quarterly*. 46(1): 67–87.
- Johnes, J., Taylor, J. i Francis, B. (1993). The research performance of UK universities: A statistical analysis of the results of the 1989 research selectivity exercise. *Journal of the Royal Statistical Society, Series A*. 156(2): 271–286.
- Jondrow, J., Lovell, C.A.K., Materou, I.S. i Schmidt, P. (1982). On the estimation of technical inefficiency in the stochastic frontier production function model. *Journal of Econometrics*. 19: 233–238.
- Jones, J.T. i Zimmer, R.W. (2001). Examining the impact of capital on academic achievement. *Economics of Education Review*. 20: 577–588.
- Kang, B.-G. i Greene, K.V. (2002). The effects of monitoring and competition on public education outputs: A stochastic frontier approach. *Public Finance Review*. 30(1): 3–26.
- Kirjavainen, T. i Loikkanen, H.A. (1998). Efficiency differences of Finnish senior secondary schools: An application of data envelopment analysis and Tobit analysis. *Economics of Education Review*. 17(4): 377–394.
- Korhonen, P., Tainio, R. i Wallenius, J. (2001). Value efficiency analysis of academic research. *European Journal of Operational Research*. 130: 121–132.
- Lovell, C.A.K. (1993). Production frontiers and productive efficiency (3–67). W: H.O. Fried, C.A.K. Lovell i S.S. Schmidt (red.), *The Measurement of Productive Efficiency*. Oxford: Oxford University Press.
- Lovell, C.A.K., Walters, L.C. i Wood, L.L. (1994). Stratified models of education production using modified data envelopment analysis and regression analysis. W: A. Charnes, W.W. Cooper, A.Y. Lewin i L.M. Seiford (red.), *Data Envelopment Analysis: Theory, Methodology and Applications*. Dordrecht: Kluwer Academic.
- Madden, G., Savage, S. i Kemp, S. (1997). Measuring public sector efficiency: A study of economics departments at Australian Universities. *Education Economics*. 5(2): 153–167.

- Malmquist, S. (1953). Index numbers and indifference surfaces. *Trabajos de Estadística*. 4: 209–242.
- Mancebon, M.J. i Bandrés, E. (1999). Efficiency evaluation in secondary schools: The key role of model specification and of *ex post* analysis of results. *Education Economics*. 7(2): 131–152.
- Mancebon, M.J. i Mar Molinero, C. (2000). Performance in primary schools. *Journal of the Operational Research Society*. 51(7): 843–854.
- Mante, B. (2001). Measuring the performance of state secondary schools in Victoria: An application of data envelopment analysis. *Education Research and Perspectives*. 28(1): 105–132.
- Mante, B. i O'Brien, G. (2002). Efficiency measurement of Australian public sector organisations: The case of state secondary schools in Victoria. *Journal of Educational Administration*. 40(3): 274–296.
- Mayston, D. i Jesson, D. (1988). Developing models of educational accountability. *Oxford Review of Education*. 14: 321–339.
- McCarty, T.A. i Yaisawarng, S. (1993). Technical efficiency in New Jersey school districts (271–287). W: H.O. Fried, C.A.K. Lovell i S.S. Schmidt (red.), *The Measurement of Productive Efficiency*. Oxford: Open University Press.
- Montmarquette, C., Mahseredjian, S. i Houle, R. (2001). The determinants of university dropouts: A bivariate probability model with sample selection. *Economics of Education Review*. 20(5): 475–484.
- Naylor, R., Smith, J. i McKnight, A. (2000). Occupational earnings of graduates: Evidence for the 1993 UK university population. Department of Economics, University of Warwick. https://www.researchgate.net/publication/228336591_Occupational_earnings_of_graduates_evidence_for_the_1993_UK_university_population [30.06.2018].
- Naylor, R., Smith, J. i McKnight, A. (2002). Why is there a graduate earnings premium for students from independent schools? *Bulletin of Economic Research*. 54(4): 315–340.
- Norman, M. i Stoker, B. (1991). *Data Envelopment Analysis: The Assessment of Performance*. Chichester: Wiley.
- Ondrich, J. i Ruggiero, J. (2001). Efficiency measurement in the stochastic frontier model. *European Journal of Operational Research*. 129: 434–442.
- Pedraja-Chaparro, F., Salinas-Jimenez, J. i Smith, P. (1999). On the quality of the data envelopment analysis model. *Journal of the Operational Research Society*. 50: 636–644.
- Peraita, C. i Sanchez, M. (1998). The effect of family background on children's level of schooling and attainment in Spain. *Applied Economics*. 30: 1327–1334.
- Portela, M.C.A.S. i Thanassoulis, E. (2001). Decomposing school and school-type efficiency. *European Journal of Operational Research*. 132(2): 357–373.
- Ramanathan, R. (2001). A data envelopment analysis of comparative performance of schools in the Netherlands. *Opsearch*. 38(2): 160–182.

- Ray, S.C. (1991). Resource use efficiency in public schools: A study of Connecticut data. *Management Science*. 37: 1620–1628.
- Ruggiero, J. (1996). On the measurement of technical efficiency in the public sector. *European Journal of Operational Research*. 90: 553–565.
- Ruggiero, J. (2000). Nonparametric estimation of returns to scale in the public sector with an application to the provision of educational services. *Journal of the Operational Research Society*. 51: 906–912.
- Ruggiero, J. i Vitaliano, D.F. (1999). Assessing the efficiency of public schools using DEA and frontier regression. *Contemporary Economic Policy*. 17(3): 321–331.
- Sammons, P., Nuttall, D. i Cuttance, D. (1993). Differential school effectiveness: Results from a reanalysis of the Inner London Education Authority's junior school project data. *British Educational Research Journal*. 19: 381–405.
- Sarrico, C.S. i Dyson, R.G. (2000). Using data envelopment analysis for planning in UK universities – an institutional perspective. *Journal of the Operational Research Society*. 51: 789–800.
- Sarrico, C.S., Hogan, S.M., Dyson, R.G. i Athanassopoulos, A.D. (1997). Data envelopment analysis and university selection. *Journal of the Operational Research Society*. 48: 1163–1177.
- Schmidt, P. (1985/1986). Frontier production functions. *Econometric Reviews*. 4(2): 289–328.
- Sengupta, J.K. (1987). Production frontier estimation to measure efficiency: A critical evaluation in light of data envelopment analysis. *Managerial and Decision Economics*. 8: 93–99.
- Sengupta, J.K. (1990). Tests of efficiency in DEA. *Computers Operations Research*. 17(2): 123–132.
- Sengupta, J.K. (1999). The measurement of dynamic productive efficiency. *Bulletin of Economic Research*. 51(2): 111–124.
- Sengupta, J.K. i Sfeir, R.E. (1986). Production frontier estimates of scale in public schools in California. *Economics of Education Review*. 5(3): 297–307.
- Sengupta, J.K. i Sfeir, R.E. (1988). Efficiency measurement by data envelopment analysis with econometric applications. *Applied Economics*. 20: 285–293.
- Sickles, R.C., Good, D.H. i Getachew, L. (2002). Specification of Distance Functions Using Semi- and Nonparametric Methods with an Application to the Dynamic Performance of Eastern and Western European Air Carriers. *Journal of Productivity Analysis*. 17(1–2): 133–155.
- Simar, L. i Wilson, P.W. (1998). Sensitivity analysis of efficiency scores: How to bootstrap in nonparametric frontier models. *Management Science*. 44(1): 49–61.
- Simar, L. i Wilson, P.W. (2004). Performance of the Bootstrap for DEA Estimators and Iterating the Principle (265–298). W: W.W. Cooper, L.M. Seiford i J. Zhu (red.), *Handbook on Data Envelopment Analysis*. New York: Springer.

- Smith, J. i Naylor, R. (2001a). Dropping out of university: A statistical analysis of the probability of withdrawal for UK university students. *Journal of the Royal Statistical Society, Series A*. 164(2): 389–405.
- Smith, J. i Naylor, R. (2001b). Determinants of degree performance in UK universities: A statistical analysis of the 1993 student cohort. *Oxford Bulletin of Economics and Statistics*. 63: 29–60.
- Smith, J., McKnight, A. i Naylor, R. (2000). Graduate employability: Policy and performance in higher education in the UK. *Economic Journal*. 110: F382–F411.
- Smith, P. i Mayston, D. (1987). Measuring efficiency in the public sector. *Omega*. 15: 181–189.
- Soteriou, A., Karahanna, E., Papanastasiou, C. i Diakourakis, M.S. (1998). Using data envelopment analysis to evaluate the efficiency of secondary schools: The case of Cyprus. *International Journal of Educational Management*. 12(2): 65–73.
- Stevens, P.A. (2001). The determinants of economic efficiency in English and Welsh universities. Discussion paper no. 185. National Institute of Economic and Social Research, London.
- Thanassoulis, E. (1996). Altering the bias in differential school effectiveness using data envelopment analysis. *Journal of the Operational Research Society*. 47: 882–894.
- Thanassoulis, E. (1999). Setting achievement targets for school children. *Education Economics*. 7(2): 101–119.
- Thanassoulis, E. i Dunstan, P. (1994). Guiding schools to improved performance using data envelopment analysis: An illustration with data from a local education authority. *Journal of the Operational Research Society*. 45(11): 1247–1262.
- Thanassoulis, E. i Portela, M.C.A.S. (2002). School outcomes: Sharing the responsibility between pupil and school. *Education Economics*. 10(2): 183–207.
- Thanassoulis, E., Simpson, G., Battisti, G. i Charlesworth-May, A. (2003). DEA and multi-level modelling as alternative methods for assessing pupil and school performance. Discussion Paper. Aston Business School.
- Tomkins, C. i Green, R. (1988). An experiment in the use of DEA for evaluating the efficiency of UK university departments of accounting. *Financial Accountability and Management*. 4(2): 147–164.
- Woodhouse, G. i Goldstein, H. (1988). Educational performance indicators and LEA league tables. *Oxford Review of Education*. 14: 301–319.
- Worthington, A. (2001). An empirical survey of frontier efficiency measurement techniques in education. *Education Economics*. 9(3): 245–268.
- Yang, M. i Woodhouse, G. (2001). Progress from GCSE to A and AS level: Institutional differences and gender differences, and trends over time. *British Educational Research Journal*. 27(3): 24–46.
- Yang, M., Goldstein, H., Browne, W. i Woodhouse, G. (2002). Multivariate multilevel analyses of examination results. *Journal of the Royal Statistical Society, Series A*. 165(1): 137–153.

Yang, M., Goldstein, H., Rath, T. i Hill, N. (1999). The use of assessment data for school improvement purposes. *Oxford Review of Education*. 25(4): 469–483.

Aneks. Wykaz badań empirycznych*

Efficiency measurement

ABSTRACT: This article aims to identify and present the most common methods of efficiency measurement in the context of assessing how well institutions of education and higher education perform and to review the empirical studies of efficiency measurement at all levels of education.

KEYWORDS: efficiency, higher education, education, measurement, nonparametric technique, DEA

CYTOWANIE: Johnes, J. (2018). Pomiar efektywności. *Nauka i Szkolnictwo Wyższe* 2(52): 17–81. DOI: 10.14746/nisw.2018.2.1

JILL JOHNES – profesor na Uniwersytecie w Huddersfield, Wielka Brytania gdzie jest dziekanem Huddersfield Business School, jest także profesorem wizytującym/honorowym na Uniwersytecie w Lancaster, na którym pracowała we wcześniejszych latach. Jej liczne prace badawcze koncentrują się przede wszystkim na ocenie efektywności funkcjonowania organizacji (szkół wyższych oraz banków). Jest autorem wielu cytowanych artykułów oraz współautorem wpływowych książek, w tym: *Performance Indicators in Higher Education* (1990) oraz *International Handbook on the Economics of Education* (2004). Dzięki swojej pracy naukowej zyskała reputację i prestiż w dziedzinie badań nad efektywnością edukacji. Współredagowała specjalne wydanie czasopisma *Journal of the Operational Research Society* (2016) poświęcone badaniom nad efektywnością edukacji. Współpracuje z wieloma organizacjami międzynarodowymi w zakresie badań nad efektywnością, była współorganizatorką konferencji: *Efficiency in Education*, Londyn 2014 oraz *Efficiency in Education, Health and other Public Services*, Huddersfield 2018.

E-mail: J.Johnes@hud.ac.uk

* Z powodów ograniczonej liczby stron czasopisma, odsyłamy zainteresowanych czytelników do oryginalnego tekstu.

ARTYKUŁY

Andrzej Szuwarzyński

Ocena efektywności procesu dyplomowania na studiach pierwszego stopnia w polskich publicznych uczelniach technicznych

STRESZCZENIE: W artykule przedstawiono analizę i ilościową ocenę funkcjonowania 18 polskich uczelni technicznych uwzględniającą dwa podstawowe problemy: rezygnację ze studiów w trakcie pierwszego roku oraz wskaźniki ukończenia studiów w nominalnym czasie. Do oceny efektywności procesu dyplomowania wykorzystano prostą metodę wskaźnikową oraz nieparametryczną metodę Data Envelopment Analysis (DEA). Ocenę przeprowadzono dla studiów pierwszego stopnia prowadzonych w formie stacjonarnej i niestacjonarnej. Na podstawie prostych wskaźników dokonano wstępnej oceny zjawiska. W modelu DEA uwzględniono po stronie nakładów liczbę studentów rozpoczynających studia w 2011 roku, liczbę nauczycieli akademickich oraz całkowitą liczbę studentów pierwszego stopnia. Po stronie rezultatów uwzględniono liczbę absolwentów z roku 2015 oraz liczbę osób, które zrezygnowały po pierwszym roku studiów. Model ten pozwolił na stworzenie rankingu oraz obliczenie pożądaných wartości zmiennych uwzględnionych w analizie, dla uczelni nieefektywnych. W interpretacji wyników uwzględniono wcześniej zdefiniowane wskaźniki.

SŁOWA KLUCZOWE: wskaźnik ukończenia studiów, wskaźnik rezygnacji w pierwszym roku studiów, analiza wskaźnikowa, data envelopment analysis, niepożądane rezultaty

Wstęp

Dynamiczny wzrost zainteresowania studiami wyższymi na świecie potwierdzają dane statystyczne. W latach 1970–2016 współczynnik skolaryzacji brutto zwiększył się w skali światowej z 10.06% do 36.77%; w krajach OECD z 23.50% do 72.78%; a w krajach UE z 17.32% do 67.67% (World Bank 2018). Masowość kształcenia na poziomie wyższym ma niewątpliwie negatywny wpływ na jego jakość, na co już w latach 70. poprzedniego stulecia zwrócił uwagę Trow (1973). Carneiro, Heckman i Vytlačil (2011) stwierdzili natomiast, że polityka rozszerzająca możliwości edukacji wyższej w wielu krajach skłania do podejmowania studiów przez wielu młodych ludzi, którzy ze względu na swoje możliwości nie powinni w nich uczestniczyć. Stąd

w analizach funkcjonowania systemów edukacji wyższej coraz większą uwagę zwraca się na zjawisko porzucania studiów w pierwszym roku (*first year dropout*) i stopy ukończenia studiów (*graduation rates*) (Sneyers i De Witte 2017; Barra i Zotti 2016; Thomas i Hovdhaugen 2014).

W dobie masowego kształcenia ważne jest, aby w analizach systemów edukacyjnych poza spojrzeniem z perspektywy ilościowej uwzględniać również aspekty jakościowe. Podkreśla się jednak, że pomiar jakości jest znacznie trudniejszy niż uzyskanie miar ilościowych. Johnes i Tone (2017) stwierdzają, że podejście ilościowe jest ważne, ale uwzględnienie jakości procesu kształcenia jest jeszcze bardziej istotne. Pomimo trudności ze sformułowaniem odpowiednich mierników ocenianie jakości funkcjonowania procesów nauczania uniwersyteckiego jest bezwzględnie konieczne w kontekście polityki edukacyjnej (Agasisti i Johnes 2015).

Liczba osób z wykształceniem wyższym ogólnie rośnie w European Higher Education Area (Europejskim Obszarze Szkolnictwa Wyższego – EHEA), a tendencja ta jest wyraźnie pozytywnie oceniana ze względu na szybko rosnące wymagania stawiane przez gospodarkę opartą na wiedzy. Stwierdza się również, że podobnie jak na całym świecie zbyt wielu europejskich studentów przedwcześnie rezygnuje z edukacji. Jednakże dostępność danych na ten temat i ich porównywalność wciąż stanowi poważny problem. Na podstawie dostępnych danych wskaźniki ukończenia studiów wahają się w krajach Unii Europejskiej w przedziale od 48% do 88% (EACEA-Eurydice 2015).

Zdaniem Vossensteyn i in. (2015) brakuje w Europie systematycznej wiedzy, danych i wskaźników na temat sukcesu studiowania. Chociaż istnieje wiele badań dotyczących czynników, które mogą mieć wpływ na sukces studiowania poszczególnych studentów, badania nad polityką sukcesu studiowania i jej skutecznością należą do rzadkości. Ponadto dane dostępne w krajach europejskich są zróżnicowane pod względem dostępności, metody zbierania danych, definicji i zastosowań. Takie mierniki jak wskaźniki ukończenia studiów, wskaźniki retencji czy rezygnacji ze studiów i średniego czasu potrzebnego do uzyskania dyplomu są trudno dostępne. Tylko 12 spośród 35 krajów europejskich regularnie raportuje krajowy wskaźnik ukończenia studiów. Jeszcze mniej krajów raportuje wskaźniki retencji, wskaźniki rezygnacji ze studiów i czas potrzebny do uzyskania dyplomu. Podobne problemy obserwuje się również w innych krajach, np. Australii i Stanach Zjednoczonych (Vossensteyn i in. 2015).

Można sformułować pytanie, w jaki sposób prowadzić badania porównawcze, uwzględniając takie czynniki jak rezygnacja ze studiów i terminowe ich ukończenie przez studentów? Międzynarodowe badania porównawcze są wyzwaniem i obserwuje się potrzebę kontynuowania dyskusji na temat metodyki, która powinna uwzględniać kontekst lokalny. Oznacza to, że ogólne wnioski można wyciągnąć z różnych

krajowych systemów szkolnictwa wyższego i przenieść je na grunt porównań międzynarodowych (Thomas i Hovdhaugen 2014).

Celem tego artykułu jest analiza i ilościowa ocena funkcjonowania polskich uczelni technicznych w kontekście wcześniej przedstawionych problemów rezygnacji ze studiów w trakcie pierwszego roku wraz ze wskaźnikami ich ukończenia. Do oceny efektywności procesu dyplomowania wykorzystano prostą metodę wskaźnikową oraz nieparametryczną metodę Data Envelopment Analysis (DEA).

Artykuł składa się z czterech części, wstępu i zakończenia. Pierwsza z nich zawiera analizę literatury w kontekście jakości funkcjonowania szkolnictwa wyższego. Drugą część to opis metodyki zastosowanej w badaniach. W kolejnej znajduje się opis danych oraz dobór zmiennych do modelu. Ostatnia część zawiera analizę i dyskusję wyników przeprowadzonych badań. Artykuł kończy się krótkim podsumowaniem.

1. Problematyka pomiaru jakości funkcjonowania szkolnictwa wyższego w literaturze

Jest pełna zgodność, że instytucje szkolnictwa wyższego to złożone, wieloproduktowe organizacje. Ich podstawowe obszary aktywności to badania naukowe, nauczanie i tzw. trzecia misja (np. Kallio, Kallio i Grossi 2017; Agasisti i Johnes 2015; Daraio, Bonaccorsi i Simar 2015b; Safón 2013; Bonaccorsi i Daraio 2008; Murias, de Miguel i Rodriguez 2008; Bonaccorsi, Daraio i Simar 2006; Abbott i Doucouliagos 2003). Trzecią misję można scharakteryzować jako angażowanie się uczelni w transfer wyników badań naukowych do przemysłu oraz aktywne przyczynianie się do wzrostu gospodarczego na poziomie krajowym i lokalnym (Bonaccorsi, Daraio i Simar 2006) czy też szeroko rozumiane usługi dla społeczeństwa (Abbott i Doucouliagos 2003). Ze względu na trudności w określeniu właściwych mierników dotyczących trzeciej misji oraz braku odpowiednich danych ten obszar aktywności uniwersytetów zwykle nie jest uwzględniany w analizach (Agasisti i Johnes 2015; Daraio, Bonaccorsi i Simar 2015b). Ponieważ uczelnie produkują łącznie badania i nauczanie w różnych dziedzinach i na różnych poziomach, utrudnia to ocenę ich funkcjonowania. Często instytucja działająca dobrze w jednym wymiarze może być gorsza w innym (Agasisti i Johnes 2015). Niektóre uczelnie mają wyraźne ukierunkowanie badawcze, a inne specjalizują się w nauczaniu (De Witte i Hudrlikova 2013).

Pomimo tego, że uniwersytety są postrzegane jako wieloproduktowe organizacje, dla celów osiągnięcia większej wiarygodności wyników dokonuje się często oddzielenia analizy funkcjonowania w zakresie kształcenia i badań, bazując na założeniu, że oba typy działalności są realizowane niezależnie (Sarrico i in. 2009; Johnes 1996). Zdaniem Johnes (1996) odrębne mechanizmy finansowania stosowane w nauczaniu i badaniach w sektorze szkolnictwa wyższego wspierają takie założenie.

1.1 Nakłady i rezultaty w analizie efektywności nauczania

W badaniach efektywności instytucji szkolnictwa wyższego specyfikacja nakładów i rezultatów ich działania jest niezwykle trudna, ponieważ są one zróżnicowane i często niemożliwe do bezpośredniego pomiaru. Stąd najczęściej stosowane są proxy dla większości nakładów i rezultatów funkcjonowania uczelni (Carrington, Coelli i Prasada Rao 2005).

W zależności od celu badania zestaw nakładów i rezultatów jest zróżnicowany. W przypadku badania działalności edukacyjnej uczelni może to być: liczba studentów, liczba absolwentów, liczba kadry akademickiej, nakłady ponoszone na nauczanie oraz szereg innych. Podstawowym problemem w modelach oceniających nauczanie jest to, co należy uznać za rezultaty. W literaturze opinie na ten temat są podzielone. Trwa dyskusja, czy miernikiem rezultatów nauczania jest liczba studentów, czy liczba absolwentów (Carrington, O'Donnell i Prasada Rao 2018). Niektóre badania wykorzystują liczbę absolwentów (np. Agasisti i Johnes 2009; Worthington i Lee 2008; Carrington, Coelli i Prasada Rao 2005), natomiast inne używają w tym celu liczby studentów (np. Johnes i Tone 2017; Agasisti i Salerno 2007; Johnes 2006).

Liczba absolwentów, jako rezultat procesu nauczania, jest czasem krytykowana. Carrington, Coelli i Prasada Rao (2005) stwierdzają, że w mniej prestiżowych uniwersytetach przyjmuje się studentów z niższymi ocenami na wejściu, a zatem może być mniej prawdopodobne, że zakończą oni studia uzyskaniem dyplomu. Istnieje też prawdopodobieństwo tego, że słabsze uczelnie mogą obniżać swoje standardy oceniania, aby uzyskać lepsze wskaźniki ukończenia studiów (*completion rates*). Dodatkowo zwraca się uwagę, że należy uwzględniać podział na studentów kierunków ścisłych (*science*), medycznych i studentów innych kierunków, co pozwala na odzwierciedlenie zróżnicowania nakładów pracy studentów (Carrington, Coelli i Prasada Rao 2005). Natomiast Worthington i Lee (2008) stwierdzają, że bez wątpienia liczby licencjackich i magisterskich dyplomów są miarą rezultatów dla każdej uczelni.

Agasisti i Johnes (2009) w modelu DEA oceny włoskich uniwersytetów po stronie nakładów uwzględnili liczbę studentów, a po stronie rezultatów liczbę absolwentów. W obu przypadkach osobno dla pierwszego i drugiego stopnia studiów. Podobnie definiują model efektywności szwedzkich szkół wyższych Andersson i in. (2017), stwierdzając, że jednym z najważniejszych nakładów uczelni jest liczba studentów pierwszego i drugiego stopnia. Z punktu widzenia efektywności instytucji edukacyjnych ważna jest proporcja, z jaką przyjęci studenci są konwertowani na absolwentów. Może to być zróżnicowane w poszczególnych uczelniach ze względu na różnice we wskaźnikach rezygnacji oraz w standardowej długości studiów (Agasisti i Johnes 2009).

Masowe szkolnictwo wyższe wymaga dwutorowych działań koncentrujących się, z jednej strony, na zwiększaniu dostępności (co jest wejściem do systemu) oraz,

z drugiej, na dbaniu o wysoki wskaźnik ukończenia studiów (co jest wyjściem z systemu). W tym kontekście uczelnie nie tylko powinny skupiać się na tym, aby mieć coraz większą liczbę studentów, ale także troszczyć się o to, aby ci studenci ukończyli swoje studia, najlepiej w nominalnym czasie trwania wybranego przez nich kursu (EACEA-Eurydice 2015).

1.2 Wpływ jakości kandydatów na osiągnięcie sukcesu na studiach

Jak wspomniano we wstępie, aspekty jakościowe procesu nauczania w uczelniach muszą być uwzględniane w badaniach ich funkcjonowania i to pomimo trudności w formułowaniu mierników. Osiągnięcie sukcesu na studiach, czyli uzyskanie dyplomu, wymaga dobrego przygotowania kandydatów. Agasisti i Salerno (2007) wykorzystali jako proxy dla jakości kształcenia odsetek studentów pierwszego roku, którzy uzyskali najlepsze wyniki w szkole średniej, co jest miernikiem ukierunkowanym na wejście pozwalającym pośrednio zmierzyć poziom przygotowania kandydatów do studiowania. Podobnie Tran, Carolyn-Dung i Villano (2017) w badaniach wietnamskich uniwersytetów, aby uwzględnić jakość przyjętych studentów, po stronie nakładów wykorzystali średnie oceny krajowych egzaminów wstępnych. Jednakże nie w każdym przypadku tego typu dane są dostępne.

Uczelnie mogą zdecydować się na selekcyjny charakter pierwszego roku, aby zwiększyć wskaźnik ukończenia i uzyskać lepsze oceny jakości przeprowadzane przez instytucje akredytacyjne. Rzeczywiście, podczas gdy niektóre uniwersyteckie programy pozwalają większości studentów zapisać się na drugi rok, inne programy starają się wybrać tylko najlepszych studentów, którzy rozpoczynają drugi rok, wprowadzając wysokie standardy oceniania. W konsekwencji wybór ten ma duży wpływ na wskaźniki rezygnacji między pierwszym a drugim rokiem. To z kolei wpływa na poziom jakości i wskaźniki ukończenia studiów (Sneyers i De Witte 2017).

Na wskaźniki ukończenia studiów mogą mieć wpływ zarówno selekcja w trakcie procesu kształcenia, jak i selekcja w procedurach przyjmowania kandydatów. Jeśli chodzi o tę ostatnią, w krajach o bardziej selekcyjnych procedurach przyjmowania sukces studentów może być wyższy niż w krajach o otwartym dostępie do wyższej edukacji (EACEA-Eurydice 2015).

1.3 Wskaźnik ukończenia studiów

Analizy dotyczące szkolnictwa wyższego są czasem kwestionowane ze względu na brak uwzględniania czynników jakościowych. Dotyczy to w szczególności problemu, jak uwzględniać jakość i czy może być ona przedstawiona za pomocą miar ilościowych. Daraio, Bonaccorsi i Simar (2015b) stwierdzają, że istnieje pełna zgodność, iż dane dotyczące ukończenia studiów są akceptowalnym wskaźnikiem jakości.

Wskaźnik ukończenia przedstawia udział studentów, którzy rozpoczynają studia i uzyskują dyplom w programach wyższego kształcenia, jest on wyrażony jako procent wszystkich rozpoczynających uczestników. Brak jest jednej wspólnej metodyki międzynarodowej obliczania tego wskaźnika. True cohort method (metoda kohortowa) daje najdokładniejsze wyniki, ale jest bardzo wymagająca pod względem danych, ponieważ konieczne jest posiadanie danych panelowych (ankiet lub rejestrów), w których indywidualny student jest śledzony przez system od wejścia do ukończenia uczelni lub rezygnacji ze studiów. Badania takie prowadzone są rzadko i z reguły dotyczą studentów pierwszego stopnia. W przypadku braku takich danych wskaźnik bazuje na metodzie przekrojowej, w której liczba absolwentów w danym roku jest dzielona przez liczbę osób nowoprzyjętych do tych programów określoną liczbę lat wcześniej (EACEA-Eurydice 2015; Luca, Verdyck i Coppens 2014; Thomas i Hovdhaugen 2014). Przykładowo w wielu krajach przyjmuje się jako wskaźnik sukcesu studiowania ukończenie studiów w ciągu nominalnego okresu trwania programu plus jeden dodatkowy rok (Vossensteyn i in. 2015). Według OECD (2013) wskaźnik ukończenia jest to stosunek liczby studentów, którzy ukończyli studia w danym roku do liczby nowych uczestników na tym kursie n lat wcześniej, gdzie n to liczba lat studiów stacjonarnych wymaganych do uzyskania dyplomu.

Wskaźnik ukończenia może też być określony jako udział studentów uniwersytetu osiągających swój cel edukacyjny. Przykładowo dla czteroletniego programu wskaźnik ukończenia studiów obejmuje studentów, którzy uzyskali dyplom w okresie sześciu lat od rozpoczęcia programu (Lukman, Krajnc i Glavic 2010). Jeszcze inny sposób zaproponowali Sneyers i De Witte (2017), którzy wskaźnik ukończenia mierzą jako odsetek studentów, którzy pomyślnie przeszli pierwszy rok i uzyskali dyplom z maksymalnym opóźnieniem jednego roku (wskaźnik ukończenia studiów nie uwzględnia osób, które zrezygnowały w trakcie pierwszego roku).

Obserwuje się, że studenci stacjonarni (*full-time*) mają większe szanse na ukończenie studiów niż studenci niestacjonarni (*part-time*) (OECD 2013). Na przykład wysoką różnicę pomiędzy studentami studiów stacjonarnych i niestacjonarnych obserwuje się w Nowej Zelandii, gdzie wskaźnik ukończenia studiów pierwszego stopnia na studiach stacjonarnych jest o 34 punkty procentowe większy niż na studiach niestacjonarnych.

Ponieważ dane na temat wskaźników ukończenia i rezygnacji są wciąż rzadkością wśród systemów szkolnictwa wyższego w EHEA, można dokonać porównania wskaźników rekrutacji i ukończenia mierzonych w tym samym roku akademickim. Takie porównanie jest traktowane jako proxy dla postępu edukacyjnego, którego wyniki mogą być wykorzystane jako informacje pomocnicze do oceny rezultatów edukacyjnych. Zaletą porównania wskaźników wejścia i ukończenia jest to, że dane są dostępne dla znacznie większej liczby krajów, co jest istotne dla porównań międzynarodowych

(EACEA-Eurydice 2015). Zastosowanie tej metody może jednak dać bardzo obciążone wyniki w przypadku niestabilnej liczby osób przyjmowanych na studia w kolejnych latach. Przykładem ilustrującym ten problem może być zmiana w zasadach finansowania polskich uczelni publicznych, która wymusiła w wielu przypadkach radykalne zmniejszenie liczby przyjmowanych studentów.

Luca, Verdyck i Coppens (2014) podkreślają, że ważne są też wskaźniki terminowego uzyskania dyplomu, które zależą od nominalnego czasu trwania studiów. W Stanach Zjednoczonych wszystkie instytucje edukacji wyższej są zobowiązane przez prawo do publikowania informacji o wskaźnikach ukończenia. Jednakże są dwie główne trudności w powszechnym stosowaniu wskaźników ukończenia: brak kompleksowych źródeł danych i brak konsensusu w sprawie definicji koncepcyjnej i technicznej dotyczącej wskaźników ukończenia (Luca, Verdyck i Coppens 2014).

Archibald i Feldman (2008) stwierdzają natomiast, że skupianie się na wskaźnikach ukończenia może być fałszywym rozumowaniem. Nie jest realne, aby każda uczelnia dążyła do 100% wskaźnika ukończenia studiów. Podkreślają, że dla niektórych studentów najlepszym wyborem jest opuszczenie uczelni przed zakończeniem kursu, ponieważ dla nich zwroty z rezygnacji przekraczają zwroty z pozostania w systemie edukacji. Pomimo najlepszych starań instytucji 100% wskaźnik ukończenia studiów nie jest ani prawdopodobny, ani społecznie optymalny. Tak więc projektowanie strategii uczelni mające na celu maksymalizowanie wskaźnika ukończenia nie zawsze byłoby dobrą decyzją edukacyjną, ponieważ uczelnie mogłyby osiągnąć wyższy wskaźnik ukończenia poprzez obniżenie standardów oceniania lub popieranie zwiększającej się inflacji uzyskiwanych dyplomów. Każda uczelnia z pewnością mogłaby również osiągnąć wyższe wskaźniki ukończenia poprzez ograniczenie dostępu studentów tylko do tych, którzy są pewni jej ukończenia. Podniesienie wskaźnika ukończenia studiów na te dwa ostatnie sposoby oczywiście nie jest społecznie użyteczne, ponieważ osłabiłoby to zobowiązanie wielu krajów do szerokiego dostępu do edukacji wyższej.

1.4 Wskaźnik rezygnacji ze studiów

Wskaźnik rezygnacji pomiędzy pierwszym a drugim rokiem kursu akademickiego pośrednio odwzorowuje brak satysfakcji z podjętych studiów, chociaż studenci mogą też zrezygnować z innych powodów (Agasisti i Salerno 2007). Zdając sobie sprawę, że przejście z pierwszego do drugiego roku studiów jest kluczowym etapem ścieżki edukacyjnej studentów, część krajów w swojej polityce edukacji uniwersyteckiej koncentruje się właśnie na retencji (lub rezygnacji) w czasie trwania pierwszego roku studiów (Vossensteyn i in. 2015).

Sneyers i De Witte (2017) zaobserwowali, że niektóre programy akademickie łączą niskie wskaźniki rezygnacji w pierwszym roku z wysokimi wskaźnikami ukończenia

studiów. Inne programy traktują pierwszy rok studiów jako bardziej selekcyjny, co oznacza ostrzejsze standardy oceniania i łączą wysokie wskaźniki rezygnacji w trakcie pierwszego roku z wysokimi wskaźnikami ukończenia studiów tych studentów, którzy przeszli na drugi rok. Jednak niektóre programy akademickie o wysokim wskaźniku rezygnacji w trakcie pierwszego roku nie osiągają wysokich wskaźników ukończenia. Byłoby interesujące zidentyfikowanie cech programowych i instytucjonalnych, które w przypadku określonych poziomów rezygnacji prowadzą do wysokiej stopy dyplomowania, jednakże jest to niemożliwe z powodu braku wiarygodnych danych.

Barra i Zotti (2016) potwierdzają doświadczenia innych autorów, że przejście z pierwszego do drugiego roku jest uznawane za jedną ze słabości włoskiego systemu szkolnictwa wyższego. System ten był często krytykowany ze względu na jego nieefektywność pod względem niskiej liczby zapisów, wysokiego wskaźnika rezygnacji, nadmiernej rzeczywistej długości studiów. W latach 2002–2009 średnio 20.35% studentów włoskich uczelni nie zapisało się na drugim roku. Biorąc pod uwagę ten sam przedział czasowy, 18.02% studentów uważa się za nieaktywnych, co oznacza, że studenci nie uzyskali żadnych punktów w ciągu pierwszego roku studiów. Zdaniem przywołanych autorów przy ocenie wyników uczelni konieczne jest uwzględnienie tego wskaźnika.

Agasisti i Salerno (2007) w swojej ocenie efektywności kosztowej włoskich uniwersytetów zastosowali wskaźnik rezygnacji ze studiów jako miarę jakości kształcenia przy założeniu, że jakość jest najlepiej odwzorowana przez zadowolenie tych, którzy faktycznie uczestniczą w systemie edukacji.

Na to, że studenci rezygnują z kontynuowania studiów między pierwszym a drugim rokiem, może mieć wpływ wiele czynników związanych z funkcjonowaniem wyższych uczelni i indywidualnymi studentami. Na poziomie indywidualnym może to być niewłaściwy wybór programu lub kierunku studiów, niewystarczająca motywacja do sprostania wymaganiom programu nauczania, a także szeroka gama innych ograniczeń, w tym barier finansowych, problemów zdrowotnych i powodów rodzinnych. Na poziomie uczelni mogą to być bariery strukturalne i instytucjonalny brak elastyczności, na przykład niemożność zaspokojenia potrzeb coraz bardziej heterogenicznej populacji studentów, co może wzmocnić indywidualne ryzyko rezygnacji. Studenci pierwszego roku są najbardziej podatni na porzucanie studiów, jeśli zbyt mało uwagi poświęca się ich pierwszym doświadczeniom i rozwojowi umiejętności (EACEA-Eurydice 2015).

Rezygnacja ze studiów nie musi oznaczać całkowitego niepowodzenia poszczególnych studentów, ale wysokie wskaźniki rezygnacji mogą wskazywać, że system edukacji nie zaspokaja potrzeb swoich klientów. Studenci mogą też stwierdzać, że oferowane programy edukacyjne nie spełniają ich oczekiwań lub potrzeb rynku

pracy, na którym będą poszukiwać zatrudnienia. Inną przyczyną to stwierdzenie, że programy trwają dłużej niż czas przewidziany przez studentów na studiowanie, a tym samym przebywanie poza rynkiem pracy (OECD 2004).

Studenci mogą podjąć decyzję o opuszczeniu systemu edukacji przed ukończeniem studiów, ponieważ w niektórych krajach oferowane będą atrakcyjne możliwości zatrudnienia po zaledwie jednym roku studiów. Podobnie niektórzy płacący za naukę studenci, którzy rozpoczynają wyższe studia, na przykład w Nowej Zelandii czy Szwecji, nie zamierzają ukończyć w całości konkretnego programu, ale raczej wybierają kilka kursów w ramach uczenia się przez całe życie lub podnoszenia kwalifikacji (OECD 2013).

1.5 Wskaźnik liczby studentów do liczby nauczycieli

Wskaźnik ukończenia studiów i wskaźnik rezygnacji ze studiów mają w modelach oceny efektywności charakter rezultatów. W pierwszym przypadku jest to rezultat pożądaný, a w drugim niepożądaný, co zostaje uwzględnione w zastosowaniu odpowiedniego modelu DEA. Jakość kandydatów ma charakter nakładu. Innym wskaźnikiem wejściowym jest liczba studentów przypadająca na jednego nauczyciela. Podobnie jak pozostałe omówione wyżej wskaźniki nie jest on jednoznacznie interpretowany przez różnych autorów.

Według Daraio, Bonaccorsi i Simar (2015a) systemy szkolnictwa wyższego w krajach rozwiniętych osiągnęły poziom masowości (tzn. stopa rekrutacji przekracza 50% odpowiedniej dla studiowania kohorty wiekowej), podczas gdy finansowanie szkolnictwa wyższego nie wzrosło w odpowiednim stopniu. Stąd uniwersytety są pod presją wykorzystywania w jak najbardziej efektywny sposób posiadanych zasobów. Duża liczba studentów przy ograniczeniu zasobów finansowych powoduje, że pogarsza się relacja między liczbą studentów a liczbą nauczycieli akademickich. W tym kontekście wskaźnikiem, w pośredni sposób odzwierciedlającym jakość procesu kształcenia, jest powszechnie stosowany stosunek liczby studentów do liczby kadry akademickiej (np. Zrelli i Hamida 2013; Murias, de Miguel i Rodriguez 2008). Zakłada się, że im mniejsza liczba studentów, za których odpowiada nauczyciel akademicki, tym wyższa będzie jakość jego pracy, bo może poświęcić więcej czasu dla każdego studenta.

Część autorów traktuje jednak stosunek liczby studentów do liczby kadry akademickiej bardziej jako wskaźnik dostępności zasobów dydaktycznych, które studenci mogą uzyskać w uczelniach, a więc nie jest on wprost miernikiem jakości. Zapewnia ogólną ocenę działań uniwersytetów dla zapewnienia studentom szerszego osobistego kontaktu z nauczycielami akademickimi (Lukman, Krajnc i Glavic 2010). Według OECD (2004) stosunek liczby studentów do liczby nauczycieli akademickich to miernik dostępności studentów do nauczycieli, którzy są najważniejszymi zasobami

w procesie nauczania. Jednakże niska wartość tego wskaźnika niekoniecznie oznacza lepsze wsparcie edukacyjne a może być po prostu symptomem nieefektywnego wykorzystania zasobów ludzkich. Z kolei bardzo wysoka wartość tego wskaźnika z pewnością wskazuje na niewystarczające profesjonalne wsparcie studentów w nauczaniu. Podkreśla się, że takie wnioskowanie trzeba przeprowadzać z dużą ostrożnością, ponieważ wiele innych czynników również wpływa na jakość procesu nauczania i efekty uczenia się.

2. Metodyka badań

Data Envelopment Analysis (DEA) jest metodą szeroko stosowaną w badaniach efektywności systemów edukacji wyższej. Jest to metoda nieparametryczna wykorzystująca programowanie liniowe, która pozwala na określenie efektywności względnej zestawu obiektów zwanych Decision Making Units (jednostkami decyzyjnymi – DMU). Pomiar efektywności polega na określaniu relacji między wieloma nakładami i wieloma rezultatami funkcjonowania danego obiektu w kontekście sformułowanego celu badania. Wyznacza się obiekty wzorcowe, które tworzą granicę dobrych praktyk i przyrównuje się do nich obiekty pozostałe. Wagi optymalne przypisywane do poszczególnych nakładów i rezultatów są obliczane endogennie, na podstawie danych, a nie są ustalane subiektywnie (Cooper, Seiford i Tone 2007).

Najbardziej ogólnie rzecz biorąc, modele stosowane w DEA można podzielić na dwie grupy: radialne i nieradialne. Dwa podstawowe, najczęściej stosowane modele radialne, czyli CCR (od nazwisk twórców: Charnes, Cooper i Rhodes) ze stałymi efektami skali i BCC (od nazwisk twórców: Banker, Charnes i Cooper) ze zmiennymi efektami skali, pozwalają na obliczenie efektywności technicznej, czystej efektywności technicznej i efektywności skali (Cooper, Seiford i Tone 2007). Oceniają one radialną (proporcjonalną) efektywność, nie uwzględniają jednakże nadwyżek nakładów oraz niedoborów rezultatów (tzw. luzów). Zgodnie z definicją efektywności DEA funkcjonowanie DMU jest w pełni (w 100%) efektywne, wtedy i tylko wtedy, gdy zarówno wynik efektywności jest równy jedności oraz nadwyżki nakładów i niedobory rezultatów są zerowe. Istnieje możliwość zastosowania modeli nieradialnych, które pozwalają na uwzględnienie luzów bezpośrednio w obliczeniach efektywności (Cooper, Seiford i Zhu 2011). Kolejną istotną kwestią w doborze rodzaju modelu jest jego orientacja na nakłady lub na rezultaty. Jest to uzależnione od tego, czy w badaniach istotne jest minimalizowanie nakładów przy zachowaniu wolumenu rezultatów, czy maksymalizowanie rezultatów przy zachowaniu poziomu nakładów. Orientacja uzależniona jest również od tego, czym decydenci mogą sterować (Cook, Tone i Zhu 2014).

W zależności od celu badania struktura wykorzystywanych modeli jest zróżnicowana, zarówno w zakresie stosowanych algorytmów, jak i zestawu nakładów i rezultatów. W przypadkach stosowania modeli radialnych, gdy mamy do czynienia z niepożądanymi rezultatami, luzy w takich sytuacjach nie są uwzględniane w obliczaniu miar efektywności. Z drugiej strony, w przypadku modeli zorientowanych na nakłady (lub rezultaty) skupiają się one jedynie na efektywności po stronie nakładów (lub rezultatów), a strona rezultatów (lub nakładów) jest drugorzędnym przedmiotem pomiaru efektywności. Dlatego tylko modele nieradialne i niezorientowane mogą uwzględnić wszystkie aspekty efektywności (Cooper, Seiford i Tone 2007).

Wyniki badań przeprowadzonych przez Johnes i Tone (2017) wskazują, że wyniki uzyskiwane z zastosowań DEA są wysoce wrażliwe na to, jaka metodyka jest wybrana. W związku z tym konieczne jest dobranie właściwego modelu i zachowanie ostrożności przy interpretacji wyników.

W artykule zastosowano więc miarę efektywności bazującą na luzach (*Slack Based Measure*, SBM), która dopuszcza niepożądane rezultaty. Przyjmuje ona wartości z przedziału $[0, 1]$, eliminując niezerowe luzy nakładów i rezultatów. Model [SBM-Undesirable] (Cooper, Seiford i Tone 2007; Tone, 2001) zakłada, że jest n DMU, z których każda ma trzy składowe: nakłady, pożądane rezultaty i niepożądane rezultaty, reprezentowane odpowiednio przez trzy wektory $\mathbf{x} \in R^m$, $\mathbf{y}^g \in R^{s_1}$ i $\mathbf{y}^b \in R^{s_2}$. Definiowane są macierze \mathbf{X} , \mathbf{Y}^g i \mathbf{Y}^b jak następuje: $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_n] \in R^{m \times n}$, $\mathbf{Y}^g = [\mathbf{y}_1^g, \dots, \mathbf{y}_n^g] \in R^{s_1 \times n}$ i $\mathbf{Y}^b = [\mathbf{y}_1^b, \dots, \mathbf{y}_n^b] \in R^{s_2 \times n}$. Zakłada się, że $\mathbf{X} > \mathbf{0}$, $\mathbf{Y}^g > \mathbf{0}$ i $\mathbf{Y}^b > \mathbf{0}$.

Zbiór możliwości produkcyjnych (P) jest definiowany przez:

$$P = \{(\mathbf{x}, \mathbf{y}^g, \mathbf{y}^b) | \mathbf{x} \geq \mathbf{X}\lambda, \mathbf{y}^g \leq \mathbf{Y}^g \lambda, \mathbf{y}^b \geq \mathbf{Y}^b \lambda, \lambda \geq \mathbf{0}\} \quad (1)$$

gdzie: $\lambda \in R^n$ jest wektorem intensywności.

DMU_o (\mathbf{x}_o , \mathbf{y}_o^g , \mathbf{y}_o^b) jest efektywna, przy założeniu istnienia niepożądanych rezultatów, jeżeli nie istnieje wektor $(\mathbf{x}, \mathbf{y}^g, \mathbf{y}^b) \in P$ taki, że $\mathbf{x}_o \geq \mathbf{x}$, $\mathbf{y}_o^g \leq \mathbf{y}^g$ i $\mathbf{y}_o^b \geq \mathbf{y}^b$, z co najmniej jedną ostrą nierównością.

Zgodnie z tą definicją model [SBM-Undesirable] przyjmuje postać:

$$\rho^* = \min \frac{1 - \frac{1}{m} \sum_{i=1}^m \frac{s_i^-}{x_{io}}}{1 + \frac{1}{s_1 + s_2} \left(\sum_{r=1}^{s_1} \frac{s_r^g}{y_{ro}^g} + \sum_{r=1}^{s_2} \frac{s_r^b}{y_{ro}^b} \right)} \quad (2)$$

z warunkami:

$$\begin{aligned} \mathbf{x}_o &= \mathbf{X}\lambda + \mathbf{s}^- \\ \mathbf{y}_o^g &= \mathbf{Y}^g \lambda - \mathbf{s}^g \\ \mathbf{y}_o^b &= \mathbf{Y}^b \lambda - \mathbf{s}^b \\ \mathbf{s}^- &\geq \mathbf{0}, \mathbf{s}^g \geq \mathbf{0}, \mathbf{s}^b \geq \mathbf{0}, \lambda \geq \mathbf{0} \end{aligned} \quad (3)$$

Wektory $\mathbf{s}^- \in R^m$ i $\mathbf{s}^b \in R^{s_2}$ odpowiadają odpowiednio nadwyżkom w nakładach i niepożądanym rezultatach, podczas gdy $\mathbf{s}^g \in R^{s_1}$ odzwierciedla niedobory w pożądanym rezultatach. Funkcja celu (2) jest ściśle malejąca w odniesieniu do $s_i^- (\forall i)$, $s_r^g (\forall r)$ i $s_i^b (\forall r)$, i wartości funkcji celu spełniającej warunek $0 < \rho^* \leq 1$. Jeżeli optymalnym rozwiązaniem powyższego problemu będzie λ^* , \mathbf{s}^{-*} , \mathbf{s}^{g*} , \mathbf{s}^{b*} , wtedy można stwierdzić, że DMU_o jest efektywna przy obecności niepożądanym rezultatom wtedy i tylko wtedy, gdy $\rho^* = 1$, to znaczy, gdy: $\mathbf{s}^{-*} = \mathbf{0}$, $\mathbf{s}^{g*} = \mathbf{0}$ i $\mathbf{s}^{b*} = \mathbf{0}$.

Aby uzyskać ranking jednostek efektywnych, można wykorzystać model super efektywności (*Super-Efficiency*) (Cooper, Seiford i Zhu 2011). Aby uzyskać taki ranking, podstawowy model rozszerza się o dodatkowy warunek pozwalający na porównanie obiektu ocenianego DMU_o z liniową kombinacją wszystkich pozostałych obiektów w próbie poprzez wyłączenie tego obiektu z oceny (przy sumowaniu w trzech pierwszych warunkach równań (3) należy wprowadzić korektę zakresu sumowania postaci: $j = 1 \dots n, j \neq o$).

Warto jeszcze zwrócić uwagę na jeden problem dotyczący doboru danych, który wynika ze specyfiki problemu poruszanego w artykule. Konwencjonalne modele DEA zakładają (Lee, Zhang i Jeong 2016), iż nakłady poniesione w danym okresie są wykorzystywane do produkcji rezultatów w tym samym okresie. Jednakże w niektórych zastosowaniach nakłady z pewnego okresu mogą przyczyniać się do rezultatów w innych okresach. Określa się to jako opóźnienie czasowe (*time lag*), które wpływa w istotny sposób na wyniki oceny efektywności. Przykładem może być publikowanie artykułów naukowych i zgłaszanie patentów, które są ważnymi rezultatami działalności badawczej, ale są one zawsze wynikiem wysiłków badawczych trwających przez kilka poprzedzających lat. W przypadku działalności badawczej długość czasu opóźnienia jest niepewna i zależy od obszarów, które podlegają ocenie, natomiast w przypadku problemu rozważanego w tym artykule można to określić na podstawie długości cyklu edukacyjnego: od momentu rozpoczęcia nauki do chwili uzyskania dyplomu ukończenia studiów.

3. Opis danych i dobór zmiennych

Do analizy wybrano grupę polskich uczelni technicznych. Zgodnie z klasyfikacją Ministerstwa Nauki i Szkolnictwa Wyższego (MNiSW) działa w Polsce 18 publicznych uczelni o profilu technicznym: Politechniki Białostocka, Częstochowska, Gdańska, Koszalińska, Krakowska, Lubelska, Łódzka, Opolska, Poznańska, Rzeszowska, Śląska, Świętokrzyska, Warszawska, Wrocławska oraz Akademia Górniczo-Hutnicza, Akademia Techniczno-Humanistyczna w Bielsku-Białej, Uniwersytet Technologiczno-Humanistyczny im. Kazimierza Pułaskiego w Radomiu, Zachodniopomorski Uniwersytet Techniczny. Wszystkie są szkołami publicznymi, które funkcjonują

w oparciu o te same przepisy, prowadzą zbliżone zestawy kierunków studiów, mają na celu głównie kształcenie inżynierów i rozwój nauki w dziedzinach technicznych. Pomimo pewnego zróżnicowania ich wielkości i zestawu prowadzonych kierunków studiów z racji deklarowanego, dominującego profilu technicznego można je traktować jako jednorodną grupę.

Wykorzystano dane z lat 2011, 2012 i 2015 pochodzące z Głównego Urzędu Statystycznego (GUS) oraz MNiSW. Dobór zmiennych przeprowadzono w oparciu o przedstawioną wcześniej analizę literatury. Ponieważ dla polskich uczelni nie zbiera się podstawowych danych o wskaźnikach rezygnacji, wskaźnikach ukończenia studiów czy liczbie studentów na nauczyciela, poniżej zostały przedstawione proxy dla tych zmiennych obliczone na podstawie dostępnych danych.

Jako punkt wyjścia przyjęto liczbę absolwentów, którzy ukończyli studia pierwszego stopnia i uzyskali dyplomy w roku 2015 (ABS_2015). Biorąc pod uwagę to, że studia o profilu technicznym trwają zwykle 3,5 roku na studiach stacjonarnych i 3,5–4 lata na studiach niestacjonarnych, przyjęto, że absolwenci z roku 2015 rozpoczynali studia w roku 2011 (STUD_I_ROK_2011). Oczywiście jest to wartość przybliżona, ponieważ w tej grupie absolwentów mogą być również osoby, które z różnych przyczyn (np. przerwy w nauce czy powtarzania roku) mogły rozpocząć studia wcześniej. Odnosząc liczbę absolwentów do liczby rozpoczynających studia, można oszacować wskaźnik ukończenia studiów ($UKONCZ_{2011} = ABS_{2015} / STUD_I_ROK_{2011}$). Jeżeli w analizie uwzględnia się liczbę studentów, którzy zrezygnowali ze studiów między pierwszym a drugim rokiem, wskaźnik ukończenia studiów powinien być obliczany względem studentów, którzy przeszli pomyślnie pierwszy rok i zostali zarejestrowani na rok drugi (jest to liczba studentów studiujących na drugim roku w 2012 roku) ($W1 = ABS_{2015} / STUD_II_ROK_{2012}$). Dane o liczbie nowoprzyjętych studentów w roku 2011 są dostępne (PRZYJ_2011), podobnie rzecz ma się z danymi o liczbie studentów studiujących na pierwszym roku (STUD_I_ROK_2011). Te dwie wartości różnią się, ponieważ niektóre uczelnie dopuszczają powtarzanie pierwszego roku. Na tej podstawie wyliczono liczbę powtarzających pierwszy rok studiów ($W4 = STUD_I_ROK_{2011} - PRZYJ_{2011}$).

Kolejnym istotnym problemem jest przedstawianie w statystykach GUS i MNiSW liczby studentów na poszczególnych latach studiów łącznie dla pierwszego stopnia i jednolitych studiów magisterskich. Uczelnie techniczne nie prowadziły w badanym okresie studiów jednolitych, co pozwala na przeprowadzenie tej analizy. Jednakże taki sposób prezentowania danych eliminuje możliwość dołączenia do analizy uniwersytetów, ponieważ nie ma możliwości określenia liczby studentów pierwszego stopnia. Różnica między liczbą studentów studiujących na pierwszym roku w roku 2011 i studentów studiujących na drugim roku

w roku 2012 jest przybliżeniem liczby studentów, którzy zrezygnowali ze studiów ($REZYGN = STUD_I_ROK_2011 - STUD_II_ROK_2012$) bądź w niektórych uczelniach zostali skierowani na powtarzanie pierwszego roku. Wskaźnik rezygnacji to bezwzględna liczba rezygnacji odniesiona do liczby studentów pierwszego roku w roku 2011 ($W_2 = REZYGN / STUD_I_ROK_2011$). W danych MNiSW są informacje na temat liczby nauczycieli akademickich w przeliczeniu na pełne etaty (KADRA), więc istnieje możliwość oszacowania wskaźnika liczby studentów na jednego nauczyciela dla wszystkich studentów uczelni (wszystkie poziomy i formy studiów) ($W_3 = STUD_WSZYSCY / KADRA$). W przypadku liczby nauczycieli również pojawia się problem, ponieważ nie są oni przypisani do rodzaju i formy studiów, więc mogą prowadzić zajęcia zarówno na studiach pierwszego i drugiego stopnia, na studiach stacjonarnych i niestacjonarnych. W artykule przyjęto, że do studiów pierwszego stopnia przypisano liczbę nauczycieli proporcjonalnie do udziału studentów pierwszego stopnia w całkowitej liczbie studentów ($KADRA_I_ST = STUD_I_ST / W_3$).

W proponowanym modelu, aby uwzględnić wielkość uczelni, przyjęto całkowitą liczbę studentów studiów stacjonarnych i niestacjonarnych pierwszego stopnia ($STUD_I_ST$). De Witte i Hudrlikova (2013) stwierdzają, że wielkość uczelni może być wyrażona jako liczba zapisanych studentów lub liczba jednostek organizacyjnych (wydziałów i katedr). Oba te wskaźniki wielkości są w dużym stopniu egzogenne dla uniwersytetów.

Dodatkowo w analizie wykorzystano udział studentów stacjonarnych studiów pierwszego stopnia (W_5) i udział studentów na kierunkach technicznych na studiach pierwszego stopnia (W_6).

Zdefiniowane wyżej wskaźniki W_1 – W_6 są wykorzystane do wstępnej analizy wskaźnikowej oraz przy interpretacji wyników z modelu DEA.

Liczba zmiennych użytych w modelu DEA musi być ograniczona ze względu na siłę dyskryminacji, która maleje wraz ze wzrostem liczby zmiennych. Ważna jest relacja między liczbą ocenianych DMU a łączną liczbą zmiennych określających nakłady i rezultaty. Sugerowana jest praktyczna zasada (*rule of thumb*) (Cook, Tone i Zhu 2014) mówiąca o tym, że liczba uwzględnianych w analizie DMU powinna być przynajmniej trzy razy większa niż łączna liczba nakładów i rezultatów. Takie reguły nie mają charakteru nakazu ani nie mają podstaw statystycznych, lecz są one wynikiem praktycznych doświadczeń.

Dla przypadku omawianego w artykule przy 18 uczelniach liczba zmiennych nie powinna przekraczać pięciu. Tak więc tylko część zmiennych została wykorzystana bezpośrednio w modelu, a reszta wykorzystana jest do interpretacji wyników.

Ponieważ stosowanie zmiennych wskaźnikowych (*ratio measures*) w DEA jest dyskusyjne (np. Olesen, Petersen i Podinovski 2015), zastosowano surowe dane

wykorzystane do tworzenia wskaźników. Ostatecznie model składa się z trzech nakładów i dwóch rezultatów.

Nakłady:

1. STUD_I_ROK_2011 – liczba studentów studiów pierwszego stopnia w roku 2011 (nowoprzyjęci i powtarzający pierwszy rok);
2. KADRA_I_ST – liczba nauczycieli akademickich przypisanych do studiów pierwszego stopnia;
3. STUD_I_ST – całkowita liczba studentów pierwszego stopnia.

Rezultaty:

4. ABS_2015 – liczba osób, które w roku 2015 ukończyły studia, uzyskując dyplom licencjata lub inżyniera (rezultat pożądany);
5. REZYGN – liczba studentów, którzy zrezygnowali ze studiów między pierwszym a drugim rokiem studiów (rezultat niepożądany).

Podstawowe statystyki opisowe zmiennych łącznie dla studiów stacjonarnych i niestacjonarnych przedstawia Tabela 1.

Tabela 1. Podstawowe statystyki opisowe zmiennych

Zmienna	STUD_I_ROK_2011	KADRA_I_ST	STUD_I_ST	ABS_2015	REZYGN
Min	2 262	270	4 420	1 190	455
Max	10 192	1 794	27 150	5 558	3 249
Średnia	4 933	832	12 443	2 535	1 278
Odchyl.	2 553	502	7 318	1 314	734

Źródło: opracowanie własne.

Spełniony jest warunek izotoniczności zestawu zmiennych, czyli między nakładami i rezultatami jest statystycznie istotna dodatnia korelacja. Wartości współczynników korelacji Pearsona mieszczą się w przedziale 0.75–0.96.

4. Wyniki i dyskusja

Obliczenia efektywności przeprowadzono dla studiów stacjonarnych, niestacjonarnych oraz łącznie dla obu form studiowania. W pierwszym etapie zostały obliczone wskaźniki ukończenia studiów, rezygnacji ze studiów, liczby studentów przypadających na jednego nauczyciela, wskaźnik osób powtarzających pierwszy rok, wskaźnik udziału studentów stacjonarnych, wskaźnik udziału studentów na kierunkach technicznych. Wyniki przedstawione są w Tabeli 2.

Tabela 2. Podstawowe wskaźniki charakteryzujące badane uczelnie (łącznie dla obu form studiów)

Nazwa uczelni	Skrót	Wskaźniki*					
		W1	W2	W3	W4	W5	W6
Akademia Górniczo-Hutnicza im. St. Staszica w Krakowie	AGH	0.75	0.23	13.62	0.013	0.83	0.93
Akademia Techniczno-Humanistyczna w Bielsku-Białej	ATH	0.73	0.29	15.7	0.009	0.70	0.60
Politechnika Białostocka	PB	0.62	0.23	16.26	0.037	0.83	0.92
Politechnika Częstochowska	PCz	0.80	0.26	11.56	0.006	0.72	0.72
Politechnika Gdańska	PG	0.62	0.23	18.91	0.135	0.91	0.94
Politechnika Koszalińska	PK	0.67	0.3	12.86	0.021	0.76	0.61
Politechnika Krakowska im. T. Kościuszki	PKr	0.70	0.20	13.38	0.025	0.81	0.98
Politechnika Lubelska	PL	0.66	0.18	17.74	0.010	0.82	0.94
Politechnika Łódzka	PŁ	0.61	0.33	14.18	0.067	0.83	0.93
Politechnika Opolska	PO	0.68	0.28	14.80	0.007	0.81	0.78
Politechnika Poznańska	PP	0.76	0.27	15.59	0.013	0.79	0.99
Politechnika Rzeszowska im. I. Łukasiewicza	PR	0.75	0.21	21.45	0.041	0.80	0.78
Politechnika Śląska w Gliwicach	PŚl	0.80	0.28	13.07	0.053	0.77	0.92
Politechnika Świętokrzyska w Kielcach	PŚw	0.73	0.27	18.15	0.000	0.75	0.94
Politechnika Warszawska	PW	0.63	0.23	14.14	0.027	0.81	0.90
Politechnika Wrocławska	PWr	0.62	0.32	16.53	0.126	0.90	0.96
Uniwersytet Technologiczno-Humanistyczny im. Kazimierza Pułaskiego w Radomiu	UTH	0.79	0.23	17.04	0.000	0.73	0.48
Zachodniopomorski Uniwersytet Technologiczny w Szczecinie	ZUT	0.62	0.31	10.71	0.041	0.85	0.93
<i>Wartość minimalna</i>		<i>0.61</i>	<i>0.18</i>	<i>10.71</i>	<i>0.00</i>	<i>0.70</i>	<i>0.48</i>
<i>Wartość maksymalna</i>		<i>0.80</i>	<i>0.33</i>	<i>21.45</i>	<i>0.13</i>	<i>0.91</i>	<i>0.99</i>
<i>Wartość średnia</i>		<i>0.70</i>	<i>0.26</i>	<i>15.32</i>	<i>0.03</i>	<i>0.80</i>	<i>0.85</i>
<i>Odchylenie standardowe</i>		<i>0.07</i>	<i>0.04</i>	<i>2.72</i>	<i>0.04</i>	<i>0.06</i>	<i>0.15</i>

* - W1 – wskaźnik ukończenia liczony względem 2012 roku; W2 – wskaźnik rezygnacji po pierwszym roku; W3 – liczba studentów na nauczyciela; W4 – udział studentów powtarzających I rok studiów w roku 2011; W5 – udział studentów studiów stacjonarnych; W6 – udział studentów na kierunkach technicznych.

Źródło: opracowanie własne.

Na podstawie tych prostych wskaźników można dokonać oceny funkcjonowania poszczególnych uczelni w kontekście celu sformułowanego we wstępie. Podstawową miarą sukcesu jest ukończenie studiów w nominalnym czasie ich trwania. Na studiach stacjonarnych z osób przyjętych w 2011 roku ukończyło studia terminowo od 43% do 55%. Zdecydowanie gorzej przedstawia się sytuacja dla studiów niestacjonarnych, które ukończyło od 24% do 40%. Łącznie średnio nie ukończyło studiów około 52% studentów, czyli z 88 800 studentów rozpoczynających studia w 2011 nie uzyskało terminowo dyplomu 42 800 osób. Podkreślić trzeba, że te wskaźniki ukończenia nie odbiegają od wartości rejestrowanych w innych krajach.

Bardzo negatywnym zjawiskiem jest porzucanie studiów między pierwszym a drugim rokiem (wskaźnik W2). Na studiach stacjonarnych wskaźniki rezygnacji ze studiów dla badanych uczelni mieszczą się w przedziale 16–33%, dla niestacjonarnych 19–48%, a łącznie dla obu form studiów w przedziale 18–33%. Jest to bezpośredni wynik braku selekcji przy przyjmowaniu na studia. Niektóre uczelnie chcąc wypełnić limity, przyjmują kandydatów, którzy nie mają odpowiedniego przygotowania do podjęcia studiów. W liczbach bezwzględnych we wszystkich badanych uczelniach było to 23 000 osób, między rokiem 2011 a 2012. Z tym związany jest kolejny problem, który ilustrują wartości wskaźnika W4. Poszczególne uczelnie prowadzą różną politykę odnośnie stwarzania studentom możliwości powtarzania pierwszego roku. Takie uczelnie jak ATH, PCz, PL, PO, PŚw czy UTH traktują pierwszy rok selekcyjnie i praktycznie dopuszczają powtarzanie pierwszego roku tylko w szczególnych przypadkach losowych (liczba bezwzględna osób powtarzających mieści się w przedziale 0–25 osób dla całej uczelni). Inne uczelnie jak np. PG, PŁ, PŚl czy PWr pozwalają na powtarzanie w sposób bardziej liberalny (liczba bezwzględna osób powtarzających mieści się w przedziale 400–1 285 osób dla całej uczelni). Sumarycznie we wszystkich uczelniach w roku 2011 pierwszy rok studiów powtarzało 4 120 studentów, z czego 3 130 na studiach stacjonarnych. Przy operowaniu wartościami bezwzględnymi trzeba oczywiście brać pod uwagę wielkość uczelni, co odwzorowuje wskaźnik W4 odnoszący liczbę powtarzających do liczby studentów pierwszego roku, którego wartości mieszczą się w przedziale 0.00–0.13.

Wskaźnik W3 przedstawiający liczbę studentów przypadającą na jednego nauczyciela akademickiego, który powszechnie próbuje się wskazywać jako główny miernik jakości kształcenia, dla badanych uczelni jest skorelowany ze wskaźnikiem W1 (który uważany jest powszechnie za główny miernik sukcesu studiowania) na poziomie 0.013, czyli praktycznie nie ma żadnego wpływu. Wartości tego wskaźnika mieszczą się w przedziale 10.7–21.5. ZUT, który ma najniższą wartość tego wskaźnika równą 10.7, w rankingu DEA zajmuje jednak końcowe pozycje.

Studia niestacjonarne w badanych uczelniach, poza małymi wyjątkami, nie są prowadzone na szeroką skalę. Wskaźnik W5 określający udział studentów studiów stacjonarnych mieści się w przedziale 0.70–0.91, a więc można stwierdzić, że niektóre

uczelnie, w tym duże takie jak PWr i PG, mają około 10% studentów niestacjonarnych. Jednakże wskaźniki rezygnacji i ukończenia studiów dla tej grupy są w większości przypadków gorsze dla studiów niestacjonarnych.

Ponieważ przedmiotem badania są uczelnie techniczne, zgodnie z ich misją powinny one prowadzić głównie kierunki techniczne. Wskaźnik W6 przyjmuje wartości z przedziału 0.48–0.99. Takie uczelnie jak PKr czy PP śladowo prowadzą kierunki nietechniczne, natomiast takie jak ATH, PK czy UTH mają odpowiednio udział studentów na kierunkach nietechnicznych 40, 39 i 52 procent. Można zadać pytanie, czy powinny być one wliczane do uczelni technicznych?

Kolejny etap badań to obliczenie efektywności na podstawie wcześniej zdefiniowanego i opisanego zestawu zmiennych przy pomocy modelu z niepożądanymi rezultatami, który przedstawiono równaniami (2) i (3). Ponieważ jak już wcześniej zasygnalizowano, wyniki dla niektórych uczelni różnią się dla studiów stacjonarnych i niestacjonarnych, analiza została przeprowadzona osobno dla tych dwóch form studiów oraz dla obu form łącznie. Wyniki przedstawione są w Tabeli 3.


Tabela 3. Wyniki efektywności

Skrót	Łącznie		Stacjonarne		Niestacjonarne	
	Wynik	Rank	Wynik	Rank	Wynik	Rank
AGH	1.12	2	1.14	2	1.03	6
ATH	0.78	8	0.79	10	0.80	9
PB	0.63	15	0.67	14	1.04	5
PCz	1.00	6	1.04	5	0.66	11
PG	0.72	11	0.75	11	0.86	8
PK	0.71	12	0.69	13	1.02	7
PKr	0.81	7	0.88	7	0.46	14
PL	1.08	4	1.12	3	1.09	3
PŁ	0.51	17	0.54	17	0.43	16
PO	0.64	13	0.63	15	1.08	4
PP	0.76	10	0.85	8	0.43	15
PR	1.12	3	1.07	4	1.32	1
PŚl	1.01	5	1.02	6	0.79	10
PŚw	0.77	9	0.83	9	0.63	13
PW	0.64	14	0.69	12	0.28	18
PWr	0.58	16	0.58	16	0.33	17
UTH	1.37	1	1.42	1	1.23	2
ZUT	0.44	18	0.48	18	0.63	12
Min	0.44		0.48		0.28	
Max	1.37		1.42		1.32	
Średnia	0.82		0.84		0.78	
Odch.	0.25		0.25		0.32	

Źródło: opracowanie własne.

Dla lepszego zobrazowania zróżnicowania efektywności na studiach stacjonarnych i niestacjonarnych wyniki przedstawiono na Wykresie 1 (w porządku malejącym według wyniku efektywności na studiach stacjonarnych). Powszechna opinia, że studia niestacjonarne są studiami „gorszej jakości”, nie do końca się tu potwierdza. Z punktu widzenia celu tego artykułu i zastosowanej metody oceny nie można jednoznacznie stwierdzić, że na studiach niestacjonarnych obserwuje się niższą efektywność procesu dyplomowania. W czterech uczelniach, które są w pełni efektywne dla studiów stacjonarnych (UTH, AGH, PL i PR) obserwuje się również pełną efektywność na studiach niestacjonarnych. Dwie kolejne w pełni efektywne uczelnie dla studiów stacjonarnych (PCz i PŚI) w przypadku studiów niestacjonarnych mają zdecydowanie niższą efektywność, odpowiednio 0.66 i 0.79. Odwrotną sytuację można zaobserwować dla trzech uczelni, które są w pełni efektywne dla studiów niestacjonarnych (PB, PK i PO), a dla studiów stacjonarnych mają niską efektywność, odpowiednio 0.67, 0.69 i 0.63. Potwierdza to celowość odrębnego analizowania tych dwóch form studiów.

Wykres 1. Wyniki efektywności dla studiów stacjonarnych i niestacjonarnych



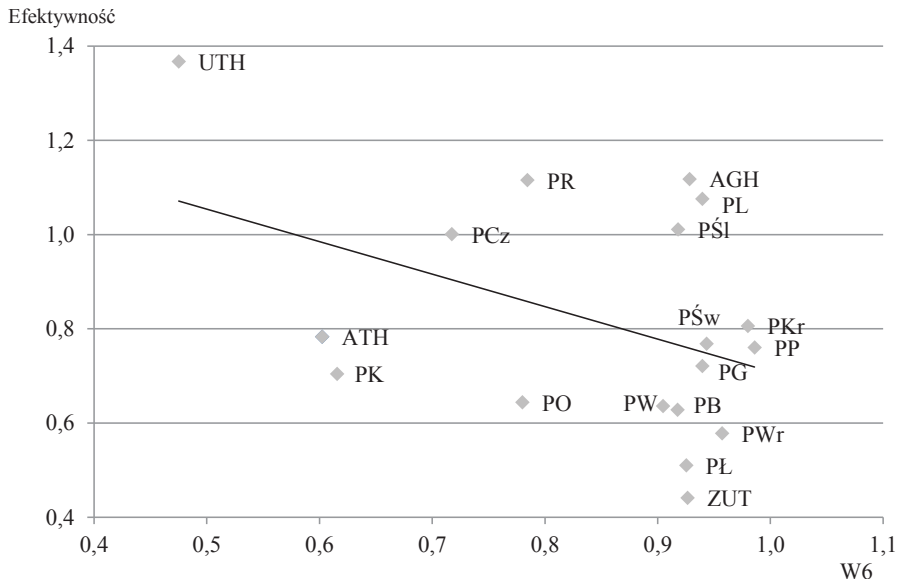
Źródło: opracowanie własne.

Na efektywność funkcjonowania uczelni wpływa bez wątpienia struktura kierunków studiów (*subject mix*) prowadzonych przez nie. Niektóre kierunki są bardziej pracochłonne i wymagające prowadzenia zajęć w mniejszych grupach, często z wykorzystaniem specjalistycznego wyposażenia laboratoryjnego (Sarrico i in. 2009).

Dotyczy to większości kierunków technicznych. Powszechnie uważa się, że kierunki z grupy społecznych (np. zarządzanie, które prowadzone jest w większości uczelni technicznych) są mniej pracochłonne.

Wykres 2 przedstawia zależność efektywności uczelni od wskaźnika W6 określającego udział studentów studiujących na kierunkach technicznych. Bezwzględny liderem jest UTH mający najwyższą efektywność i najniższy udział studentów na kierunkach technicznych (0,48). Podobnie niski udział jest w ATH i PK, jednakże poziom efektywności sytuuje się tam poniżej 0,8. Tak więc jednoznacznie nie można stwierdzić też, że efektywność procesu dyplomowania jest zależna od struktury kierunków.

Wykres 2. Zależność efektywności od udziału studentów na kierunkach technicznych (studia stacjonarne i niestacjonarne łącznie)



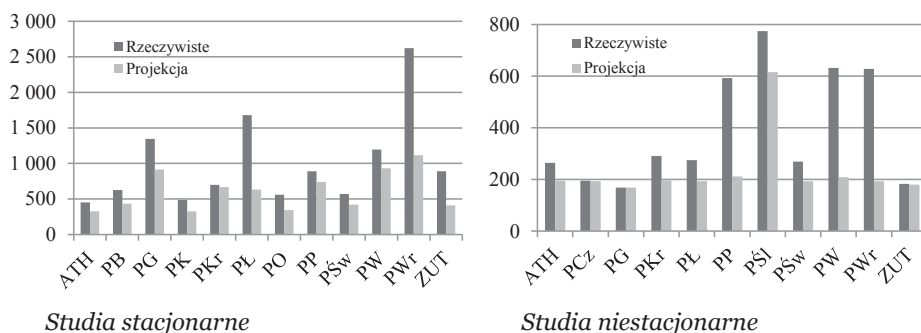
Źródło: opracowanie własne.

Na terminowe uzyskanie dyplomu studiów wpływają jednakże również inne czynniki, które nie zostały uwzględnione w proponowanym modelu, głównie z powodu braku odpowiednich danych. Jednym z takich czynników jest poziom przygotowania kandydatów do studiowania. Zwracają na to uwagę Sneyers i De Witte (2017) oraz Katharaki i Katharakis (2010). Ci ostatni podkreślają również, że na osiągnięcie sukcesu przez studentów znaczny wpływ ma liczba tych z nich, którzy muszą pracować w trakcie swoich studiów (również stacjonarnych) oraz zróżnicowane wymagania edukacyjne na poszczególnych uczelniach. Są to czynniki, które mogą tłumaczyć

różnice w efektywności poszczególnych uczelni, jednakże trudno to zweryfikować, gdyż dane w tym zakresie są niedostępne.

DEA poza rankingami dostarcza wielu przydatnych wyników w postaci tzw. projekcji wartości zmiennych dla obiektów, które uznane zostały za nieefektywne. Ponieważ w artykule zastosowano model niezorientowany, optymalne rozwiązanie, jakie się uzyskuje, maksymalizuje pożądane rezultaty oraz minimalizuje niepożądane rezultaty oraz nakłady. Dla nieefektywnych uniwersytetów można więc uzyskać informacje, jakie powinny być docelowe wartości nakładów i rezultatów, aby te uczelnie osiągnęły pełną efektywność. W przypadku rezultatu ABS_2015, czyli liczby absolwentów, projekcja nie różni się w istotny sposób od wartości zarejestrowanych w roku 2015, zarówno na studiach stacjonarnych, jak i niestacjonarnych. Wyjątkiem dla studiów niestacjonarnych są PŁ oraz ZUT, gdzie liczba absolwentów powinna wzrosnąć odpowiednio o 9% i 71%. Znacznie bardziej istotne jest przeanalizowanie wymaganych zmian niepożądanego rezultatu, czyli liczby rezygnacji ze studiów między pierwszym i drugim rokiem (zmienna REZYGN). Jest to kluczowy czynnik obniżający efektywność. Wyniki przedstawione są na Wykresie 3.

Wykres 3. Wartości rzeczywiste i pożądane zmiennej REZYGN



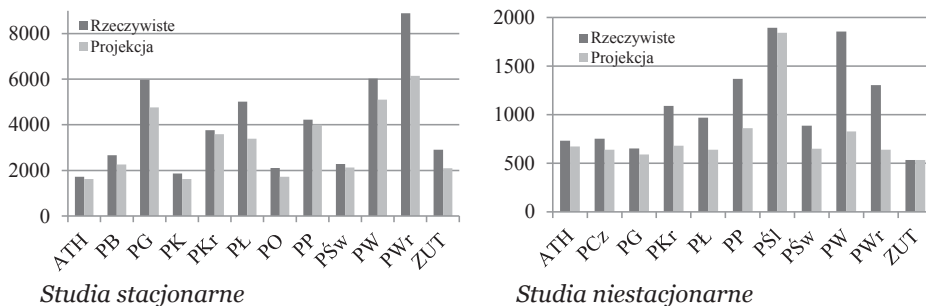
Źródło: opracowanie własne.

Dla studiów stacjonarnych w trzech uczelniach (PG, PŁ i PWr) widać wyraźną konieczność zdecydowanego zminimalizowania niekorzystnego zjawiska rezygnacji ze studiów między pierwszym a drugim rokiem. Liczba osób rezygnujących powinna być odpowiednio zredukowana o 32%, 62% i 58%. Przyczyn rezygnacji może być wiele, np. Sneyers i De Witte (2017) na podstawie swoich badań wskazali takie jak: brak satysfakcji studentów z realizowanego programu, brak odpowiedniego przygotowania pewnych grup studentów do kształcenia, brak wsparcia dla grup słabszych studentów. Zwracają też uwagę, że wysoki wskaźnik rezygnacji może wynikać z przyjętej na uczelniach polityki selekcyjnego charakteru pierwszego roku. W przypadku

studiów niestacjonarnych są cztery uczelnie, w których liczba rezygnacji powinna być w istotny sposób zredukowana. Są to PP o 64%, PŚl o 21%, PW o 67% i PWr o 33%. W przypadku uczelni w dużych aglomeracjach prawdopodobną przyczyną tak dużego udziału osób rezygnujących ze studiów między pierwszym a drugim rokiem jest trudność pogodzenia pracy zawodowej ze studiami. Znacznie łatwiej znaleźć tam pracę, ale też wymagania stawiane przez pracodawców co do zaangażowania się w działalność zawodową są większe. Za wyjątkiem PO i PW wymienione wyżej uczelnie prowadzą bardzo liberalną politykę dotyczącą możliwości powtarzania pierwszego roku. Pierwszy rok powinien mieć charakter selekcyjny, jeżeli nie ma selekcji na wejściu na studia. Trudno bowiem uznać wynik z matury za wiarygodną podstawę oceny zdolności intelektualnych kandydata do podjęcia studiów.

Ponieważ w modelu nieorientowanym minimalizowane są również nakłady warto zwrócić uwagę na liczbę osób studiujących na pierwszym roku studiów. Przy dużych limitach przyjęć może bowiem dojść do sytuacji, że aby je wypełnić, zaniża się kryteria na wejściu, przyjmując słabych kandydatów. Na Wykresie 4 przedstawione są wartości rzeczywiste i pożądane zmiennej STUD_I_ROK_2011, czyli osób rozpoczynających studia, w tym przypadku w roku 2011.

Wykres 4. Wartości rzeczywiste i pożądane zmiennej STUD_I_ROK_2011



Źródło: opracowanie własne.

Polityka rekrutacyjna ma również wpływ na efektywność procesu dyplomowania. Kilka uczelni dla osiągnięcia pełnej efektywności powinno zmniejszyć nabór studentów na pierwszy rok. W przypadku studiów stacjonarnych są to PG, PL, PWr i ZUT, które w istotny sposób powinny zmniejszyć liczbę studentów na pierwszym roku. Są to uczelnie, które stosują liberalną politykę powtarzania pierwszego roku. Np. PWr powinna zmniejszyć nabór na pierwszy rok o 2 743 osoby, a około 870 osób w liczbie studentów pierwszego roku, to powtarzający; natomiast w przypadku PG powinno być na pierwszym roku mniej o 1 210 osób, a powtarzających było 830. Tak więc niedopuszczanie do powtarzania pierwszego roku powinno w sposób zdecydowany

poprawić efektywność. Zmniejszenie limitów przyjęć zostało od roku 2017/2018 wprowadzone i w przyszłości warto takie badania powtórzyć, aby sprawdzić, czy efektywność dyplomowania poprawiła się. W podobny sposób można przeanalizować i zinterpretować wyniki dla studiów niestacjonarnych.

Podsumowanie

Artykuł przedstawia ilościową analizę negatywnych aspektów funkcjonowania 18 wyższych uczelni technicznych w Polsce. Rozwój masowego kształcenia wyższego obserwowany na całym świecie ma wiele pozytywnych efektów, jednakże również wiele negatywnych, które coraz częściej stają się przedmiotem badań. Podstawowym problemem współczesnych systemów szkolnictwa wyższego jest relatywnie niska liczba absolwentów studiów pierwszego stopnia w stosunku do liczby osób rozpoczynających studia. W przebadanych polskich uczelniach technicznych średnio 26% studentów przyjętych na pierwszy rok studiów pierwszego stopnia nie przechodzi na drugi rok (na podstawie danych z lat 2011–2012). Z tych, którzy rejestrują się na drugi rok, w nominalnym czasie kończy studia średnio 70% (na podstawie danych z roku 2015). Z osób rozpoczynających studia w 2011 roku nie ukończyło ich w terminie 52%, czyli w liczbach bezwzględnych jest to 42 800 osób z 88 800 rozpoczynających. Biorąc pod uwagę, że w polskich uczelniach technicznych średnio 80% studentów uczestniczy w studiach stacjonarnych finansowanych ze środków publicznych, można stwierdzić, że około 40% publicznych środków inwestowanych w stacjonarne studia pierwszego stopnia to raczej chybiona inwestycja, bo albo zwrotu nie będzie w ogóle, albo będzie po czasie dłuższym niż nominalny czas trwania studiów, gdyż wielu studentów „przedłuża” sobie moment złożenia i obrony pracy dyplomowej.

Warto zwrócić uwagę na trudności badania tego problemu wynikające z niedostępności odpowiednich danych. GUS od wielu lat publikuje masę danych, które bez wątpienia mają jakieś znaczenie, ale do tego typu analiz nie są użyteczne. Podstawowa trudność wynika z tego, że dane o liczbie studentów na poszczególnych latach studiów są podawane łącznie dla studiów pierwszego stopnia i jednolitych studiów magisterskich. Brakuje danych o liczbie nauczycieli akademickich, z uwzględnieniem stanowisk, w poszczególnych uczelniach. Co prawda MNiSW takie dane publikuje, ale nie są one powszechnie dostępne (a powinny być udostępnione na stronie internetowej ministerstwa). Nigdzie nie są publikowane dane o rezygnacji studentów między pierwszym i drugim rokiem studiów czy o terminowym ukończeniu studiów w nominalnym czasie ich trwania. Jedyna dostępna informacja to ile osób „ukończyło” studia bez obrony pracy dyplomowej. Oczywiście można te czynniki oszacować stosując różnego rodzaju proxy, tak jak miało to miejsce w tym artykule, ale takie

oszacowania zawsze są obarczone pewnym błędem, co zostało podkreślone w sekcji doboru zmiennych. Jednakże lepiej mieć wyniki analiz ze świadomością tego, że obarczone są trudnym do oceny błędem, niż nie robić nic.

Wszyscy są przyzwyczajeni do tego, że rankingi odwzorowują powszechne przekonanie o światowej randze poszczególnych uczelni. Przedstawiony w tym artykule ranking należy interpretować dokładnie zgodnie z celem tego badania. Dwie uczelnie będące liderami w rankingach uwzględniających badania naukowe i prestiż, czyli PW i PWr, pod względem efektywności procesu dyplomowania znajdują się na samym dole tabeli ligowej, a UTH, który klasyfikowany jest przez MNiSW jako uczelnia techniczna, jest liderem, jednakże aż 52% studentów kształci na kierunkach nietechnicznych. To jest wynik złożoności problemu, który był już wcześniej sygnalizowany. Jest zbyt wiele czynników wpływających na rezygnację ze studiów między pierwszym i drugim rokiem czy przedłużania zakończenia studiów ponad nominalny czas ich trwania. Na podstawie przeanalizowanej literatury można wskazać kilka przyczyn. Podstawową wydaje się być przyjmowanie na studia kandydatów, którzy nie spełniają określonych wymagań tylko dlatego, żeby wypełnić limit. Tego nie da się udowodnić na podstawie dostępnych danych. Drugą przyczyną jest zróżnicowanie wymagań stawianych studentom, aby mogli zarejestrować się na kolejny semestr. Bardzo poważną przyczyną niskiej efektywności, co zostało wykazane w tym artykule, jest dopuszczanie przez niektóre uczelnie do powtarzania pierwszego roku. Kolejną przyczyną, bezpośrednio związana z poprzednią, to brak selekcji na wejściu na studia. Jeszcze raz trzeba podkreślić, że wynik z egzaminu maturalnego nie jest wystarczającą oceną zdolności kandydata do studiowania.

Problem jest poważny, jednakże nie jest nierozwiązywalny. Rozwiązaniem pokazującym przyczyny tych niekorzystnych zjawisk mogą być badania kohortowe. Wymagają one śledzenia poszczególnych studentów w trakcie ich cyklu edukacyjnego. Wyniki takich badań pozwoliłyby na zdiagnozowanie tego problemu i wskazanie jego przyczyn. Tego rodzaju wyniki pozwoliłyby na takie kształtowanie polityki wyższej edukacji, która zminimalizowałaby te negatywne zjawiska.

Literatura

- Abbott, M. i Doucouliagos, C. (2003). The efficiency of Australian universities: A Data Envelopment Analysis. *Economics of Education Review*. 22(1): 89–97.
- Agasisti, T. i Johnes, G. (2009). Beyond frontiers: Comparing the efficiency of higher education decision-making units across more than one country. *Education Economics*. 17(1): 59–79.
- Agasisti, T. i Johnes, G. (2015). Efficiency, costs, rankings and heterogeneity: The case of US higher education. *Studies in Higher Education*. 40(1): 60–82.

- Agasisti, T. i Salerno, C. (2007). Assessing the cost efficiency of Italian universities. *Education Economics*. 15(4): 455–471.
- Andersson, C., Antelius, J., Månsson, J. i Sund, K. (2017). Technical efficiency and productivity for higher education institutions in Sweden. *Scandinavian Journal of Educational Research*. 61(2): 205–223.
- Archibald, R.B. i Feldman, D.H. (2008). Graduation rates and accountability: Regressions versus production frontiers. *Research in Higher Education*. 49(1): 80–100.
- Barra, C. i Zotti, R. (2016). A directional distance approach applied to higher education: An analysis of teaching-related output efficiency. *Annals of Public and Cooperative Economics*. 87(2): 145–173.
- Bonaccorsi, A. i Daraio, C. (2008). The differentiation of the strategic profile of higher education institutions. New positioning indicators based on microdata. *Scientometrics*. 74(1): 15–37.
- Bonaccorsi, A., Daraio, C. i Simar, L. (2006). Advanced indicators of productivity of universities: An application of robust nonparametric methods to Italian data. *Scientometrics*. 66(2): 389–410.
- Carneiro, P., Heckman, J.J. i Vytlačil, E. (2011). *Estimating marginal returns to education*. NBER Working Paper No. 16474. Cambridge: National Bureau of Economic Research.
- Carrington, R., Coelli, T. i Prasada Rao, D.S. (2005). The performance of Australian universities: conceptual issues and preliminary results. *Economic Papers*. 24(2): 145–163.
- Carrington, R., O'Donnell, C. i Prasada Rao, D.S. (2018). Australian university productivity growth and public funding revisited. *Studies in Higher Education*. 43(8): 1417–1438.
- Cook, W.D., Tone, K. i Zhu, J. (2014). Data envelopment analysis: Prior to choosing a model. *Omega-International Journal of Management Science*. 44: 1–4.
- Cooper, W.W., Seiford, L.M. i Tone, K. (2007). *Data Envelopment Analysis: A comprehensive text with models, applications, references and DEA-Solver Software*. New York: Springer.
- Cooper, W.W., Seiford, L.M. i Zhu J. (2011). *Handbook on data envelopment analysis*. New York: Springer.
- Daraio, C., Bonaccorsi, A. i Simar, L. (2015a). Efficiency and economies of scale and specialization in European universities: A directional distance approach. *Journal of Informetrics*. 9(3): 430–448.
- Daraio, C., Bonaccorsi, A. i Simar, L. (2015b). Rankings and university performance: A conditional multidimensional approach. *European Journal of Operational Research*. 244(3): 918–930.
- De Witte, K. i Hudrlikova, L. (2013). What about excellence in teaching? A benevolent ranking of universities. *Scientometrics*. 96(1): 337–364.
- EACEA-Eurydice (2015). *The European Higher Education Area in 2015: Bologna Process Implementation Report*. Luxembourg: Publications Office of the European Union.
- Johnes, G. i Tone, K. (2017). The efficiency of higher education institutions in England revisited: comparing alternative measures. *Tertiary Education and Management*. 23(3): 191–205.

- Johnes, J. (1996). Performance assessment in higher education in Britain. *European Journal of Operational Research*. 89(1): 18–33.
- Johnes, J. (2006). Data envelopment analysis and its application to the measurement of efficiency in higher education. *Economics of Education Review*. 25(3): 273–288.
- Kallio, K.M., Kallio, T.J. i Grossi, G. (2017). Performance measurement in universities: ambiguities in the use of quality versus quantity in performance indicators. *Public Money & Management*. 37(4): 293–300.
- Katharaki, M., i Katharakis, G. (2010). A comparative assessment of Greek universities' efficiency using quantitative analysis. *International Journal of Educational Research*, 49(4–5): 115–128.
- Lee, T., Zhang, Y. i Jeong, B.H. (2016). A multi-period output DEA model with consistent time lag effects. *Computers & Industrial Engineering*. 93: 267–274.
- Luca, S., Verdyck, M. i Coppens, M. (2014). An approach to estimate degree completion using drop-out rates. *Studies in Educational Evaluation*. 40: 43–49.
- Lukman, R., Krajnc, D. i Glavic, P. (2010). University ranking using research, educational and environmental indicators. *Journal of Cleaner Production*. 18(7): 619–628.
- Murias, P., de Miguel, J.C. i Rodriguez, D. (2008). A Composite indicator for university quality assessment: The case of Spanish Higher Education System. *Social Indicators Research*. 89(1): 129–146.
- Olesen, O.B., Petersen, N.C. i Podinovski, V.V. (2015). Efficiency analysis with ratio measures. *European Journal of Operational Research*. 245(2): 446–462.
- OECD (2004). OECD Handbook for internationally comparative education statistics: Concepts, standards, definitions and classifications. Paris: OECD Publishing.
- OECD (2013). Education at a Glance 2013: OECD Indicators. Paris: OECD Publishing.
- Safón, V. (2013). What do global university rankings really measure? The search for the X factor and the X entity. *Scientometrics*. 97(2): 223–244.
- Sarrico, C., Teixeira, P., Rosa, M.J. i Cardoso, M.F. (2009). Subject mix and productivity in Portuguese universities. *European Journal of Operational Research*. 197(1): 287–295.
- Sneyers, E. i De Witte, K. (2017). The interaction between dropout, graduation rates and quality ratings in universities. *Journal of the Operational Research Society*. 68(4): 416–430.
- Thomas, L. i Hovdhaugen, E. (2014). Complexities and challenges of researching student completion and non-completion of HE programmes in Europe: A comparative analysis between England and Norway. *European Journal of Education*. 49(4): 457–470.
- Tone, K. (2001). A slacks-based measure of efficiency in data envelopment analysis. *European Journal of Operational Research*. 130(3): 498–509.
- Tran, Carolyn-Dung, T. T. i Villano, R.A. (2017). An empirical analysis of the performance of Vietnamese higher education institutions. *Journal of Further and Higher Education*. 41(4): 530–544.
- Trow, M. (1973). *Problems in the transition from elite to mass higher education*. Berkeley: Carnegie Commission on Higher Education.

- Vossensteyn, H., Stensaker, B., Kottmann, A., Hovdhaugen, E., Jongbloed, B., Wollscheid, S., Kaiser, F. i Cremonini, L. (2015). Dropout and Completion in Higher Education in Europe. Main Report. Luxembourg: Publications Office of the European Union.
- World Bank (2018). School enrollment, tertiary (% gross). <http://databank.worldbank.org/data/reports.aspx?source=2&series=SE.TER.ENRR&country#> [02.06.2018].
- Worthington, A.C. i Lee, B.L. (2008). Efficiency, technology and productivity change in Australian universities, 1998–2003. *Economics of Education Review*. 27(3): 285–298.
- Zrelli, N. i Hamida, B. (2013). Efficiency and quality in higher education. A dynamic analysis. *Research in Applied Economics*. 5(4): 116–130.

Assessment of the graduation process efficiency on the first degree studies in Polish public technical universities

ABSTRACT. This paper presents an analysis and quantitative assessment of the functioning of 18 Polish technical universities taking into account two basic problems, first year dropout rate and graduation rate at a nominal time. To assess the efficiency of the graduation process, a simple indicator method and non-parametric Data Envelopment Analysis (DEA) method are used. The assessment is performed for undergraduate studies in a full-time and part-time form. A preliminary assessment of the phenomenon was made on the basis of simple indicators. In the DEA model, on the input side the number of commencing students in 2011, the number of academic staff and the total number of undergraduate students are taken into account. On the output side, the number of graduates from 2015 and the number of dropout students after the first year of studies are taken into account. This model allows to create a ranking and to calculate the target values of variables included in the analysis for inefficient universities. The interpretation of results includes previously defined indicators.

KEYWORDS: graduation rate, first year dropout rate, ratio analysis, data envelopment analysis, undesirable output

CYTOWANIE: Szuwarzyński, A. (2018). Ocena efektywności procesu dyplomowania na studiach pierwszego stopnia w polskich publicznych uczelniach technicznych. *Nauka i Szkolnictwo Wyższe*. 2(52): 85–111. DOI: 10.14746/nisw.2018.2.2

ANDRZEJ SZUWARZYŃSKI - Pracownik Katedry Zarządzania na Wydziale Zarządzania i Ekonomii Politechniki Gdańskiej. Zainteresowania badawcze związane z funkcjonowaniem szkolnictwa wyższego oraz kształcenia przez całe życie. Autor wielu publikacji poruszających tematykę oceny efektywności instytucji szkolnictwa wyższego, z wykorzystaniem metody Data Envelopment Analysis. e-mail: Andrzej.Szuwarzynski@zie.pg.gda.pl

Piotr Grzegorz Pietrzak, Joanna Baran

Efektywności i skuteczność kształcenia w publicznym szkolnictwie wyższym w Polsce

STRESZCZENIE: Ze względu na trwające prace nad reformą szkolnictwa wyższego w Polsce w artykule podjęto dyskusję na temat efektywności i skuteczności kształcenia akademickiego. Dokonano przeglądu literatury zagranicznej i krajowej w tym zakresie. W artykule zaprezentowano również wyniki wstępnych badań, które dotyczyły 58 uczelni podlegających nadzorowi Ministerstwa Nauki i Szkolnictwa Wyższego (MNiSW). W pomiarze efektywności działalności dydaktycznej wykorzystano podejście nieparametryczne (metodę DEA) – model BCC ukierunkowany na maksymalizację efektów. Zaś w pomiarze skuteczności zastosowano hierarchiczną metodę aglomeracyjną (metoda Warda), jako miarę odległości wykorzystano odległość euklidesową.

SŁOWA KLUCZOWE: szkolnictwo wyższe, kształcenie, efektywność, skuteczność

Wstęp

Zarówno efektywność, jak i skuteczność kształcenia akademickiego to zjawiska o charakterze interdyscyplinarnym. Dotychczas zagadnieniami tymi zajmowali się przedstawiciele dyscyplin z pogranicza nauk ekonomicznych i pedagogicznych (Denek 1997). Ponadto pomiar skuteczności i efektywności procesu dydaktycznego nie należy do zadań trywialnych. Nie istnieje bowiem uniwersalny zestaw zmiennych diagnostycznych. Ich dobór często limitowany jest dostępnością danych oraz wynika z doświadczeń autorów z poprzednich badań (Pietrzak 2016). W dotychczasowych analizach efektywności najczęściej za nakłady przyjmowano: łączną liczbę pełno- i niepełnozatrudnionych nauczycieli akademickich, łączną liczbę pełno- i niepełnozatrudnionych pracowników administracyjnych, przychody z działalności dydaktycznej, wartość majątku trwałego, zaś jako efekty: liczbę absolwentów i liczbę studentów, liczbę dyplomów licencjackich i magisterskich. Z kolei za miary skuteczności kształcenia akademickiego przyjmowano najczęściej: wynagrodzenie, ryzyko bezrobocia czy czas poszukiwania pracy przez absolwentów (Pietrzak 2018).

Celem niniejszego artykułu jest zaprezentowanie wstępnych wyników badań w zakresie efektywności i skuteczności kształcenia na przykładzie 58 uczelni publicznych podlegających nadzorowi Ministerstwa Nauki i Szkolnictwa Wyższego. W ramach badań założono weryfikację następującej hipotezy badawczej:

- H_0 : nie istnieje zależność między efektywnością a skutecznością kształcenia uczelni podlegających nadzorowi MNiSW.

Artykuł składa się z pięciu części. Pierwsza posiada charakter wstępu, w drugiej dokonano przeglądu literatury z zakresu efektywności i skuteczności kształcenia szkół wyższych. W kolejnej części przedstawiono metodykę badania wraz z zestawem zmiennych diagnostycznych. W następnej omówiono uzyskane wyniki i przedstawiono ich interpretację. Artykuł kończą wnioski i podsumowanie.

Efektywność i skuteczność kształcenia akademickiego – przegląd literatury

We współczesnej dyskusji naukowej nie ma zgodności w określeniu relacji zachodzącej między efektywnością (z ang. *efficiency*) a skutecznością (z ang. *effectiveness*). Część badaczy postuluje pojęciowe rozdzielanie tych dwóch terminów (Sidor-Rządowska 2005; Dąbrowski 2012). W ich rozważaniach skuteczność oznacza „robienie właściwych rzeczy” (z ang. *doing right things*), zaś efektywność „robienie rzeczy we właściwy sposób” (z ang. *doing the things right*). Innymi słowy, skuteczność to stopień zgodności rezultatu z zamierzeniem niezależnie od relacji między nakładami a efektami, a efektywność to „dodatnia cecha działań dających oceniany pozytywnie wynik, bez względu na to, czy był on zamierzony, czy też nie” (Pszczółowski 1978:60).

Tym samym przez skuteczność kształcenia akademickiego należy rozumieć takie organizowanie i prowadzenie zajęć dydaktycznych, które zmierzają do osiągnięcia zakładanych celów. Z kolei efektywność oznacza relację efektów do zaangażowanych nakładów. W niniejszym artykule za efekt finalny działalności dydaktycznej przyjmuje się liczbę absolwentów studiów drugiego stopnia, zaś za nakłady: liczbę nauczycieli akademickich, liczbę pracowników niebędących nauczycielami akademickimi oraz wartość rzeczowych aktywów trwałych.

Warto zauważyć, że problematyka pomiaru efektywności (rzadziej skuteczności) jest podejmowana od ponad dekady w polskim piśmiennictwie naukowym. Badania z tego zakresu powstają m.in. na Politechnice Gdańskiej, Politechnice Białostockiej, Zachodniopomorskim Uniwersytecie Technologicznym w Szczecinie, Uniwersytecie Gdańskim, Uniwersytecie Wrocławskim, Uniwersytecie Jagiellońskim czy w Szkole Głównej Gospodarstwa Wiejskiego w Warszawie (Brzezicki i Pietrzak 2018). Badacze

w pomiarze efektywności wykorzystują różne metody takie jak: klasyczne, parametryczne i nieparametryczne (Szuwarzyński i Julkowski 2014).

Jednak najczęściej wykorzystywaną metodą (zaliczaną do grupy metod nieparametrycznych) jest DEA – *Data Envelopment Analysis*, która umożliwia analizę efektywności skończonej liczby jednostek decyzyjnych (DMU – *Decision Making Unit*). Przez jednostki decyzyjne rozumie się np. przedsiębiorstwa, instytucje publiczne, szkoły, biblioteki, szpitale, oddziały bankowe. Metodę DEA należy stosować w przypadku jednostek, które dążą do tego samego celu oraz działają w tych samych warunkach rynkowych. Ponadto czynniki, które charakteryzują ich działalność, są takie same z wyjątkiem różnic w rozmiarze i intensywności ich stosowania (Ćwiąkała-Małys i Nowak 2009).

W modelu DEA efektywność danego obiektu jest zdefiniowana w następujący sposób (Cooper i in. 2007):

$$\frac{\sum_{r=1}^s \mu_r y_r}{\sum_{i=1}^m v_i x_i} = \frac{\mu_1 y_1 + \mu_2 y_2 + \dots + \mu_s y_s}{v_1 x_1 + v_2 x_2 + \dots + v_m x_m} \quad (1)$$

gdzie:

s – liczba efektów,

m – liczba nakładów,

y_r – wartość efektu,

x_i – wartość nakładu,

μ_r – wagi określające ważność poszczególnych efektów,

v_i – wagi określające ważność poszczególnych nakładów.

W modelu DEA m nakładów i s różnych efektów sprowadzonych zostaje do pojedynczych wielkości „syntetycznego” nakładu i „syntetycznego” efektu, które następnie są wykorzystywane przy obliczaniu wskaźnika efektywności obiektu. Ilość „syntetycznego” efektu i „syntetycznego” nakładu poniesiony przez obiekt jest funkcją celu, którą dla każdego obiektu należy maksymalizować w ramach zadania programowania liniowego. Zmiennymi optymalizowanymi są wagi μ_r i v_i wielkości nakładów oraz efektów, a wielkości efektów oraz nakładów są danymi empirycznymi.

W metodzie DEA estymuje się na podstawie danych empirycznych obwiednię (krawędź) zbioru możliwości produkcyjnych nazywaną krzywą efektywności. Krzywa efektywności jest wyznaczona przez jednostki mające najlepsze relacje wyników do nakładów. Obiekty uważa się za efektywne, jeżeli znajdują się na krzywej efektywności – wskaźnik ich efektywności wynosi 1, jeżeli natomiast znajdują się poza krzywą

efektywności, są nieefektywne technicznie. W metodzie DEA miarą nieefektywności jest odległość między punktem empirycznym charakteryzującym daną jednostkę a estymowaną krawędzią zbioru możliwości produkcyjnych. Efektywność danego obiektu jest mierzona względem innych obiektów z badanej grupy. Stosuje się modele DEA zorientowane na maksymalizację efektów lub zorientowane na minimalizację nakładów (Coelli i in. 2005).

Dodatkowo w celu wprowadzenia rankingu (rozdzielenia) obiektów efektywnych wykorzystuje się modele superefektywności (*the super-efficiency models*). Z kolei dla obiektów nieefektywnych można ustalić technologię optymalną, która jest określana na podstawie technologii obiektów o najwyższej względnej efektywności w badanej grupie. Technologia optymalna wyznaczana jest na podstawie wzoru (Guzik 2009):

$$T^*_o = \sum_{j=1}^N \lambda_{oj} \cdot t_j \quad (2)$$

gdzie:

T^*_o – technologia optymalna dla o -tego obiektu,

t_j – technologia empiryczna j -tego obiektu,

λ_{oj} – udział technologii j -tego obiektu w technologii optymalnej dla o -tego obiektu.

Jednakże należy pamiętać o ograniczeniach metody DEA. Należą do nich: nadmiarowość (redundacja), czyli zawyżanie liczby obiektów wskazywanych za efektywne, wrażliwość oraz niestabilność wyników w sytuacji nietypowych danych lub ich silnego skorelowania (Ziębicki 2014). W końcu badania z wykorzystaniem DEA dotyczą względnych miar efektywności badanych obiektów.

Material i metoda

Do badania przyjęto 58 z 59 uczelni akademickich nadzorowanych przez MNiSW. Z badania wyłączono Chrześcijańską Akademię Teologiczną w Warszawie ze względu na odrębną specyfikę jej funkcjonowania (jedyna uczelnia teologiczna podlegająca pod nadzór MNiSW). Wykaz szkół wyższych objętych badaniem wraz z nadanymi kodami zawiera Tabela 4 w aneksie.

Zmienne diagnostyczne do badania pozyskano ze sprawozdań z wykonania planu rzeczowo-finansowego uczelni, z informatora statystycznego MNiSW „Szkolnictwo wyższe – dane podstawowe”, a także z raportów publikowanych w ramach

ogólnopolskiego systemu monitorowania Ekonomicznych Losów Absolwentów szkół wyższych – ELA. Przy wyborze zmiennych do badania kierowano się doświadczeniem innych autorów oraz dostępnością danych.

W pomiarze efektywności dydaktycznej po stronie efektów uwzględniono ogólną liczbę absolwentów studiów drugiego stopnia (w tym jednolitych studiów magisterskich) – Y_1 , którzy są naturalnie utożsamiani z finalnym wynikiem procesu kształcenia. Z kolei za nakłady przyjęto liczbę nauczycieli akademickich (pełno- i niepełnozatrudnionych) – X_1 , liczbę pracowników niebędących nauczycielami akademickim (pełno- i niepełnozatrudnionych) – X_2 , którzy stanowią wsparcie dla kadry dydaktycznej oraz wartość rzeczowych aktywów trwałych (w zł) – X_3 . Do pomiaru efektywności zastosowano metodę DEA – model BCC (o zmiennych korzyściach skali) ukierunkowany na maksymalizację efektów (*output-oriented*) oraz model superefektywności. Przyjęto orientację modelu na maksymalizację efektów, gdyż strategię większości uczelni nie zakładają redukcji potencjału kadrowego¹.

Natomiast w zakresie eksperymentalnego badania skuteczności kształcenia przyjęto następujący zestaw zmiennych diagnostycznych:

- względny wskaźnik zarobków absolwentów (liczba)² – Z_1 ,
- czas poszukiwania pracy etatowej przez absolwentów (w miesiącach)³ – Z_2 ,
- względny wskaźnik bezrobocia absolwentów (liczba)⁴ – Z_3 .

Warto zauważyć, że dwie zmienne mają charakter destymulanty – Z_2, Z_3 , a jedna stymulanty – Z_1 .

W oparciu o te kryteria została przeprowadzona analiza skupień. Z literatury przedmiotu wynika, że najlepsze własności formalne wśród hierarchicznych metod aglomeracyjnych posiada metoda Warda, której efektywność wykrywania prawdziwej struktury danych jest około 40% lepsza niż w przypadku metody pojedynczego wiązania (Berbeka 2006). Metoda Warda wykorzystuje podejście analizy wariancji, co oznacza, że zmierza do minimalizacji sumy kwadratów dowolnych dwóch skupień, które mogą zostać uformowane na każdym etapie. Z kolei jako miarę odległości

¹ Autorzy posiadają świadomość, że przyjęcie orientacji modelu na maksymalizację efektów może budzić pewne wątpliwości m.in. ze względu na obowiązujący algorytm przyznawania dotacji i wskaźnik dostępności dydaktycznej. Jednakże warto zauważyć, że po stronie efektów uwzględniono liczbę absolwentów, a nie studentów oraz, że wybór modelu wynikał z doświadczenia innych badaczy.

² Proporcja wynagrodzeń ogółem do średnich zarobków w powiecie zamieszkania absolwenta w pierwszym roku po uzyskaniu dyplomu.

³ Liczba miesięcy, których przeciętny absolwent zatrudniony na etacie potrzebował do znalezienia pracy etatowej.

⁴ Proporcja ryzyka bycia bezrobotnym do stopy bezrobocia w powiecie zamieszkania absolwenta w pierwszym roku po uzyskaniu dyplomu.

między obiektami wykorzystano odległość euklidesową (tj. odległość geometryczną w przestrzeni wielowymiarowej).

Wybór okresu badawczego podyktowany był przede wszystkim dostępnością i aktualnością danych. Wszystkie zmienne wykorzystane w pomiarze efektywności (liczba absolwentów, liczba nauczycieli akademickich, liczba pracowników niebędących nauczycielami akademickimi, wartość rzeczowych aktywów trwałych) dotyczą roku 2014. Z kolei zmienne obrazujące skuteczność kształcenia odnoszą się do roku 2015 oraz uwzględniają sytuację absolwentów, którzy byli obecni w rejestrach ZUS⁵.

W procesie przetwarzania materiału badawczego wykorzystano arkusz kalkulacyjny *Microsoft Excel 2013*, program *STATISTICA 7.0*. oraz *DEA Solver Pro14c*.


Wyniki badań

W pierwszym etapie badań rozpoznano poziom efektywności uczelni wyższych i stworzono ich ranking według wskaźnika efektywności DEA (Rysunek 1 i Tabela 1). Średnia efektywność badanych uczelni w Polsce kształtowała się na dość wysokim poziomie – wskaźnik efektywności DEA wyniósł 0.72. 12 uczelni z 58 badanych uznano za w pełni efektywne, ich wskaźnik efektywności wyniósł 1. W grupie efektywnych obiektów znalazły się Akademia Pedagogiki Specjalnej im. Marii Grzegorzewskiej w Warszawie (U3), Akademia Pomorska w Słupsku (U4), Akademia Wychowania Fizycznego i Sportu im. Jędrzeja Śniadeckiego w Gdańsku (U6), Akademia Wychowania Fizycznego im. Jerzego Kukuczki w Katowicach (U9), Szkoła Główna Handlowa (U27), Uniwersytet Ekonomiczny w Katowicach (U28), Uniwersytet Ekonomiczny w Krakowie (U29), Uniwersytet Jagielloński w Krakowie (U34), Uniwersytet Kardynała Stefana Wyszyńskiego w Warszawie (U36), Uniwersytet Łódzki (U38), Uniwersytet Opolski (U41), Uniwersytet Rzeszowski (U48). Z kolei najniższą efektywnością dydaktyczną (przy tak zdefiniowanym zbiorze zmiennych diagnostycznych) odznaczała się Politechnika Białostocka (U12) – patrz Rysunek 1.

W drugim etapie badań dla obiektów efektywnych zastosowano model superefektywności DEA i wskazano, które uczelnie uznane za liderów szkolnictwa w zakresie działalności dydaktycznej najbardziej efektywnie przetwarzają posiadane nakłady w wyniki. W modelu superefektywności wskaźniki 12 uczelni ukształtowały się w przedziale od 1.00 do 1.55. Zdecydowaną przewagą nad pozostałymi uczelniami charakteryzował się Uniwersytet Łódzki (wskaźnik superefektywności DEA wyniósł 1.55 – patrz rysunek 2).

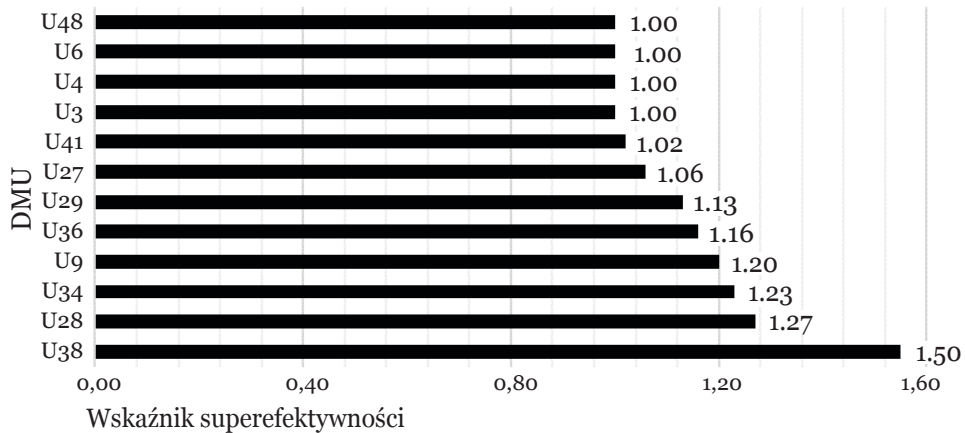
⁵ W rejestrach ZUS nie widnieją osoby ubezpieczone w Kasie Rolniczego Ubezpieczenia Społecznego (KRUS), osoby posiadające umowę o pracę podpisaną za granicą, osoby nieposiadające formalnej umowy o pracę.

Rysunek 1. Ranking uczelni według efektywności (model BCC)



Źródło: opracowanie własne.

Rysunek 2. Ranking uczelni efektywnych według modelu superefektywności DEA



Źródło: opracowanie własne.

Następnie bazując na metodzie DEA dla nieefektywnych uczelni, zidentyfikowano benchmarki (wzorce) – inne efektywne uczelnie o optymalnej technologii. Na podstawie tych wzorców dla nieefektywnych uczelni wyznaczono, o ile powinny się zmienić nakłady i efekty, aby daną uczelnię uznać za w pełni efektywną (Tabela 1). Oczywiście należy mieć na uwadze, że niektóre zmiany ze względu na obowiązujące przepisy prawa są niemożliwe do wprowadzenia. Zamierzeniem autorów jest wyłącznie wskazanie kierunku i potencjalnych zmian.

Na przykład dla Szkoły Głównej Gospodarstwa Wiejskiego w Warszawie (U26) wzorcem odniesienia były Uniwersytet Ekonomiczny w Katowicach (U28) i Uniwersytet Łódzki (U38). Aby SGGW mogło być uznane za efektywne, powinno zwiększyć liczbę absolwentów studiów drugiego stopnia do 4 823 (czyli o 78%) oraz zmniejszyć liczbę pracowników niebędących nauczycielami akademickimi do 951 i wartość rzeczowych aktywów trwałych do 357 085 108 zł. Zalecane wielkości nakładów znajdują się znacznie poniżej wielkości nakładów wykorzystanych w SGGW. Uczelnię tę można byłoby zatem zaliczyć do efektywnych, gdyby zmniejszyła liczbę pracowników niebędących nauczycielami akademickimi (o 33%) i wartość rzeczowych aktywów trwałych (o 82%). Wyniki w Tabeli 1 sugerują, jakie zmiany powinny dokonać się w poszczególnych uczelniach, aby mogły być one uznane za w pełni efektywne.

W trzecim etapie badań przeprowadzono analizę skupień, której celem był podział uczelni na grupy różniące się skutecznością kształcenia. Wydzielone grupy szkół wyższych powinny spełniać kryteria wewnętrznej spójności oraz zewnętrznej izolacji. Na Rysunku 3a przedstawiono diagram drzewa⁶ (dendrogram) ilustrujący uzyskaną hierarchię skupień. Oś pozioma odzwierciedla odległość wiązania, w tym przypadku odległość euklidesową, zaś oś pionowa analizowane uczelnie.

Aby określić optymalną liczbę skupień, posłużono się wykresem przebiegu aglomeracji, na którym przedstawiono odległości między skupieniami w momencie ich łączenia – Rysunek 3b. Punkt odcięcia wyznacza się w miejscu nagłego wzrostu odległości wiązania. W analizowanym przypadku znajduje się on między krokiem 55 a 56. Jego rzędna odpowiada odległości między wiązaniami wynoszącej około 9.5. Stąd możliwe było wyodrębnienie trzech skupień („A”, „B”, „C”). Ich charakterystykę zawiera Tabela 2.

Na podstawie uzyskanych wyników badań można stwierdzić, że najwyższą skutecznością kształcenia odznaczają się uczelnie wchodzące w skład skupienia „A”. Ich absolwenci średnio w pierwszym roku po uzyskaniu dyplomu odznaczają się najwyższym względnym wskaźnikiem zarobków (0.93), najkrótszym czasem poszukiwania pracy etatowej (2.16 miesiąca) oraz najniższym względnym wskaźnikiem bezrobocia (0.87). W skład skupienia „A” weszło dziewięć uczelni, a mianowicie:

⁶ Diagram drzewa otrzymuje się poprzez krokową aglomerację (łączenie w podzbiory) operacyjnych jednostek taksonomicznych (tu: uczelnie podlegających pod nadzór MNiSW).

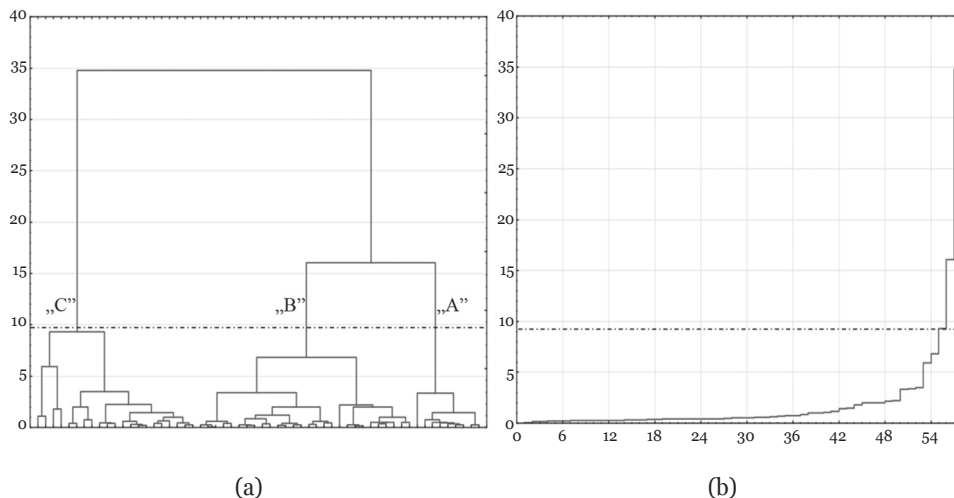
ID	Efektywność DEA	Liczba pracowników niebędących nauczycielami akademickimi – X1			Liczba nauczycieli akademickich – X2			Wartość rzeczowych aktywów trwałych – X3			Liczba absolwentów studiów II stopnia – Y1		
		Dane	Proponowane zmiany	Zmiana (%)	Dane	Proponowane zmiany	Zmiana (%)	Dane (mln zł)	Proponowane zmiany	Zmiana (%)	Dane	Proponowane zmiany	Zmiana (%)
U3	1.00	204	0	0	333.3	0	0	40214896	0	0	1142	0	0
U4	1.00	140	0	0	343	0	0	37680001	0	0	403	0	0
U6	1.00	177	0	0	154.5	0	0	96844222	0	0	364	0	0
U9	1.00	170	0	0	222.4	0	0	102229898	0	0	546	0	0
U27	1.00	512	0	0	772.4	0	0	83092399	0	0	1849	0	0
U28	1.00	495	0	0	504.3	0	0	164664936	0	0	2076	0	0
U29	1.00	653	0	0	723.4	0	0	120786128	0	0	2264	0	0
U34	1.00	3423	0	0	3879.4	0	0	2590026598	0	0	6114	0	0
U36	1.00	371	0	0	709.2	0	0	196908768	0	0	1997	0	0
U38	1.00	1445	0	0	2188.2	0	0	565328132	0	0	4987	0	0
U41	1.00	501	0	0	696.4	0	0	164088212	0	0	2172	0	0
U48	1.00	775	0	0	1275.8	0	0	506195185	0	0	3130	0	0
U49	0.99	862	-90	-10	1152.2	-209.2	-18	187543577	0	0	2658	45	2
U33	0.98	2202	0	0	2963.9	-128.9	-4	141575259	-75528156	-5	5310	323	6
U30	0.97	448	0	0	525.5	0	0	112395964	0	0	1787	154	9
U55	0.97	3341	-809	-24	3486.8	-368.8	-11	1678464288	0	0	5439	498	9
U8	0.92	244	0	0	240.5	0	0	237693514	-131611810	-55	717	175	24
U31	0.92	639	-71	-11	633.5	0	0	448396600	-252990120	-56	2117	533	25
U32	0.91	1456	-303	-21	1670.6	0	0	715102373	-272930764	-38	3725	1069	29
U42	0.91	494	0	0	924	-145	-16	199107551	0	0	2041	586	29
U50	0.84	1286	0	0	1940.9	-13.9	-1	492699150	0	0	3795	1995	53
U53	0.84	571	0	0	776.1	0	0	313562326	-35287686	-11	2027	1078	53
U40	0.84	2019	-655	-32	2045.5	0	0	962316589	-430942158	-45	3959	2215	56
U56	0.83	1466	-219	-15	1837.7	0	0	610893938	-128962949	-21	3616	2162	60
U39	0.82	1280	-82	-6	1744.7	0	0	449282743	0	0	3464	2077	60
U35	0.82	535	0	0	856	0	0	339093560	-101672020	-30	1957	1240	63
U26	0.78	1416	-465	-33	1313	0	0	1973061559	-1615976451	-82	2717	2106	78
U1	0.75	1873	-369	-20	2239.4	0	0	785054887	-158430302	-20	3742	3512	94
U20	0.74	865	0	0	1269.8	0	0	536667385	-194112662	-36	2433	2342	96

CD. Tabela 1. Efektywność dydaktyczna uczelni wyższych – metoda DEA

ID	Efektywność DEA	Liczba pracowników niebędących nauczycielami akademickimi – X1			Liczba nauczycieli akademickich – X2			Wartość rzeczowych aktywów trwałych – X3			Liczba absolwentów studiów II stopnia – Y1			
		Dane	Proporowane zmiany	Zmiana (%)	Dane	Proporowane zmiany	Zmiana (%)	Dane (mln)	Proporowane zmiany	Zmiana (%)	Dane	Proporowane zmiany	Zmiana (%)	
U25	0.73	2395	-1055	-44	2003.3	0	-96.2	-22	99345868	-54903619	-55	778	1033	133
U37	0.71	524	0	0	644.4	0	0	0	146652699	-7626147	-5	1177	1693	144
U54	0.70	1412	-77	-5	1994	0	0	0	198335523	-23034774	-12	1385	2031	147
U22	0.70	1700	-475	-28	1801.3	-19.3	-1	-1	346697965	-118575059	-34	1617	2427	150
U14	0.68	1425	-526	-37	1220.7	0	0	0	121045591	0	0	1169	1758	150
U12	0.67	209	0	0	439.2	-96.2	-22	0	273116693	0	0	1689	2573	152
U19	0.65	393	0	0	504.2	0	0	0	152194356	0	0	1316	2266	172
U17	0.64	582	-62	-11	549	0	0	0	189693369	-122836809	-65	475	837	176
U21	0.64	834	-189	-23	771	0	0	0	548818484	-427119439	-78	812	1561	192
U43	0.64	431	0	0	512.1	0	0	0	514910681	-183618014	-36	1877	3624	193
U57	0.63	667	0	0	899	0	0	0	2406018552	-1643392461	-68	2734	5993	219
U13	0.60	537	0	0	772.7	-72.7	-9	0	108543790	-37232894	-34	675	1691	250
U10	0.57	350	0	0	373.9	0	0	0	266792558	-126331536	-47	883	2480	281
U16	0.57	927	-37	-4	1204.6	0	0	0	291153684	-57724769	-20	1191	3409	286
U24	0.54	2390	-753	-31	2353	0	0	0	486440259	-237593979	-49	1191	3409	286
U51	0.50	262	0	0	388	0	0	0	581665075	-216823200	-37	1378	5145	373
U23	0.47	434	0	0	474.3	0	0	0	391194031	-1644451164	-42	882	3864	438
U44	0.46	878	-220	-25	793.3	0	0	0	129422892	0	0	598	2640	441
U45	0.46	653	0	0	806	0	0	0	378835946	-90562404	-24	1003	4607	459
U18	0.39	1408	-439	-31	1345.6	0	0	0	160557299	0	0	695	3479	441
U47	0.35	682	-40	-6	765.2	0	0	0	365332811	-149630250	-41	756	3904	516
U58	0.35	359	0	0	498	0	0	0	66084497	-12997585	-20	346	2004	579
U52	0.34	1101	-313	-28	1023.8	0	0	0	178959518	-91569088	-51	251	1726	687
U46	0.31	861	-245	-28	718.8	0	0	0	313366328	-110774132	-35	115	4582	3985
U5	0.28	225	0	0	358.3	0	0	0						
U11	0.25	251	0	0	296.4	0	0	0						
U12	0.05	697	-112	-16	663.7	0	0	0						

Źródło: opracowanie własne.

Rysunek 3. Etapy analizy skupień: (a) diagram drzewa, (b) wykres przebiegu aglomeracji



Źródło: opracowanie własne.

Tabela 2. Charakterystyka skupień

ID skupienia	Elementy skupienia	Minimum			Średnia			Maksimum		
		Z ₁	Z ₂	Z ₃	Z ₁	Z ₂	Z ₃	Z ₁	Z ₂	Z ₃
„A”	U1, U14, U17, U22, U24, U25, U27, U31, U52	0.85	1.47	0.55	0.93	2.16	0.87	1.18	2.73	1.06
„B”	U3, U4, U5, U6, U9, U10, U13, U15, U16, U18, U20, U28, U29, U30, U32, U33, U34, U36, U37, U41, U43, U46, U50, U51, U55, U56, U57, U58	0.53	1.87	0.86	0.67	2.80	1.19	0.81	3.58	1.77
„C”	U2, U7, U8, U11, U12, U19, U21, U23, U26, U35, U38, U39, U40, U42, U44, U45, U47, U48, U49, U53, U54	0.35	2.95	1.47	0.53	3.96	2.00	0.65	6.68	3.64

Źródło: opracowanie własne.

Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie (U1), Politechnika Gdańska (U14), Politechnika Lubelska (U17), Politechnika Śląska w Gliwicach (U22), Politechnika Warszawska (U24), Politechnika Wrocławska (U25), Szkoła Główna Handlowa (U27), Uniwersytet Ekonomiczny we Wrocławiu (U27), Uniwersytet Technologiczno-Przyrodniczy im. Jana i Jędrzeja Śniadeckich w Bydgoszczy (U52).

Szkoły wyższe, które weszły w skład skupienia „B”, odznaczają się „przeciętną” skutecznością kształcenia. Z kolei jednostki tworzące skupienie „C” charakteryzują się najniższą skutecznością kształcenia. W grupie tej znalazło się dwadzieścia jeden uczelni, w tym np.: Politechnika Białostocka (U12), Politechnika Opolska (U19), Uniwersytet Jana Kochanowskiego w Kielcach (U35), Uniwersytet Łódzki (U38) czy Uniwersytet Warmińsko-Mazurski w Olsztynie (U54).

W kolejnym kroku analizy, na podstawie uzyskanego wskaźnika efektywności DEA, podzielono uczelnie na⁷:

- wysoko-efektywne (powyżej 66 percentyla)⁸,
- średnio-efektywne (powyżej 33 i poniżej 66 percentyla)⁹,
- nisko-efektywne (poniżej 33 percentyla)¹⁰.

Następnie skonstruowano macierz składającą się z dziewięciu pól, która pozwala ocenić każdą z uczelni pod względem przyznanej kategorii efektywności oraz skuteczności kształcenia – Rysunek 4.

W grupie uczelni odznaczających się wysoką efektywnością i skutecznością kształcenia znalazły się Szkoła Główna Handlowa (U27) oraz Uniwersytet Ekonomiczny we Wrocławiu (U31), zaś w grupie szkół wyższych charakteryzujących się niską efektywnością i skutecznością kształcenia: Akademia Wychowania Fizycznego im. Bronisława Czecha w Krakowie (U7), Akademia Wychowania Fizycznego we Wrocławiu (U11), Politechnika Białostocka (U12), Politechnika Świętokrzyska w Kielcach (U23), Uniwersytet Przyrodniczy w Lublinie (U44), Uniwersytet Przyrodniczy w Poznaniu (U45) oraz Uniwersytet Rolniczy im. Hugona Kollątaja w Krakowie (U47).

Przy użyciu testu niezależności chi kwadrat (χ^2) zweryfikowano hipotezę zerową (H_0 : efektywność i skuteczność kształcenia szkół wyższych podlegających nadzorowi MNiSW są niezależne). Ze względu na to, że wartość obliczona χ^2 (6.606) była mniejsza od teoretycznej (9.488), można stwierdzić, że – na poziomie istotności $\alpha = 0.05$ – nie istnieją podstawy do odrzucenia hipotezy zerowej, zatem efektywność i skuteczność kształcenia uczelni publicznych podlegających MNiSW są niezależne.

⁷ Podział szkół wyższych na trzy grupy pod względem efektywności był podyktowany przyjętą procedurą badawczą. Warto zauważyć, że test chi kwadrat (χ^2) jest „wrażliwy” na puste pola w tabeli krzyżowej. Autorzy postanowili dokonać takiego podziału uczelni, aby było możliwe przeprowadzenie dalszych analiz.

⁸ Wskaźnik efektywności kształcenia z przedziału $<0.9; 1.0>$.

⁹ Wskaźnik efektywności kształcenia z przedziału $<0.64; 0.9>$.

¹⁰ Wskaźnik efektywności kształcenia z przedziału $<0.05; 0.64>$.

Rysunek 4. Macierz efektywności i skuteczności kształcenia

wysoka skuteczność kształcenia	U24, U52	U1, U14, U17, U22, U25	U27, U31
średnia skuteczność kształcenia	U5, U10, U13, U15, U16, U18, U46, U51, U57, U58	U20, U37, U43, U50, U56	U3, U4, U6, U9, U28, U29, U30, U32, U33, U34, U36, U41, U55
niska skuteczność kształcenia	U7, U11, U12, U23, U44, U45, U47	U2, U19, U21, U35, U39, U40, U53, U26, U54	U8, U38, U42, U48, U49
	niska efektywność kształcenia	średnia efektywność kształcenia	wysoka efektywność kształcenia

Źródło: opracowanie własne.

W kolejnym kroku analizy uzyskany wskaźnik efektywności DEA dla poszczególnych szkół wyższych skonfrontowano z trzema zmiennymi diagnostycznymi opisującymi ich skuteczność kształcenia (Z_1 , Z_2 i Z_3). Również w tym przypadku siłę związku w każdym z przypadków można określić jako słabą – Tabela 3.

Tabela 3. Współczynniki korelacji prostej Pearsona pomiędzy wskaźnikiem efektywności a poszczególnymi zmiennymi opisującymi skuteczność kształcenia uczelni

Zmienna diagnostyczna	Współczynnik korelacji liniowej Pearsona
Z1	-0.029
Z2	-0.102
Z3	-0.145

Źródło: opracowanie własne

Podsumowanie i wnioski

W niniejszym artykule autorzy przedstawili wyniki wstępnych badań w zakresie efektywności i skuteczności procesu dydaktycznego dla 58 uczelni podlegających nadzorowi MNiSW. Za miary skuteczności przyjęto: względny wskaźnik zarobków

absolwentów, czas poszukiwania pracy etatowej przez absolwentów, względny wskaźnik bezrobocia absolwentów. Z kolei w pomiarze efektywności po stronie nakładów uwzględniono: liczbę nauczycieli akademickich (pełno- i niepełnozatrudnionych), liczbę pracowników niebędących nauczycielami akademickimi (pełno- i niepełnozatrudnionych), wartość rzeczowych aktywów trwałych, zaś po stronie efektów – liczbę absolwentów studiów drugiego stopnia. Przeprowadzone analizy potwierdziły, że nie istnieje zależność między efektywnością procesu kształcenia a jego skutecznością (oczywiście w zakresie uwzględnionych w badaniu zmiennych diagnostycznych).

Uzyskane wyniki badań można krytykować zasadniczo z dwóch perspektyw. Po pierwsze z perspektywy przyjętych w badaniach założeń, po drugie z pozycji krytyki zastosowanych metod.

Można polemizować z przyjętym założeniem, że ekonomiczny wymiar aktywności ludzkiej (osiągane wynagrodzenie, ryzyko bycia bezrobotnym, czas poszukiwania pracy) jest jedyną kwestią, którą należy uwzględnić przy analizie skuteczności kształcenia akademickiego. W badaniu pominięto również absolwentów, którzy nie figurują w raportach ZUS: osoby ubezpieczone w Kasie Rolniczego Ubezpieczenia Społecznego, osoby posiadające umowy o pracę podpisane za granicą oraz osoby bez formalnej umowy o pracę.

Drugą grupę argumentów krytycznych w stosunku do uzyskanych wyników badań można próbować wysnuć z krytyki metody DEA. Do najważniejszych jej ograniczeń należą: duża wrażliwość wyników na błędne lub nietypowe dane w obiektach uznanych za efektywne (co przypadku różnorodnej specyfiki uczelni jest prawdopodobne), względny charakter efektywności obiektu (np. może się również zdarzyć, że obiekt o niezbyt dużej sprawności zostanie uznany za w pełni efektywny – gdyż inni są jeszcze gorsi, taka sytuacja nie występuje przy stosowaniu wskaźników finansowych), wrażliwość na liczbę uwzględnionych nakładów i efektów (im większa liczba zmiennych, tym większa możliwość znalezienia się na granicy efektywności jednostki w rzeczywistości nieefektywnej). Ponadto nie skonfrontowano otrzymanych wyników z alternatywnymi modelami DEA, dlatego wyciąganie kategorycznych wniosków nie jest uprawnione.

Konkludując, ocena efektywności i skuteczności kształcenia akademickiego jest niezwykle ważnym, a zarazem złożonym zagadnieniem badawczym. Niniejszy artykuł nie wyczerpuje tej problematyki, a ze względu na wskazane ograniczenia powinien być raczej traktowany jako załączek do dalszych badań z tego zakresu.

Literatura

Berbeka, J. (2006). *The Standard of Living of the Population and Economic Growth in the Countries of the European Union*. Kraków: Wydawnictwo Akademii Ekonomicznej w Krakowie.

- Brzezicki, Ł. i Pietrzak, P. (2018). Produktywność dydaktyczna publicznych uniwersytetów w latach 2010–2015. *Edukacja*. 1: 96–105.
- Coelli, T.J., Rao D.S., O'Donnell, C.J., i Battese, G.E. (2005). *An Introduction to Efficiency and Productivity Analysis*. New York: Springer.
- Cooper, W.W., Seiford, L.M., i Tone, K. (2007). *Data Envelopment Analysis: A Comprehensive Text with Models, Applications, References and DEA-Solver Software*. New York: Kluwer Academic Publishers.
- Ćwiąkała-Małys, A. i Nowak, W. (2009). Sposoby klasyfikacji modeli DEA. *Badania Operacyjne i Decyzje*. 3: 5–18.
- Dąbrowski, J. (2012). Metodyczne aspekty pomiaru efektywności przedsiębiorstw portowych. *Studia i Materiały Instytutu Transportu i Handlu Morskiego*. 9: 31–50.
- Denek, K. (1997). Efektywność edukacji szkolnej. *Zeszyty Naukowe Wyższej Szkoły Pedagogicznej w Bydgoszczy. Studia Pedagogiczne*. 30: 91–106.
- Guzik, B. (2009). *Podstawowe modele DEA w badaniu efektywności gospodarczej i społecznej*. Poznań: Wydawnictwo Uniwersytetu Ekonomicznego w Poznaniu.
- Pietrzak, P. (2016). *Efektywność funkcjonowania publicznych szkół wyższych w Polsce*. Warszawa: Wydawnictwo Szkoły Głównej Gospodarstwa Wiejskiego w Warszawie.
- Pietrzak, P. (2018). Skuteczność kształcenia akademickiego w zakresie nauk rolniczych. *Roczniki Naukowe Stowarzyszenia Ekonomistów Rolnictwa i Agrobiznesu*. 20(1): 104–110.
- Pszczółowski, T. (1978). *Mała encyklopedia prakseologii i teorii organizacji*. Wrocław: Zakład Narodowy im. Ossolińskich.
- Sidor-Rządkowska, M. (2005). *Kształtowanie nowoczesnych systemów ocen pracowników*. Kraków: Wydawnictwo Oficyna Ekonomiczna.
- Szuwarzyński, A. i Julkowski, B. (2014). Wykorzystanie wskaźników złożonych i metod nieparametrycznych do oceny i poprawy efektywności funkcjonowania wyższych uczelni technicznych. *Edukacja*. 3: 54-74.
- Ziębicki, B. (2014). *Efektywność organizacyjna podmiotów sektora publicznego*. Kraków: Wydawnictwo Uniwersytetu Ekonomicznego w Krakowie.

Aneks

Tabela 4. Szkoły wyższe objęte badaniem

Kod uczelni	Nazwa uczelni
U1	Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie
U2	Akademia im. Jana Długosza w Częstochowie
U3	Akademia Pedagogiki Specjalnej im. Marii Grzegorzewskiej w Warszawie
U4	Akademia Pomorska w Słupsku
U5	Akademia Techniczno-Humanistyczna w Bielsku-Białej

Kod uczelni	Nazwa uczelni
U6	Akademia Wychowania Fizycznego i Sportu im. Jędrzeja Śniadeckiego w Gdańsku
U7	Akademia Wychowania Fizycznego im. Bronisława Czecha w Krakowie
U8	Akademia Wychowania Fizycznego im. Eugeniusza Piaseckiego w Poznaniu
U9	Akademia Wychowania Fizycznego im. Jerzego Kukuczki w Katowicach
U10	Akademia Wychowania Fizycznego Józefa Piłsudskiego w Warszawie
U11	Akademia Wychowania Fizycznego we Wrocławiu
U12	Politechnika Białostocka
U13	Politechnika Częstochowska
U14	Politechnika Gdańska
U15	Politechnika Koszalińska
U16	Politechnika Krakowska im. Tadeusza Kościuszki
U17	Politechnika Lubelska
U18	Politechnika Łódzka
U19	Politechnika Opolska
U20	Politechnika Poznańska
U21	Politechnika Rzeszowska im. Ignacego Łukasiewicza
U22	Politechnika Śląska w Gliwicach
U23	Politechnika Świętokrzyska w Kielcach
U24	Politechnika Warszawska
U25	Politechnika Wrocławska
U26	Szkoła Główna Gospodarstwa Wiejskiego w Warszawie
U27	Szkoła Główna Handlowa
U28	Uniwersytet Ekonomiczny w Katowicach
U29	Uniwersytet Ekonomiczny w Krakowie
U30	Uniwersytet Ekonomiczny w Poznaniu
U31	Uniwersytet Ekonomiczny we Wrocławiu
U32	Uniwersytet Gdański
U33	Uniwersytet im. Adama Mickiewicza w Poznaniu
U34	Uniwersytet Jagielloński
U35	Uniwersytet Jana Kochanowskiego w Kielcach
U36	Uniwersytet Kardynała Stefana Wyszyńskiego w Warszawie
U37	Uniwersytet Kazimierza Wielkiego w Bydgoszczy
U38	Uniwersytet Łódzki
U39	Uniwersytet Marii Curie-Skłodowskiej w Lublinie
U40	Uniwersytet Mikołaja Kopernika w Toruniu
U41	Uniwersytet Opolski
U42	Uniwersytet Pedagogiczny im. Komisji Edukacji Narodowej w Krakowie
U43	Uniwersytet Przyrodniczo-Humanistyczny w Siedlcach
U44	Uniwersytet Przyrodniczy w Lublinie
U45	Uniwersytet Przyrodniczy w Poznaniu
U46	Uniwersytet Przyrodniczy we Wrocławiu

Kod uczelni	Nazwa uczelni
U47	Uniwersytet Rolniczy im. Hugona Kollątaja w Krakowie
U48	Uniwersytet Rzeszowski
U49	Uniwersytet Szczeciński
U50	Uniwersytet Śląski w Katowicach
U51	Uniwersytet Technologiczno-Humanistyczny im. Kazimierza Pułaskiego w Radomiu
U52	Uniwersytet Technologiczno-Przyrodniczy im. Jana i Jędrzeja Śniadeckich w Bydgoszczy
U53	Uniwersytet w Białymstoku
U54	Uniwersytet Warmińsko-Mazurski w Olsztynie
U55	Uniwersytet Warszawski
U56	Uniwersytet Wrocławski
U57	Uniwersytet Zielonogórski
U58	Zachodniopomorski Uniwersytet Technologiczny w Szczecinie

Źródło: opracowanie własne.

Efficiency and Effectiveness of Academic Teaching in Public Higher Education in Poland

ABSTRACT: Due to the ongoing work on the reform of higher education in Poland, the article discusses the efficiency and effectiveness of academic teaching. The foreign and domestic literature has been reviewed in this respect. The article also presents the results of preliminary research, which concerned fifty-eight universities subject to the supervision of the Ministry of Science and Higher Education (MNiSW). The non-parametric approach (DEA method) was used to measure the efficiency of teaching activity - the BCC model aimed at maximizing the effects. In the measure of effectiveness, the hierarchical agglomeration method (Ward method) was used, the Euclidean distance was used as the distance measure.

KEYWORDS: higher education, teaching, efficiency, effectiveness.

CYTOWANIE: Pietrzak, P. i Baran, J. (2018). Efektywność i skuteczność kształcenia w publicznym szkolnictwie wyższym w Polsce. *Nauka i Szkolnictwo Wyższe*. 2(52): 113–130. DOI: 10.14746/nisw.2018.2.3.

PIOTR GRZEGORZ PIETRZAK – adiunkt w Katedrze Ekonomiki i Organizacji Przedsiębiorstw Wydziału Nauk Ekonomicznych Szkoły Głównej Gospodarstwa Wiejskiego w Warszawie. Jego zainteresowania naukowe obejmują ekonomikę i organizację sektora publicznego a w szczególności efektywność funkcjonowania szkół wyższych, zarządzanie strategiczne oraz współczesne koncepcje zarządzania (orcid.org/0000-0002-1319-4815).

JOANNA BARAN – adiunkt w Katedrze Logistyki Wydziału Nauk Ekonomicznych SGGW w Warszawie, Kierownik Studiów Podyplomowych Logistyka. Jej zainteresowania naukowe dotyczą parametrycznych i nieparametrycznych metod pomiaru efektywności przedsiębiorstw, ekonomiki przedsiębiorstw agrobiznesu, logistyki i gospodarki odpadami. Opublikowała z tego zakresu ponad 120 artykułów naukowych w czasopismach polskich i zagranicznych (orcid.org/0000-0001-9801-4344).

Łukasz Brzezicki

Efektywność studiów Master of Business Administration (MBA) w Polsce

STRESZCZENIE: W artykule oszacowano efektywność 28 programów studiów MBA w Polsce za pomocą „alokacyjnego” modelu *New Cost* (Tone 2002) należącego do nieparametrycznej metody DEA. Za nakłady przyjęto liczbę godzin programu MBA oraz jego koszt, zaś za wynik ogólny wskaźnik rankingowy studiów MBA w 2018 roku opracowany przez *Perspektywy*. Uzyskane wyniki świadczą o przeciętnej efektywności studiów MBA wynoszącej 68%, tylko sześć programów było w pełni efektywne (100%). Średnia wartość redukcji nakładów oscyluje wokół 33%. Sześć programów MBA było jednostkami wzorcowymi dla nieefektywnych studiów.

SŁOWA KLUCZOWE: szkolnictwo wyższe, efektywność, DEA, koszt, MBA

Wstęp

W najnowszej ustawie z dnia 20 lipca 2018 r. Prawo o szkolnictwie wyższym i nauce (Dz.U. 2018 poz. 1668) wskazuje się, że „misją systemu szkolnictwa wyższego i nauki jest prowadzenie najwyższej jakości kształcenia [...], a także uczestnictwo w rozwoju społecznym oraz tworzeniu gospodarki opartej na innowacjach”. Ponadto „system szkolnictwa wyższego i nauki funkcjonuje z poszanowaniem standardów międzynarodowych, zasad etycznych i dobrych praktyk w zakresie kształcenia”. W powyższym kontekście szczególnego znaczenia nabierają prestiżowe studia menedżerskie Master of Business Administration (MBA), które skierowane są do osób chcących rozwijać swoją karierę na stanowiskach kierowniczych i dyrektorskich.

Jednak należy zauważyć, że Ministerstwo Nauki i Szkolnictwa Wyższego poproszone o zdefiniowanie studiów MBA wskazało, że:

W polskim obszarze szkolnictwa wyższego brak jest definicji prawnej „studiów MBA” (Master of Business Administration). Zarówno nadrzędny akt prawny, jak i akty

wykonawcze, nie określają pojęcia „studiów MBA”, ani tytułów zawodowych związanych z ich ukończeniem.

Z reguły programy MBA w Polsce prowadzone są na podstawie porozumień partnerskich polskich uczelni z renomowanymi uczelniami z zagranicy. Podstawową formą ich organizacji w Polsce są studia podyplomowe. Do prowadzenia studiów podyplomowych są uprawnione nie tylko uczelnie, ale również instytuty naukowe Polskiej Akademii Nauk, instytuty badawcze lub Centrum Medyczne Kształcenia Podyplomowego [...]. Uczestnicy programów MBA prowadzonych w Polsce mają możliwość uzyskania dyplomu MBA zagranicznej uczelni oraz – jeżeli program jest realizowany w formie studiów podyplomowych – świadectwa ukończenia studiów podyplomowych polskiej uczelni. Tytuły po ukończeniu studiów MBA (Master of Business Administration) nadawane są poza polskim systemem szkolnictwa wyższego. Natomiast jakość programów MBA potwierdzają przede wszystkim akredytacje instytucji międzynarodowych (MNiSW 2017).

W Polsce oprócz rankingu studiów MBA prowadzonego przez *Perspektywy*, który jest ukierunkowany na jakościowy aspekt kształcenia, nie są realizowane inne badania ilościowe. W związku z powyższym należy wypełnić powyższą lukę w wiedzy i określić efektywność ich funkcjonowania.

Celem badania jest oszacowanie efektywności alokacyjnej studiów MBA w Polsce za pomocą nieparametrycznej metody DEA. Wartością dodaną artykułu jest zwrócenie uwagi na studia MBA, które nie były dotychczas oceniane w Polsce, a i zagranicą tylko w kilku badaniach zostały one ujęte. Jego dodatkowym wkładem będzie wykorzystanie metody DEA do pomiaru efektywności alokacyjnej, a nie jak miało to miejsce dotychczas jedynie do efektywności technicznej.

Artykuł składa się z pięciu części. W drugiej z nich dokonano przeglądu literatury. W następnej przedstawiono metodykę badawczą odnośnie do badanych jednostek, przyjętych zmiennych oraz modelu DEA. W czwartej części zaprezentowano wyniki badania. W ostatniej wskazano wnioski końcowe oraz kierunki dalszych badań.

Przegląd literatury

Badania dotyczące szkolnictwa wyższego są prowadzone od wielu lat i z dokonanej przez autora kwerendy (Brzezicki 2018; Brzezicki i Prędko 2018) wynika, że są one realizowane za pomocą parametrycznej metody SFA i nieparametrycznej DEA. W literaturze ukształtował się pogląd, że metoda DEA jest najwłaściwsza do oszacowania efektywności technicznej (Nazarko i in. 2008), a SFA kiedy mamy informację o cenie lub koszcie (np. Robst 2001; Izadi i in. 2002; Sav 2012). Należy jednak zauważyć, że z uwagi na utrudniony dostęp do danych finansowych do badania efektywności szkolnictwa wyższego stosuje się głównie metodę DEA, a w dużo mniejszym stopniu SFA.

Do badania efektywności technicznej w ramach metody DEA były wykorzystywane różne modele (Brzezicki i Pietrzak 2018): np. CCR ze stałymi efektami skali, BCC ze zmiennymi efektami, model nieradialny SBM, model Hybrydowy. Jednak dotychczas w polskiej literaturze nie wykorzystano modeli „alokacyjnych” DEA, natomiast w badaniach zagranicznych miało to miejsce w nielicznych pracach (np. Johnes i Ruggiero 2016). W przypadku metody SFA wykorzystano albo funkcję produkcji (zob. np. Brzezicki i Prędko 2018; Kulshreshtha i Nayak 2015) albo kosztu (np. Izadi i in. 2002; Robst 2001) do oszacowania efektywności szkolnictwa wyższego.

W zależności od wybranej metody lub celu prowadzonego badania autorzy wykorzystywali różne zmienne, dominują jednak dane statystyczne i finansowe. W przypadku nakładów przyjmowano liczbę nauczycieli akademickich (Ćwiąkała-Małys 2010), pozostałych pracowników (Brzezicki i Wolszczak-Derlacz 2015), ogólnych przychodów szkoły wyższej (Wolszczak-Derlacz 2013), różnego rodzaju kosztów (np. w postaci zużycia materiałów i energii, usług obcych, płac brutto (kosztów osobowych), amortyzacji i innych (np. Świtłyk 2012; Warning 2004)), ogólnych wydatków (Izadi i in. 2002), wartość aktywów (np. Ćwiąkała-Małys 2010), środków trwałych (Brzezicki i Prędko 2018). Niekiedy w badaniu działalności edukacyjnej wykorzystywano wartość dotacji (Brzezicki 2016), przychodów (Brzezicki i Wolszczak-Derlacz 2015) lub kosztów dydaktycznych (Brzezicki 2016). Za wyniki przyjmowano liczbę studentów (Rusielik 2010), absolwentów (Brzezicki 2016), doktorantów (Chodakowska 2015), stopni naukowych (Brzezicki i Prędko 2018), publikacji, cytowań, wartość grantów (Wolszczak-Derlacz 2013), ocenę preferencji pracodawców w stosunku do absolwentów według rankingu *Perspektyw* (Brzezicki 2016; Brzezicki i Wolszczak-Derlacz 2015), ogólny wskaźnik rankingowy szkół wyższych oszacowany przez *Perspektywy* (Sivińska-Gorzela 2010).

Badanie efektywności działalności dydaktycznej szkolnictwa wyższego było przede wszystkim skoncentrowane na studiach I, II stopnia i jednolitych magisterskich (np. Ćwiąkała-Małys 2010; Wolszczak-Derlacz 2013). Inne rodzaje studiów, np. doktoranckich, były przeważnie uwzględniane podczas badania studiów I i II stopnia (Chodakowska 2015; Nazarko i Šaparauskas 2014). Należy jednak zauważyć, że jest bardzo mało badań, w których uwzględniano studia podyplomowe, występują one tylko w literaturze zagranicznej (np. Johnes 2006). Jeszcze mniej badań dotyczy studiów MBA, podobnie jak w przypadku studiów podyplomowych były one dotychczas realizowane tylko w literaturze zagranicznej, wśród nielicznych prac z tego zakresu warto wymienić np. Wang i Huang (2004); Colbert, Levary i Shaner (2000); Jaska i Swamy (2013); Fisher, Kiang i Fisher (2007); Hsu, James i Chao (2009); Ray i Jeon (2008); Fu i Huang (2009).

Ray i Jeon (2008) wykorzystali w swoich badaniach dwa wyniki, z których pierwszym jest wskaźnik „GAIN” mierzący różnicę między roczną zmianą zarobków przed

i po studiach MBA skorygowany o czesne reprezentatywnego absolwenta szkoły wyższej. Drugim jest wskaźnik ofert pracy po ukończeniu studiów obliczany na podstawie średniej liczby ofert po ukończeniu edukacji pomnożone przez prawdopodobieństwo uzyskania pracy po ukończeniu studiów. Autorzy za nakłady przyjęli m.in. przychody z działalności dydaktycznej, udział przyjętych kandydatów na studia MBA ze wszystkich zgłoszonych osób, udział zgłoszeń międzynarodowych i kobiet, stosunek studentów do pracowników dydaktycznych. Colbert, Levary i Shaner (2000) wykorzystując opracowanie rankingowe przeprowadzone przez *Business Week Magazine*, ujęli w swoim badaniu m.in. udział absolwentów, którzy płacą za studia, następnie zadowolenie studentów z procesu nauczania, programów studiów oraz miejsca studiowania, a także poziom zadowolenia osób zajmujących się rekrutacją kandydatów do pracy z ich umiejętności analitycznych, pracy zespołowej i „spojrzenia globalnego” nauczanego podczas studiów MBA. Następnie uwzględniono stosunek studentów na wydziale, średni stosunek studentów do kadry dydaktycznej w danym programie MBA, liczbę przedmiotów fakultatywnych. Podobną konwencję badawczą wykorzystali Jaska i Swamy (2013), którzy pozyskali dane z popularnego zestawienia *Careers 360*, m.in. w postaci: wskaźnika określającego różnorodność studentów, następnie doświadczenia zawodowego studentów, odsetka studentów w miejscu zamieszkania, a także średniej pensji absolwentów i stopę zwrotu z inwestycji w edukację MBA. Wang i Huang (2004) wykorzystali następujące dane: liczbę studentów zagranicznych, liczbę wydziałów, w których większość kadry dydaktycznej to pracownicy z zagranicy, wydziałów mających doktorantów, wzrost procentowy pensji, stosunek jakości do ceny. Hsu, James i Chao (2009) ujęli w swoim badaniu m.in. średnie początkowe wynagrodzenie absolwentów, średniomiesięczne bieżące wynagrodzenie w okresie 3-letnim, średni czas poszukiwania pracy przez absolwentów, poziom zadowolenia studentów z programu studiów.

Znalezione podczas kwerendy luki w wiedzy w zakresie niewykorzystywania „alokacyjnych” modeli DEA do szacowania efektywności szkolnictwa wyższego oraz brak pomiaru efektywności studiów MBA w Polsce stanowią podstawę niniejszego badania.

Metodyka badania empirycznego

Jak zaznaczono w poprzedniej części artykułu, najczęściej wykorzystywano metodę DEA do badania szkolnictwa wyższego, jednak tylko w zakresie szacowania efektywności technicznej. Podejście takie jest uzasadnione, gdy nie ma informacji albo o cenach, albo o koszcie nakładów lub efektów działalności jednostek produkcyjnych. Jednak gdy dysponujemy informacjami dotyczącymi cen lub kosztów, można zastosować modele „alokacyjne” DEA. Cooper, Seiford i Tone (2007: 258, 273) wskazują,

że „efektywność alokacyjną można powiązać z publikacjami Farrella (1957) i Debreu (1951), których prace stanowią podwaliny metody DEA. Natomiast Färe, Grosskopf i Lovell (1985) opracowali formuły programowania liniowego w ramach metodyki DEA”, które pozwalają oszacować efektywność alokacyjną. Farrell (1957) w swoich rozważaniach podzielił efektywność ogólną na techniczną i alokacyjną (Blackburn, Brennan i Ruggiero 2014). Pierwsza efektywność związana jest z technologicznymi możliwościami produkcyjnymi jednostki do minimalizacji nakładów przy danym zbiorze efektów (orientacja na nakłady) osiąganymi przez dany podmiot gospodarczy, a druga efektywność dotyczy optymalnej alokacji (struktury) zasobów poprzez wykorzystanie nakładów w odpowiedniej proporcji przy uwzględnieniu poziomu cen czynników wytwórczych (minimalizacji kosztów) w procesie produkcji (Perek 2014). Efektywność alokacyjna występuje (Kisielewska 2008: 191) „wtedy, gdy nakłady na wytworzenie danego poziomu (skala) i zestawu (zakres) efektów są użyte przez firmę” we właściwych „proporcjach”. Jednostka będzie efektywna alokacyjnie, gdy do produkcji swoich wyrobów (Domagała 2009: 21) „wykorzystuje taką kombinację nakładów, które charakteryzują się najniższym kosztem czyli najniższą ceną”. Inaczej mówiąc, „miara efektywności alokacyjnej dostarcza informacji, czy wykorzystana kombinacja nakładów [...] jest właściwa z ekonomicznego punktu widzenia” (Nazarko i in. 2008: 93).

Zanim przejdziemy do określenia modelu DEA, najpierw niezbędne jest zdefiniowanie zależności poszczególnych rodzajów efektywności. Całkowita (kosztowa) efektywność (Cooper, Seiford i Tone 2007) zwana również ekonomiczną (EC) jest iloczynem efektywności alokacyjnej (EA) i technicznej (ET). Natomiast efektywność alokacyjna (EA), jak podaje Coelli i in. (2005), jest stosunkiem efektywności całkowitej (EA) do efektywności technicznej (ET).

$$EC = EA * ET \quad (1)$$

$$EA = EC/ET \quad (2)$$

Tone i Tsutsui (2007), nawiązując do pracy Tone (2002), wskazują, że tradycyjne postrzeganie efektywności kosztowej i alokacyjnej, która zakłada jednolite ceny nakładu, nie sprawdza się, gdy ceny jednostkowe nakładów nie są identyczne w każdym badanym podmiocie. W celu zrozumienia tych wad autorzy przytaczają przykład: „jeśli dwa podmioty gospodarcze (DMU) mają te same nakłady i wyjścia, a cena jednostkowa dla jednego DMU jest dwa razy większa od drugiej, wówczas tradycyjny model efektywności kosztowej przypisuje obu tym samym firmom taką samą efektywność kosztową. Jest to jednak nie do przyjęcia przy analizie faktycznej sytuacji gospodarczej” (Tone i Tsutsui 2007: 91–92). Tone (2002) zidentyfikował powyższe

niedociągnięcia klasycznego modelu efektywności kosztowej Farrell-Debreu i zaproponował nowy model – *New Cost*, który jest wolny od takich niespójności. Model *New Cost* ze zmiennymi efektami skali [NewCost-V] przyjęty do badania empirycznego charakteryzuje się minimalizacją nakładów (orientacja na nakłady). Zastosowanie powyższego modelu *New Cost* ma uzasadnienie merytoryczne, gdyż jest on szczególnie formą badania efektywności alokacyjnej w przypadku przyjęcia pojedynczych zmiennych po stronie wejść i wyjść, których to klasyczne modele „alokacyjne” nie są w stanie należycie oszacować. Wynika to z faktu, że w standardowych modelach alokacyjnych DEA w sytuacji jednowymiarowej (tj. 1 nakład [$C_1 X_1$] składający się z pojedynczego wejścia [X_1] i odpowiadający jemu koszt lub cena [C_1] oraz 1 wynik [Y_1]) poziom efektywności technicznej jest równy efektywności kosztowej, a poziom efektywności alokacyjnej dla każdej jednostki wynosi dokładnie 1. Tone (2002: 1226) wskazuje, że „brzmi to bardzo dziwnie, ponieważ w tym przypadku koszt nakładu wydaje się nie mieć nic wspólnego z efektywnością alokacji.”. Mimo że modele DEA są szczególnie przydatne, gdy mamy do czynienia z wieloma nakładami i wieloma wynikami, to równie dobrze sprawdzają się w przypadkach jednowymiarowych (zob. Pietrzak i Brzezicki 2017).

Po zdefiniowaniu modelu DEA można przejść do określenia założeń badawczych. Postanowiono oszacować efektywność studiów MBA w Polsce. Jednak należy zauważyć, że nie są one wyodrębnione w statystyce publicznej, tylko należą do studiów podyplomowych. Dlatego niezmiernie ciężko uzyskać jakiegokolwiek informacje na ich temat. Po dokonaniu kwerendy dostępnych informacji i danych na temat studiów MBA zdecydowano się uwzględnić ogólny wskaźnik rankingu studiów MBA (Y_1), który w pewnym sensie kwantyfikuje ich jakość i przyjąć wartość za wynik modelu DEA. Wskaźnik rankingowy jest określany przez *Perspektywy* na podstawie siedmiu grup kryteriów, z których każdy stanowi procentowy udział w ogólnym wyniku: preferencje pracodawców (10%), opinia absolwentów (15%), studenci programu (15%), kadra dydaktyczna programu (15%), merytoryczne cechy programu (20%), wsparcie procesu kształcenia (5%) oraz ranga i prestiż programu (20%). Przyjęcie wskaźnika rankingowego studiów MBA jest uzasadnione merytorycznie, gdyż studia tego typu w Polsce są prowadzone jako szczególnie forma studiów podyplomowych, które z założenia powinny przekazywać wiedzę praktyczną dla kursantów i stanowić odpowiedź na zapotrzebowanie rynku w zakresie uzupełnienia kwalifikacji zawodowych pracowników. Dlatego wynik rankingowy MBA stanowi informację od odbiorców zewnętrznych (spoza danej uczelni) na oferty edukacyjne proponowane przez poszczególne szkoły wyższe. Wynik ten powinien być impulsem dla organizatorów studiów MBA zarówno do podwyższania jakości kształcenia, jak i narzędziem uwzględniania potrzeb społeczno-gospodarczych w zakresie tej szczególnej formy edukacyjnej. Przyjęto

następnie liczbę godzin danego kursu MBA za nakład (X_1), a cenę studiów w PLN za koszt (C_1). Cena studiów stanowi całość kwoty w PLN, jaką musi zapłaci kursant za cały kurs MBA, składa się na to m.in. czesne i opłaty aplikacyjne. Dane do obliczeń zaczerpnięto z *Rankingu MBA Perspektywy 2018* w zakresie ogólnego wskaźnika rankingowego. Natomiast koszt studiów MBA oraz ich okres trwania pozyskano z Ogólnopolskiej Bazy Programów MBA prowadzonej przez serwis MBAPortal.pl oraz stron internetowych organizatorów poszczególnych kursów MBA – dane dotyczą 2018 roku. Podstawowe statystyki przyjętych zmiennych przedstawiono w tabeli 1.

Tabela 1. Statystyki opisowe zmiennych

	Liczba godzin kursu MBA (X_1)	Koszt studiów MBA (C_1)	Wskaźnik Rankingowy Perspektyw (Y_1)
Min.	300	13600	45.6
Śred.	496	36020	72.7
Maks.	784	71026	100.0
Od. std.	122	17264	14.6

Źródło: opracowanie własne.

Do badania empirycznego przyjęto 28 programów studiów MBA (tabela 2) z 31 uwzględnionych w Rankingu MBA (*Perspektywy 2018*).

Tabela 2. Badane programy MBA według *Perspektywy 2018*

DMU	Program	Organizator	Miasto	Ranking Perspektyw
S1	Canadian Executive MBA (CEMBA)	Szkoła Główna Handlowa	Warszawa	100.0
S2	emba@uw – Executive MBA na UW	Międzynarodowe Centrum Zarządzania, Wydział Zarządzania UW	Warszawa	99.8
S3	Executive MBA	Akademia Leona Koźmińskiego	Warszawa	99.5
S4	Executive MBA Poznań–Atlanta	Uniwersytet Ekonomiczny w Poznaniu	Poznań	88.4
S5	Executive MBA	Krakowska Szkoła Biznesu Uniwersytetu Ekonomicznego w Krakowie	Kraków	86.5
S6	Executive MBA Katalyst	Szkoła Biznesu Politechniki Warszawskiej	Warszawa	86.3

DMU	Program	Organizator	Miasto	Ranking Perspektyw
S7	MBA-SGH	Szkoła Główna Handlowa	Warszawa	83.4
S8	European Multicultural Integrated Management Program, International MBA	Krakowska Szkoła Biznesu Uniwersytetu Ekonomicznego w Krakowie	Kraków	81.3
S9	Aalto Executive MBA w Poznaniu	Wyższa Szkoła Bankowa w Poznaniu	Poznań	78.9
S10	Polsko-Amerykański Program Studiów MBA	Polsko-Amerykańskie Centrum Zarządzania, Wydział Zarządzania UŁ	Łódź	78.3
S11	International MBA in Strategy, Programme and Project Management	Politechnika Gdańska, Wydział Zarządzania i Ekonomii	Gdańsk	77.8
S12	Franklin University MBA-(FUMBA)	Wyższa Szkoła Bankowa we Wrocławiu	Wrocław	76.4
S13	Koźmiński MBA z semestrem specjalistycznym	Akademia Leona Koźmińskiego	Warszawa	76.2
S14	International MBA	Wyższa Szkoła Handlowa we Wrocławiu	Wrocław	73.9
S15	MBA – Innovation and Data Analysis	Instytut Podstaw Informatyki Polskiej Akademii Nauk	Warszawa	71.4
S16	Executive MBA	Akademia WSB	Dąbrowa Górnicza	68.8
S17	Magisterskie Studia Menedżerskie Executive MBA	Uniwersytet Ekonomiczny we Wrocławiu, Wydział Zarządzania, Informatyki i Finansów	Wrocław	67.1
S18	MBA KSB + Master	Krakowska Szkoła Biznesu Uniwersytetu Ekonomicznego w Krakowie	Kraków	66.4
S19	Executive MBA	Wyższa Szkoła Handlowa we Wrocławiu	Wrocław	64.0
S20	„Polsko-Amerykańska Szkoła Biznesu” Executive MBA	Politechnika Wrocławska, Wydział Informatyki i Zarządzania	Wrocław	62.1
S21	MBA Zarządzanie w Biznesie Międzynarodowym	Wyższa Szkoła Bankowa w Poznaniu, Wydział Zamiejscowy w Chorzowie	Chorzów	59.6
S22	Master of Business Administration	Wyższa Szkoła Bankowa we Wrocławiu	Wrocław	59.0
S23	Master of Business Administration	Wyższa Szkoła Bankowa w Toruniu	Toruń	58.9

DMU	Program	Organizator	Miasto	Ranking Perspektyw
S24	Polsko-Amerykańska Szkoła Biznesu, Program Executive MBA (CCSU)	Politechnika Krakowska	Kraków	58.7
S25	Master of Business Administration	Wyższa Szkoła Bankowa w Poznaniu	Poznań	58.2
S26	Master of Business Administration	Wyższa Szkoła Bankowa w Toruniu, Wydział Finansów i Zarządzania w Bydgoszczy	Bydgoszcz	56.4
S27	MBA@SAN	Społeczna Akademia Nauk	Łódź	52.3
S28	Executive MBA	Instytut Nauk Ekonomicznych Polskiej Akademii Nauk	Warszawa	45.6

Uwaga: Nazwa programu i określenie organizatora programu MBA jest wzięty bezpośrednio z rankingu *Perspektyw* (2018). Programy MBA są uszeregowane wg. wskaźnika rankingowego *Perspektyw* (2018).

Źródło: opracowanie własne na podstawie *Perspektywy* (2018).

Z uwagi na wykorzystywaną metodę DEA, która jest niezwykle wrażliwa na obserwacje odstające, z badania wyłączono 3 programy, których wartość sytuowała się poniżej 10 tysięcy złotych. Każdemu programowi MBA przypisano zmienne S_n , które ułatwią prezentację wyników badania empirycznego.


Wyniki badań

Badanie empiryczne zostało podzielone na trzy następujące po sobie etapy, z których pierwszym było oszacowanie efektywności programów MBA (wykres 1), drugim projekcja redukcji nakładów w celu uzyskania 100% efektywności (tabela 3), a trzecim wskazanie wzorcowych (wzorce benchmarkingowe) programów MBA (tabela 4).

Średnia efektywność programów MBA (wykres 1) wynosi 0.68, a odchylenie standardowe 0.24. Najniższą wartość wskaźnika efektywności uzyskał S22 (0.31). Natomiast sześć programów MBA uzyskało 100% efektywności. Były to: S5, S15, S3, S20, S1 i S24. Jednak w przypadku S4 niewiele brakowało, aby uzyskać status jednostki w pełni efektywnej, gdyż wskaźnik wynosił aż 0.99. Warto zaznaczyć, że dziesięć programów MBA nie przekroczyło progu 0.5 efektywności. Oszacowane wskaźniki efektywności można pogrupować w pary, gdyż niektóre jednostki uzyskały bardzo podobne wartości. Pierwszą parą jest S17 i S27 z wynikiem 0.33, drugą S21 i S26 ze wskaźnikiem 0.49. Trzecią grupę stanowi S8 i S16 (0.70), zaś czwartą

jednostki, które uzyskały pełną 100% efektywność. Powyższe wyniki przedstawiają bezpośrednich konkurentów programów MBA.

Wykres 1. Wyniki efektywności studiów MBA w 2018 roku (NewCost-V)



Źródło: opracowanie własne.

Graficzna prezentacja rankingu efektywności ukazała, że w badanej próbie między wybranymi programami MBA występuje znaczne zróżnicowanie („tąpnięcia”) w stosunku do jednostki przed nią i po niej, które wskazuje na istnienie podgrup. Powyższe zależności zauważono między S27 i S18, następnie S19 i S6, kolejno S25 i S11, S28 i S10, S10 i S2 oraz S2 i S4.

Zgodnie z założeniem badawczym drugim etapem analizy była projekcja redukcji nakładów, które pozwolą poszczególnym nieefektywnym jednostkom uzyskać pełną 100% efektywność. Wyniki przedstawiono w tabeli 3.

Tabela 3. Projekcja redukcji nakładów dla nieefektywnych jednostek (w %)

DMU	Liczba godzin kursu MBA (X_i)	Koszt studiów MBA (C_i)
S1	0.00	0.00
S2	-10.79	-10.79
S3	0.00	0.00
S4	-1.21	-1.21
S5	0.00	0.00
S6	-53.76	-53.76
S7	-47.62	-47.62
S8	-29.39	-29.39
S9	-29.89	-29.89
S10	-19.96	-19.96
S11	-36.18	-36.18
S12	-35.08	-35.08
S13	-31.26	-31.26
S14	-51.44	-51.44
S15	0.00	0.00
S16	-29.14	-29.14
S17	-66.49	-66.49
S18	-60.28	-60.28
S19	-59.04	-59.04
S20	0.00	0.00
S21	-50.48	-50.48
S22	-68.93	-68.93
S23	-50.04	-50.04
S24	0.00	0.00
S25	-45.30	-45.30
S26	-50.27	-50.27
S27	-66.12	-66.12
S28	-27.50	-27.50
Min.	-0.69	-0.69
Śred.	-0.33	-0.33
Maks.	0.00	0.00
Od. Std.	0.24	0.24

Źródło: opracowanie własne.

Z uwagi na to, że wykorzystano jeden zestaw nakładów ($X_1 * C_1$) składający się z wartości liczbowej (całkowitej liczby godzin programów MBA) i wartości pieniężnej (całkowitego kosztu studiów MBA), uzyskane poziomy redukcji obu nakładów są tożsame. Średnia wartość redukcji nakładów wynosi 33%. Natomiast odchylenie standardowe jest równe 0,24. Największy poziom redukcji nakładów oscyluje wokół aż 69% (S22). Najniższy poziom redukcji nakładów (poza jednostkami w 100% efektywnymi, których poziom redukcji nakładów wynosi 0) występuje w S4 – 1.21%.

Jedną z możliwości analitycznych modeli DEA jest wskazanie jednostek wzorcowych dla nieefektywnych obiektów, co zostało wykonane i przedstawione w tabeli 4.

Tabela 4. Częstotliwość występowania jednostek referencyjnych w zestawie benchmarkingu dla innych programów MBA

Lp.	Jednostki referencyjne	Częstotliwość w stosunku do innych nieefektywnych DMU
1.	S1	1
2.	S3	2
3.	S5	10
4.	S15	13
5.	S20	7
6.	S24	7

Źródło: opracowanie własne.

Z dokonanego badania wynika, że sześć programów MBA było jednostkami referencyjnymi (wzorcowymi) dla nieefektywnych podmiotów. Prym pod tym względem wiedzie S15, która była jednostką referencyjną aż dla 13 nieefektywnych programów MBA. Na drugim miejscu uplasowała się S5 dla 10 studiów. Natomiast *ex aequo* na trzecim miejscu znajdują się S20 i S24, które były wzorcami benchmarkowymi dla 7 nieefektywnych programów MBA. Ranking zamykają S3 i S1, które zajmowały odpowiednio przedostatnie i ostatnie miejsce.

Podsumowanie

W artykule dokonano pilotażowego oszacowania efektywności studiów MBA w Polsce za pomocą „alokacyjnego” modelu *New Cost* należącego do metody DEA. Należy w tym miejscu podkreślić, że otrzymane w niniejszym badaniu wyniki i określone na ich podstawie wnioski mają charakter względny, gdyż dotyczą sytuacji, w której przyjęto szczególne założenia badawcze zarówno w ramach metody DEA, jak i definicji nakładów i wyników. Dlatego nie należy ich przyjmować bezwzględnie, a jedynie

jako narzędzie wspomagające dla kadry zarządczej poszczególnymi studiami MBA w Polsce. Niemniej jednak wyniki badania wskazują na nieefektywność programów MBA, gdyż średni wskaźnik wynosił zaledwie 0.68. Tylko sześć analizowanych jednostek okazało się w pełni efektywnych. Niepokojący jest fakt, że aż dziesięć programów MBA nie przekroczyło progu 0.5 efektywności. Świadczyć to może o zbyt wysokim koszcie kształcenia w stosunku do jakości edukacji wyrażonej w postaci wyniku rankingu *Perspektyw*. Średni poziom redukcji nakładów wynosi 0.33. Sześć programów MBA okazało się jednostkami wzorcowymi dla nieefektywnych studiów menedżerskich.

Przyszłe kierunki badań szkolnictwa wyższego w zakresie działalności dydaktycznej, ale również naukowo-badawczej powinny uwzględniać wszystkie wymiary efektywności, tj. całkowitej (ekonomicznej), technicznej i alokacyjnej. Wymaga to jednak zgromadzenia odpowiednich danych dotyczących szkolnictwa wyższego, co nie jest zadaniem prostym. Całościowa ocena efektywności działalności dydaktycznej pozwoliłaby uzyskać kompleksową informację zarządczą, która jest niezbędna do kreowania racjonalnej polityki edukacyjnej.

Literatura

- Blackburn, V., Brennan, S. i Ruggiero, J. (2014). *Nonparametric Estimation of Educational Production and Costs Using Data Envelopment Analysis*. New York: Springer.
- Brzezicki, Ł. (2016). Efektywność procesu kształcenia w wyższych szkołach zawodowych w 2012 roku. *Folia Oeconomica*. 4(323): 53–66.
- Brzezicki, Ł. (2018). Zestawienie badań efektywności i produktywności polskiego szkolnictwa wyższego prowadzonych za pomocą metody DEA i indeksu Malmquista w latach 2005–2018. Wersja 4. https://www.researchgate.net/profile/Lukasz_Brzezicki [14.09.2018].
- Brzezicki, Ł. i Wolszczak-Derlacz, J. (2015). Ocena efektywności działalności dydaktycznej publicznych szkół wyższych w Polsce wraz z analizą czynników ją determinujących. *Acta Universitatis Nicolai Copernici. Oeconomia*. 46(1): 123–139.
- Brzezicki, Ł. i Pietrzak, P. (2018). Efektywność i skuteczność studiów doktoranckich w publicznym szkolnictwie wyższym w Polsce. *Gospodarka narodowa*. 2(294): 129–159.
- Brzezicki, Ł. i Prędko, A. (2018). Zastosowanie metod DEA, SFA oraz StoNED do pomiaru efektywności publicznych szkół wyższych. *Wiadomości Statystyczne*. 5(684): 5–24.
- Chodakowska, E. (2015). An Example of Network DEA – Assessment of Operating Efficiency of Universities. *Metody ilościowe w badaniach ekonomicznych*. 16(1): 75–84.
- Coelli, T., Rao, D.S.P., O'Donnell, C.J. i Battese, G.E. (2005). *An Introduction to Efficiency and Productivity Analysis* (2nd edition). New York: Springer.
- Colbert, A., Levary, R.R. i Shaner, M.C. (2000). Determining the relative efficiency of MBA programs using DEA. *European Journal of Operational Research*. 125: 656–669.

- Cooper, W.W., Seiford, L.M. i Tone, K. (2007). *Data Envelopment Analysis: A Comprehensive Text with Models, Applications, References and DEA-Solver Software* (2nd edition). New York: Springer.
- Ćwiąkała-Małys, A. (2010). *Pomiar efektywności procesu kształcenia w publicznym szkolnictwie akademickim*. Wrocław: Wydawnictwo Uniwersytetu Wrocławskiego.
- Debreu, G. (1951). The Coefficient of Resource Utilization. *Econometrica*. 19: 273–292.
- Domagała, A. (2009). *Zastosowanie metody Data Envelopment Analysis do badania efektywności europejskich giełd papierów wartościowych*. Rozprawa doktorska. Poznań: Uniwersytet Ekonomiczny w Poznaniu.
- Färe, R., Grosskopf, S. i Lovell, C.A.K. (1985). *The Measurement of Efficiency of Production*. Boston: Kluwer Nijhoff.
- Farrell, M.J. (1957). The measurement of productive efficiency. *Journal of the Royal Statistical Society, Series A*. 120: 253–290.
- Fisher, D.M., Kiang, M. i Fisher S.A. (2007). A Value-Added Approach to Selecting the Best Master of Business Administration (MBA) Program. *Journal of Education for Business*. 83(2): 72–76.
- Fu, T.-T. i Huang, M.-Y. (2009). Performance Ranking and Management Efficiency in Colleges of Business: A Study at the Department Level in Taiwanese Universities. W: J.-D. Lee i A. Heshmati (red.), *Productivity, Efficiency, and Economic Growth in the Asia-Pacific Region* (197–215). Heidelberg: Physica-Verlag.
- Hsu, M.K., James, M.L. i Chao G.H. (2009). An Efficiency Comparison of MBA Programs: Top 10 Versus Non-Top 10. *Journal of Education for Business*. 84(5): 269–274.
- Izadi, H., Johnes, G., Oskrochi, R. i Crouchley, R. (2002). Stochastic frontier estimation of a CES cost function: The case of higher education in Britain. *Economics of Education Review*. 21(1): 63–71.
- Jaska, P. i Swamy, V.K. (2013). Efficiency Rankings of MBA Programs in Indian Top Public Colleges. *Journal of Modern Accounting and Auditing*. 9(9): 1275–1279.
- Johnes, J. (2006). Data envelopment analysis and its application to the measurement of efficiency in higher education. *Economics of Education Review*. 25 (3): 273–288.
- Johnes, G. i Ruggiero, J. (2016). Revenue efficiency in higher education institutions under imperfect competition. *Public Policy and Administration*. 32(4): 282–295.
- Kisielewska, M. (2008). Pojęcie efektywności w metodach analizy granicznej. *Studia i Prace WNEiZ US*. 1: 189–198.
- Kulshreshtha, P. i Nayak, T.K. (2015). Efficiency of Higher Technical Educational Institutions in India. *Archive of Business Research*. 3(1): 94–122.
- MNiSW (2017). Odpowiedź Ministerstwa Nauki i Szkolnictwa wyższego (DSW.WNP.1700.1.2017.1) na oświadczenie złożone przez senatora Marka Rockiego podczas 34. posiedzenia Senatu RP w dniu 1 lutego 2017 r. (nr BPS/043-34-803/17), w sprawie zdefiniowania pojęcia „studia Master of Business Administration (MBA)”. <https://www.>

- senat.gov.pl/download/gfx/senat/pl/senatoswiadczenia/782/09_034_803_1_odp.pdf [14.09.2018].
- Nazarko, J., Komuda, M., Kuźmich, K., Szubzda, E. i Urban J. (2008). Metoda DEA w badaniu efektywności instytucji sektora publicznego na przykładzie szkół wyższych. *Badania Operacyjne i Decyzje*. 4: 89–105.
- Nazarko, J. i Šaparauskas, J. (2014). Application of DEA method in efficiency evaluation of public higher education institutions. *Technological and Economic Development of Economy*. 20(1): 25–44.
- Perspektywy. (2018). Ranking MBA. <http://mba.perspektywy.pl/2018/najlepsze-programy-mba-w-polsce-2018> [14.09.2018].
- Perek, A. (2014). Wykorzystanie metody DEA do oceny banków spółdzielczych w Polsce. *Economics and Management*. 3: 222–235.
- Pietrzak, P. i Brzezicki, Ł. (2017). Wykorzystanie sieciowego modelu DEA do pomiaru efektywności wydziałów Politechniki Warszawskiej. *Edukacja*. 3(142): 83–93.
- Ray, S.C. i Jeon, Y. (2008). Reputation and efficiency: A non-parametric assessment of America's top-rated MBA programs. *European Journal of Operational Research*. 189: 245–268.
- Robst, J. (2001). Cost Efficiency in Public Higher Education Institutions. *The Journal of Higher Education*. 72(6): 730–750.
- Rusielik, R. (2010). Zastosowanie metody DEA do porównania procesów dydaktycznych w szkołach wyższych. *Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu*. 113: 779–795.
- Sav, G.T. (2012). Stochastic Cost Frontier and Inefficiency Estimates of Public and Private Universities: Does Government Matter? *International Advances in Economic Research*. 18: 187–198.
- Siwińska-Gorzelać, J. (2010). Uwagi dotyczące finansowania szkolnictwa wyższego. W: J. Wilkin (red.), *Reformowanie systemu szkolnictwa wyższego w Polsce – uwarunkowania ekonomiczno-finansowe i prawne* (106–108). Warszawa: Oficyna Wydawnicza Politechniki Warszawskiej.
- Świtłyk, M. (2012). Efektywność techniczna publicznych uczelni w latach 2001–2010. *Ekonometria*. 4(38): 320–342.
- Tone, K. i Tsutsui, M. (2007). Decomposition of cost efficiency and its application to Japanese-US electric utility comparisons. *Socio-Economic Planning Sciences*. 41(2): 91–106.
- Tone, K. (2002). A strange case of the cost and allocative efficiencies in DEA. *Journal of the Operational Research Society*. 53: 1225–1231.
- Ustawa z dnia 20 lipca 2018 r. Prawo o szkolnictwie wyższym i nauce, Dz.U. 2018 poz. 1668.
- Wang, W.-K. i Huang, H.-Ch. (2004). Measuring the Relative Efficiency of European MBA Programs: A Comparative analysis of DEA, SBM, and FDH Model, <http://gebr.nccu.edu.tw/proceedings/APDSI/2004/pdf/023.pdf> [14.09.2018].

- Warning, S. (2004). Performance Differences in German Higher Education: Empirical Analysis of Strategic Groups. *Review of Industrial Organization*. 24: 393–408.
- Wolszczak-Derlacz, J. (2013). *Efektywność naukowa, dydaktyczna i wdrożeniowa publicznych szkół wyższych w Polsce – analiza nieparametryczna*. Gdańsk: Wydawnictwo Politechniki Gdańskiej.

Efficiency of the Master of Business Administration (MBA) in Poland

ABSTRACT: The article estimates the efficiency of 28 MBA programs in Poland using the “allocative” New Cost model (Tone, 2002) belonging to the non-parametric DEA method. The number of hours of the MBA program and cost was assumed as input, and the general ranking index of the MBA studies in 2018 developed by *Perspektywy* as the output. The obtained results show the average efficiency of the MBA studies amounting to 68%, only six programs were fully efficiency (100%). The average value of input reduction oscillates around 33%. Six MBA programs were reference for inefficient units.

KEYWORDS: higher education, efficiency, DEA, cost, MBA

CYTOWANIE: Brzezicki, Ł. (2018). Efektywność studiów Master of Business Administration (MBA) w Polsce. *Nauka i Szkolnictwo Wyższe*. 2(52): 131–146. DOI: 10.14746/nisw.2018.2.4

ŁUKASZ BRZEZICKI – od 2016 roku doktor nauk ekonomicznych. Pracownik Urzędu Statystycznego w Gdańsku. Autor wielu publikacji poświęconych efektywności, produktywności i skuteczności szkolnictwa wyższego. Obecnie zajmuje się problematyką efektywności oświaty i szkolnictwa wyższego. E-mail: brzezicki.lukasz@wp.pl.

Joanna Wolszczak-Derlacz

Efektywność szkół wyższych w Polsce na tle uczelni europejskich – analiza dla dziewiętnastu krajów

STRESZCZENIE: W artykule przeprowadzono analizę empiryczną efektywności szkół wyższych wraz z estymacją determinujących ją czynników. Próba badawcza składa się z uczelni z 19 krajów europejskich i obejmuje dane dla lat 2011–2014. Na podstawie nieparametrycznej metody DEA oszacowano wskaźniki efektywności, gdzie za nakłady przyjęto: wartość przychodów i liczbę nauczycieli akademickich. W wynikach działalności uczelni ujęto liczbę absolwentów oraz liczbę publikacji. Dodatkowo zbadano relację pomiędzy wybranymi zmiennymi a wskaźnikami efektywności. Rezultaty wskazują, że uczelnie większe i starsze są bardziej efektywne. Porównanie uczelni o tej samej wielkości i roku założenia pokazało, że te z nich, które mają większy odsetek pracowników niebędących nauczycielami akademickim i niższy udział przychodów zewnętrznych w budżecie, charakteryzują się niższą efektywnością.

SŁOWA KLUCZOWE: DEA, efektywność, determinanty efektywności, szkoły wyższe, ETER

Wstęp

Porównanie działalności szkół wyższych w Polsce do uczelni z innych krajów nie napawa optymizmem. Obraz, jaki się wyłania z rankingów światowych, jest mało zadawalający. Przykładowo według tzw. rankingu szanghajskiego¹, który klasyfikuje 500 najlepszych uczelni z całego świata, w 2018 roku na miejsce w zestawieniu zasłużyły tylko dwie polskie uczelnie: Uniwersytet Warszawski, który uplasował się w czwartej setce, i sklasyfikowany w piątej Uniwersytet Jagielloński. Podobnie rzecz ma się według rankingu Times Higher Education, gdzie wśród najlepszych 1000 uczelni znajduje się 9 z Polski, w tym sześć w przedziale miejsc 800–1000².

Mimo krytyki podnoszonej przez niektórych naukowców odnośnie metodyki tworzenia powyższych rankingów (zob. np. Daraio i in. 2015b) stanowią one niewątpliwie

¹ <http://www.shanghairanking.com/> [15.07.2018].

² https://www.timeshighereducation.com/world-university-rankings/2018/world-ranking#!/page/0/length/-1/sort_by/rank/sort_order/asc/cols/stats [15.07.2018].

opiniotwórczy punkt odniesienia dla różnych interesariuszy (studentów i ich rodziców, zarządzających uczelniami itd.). Rankingi te dotyczą różnych aspektów związanych z funkcjonowaniem szkół wyższych, nie można ich jednak utożsamiać z efektywnością działalności uczelni, ta bowiem dotyczy sprawności uzyskiwania wyników przy danych nakładach (finansowych, osobowych). Jak piszą Daraio i in. (2015b), rankingi abstrahują od relacji wyniki-nakłady, która jest istotą pomiaru efektywności. Efektywność (techniczna) szkół wyższych w najbardziej ogólnym znaczeniu jest rozumiana jako stosunek wyników działalności uczelni (takich jak absolwenci czy publikacje) do nakładów (liczba osób zatrudnionych, przychody). W literaturze przedmiotu spotykamy różne metody i narzędzia służące do pomiaru efektywności szkół wyższych (przegląd różnych metod i ich zastosowanie, zob. np. Johnes 2004). W ostatnich latach na znaczeniu zyskały metody nieparametryczne, których niewątpliwą zaletą jest brak sztywnych założeń co do kształtu relacji pomiędzy wynikami a nakładami.

W poniższym artykule zostanie wykorzystana nieparametryczna metoda *data envelopment analysis* (DEA) do oceny efektywności szkół wyższych w Polsce i wybranych 18 krajach europejskich. W badaniu wykorzystane zostaną dane z bazy ETER: European Tertiary Education Register, która podaje wybrane statystyki na poziomie pojedynczych szkół wyższych. W pierwszym kroku analizy zostaną oszacowane wskaźniki efektywności dla próby uczelni z poszczególnych krajów, natomiast w kolejnym przeprowadzona zostanie analiza mająca za zadanie ocenić zależność pomiędzy wybranymi determinantami efektywności a wskaźnikami efektywności.

Przeprowadzona analiza pozwoli odpowiedzieć na następujące pytania badawcze:

- jaki jest poziom efektywności (technicznej) uczelni w Polsce na tle uczelni z innych krajów europejskich?
- jakie są zmiany efektywności w czasie?
- jakie są podstawowe determinanty efektywności szkół wyższych?

Niewątpliwą wartością dodaną przeprowadzonej analizy w niniejszym artykule jest zakres przestrzenny badań: obejmą one ponad 400 uczelni z 19 krajów europejskich dla lat 2011–2014. Wedle wiedzy autorki jest to jedno z najobszerniejszych badań w tej tematyce. Dzięki takiemu podejściu możliwym będzie wyznaczenie generalnych trendów i zależności, które mogą wskazać na kierunki zmian niezbędne w celu podniesienia efektywności i produktywności szkół wyższych. Są to zagadnienia niezwykle ważne z punktu widzenia polityki prowadzonej przez państwo w stosunku do uczelni wyższych.

Artykuł składa się z czterech części. W części pierwszej przedstawiono zwięzły przegląd badań nad efektywnością szkół wyższych wykorzystujących metody nieparametryczne, w części drugiej ukazano podstawowe statystyki dla szkół wyższych w Polsce na tle uczelni europejskich z wykorzystaniem danych z bazy ETER. W kolejnej

części zamieszczono wyniki badań empirycznych: obliczono wskaźniki efektywności oraz przeprowadzono analizę potencjalnych determinant uprzednio uzyskaniach wskaźników. Ostatnia część poświęcona została podsumowaniu oraz dyskusji wyników.

1. Wykorzystanie metod nieparametrycznych w badaniach nad szkolnictwem wyższym – przegląd literatury

Jak już zauważono wcześniej, wykorzystanie metod nieparametrycznych w badaniach efektywności sektora edukacji jest w ostatnich latach o wiele częstsze. Przykładowo w bazie Scopus do 1990 roku zostało wydanych 23 publikacji wykorzystujących metodę DEA do oceny efektywności jednostek z sektora edukacji, by w latach 1991–2000 było ich już 97, a w okresie 2001–2010 519. Od 2001 do 2017 roku takich publikacji wydano już 1256³.

Jedne z pierwszych zestawień prac wykorzystujących metody nieparametryczne do oceny efektywności jednostek z sektora edukacji zamieszczają Worthington (2001) oraz Johnes (2004). Pierwszy z autorów skupia się na publikacjach z lat 1981–1998, które w tym okresie w głównej mierze odnosiły się do badań nad efektywnością szkół podstawowych i średnich. Wymienia w sumie 27 publikacji, podając przedmiot analizy, wielkość próby badawczej, zestaw nakładów i wyników, metodykę badania oraz główne wyniki. Natomiast Johnes (2004) zamieszcza zestawienie ponad stu badań empirycznych wykorzystujących różne metody, w tym dla ponad 50 badań są to metody nieparametryczne. Podobnie jak we wcześniej przywoływanym przeglądzie literatury przywoływana autorka podaje podmiot i zakres analizy oraz zestaw zastosowanych miar opisujących nakłady i wyniki działalności analizowanych jednostek.

W moich własnych badaniach (Wolszczak-Derlacz 2017) przeprowadziłam przegląd literatury, w której analizy obejmują więcej niż jeden kraj, co jest stosunkowo rzadkim przypadkiem. Wymieniam tam siedemnaście prac, w których wykorzystano metody nieparametryczne.

Rozwój badań z wykorzystaniem metod nieparametrycznych do oceny efektywności i produktywności szkół wyższych jest również widoczny w literaturze krajowej. Zestawienie badań polskiego szkolnictwa wyższego prowadzonych za pomocą metody DEA i indeksu Malmquista w latach 2005–2017 opracował Brzezicki (2018), który wyszczególnia 60 pozycji. Niestety nieliczne z nich zostały opublikowane w obiegu międzynarodowym.

Podstawowe wnioski, jakie wynikają z przywoływanych przeglądów literaturowych oraz zestawień prac wykorzystujących metody nieparametryczne do oceny efektywności i produktywności szkół wyższych, to:

³ Wyszukiwanie dwustopniowe: według terminu „DEA” w polu „Article title, Abstract, Keywords”, a następnie poprzez zawężenie wyników do „education” [30.06.2018].

- nieliniowy (wykładniczy) wzrost liczby publikacji, w których sektor edukacji badany jest za pomocą narzędzi nieparametrycznych;
- różny poziom agregacji badanych podmiotów: sektor szkół wyższych jako całość (np. Agasisti 2011; Wolszczak-Derlacz 2013, rozdział 5), uczelnie (Agasisti i Pohl 2012; Bonaccorsi i in. 2006; Johnes 2006a; Wolszczak-Derlacz 2017), wydziały (Johnes i Johnes 1995; Agasisti i in. 2012), programy nauczania (Colbert i in. 2000), absolwenci (Johnes 2006b);
- w przeważającej części badania są prowadzone dla jednego wybranego kraju – brytyjskie szkoły wyższe (Johnes i Johnes 1995; Johnes 2006b), włoskie (Bonaccorsi i in. 2006; Agasisti i in. 2012), niemieckie (Kempkes i Pohl 2010); czymś rzadziej spotykanym są analizy dla wielu krajów (Daraio i in. 2015; Wolszczak-Derlacz 2017);
- różnorodność modeli nieparametrycznych używanych do oceny efektywności (co skutkuje tym, że różne badania trudno jest bezpośrednio porównywać) oraz rozwój coraz bardziej wyspecjalizowanych metod np. warunkowej metody DEA (Daraio i Simar 2007).

Wszystkie z przywoływanych przeglądów literatury podają zmienne, które zostały wykorzystane jako miary nakładów i wyników działalności jednostek. Na ich podstawie można stworzyć katalog nakładów i wyników działalności szkół wyższych, które są najczęściej stosowane przez badaczy. Do miar nakładów zaliczyć można: liczbę pracowników (nauczycieli akademickich, pracowników niebędących nauczycielami akademickimi, z podziałem na stopnie i stanowiska), liczbę godzin dydaktycznych wykonywanych przez nauczycieli akademickich, zasoby finansowe (wartość przychodów z podziałem na źródła), koszty z podziałem na formy poniesienia, aktywa, warunki lokalowe (np. powierzchnia laboratoriów). Wyniki działalności uczelni mierzone są najczęściej za pomocą miar bibliometrycznych takich jak: liczba publikacji pracowników z afiliacją danej uczelni, wskaźniki cytowań, wskaźniki wpływu, ale także za pomocą liczby nadanych stopni i tytułów naukowych, liczby absolwentów (liczba dyplomów licencjata, inżyniera, magistra), liczby studentów (np. przechodzących na wyższe lata, uzyskujących daną liczbę punktów ECTS), wyniki z testów i egzaminów, np. wyniki z egzaminów kończących studia, oceny na dyplomie, patenty, wzory przemysłowe, liczby i wartość umów z podmiotami zewnętrznymi, wysokości środków finansowych pozyskanych na działalność naukową ze źródeł zewnętrznych, wartości sprzedanych usług badawczych. Natomiast jako wyniki działalności dydaktycznej szkół wyższych do tej pory rzadko spotyka się miary związane ze wskaźnikami zatrudnienia absolwentów czy preferencji pracodawców (Brzezicki i Wolszczak-Derlacz 2015). Należy zauważyć, że większość z wymienionych zmiennych ma wyłącznie charakter miar ilościowych, nie odzwierciedlają one bowiem jakości prowadzonej przez uczelnie działalności dydaktycznej

i naukowej – jest to niewątpliwie ograniczenie dla metod, które wykorzystują je w swoich badaniach empirycznych.

Wydaje się, że wzrost zainteresowania narzędziami nieparametrycznymi w badaniach światowych (w tym DEA) możliwy był dzięki nowym i powszechnie dostępnym programom komputerowym do obliczeń oraz lepszym dostępem do danych na temat sektora szkolnictwa wyższego oraz jednostek w nim funkcjonujących. Dodatkowo zainteresowanie pomiarem efektywności i jej determinant nabrało jeszcze większego znaczenia w okresie kryzysu gospodarczego, w którym doszło do silniejszej presji nakładanej na jednostki publiczne (w tym szkoły wyższe) do racjonalnego wydatkowania środków publicznych oraz ich rozliczalności. Sama metoda DEA zostanie opisana w późniejszej części artykułu.

2. Porównanie szkół wyższych w Polsce na tle krajów europejskich

2.1 Baza ETER

Dane dla poszczególnych uczelni użyte w części empirycznej analizy pochodzą z bazy ETER: European Tertiary Education Register (<https://www.eter-project.com/>) finansowanej przez Komisję Europejską. Jest to pierwsza⁴ ogólnodostępna baza danych, gdzie informacje notowane są na poziomie indywidualnych uczelni w odróżnieniu od statystyk zagregowanych podawanych np. przez OECD, EUA czy przez urzędy statystyczne wybranych państw. Na dzień dzisiejszy dane dotyczą lat 2011/2012–2015/20156 oraz uczelni wyższych z 36 państw europejskich (w 2014 roku notowanych było 2767 uczelni). Utworzenie samej bazy danych oraz zagwarantowanie publicznego dostępu do statystyk na poziomie indywidualnych uczelni (takich jak: liczba studentów, nauczycieli, absolwentów, dane finansowe: przychody, koszty itp.) jest niewątpliwie kamieniem milowym w tworzeniu zintegrowanej bazy danych dla szkół wyższych w Europie. W odróżnieniu od ogólnodostępnych danych bibliometrycznych, takich jak Scopus czy Web of Science, zarówno gromadzenie i dostęp do danych dotyczących zasobów finansowych, jak i osobowych poszczególnych uczelni jest wysoce utrudniony. Dotyczy to zarówno Polski, jak i innych krajów. Problemy ze stworzeniem jednej zharmonizowanej bazy danych na szczeblu europejskim są pochodną tego, że poszczególne kraje różnią się w zakresie publicznego dostępu do danych statystycznych na poziomie indywidualnych uczelni. Przykładowo w Polsce Ministerstwo Nauki i Szkolnictwa Wyższego zaprzestało wydawania informatora statystycznego obejmującego dane dla indywidualnych uczelni (z wyłączeniem

⁴ Komisja Europejska podjęła kilka inicjatyw mających na celu stworzenie europejskiej bazy danych np. projekt Aquameth (Advanced Quantitative Methods for the Evaluation of the Performance of Public Sector Research), w wyniku którego stworzono bazę na poziomie indywidualnych uczelni, ale dostęp do danych mieli tylko członkowie konsorcjum. Kontynuacją był projekt Feasibility Study for Creating a European University Data Collection (EUMIDA), który przerodził się w ETER.

danych finansowych) – *Szkoły Wyższe – dane podstawowe*, co niewątpliwie utrudni prowadzenie badań nad szkołami wyższymi w przyszłości.

Największy mankament bazy ETER to duża ilość brakujących informacji, np. dla niektórych kategorii finansowych więcej niż 50% obserwacji jest niedostępnych, a dane na temat liczby pracowników dostępne są dla 70% uczelni (ETER Final Quality Report 2017: 15–20). Kompletność danych w bazie ETER jest zróżnicowana w zależności od kraju. Przykładowo dla Czarnogóry, Rumunii, Słowenii, Turcji oraz Belgii (części francuskojęzycznej) podana jest tylko lista uczelni bez jakichkolwiek dodatkowych informacji.

Baza ETER (i inicjatywy ją poprzedzające) była już wykorzystywana w badaniach nad szkolnictwem wyższym w Europie, w tym także w badaniach dotyczących różnych aspektów efektywności i produktywności szkół wyższych. Przykładowo Daraio i in. (2015a) przeprowadzili analizę, biorąc pod uwagę 400 uczelni z 16 krajów europejskich dla jednego roku (2008/2009) i potwierdzili, że wielkość uczelni (ekonomia skali) oraz stopień specjalizacji jednostki (ekonomia różnorodności) mają dodatni wpływ na efektywność uczelni dla modelu, który łącznie bierze pod uwagę działalność edukacyjną i naukową. Natomiast dla modelu ograniczonego do działalności naukowej specjalizacja uczelni nie ma wpływu na jej efektywność. Daraio i in. (2015b) przy użyciu tych samych danych podkreślili aspekty zróżnicowania kraju wpływającego na efektywność uczelni. Bolli i in. (2016) badali rolę konkurencyjnego finansowania na poziom efektywności uczelni. W swych badaniach wykorzystali metody parametryczne (translogarytmiczną funkcję produkcji), którą oszacowali na próbie 263 uczelni z 8 krajów europejskich. Wyniki działalności uczelni były mierzone za pomocą liczby publikacji oraz liczby studentów, natomiast wśród nakładów znalazły się: liczba profesorów, liczba innych pracowników naukowych oraz liczba pracowników administracyjnych. Dodatkowo za zmienne zewnętrzne mające wpływ na wskaźnik nieefektywności uznano procent budżetu ze źródeł zewnętrznych (prywatnych i publicznych). Wnioski z badań Bolli i in. (2016) dotyczą wpływu (ujemnego) publicznych środków zewnętrznych pochodzących ze źródeł międzynarodowych na produktywność najlepszych uczelni, ale środki te doprowadzają do wzrostu średniej efektywności uczelni. Uczelnie konkurując o zewnętrzne środki finansowe ze źródeł międzynarodowych, stają się średnio bardziej efektywne, ale nie dotyczy to uczelni najbardziej produktywnych, dla których nakłady poniesione na dodatkowe prace administracyjne (np. związane z aplikowaniem o środki ze źródeł zewnętrznych) nie są wyrównywane przez dostateczny wzrost produktywności uczelni (tzw. efekt administracyjny).

Daraio i Glänzel (2016) podsumowują prace, jakie przeprowadzono na świecie w ostatnich latach na rzecz budowy zintegrowanych systemów dostarczających informacji w zakresie wskaźników R&D, w tym także pochodzących z systemów

szkolnictwa wyższego. Zwracają uwagę na wyzwania, jakie stoją jeszcze przed nami w zakresie integracji danych oraz jakie są perspektywy na przyszłość.

2.2 Statystyki opisowe

Analizie poddano publiczne szkoły wyższe z krajów europejskich działające w sektorze akademickim (nie zawodowym)⁵. Dane pochodzą z przywoływanej już bazy ETER⁶, a okres analizy dotyczy lat: 2011/2012–2014/2015⁷. W celu zapewnienia względnej homogeniczności z analizy zostały wykluczone jednostki specyficzne: szkoły medyczne, artystyczne i wojskowe, akademie ekonomiczne, akademie wychowania fizycznego itd. Przykładowo dla Polski w próbie mamy 36 jednostek, są to uczelnie, które podlegają pod MNiSW (uniwersytety i politechniki).

Ostateczna próba badawcza została w dużej mierze wyznaczona przez dostępność kompletnych danych potrzebnych do wyznaczenia wskaźników efektywności (dane na temat nakładów i wyników na poziomie indywidualnych uczelni). W sumie w zależności od roku analizy notowanych jest od 465 uczelni w 2011/2012 roku do 426 uczelni w 2014/2015 roku z 19 państw europejskich.

W Tabeli 1 przedstawiono podstawowe charakterystyki dla analizowanych uczelni dla roku 2014, są one wyrażone jako średnie krajowe. W pierwszej kolumnie pokazano dane na temat zestandaryzowanej liczby publikacji⁸

⁵ Prywatne szkoły wyższe znacznie różnią się od publicznych zarówno w zakresie źródeł przychodów oraz samego nastawienia na wyniki działalności naukowej i dydaktycznej, porównanie ich efektywności do szkół publicznych wydaje się więc nie spełniać warunku względnej homogeniczności jednostek. Z tego samego powodu z analizy zostały wykluczone szkoły wyższe nastawione głównie na kształcenie zawodowe takie jak: Fachhochschule w Niemczech, Wyższe Szkoły Zawodowe w Polsce itd. W odniesieniu do Wielkiej Brytanii do analizy zostały wzięte instytucje prywatne zależne od państwa (ang. *government-dependent institutions*).

⁶ Dane zostały ściągnięte przez portal OrgReg (Register of Public-Sector Organizations), który zapewnia dostęp do danych RISIS-ETER będącą rozbudowaną wersją bazy ETER o dodatkowe pozycje takie jak liczba publikacji z afiliacją danej uczelni – <https://risis-eter.orgreg.joanneum.at/about/intro> [9.04.2018].

⁷ W oryginalnej bazie ETER dostępne są dane także dla roku 2015/2016, ale dla tego roku brak jest informacji w zakresie liczby publikacji pochodzących z bazy RISIS-ETER.

⁸ Liczba publikacji pochodzi z bazy Leiden Ranking (zarządzanej przez CWTS, University of Leiden) i dotyczy publikacji napisanych w języku angielskim notowanych w Web of Science (Science Citation Index Expanded, Social Sciences Citation Index oraz Arts & Humanities Citation Index). Baza ograniczona jest do artykułów i recenzji (*review*), gdzie co najmniej jeden z autorów podaje afiliację danej uczelni. W próbie brane są tylko uczelnie z minimum 50 publikacjami rocznie. Do obliczenia liczby publikacji zastosowano metodę cząstkową tzn. artykuł, który napisany jest przez jednego autora posiadającego jedną afiliację, uzyskuje 1 punkt, dla artykułu autorstwa dwóch autorów pochodzących z różnych instytucji każda z uczelni otrzymuje wartość 0.5, jeżeli artykuł jest napisany przez trzech współautorów z trzech różnych uczelni, otrzymują one 0.333 punktu itd. Więcej na temat zbierania danych oraz metodyki innych notowanych wskaźników bibliometrycznych m.in. w: Lepori i in. (2017) oraz w materiałach na stronie: <http://leidenranking.com/information/indicators> [9.04.2018].

przypadającej na jednego nauczyciela akademickiego – może to być cząstkowa miara produktywności uczelni. Wartości najwyższe odnotowano dla uniwersytetów z Holandii, gdzie średnio na jednego nauczyciela akademickiego przypada 0.75 publikacji; Polska zajmuje szóste miejsce od dołu z wartością 0.11. W kolejnej kolumnie przedstawiono wskaźnik publikacji w przeliczeniu na wartość 1 mln euro przychodów uczelni⁹. Pozycja Polski ulega teraz poprawie, znajduje się na siódmym miejscu (wraz z Finlandią) z wartością 1.97 publikacji na 1 mln euro przychodu, co jest wynikiem wyższym od średniej dla analizowanej grupy krajów. Przesunięcie uczelni polskich w rankingu, gdy liczba publikacji jest przeliczona na wartość przychodu, jest niewątpliwie związane z relatywnie niskim finansowaniem uczelni w Polsce. Potwierdzone to zostaje w kolumnie 4, gdzie pokazano wartość przychodów przypadającego na jednego nauczyciela akademickiego. W Polsce wartość ta wynosi 56 000 euro rocznie i wraz z Chorwacją i Litwą są to najniższe wartości wśród analizowanych krajów, pięciokrotnie niższe niż wartości z Liechtensteinu, Holandii czy Wielkiej Brytanii. W kolejnej kolumnie pokazano relację liczby absolwentów do liczby nauczycieli akademickich (może to być częściowa miara produktywności dydaktycznej i/lub obciążenia dydaktycznego). Najwyższą wartość zanotowano we Włoszech, gdzie przypadało średnio 22 studentów na jednego nauczyciela akademickiego. Natomiast w Szwajcarii i Belgii średnio na jednego nauczyciela akademickiego przypadało tylko sześciu studentów, w Polsce wartość ta wyniosła 16.8. W kolejnej kolumnie zaprezentowano liczbę pracowników administracyjnych przypadających na nauczyciela akademickiego i była ona najniższa (poniżej 0.5) dla uczelni z Belgii i Szwajcarii. Powyżej jednego pracownika administracyjnego na nauczyciela akademickiego zanotowano na Węgrzech, Litwie, Wielkiej Brytanii i na Cyprze. W Polsce wartość ta wyniosła 0.83. W ostatniej kolumnie pokazano liczbę doktorantów przypadających na całkowitą liczbę studentów (na poziomach kształcenia ISCED 5–7). Przykładowo Bonaccorsi i Daraio (2007) uznają ten wskaźnik za miarę unaukowienia instytucji: im wyższy udział doktorantów w całej populacji studentów, tym większe zaangażowanie uczelni w badania naukowe. Najwyższą wartość zanotowano w Szwajcarii gdzie na 100 studentów przypada 18 doktorantów, w Polsce natomiast wskaźnik ten wyniósł tylko 3.

Warto zauważyć, że statystyki przedstawione w Tabeli 1 nie obrazują zróżnicowania uczelni wewnątrz danych państw. Na Rysunku 1 przedstawiono wykres ramka-wąsy, który ilustruje zróżnicowanie przychodów na nauczyciela akademickiego w 2014 roku pomiędzy krajami, ale także wewnątrz danych państw. Wartość środkowa wykresu oznacza medianę, a odpowiednie wąsy – minimum i maksimum wartości przychodów na nauczyciela akademickiego. Widać znaczne

⁹ Jako kurs wymiany przyjęto PPP.

zróznicowanie wskaźnika pomiędzy uczelniami z dużych krajów takich jak Niemcy, ale także w państwach, gdzie notowana jest znacznie mniejsza liczba uczelni np. Holandia czy Węgry.


Tabela 1. Podstawowe charakterystyki dla analizowanych szkół wyższych, 2014 rok (średnia krajowa)

Kraj	Liczba uczelni	Publikacje na nauczyciela akadem.	Publikacje na 1 mln euro przychodu	Przychód roczny na nauczyciela akadem. [w euro]	Liczba studentów na nauczyciela akadem.	Liczba pracowników administracji na nauczyciela akadem.	Liczba doktorantów do liczby studentów
BE	5	0.37	3.04	123 136	6.36	0.46	0.10
CH	12	0.32	1.38	226 797	6.01	0.47	0.18
CY	2	0.42	2.24	184 754	12.35	1.01	0.09
DE	73	0.25	1.25	200 513	11.55	0.96	0.07
FI	13	0.30	1.97	153 726	10.07	0.72	0.12
HR	7	0.05	1.07	45 555	14.08	Bd	0.02
HU	17	0.10	0.97	103 461	17.44	1.49	0.03
IE	6	0.42	2.10	198 082	13.93	0.82	0.07
IT	61	0.35	2.13	159 072	22.27	0.71	0.02
LI	1	0.12	0.40	287 614	9.10	0.77	0.03
LT	8	0.06	1.05	54 276	15.57	1.23	0.02
MT	1	0.09	1.20	77 658	10.33	0.78	0.01
NL	13	0.75	2.92	254 049	10.34	0.71	0.04
NO	8	0.29	1.22	240 181	11.06	0.85	0.07
PL	36	0.11	1.97	56 294	16.79	0.83	0.03
PT	12	0.32	4.20	75 606	10.29	0.78	0.09
SE	27	0.31	1.22	238 625	21.11	0.71	0.05
SK	15	0.06	0.86	61 183	13.62	0.83	0.05
UK	109	0.23	0.90	251 187	17.22	1.18	0.06
Średnia	426	0.26	1.51	180 820	15.69	0.93	0.05

Uwaga: bd – brak danych

Źródło: opracowanie własne na podstawie danych z bazy RISIS-ETER.

Rysunek 1. Przychody na nauczyciela akademickiego, 2014 rok – różnice wewnątrz krajów i pomiędzy nimi



Źródło: opracowanie własne na podstawie danych z bazy ETER

3. Analiza empiryczna

3.1 Metodyka badań

Do oceny efektywności szkół wyższych zastosowana zostanie nieparametryczna metoda *data envelopment analysis* (DEA), tłumaczona na język polski jako graniczna analiza danych (Ćwiąkała-Małys i Nowak 2009: 198). Istotą tej metody jest ustalenie odległości danego empirycznego punktu od granicy możliwości produkcyjnych, która jest wyznaczana przez jednostki wzorcowe o 100% efektywności poprzez rozwiązanie zadania minimalizacji stosunku ważonych nakładów do ważonych wyników bądź maksymalizacji stosunku ważonych wyników do nakładów (Simar i Wilson 2000). Występują różne specyficzne rodzaje modeli DEA, które definiują dalsze procedury ich wyliczeń. Podstawowe modele DEA dzielone są ze względu na (Cooper i in. 2004): orientację modelu oraz korzyści skali. Ze względu na orientację modelu analiza może być zorientowana na nakłady: minimalizacja nakładów przy danych wynikach, gdzie wskaźnik odpowiada na pytanie, o ile trzeba zredukować nakłady, żeby obiekt

był efektywny, produkując co najmniej tę samą ilość rezultatów; lub zorientowana na wyniki: maksymalizacja wyników/rezultatów przy danych nakładach, a miara efektywności wskazuje, o ile trzeba zwiększyć wyniki, żeby obiekt był efektywny przy danych nakładach (Simar i Wilson 2000). Warto zauważyć, że wybór określonej orientacji modelu odbywa się za pomocą odpowiedzi na pytanie, na jakie czynniki dana jednostka (w nazewnictwie badań nieparametrycznych nazywana jednostką decyzyjną, ang. *decision making unit* DMU) ma w głównej mierze wpływ. W odniesieniu do badań nad szkołami wyższymi badacze częściej stosują założenie o maksymalizacji wyników przy danych nakładach, argumentując, że przynajmniej w krótkim okresie czasu zarządzający szkołami mają większy wpływ na wartość wyników aniżeli na same nakłady (zob. przegląd badań nad efektywnością szkół wyższych w Wolszczak-Derlacz 2013: 148–157). W dalszej kolejności modele DEA są zróżnicowane ze względu na przyjęte założenia co do korzyści skali. Można wyróżnić modele o stałych korzyściach skali (ang. *Constant Returns to Scale* – CRS) oraz zmienne korzyści skali (ang. *Variable Returns to Scale* – VRS). Stałe korzyści skali odnoszą się do dość restrykcyjnego założenia, że zwiększenie wszystkich czynników produkcji powoduje proporcjonalnie wzrost wyników tej produkcji, podczas gdy w modelach o zmiennych korzyściach skali dochodzi do większego lub mniejszego niż proporcjonalnie wzrostu wyników produkcji (Cwiąkała-Małys i Nowak 2009).

W pracy Cooper i in. (2007) można znaleźć szczegółowe zapisy obliczeń matematycznych dla programowania liniowego niezbędnego do obliczenia wskaźników efektywności metodą DEA.

Do podstawowych zalet stosowania nieparametrycznej metody DEA należy zaliczyć: brak narzuconych założeń co do relacji pomiędzy nakładami i wynikami, brak potrzeby spełnienia rygorystycznych warunków, aby dany estymator był nieobciążony, porównywanie jednostek do obserwacji rzeczywistych, a nie np. jednostek teoretycznych, możliwość ujęcia w analizie wielu nakładów i wyników. Trzeba jednak podkreślić, że jest to metoda wrażliwa na ilość i skład badanych jednostek, w szczególności na obserwacje nietypowe – odstające. Ponadto charakteryzuje się ograniczeniami co do ilości zmiennych przyjętych za nakłady i wyniki (w stosunku do liczby badanych jednostek), a sam ich skład może także determinować rezultaty (Coelli i in. 2005). Dlatego najczęściej do dobrych praktyk należy sprawdzenie stabilności wyników poprzez obliczanie alternatywnych modeli DEA np. w oparciu o inne zbiory nakładów/wyników.

3.2 Ocena efektywności

Wskaźniki efektywności zostały obliczone za pomocą nieparametrycznej metody DEA, gdzie za nakłady przyjęto wartość przychodów (wyrażoną w euro PPP) oraz liczbę nauczycieli akademickich (w przeliczeniu na pełne etaty), a za rezultaty działalności uczelni: liczbę absolwentów oraz liczbę publikacji. Dobór zmiennych do grona

nakładów i wyników podyktowany został praktykami stosowanymi przez badaczy we wcześniejszych analizach (zob. przegląd literatury badań empirycznych podających miary nakładów i wyników m.in. w Worthington 2001; Johnes 2004; Wolszczak-Derlacz 2017). Oszacowano wskaźnik efektywności przy założeniu maksymalizacji wyników, który odpowiada na pytanie, o ile trzeba zwiększyć rezultaty działalności przy danych nakładach. Do obliczeń przyjęto model DEA o zmiennych korzyściach skali. Z powodu dużego zróżnicowania próby badawczej zmienne opisujące nakłady i wyniki zostały wystandaryzowane i odniesione do wartości średniej dla danego kraju w danym roku. Podejście takie zalecają m.in. Daraio i in. (2011). Wskaźniki DEA zostały oszacowane oddzielnie dla poszczególnych lat analizy.

W Tabeli 2 pokazano wskaźniki dla poszczególnych państw i lat analizy obliczone jako średnia ze wskaźników dla uczelni z poszczególnych państw¹⁰. Najniższe wartości (najwyższa efektywność) uzyskano dla uczelni angielskich, niemieckich i norweskich. Na przeciwnym krańcu znalazła się Chorwacja, której uczelnie okazały się bardzo nieefektywne. Polska uplasowała się w środku stawki z wartością wskaźnika efektywności 1.78 w 2014 roku, co jest nieznacznie wyższe od średniej wartości dla całej grupy analizowanych jednostek.

Tabela 2. Wskaźniki efektywności DEA, od najniższych do najwyższych dla 2014 roku

Kraj	2011	2012	2013	2014
UK	1.48	1.54	1.50	1.49
NO	1.62	1.61	1.59	1.57
DE	1.54	1.61	1.61	1.57
SK	1.54	1.60	1.65	1.57
CH	1.49	1.61	1.65	1.62
FI	1.57	1.74	1.76	1.65
SE	1.57	1.58	1.66	1.66
LI	1.67	1.78	1.73	1.72
MT	1.67	1.78	1.73	1.72
IE	1.77	1.85	1.79	1.74
PL	1.73	1.78	1.79	1.78
NL	1.87	1.92	1.85	1.82
LT	1.54	1.62	1.74	1.83
HU	1.73	b.d.	1.84	1.87

¹⁰ Wskaźniki efektywności dla indywidualnych uczelni dostępne u autorki.

Kraj	2011	2012	2013	2014
PT	1.95	2.22	2.15	1.90
IT	1.86	1.95	1.93	1.91
CY	2.30	2.17	2.22	1.94
BE	2.09	2.30	2.08	1.98
HR	b.d	2.99	2.79	2.74
Średnia	1.64	1.73	1.71	1.69

Uwaga: b.d – brak danych

Źródło: opracowanie własne na podstawie danych z ETER. Obliczenia wykonano w programie STATA, pakiet teradial.

W celu sprawdzenia wyników obliczono wskaźniki dla alternatywnych modeli DEA. W modelu DEA2 jako dodatkowe nakłady przyjęto liczbę studentów, w modelu DEA 3 nakłady zostały ograniczone tylko do nakładów finansowych, natomiast model DEA4 został policzony na zmiennych wyjściowych takich jak w oryginalnym modelu DEA 1 (nakłady: wartość przychodów oraz liczba nauczycieli akademickich, wyniki: liczba absolwentów i liczba publikacji), ale wyrażonych jako średnie czteroletnie. Korelacja między wskaźnikami efektywności obliczonymi przy użyciu tych różnych modeli DEA jest wysoka – od 0.75 pomiędzy modelem DEA4 a modelem DEA2 do 0.94 pomiędzy modelem DEA 1 a DEA 4 (Tabela 3). Dodatkowo można stwierdzić, że ranking państw uzyskany na podstawie alternatywnych modeli nie ulega zmianie, Polska plasuje się w połowie stawki.

Tabela 3. Korelacja pomiędzy alternatywnymi modelami DEA

	DEA1	DEA2	DEA3	DEA4
DEA1	1			
DEA2	0.853	1		
DEA3	0.906	0.753	1	
DEA4	0.937	0.752	0.837	1

Uwagi: DEA 1: nakłady: wartość przychodów, liczba nauczycieli akademickich, wyniki: liczba absolwentów, liczba publikacji; DEA2: nakłady: wartość przychodów, liczba nauczycieli akademickich, liczba studentów, wyniki: liczba absolwentów, liczba publikacji; DEA3: nakłady: wartość przychodów, wyniki: liczba absolwentów, liczba publikacji; DEA4: nakłady wartość przychodów, liczba nauczycieli akademickich, wyniki: liczba absolwentów, liczba publikacji (średnie czteroletnie dla lat 2011–2014).

Źródło: opracowanie własne.

3.3 Analiza determinant efektywności

Następnie przeprowadzono analizę w celu ustalenia czynników, które mogą mieć wpływ na wskaźniki efektywności. Oszacowano funkcję regresji według równania (1), gdzie za zmienną zależną przyjęto wcześniej obliczone wskaźniki efektywności (DEA), a wśród zmiennych niezależnych – potencjalnych czynników mających wpływ na efektywność – znalazły się: liczba studentów (wyrażona w logarytmie) jako miara wielkości uczelni ($\ln(\text{Studenci})$), rok założenia uczelni (Rok_założenia) będący przybliżeniem tradycji/prestiżu jednostki, stosunek liczby osób zatrudnionych na stanowiskach administracyjnych do liczby nauczycieli akademickich (Admin/NA) odzwierciedlający rolę pracowników niebędących nauczycielami akademickimi, liczba doktorantów przypadająca na studentów ($\text{Doktoranci/Studenci}$) oraz udział środków zewnętrznych w budżecie jednostki (Przychody_zewn)¹¹. W regresji uwzględniono także efekt czasu (D_t) oraz efekty specyficzne dla poszczególnych krajów związane np. z różnymi systemami szkolnictwa wyższego (D_j).

$$DEA_{i,t} = \alpha + \beta_1 \ln(\text{Studenci})_{i,t} + \beta_2 \text{Rok_założenia}_i + \beta_3 \text{Admin/NA}_{i,t} + \beta_4 \text{Doktoranci/Studenci}_{i,t} + \beta_5 \text{Przychody_zewn}_{i,t} + D_j + D_t + \varepsilon_{i,t} \quad (1)$$

Do estymacji równania zastosowano metodę regresji uciętej (ang. *truncated regression*), gdzie punktem odcięcia jest wartość 1: minimalny wskaźnik DEA oznaczający maksymalną 100% efektywność. Jeżeli parametr strukturalny (β) jest mniejszy (większy) od zera oznacza to, że wraz ze wzrostem wartości danej zmiennej, wartość wskaźnika DEA ulega zmniejszeniu (zwiększeniu) w kierunku wyższej (niższej) efektywności. Wyniki estymacji przedstawiono w Tabeli 4.

Tabela 4. Determinanty efektywności, zmienna zależna wskaźniki DEA1

	(1)	(2)	(3)	(4)	(5)
$\ln(\text{Studenci})$	-0.605***	-0.583***	-0.464***	-0.470***	-0.499***
	[0.029]	[0.029]	[0.024]	[0.025]	[0.026]
Rok założenia		0.032***	0.036***	0.031***	0.030***
		[0.012]	[0.010]	[0.010]	[0.009]
Admin/NA			0.143***	0.145***	0.177***
			[0.041]	[0.041]	[0.040]
$\text{Doktoranci/Studenci}$				-0.801**	

¹¹ Przychody zewnętrzne są obliczone jako różnica pomiędzy całkowitymi przychodami, a przychodami ze źródeł podstawowych (*core budget*), opłat studentów oraz przychodów niesklasyfikowanych.

	(1)	(2)	(3)	(4)	(5)
				[0.326]	
<i>Przychody_zewn</i>					-0.340**
					[0.141]
Liczba obserwacji	1648	1648	1544	1542	1301
Liczba krajów	19	19	18	18	15
Kraje nieobjęte analizą			HR	HR	HR, FI, PL, SK (2011, 2012), BE (2012)

Uwaga: * $p < 0,10$, ** $p < 0,05$, *** $p < 0,01$, w nawiasach błęd standardowy. Obliczenia zostały wykonane w programie STATA SE. Estymacje z dodatkową zmienną zerojedynkową dla roku badania oraz kraju. Współczynniki dla zmiennej: rok założenia przeskalowano przez 100.

Źródło: opracowanie własne.

W pierwszej kolumnie umieszczono tylko liczbę studentów, ujemny parametr oznacza, że wraz ze wzrostem liczby studentów wskaźnik efektywności maleje – zwiększa się efektywność. Generalnie szkoły większe są bardziej efektywne. Potwierdzone to zostaje w kolejnych specyfikacjach, gdzie dodane są dodatkowe zmienne niezależne. W kolumnie drugiej dodano zmienną „rok założenia uczelni” i potwierdzono, że uczelnie młodsze są mniej efektywne. W kolejnych kolumnach dodawano dodatkowe zmienne, kontrolując wielkość uczelni i rok założenia: te dwie zmienne były dostępne dla wszystkich uczelni z analizowanych krajów. W specyfikacji (3) wśród zmiennych niezależnych znalazła się dodatkowa zmienna *Admin/NA*, dla której parametr jest dodatni: przy uwzględnieniu innych cech uczelni (np. liczby studentów) szkoły, gdzie większa liczba pracowników administracji przypada na nauczycieli akademickich, są mniej efektywne. Odwrotną rolę pełnią doktoranci: im wyższy odsetek doktorantów w stosunku do studentów, tym wyższa efektywność uczelni (podobnych pod względem wielkości, roku założenia i stosunku pracowników administracji do nauczycieli akademickich) (kolumna 4). W ostatniej kolumnie dodano do specyfikacji zmienną: *Przychody_zewnetrzne*, ponieważ jest ona dodatnio skorelowana ze zmienną *Doktoranci/Studenti*, dwie zmienne nie znalazły się jednocześnie w jednej regresji¹². Pokazano, że przychody pochodzące ze źródeł zewnętrznych są ujemnie skorelowane ze wskaźnikiem nieefektywności, im wyższy odsetek przychodów zewnętrznych w budżecie uczelni podobnych pod względem wielkości i roku założenia, tym wyższa efektywność jednostek.

Podobnie jak w poprzedniej części oszacowano regresję 1 dla alternatywnych modeli DEA (wyniki zamieszczono w tabelach: 1A, 2A i 3A w Aneksie). Potwierdzają

¹² Współczynnik korelacji Pearsona pomiędzy zmiennymi: *Przychody_zewnetrzne* i *Doktoranci/Studenti* wynosi 0.51.

one większość rezultatów uzyskanych dla modelu wyjściowego. Dla wszystkich specyfikacji parametr przy zmiennej $\ln(\textit{Studenti})$ jest ujemny i statystycznie istotny, a parametr $\textit{Admin/NA}$ dodatni i statystycznie istotny (dla wyników z kolumny 5, modelu dla DEA2 brak statystycznej istotności parametru). Dla modelu, w którym zmienną zależną jest wskaźnik DEA uzyskany na zmiennych będących średnią czteroletnią, rok założenia uczelni w 3 na 4 estymacjach nie jest statystycznie istotny, podobnie jak liczba doktorantów przypadająca na studentów oraz przychody zewnętrzne. W tym zakresie wyniki tego modelu odbiegają od bazowych, warto jednak zauważyć, że liczba obserwacji jest w tym wypadku znacznie mniejsza. Dodatkowo poprzez użycie zmiennych, które są średnimi z 4 lat analizy, zróżnicowanie zmiennych zależnych i niezależnych znacznie spadło.

Odnosząc uzyskane rezultaty do tych uzyskanych przez innych badaczy, można stwierdzić, że są one z nimi dalece zbieżne. Generalnie przyjmuje się, że duże jednostki są bardziej efektywne, chociaż Daraio i in. (2015a) w przeprowadzonym przeglądzie literatury wskazują, że pomiędzy wielkością jednostki a jej efektywnością odmienne mogą być zależności w odniesieniu do działalności dydaktycznej i naukowej uczelni. Dodatkowo zwracają uwagę na możliwy nieliniowy charakter związku, gdzie po przekroczeniu pewnego progu wielkości uczelni (mierzonego najczęściej liczbą pracowników naukowych czy liczbą studentów) dochodzi do spadku jej efektywności. Argumentują to zbyt rozbudowanymi strukturami administracyjnymi i procedurami biurokratycznymi.

Kolejny analizowany element to rok założenia uczelni mający odzwierciedlać jej prestiż i tradycję. Uczelnie starsze, z długoletnią tradycją mogą przyciągać bardziej produktywnych pracowników nastawionych np. na prowadzenie badań naukowych. Z tego samego powodu kandydaci na studentów mogą decydować się na wybór tej, a nie innej szkoły wyższej. Z drugiej strony uczelnie młodsze mogą być bardziej elastyczne, bardziej otwarte na wprowadzanie zmian np. motywujących pracowników do pracy naukowej czy też związanych z podniesieniem jakości nauczania. Wyniki przeprowadzonych badań w niniejszym artykule są zgodne z moimi wcześniejszymi badaniami (Wolszczak-Derlacz 2017), gdzie stwierdziłam, że starsze europejskie uczelnie były bardziej efektywne. Co ciekawe, w przywoływanych badaniach uzyskałam niejednoznaczne wyniki dla uczelni ze Stanów Zjednoczonych. Relacja dla nich nie była statystycznie istotna lub wręcz wykazano zależność odwrotną: uczelnie młodsze były bardziej efektywne.

Na podstawie uzyskanych wyników można powiedzieć, że wśród uczelni podobnych pod względem wielkości i roku założenia bardziej efektywne są te, w których jest mniejszy odsetek pracowników niebędących nauczycielami akademickimi. Martin (2016) jako jedną z bolączek dzisiejszego funkcjonowania uczelni wskazuje rozrost biurokratycznych procedur i, co za tym idzie, nieproporcjonalny przyrost pracowników zatrudnionych na stanowiskach administracyjnych. W najnowszych

badaniach Baltaru (2018) dla próby 100 brytyjskich uniwersytetów testuje, czy zmiany w strukturze zatrudnienia (wzrost odsetka pracowników administracji) pomiędzy 2003 a 2011 rokiem wpłynęły na wyniki działalności uczelni. Autorka stwierdza, że uczelnie, które w sposób umiarkowany zwiększały zatrudnienie osób niebędących nauczycielami akademickimi, charakteryzują się wyższymi współczynnikami ukończenia studiów, ale nie miało to wpływu na efekty związane z prowadzeniem badań naukowych, na wskaźniki związane z ukończeniem studiów z wyróżnieniem ani na wskaźniki zatrudnienia absolwentów. Te trzy aspekty są zdeterminowane wyłącznie przez reputację i prestiż uczelni.

W literaturze przedmiotu podkreśla się rolę źródeł zewnętrznych, przyznawanych na zasadach konkurencyjnych, na efektywność uczelni (Bolli i in. 2016; Bolli i Somogyi 2011; Wolszczak-Derlacz i Parteka 2010, 2011; Wolszczak-Derlacz 2017).

Bolli i in. (2016) przedstawiają trzy potencjalne kanały wpływu środków zewnętrznych na produktywność uczelni. Pierwszy, nazwany efektem konkurencji, związany jest z tym, że najczęściej o środki zewnętrzne trzeba aplikować w otwartych konkursach, a więc są one rozdysponowane na zasadach konkurencyjnych. Przyznawanie środków na zasadach konkursów powinno przyczyniać się do ich efektywnego wykorzystania – środki powinni otrzymywać ci badacze i te ośrodki, które gwarantują ich najbardziej wydajne wydatkowanie. Kolejny z efektów to efekt administracyjny, tzn. aplikowanie o konkurencyjne środki, który wiąże się ze wzrostem obciążeń administracyjnych. Ostatni z kanałów to tzw. efekt selekcji (ang. *sorting effect*), gdy w wyniku uzyskiwania zewnętrznych grantów dochodzi do przemieszczenia najbardziej wydajnych naukowców w kierunku uczelni o największym prestiżu, które dalej stają się bardziej produktywne, bo skupiają najlepszych naukowców. Wyniki badań empirycznych nie są jednak jednoznaczne. Dodatni wpływ środków zewnętrznych na efektywność uczelni pokazany został m.in. przez Cherchye i Abeele (2005), Butler (2003), Wolszczak-Derlacz i Partekę (2010, 2011). Wolszczak-Derlacz i Parteka (2010) pokazały w szczególności, że uczelnie z krajów o wyższym udziale przychodów pochodzących ze źródeł państwowych charakteryzują się niższymi bibliograficznymi wskaźnikami produktywności naukowej. W moich własnych badaniach (Wolszczak-Derlacz 2017) zwróciłam w tym kontekście uwagę na różnice pomiędzy uczelniami europejskimi a amerykańskimi, gdzie dla tych pierwszych zależność pomiędzy źródłami publicznymi a efektywnością jest ujemna. Wiąże to się niewątpliwie z innymi procedurami przyznawania grantów w Stanach Zjednoczonych i w Europie. Natomiast Bolli i Somogyi (2011) podkreślają wagę źródeł pochodzenia środków zewnętrznych: czy są one dostarczane przez sektor prywatny, czy publiczny. Stwierdzają, że prywatne źródła zewnętrzne wpływają dodatnio na stronę aplikacyjną (patenty), a ujemnie na badania podstawowe (publikacje). Bolli i in. (2016) podkreślają natomiast, że istotne jest rozróżnienie czy środki zewnętrzne pochodzą ze źródeł

krajowych, czy z zagranicznych (międzynarodowych). Te ostatnie w mniejszym stopniu przekładają się na efektywność jednostek – możemy mieć tutaj do czynienia z silnym efektem administracyjnym – zbyt dużymi obciążeniami administracyjnymi związanymi z aplikowaniem o granty zagraniczne/międzynarodowe, które niwelują pozytywne efekty w zakresie wzrostu produktywności.

Podsumowanie i dyskusja

W artykule przeprowadzono analizę empiryczną efektywności szkół wyższych wraz z estymacją czynników ją determinujących. Próba badawcza składa się z uczelni z 19 krajów europejskich i obejmuje dane dla lat 2011–2014. Dane pochodzą z ogólnodostępnej bazy ETER. W analizie uwzględniono 36 uczelni (uniwersytety i politechniki) z Polski. Porównanie ich funkcjonowania do uczelni z pozostałych krajów europejskich wskazuje na pewne cechy charakterystyczne: bardzo niskie zasoby finansowe, jeden z najniższych wskaźników przychodów przypadających na nauczycieli akademickich, relatywnie niskie wskaźniki publikacji na liczbę nauczycieli akademickich, ale wyższe, gdy wyrażone w przeliczeniu na wartość przychodów. Liczba studentów przypadająca na jednego nauczyciela akademickiego w analizowanych uczelniach z Polski odpowiada średniej dla uczelni z wszystkich krajów europejskich, natomiast niższy jest w ich wypadku odsetek liczby pracowników niebędących nauczycielami akademickimi oraz relatywnie mała liczba doktorantów w grupie wszystkich studentów.

Na podstawie nieparametrycznej metody DEA oszacowano wskaźniki efektywności, gdzie w modelu bazowym za nakłady przyjęto: wartość przychodów i liczbę nauczycieli akademickich, a za wyniki działalności uczelni: liczbę absolwentów oraz liczbę publikacji. Wyniki wskazują, że szkoły wyższe są nieefektywne, a wartość nieefektywności jest stała w czasie. Uczelnie z Polski plasowały się w połowie stawki pod względem wartości wskaźników efektywności. Za najbardziej efektywne uznano uczelnie z Wielkiej Brytanii, a za najmniej efektywne uczelnie z Chorwacji.

Dodatkowo zbadano relację pomiędzy wybranymi zmiennymi a wskaźnikami efektywności. Rezultaty wskazują, że uczelnie większe i starsze są bardziej efektywne. Porównanie uczelni o tej samej wielkości i roku założenia pokazało, że jednostki, które mają większy odsetek pracowników niebędących nauczycielami akademickimi i niższy udział przychodów zewnętrznych w całkowitej sumie przychodów, charakteryzują się niższą efektywnością, a te które mają wyższy udział doktorantów do liczby wszystkich studentów wyższą efektywnością.

Powyższe wyniki należy traktować jako wstępne. Chociaż przeprowadzono analizę wrażliwości wyników (analizy na podstawie alternatywnych modeli DEA), to założono jedną wspólną dla wszystkich państw granicę produkcji i to, że wszystkie uczelnie posiadają taką samą technologię „produkcji”. Uczelnie z Polski porównywane były do tych najlepszych z krajów europejskich.

Interpretując wyniki, należy wskazywać raczej na pewne generalne tendencje występujące wśród uczelni europejskich. Nie jest rekomendowane wysuwanie wniosków dla konkretnych uczelni, np. potrzeba zmniejszenia liczby pracowników administracji w celu zwiększenia efektywności. Należy zauważyć, że związki przyczynowo-skutkowe mogą być tutaj niejednoznaczne albo wręcz dwukierunkowe, np. zewnętrzne źródła finansowe podnoszą efektywność działań na uczelniach, ale silniejsze uczelnie przyciągają więcej funduszy ze źródeł zewnętrznych. Dodatkowym ograniczeniem analizy jest nieduża liczba nakładów i wyników, które dodatkowo odzwierciedlały jedynie cechy ilościowe.

Powyższe badania potwierdziły, że porównania międzynarodowe mogą i powinny być prowadzone. Benchmarking uczelni krajowych w stosunku do uczelni zagranicznych jest nieodzownym elementem procesów globalizacji. Żeby badania te były jak najbardziej rzetelne, powinny być dokonywane na podstawie zharmonizowanych i wiarygodnych danych. Tendencje światowe odnośnie gromadzenia i udostępniania danych na temat uczelni, w tym w szczególności uczelni publicznych, idą w kierunku otwartego dostępu do danych. Tym bardziej zaskakujące są działania w Polsce, które ograniczają dostęp do statystyk na poziomie indywidualnych uczelni.

Aneks

Tabela 1A. Determinanty efektywności, zmienna zależna wskaźniki DEA2

	(1)	(2)	(3)	(4)	(5)
<i>ln(Studenci)</i>	-0.279***	-0.253***	-0.193***	-0.200***	-0.210***
	[0.017]	[0.017]	[0.014]	[0.014]	[0.016]
<i>Rok założenia</i>		0.037***	0.035***	0.024***	0.029***
		[0.007]	[0.006]	[0.006]	[0.006]
<i>Admin/NA</i>			0.043*	0.048**	0.04
			[0.024]	[0.023]	[0.026]
<i>Doktoranci/Studenci</i>				-1.805***	
				[0.218]	
<i>Przychody_zewn</i>					-0.616***
					[0.092]
Liczba obserwacji	1648	1648	1544	1542	1301

Uwaga: * $p < 0,10$, ** $p < 0,05$, *** $p < 0,01$, w nawiasach błęd standardowy. Obliczenia zostały wykonane w programie STATA SE. Estymacje z dodatkową zmienną zerojedynkową dla roku badania oraz kraju. Współczynniki dla zmiennej: rok założenia przeskalowano przez 100.

Źródło: opracowanie własne.

Tabela 2A. Determinanty efektywności, zmienna zależna wskaźniki DEA3

	(1)	(2)	(3)	(4)	(5)
<i>ln(Studenci)</i>	-1.016***	-0.971***	-0.780***	-0.788***	-0.825***
	[0.041]	[0.042]	[0.030]	[0.031]	[0.032]
<i>Rok założenia</i>		0.066***	0.060***	0.053***	0.055***
		[0.017]	[0.012]	[0.013]	[0.012]
<i>Admin/NA</i>			0.567***	0.570***	0.592***
			[0.051]	[0.051]	[0.051]
<i>Doktoranci/Studenci</i>				-1.232***	
				[0.401]	
<i>Przychody_zewn</i>					-0.282
					[0.172]
Liczba obserwacji	1648	1648	1544	1542	1301

Uwaga: * $p < 0,10$, ** $p < 0,05$, *** $p < 0,01$, w nawiasach błęd standardowy. Obliczenia zostały wykonane w programie STATA SE. Estymacje z dodatkową zmienną zerojedynkową dla roku badania oraz kraju. Współczynniki dla zmiennej: rok założenia przeskalowano przez 100.

Źródło: opracowanie własne.

Tabela 3A. Determinanty efektywności, zmienna zależna wskaźniki DEA4

	(1)	(2)	(3)	(4)	(5)
<i>ln(Studenci)</i>	-0.407***	-0.389***	-0.396***	-0.397***	-0.454***
	[0.041]	[0.043]	[0.042]	[0.042]	[0.046]
<i>Rok założenia</i>		0.023	0.027*	0.025	0.023
		[0.016]	[0.016]	[0.016]	[0.016]
<i>Admin/NA</i>			0.285***	0.285***	0.313***
			[0.102]	[0.102]	[0.102]
<i>Doktoranci/Studenci</i>				-0.517	
				[0.593]	
<i>Przychody_zewn</i>					-0.177
					[0.277]
Liczba obserwacji	387	387	387	387	336

Uwaga: * $p < 0,10$, ** $p < 0,05$, *** $p < 0,01$, w nawiasach błęd standardowy. Obliczenia zostały wykonane w programie STATA SE. Estymacje z dodatkową zmienną zerojedynkową dla kraju. Współczynniki dla zmiennej: rok założenia przeskalowano przez 100.

Źródło: opracowanie własne.

Podziękowania

Badania zostały zrealizowane w ramach projektu MNiSW Dialog: „Doskonałość naukowa: konkurencyjność, mierzalność, umiędzynarodowienie (od badań empirycznych do reform szkolnictwa wyższego) (EXCELLENCE)” – Dialog umowa: 0021/DLG/2016/10. Pragnę podziękować za cenne uwagi uczestnikom debaty, która odbyła się 16 czerwca 2018 roku na Wydziale Zarządzania i Ekonomii Politechniki Gdańskiej, gdzie zaprezentowane zostały powyższe analizy empiryczne (jako część Raportu: *Wzmocnienie efektywności i produktywności szkół wyższych*).

Literatura

- Agasisti, T. (2011). Performances and spending efficiency in higher education: a European comparison through non-parametric approaches. *Education Economics*. 19(2): 199–224.
- Agasisti, T., Catalano, G., Landoni, P. i Verganti, R. (2012). Evaluating the performance of academic departments: an analysis of research-related output efficiency. *Research Evaluation*. 21(1): 2–14.
- Agasisti, T. i Pohl, C. (2012). Comparing German and Italian public universities: Convergence or divergence in the higher education landscape? *Managerial and Decision Economics*. 33(2): 71–85.
- Baltaru, R. D. (2018). Do non-academic professionals enhance universities' performance? Reputation vs. organisation. *Studies in Higher Education*: 1–14.
- Bolli, T., Olivares, M., Bonaccorsi, A., Daraio, C., Aracil, A. G. i Lepori, B. (2016). The differential effects of competitive funding on the production frontier and the efficiency of universities. *Economics of Education Review*. 52: 91–104.
- Bolli, T. i Somogyi, F. (2011). Do competitively acquired funds induce universities to increase productivity? *Research Policy*. 40: 136–147.
- Bonaccorsi, A. i Daraio, C. (red.) (2007). *Universities and Strategic Knowledge Creation: Specialization and Performance in Europe*. Cheltenham–Northampton, MA: Edward Elgar Publishing.
- Bonaccorsi, A., Daraio, C. i Simar, L. (2006). Advanced indicators of productivity of universities an application of robust nonparametric methods to Italian data. *Scientometrics*. 66(2): 389–410.
- Brzezicki, Ł. (2018). *Zestawienie badań polskiego szkolnictwa wyższego prowadzonych za pomocą metody DEA i indeksu Malmquista w latach 2005–2017*. https://www.researchgate.net/profile/Lukasz_Brzezicki [30.06.2018].
- Brzezicki, Ł. i Wolszczak-Derlacz, J. (2015). Pomiar efektywności kształcenia i produktywności publicznych szkół wyższych za pomocą nieparametrycznej metody DEA i indeksu Malmquista. *Gospodarka Rynek Edukacja*. 16(4): 13–19.
- Butler, L. (2003). Explaining Australia's increased share of ISI publications –The effects of a funding formula based on publication counts. *Research Policy*. 32(1): 143–15.

- Cherchye, L. i Abeele, P. V. (2005). On research efficiency: A micro-analysis of Dutch university research in economics and business management. *Research Policy*. 34(4): 495–516.
- Coelli, T. J., Rao, D. S. P., O'Donnell, C.J. i Battese, G.E. (2005). *An introduction to efficiency and productivity analysis* (2nd edition). New York: Springer.
- Colbert, A., Levary, R.R. i Shaner, M.C. (2000). Determining the relative efficiency of MBA programs using DEA. *European Journal of Operational Research*. 125: 656–669.
- Cooper, W. W., Seiford, L. M., Tone, K. i Zhu, J. (2007). Some models and measures for evaluating performances with DEA: past accomplishments and future prospects. *Journal of Productivity Analysis*. 28(3): 151–163.
- Cooper, W.W., Seiford, L.M. i Zhu, J. (2004). *Handbook on Data Envelopment Analysis*. Hingham, MA: Kluwer Academic Publishers.
- Ćwiąkała-Małys, A., Nowak, W. (2009). *Wybrane metody pomiaru efektywności podmiotu gospodarczego*. Wrocław: Wydawnictwo Uniwersytetu Wrocławskiego.
- Daraio, C., Bonaccorsi, A., Geuna, A., Lepori, B., Bach, L., Bogetoft, P. i in. (2011). The European university landscape: A micro characterization based on evidence from the AQUAMETH project. *Research Policy*. 40(1): 148–164.
- Daraio, C., Bonaccorsi, A. i Simar, L. (2015a). Efficiency and economies of scale and specialization in European universities. A directional distance approach. *Journal of Informetrics*. 9: 430–448, D.
- Daraio, C., Bonaccorsi, A. i Simar, L. (2015b). Rankings and University Performance: a Conditional Multidimensional Approach. *European Journal of Operational Research*. 244: 918–930.
- Daraio, C. i Simar, L. (2007). *Advanced robust and nonparametric methods in efficiency analysis: Methodology and applications*. New York: Springer.
- Daraio, C. i Glänzel, W. (2016). Grand challenges in data integration – State of the art and future perspectives: An introduction. *Scientometrics*. 108(1): 391–400.
- ETER Final Quality Report (2017). https://www.eterproject.com/assets/pdf/ETER_quality_report_2017.pdf [9.04.2018].
- Johnes, J. (2004). Efficiency measurement. W G. Johnes i J. Johnes (red.), *International handbook on the economics of education* (613–742). Edward Elgar Publishing Ltd: Cheltenham, UK.
- Johnes, J. (2006a). Data envelopment analysis and its application to the measurement of efficiency in higher education. *Economics of Education Review*. 25(3): 273–288.
- Johnes, J. (2006b). Measuring Teaching Efficiency in Higher Education: An Application of Data Envelopment Analysis to Economics Graduates from UK Universities 1993. *European Journal of Operational Research*. 174(1): 443–456.
- Johnes, J. i Johnes, G. (1995). Research Funding and Performance in U.K. University Departments of Economics: A Frontier Analysis. *Economics of Education Review*. 14(3): 301–314.

- Kempkes, G. i Pohl, C. (2010). The efficiency of German universities – Some evidence from nonparametric and parametric methods. *Applied Economics*. 42: 2063–2079.
- Lepori, B., Ploder, M., Wagner-Schuster, D. i Gunnes, H. (2017) Report on the content and technical structure of the RISIS- ETER facility: http://risis.eu/wpcontent/uploads/2017/10/RISIS_ETER_report.pdf [1.03.2018].
- Martin, B. (2016). What's happening to our universities? *Prometheus*. 34(1): 7–24.
- Simar, L. i Wilson, P. (2000). A General Methodology for Bootstrapping in Non-parametric Frontier Models. *Journal of Applied Statistics*. 27(6): 779–802.
- Wolszczak-Derlacz, J. (2013). *Efektywność naukowa dydaktyczna i wdrożeniowa publicznych szkół wyższych w Polsce – analiza nieparametryczna*. Gdańsk: Wydawnictwo Politechniki Gdańskiej.
- Wolszczak-Derlacz, J. (2017). An evaluation and explanation of (in) efficiency in higher education institutions in Europe and the US with the application of two-stage semi-parametric DEA. *Research Policy*. 46(9): 1595–1605.
- Wolszczak-Derlacz, J. i Parteka A. (2010). Produktywność naukowa wyższych szkół publicznych w Polsce – Bibliometryczna analiza porównawcza. Ernst & Young Polska.
- Wolszczak-Derlacz, J. i Parteka A. (2011). Efficiency of European public higher education institutions: a two-stage multicountry approach. *Scientometrics*. 89: 887–917.
- Worthington, A.C. (2001). An Empirical Survey of Frontier Efficiency Measurement Techniques In Education. *Education Economics*. 9(3): 245–268.

Efficiency of Polish higher education institutions in comparison to European universities – an analysis for 19 countries

ABSTRACT: In the article empirical analysis of the efficiency of higher education institutions (HEIs) is carried out along with the estimation of factors determining it. The sample of HEIs consists of universities from 19 European countries covering period 2011-2014. On the basis of the non-parametric DEA method, the efficiency scores are estimated for individual universities. The inputs include: revenues and the number of academic staff, while outputs: number of graduates and the number of publications. Additionally, the relationship between selected environmental variables and efficiency scores is examined. The results indicate that larger and older universities are more efficient. Comparing universities of the same size, and year of foundation, those that have a greater share of non-academic staff and lower share of external revenues in the total budget are characterized by lower efficiency.

KEYWORDS: DEA, efficiency, determinants of efficiency, higher education institutions, ETER

CYTOWANIE: Wolszczak-Derlacz, J. (2018). Efektywność szkół wyższych w Polsce na tle uczelni europejskich – analiza dla dziesięciu krajów. *Nauka i Szkolnictwo Wyższe*. 2(52): 147–170. DOI: 10.14746/nisw.2018.2.5.

JOANNA WOLSZCZAK-DERLACZ – doktor habilitowany nauk ekonomicznych, profesor nadzwyczajny Politechniki Gdańskiej, kierownik Katedry Nauk Ekonomicznych na Wydziale Zarządzania i Ekonomii PG. Prowadziła badania naukowe m.in. na Katolickim Uniwersytecie w Leuven (Belgia) – pobyt w ramach stypendium Marie Curie, na Uniwersytecie w Glasgow (Wielka Brytania) – stypendium Dekaban Junior Fellowship, na Europejskim Instytucie Uniwersyteckim (European University Institute) we Florencji jako beneficjentka stypendium podoktorskiego Max Weber Fellowship oraz na Uniwersytecie Kalifornijskim w Berkeley w ramach programu „Mobilność Plus”. Jej zainteresowania naukowe skupiają się na teorii konwergencji gospodarczej, analizach produktywności i efektywności, ekonomii edukacji i rynkach pracy. Wyniki badań nad efektywnością i produktywnością szkół wyższych publikowała m.in. w: *Research Policy*, *Journal of Productivity Analysis*, *Scientometrics*.

E-mail: jwo@zie.pg.gda.pl

Jacek Lewicki

Nowy algorytm podziału dotacji podstawowej dla uczelni akademickich. Pierwsze skutki zmian i wstępne wnioski

STRESZCZENIE: Działalność dydaktyczna stanowi około 60% przychodów uczelni publicznych w Polsce. Pod koniec 2016 roku Ministerstwo Nauki i Szkolnictwa Wyższego zmodyfikowało zasady podziału tej dotacji. Kluczowymi zmianami dla szkół akademickich było powiązanie wysokości przyznawanych środków z liczbą studentów przypadających na nauczyciela akademickiego oraz uwzględnianie posiadanych przez uczelnie kategorii naukowych. Obowiązki nowego algorytmu podziału dotacji w 2017 roku skutkowało dużymi zmianami w wysokości dotacji dla wielu uczelni, które podjęły działania dostosowawcze, na przykład zmniejszając nabory na kolejny rok akademicki. W 2018 roku nowa ewaluacja nauki spowodowała kolejne zmiany w podziale dotacji.

SŁOWA KLUCZOWE: dotacja podstawowa, algorytm, finasowanie uczelni, Polska

Wstęp

W większości systemów europejskich państwo jest nie tylko regulatorem szkół wyższych, ale też *de facto* właścicielem wielu z nich i nawet jeżeli nie wykonuje wprost działań jako właściciel (autonomia uczelni), to finansuje znaczącą część kształcenia i badań (zob. np. European Commission i in. 2018: 32–40; EUA 2017). W Polsce uczelnie publiczne stanowią dominującą grupę, w której kształcą się większość studentów i prowadzona jest większość badań naukowych. Zatem dystrybucja środków finansowych pozostaje bardzo ważnym narzędziem Ministerstwa Nauki i Szkolnictwa Wyższego (MNiSW) w prowadzeniu polityki w obszarze nauki i szkolnictwa wyższego. Poprzez wprowadzanie środków celowych, konkursów, ale także zmiany zasad obliczania dotacji na dydaktykę czy badania statutowe od lat próbuje się: stymulować działania uczelni na rzecz jakości kształcenia, stymulować podaż określonej oferty kształcenia czy wpływać na politykę kadrową.

Sposób podziału środków publicznych na poszczególne działania szkół wyższych jest przedmiotem licznych analiz i dyskusji od przełomu ustrojowego 1989 roku.

Stosowanie odpowiednich algorytmów wpływających na działania szkół wyższych ma jednocześnie zobiektywizować dzielenie funduszy. Pod koniec 2016 roku MNiSW wprowadziło zmiany w zasadach podziału najważniejszej dla szkół publicznych dotacji – dotacji podstawowej. Ze względu na zakres zmian, ale też ich obowiązywanie od 2017 roku, można mówić o bardzo ważnej zmianie dla całego systemu szkolnictwa wyższego. Niniejszy artykuł przedstawia istotę działania nowego algorytmu podziału środków i jego najważniejsze efekty. Ze względu na zakres dostępnych danych (stan na styczeń 2018 rok) omówione zostały tylko wybrane skutki, a część wniosków ma charakter wstępny i ogólny¹.

Znaczenie dotacji podstawowej dla uczelni publicznych

W 2016 roku przychody z działalności dydaktycznej stanowiły 77.9% (15.9 mld zł) przychodów z działalności operacyjnej (20.5 mld zł) uczelni publicznych (z działalności badawczej tylko 13.6% tj. 2.8 mld zł). Dla poszczególnych typów szkół wyższych proporcje te wyglądały odpowiednio:

- dla uniwersytetów – 76.4% i 15.7%,
- dla uczelni technicznych – 72.3% i 18.0%,
- dla uczelni rolniczych – 72.6% i 12.6%,
- dla uczelni ekonomicznych – 93.1% i 4.5%,
- dla uczelni pedagogicznych – 91.3% i 4.2%,
- dla uczelni medycznych – 80.1% i 11.8%.

Zarazem głównym źródłem finansowania działalności dydaktycznej uczelni publicznych są dotacje z budżetu państwa stanowiące aż 81.1% przychodów w tym obszarze. Środki prywatne w postaci opłat za zajęcia dydaktyczne (w tym czesne za studia niestacjonarne) to 11.6%, pozostałe przychody – 7.2%, a środki z budżetu gmin i inne fundusze publiczne – jedynie 0.1% (GUS 2017: 49–50). Jak zauważa Krzysztof Leja, analizując strukturę przychodów uczelni technicznych w Polsce, nawet one zdecydowanie bardziej zbliżone są zatem do modelu uniwersytetu humboldtowskiego niż do uniwersytetu przedsiębiorczego według Burtona R. Clarka (Leja 2013: 129–132). Warto zauważyć za Anną Białek-Jaworską, że ze względu na m.in. zmiany demograficzne i zmiany w strukturze kształcenia na studiach wyższych od lat maleje liczba osób płacących za studia (z 66% w 2000 roku do 51.5% w 2012 roku). W samych szkołach publicznych (wszystkich typów) liczba studentów niestacjonarnych

¹ Autor pragnie podziękować Pani Monice Głąb z Działu Analiz Ekonomicznych Szkoły Głównej Handlowej w Warszawie za pomoc w opracowaniu danych uzyskanych z Ministerstwa Nauki i Szkolnictwa Wyższego.

spadła z 46.4% w 2001 roku do 27.2% w 2012 roku (Białek-Jaworska 2017: 125) i do 21.3% w 2016 roku (GUS 2017: 57).

Kluczowym źródłem finansowania uczelni publicznych jest zatem dotacja podstawowa – około 60% wszystkich przychodów operacyjnych (59% dla szkół akademickich i 79% dla zawodowych). Ze względu na fakt, że uczelniom akademickim (z wyłączeniem medycznych, morskich, artystycznych, wojskowych w zakresie kształcenia żołnierzy oraz podległych Ministerstwu Spraw Wewnętrznych i Administracji) w 2016 roku przypadło 9.4 mld zł, natomiast Państwowym Wyższym Szkołom Zawodowym (PWSZ) jedynie niecałe 0.6 mld zł (MNiSWa 2017), w dalszych częściach niniejszego tekstu mowa będzie przede wszystkim o pierwszej grupie szkół wyższych.

Zasady podziału dotacji podstawowej

Dotacja podstawowa dzielona jest od początku lat 90. XX wieku według algorytmu (zob. np. Pakuła 1994), który istotnie ewoluował na przestrzeni minionego ćwierćwiecza. Zgodnie z przepisami dotacja podstawowa składa się z części zasadniczej oraz uzupełniającej. Pierwsza dzielona jest według algorytmów (dla szkół akademickich i zawodowych), druga (do 2% całości) przeznaczona jest na rzecz podziałów uzupełniających i korygujących. Rozporządzenie nie wskazuje, jak ma wyglądać podział pomiędzy szkoły akademickie a zawodowe². Jednym z elementów algorytmu była i jest tzw. stała przeniesienia, czyli udział dotacji z roku minionego w nowym przydziale środków (por. niżej). Anna Białek-Jaworska i Marek Żukowski zauważają, że po zmianie zasad podziału dotacji w 2007 roku wprowadzono stałą przeniesienia o bardzo wysokiej wadze 0.7 (tuż przed nowelizacją wynosiła jedynie 0.2, ale też konstrukcja algorytmu była inna). Było to konieczne, gdyż wyliczenia dotacji w oparciu o pozostałe składniki w nowej formule wskazywały różnice pomiędzy uczelniami rzędu 50%–80%. Zatem konieczny stał się mechanizm chroniący uczelnie przed gwałtownym spadkiem wysokości dotacji. Przy rosnącej konkurencji o szczupłe środki stała przeniesienia w pewnym zakresie chroniła słabsze szkoły wyższe, dając im czas na dostosowanie się. Pomimo tego i tak nastąpiło rozwarstwienie w wysokości dotacji, szczególnie pomiędzy uniwersytetami. Część środowiska naukowego (np. Maciej Żylicz) wskazywała, że zmiany, choć idące w dobrym kierunku, zbyt słabo wymuszają poprawę jakości kształcenia (Białek-Jaworska i Żukowski 2017: 79–81). W kolejnych latach znacznej stałej przeniesienia pozostawało bardzo istotne (w 2016 roku waga 0.65 – por. niżej).

W połowie września 2016 roku MNiSW przedstawiło „Koncepcję zmian algorytmu podziału dotacji podstawowej dla uczelni akademickich oraz zawodowych z części 38.

² Identyczne rozwiązanie zastosowane zostały we wcześniejszych rozporządzeniach (zob. A. Białek-Jaworska i M. Żukowski 2017).

budżetu państwa”. Dokument przeznaczony do konsultacji nie był projektem nowego rozporządzenia, lecz przede wszystkim próbą wysondowania stanowiska środowiska władz uczelni. Właściwy Projekt Rozporządzenia Ministra Nauki i Szkolnictwa Wyższego zmieniającego rozporządzenie w sprawie podziału dotacji z budżetu państwa dla uczelni publicznych i niepublicznych przedstawiony został 6 października 2016 roku (zob. Lewicki 2016). W toku konsultacji społecznych jedną z kluczowych i najczęściej podnoszonych uwag było zwrócenie uwagi na zbyt szybkie wejście w życie przepisów, zwłaszcza w kontekście wprowadzenia składnika dostępności kadry (szerzej zob. MNiSW 2017b). Ostatecznie prawodawca złagodził nieznacznie niektóre z propozycji, jednak rozporządzenie przyjęte 7 grudnia 2016 roku (Rozporządzenie 2016) posłużyło do podziału dotacji już w 2017 roku.

W debacie nad algorytmem, obok zagadnienia wysokiej stałej przeniesienia przed zmianami z końca 2016 roku we wcześniejszych latach, podnoszone były też głosy wskazujące na m.in. zbyt dużą liczbę składników algorytmu czy problem relacji liczebności kadry do liczby kształconych studentów (np. Jurek 2015: 89, 106; Cieśliński 2016: 159–161). Nowe rozporządzenie dokonało istotnej modyfikacji i w tych obszarach. Zmiany składników i ich wag przedstawia Tabela 1.

Tabela 1. Wagi składników w algorytmach podziału dotacji podstawowej dla szkół akademickich stosowanych w 2016 i od 2017 roku

l.p.	do 2016 roku		od 2017 roku	
	składnik	waga	składnik	waga
1	stała przeniesienia C	0.65	stała przeniesienia C	0.50 (0.57 w 2017)
2	studencko-doktorancki W_s	0.35	studencko-doktorancki W_s	0.40
3	kadrowy W_k	0.35	kadrowy W_k	0.45
4	proporcjonalnego rozwoju kształcenia W_d	0.10	-	-
5	badawczy W_b	0.10	badawczy W_b	0.10
6	uprawnień W_u	0.05	-	-
7	wymiany W_w	0.05	umiędzynarodowienia W_u	0.05

Źródło: opracowanie własne.

Warto zwrócić uwagę na istotny wzrost znaczenia składników studencko-doktoranckiego oraz kadrowego, na który składają się wzrost ich wag przy jednoczesnym spadku wagi stałej przeniesienia. Dla składnika studencko-doktoranckiego jest to

(docelowo) zmiana z poziomu $0.35 \times 0.35 = 0.1225$ na $0.40 \times 0.50 = 0.20$; a dla kadrowego na $0.45 \times 0.50 = 0.225$.

Znaczenie poszczególnych składników

Zmiana liczby i wag składników algorytmu w Rozporządzeniu z 2016 roku wiąże się z istotnymi modyfikacjami w konstrukcji samych składników. O stałej przeniesienia była mowa powyżej³. Natomiast w składniku studentko-doktoranckim sam sposób obliczania liczby tzw. studentów przeliczeniowych w zasadzie nie uległ zmianie. Jest to nadal suma stacjonarnych studentów, doktorantów oraz uczestników rocznych kursów przygotowawczych do podjęcia nauki w języku polskim z odpowiednimi wagami. Dla studentów i doktorantów jest to wskaźnik kosztochłonności studiów i studiów doktoranckich, dodatkowo w przypadku doktorantów uwzględnia się fakt przyznania stypendium doktoranckiego z wagą 6.0, a bez stypendium 1.5 (było 5.0 i 1.0), zaś uczestnicy kursów języka polskiego mają stałą wagę 1.5. Wskaźniki kosztochłonności nie zostały jednak zmienione od 2012 roku⁴, co budzi istotne zastrzeżenia. Warto bowiem zauważyć (np. za Miłoszem), że wskaźniki te nie odzwierciedlają rzeczywistej relacji kosztów pomiędzy poszczególnymi kierunkami czy też różnic w kształceniu praktycznym i akademickim na pokrewnych kierunkach (Białek-Jaworska i Żukowski 2017: 82–83). Nadal przeliczeniowy student na kierunku o najniższej kosztochłonności (np. na prawie) ma wagę 1.0, a na kierunku „najdroższym” (np. na weterynarii) 3.0. Co ciekawe, *de facto* taki sam kierunek studiów prowadzony przed 2012 rokiem może mieć inną kosztochłonność niż kierunek bliźniaczy uruchomiony po tym terminie (np. ekonomia w Rozporządzeniu z 2010 roku⁵ ma wskaźnik 1.0, a z 2012 roku 1.5).

O ile sposób obliczania liczby studentów przeliczeniowych nie uległ praktycznie zmianie, to kluczowe znaczenie ma wprowadzenie wskaźnika dostępności dydaktycznej $d(i)$, czyli stosunku liczby studentów do liczby nauczycieli akademickich (*student-staff ratio*, SSR). Wskaźnik ten stanowi najważniejszy mechanizm mający w założeniu MNiSW ograniczyć umasowienie studiów.

W nowym rozporządzeniu prawodawca przyjął referencyjną liczbę studentów i doktorantów przypadających na nauczyciela akademickiego dla omawianej grupy szkół akademickich⁶ na poziomie $M=13$. Natomiast liczbę studentów i doktorantów przypadających na nauczyciela akademickiego w danej uczelni m oblicza się jako sumę wszystkich studentów i doktorantów stacjonarnych i niestacjonarnych

³ Dokładne wzory poszczególnych składników algorytmu patrz: Rozporządzenie 2016: Zał. 1.


⁴ Rozporządzenie 2012.

⁵ Rozporządzenie 2010.

⁶ Dla innych grup np. uczelni medycznych – $M=8$; artystycznych – $M=5,5$ (Rozporządzenie 2016: Zał. 1).

(na pełnym cyklu studiów lub studiów doktoranckich) podzieloną przez przeciętną liczbę nauczycieli akademickich zatrudnionych w roku poprzednim (w przeliczeniu na pełne etaty). W praktyce oznacza to, że do poziomu dostępności kadry o wartości równej 13 liczba studentów przeliczeniowych jest wyliczana zgodnie z powyżej omówionymi zasadami, gdyż $d(i)=1$. Natomiast w przypadku, gdy liczba studentów i doktorantów przypadających na nauczyciela jest wyższa od 13, to liczba studentów przeliczeniowych przemnażana jest przez wskaźnik $d(i)<1$ (zmianę wartości wskaźnika $d(i)$ dla poszczególnych wartości współczynnika m przedstawia Wykres 1).

Wykres 1. Wartość wskaźnika dostępności dydaktycznej $d(i)$ w zależności od wartości m




Źródło: opracowanie własne.

Praktyczne skutki zastosowania SSR w składniku studencko-doktoranckim prezentuje Wykres 2. W poniższym poglądowym przykładzie⁷ dla stałej liczby nauczycieli akademickich wynoszącej 500 etatów przeliczeniowych przyjęto różne liczby studentów od 6.5 tysięcy (uczelnia 1) do 10.5 tysięcy (uczelnia 10). Dla uproszczenia przyjęto, że wszyscy studenci to studenci stacjonarni o kosztachłonności studiów 1.0 (liczba studentów = liczba studentów przeliczeniowych = suma studentów przypadająca na sumę nauczycieli). Dla wskaźników m o wartości mniejszej lub równej 13 liczba studentów przeliczeniowych nie jest *de facto* korygowana, bo $d(i)=1$ (uczelnie 1 i 2). Powyżej 13 studentów na nauczyciela liczba studentów przeliczeniowych skorygowana o $d(i)$ jest wyraźnie mniejsza. Na przykład przy 15 studentach na nauczyciela akademickiego $d(i)=0.75$, czyli z 7.5 tysiąca studentów przeliczeniowych „zostaje”

⁷ Ze względu na dostępne dane, ale także charakter artykułu, który ma przede wszystkim wyjaśniać mechanizmy podziału dotacji, poniższe przykłady mają uproszczony charakter i nie mogą stanowić materiału do symulacji podziału dotacji podstawowej.

5633 (uczelnia 4); przy $m=17$: $d(i)=0.58$, czyli z 8500 „zostaje” 4971 (uczelnia 6); zaś przy $m=21$: $d(i)=0.38$, czyli z 10500 „zostaje” 4024 (uczelnia nr 10).

Wykres 2. Wpływ wskaźnika dostępności dydaktycznej $d(i)$ na liczbę studentów przeliczeniowych



Źródło: opracowanie własne.

Należy pamiętać, że wartość każdego składnika dla danej uczelni jest obliczana na tle wartości składnika dla sumy uczelni w grupie.

W przypadku drugiego kluczowego elementu algorytmu, jakim jest składnik kadrowy, sam sposób obliczania liczby etatów także nie uległ istotnym zmianom. Profesor tytułarny ma wagę 2.5, doktor habilitowany 2.0, doktor 1.5, a magister 1.0. Osoby niebędące na pierwszym etacie liczone są osobno z takimi samymi wagami, ale suma ich etatów przeliczeniowych mnożona jest przez 0.5. Nie mają zatem znaczenia stanowiska nauczycieli akademickich (np. doktor habilitowany na stanowisku adiunkta = doktor habilitowany na stanowisku profesora nadzwyczajnego i ma wagę 2.0), liczą się zatem tytuły i stopnie naukowe oraz tytuły zawodowe magistra lub równorzędne. W przypadku zagranicznych profesorów wizytujących⁸ wprowadzono jedną wagę 4.0, jeżeli przeprowadzili co najmniej 60 godzin zajęć dydaktycznych w poprzednim roku akademickim (wcześniej występowali z wagami 4.0 lub 5.0,

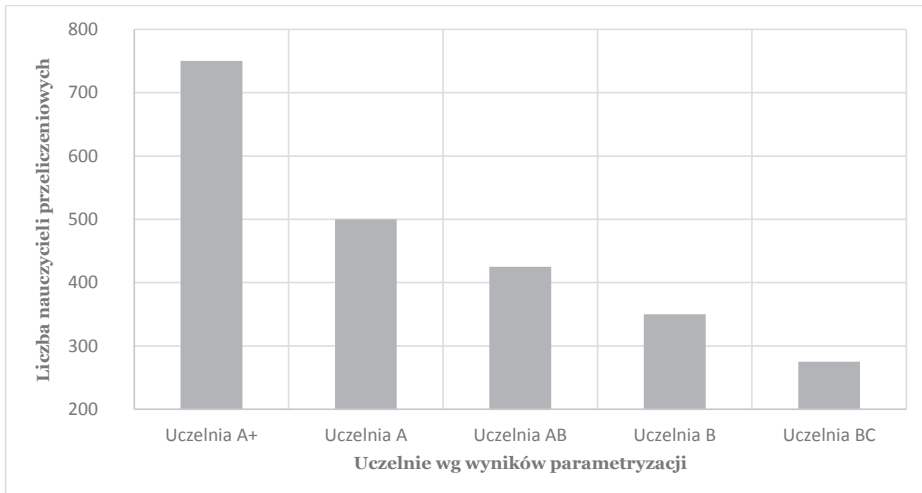
⁸ Osoby niebędące obywatelami polskimi i posiadające tytuł profesora lub zatrudnione na stanowisku profesora w innej uczelni lub instytucji naukowej polskiej lub zagranicznej (Rozporządzenie 2016: Zał. 1). Zatem cudzoziemiec zatrudniony na etat albo jego część wchodzi do grupy z resztą kadry (z odpowiednią wagą).

gdy rzeczony 60 godzin zajęć miało miejsce w czasie pobytu powyżej 3 miesięcy). Kluczową zmianą jest natomiast przemnażanie liczby etatów przeliczeniowych przez nowy wskaźnik potencjału naukowego $Y(i)$. Wskaźnik ten to średnia z wag za przyznane przez Komitet Ewaluacji Jednostek Naukowych (KEJN) jednostkom uczelni kategorii naukowe: A+ – 1.5, A – 1.0, B – 0.7, C – 0.4. Oznacza to, że dla uczelni, gdzie wszystkie jednostki naukowe otrzymały kategorię naukową A, etaty przeliczeniowe nie będą korygowane, bo $Y(i)=1$.

Praktyczne skutki zastosowania wskaźnika potencjału naukowego w składniku kadrowym prezentuje Wykres 3. Dla uproszczenia przyjęto stałą liczbę etatów przeliczeniowych równą 500, które przeliczane są dla uczelni o różnych kategoriach naukowych ich czterech jednostek:

- „uczelnia A+” mająca 4 kategorie A+, czyli $Y(i)=1.5$,
- „uczelnia A” mająca 4 kategorie A, czyli $Y(i)=1$,
- „uczelnia AB” mająca 2 kategorie A i 2 kategorie B, czyli $Y(i)=0.85$,
- „uczelnia B” mająca 4 kategorie B, czyli $Y(i)=0.7$,
- „uczelnia BC” mająca 2 kategorie B i 2 kategorie C, czyli $Y(i)=0.55$.

Wykres 3. Znaczenie wskaźnika potencjału naukowego



Źródło: opracowanie własne.

Warto zauważyć, że w ocenach parametrycznych z 2013 roku (por. niżej) dominuje kategoria naukowa B, zatem przy obliczaniu wartości nowego składnika kadrowego zyskują już uczelnie mające większość ocen co najmniej A.

W składniku badawczym nastąpiło zrównanie wag konsorcjantów z wagami dla liderów w projektach badawczych. Zachowano wagi ze względu na typy projektów tj. krajowe 1.0, międzynarodowe 2.0, a w ramach programu Horyzont 2020 – 4.0.

Natomiast składnik umiędzynarodowienia zastąpił dotychczasowy składnik wymiany. Podstawową zmianą jest uwzględnienie cudzoziemców podejmujących studia lub studia doktoranckie na pełnym cyklu w danej uczelni z wagą 3.0. Natomiast w przypadku wymiany akademickiej powyżej 3 miesięcy (np. w ramach programu Erasmus+) studenci wyjeżdżający są liczeni z wagą 1.0, a przyjeżdżający z zagranicy z wagą 2.0 (było 3.0).

Prawodawca przewidując możliwość dużych zmian r/r w wysokości dotacji dla poszczególnych uczelni, wprowadził zasadę, że jeżeli część zasadnicza dotacji podstawowej obliczona na podstawie nowego algorytmu będzie niższa niż 95% dotacji z roku poprzedniego (w warunkach porównywalnych), to różnica do tej wysokości (tj. 95%) będzie wyrównana. Analogicznie – gdyby dotacja obliczana według nowego wzoru miała być wyższa niż 105% dotacji z roku poprzedniego, to przyznane środki i tak nie będą mogły przekroczyć rzeczonych 105%.

Z kolei w przypadku konsolidacji szkół wyższych wprowadzono premię za połączenie. Przez pięć kolejnych lat od połączenia wysokość dotacji będzie wyrównywana do 103% sumy dotacji podstawowych przyznanych połączonym uczelniom w roku połączenia (albo w przypadku włączenia jednej uczelni publicznej do drugiej) w warunkach porównywalnych. Z takiego bonusu skorzystały w 2017 roku Uniwersytet Zielonogórski (włączenie PWSZ w Sulechowie) oraz Uniwersytet Jana Kochanowskiego w Kielcach (włączenie PWSZ w Sandomierzu). Należy przy tym zauważyć, że obie PWSZ zostały zlikwidowane ze względu na bardzo małą liczbę studentów, zatem wpływ na dotację dla UZ czy UJK był ograniczony⁹.

Skutki bezpośrednie i pośrednie zmiany algorytmu

Istotne zmiany w wysokości dotacji podstawowej to najważniejszy, bezpośredni skutek wprowadzenia nowego algorytmu. Aż 19 uczelni w omawianej grupie szkół akademickich w 2017 roku otrzymało dotację niższą o 5%, kolejnych 6 między -4.4% a -3.02%. Po przeciwnej stronie tabeli z wysokością dotacji 9 uczelni zyskało 5%, kolejne 11 między 2.98% a 4.91%. Można przyjąć, że dla większości szkół o zmianie (spadek/wzrost) dotacji r/r o równo 5% zastosowany został mechanizm zabezpieczający przed zbyt dużymi wahaniami wysokości dotacji (por. wyżej).

W grupie najbardziej stratnych (-5%) szkół znalazły się przede wszystkim uczelnie o bardzo niekorzystnym (z punktu widzenia przyjętego przez prawodawcę parametru referencyjnego $M=13$) stosunku liczby studentów do kadry od około $m=15$

⁹ Na podstawie danych uzyskanych z MNiSW.

do $m=25$, przy jednoczesnym niższym składniku kadrowym wynikającym z dominujących kategorii B (w 2017 roku obowiązywały oceny z kategoryzacji z 2013 roku). Najbardziej stratne uczelnie o dobrym SSR na poziomie około $m=12$ miały z kolei skrajnie niskie kategorie naukowe. Najwięksi beneficjenci nowego podziału w 2017 roku to uczelnie o zbliżonym do „optymalnego” (czyli $M=13$) SRR – od około $m=12$ do $m=14.5$ i licznymi jednostkami z kategorią A ($Y(i)>0.8$). Można przyjąć, że dla wielu szkół wysokie kategorie naukowe pozwoliły zniwelować przez składnik kadrowy „straty” na niekorzystnym SRR dla składnika studencko-doktoranckiego. Nie bez znaczenia pozostaje fakt, że ogólnie w grupie omawianych uczelni liczba studentów w przeliczeniu na nauczyciela przekraczała modelowe $M=13$, a dominującą kategorią naukową była kategoria B. W tych okolicznościach znaczenie składników umiędzynarodowienia i badawczego, ze względu na ich niskie wagi, pozostaje mało istotne. Co więcej, składnik badawczy w dużej mierze będzie jednak powiązany z kategoriami naukowymi KEJN. Pełne zestawienie wysokości dotacji podstawowej wraz z wartościami wskaźników m i $Y(i)$ zawiera Załącznik 1.

Jak zauważa prawodawca, „wbrew wcześniejszym obawom nowy sposób podziału dotacji nie różnicuje ze względu na kryterium geograficzne czy też wielkościowe” (MNiSW 2017a: 7). Jest to w zasadzie zgodne z prawdą, choć w grupie uczelni +5% znalazły się m.in. Uniwersytet Jagielloński, Uniwersytet Warszawski, Uniwersytet im. Adama Mickiewicza, Akademia Górniczo-Hutnicza i Politechnika Warszawska, a zatem polskie uczelnie najwyżej notowane w różnych światowych rankingach (por. np. Górniak 2015) i będące liderami rankingów krajowych. Nowy algorytm okazał się natomiast niekorzystny dla dwóch typów uczelni akademickich – uniwersytetów ekonomicznych (z wyjątkiem Szkoły Głównej Handlowej w Warszawie) oraz akademii wychowania fizycznego. W pierwszym przypadku decydująca była bardzo duża liczba studentów przypadająca na nauczyciela akademickiego (nawet 28.8 dla UE w Krakowie) przy dobrych kategoriach naukowych (w przypadku SGH bardzo wysokie $Y(i)=1.2$). Z kolei AWF-y, obok dość wysokich wskaźników SSR, miały głównie kategorie naukowe B.

Jednym z celów jaki przyświecał MNiSW przy wprowadzaniu nowego algorytmu była poprawa jakości kształcenia poprzez poprawę dostępności kadry. Przy czym zagadnienie realnego wpływu SSR na faktyczną jakość kształcenia nie jest przedmiotem niniejszego opracowania. W 2017 roku uczelnie praktycznie nie miały możliwości wpływu na liczbę studentów czy kadry w roku akademickim 2016/2017. Dlatego działania w tym obszarze podjęto w związku z rekrutacją na rok akademicki 2017/2018. Odpowiedź na pytanie, na ile trendy demograficzne czy popyt na konkretną ofertę edukacyjną miały wpływ na wyniki rekrutacji, a na ile stały za tym nowe limity rekrutacyjne przyjęte przez uczelnie, wymagałoby dokładnej analizy m.in. uchwał rekrutacyjnych z kilku minionych lat. Z pewnością natomiast liczne

uczelnie redukowały limity przyjęć przynajmniej na niektórych kierunkach, o czym dość szeroko informowały media (np. Mirowska-Łoskot 2017; Zdrojewski 2017).

Ogólnie w 2017 roku spośród 60 uczelni akademickich tylko 17 w zasadzie nie miało niższych naborów. Pozostałe 43 uczelnie przyjęły mniej studentów niż rok wcześniej. Ogółem w tej grupie szkół wyższych przyjęto około 8% mniej studentów na pierwszy rok. Analizując wyniki rekrutacji¹⁰, można zaobserwować, że większość uczelni, które w 2017 r. straciły 5% dotacji, w rekrutacji na rok akademicki 2017/2018 przyjęła znacząco mniej studentów niż rok wcześniej (Tabela 2). Skala redukcji przyjęć sięgnęła nawet 49% (AWF w Katowicach w 2016 roku przyjęła 1.94 tysięcy studentów, a w 2017 roku – tylko 0.98 tysiąca).

Tabela 2. Zmiana w liczbie kandydatów przyjętych na studia w 2017 r. w stosunku do 2016 r. w wybranych uczelniach akademickich

L.p.	Nazwa uczelni	Zmiana w rekrutacji	% zmiana
1	Akademia Wychowania Fizycznego w Katowicach	-962	-49%
2	Uniwersytet Kardynała Stefana Wyszyńskiego w Warszawie	-1 930	-35%
3	Akademia Wychowania Fizycznego w Krakowie	-607	-31%
4	Akademia Wychowania Fizycznego w Poznaniu	-663	-31%
5	Politechnika Rzeszowska	-1 635	-31%
6	Politechnika Białostocka	-955	-30%
7	Politechnika Gdańska	-1 735	-29%
8	Akademia Pedagogiki Specjalnej w Warszawie	-800	-29%
9	Akademia Wychowania Fizycznego i Sportu w Gdańsku	-310	-27%
10	Uniwersytet Technologiczno-Humanistyczny w Radomiu	-481	-23%
11	Uniwersytet Ekonomiczny w Poznaniu	-809	-17%
12	Uniwersytet Ekonomiczny w Katowicach	-701	-15%
13	Akademia Techniczno-Humanistyczna w Bielsku-Białej	-324	-13%
14	Politechnika Świętokrzyska	-156	-8%
15	Uniwersytet Ekonomiczny we Wrocławiu	88	2%

Źródło: opracowanie własne na podstawie danych z MNiSW.

¹⁰ Dane w oparciu o sprawozdania uczelni EN1 za 2017 rok uzyskane z MNiSW.

Wstępne wnioski

Modyfikacje algorytmu zwiększyły wpływ zmiany liczby studentów na dynamikę zmiany dotacji, przy czym związały tę dynamikę z potencjałem kadrowym. Modyfikacja składnika kadrowego poprzez uwzględnienie kategorii naukowych KEJN sprzyja uczelniom mocnym naukowo. Jednocześnie ze względu na fakt, że kategorie naukowe przyznawane są przez KEJN na cztery lata, dość mocno ogranicza to możliwości działania uczelni w celu poprawy wyników w tej części algorytmu. Dużo bardziej widoczne są działania szkół wyższych na rzecz poprawy wskaźnika dostępności kadry, przy czym przyjmują one głównie formę redukcji naborów na najbardziej umasowione studia. W przypadku polityki kadrowej bliższe szacunki będą możliwe dopiero późną wiosną 2018 roku, kiedy Ministerstwo dokona zestawienia sprawozdań uczelni za rok 2017. Co prawda niektóre uczelnie wprowadziły nowe etaty asystentów (bez doktoratu), nieraz przy jednoczesnej wyraźnej redukcji naborów na studia doktoranckie, ale należy przypuszczać, że jest to efekt zmiany innych przepisów. W związku z nowymi przepisami dotyczącymi studiów doktoranckich połowa doktorantów stacjonarnych musi otrzymywać stypendia doktoranckie (w wysokości co najmniej 60% podstawy uposażenia asystenta). Instytucje, które prowadzą masowe studia doktoranckie, gdzie niewielu doktorantów otrzymuje stypendia, miały mocny bodziec do ograniczenia naborów. I w sytuacji, gdy np. większość doktorantów w ramach praktyk dydaktycznych prowadziła zajęcia ze studentami (dopuszczalne maksymalnie 90 godzin rocznie), korzystne może być uzupełnienie powstałej luki przez zatrudnienie asystentów (z pensum np. 240 godzin rocznie). Tym bardziej, że nowe etaty dodatkowo poprawią wskaźnik jakości dydaktycznej (Lewicki 2016).

Omawiając wpływ kategorii naukowych na dotację podstawową, nie sposób nie wspomnieć o skutkach jakie wywoła nowa kategoryzacja KEJN w podziale dotacji w 2018 roku. W efekcie oceny z 2017 roku¹¹ spośród 60 uczelni akademickich tylko 15 poprawiło swój wskaźnik potencjału naukowego $Y(i)$, natomiast blisko połowa (28 uczelni) uzyskało gorsze niż w poprzedniej czterolatce wyniki parametryzacyjne. 17 uczelni utrzymało swoje oceny. Przeciętny wskaźnik $Y(i)$ wynosi obecnie 0.78, wobec 0.81 w poprzedniej czterolatce (na podstawie danych MNiSW). Dla wielu uczelni przeloży się to na wyraźną zmianę wysokości dotacji r/r . Oczywiście wielkość tej zmiany zależy będzie także od podjętych kroków we wspomnianym obszarze liczby studentów, działań podejmowanych przez inne uczelnie w grupie oraz globalnych nakładów budżetowych na szkolnictwo wyższe. Według wstępnych szacunków Marcina Kędzierskiego i Pauli Koleśnik znacząco zyska np. Politechnika Gdańska, która była bardzo stratna w 2017 roku. Z kolei UAM (beneficjent z 2017

¹¹ Dane przed rozpatrzeniem odwołań od oceny KEJN.

roku) w 2018 roku odnotuje wyraźną stratę (zob. Kędzierski i Koleśnik 2018). Przykłady kolejnych dziesięciu uczelni o największym wzroście i kolejnych dziesięciu o największym spadku wskaźnika $Y(i)$ przedstawia Tabela 3.

Tabela 3. Zmiana wartości wskaźnika $Y(i)$ za 2016 roku i od 2017 roku dla wybranych uczelni akademickich

L.p.	Nazwa uczelni	Wskaźnik $Y(i)$ 2016	Wskaźnik $Y(i)$ 2017	Zmiana $Y(i)$
1	Politechnika Gdańska	0.80	1.04	0.24
2	Uniwersytet Pedagogiczny w Krakowie	0.65	0.85	0.20
3	Akademia Wychowania Fizycznego w Katowicach	0.70	0.85	0.15
4	Politechnika Częstochowska	0.75	0.85	0.10
5	Uniwersytet Przyrodniczy we Wrocławiu	0.88	0.98	0.10
6	Uniwersytet Kazimierza Wielkiego w Bydgoszczy	0.70	0.79	0.09
7	Politechnika Śląska	0.83	0.91	0.09
8	Akademia Górniczo-Hutnicza w Krakowie	0.94	1.02	0.08
9	Uniwersytet Ekonomiczny w Katowicach	0.85	0.93	0.08
10	Akademia Wychowania Fizycznego w Warszawie	0.63	0.70	0.07
11	Akademia Techniczno-Humanistyczna w Bielsku-Białej	0.70	0.58	- 0.12
12	Uniwersytet Warmińsko-Mazurski w Olsztynie	0.86	0.74	- 0.12
13	Politechnika Opolska	0.80	0.65	- 0.15
14	Szkoła Główna Handlowa w Warszawie	1.20	1.04	- 0.16
15	Uniwersytet Wrocławski	1.01	0.85	- 0.16
16	Zachodniopomorski Uniwersytet Technologiczny w Szczecinie	0.82	0.64	- 0.18
17	Uniwersytet Technologiczno-Humanistyczny w Radomiu	0.63	0.44	- 0.19
18	Akademia Wychowania Fizycznego w Poznaniu	0.70	0.50	- 0.20
19	Uniwersytet Ekonomiczny we Wrocławiu	1.00	0.78	- 0.23
20	Uniwersytet Ekonomiczny w Krakowie	1.00	0.70	- 0.30

Źródło: opracowanie własne na podstawie danych z MNiSW, stan na styczeń 2018 roku.

W kontekście wpływu kategorii naukowych na podział dotacji podstawowej zbędny wydaje się wskaźnik badawczy, na który składają się elementy (m.in. granty), i tak też jest on oceniany przez KEJN. Można zatem rozważyć np. podniesienie wagi wskaźnika umiędzynarodowienia, który zresztą w pierwszej koncepcji zmiany algorytmu miał mieć dwukrotnie wyższą wagę niż ta przyjęta w rozporządzeniu z 2016 roku (0.1 wobec 0.05). Można także rozważyć wprowadzenie w to miejsce nowego wskaźnika promującego mobilność kadr poprzez zatrudnianie nauczycieli akademickich, którzy stopnie naukowe uzyskali poza daną uczelnią¹².

W kontekście wewnętrznych polityk poszczególnych uczelni warto zauważyć za Piotrem Modzelewskim i Marcinem Dwórznikiem, że 4 na 5 badanych uczelni stosowało zdecentralizowany system zarządzania finansami i przy podziale środków z dotacji podstawowej stosuje algorytmy podziału zbliżone do algorytmu MNiSW. Uczelnie te przeznaczają na potrzeby administracji centralnej i tzw. rezerwy rektorskiej około 5–10% dotacji (choć zidentyfikowano przypadek nawet 20%) (Modzelewski i Dwórznik 2017: 197–199). Wprowadzenie nowego algorytmu w 2017 roku mogło wywołać zatem liczne napięcia w mocno zróżnicowanych wewnętrznie uczelniach tj. w szczególności takich, gdzie występują zarówno jednostki o dobrym (z punktu widzenia algorytmu) SSR i wysokiej kategorii naukowej oraz o gorszym SSR i niższej kategorii. Warto także zwrócić uwagę, że w przypadku niektórych uczelni kategoryzacji naukowej poddane zostały (w 2013, jak i 2017 roku) zarówno podstawowe jednostki organizacyjne co do zasady prowadzące studia, jak i jednostki o charakterze wyłącznie badawczym (prowadzące co najwyżej kształcenie na poziomie doktorskim). Uwzględnienie ocen KEJN we wskaźniku potencjału naukowego mogło mieć zatem wpływ (pozytywny albo negatywny) na składnik kadrowy, nawet jeżeli dana jednostka nie uczestniczy w procesie dydaktycznym. Z kolei nagła zmiana zasad podziału środków w 2017 roku i nowe wyniki oceny KEJN wpływające na podział w 2018 roku znacząco ograniczyły szanse na wprowadzenie w uczelniach odpowiednich zmian organizacyjnych. Trzeba podkreślić, że dokładna analiza na poziomie pojedynczych uczelni, jak i całego systemu jest bowiem nie tylko czasochłonna, ale zwyczajnie bardzo trudna ze względu choćby na pomiar kosztów kształcenia. Jak zauważają Urszula Sztanderska i Gabriela Grotkowska (2017: 13), zwykle nie są one bowiem bezpośrednio obserwowalne, a uczelnie publiczne mają trudność w ocenie, np. jaką część wynagrodzenia pracowników naukowo-dydaktycznych stanowią koszty kształcenia, a jaką działalność badawcza czy popularyzatorska. Opracowanie nowych zasad oceny kosztochłonności studiów oraz nowych wskaźników na ich podstawie powinny być kolejnym krokiem prawodawcy w obszarze modernizacji zasad finansowania szkolnictwa wyższego.

¹² Taką zmianę zaproponował m.in. Piotr Stec w dyskusji z autorem niniejszego opracowania.

Obserwacja skutków nowego algorytmu, jak i reakcji szkół wyższych na te zmiany powinna być także cennym doświadczeniem w kontekście planowanej reformy systemu nauki i szkolnictwa wyższego.

Literatura

- Białek-Jaworska, A. (2017). Koszty działalności dydaktycznej szkół wyższych i źródła ich finansowania w świetle danych zastanych (ss. 114–190). W: U. Sztanderska i G. Grotkowska (red.), *Koszty kształcenia wyższego*. Warszawa: Wydawnictwa Uniwersytetu Warszawskiego.
- Białek-Jaworska, A. i Żukowski, M. (2017). Prawne uwarunkowania kształtowania kosztów kształcenia i ich finansowania w szkołach wyższych (ss. 75–113). W: U. Sztanderska i G. Grotkowska (red.), *Koszty kształcenia wyższego*. Warszawa: Wydawnictwa Uniwersytetu Warszawskiego.
- Cieśliński, J.L. (2016). Algorytm podziału dotacji podstawowej dla polskich uczelni akademickich. *Nauka*. 1: 159–180.
- EUA. (2017). *University Autonomy in Europe III Country Profiles*. Brussels: European University Association. <http://www.eua.be/Libraries/publications-homepage-list/university-autonomy-in-europe-iii-country-profiles.pdf?sfvrsn=8> [20.01.2018].
- European Commission, EACEA, Eurydice. (2018). *The European Higher Education Area in 2018: Bologna Process Implementation Report*. Luxembourg: Publications Office of the European Union. https://eacea.ec.europa.eu/national-policies/eurydice/content/european-higher-education-area-2018-bologna-process-implementation-report_en [20.01.2018].
- GUS. (2017). *Szkoły wyższe i ich finanse w 2016 r.* Warszawa: Główny Urząd Statystyczny.
- Górniak, J. (red.) (2015). *Diagnoza szkolnictwa wyższego. Program rozwoju szkolnictwa wyższego do 2020 r. Część III*. Warszawa: FRP, KRASP.
- Jurek, W. (2015). Koszty i jakość kształcenia w podziale funduszy publicznych przeznaczonych na finansowanie szkolnictwa wyższego (ss. 87–95). W: J. Wilkin (red.), *Finansowanie szkół wyższych ze środków publicznych: Program rozwoju szkolnictwa wyższego do 2020 r. Część IV*. Warszawa: FRP, KRASP.
- Kędzierski, M. i Koleśnik, P. (2018). Reforma szkolnictwa wyższego już się rozpoczęła. <http://cakj.pl/2018/01/25/reforma-szkolnictwa-wyzszego-juz-sie-rozpoznecala/> [10.06.2018].
- Leja, K. (2013). *Zarządzanie uczelnią*. Warszawa: Wolters Kluwer Polska.
- Lewicki, J. (2016). Uczelnie publiczne czekają zmiany zasad finansowania, *obserwatorfinansowy.pl*. 14 listopada. <https://www.obserwatorfinansowy.pl/forma/rotator/uczelnie-publiczne-zmiany-zasad-finansowania/> [6.01.2018].
- Mirowska-Łoskot, U. (2017). Rok akademicki 2017/2018: Uczelnie przykręcą śrubę studentom. *gazetaprawna.pl*. 23 stycznia. <http://serwisy.gazetaprawna.pl/edukacja/artykuly/1012777,rok-akademicki-2017-2018-mniej-miejsc-dla-studentow.html> [8.01.2018].

- MNiSW. (2017a). Informacja na temat funkcjonowania nowego algorytmu podziału dotacji z budżetu państwa dla uczelni publicznych i niepublicznych oraz ocena dotychczasowych rezultatów jego wprowadzenia. Materiał dla Podkomisji stałej [Sejmu] ds. nauki szkolnictwa wyższego. Warszawa.
- MNiSW. (2017b). *Raport z konsultacji projektu rozporządzenia Ministra Nauki i Szkolnictwa Wyższego zmieniającego rozporządzenie w sprawie sposobu podziału dotacji z budżetu państwa dla uczelni publicznych i niepublicznych*. <http://legislacja.rcl.gov.pl/docs//506/12290652/12383174/12383178/dokument258272.pdf> [10.01.2018].
- Modzelewski, P. i Dwórznik, M. (2017). Ewidencja i zarządzanie kosztami w szkołach wyższych (ss. 191–228). W: U. Sztanderska i G. Grotkowska (red.), *Koszty kształcenia wyższego*. Warszawa: Wydawnictwa Uniwersytetu Warszawskiego.
- Pakuła, W. (1994). Wybrane problemy gospodarki finansowej szkół wyższych w Polsce, *Nauka i Szkolnictwo Wyższe*. 3: 88–97.
- Rozporządzenie Ministra Nauki i Szkolnictwa Wyższego z dn. 9 lutego 2012 r. w sprawie sposobu i trybu ustalania kosztochłonności dla poszczególnych kierunków studiów stacjonarnych pierwszego i drugiego stopnia, jednolitych studiów magisterskich oraz obszarów kształcenia, a także dla stacjonarnych studiów doktoranckich, Dz.U. 2015, poz. 998.
- Rozporządzenie Ministra Nauki i Szkolnictwa Wyższego z dn. 9 kwietnia 2010 r. zmieniające rozporządzenie w sprawie wskaźników kosztochłonności poszczególnych kierunków, makrokierunków i studiów międzykierunkowych studiów stacjonarnych oraz stacjonarnych studiów doktoranckich w poszczególnych dziedzinach nauki. Dz.U. z 2010 nr 65, poz. 413.
- Rozporządzenie Ministra Nauki i Szkolnictwa Wyższego z dn. 7 grudnia 2016 r. zmieniające rozporządzenie w sprawie sposobu podziału dotacji z budżetu państwa dla uczelni publicznych i niepublicznych. Dz.U. z 2016, poz. 2016.
- Sztanderska, U. i Grotkowska, G. (2017). Wprowadzenie. W: U. Sztanderska i G. Grotkowska (red), *Koszty kształcenia wyższego*, Warszawa: Wydawnictwa Uniwersytetu Warszawskiego.
- Zdrojewski, D. (2017). Niektóre uczelnie przyjmą mniej studentów. Przez zmiany zasad finansowania szkół wyższych. *polsatnews.pl*. 17 stycznia. <http://www.polsatnews.pl/wiadomosc/2017-01-17/niektore-uczelnie-przyjma-mniej-studentow-przez-zmiany-zasad-finansowania-szkol-wyzszych/> [8.01.2018].

A new algorithm of allocation for basic subsidy for universities in Poland. First results of changes and preliminary conclusions

ABSTRACT: Teaching activity makes about 60% of incomes of public universities in Poland. At the end of 2016, the Ministry of Science and Higher Education in Poland modified the rules for the allocation of this subsidy. The key changes for the academic schools were the linking of the amount of funds allocated to the number of students per academic teacher (student-staff ratio)

and the consideration of the scientific categories (classes) held by the universities. The existence of a new subsidy allocation algorithm in 2017 resulted in large changes in the amount of subsidies for many universities, which undertook adaptation activities like reducing recruitment for the next academic year. In 2018, a new evaluation of science caused further changes in the distribution of subsidies.

KEYWORDS: basic subsidy, algorithm, university funding, Poland

CYTOWANIE: Lewicki, J. (2018). Nowy algorytm podziału dotacji podstawowej dla uczelni akademickich. Pierwsze skutki zmian i wstępne wnioski. *Nauka i Szkolnictwo Wyższe*. 2(52): 171–187. DOI: 10.14746/nisw.2018.2.6

JACEK LEWICKI – adiunkt w Ośrodku Rozwoju Studiów Ekonomicznych w Szkole Głównej Handlowej w Warszawie. Doktor nauk społecznych w dyscyplinie nauki o polityce (Uniwersytet Jagielloński w Krakowie, 2013 rok), ekspert ds. postępowania oceniającego Polskiej Komisji Akredytacyjnej. Pracował m.in. w Instytucie Badań Edukacyjnych w Warszawie (2013–2015) w projekcie krajowych ram kwalifikacji. Pełnił funkcje m.in. wiceprezesa Fundacji Młodej Nauki (2013–2017), Członka Rady Młodych Naukowców przy Ministrze Nauki i Szkolnictwa Wyższego (2012–2015), eksperta ds. doktoranckich PKA (2012–2013), eksperta bolońskiego (2011–2013), wiceprzewodniczącego Krajowej Reprezentacji Doktorantów (2009–2011).

WYWIAD

Joanna Wolszczak-Derlacz

Otwarty dostęp do statystyk uczelni powinien być czymś normalnym! Wywiad z Benedetto Leporim, koordynatorem European Tertiary Education Register (ETER)¹

STRESZCZENIE: Wywiad dotyczy wyzwań związanych z tworzeniem publicznie dostępnej i zharmonizowanej bazy obejmującej dane na temat poszczególnych instytucji szkolnictwa wyższego z krajów europejskich: European Tertiary Education Register (ETER) oraz możliwości wykorzystania jej do porównań międzynarodowych. Benedetto Lepori przekonuje w nim, że ogólny dostęp do danych na poziomie indywidualnych uczelni powinien być czymś normalnym. Dodatkowo uważa, że wykorzystywanie podejścia nakłady-wyniki wraz z zaawansowanymi narzędziami badawczymi w zakresie oceny efektywności i produktywności jest zasadne z punktu widzenia stawianych pytań badawczych, jednak nie powinno się ich automatycznie stosować np. do ewaluacji uniwersytetów czy dystrybucji środków finansowych.

SŁOWA KLUCZOWE: ETER, otwarty dostęp do danych, dane na poziomie indywidualnych uczelni

JOANNA WOLSZCZAK-DERLACZ: ETER (<https://www.eter-project.com/>) to pierwsza tak obszerna baza danych dotyczących europejskich instytucji szkolnictwa wyższego, która obecnie jest dostępna za darmo online i obejmuje 2764 instytucje z 36 państw. Dla 31 krajów dostępne są z kolei dane jednostkowe. Obecnie dostępne dane obejmują okres od roku akademickiego 2011/2012 do 2015/2016. ETER jest wspólną inicjatywą Komisji Europejskiej wspieraną i zarządzaną przez Joint Research Centre i Directorate General Education and Culture. Czy mógłby Pan opowiedzieć o genezie powstania bazy ETER oraz inicjatywach, które ją poprzedzały?

¹ Benedetto Lepori – koordynator European Tertiary Education Register (ETER) z ramienia Università della Svizzera Italiana (USI) i koordynator naukowy programu ramowego Unii Europejskiej Horyzont 2020 KNOWMAK poświęconego tworzeniu Europejskiej Mapy Nauki i Technologii. Wywiad przeprowadzono 24 listopada 2018 roku.

BENEDETTO LEPORI: To stosunkowo długa historia, która rozpoczęła się mniej więcej w 2003–2004 roku, gdy Andrea Bonaccorsi, profesor na Uniwersytecie w Pizie, postawił pytanie dotyczące możliwości stworzenia bazy danych o poszczególnych europejskich instytucjach szkolnictwa wyższego. W tamtym czasie nikt nie wierzył w taką możliwość. Nawet Eurostat publikował wyłącznie dane dotyczące regionu czy poszczególnych państw. Andrea rozpoczął pracę w ramach projektu europejskiego. Początkowo był to eksperyment na niewielką skalę. W ramach AQUAMETH², bo tak nazywał się projekt, zbierano dane z około 8–10 państw europejskich, które pochodziły ze źródeł administracyjnych takich jak urzędy statystyczne, raporty z konferencji rektorskich itd. Projekt ten trwał dwa czy trzy lata. Miał on bardziej charakter naukowy, ale w pewnym sensie udało nam się (byłem częścią tego zespołu) udowodnić, że co do zasady zbieranie i doprowadzanie tych danych do postaci pozwalającej na porównania jest w ogóle możliwe. Rzecz jasna na tamtym etapie nigdy nie myśleliśmy, że doprowadzimy te dane do postaci pozwalającej na pełne porównania międzynarodowe. Projekt szybko został zauważony, a ze zgromadzonych danych powstało wiele książek i artykułów, co pokazało zainteresowanie podejściem porównawczym.

J.W-D.: Czyli ta pierwsza inicjatywa przeobraziła się automatycznie w kolejne projekty?

B.L.: Nie, dopiero kilka lat później, mniej więcej w 2011 roku udało się przekonać Komisję Europejską do uruchomienia dużego programu pilotażowego polegającego na zbieraniu danych. W ten sposób Komisja uruchomiła program EUMIDA³, w którym brały udział te same osoby. Właściwie to ten sam zespół, który obecnie pracuje w ramach programu ETER. Naszym głównym zadaniem było zbieranie danych na temat instytucji szkolnictwa wyższego ze wszystkich państw europejskich w oparciu o doświadczenie zbierania danych np. na temat liczby studentów, liczby osób kończących studia, finansów, kadry i badań z krajowych urzędów statystycznych w ramach projektu AQUAMETH. Projekt znów okazał się dużym sukcesem. Udało nam się zdobyć dane z większości krajów.

J.W-D.: Czy na tym etapie napotkali Państwo na jakieś znaczne problemy i trudności?

B.L.: Oczywiście pojawiły się pewne problemy, największe trudności napotkaliśmy z zebraniem danych dla uczelni francuskich, gdyż dane z tego kraju były

² Advanced Quantitative Methods for the Evaluation of the Performance of Public Sector Research

³ Feasibility Study for Creating a European University Data Collection

zaklasyfikowane jako poufne. W każdym razie, w ten sposób udało nam się stworzyć pierwszy zbiór danych, nawet jeśli wciąż znajdował się wyłącznie w Excelu, a sam proces dopiero się utrwał. Dla przykładu napisaliśmy szkic podręcznika metodologicznego i zaczęliśmy omawiać problemy metodologiczne, problemy związane z prowadzeniem porównań międzynarodowych itd. Następnie prace ustały na dwa czy trzy lata, ponieważ Komisja Europejska liczyła, że zbieranie danych przejmie Eurostat. Jednak okazało się, że Eurostat z różnych powodów nie jest zainteresowany zbieraniem mikrodanych dotyczących uniwersytetów. Spowodowało to jednak przerwę w pracach i dopiero pięć lat temu Komisja Europejska zdecydowała, by powrócić do projektu i zawrzeć umowę, w której ramach powstał ETER. Projekt ten korzysta z metodologii, którą stworzyliśmy w poprzednich latach, ale jego główne zadania są znacznie bardziej ambitne: to utrwalenie całego procesu i procedur, stworzenie bazy danych gwarantującej publiczny dostęp, standaryzacja zebranych danych, zapewnienie porównywalności i jakości samych danych itd. Po tej umowie nastąpiła kolejna, a obecnie projekt został przedłużony kolejny raz, więc na koniec tego etapu będziemy dysponować danymi z sześcioletniego okresu i wszystko wygląda na to, że systematycznie zmierzamy w stronę dużej zestandaryzowanej bazy dotyczącej europejskich uniwersytetów.

J.W-D.: Dziękuję Panu za to historyczne wprowadzenie. Konsorcjum składa się z pięciu partnerskich instytucji⁴ realizujących to przedsięwzięcie. Jak zorganizowane jest zbieranie danych w ramach projektu? Czy mają Państwo przedstawicieli/koordynatorów w każdym z krajów, w którym zbieracie dane?

B.L.: Proces zachodzi następująco. Po pierwsze, dysponujemy centralną bazą danych, która jest zarządzana przez Joanneum Research w Grazu i na jej podstawie tworzymy arkusze gromadzenia danych. W ten sposób powstaje standardowy plik w Excelu z wyróżnionymi poszczególnymi instytucjami, listą zmiennych itd. Następnie, w przypadku większości krajów, jesteśmy w bezpośrednim kontakcie z urzędami statystycznymi. W przypadku większości krajów to urzędy statystyczne dostarczają dane, a jeden z partnerów działa na poziomie bardziej centralnym, sprawdzając dane, rozwiązując problemy i czuwając nad tym procesem. W niektórych krajach wciąż mamy funkcję krajowego korespondenta, który pośredniczy w kontaktach między nami a państwowymi urzędami statystycznymi, gdyż zdarza się, że taki kontakt jest utrudniony. Dla przykładu w Polsce taką funkcję pełni Krzysztof Leja z Politechniki

⁴ Są to: USI – Università della Svizzera Italiana, Center for Organizational Research, Lugano; JOANNEUM RESEARCH, POLICIES – Centre for Economic and Innovation Research, Graz; NIFU – Nordic Institute for Studies in Innovation, Research and Education, Oslo; University of Rome La Sapienza, Department of Computer, Control and Management Engineering Antonio Ruberti, Rzym; University of Pisa, Department of Electrical Engineering, Piza.

Gdańskiej. Nie zbieramy danych sami. Zazwyczaj nie zbieramy również danych z raportów rektorskich poza kilkoma krajami, w których opracowujemy dane na podstawie informacji ze stron internetowych uniwersytetów.

J.W-D.: Jak radzą sobie Państwo z kwestią poufności danych? W ETER podają Państwo na przykład informacje dotyczące budżetów i źródeł finansowania poszczególnych instytucji szkolnictwa wyższego. Czy we wszystkich krajach są to dane powszechnie dostępne? Czy nie są one objęte tajemnicą statystyczną?

B.L.: Kwestia ta budziła duże obawy na początku istnienia ETER-u. Koniec końców okazało się, że nie jest to jednak tak dużym problem, wyłączając kilka prywatnych uniwersytetów. Trzeba wziąć pod uwagę, że w większości przypadków zajmujemy się sektorem publicznym i w większości państw europejskich uniwersytety są zwyczajnie zobligowane do ujawniania swoich budżetów, gdyż ich znaczną część stanowią pieniądze publiczne. Dlatego też w większości przypadków problem ten okazał się znacznie mniejszy i państwowe urzędy statystyczne po prostu poinformowały nas, że wszystkie dane, które oni udostępniają, mogą zostać udostępnione publicznie także na naszej stronie internetowej. Niemniej mieliśmy kilka takich problematycznych przypadków. Dlatego też stworzyliśmy odpowiednie procedury, na przykład czasem wymagane jest podpisanie umowy dotyczącej jawności danych, pozwalają one na ich zaklasyfikowanie jako przeznaczone wyłącznie do celów badawczych albo uzyskuje się do nich dostęp dopiero po rejestracji na stronie internetowej. Dotyczy to danych finansowych z kilku krajów, nie jest to jednak duża grupa. W niektórych krajach to urzędy statystyczne występują bezpośrednio do poszczególnych uniwersytetów z prośbą o zgodę na dostęp do danych i przeważnie ją otrzymują. Problem ten nie był więc poważny. W przypadkach, w których brakuje danych finansowych, jest to raczej wynik tego, że dane te nie są zbierane na poziomie centralnym, a nie z powodu tajności tych danych. Co więcej, warto dodać, że w tym zakresie w sektorze szkolnictwa wyższego zaszła daleko idąca zmiana w przeciągu ostatnich dwudziestu lat. Dla przykładu w 2010 roku Francja odmówiła udostępnienia danych w ramach programu EUMIDA. Francuskie ministerstwo argumentowało, że są to ich wewnętrzne dane. Obecnie jednak nawet Francuzi je udostępniają. Zaszła wyraźna zmiana po stronie władz, które zaczynają gwarantować otwarty dostęp do danych. Istnieje również presja ze strony uniwersytetów, by znajdować się w takich bazach jak ETER i udostępniać dane w celach porównawczych. Podsumowując, problem poufności okazał się nie być tak istotny, jak na początku przypuszczaliśmy.

J.W-D.: W Polsce, dzięki publikowanym corocznie raportom Ministerstwa Nauki i Szkolnictwa Wyższego, dysponowaliśmy danymi na poziomie indywidualnych instytucji

szkolnictwa wyższego (nie obejmowały one danych finansowych). Niestety ministerstwo z niezrozumiałych powodów przestało je udostępniać. Co Pan sądzi o otwartym dostępie do danych na temat poszczególnych instytucji szkolnictwa wyższego?

B.L.: To bardzo proste. W większości przypadków są to instytucje publiczne. Nie widzę więc powodu, dla którego dane te nie powinny być publicznie dostępne. Nawet we wspomnianym przez Panią przypadku Polski mamy dostęp na stronie ETER-u do danych finansowych pochodzących z przynajmniej czterdziestu uniwersytetów. Problemy mogą się pojawiać w przypadku instytucji prywatnych, które nie mają publicznego wsparcia, jeśli jednak je dostają, nie ma powodów, by dane te nie były dostępne. Wydaje mi się, że publiczny dostęp do danych to coś normalnego. Zdajemy sobie jednak sprawę, że w niektórych krajach, przede wszystkim Europy Środkowej i Wschodniej, pojawiają się duże problemy, ale nie sądzę, żeby w przyszłości dalej tak to wyglądało.

J.W-D.: Mam wrażenie, że generalnie wszyscy jesteście zwolennikami otwartego dostępu do danych poza przypadkami, w których dotyczą one nas samych. Dla przykładu omawiałam ten problem kilkakrotnie z pracownikami z mojej uczelni i ku mojemu zaskoczeniu zauważyłam, że część przedstawicieli niektórych wydziałów, zwłaszcza tych o charakterze technicznym, sprzeciwia się ujawnianiu informacji na przykład na temat wartości zleceń pochodzących z sektora prywatnego. Argumentują, że nie chcą, by konkurencja wiedziała, ile zarabiają na umowach z sektorem prywatnym i jak silni (albo słabi) są.

B.L.: Wydaje mi się, że musimy rozróżnić dane na poziomie instytucjonalnym i dane wewnętrzne na przykład na poziomie wydziałów. Analogicznie również firmy nie będą raczej chciały udostępniać danych dla poszczególnych swoich oddziałów albo nie będą skłonne udostępniać bardzo szczegółów danych. Jeśli jednak rozmawiamy o budżecie uniwersytetów, które składają się przede wszystkim ze środków publicznych, nie ma powodu by zatajać te dane. W ten sam sposób Europejska Rada ds. Badań Naukowych publikuje zbiorczą listę przyznanych grantów. Jeśli chcesz sprawdzić jak wiele pieniędzy pochodzi z umów, możesz to zrobić, gdyż są to publiczne pieniądze. Informowanie społeczeństwa, na co wydawane są środki publiczne, jest obowiązkiem. W rzeczywistości okazuje się, że w Europie mamy bardzo niewiele problemów z tajnością danych, nawet w kontekście danych finansowych.

J.W-D.: Jako koordynator ETER-u z ramienia USI jest Pan kluczową osobą odpowiedzialną za rozwój bazy danych. Czy mógłby Pan opowiedzieć, jak rozpoczęła się Pana praca w tym projekcie?

B.L.: Pracuję w projekcie od jego samych początków z powodów, które nie są dla mnie całkowicie jasne (śmiech). A tak na poważnie, pasowałem do projektu z uwagi na moją karierę naukową i akademicką. Jestem również niezłym metodykiem, znaczna część mojej kariery skupiała się na metodologii wskaźników lub na pisaniu podręczników dotyczących wskaźników. Dla przykładu stworzyłem metodologię pomiaru finansowania projektów, która używana jest dziś przez Eurostat. W pewien sposób pasowałem więc do projektu jako metodolog, ponieważ to metodologia jest w rzeczywistości podstawą projektu ETER. Następnie Andrea Bonaccorsi zaangażował się w ANVUR (Agenzia Nazionale di Valutazione del Sistema Universitario e della Ricerca) w ramach Włoskiej Krajowej Rady ds. Ewaluacji Systemów Szkolnictwa Wyższego i Badań, więc zostałem poproszony o przejęcie tego projektu.

J.W-D.: Jakie są dalsze plany rozwoju ETER-u? Jak Pan wspominał, Eurostat nie ma zamiaru przejmowania projektu.

B.L.: To jest kluczowa sprawa odnośnie tego projektu, która w rzeczywistości nie zależy w pełni od nas. Po pierwsze, baza danych ETER jest już w pełni ugruntowana i rozwinięta. Wiele osób korzysta z tych danych i w wielu artykułach znajdziemy odniesienia do ETER-u. W czerwcu braliśmy udział w konferencji w Paryżu, w trakcie której dyrektor amerykańskiej Carnegie Classifications of Institutions of Higher Education stwierdził, że ETER jest tym, czym IPEDS (The Integrated Postsecondary Education Data System) było dziesięć lat temu w Stanach Zjednoczonych. Wydaje mi się więc, że projekt ten ma przyszłość, zwłaszcza dlatego, że dane te okazują się przydatne. Wciąż pozostaje jednak pytanie o to, jak ta przyszłość się ułoży. Jasne jest, że Eurostat nie przejmie nigdy tego projektu, ponieważ nie są do tego organizacyjnie przygotowani. Zarządzanie danymi na poziomie indywidualnym instytucji wymaga nieco innych kompetencji, lepszej znajomości systemów szkolnictwa wyższego itd. Poza tym istnieją sztywne zasady w ramach europejskich regulacji statystycznych dotyczące udostępniania w Europie danych na poziomie mikro. W takim przypadku potrzebna jest zgoda od pierwotnego właściciela danych i dotyczy to nawet tych sytuacji, gdy dane są publiczne na poziomie krajowym. Eurostat musiałby skontaktować się więc ze wszystkimi uniwersytetami, prosząc je o zgodę, co jest zwyczajnie zbyt skomplikowane. Jak na razie Komisja Europejska podpisywała dwuletnie umowy na działanie ETER-u, czyli tak jak robi się to zazwyczaj. Nie wiem, na co zdecydują się w przyszłości, ale na razie praca idzie naprzód, co stwarza szersze warunki dla kontynuacji prac nad ETER-em również w przyszłości.

J.W-D.: A więc baza będzie dalej rozwijana?

B.L.: Taka byłaby moja odpowiedź, rozpoczęliśmy prace w 2013 roku na podstawie dwuletniej umowy, a teraz kontynuujemy już pracę przez szósty rok. Wydaje się więc, że są mocne podstawy, by uważać, że projekt będzie kontynuowany. Jednak dokładnie na jakich zasadach, nie jest to wciąż jasne. Muszę przyznać, że jest to szerszy problem każdej infrastruktury badawczej w tym obszarze. Część infrastruktury zostaje przywłaszczona i wykorzystywana do celów komercyjnych (np. bazy bibliometryczne), nie istnieje niestety mechanizm na poziomie europejskim, który pozwalałby na utrzymywanie publicznej infrastruktury odpowiadającej za zbieranie danych (poza statystykami udostępnianymi przez Eurostat). Nasze środowisko będzie musiało się zmierzyć z tymi problemami w nadchodzących latach. Udało nam się osiągnąć jednak znaczny postęp i obecnie znajdujemy się w sytuacji, w której podtrzymywanie istniejącej infrastruktury jest łatwiejsze niż tworzenie nowej.

J.W-D.: Wspominał Pan o swoich pracach poświęconym metodologicznym aspektom pomiaru badań naukowym. Prowadzi Pan badania dotyczące różnych aspektów funkcjonowania instytucji szkolnictwa wyższego. Co Pan myśli o metodach, które powinno się stosować w ewaluacji instytucji szkolnictwa wyższego i w tworzeniu np. rankingów?

B.L.: Muszę zaznaczyć, że moje badania dotyczą bardziej analizy funkcjonowania szkolnictwa wyższego niż samych systemów ewaluacji i rankingów. Pracuję – dla przykładu – nad takimi rzeczami jak tworzenie topologii uniwersytetów. Pracowałem również nad problemem zarządzania uniwersytetami. Obecnie pracujemy nad kwestią finansowania uniwersytetów. Zajmujemy się również umiędzynarodowieniem. W moich badaniach naukowych bardziej chodzi o porównywanie różnych aspektów i wyodrębnienie mechanizmów. W kontekście umiędzynarodowienia odkryliśmy choćby, że państwo odgrywa znaczną rolę. Można by pomyśleć, że ludzie decydują się na wybór danego uniwersytetu po prostu ze względu na jego prestiż i renomę, ale okazuje się, że zagraniczni naukowcy w znacznej mierze przemieszają się z uwagi na jakość życia w danym kraju, co rzecz jasna tworzy problem dla mniej zamożnych i rozwijających się krajów. Myślę, że najważniejszy wniosek dla ewaluacji i rankingów z moich badań to dostrzeżenie, że na szkolnictwo wyższe składają się jednostki niesamowicie zróżnicowane.

J.W-D.: Czy oznacza to, że uczelnie nie można porównywać?

B.L.: Nie, oczywiście, że można, ale gdy spojrzysz przykładowo na dane z ETER-u, natychmiast zdajesz sobie sprawę, że nie możesz porównywać ze sobą jednostek bez wzięcia pod uwagę ich heterogeniczności. Mamy na przykład uczelnie wojskowe,

koledże skupiające się na kształceniu i uniwersytety klasy światowej, które są po prostu zupełnie innymi organizacjami. Dlatego też kluczowym wnioskiem, szczególnie dla polityki wobec całego sektora, jest to, żeby ewaluacja opierała się zarówno na misji, jak i na funkcjonowaniu instytucji. Nie można poddawać ocenie koledżu na tych samych zasadach, co czołowego uniwersytetu badawczego. ETER pokazuje, że krajobraz instytucji szkolnictwa wyższego w Europie jest bardzo zróżnicowany. Istnieje w nim ponad 10 000 instytucji, a wiele z nich jest bardzo mała. ETER obejmuje około 2 700 instytucji, które są przynajmniej średniej wielkości, jedna trzecia z nich to instytucje prywatne – często niewielkie, kolejna jedna trzecia, to instytucje specjalistyczne takie jak akademie sztuki, akademie muzyczne itd. Po odjęciu tych instytucji zostaje nieco ponad 1 500 instytucji z misją ogólną, a wśród nich około 300–400 wskazujących na misję badawczą jako najważniejszą aktywność. Zanim zaczniesz więc porównywać, musisz mieć świadomość tych różnych warstw. Paradoksalnie jedną z najważniejszych wskazówek otrzymaliśmy ze Stanów Zjednoczonych, które jak mogłoby się wydawać, są zainteresowane wyłącznie doskonałością na samym szczycie systemu. Amerykanie twierdzą, że największym wyzwaniem dla polityki wobec sektora nie są wcale najlepiej oceniane uniwersytety, w większości są one i tak prywatne, ale uwaga powinna skupiać się raczej na koledżach niższego szczebla, bo to one tworzą wielką bazę dla systemu. Wydaje mi się, że ewaluacja powinna być mocno skontekstualizowana, a rankingi rzecz jasna są dobre do porównywania garstki europejskich uniwersytetów, a nie całych systemów.

J.W-D.: Mam wrażenie, że obecnie wiemy coraz więcej o instytucjach szkolnictwa wyższego, mamy więcej źródeł danych takich jak ETER, nowe narzędzia analiz jak choćby metody pomiaru produktywności i efektywności, ale wciąż mierzymy się z licznymi problemami podczas prób ewaluacji funkcjonowania instytucji szkolnictwa wyższego. Istnieje rozbieżność pomiędzy danymi, do których mamy dostęp, nowymi metodami i narzędziami a celem, jakim jest ocena działalności szkół wyższych. Wciąż nie znamy odpowiedzi na pytanie, jaki sposób ewaluacji instytucji szkolnictwa wyższego jest najlepszy. Dlaczego?

B.L.: Myślę, że po prostu bierze się to z niesłychanego skomplikowania tej kwestii. Brakuje nam niektórych kluczowych danych, ale brakuje również zrozumienia tej organizacyjnej heterogeniczności. Dla przykładu ETER dostarcza dane, ale nie wiemy tego, jak uniwersytety wewnętrznie funkcjonują. Ekonomiści twierdzą, że to nie ma znaczenia, ponieważ stosuje się funkcję produkcji opartą na nakładach i wynikach, ale to się tylko sprawdza w przypadku, gdy możemy przyjąć, że funkcja produkcji jest niezależna od struktury wewnętrznej, a tak w praktyce nie jest. Pojawiają się również kolejne kwestie, które nie są w wystarczającym stopniu skontekstualizowane. Ekonomiści mają skłonność do mówienia: „ok, w tym wszystkim chodzi o nakłady i wyniki,

chodzi o mikro-jednostki przekształcające nakłady w wyniki”. Jednak dziś wiemy, że rynek szkolnictwa wyższego opiera się w dużej mierze na statusie danych jednostek.

J.W-D.: Czyli jednostki o największym prestiżu i renomie „biorą” wszystko?

B.L.: Istnieje silne rozwarstwienie pomiędzy instytucjami, znaczenie mają również status i renoma, które sprawiają, że czołowym uniwersytetom łatwiej pozyskiwać zasoby. Jeśli porównamy Oxford z innym mniej prestiżowym uniwersytetem europejskim, okaże się, że Oxford jest bardziej efektywny. Chodzi jednak o to, że działalność jednostki takiej jak Oxford jest prostsza, ponieważ wyższy status oznacza, że może ona na przykład podnieść czesne, a i tak będzie miała więcej studentów. Ewaluacja jest więc skomplikowana, gdyż jest wieloaspektowa. Jedna rzecz to proste porównywanie uniwersytetów. Natomiast wiedza na temat tego, czy dany uniwersytet, który jest spozycjonowany w danym miejscu, jest skuteczny w przekształcaniu nakładów w wyniki przy wzięciu pod uwagę ograniczeń, z jakimi się mierzy, to jeszcze coś innego. Być może znajdujemy się w regionie, w którym nie ma wielu studentów, może jest to region dotknięty przez recesję, a może twojej instytucji nie udało się pozyskać renomy. Mam na myśli to, że nie wydaje mi się, żebyśmy mieli odpowiednie metody. Wydaje mi się również, że powinniśmy rozróżniać porównania prowadzone wyłącznie dla celów naukowych (np. weryfikacja hipotezy o istnieniu efektów skali w szkolnictwie wyższym) i porównania prowadzone dla innych celów. Na przykład w celu odpowiedzi na pytanie, jak funkcjonuje mój uniwersytet w porównaniu z innym podobnymi instytucjami, jak robi to choćby U-Multirank. Wydaje mi się, że wciąż istnieją problemy na poziomie konceptualnym, poziomie metod czy danych, z którymi musimy się zmierzyć, by stworzyć sprawiedliwą ewaluację.

J.W-D.: Istnieją różne sposoby ewaluacji produktywności i efektywności instytucji szkolnictwa wyższego, na przykład metody parametryczne i nieparametryczne. Jednak, o ile wiem, nie są one powszechnie używane do ewaluacji działalności instytucji szkolnictwa wyższego przez władze czy zarządzających szkołami. Co Pan myśli o włączeniu analiz opartych na ocenie skuteczności przekształcania nakładów w wyniku czy nawet bardziej zaawansowanych metod – takich jak warunkowa metoda DEA – do formalnej ewaluacji instytucji szkolnictwa wyższego?

B.L.: Pozostają nieco sceptyczny co do tych metod. Nie dlatego, że nie mają zalet, wręcz przeciwnie. Pozwalają dowiedzieć się wiele na temat leżących u podstaw związków i sam ten fakt jest bardzo istotny. Nie wydaje mi się jednak, że można je automatycznie zastosować do ewaluacji uniwersytetów. Podam przykład. Mimo różnych reguł ekonomicznych w sektorze szkolnictwa wyższego jest tylko jedno sprawdzające

się prawo: „im szybciej jedziesz, tym więcej spalasz paliwa”. W gruncie rzeczy najlepszym wskaźnikiem pozwalającym prognozować wyniki badań uniwersytetu, tyczy się to zarówno koledzy, jak i Harvardu, jest to, ile pieniędzy wkładasz w jednostkę. Można oczywiście się spierać, pieniądze są zmienną endogeniczną, Harvard posiada renomę, istnieją inne czynniki niż status i prestiż jednostki itd., to wszystko może być przedmiotem badań naukowych. Jeśli jednak chodzi o mój uniwersytet, to chciałbym ocenić, jaką pozycję on zajmuje i jak poprawić obecny stan rzeczy, biorąc pod uwagę status, którym obecnie dysponujemy. Wobec tego ostatecznie stajemy przed bardziej praktycznymi wyzwaniami. Powiedziałbym, że zaadoptowanie się do zmiany i zrozumienie jej wygląda podobnie jak w firmie. Jeśli chcesz zmienić firmę, musisz wiedzieć, w którym obszarze konieczna jest zmiana. Uniwersytety są ciałami politycznymi, na które składa się skomplikowana równowaga sił pomiędzy uniwersytetami, naukowcami a państwem i kwestia ta wymaga pragmatyzmu.

J.W-D.: Czy mógłby Pan przywołać jakiś konkretny przykład?

B.L.: Mogę przywołać pewną historię z mojego kraju. Jak zapewne Pani wie, mamy w Szwajcarii dwa bardzo dobre uniwersytety techniczne, jeden w Zurychu, drugi w Lozannie. Ten drugi jest stosunkowo młodszy i jest zarządzany nie przez naukowca, ale dyrektora administracyjnego, którego charakteryzuje hierarchiczne zarządzanie. Z kolei uczelnia w Zurychu ma profil bardziej naukowy, posiada szkołę Einsteina, noblistów i mniej scentralizowaną strategię. W pewnym momencie stwierdzono, że uczelnia w Zurychu nie jest odpowiednio zarządzana. Uznano, że potrzeba bardziej menadżerskiego podejścia (a nie zarządzania przez przedstawiciela nauczycieli akademickich) i na główną osobę mianowano dyrektora administracyjnego. W czasie pełnienia swojej funkcji spowodował on tak wiele konfliktów, że po roku musiał zrezygnować z posady. Jego następcą był pragmatykiem, który podkreślając charakter naukowy instytucji, powrócił do wcześniejszych rozwiązań i osiągnął wiele sukcesów. Nie mówię, że metody czysto naukowe nie są przydatne, ale mam na myśli to, że bezrefleksyjne aplikowanie ich do takich obszarów jak na przykład podział zasobów może się okazać bardzo niebezpieczne.

J.W-D.: Szkoły wyższe posiadają trzy misje: badania, kształcenie i tak zwaną trzecią misję związaną ze współpracą z otoczeniem społeczno-gospodarczym. O ile mierzenie wyników badań, na przykład na podstawie aktywności publikacyjnej kadry, jest stosunkowo łatwe, to wydaje się, że mierzenie wyników działalności w zakresie kształcenia jest bardziej złożone. Jak możemy mierzyć te aktywności, biorąc pod uwagę nie tylko wymiar ilościowy (na przykład ilość osób kończących studia), ale również jakość kształcenia?

B.L.: Nie jest to co prawda pole moich bezpośrednich zainteresowań badawczych, ale sama kwestia jest bardzo interesująca. W rzeczywistości główna miara kształcenia odnosi się do jego ilościowego wymiaru, są jednak dwa sposoby na zmierzenie się z tą kwestią. Pierwszy to spojrzenie przez pryzmat rynku pracy na przykład procent zatrudnionych absolwentów czy zarobki absolwentów. W takim wypadku pojawia się jednak problem ze standaryzacją tych miar. W końcu rynek pracy w Grecji nie jest tym samym co rynek pracy w Szwajcarii. Podejmując się więc takich porównań, konieczne jest znalezienie właściwego punktu odniesienia. Jednak i te miary nie oddają jakości kształcenia. Jeśli ukończyłeś Oxford, a jakość zajęć była kiepska, szanse na znalezienie pracy i wyższe zarobki są i tak z pewnością wyższe niż w przypadku skończenia innej uczelni w związku z rolą, jaką odgrywa ich status. W pewnym sensie są to więc dobre miary, ale trzeba mieć świadomość, że obecny w nich jest silny komponent w postaci statusu instytucji. Drugi sposób to bezpośredni pomiar efektów kształcenia, ale w takim wypadku również pojawiają się problemy. Musimy odpowiedzieć sobie na pytanie, jakich metod użyć i jak zorganizować i zestandaryzować pomiar na poziomie uniwersytetu, ponieważ takich pomiarów dokonuje się przede wszystkim za pomocą ankiet, wywiadów itd. Na poziomie średniego kształcenia mamy PISA⁵, ale nie obejmuje on poziomu kształcenia wyższego. Niemniej istnieją pewne badania w Stanach Zjednoczonych, które pokazują, że jakość kształcenia jest niska nawet w przyzwoitych instytucjach szkolnictwa wyższego. W każdym razie myślę, że w przyszłości, w przeciągu kilku lat w ramach ETER-u będziemy dysponować danymi na temat szans na zatrudnienie absolwentów jednak nie jako miara kształcenia, a raczej miara korzyści z edukacji wyższej.

J.W-D.: Dziękuję serdecznie za rozmowę i Pana uwagi odnośnie wszystkich poruszanych tematów – zwrócił Pan uwagę na szereg problemów, które wciąż napotykamy podczas prób mierzenia efektywności i produktywności instytucji szkolnictwa wyższego.

Tłumaczenie: Jakub Krzeski

Open access to universities' data should be something normal ! Interview with Benedetto Lepori, coordinator of the European Tertiary Education Register (ETER)

ANSTRACT: The interview explores the challenges related to the creation of harmonized and publicly available data on individual higher education institutions from European countries: European Tertiary Education Register (ETER) and its usage for international comparison. Benedetto Lepori argues that open access to data at the level of individual universities should be something normal.

⁵ Programme for International Student Assessment: <http://www.oecd.org/pisa/>

In addition, he believes that usage of input-output analysis together with advanced tools in efficiency and productivity is justified from the point of view of conducting research, however they should not be automatically applied for example to evaluate universities or distribute financial resources among them.

KEYWORDS: ETER, data open access, statistics on individual higher education institutions

CYTOWANIE: Wolszczak-Derlacz J. (2018). Otwarty dostęp do statystyk uczelni powinien być czymś normalnym! Wywiad z Benedetto Leporim, koordynatorem European Tertiary Education Register (ETER). *Nauka i Szkolnictwo Wyższe*. 2(52): 191–202. DOI: 10.14746/nisw.2018.2.7.

RECENZJA

Anna Maria Kola

Glauben schenken wollen ... czyli akredytować po niemiecku¹

Recenzja książki Krzysztofa Szewiora, *Akredytacja w niemieckim szkolnictwie wyższym: Zarys zagadnienia* (Warszawa 2018: Wydawnictwo ASPRA-JR, ss. 384.)

STRESZCZENIE: Niniejsza recenzja jest omówieniem i próbą oceny książki autorstwa Krzysztofa Szewiora, *Akredytacja w niemieckim szkolnictwie wyższym. Zarys zagadnienia*.

SŁOWA KLUCZOWE: szkolnictwo wyższe, akredytacja, Niemcy, agencje akredytacyjne

Niedługo przed rozpoczęciem roku akademickiego 2018/2019, ale jeszcze przed wejściem w życie nowej ustawy Prawo o szkolnictwie wyższym i nauce na rynku księgarskim pojawiła się publikacja poświęcona bardzo specjalistycznej, jak się wydawało w pierwszym momencie, kwestii, a mianowicie procesowi akredytacji edukacji wyższej w Republice Federalnej Niemiec. Autorem pracy zatytułowanej *Akredytacja w niemieckim szkolnictwie wyższym: Zarys zagadnienia* jest Krzysztof Szewior, doktor habilitowany w zakresie nauk o polityce, obecnie pracujący w Instytucie Europeistyki Uniwersytetu Warszawskiego.

Recenzowana książka rzeczywiście podejmuje temat wysoce specjalistyczny, który opracowano w sposób niezwykle merytoryczny i niehermetyczny, a jak spróbuję pokazać i uargumentować poniżej, jest to pozycja wartościowa i potrzebna w Polsce.

Przede wszystkim należy docenić, że przygotowane opracowanie nie jest tłumaczeniem niemieckiej monografii, ale efektem autorskich czynności badawczych, które opierały się na analizie danych zastanych. Podstawę tej analizy stanowią w przypadku książki Szewiora dokumenty statystyki publicznej, sprawozdania, analizy i publikacje

¹ Jest to cytat z książki – tłumaczenie słowa akredytacja w języku niemieckim: „Określenie akredytacja wywodzi się od słowa *accredere*, oznaczającego chęć obdarzenia wiarą i zaufaniem (*Glauben schenken wollen*)” (Szewior 2018: 66).

z obszaru badań nad szkolnictwem wyższym w Niemczech. Liczba zgromadzonych materiałów jest imponująca, Autor przeanalizował bowiem akty prawne np. przepisy prawa o randze konstytucyjnej, ustawy ogólnokrajowe, akty wewnętrzne instytucji, porozumienia międzypaństwowe, stanowiska, analizy i opracowania instytucji, tj. raporty, rekomendacje, analizy, przewodniki, komunikaty prasowe (przytoczono je w tekście i w spisie literatury, Szewior 2018: 346). Wśród nich znalazły się 22 akty prawne, 266 dokumentów wewnętrznych oraz 76 pozycji stanowiących „literaturę przedmiotu”. Opisują one funkcjonowanie różnych instytucji, które współtworzą proces akredytacji – zarówno organów ustawodawczych szczebla centralnego i państw związkowych, szkół wyższych publicznych i niepublicznych, organów jednoosobowych szkolnictwa wyższego, wielorakich organów w instytucjach, tj. zarządów, komisji, rad, komitetów, grup roboczych oraz związków zawodowych (Szewior 2018: 346).

Dlaczego warto zapoznać się z recenzowaną publikacją? Recenzenci i sam Autor wskazują na bardzo wiele celów badawczych, wśród których znajdują się: jakość kształcenia, ewaluacji i akredytacji w szkolnictwie wyższym; badanie agencji akredytacyjnych oraz rynku akredytacyjnego w kontekście europejskiego obszaru szkolnictwa wyższego i procesów globalnych; związek zachodzący pomiędzy międzynarodowym systemem akredytacji a strukturą państwa i modelem polityki szkolnictwa wyższego; opracowanie modelu ładu akredytacyjnego, celów polityki i praktyki akredytacyjnej w powiązaniu z modelem szkolnictwa wyższego i statusem szkół wyższych; analiza zadań, kompetencji i instrumentów działania podmiotów akredytacyjnych; ocena zdolności instytucji akredytacyjnych przyczyniania się do rozwoju kultury i systemów zapewniania jakości w szkołach wyższych, a także przyczyniania się do trwałego zapewniania i rozwoju nauczania „dobrej jakości”. Recenzentami pracy były osoby związane z procesem akredytacji w Polsce: prof. zw. dr hab. Danuta Strahl z Uniwersytetu Ekonomicznego we Wrocławiu oraz dr hab. Andrzej Korybski, prof. nadzwyczajny w Katedrze Teorii i Filozofii Prawa UMCS. Fakt powołania tak wybitnych postaci świata nauki na recenzentów wskazuje bezsprzecznie na wysoką jakość publikacji.

Recenzenci wyróżniają rozliczne kwestie podejmowane w publikacji, jednak warto zwrócić uwagę na sześć powodów, dla których warto się zaznajomić z książką Szewiora. Wśród nich są: (1) eksperckość – zarówno autorskiego wywodu, jak i tematyki; (2) systemowość ujęcia badań zaprezentowanych w publikacji; (3) aktualność podejmowanej problematyki – nie tylko z uwagi na datę wydania, ale też reformy polskiego i niemieckiego systemu edukacji wyższej; (4) niemieckojęzyczny obszar badań, który jest rzadko obecny w publicznym dyskursie poświęconym nauce i szkolnictwu wyższemu; (5) książka przyczynia się wydatnie do rozwoju dyscypliny – nauk o polityce publicznej w dziedzinie nauk społecznych i obszarze nauk społecznych; (6) potencjał aplikacyjny wniosków recenzowanej publikacji.

1. Eksperckość

Kompetencje Autora należy widzieć dwutorowo, po pierwsze, ze względu na dorobek naukowy i pracę naukową, badawczą i dydaktyczną. Drugą ścieżką jest wieloletnia współpraca Krzysztofa Szewiora z Polską Komisją Akredytacyjną, od kilku kadencji Autor jest członkiem PKA. W latach 2008–2011 był członkiem Zespołu Kierunków Studiów Społecznych i Prawnych; w latach 2012–2015 – przewodniczącym Zespołu nauk społecznych w zakresie nauk społecznych i prawnych; obecnie, czyli w kadencji 2016–2019, jest wiceprzewodniczącym tego samego zespołu.

Dr hab. Krzysztof Szewior jest absolwentem studiów politologicznych (1994), a następnie studiów doktoranckich (1998) na Wydziale Nauk Społecznych Uniwersytetu Wrocławskiego. Awans naukowy na stopień naukowy doktora habilitowanego nauk humanistycznych w zakresie nauki o polityce zdobył w 2007 roku. Obecnie zatrudniony jest w Instytucie Europeistyki na Wydziale Nauk Politycznych i Studiów Międzynarodowych Uniwersytetu Warszawskiego, gdzie prowadzi zajęcia dla studentów z obszaru nauki o państwie, polityki społecznej UE, kwestii społeczno-ekonomicznych państw niemieckojęzycznych, społecznej odpowiedzialności przedsiębiorstw oraz międzynarodowych porównań społecznych, w tym szczegółowych procedur tj. akredytacji czy zapewniania bezpieczeństwa. Są one wyrazem zainteresowań naukowych i badawczych, które dotyczą szeroko zdefiniowanej polityki społecznej i jej elementów, tj. szkolnictwa wyższego, polityki społecznej na rzecz kobiet, bezpieczeństwa społecznego, czego wyrazem jest np. publikacja *Bezpieczeństwo społeczne jednostki: Założenia i polska rzeczywistość* (2016).

Ponadto Szewior jest aktywnym członkiem politologicznych towarzystw naukowych: Polskiego Towarzystwa Nauk Politycznych czy Komitetu Nauk Politycznych PAN. Był stypendystą wielu organizacji naukowych, w tym zagranicznych, które oferują stypendia i staże badawcze w Niemczech: DAAD – Deutscher Akademischer Austauschdienst, GFPS – Gemeinschaft für studentischen Austausch in Mittel- und Osteuropa e.V., KAAD – Katholischer Akademischer Ausländer-Dienst czy Konrad Adenauer Stiftung. Wynikiem tych grantów i nagród były liczne staże badawcze i wizyty studyjne w Bonn, Marburgu, Kolonii, Wiedniu, Salzburgu, Bazylei, Berlinie, Newcastle i Hanowerze. Potwierdzają one niezwykle kompetencje w zakresie zarówno niemieckojęzycznego obszaru badań nad politykami publicznymi, jak i procesu akredytacji, co Autor podsumowuje i prezentuje w recenzowanej książce.

2. Systemowość ujęcia badań

We wstępie do swojej książki Krzysztof Szewior pisze, że:

[H]ad akredytacyjny Republiki Federalnej Niemiec szkicuje strukturę książki i wyznacza wiodące wątki tematyczne. System niemiecki budowano przez szereg minionych lat, osadzono go na kilku wartościach, tj. wielostopniowości i wielopodmiotowości, na niezależności instytucjonalnej i decyzyjnej agencji, na wewnątrzsystemowej konkurencyjności, na ograniczonej otwartości rynku, na transparentności i odpowiedzialności uczelni. [...] Działania te były skutkiem adaptacji liberalnego modelu do form instytucjonalno-prawnych bliższych tradycji Europy kontynentalnej (Szewior 2018: 19).

Ład ten Szewior opisuje z niezwykłą rzetelnością i dokładnością, przy czym wspomniana systemowość ujęcia dotyczy nie tylko systemu akredytacji, ale też edukacji i procesu kształcenia w Niemczech. Autor przybliży czytelnikom skomplikowaną specyfikę tego systemu, w sposób metodyczny i klarowny charakteryzując jego poszczególne elementy.

Praca składa się z dziesięciu rozdziałów, ale jak zaznacza Autor, wyodrębnić należy siedem pól i obszarów analizy. Pierwszy wątek publikacji dotyczy zasadności procesu bolońskiego i samej akredytacji. Druga część podejmuje kwestię niemieckiej procedury akredytacyjnej, która do reformy w 2017 roku była zdecentralizowana i wewnętrznie podzielona. Analiza obejmuje m.in. podstawy prawne i wytyczne akredytacji, wytyczne ogólnokrajowe dla akredytacji programowej i systemowej, opis działalności Rady Akredytacji odpowiedzialnej za akredytacje kierunków na uczelniach państwowych (Rada Nauki zaś – na uczelniach prywatnych/ niepaństwowych) i Fundacji ds. Akredytacji Toku Studiów, której do 2017 roku przypisano wiele zadań, w tym:

[c]ertyfikowanie agencji akredytacyjnych oraz wyznaczanie reguł postępowania i kryteriów akredytacji, informowanie o wynikach postępowań akredytacyjnych, rozwijanie systemów akredytacyjnych, reprezentowanie niemieckiego systemu akredytacji na zewnątrz i współdziałanie na rzecz rozwoju europejskiego obszaru szkolnictwa wyższego czy współpraca z agencjami akredytacyjnymi i innymi podmiotami, także zagranicznymi, z partnerami reprezentującymi uczelnie, środowisko studentów, państwo i praktykę zawodową (Szewior 2018: 103–104).

Następnie Autor charakteryzuje i przybliża działalność niemieckich agencji akredytacyjnych uprawnionych do nadawania „znaku jakości” Rady Akredytacyjnej.

Kolejny rozdział zawiera opisy procedur postępowania i kryteria oceny agencji akredytacyjnych – w zależności od rodzaju oceny tj. oceny programowej oraz systemowej. Bardzo interesujący jest następny rozdział dotyczący ewaluacji i sprawozdań z prac Rady Akredytacyjnej². Autor przywołuje także ważny moment w procedurze

² W Polsce także prowadzi się badania ewaluacyjne działalności PKA zarówno przez samą instytucję (Wojciechowska 2018), jak i organy kontrolne tj. NIK (*System oceny jakości kształcenia w szkołach wyższych: Informacja o wynikach kontroli* 2018).

akredytacyjnej tj. „nowe otwarcie” systemu akredytacji w 2018 roku. Ostatni ważny wątek dotyczy roli Rady Nauki jako instytucji akredytującej instytucjonalnie uczelnie niepaństwowe.

3. Aktualność problematyki

Ważną cechą recenzowanej pracy jest jej aktualność. Dotyczy to zarówno polskich reform nauki, wprowadzanych tzw. Ustawą 2.0, ale też opisanej w książce reformy akredytacji w Niemczech.

Już we „Wstępie” Autor zaznacza, że „[s]tan prawny i dokumentacyjny tworzący bazę źródłową książki zamknięto z końcem 2017 r.” (Szewior 2018: 23). Na podstawie tych dokumentów opisuje skomplikowaną i złożoną procedurę akredytacyjną, ale też wskazuje na „nowe otwarcie” systemu akredytacji w 2018 roku, próbę scalenia zadań wszystkich instytucji nadających znak jakości, nad którymi pieczę sprawować ma Fundacja Rada Akredytacji.

[u]stawodawca za istotne zadanie Fundacji [podkr. autora – dop. A.M.K.] uznał akredytację i reakredytację kierunków studiów i wewnętrznych systemów zapewnienia jakości w uczelniach, wyznaczanie warunków uznawalności akredytacji przeprowadzanych przez zagraniczne instytucje, wspieranie międzynarodowej współpracy w sferze akredytacji i zapewnienia jakości, raportowanie o systemie akredytacji i jakości kształcenia, dopuszczanie agencji na rynek niemiecki oraz wspieranie landów w doskonaleniu niemieckiego systemu zapewnienia i doskonalenia jakości (Szewior 2018: 262).

Jej siedzibą jest Bonn, a o jej pracach decyduje Rada Akredytacji, która składa się z przedstawicieli siedmiu środowisk: ośmiu nauczycieli akademickich, jednego przedstawiciela HRK – Konferencji Rektorów Szkół Wyższych, czterech reprezentantów landów, pięciu przedstawicieli praktyki zawodowej, dwojga studentów, dwojga przedstawicieli zagranicznych z doświadczeniem akredytacyjnym, jednego przedstawiciela agencji z głosem doradczym.

System akredytacji wciąż bazuje na dwóch rodzajach kryteriów oceny kierunków studiów – formalnych i merytorycznych. Wśród kryteriów formalnych wyróżniamy takie elementy jak: „struktura studiów, czas ich trwania, profile, warunki dopuszczenia, ścieżki przejścia pomiędzy ofertami studiów, egzaminy, moduły, mobilność, system punktów, porównywalność studiów z różną formułą ukończenia (egzamin dyplomowy, państwowy, praca dyplomowa), uznawanie wyników przy zmianie uczelni i tych uzyskanych poza szkołą wyższą” (Szewior 2018: 265). Kryteria merytoryczne są bardziej rozbudowane i uwzględnia się tutaj: cele kwalifikacji określonego poziomu nauczania i egzaminowania, kierunki studiów odnoszące się do kompetencji

naukowych i artystycznych, a także do kwalifikacji właściwych dla aktywności zawodowej i rozwoju osobistego czy środki i działania służące wyrównywaniu nierówności i dysproporcji (kwestia płci, niepełnosprawności, chorób przewlekłych) (Szewior 2018: 265).

4. Niemieckojęzyczny obszar badań

Publikacja dotyczy obszaru niemieckiego, co jest ważne w kontekście przemian nauki globalnej, która jest bezsprzecznie anglojęzyczna. Dominacja naukowa uczelni anglosaskich w świecie skutkuje przodowaniem tych szkół w rankingach uczelni wyższych m.in. w rankingu szanghajskim – ARWU³. Jednak należy zwrócić uwagę, że w grupie stu najlepszych uczelni wyższych według tego rankingu w 2018 roku obecne były cztery niemieckie szkoły wyższe, które są uczelniami z tradycjami. Na 47. miejscu rankingu ARWU jest Uniwersytet w Heidelbergu, na 48. Politechnika w Monachium, na 53. Monachijski Uniwersytet Techniczny, a na 99. Uniwersytet w Getyndze. W na miejscach 101–150 sklasyfikowano dobre uniwersytety w miastach Bonn, Frankfurtu i Freiburgu, natomiast w przedziale 151–200: Uniwersytet Techniczny w Dreźnie, Uniwersytety w Kolonii, Hamburgu, Lipsku, Münster, Tybindze i Würzburgu. W całym rankingu 500 najlepszych uczelni wyższych na świecie jest 36 niemieckich uczelni. Dla porównania w całym zestawieniu jest także sześć uczelni austriackich, osiem szwajcarskich, a także dwie polskie (Uniwersytet Warszawski w przedziale 301–400 i Uniwersytet Jagielloński w przedziale 401–500).

Ponadto należy podkreślić, że Niemcy są aktywne i mobilne w projektach wymiany akademickiej, np. w programie Erasmus Plus⁴. W sprawozdaniach programu można znaleźć informacje, że Francja, Niemcy i Hiszpania pozostają trzema krajami wysyłającymi na studia za granicę największą liczbę osób, a Hiszpania, Niemcy i Zjednoczone Królestwo przyjmują najwięcej uczestników programu.

Warto też wspomnieć o cytowalności wyników badań badaczy niemieckich, np. odwołując się do zestawień przygotowywanych przez firmę Clarivate Analytics, która identyfikuje najbardziej wpływowe badania naukowe, wykorzystując cytowania do wytypowania laureatów Nagrody Nobla. W gronie nominowanych znajduje się wielu wybitnych naukowców z Niemiec⁵, jak również z Rosji, Danii, Niemiec, Grecji, Indii, Japonii, Holandii, Korei Południowej i Tajwanu, a także Wielkiej Brytanii i Stanów Zjednoczonych.

³ <http://www.shanghairanking.com/ARWU2018.html> [29.10.2018].

⁴ http://erasmusplus.org.pl/wp-content/uploads/2016/01/eplus_statystyki_14_16_www_popr.pdf [29.10.2018].

⁵ Jest nim fizyk Rashid A. Sunyaev, dyrektor i członek naukowy Instytutu Astrofizyki Maxa Plancka w Garching (od 1995 roku).

Świadczy to o tym, że Niemcy mogą być postrzegane jako silny gracz na międzynarodowej arenie uczelni akademickich i instytucji nauki, co może być efektem myślenia strategicznego, w którym mieszczą się zarówno badania naukowe, jak i system kształcenia na studiach wyższych. Wysoką jakość zapewniają państwowe organy, które ewaluują i reformują swoją działalność, zmieniając zakres oddziaływań i typy rozwiązań, co jest właśnie tematem książki Krzysztofa Szewiora.

5. Działania na rzecz rozwoju dorobku dyscypliny

Publikacja *Akredytacja w niemieckim szkolnictwie wyższym: Zarys zagadnienia* poszerza dorobek obszaru dyscypliny funkcjonującej do 2018 roku w polskiej nauce, tj. polityk publicznych, zniesionych Rozporządzeniem Ministra Nauki i Szkolnictwa Wyższego z dnia 20 września 2018 roku w sprawie dziedzin nauki i dyscyplin naukowych oraz dyscyplin artystycznych. Można przyjąć nową klasyfikację, jednak należy oddać, że polityki publiczne były w Polsce intensywnie rozwijane, także przez Krzysztofa Szewiora i jego badania w obszarze polityki państwa, instytucji państwowych (administracji publicznej i klasy politycznej) i procesów politycznych. Dotychczasowa państwowcentryczna orientacja badawcza reprezentantów nauk o polityce publicznej zmienia się właśnie za sprawą recenzowanej książki, bowiem jej istotą jest wskazanie, iż fundamentem działania publicznego jest współpraca między różnymi podmiotami skupionymi wokół tego samego działania i realizacji tej samej funkcji. Stąd polityki publiczne mogą być rozpatrywane jako sekwencja działań i decyzji administracji publicznej w celu wywołania zamierzonego, korzystnego z punktu widzenia państwa i społeczeństwa efektu. W przypadku procedury akredytacyjnej chodzi o zapewnienie najwyższej jakości kształcenia, szczególnie w sytuacji, gdy kształcenie to jest finansowane ze środków państwowych. Krzysztof Szewior, podejmując temat akredytacji w Niemczech, wpisuje się w ten nurt rozważań, projektując potencjalne rozwiązania dla polskiego obszaru edukacji wyższej.

6. Potencjał aplikacyjny wniosków z prezentowanych badań

W związku z powyższym zaproponować należy ostatni argument za tym, by podjąć lekturę książki Krzysztofa Szewiora. Jest nim swoisty potencjał aplikacyjny dla sformułowania innowacyjnych rozwiązań w zakresie akredytacji w Polsce. Wykorzystanie zachodniego, niemieckiego wzorca (albo jego elementów) może przynieść korzyść choćby w postaci refleksji nad podejmowanymi działaniami czy ewaluacją przyjętych rozwiązań. Co ciekawe, w publikacji brakuje perspektywy często obecnej w Polsce, która nazywa procedurę akredytacyjną oceną bądź nawet kontrolą. Istnieje za to rozumienie, które warto wspierać i wzmacniać na polskich uczelniach, chodzi

o uznanie, że akredytacja jest nadaniem znaku jakości gwarantującym zarówno doskonałe kształcenie, jak i badania.

Podsumowanie

By dopełnić obrazu recenzowanej książki, należy także poświęcić akapit na rozważania o tym, czego w niej zabrakło. Zdecydowanie korzystne byłoby umieszczenie zawartych w pracy faktów w szerokim kontekście kulturowym i historycznym. Byłoby to interesujące studium społeczno-kulturowe, jednak zamierzeniem Autora było wpisanie wniosków w dorobek polityk publicznych. Brakuje także krytycznego osądu, włączenia perspektywy krytycznej, która szukałaby drugiego dna czy pułapek przyjętych rozwiązań.

Nie zmienia to jednak ostatecznej oceny całości, która prowadzi do konstatacji, że jest to „dzieło kompletne”, a kompetencja Autora jest odczuwalna na każdej stronie. Rzetelność badawcza Szewiora jest adekwatna do rzetelności redakcyjnej, bowiem poza główną częścią merytoryczną dotyczącą procesu akredytacji w pracy poza wynikami *desk research* umieszczono spis treści, wstęp oraz podsumowanie w języku polskim i angielskim; wykaz tabel i rysunków; dwa aneksy – *Opis typów szkół kształcenia ogólnego i zawodowego* oraz *Standardy i wskazówki dotyczące zapewnienia jakości w Europejskim Obszarze Szkolnictwa Wyższego* – i zestawienie *Dane statystyczne dotyczące niemieckiego szkolnictwa wyższego w latach 2012–2017*. Są one skrótowym, ale precyzyjnym uzupełnieniem analiz na temat szkolnictwa wyższego w RFN. Autor ułatwił lekturę czytelnikowi, dołączając ponadto wykaz skrótów niemieckich nazw instytucji, przepisów prawnych, uczelni wyższych i innych, tym samym wskazując na podręcznikowy i przeglądowy charakter publikacji.

Publikacja jest dziełem kompletnym, bowiem łączy zainteresowania, kompetencje i doświadczenia w pracy eksperckiej Autora. Przede wszystkim jednak opisana w recenzji książka „jest głosem w dyskusji nad szeregiem podniesionych kwestii, a w pewnych aspektach może okazać się przydatnym przewodnikiem. Poza tym jest wyrazem podziękowania dla grona ludzi w Polsce z przekonaniem zaangażowanych na rzecz akredytacji, z którymi autorowi było dane mieć styczność i współpracować przez szereg minionych lat” (Szewior 2018: 23). Warto poznać ten głos, by zrozumieć, że akredytacja to proces złożony, wielowymiarowy i fundamentalny dla rozwoju systemu kształcenia akademickiego.

Literatura

System oceny jakości kształcenia w szkołach wyższych: Informacja o wynikach kontroli. (2018). Warszawa: Najwyższa Izba Kontroli.

- Szewior, K. (2016). *Bezpieczeństwo społeczne jednostki: Założenia i polska rzeczywistość*. Warszawa: Wydawnictwo ASPRA-JR.
- Szewior, K. (2018). *Akredytacja w niemieckim szkolnictwie wyższym: Zarys zagadnienia*. Warszawa: Wydawnictwo ASPRA-JR.
- Wojciechowska, B. (red.) (2018). *Działalność Polskiej Komisji Akredytacyjnej w 2017 roku*. Warszawa: Polska Komisja Akredytacyjna.

Strony internetowe

- <http://www.shanghai ranking.com/ARWU2018.html> [29.10.2018].
- http://erasmusplus.org.pl/wpcontent/uploads/2016/01/eplu_statystyki_14_16_www_popr.pdf [29.10.2018].

Glauben schenken wollen... or accreditation in Germany

ABSTRACT: Review of *Akredytacja w niemieckim szkolnictwie wyższym: Zarys zagadnienia* by Krzysztof Szewior.

KEYWORDS: higher education, Germany, accreditation, accreditation agency

CYTOWANIE: Kola, A. (2018). *Glauben schenken wollen... czyli akredytować po niemiecku*. *Nauka i Szkolnictwo wyższe*. 2(52): 205–213. DOI: 10.14746/nisw.2018.2.8.

ANNA MARIA KOLA – adiunkt w Katedrze Pracy Socjalnej na Wydziale Nauk Pedagogicznych Uniwersytetu Mikołaja Kopernika, magister socjologii i filologii polskiej, dyplomowana logopedka oraz lektorka języka polskiego dla obcokrajowców. Członkini Polskiej Komisji Akredytacyjnej (2016–2019). Zainteresowania naukowe autorki mają charakter interdyscyplinarny, ale dotyczą głównie socjologii edukacji (szkoły wyższej) oraz pracy socjalnej w kontekście przemian globalizacyjnych. Badaczka elitarnych uniwersytetów na całym świecie (USA, Anglia, Chiny). Propagatorka i inicjatorka wielu projektów społecznych w III sektorze, działaczka ruchu społecznego Obywatele Nauki.

