

# Wykorzystanie wskaźników złożonych i metod nieparametrycznych do oceny i poprawy efektywności funkcjonowania wyższych uczelni technicznych

ANDRZEJ SZUWARZYŃSKI, BARTOSZ JULKOWSKI

Wydział Zarządzania i Ekonomii, Politechnika Gdańska\*

Publiczne uczelnie wyższe, podobnie jak organizacje komercyjne, muszą dbać o efektywność funkcjonowania. W artykule został przedstawiony model pomiaru i oceny efektywności względnej uczelni technicznych. Analizę przeprowadzono wśród 18 uczelni, wykorzystując metodę złożonych wskaźników i model SBM Data Envelopment Analysis. Zdefiniowano 14 wskaźników wpływających na efektywność dla pięciu obszarów funkcjonowania uczelni: badań naukowych, dydaktyki, rozwoju kadr naukowych, jakości procesów kształcenia oraz finansowania ze środków publicznych. Na podstawie wyników wskazano jednostki nieefektywne oraz kierunki zmian, które pozwolą im osiągnąć pełną efektywność. Zastosowane metody pozwoliły uwzględnić w ocenie efektywności łączne oddziaływanie wszystkich istotnych czynników opisujących podstawowe usługi świadczone przez uczelnie.

SŁOWA KLUCZOWE: ekonomia edukacji, Data Envelopment Analysis, wskaźniki złożone, efektywność, wyższe uczelnie techniczne.

Funkcjonowanie szkół wyższych, w zakresie ustawowych obowiązków prowadzenia działalności dydaktycznej oraz badawczej, jest oceniane na różne sposoby, np. w formie rankingów (*Ranking szkół wyższych*, 2013). Mają one jednak większe znaczenie dla budowania wizerunku uczelni niż dla oceny i usprawniania procesów kształcenia i prowadzenia badań, ponieważ nie odzwierciedlają w sposób

bezpośredni ich efektywności. W obszarze działalności badawczej przeprowadzana jest przez Ministerstwo Nauki i Szkolnictwa Wyższego (MNiSW) okresowa parametryzacja jednostek naukowych, której wyniki – poza znaczeniem prestiżowym – mają bardziej wymierne efekty, gdyż przekładają się na wysokość finansowania działalności badawczej. Simon Marginson (2014), który dokonał krytycznej oceny światowych rankingów uczelni wyższych (m.in. Shanghai Academic Ranking of World Universities, tzw. listy szanghajskiej), uważa,

---

Artykuł jest wynikiem prac podjętych w zakresie tematu „Wykorzystanie metod nieparametrycznych do badania efektywności” prowadzonego w ramach działalności statutowej Katedry Zarządzania, Wydziału Zarządzania i Ekonomii Politechniki Gdańskiej.

© Instytut Badań Edukacyjnych

---

\* Adres do korespondencji: Narutowicza 11/12, 80-233 Gdańsk. E-mail: andrzej.szuwarzynski@zie.pg.gda.pl

że porównanie uniwersytetów powinno skupiać się na istocie ich funkcjonowania, a nie na renomie. Rankingi opierające się na renomie działają na zasadzie gry konkurencyjnej, która jest celem samym w sobie, i nie przyczyniają się do poprawy kształcenia, jakości prowadzonych badań i innych usług świadczonych przez uczelnie. Szkoły wyższe finansowane głównie ze środków publicznych powinny zwracać szczególną uwagę na efektywność ich wykorzystania. Prawo o szkolnictwie wyższym określa ogólne zasady podziału subwencji dla publicznych szkół wyższych, podkreślając jednak, że: musi być zapewnione efektywne wydatkowanie środków publicznych z uwzględnieniem jakości kształcenia (Dziennik Ustaw Nr 84, poz. 455). Potwierdza to celowość zainteresowania się pomiarem i oceną efektywności publicznych szkół wyższych.

Uwarunkowania funkcjonowania szkolnictwa wyższego w Polsce zmieniły się radykalnie od 1990 r., kiedy zniesiony został państwowy monopol na tworzenie uczelni. Spowodowało to lawinowy wzrost liczby wyższych szkół niepublicznych. Na początku roku akademickiego 2011/12 w polskim systemie szkolnictwa wyższego funkcjonowało 460 szkół, w tym 328 niepublicznych i 132 publiczne (GUS, 2012).

Dynamiczny rozwój szkolnictwa wyższego jest obecnie hamowany przez zmiany spowodowane sytuacją demograficzną. Dominik Antonowicz i Bartłomiej Gorlewski (2011) nie bez przyczyny nadali swojemu raportowi tytuł *Demograficzne tsunami* – przedstawia on trudną sytuację, w jakiej niedługo znajdzie się polskie szkolnictwo wyższe. W roku akademickim 1990/1991 studiowało w polskich uczelniach około 403 tys. osób, podczas gdy w rekordowym 2005/2006 roku blisko 1954 tys. Od tego czasu liczba studentów powoli zmniejszała się i w 2012 r. wynosiła 1676 tys., z czego w uczelniach niepublicznych kształciło się 27,4% osób. W 2012 r. w stosunku do roku

1995 liczba potencjalnych kandydatów na studia, czyli dziesięcioletników, spadła o ok. 24,3% (GUS, 2013). Obserwowany spadek popytu na usługi edukacyjne w szkolnictwie wyższym jest argumentem przemawiającym za tym, aby zwrócić uwagę na efektywność funkcjonowania uczelni.

Wyższe uczelnie techniczne prowadzą badania, często finansowane ze środków publicznych, w obszarach, które mają decydujący wpływ na innowacje w przemysłach wysokich technologii, np. farmaceutycznym, chemicznym czy elektronicznym. Podkreśla się też konieczność integracji działalności badawczej z procesami kształcenia kadr dla przemysłu, gdyż tylko dzięki wysokokwalifikowanym absolwentom, innowacyjne rozwiązania mogą przełożyć się na korzyści ekonomiczne, a tym samym na wzrost gospodarczy kraju (Mansfield, 1995; Salter i Martin 2001). Jest to również istotny argument uzasadniający podejmowanie prób badania efektywności tego obszaru działalności uczelni technicznych.

Głównym celem badania, którego wyniki zostały przedstawione w artykule, był pomiar i ocena efektywności funkcjonowania publicznych uczelni technicznych w Polsce, wskazanie przyczyn braku efektywności i określenie kierunków działań mających ją poprawić. Na podstawie dostępnych danych statystycznych dokonano identyfikacji obszarów wpływających na efektywność. Wykorzystano model opierający się na złożonych wskaźnikach (OECD, 2008) oraz model wykorzystujący nieparametryczną metodę *Data Envelopment Analysis* (DEA), którą opracowali Abraham Charnes, William W. Cooper i Edwardo L. Rhodes (1978). DEA znajduje szerokie zastosowanie w badaniach efektywności różnego typu instytucji. Pozwala ona sformułować rekomendacje dotyczące kierunków zmian w nieefektywnych jednostkach i wskazać im, co należy zrobić, aby odwrócić negatywny trend.

## Metody pomiaru efektywności względnej

### Ogólna koncepcja pomiaru efektywności względnej

Pomiar efektywności opiera się na określeniu relacji między nakładami a rezultatami funkcjonowania danego podmiotu. Jednym z jego celów jest uzyskanie informacji niezbędnych do optymalizacji procesów decyzyjnych. Poza efektywnością ekonomiczną, bazującą na kryteriach kosztów, dochodu czy zysku, wyróżnia się efektywność alokacyjną nazywaną efektywnością Pareto-Koopmansa. W przypadku tego rodzaju alokacji zasobów nie można polepszyć sytuacji jednego podmiotu bez jednoczesnego pogorszenia sytuacji drugiego. Jest on zatem nazywany efektywnym w rozumieniu Pareta lub optymalnym w sensie Paretowskim (Stiglitz, 2004). Efektywność alokacyjna określa natomiast, czy wykorzystywana kombinacja nakładów i rezultatów ma właściwe proporcje. Na tej podstawie Gerard Debreu (1951) oraz Michael Farrell (1957) zdefiniowali pojęcie efektywności technicznej, jako relacji między produktywnością danego obiektu a maksymalną produktywnością, jaką można uzyskać przy danych nakładach i stosowanej technologii. Organizacja jest nieefektywna technicznie, jeżeli zużywa więcej nakładów, niż jest to konieczne do uzyskania danego poziomu produkcji (bądź też, gdy przy danych nakładach produkuje poniżej granicy możliwości produkcyjnych). Obiekty efektywne technicznie znajdują się na granicy efektywności (*efficient frontier*), a nieefektywne poniżej tej granicy.

Istnieje związek między efektywnością alokacyjną a techniczną. Organizacja może być efektywna technicznie (znajdować się na granicy możliwości produkcyjnych), a jednocześnie nieefektywna alokacyjnie w przypadku, gdy zmiana kombinacji nakładów i rezultatów mogłaby przyczynić się do obniżenia kosztów jej działania.

Sytuacja, w której organizacja będzie efektywna zarówno alokacyjnie, jak i technicznie, określana jest mianem efektywności całkowitej (*overall efficiency*) bądź efektywności ekonomicznej (*economic efficiency*; Coelli, Rao, O'Donnell i Battese, 2005).

W badaniu efektywności wyróżnia się metody klasyczne (wskaźnikowe), parametryczne (modele ekonometryczne) i nieparametryczne (programowanie matematyczne; Guzik, 2009a). Metody klasyczne stosowane są zwykle do oceny relacji zachodzących między dwoma badanymi wielkościami. Jednakże powszechnie stosowane są również złożone wskaźniki (*Composite indicators*, CIs), znajdujące szerokie zastosowanie w analizie polityk publicznych (zasady budowy złożonych wskaźników znajdują w Aneksie 1).

Gdy w analizie uwzględniane są co najmniej dwa typy nakładów i jeden rezultat (lub odwrotnie), można stosować metody parametryczne, wykorzystujące ekonomiczną funkcję produkcji, która określa zależność między nakładami a rezultatami. W przypadku wielowymiarowości (przynajmniej dwa typy nakładów uczestniczących jednocześnie w wytwarzaniu co najmniej dwóch rezultatów) metody parametryczne nie znajdują zastosowania, ponieważ nie jest możliwe ustalenie, jak wielki nakład danego rodzaju zostaje bezpośrednio użyty do uzyskania poszczególnych rezultatów (Guzik, 2009b). W tych przypadkach stosuje się metody nieparametryczne, takie jak DEA (algorytm zastosowanego modelu znajduje się w Aneksie 2).

### Zasady doboru struktury modelu DEA

Punktem wyjścia do badania wykorzystującego DEA jest zrozumienie procesu i określenie celu badania oraz zdefiniowanie grupy jednostek decyzyjnych (*decision making units*, DMU) podlegającej ocenie i zestawu zmiennych opisujących nakłady i rezultaty (Cook, Tone i Zhu, 2014). Chociaż DEA jest

w tym zakresie elastyczna, konieczne jest spełnienie pewnych założeń: wartości nakładów i rezultatów muszą być większe od zera; preferowana jest mniejsza liczba nakładów i większa liczba rezultatów; wybór nakładów, rezultatów i DMU powinien odzwierciedlać cele analizy (Cooper, Seiford i Tone, 2007).

Zbiór DMU powinien być jednorodny bądź prawie jednorodny (aby nie porównywać zjawisk, które z natury są odmienne), a kierunek preferencji musi być jednolity, tzn. wzrost rezultatu, z punktu widzenia celu funkcjonowania DMU, ma być oceniany pozytywnie, natomiast wzrost nakładu, przy zachowaniu stałości rezultatów, ma być oceniany negatywnie (Guzik, 2009a). Parametrem wpływającym na siłę dyskryminacji DEA jest relacja między liczbą ocenianych DMU a łączną liczbą zmiennych określających nakłady i rezultaty. Sugerowana jest praktyczna zasada (*rule of thumb*; Cook i in., 2014), mówiąca o tym, że liczba DMU uwzględnianych w analizie powinna być dwa razy większa niż łączna liczba nakładów i rezultatów, a dla modeli radialnych trzy razy większa. Takie reguły nie mają charakteru nakazu, ani nie mają podstaw statystycznych, lecz są one wynikiem praktycznych doświadczeń.

### **Zastosowania metod badania efektywności w szkolnictwie wyższym**

Istnieje wiele przykładów wykorzystania DEA do oceny efektywności w szkolnictwie wyższym. W modelu oceny efektywności wydziałów uczelni w Austrii (Leitner, Priskozovits, Schaffhauser-Linzatti, Stowasser i Wagner, 2007) przyjęto 2 typy nakładów (liczba nauczycieli i powierzchnia wydziałów) oraz 12 rezultatów (środki finansowe ze źródeł zewnętrznych, liczba ukończonych projektów na pracownika, liczba ukończonych projektów na wydziale oraz liczby: egzaminów, dyplomantów, monografii, artykułów, raportów, patentów, prezentacji, innych publikacji oraz doktoratów).

Autorzy tych badań podkreślili, że DEA – poza obliczeniem efektywności i stworzeniem rankingu – pozwala również na określenie kierunków poprawy nieefektywnych DMU. W Australii (Abbott i Doucouliagos, 2004) DEA została wykorzystana do oceny działalności badawczej uniwersytetów. Założono, że rezultatem jest ważony indeks publikacji. Jako nakłady przyjęto: przychód z badań, liczebność kadry akademickiej i innych pracowników, a także wielkość uczelni. Powodem analizy efektywności wydziałów na jednym z uniwersytetów na Tajwanie było istotne zredukowanie dotacji rządowych (Kao i Hung, 2008). Celem była ocena efektywności wykorzystania zasobów na podstawie modelu, w którym jako rezultaty przyjęto: całkowite obciążenia dydaktyczne, liczbę publikacji z listy Science Citation Index oraz kwotę grantów uzyskiwanych przez pracowników. Jako nakłady przyjęto ważoną liczbę nauczycieli i administracji, całkowite koszty operacyjne i wielkość powierzchni wydziałów. Wskazano kierunki działań mających na celu poprawienie funkcjonowania jednostek nieefektywnych przez lepsze wykorzystanie zasobów. Gerhard Kempkes i Carsten Pohl (2010) w badaniach niemieckich uniwersytetów przyjęli jako rezultaty liczbę absolwentów oraz wielkość grantów badawczych, a jako nakłady liczbę personelu technicznego i badawczego oraz wysokość bieżących wydatków. Zastosowali zorientowany na rezultaty model, wychodząc z założenia, że dla uczelni finansowanych ze środków publicznych nie ma możliwości sterowania nakładami, więc przy zadanych nakładach uniwersytety powinny maksymalizować rezultaty.

W Polsce najbardziej kompleksowym badaniem przeprowadzonym z wykorzystaniem DEA była analiza dotycząca 59 publicznych szkół wyższych (Ćwiąkała-Małys, 2010). Sformułowano kilka modeli, w których jako nakłady potraktowano: liczbę

pracowników (nauczycieli i nie-nauczycieli), koszty, majątek trwały oraz dotację dydaktyczną, zaś za rezultaty uznano liczbę studentów i absolwentów. Stwierdzono nieefektywność systemu finansowania publicznego szkolnictwa wyższego, wskazując, że algorytm podziału dotacji nie jest adekwatny do efektywności poszczególnych szkół oraz zaproponowano kilka wariantów jego modyfikacji.

Do badania efektywności i tworzenia rankingów uczelni wyższych wykorzystuje się również metodę złożonych wskaźników. Przykładem jest ocena efektywności i jakości hiszpańskiego systemu edukacji wyższej (Murias, de Miguel i Rodriguez, 2008), w której analizie poddano wszystkie uniwersytety hiszpańskie, za wyjątkiem uczelni technicznych (dla zachowania jednorodności próby). Podobną ocenę efektywności i jakości, na poziomie krajowych systemów szkolnictwa wyższego, przeprowadzono dla 16 krajów, w tym Japonii, Tunezji, Maroka i trzynastu krajów europejskich (Zrelli i Hamida1, 2013). W obu tych badaniach do ustalania wag wykorzystano model DEA, w którym zastosowano jeden nakład równy jedności dla wszystkich porównywanych obiektów. Wykorzystano tu pojęcie *helmsmana*, które wprowadził Tjalling Charles Koopmans, badając zagadnienia efektywności w systemach zdecentralizowanych decyzji. Koncepcja ta zakłada, że każdy kraj ma do dyspozycji narzędzia umożliwiające prowadzenie polityki makroekonomicznej, a jej wyniki są uzależnione tylko od jednego wejścia, władz podejmujących decyzje makroekonomiczne, określanymi jako *helmsman* (Koopmans 1951; Lovell 1995). Metodę złożonych wskaźników, w formie przedstawionej w Aneksie 1, zastosowano do stworzenia rankingu uczelni na podstawie wskaźników cząstkowych z trzech obszarów: badań, kształcenia i oddziaływania na środowisko (Lukman, Krajnc

i Glavic, 2010). Na podobnych zasadach budowane są powszechnie znane, światowe rankingi uczelni, takie jak Shanghai Academic Ranking of World Universities, czy też brytyjski Times Higher Education Supplement. Dyskutowana jest jednakże ich wiarygodność, głównie z powodu zbyt dużego subiektywizmu w doborze struktury stosowanych modeli (Marginson, 2014; Paruolo, Saisana i Saltelli, 2013; Saisana, d’Hombres i Saltelli, 2011).

### Wybór jednostek do badań

Do analizy wybrano grupę uczelni technicznych, m.in. z tego powodu, że kształcą one głównie na kierunkach o wysokich współczynnikach kosztocłonności i z reguły nie prowadzą kierunków masowych, a ich działalność naukowa wymaga kosztownej infrastruktury badawczej. Wybrana grupa uczelni spełnia postulat jednorodności (Guzik, 2009a), m.in. ze względu na to, że są szkołami publicznymi, funkcjonującymi na podstawie tych samych przepisów, prowadzącymi zbliżone kierunki studiów i badania o podobnej tematyce, mającymi na celu głównie kształcenie inżynierów i rozwój nauki w dziedzinach technicznych. Niejednorodność DMU mogłaby spowodować, że wyniki oceny efektywności odzwierciedlałyby raczej istniejące różnice w środowisku ich funkcjonowania niż rzeczywistą nieefektywność (Haas i Murphy, 2003).

Obecnie w Polsce, zgodnie z klasyfikacją MNiSW, funkcjonuje 18 publicznych uczelni o profilu technicznym: Politechniki: Białostocka (PB), Częstochowska (PCz), Gdańska (PG), Koszalińska (PK), Krakowska (PKr), Lubelska (PL), Łódzka (PŁ), Opolska (PO), Poznańska (PP), Radomska (PRa, od 11 września 2012 r. Uniwersytet Technologiczno-Humanistyczny im. Kazimierza Pułaskiego w Radomiu), Rzeszowska (PRz), Śląska (PŚl), Świętokrzyska (PŚw), Warszawska (PW), Wrocławska (PW) oraz

Akademia Górniczo-Hutnicza (AGH), Zachodniopomorski Uniwersytet Technologiczny (ZUT, powstały w 2009 r. z połączenia Politechniki Szczecińskiej i Akademii Rolniczej w Szczecinie) oraz Akademia Techniczno-Humanistyczna w Bielsku-Białej (ATH, dawniej filia Politechniki Łódzkiej). Różnią się one między sobą wielkością oraz czasem i sposobem powstania. Odmienne są również obszary, w których się specjalizują, jednak z racji deklarowanego, dominującego profilu technicznego stanowią jednorodną grupę.

### **Proponowany model oceny efektywności uczelni technicznych**

Podstawowym problemem w analizach bazujących na danych statystycznych jest zapewnienie kompletności danych. W analizie wykorzystano dane pochodzące z kilku źródeł. Liczby cytowań i publikacji zostały pobrane z bazy Web of Science. Informacje dotyczące liczby studentów, absolwentów, doktorantów, kierunków studiów oraz struktury pracowników uczelni pochodzą z danych podstawowych, gromadzonych i opracowywanych przez Departament Finansowania Szkół Wyższych, MNiSW (do 2009 r. dane te były publikowane w formie zwartej, w serii „Szkolnictwo wyższe 2009. Dane podstawowe”). Jako źródło danych finansowych posłużyły: Dziennik Urzędowy MNiSW, gdzie corocznie podawana jest wysokość dotacji przyznanej poszczególnym uczelniom, oraz Monitor Polski B z sierpnia 2012 r., w którym opublikowano sprawozdania finansowe publicznych szkół wyższych, a w tym przychody netto i przychody własne uczelni. Analiza i ocena efektywności zostały przeprowadzone na podstawie danych z 2011 r., dla którego dysponowano pełnymi danymi ze wszystkich analizowanych obszarów. Zdecydowano, że w celu zachowania spójności między obydwoma zastosowanymi

modelami, w modelu DEA zostały wykorzystane te same zmienne wskaźnikowe, jakie wykorzystano w modelu CIs. Dodatkowym argumentem przemawiającym za zastosowaniem wskaźników jest to, że ich wykorzystanie niweluje różnice skali porównywanych jednostek. Często w analizach nie używa się identycznych mianowników dla wszystkich wskaźników, co ma tę zaletę, że są niezależne od wielkości jednostki, a zatem ułatwiają porównywanie (Hollingsworth i Smith, 2003).

Na potrzeby badania przyjęto wyjściowy zestaw 14 wskaźników, z których 8 miało charakter rezultatów (oznaczone przez R – wyższe wartości oceniane pozytywnie), a 6 traktowanych było jako nakłady (oznaczone przez N – niższe wartości oceniane pozytywnie). Poszczególne wskaźniki zostały przypisane do pięciu podstawowych procesów realizowanych w uczelni: działalności badawczej, działalności dydaktycznej, rozwoju kadry, zapewnienia jakości procesu dydaktycznego i gospodarki finansowej. Przy doborze tego zestawu kierowano się zasadami opisanymi przez Stefano Tarantola i Massimiliano Mascheriniego (2009), które są zestawem dobrych praktyk w tworzeniu złożonych wskaźników:

- znaczenie wskaźnika z punktu widzenia celu badania: wskaźniki muszą mieć znaczenie dla procesów decyzyjnych i być odwzorowaniem badanego zjawiska;
- eliminowanie redundancji: gdy dwa wskaźniki okażą się redundantne, wskazane jest, aby wybrać tylko jeden z nich, najlepiej taki, który był już wcześniej wykorzystywany w innych badaniach;
- korelacja: gdy dwa wskaźniki są silnie skorelowane, a przekazują istotne informacje z punktu widzenia celu badania, oba mogą być uwzględnione w ostatecznym modelu;
- dostępność: zalecane jest wykorzystywanie wskaźników, które są dostępne dla wszystkich porównywanych obiektów i mogą być pozyskane z wiarygodnych baz danych.

Problem decyzji o eliminacji z modelu zmiennych silnie skorelowanych jest podnoszony również przez innych autorów. Koen Decancq i Maria Lugo (2010) stwierdzili, że korelacja między zmiennymi na poziomie 0,8 dopuszcza ich włączenie, o ile odzwierciedlają one ważne aspekty opisywanej przez model sytuacji. Dobór wskaźników do modelu zawsze może budzić kontrowersje z uwagi na podnoszony wcześniej subiektywizm w budowie rankingów (Paruolo, Saisana i Saltelli, 2013).

W Tabeli 1 znajduje się krótki opis wskaźników wraz z podstawowymi statystykami

oraz ich interpretacja (jeżeli w opisie wskaźników jest liczba studentów, to należy to interpretować, jako łączną liczbę studentów studiów stacjonarnych i niestacjonarnych).

Dla działalności badawczej zdefiniowano dwa wskaźniki, charakteryzujące dorobek naukowy pracowników uczelni, na poziomie międzynarodowym (na podstawie danych z bazy Web of Science): (R1) – liczbę cytowań przypadającą na jednego nauczyciela akademickiego oraz (R2) – liczbę zarejestrowanych publikacji przypadającą na jednego nauczyciela akademickiego. Wyjątkowo, dla tego obszaru wskaźniki

Tabela 1

Zestaw wskaźników wykorzystanych w analizie

Obszar	Symbol	<i>M</i>	<i>SD</i>	Min	Max	Opis
Badania	R1	4,72	3,65	0,55	12,6	Liczba cytowań przypadająca na jednego nauczyciela akademickiego.
	R2	1,50	0,71	0,34	2,72	Liczba zarejestrowanych publikacji przypadających na nauczyciela akademickiego.
Dydaktyka	N1	0,26	0,24	0,00	0,74	Stosunek liczby dyplomów licencjackich do liczby dyplomów ogółem.
	R3	349,9	161,4	144,1	692,7	Stosunek liczby studentów do liczby technicznych kierunków studiów.
Rozwój	R4	1,34	0,72	0,26	2,49	Liczba doktorantów przypadających na jednego samodzielnego pracownika.
	R5	0,02	0,01	0,00	0,03	Stosunek liczby uzyskanych habilitacji do liczby adiunktów.
	R6	0,09	0,04	0,03	0,18	Stosunek liczby uzyskanych doktoratów do liczby asystentów i doktorantów.
Jakość	N2	5,80	1,48	3,51	8,73	Liczba dyplomów przypadających na jednego promotora.
	N3	0,67	0,15	0,38	1,06	Stosunek liczby kierunków prowadzonych na studiach niestacjonarnych do liczby kierunków stacjonarnych.
	R7	0,12	0,06	0,00	0,23	Stosunek liczby otwartych przewodów doktorskich do liczby doktorantów.
Finanse	N4	0,46	0,04	0,39	0,54	Stosunek liczby nie-nauczycieli do liczby wszystkich pracowników.
	N5	119,8	16,6	88,6	152,4	Wysokość dotacji przypadająca na jednego nauczyciela akademickiego (tys. zł).
	N6	0,59	0,08	0,46	0,74	Stosunek wysokości dotacji do wielkości przychodów netto uczelni.
	R8	90,0	35,5	35,9	154,0	Wysokość przychodów własnych uczelni na jednego nauczyciela (tys. zł).

zostały obliczone z okresu pięcioletniego (2007–2011), co jest uzasadnione długością cyklu badawczego i publikacyjnego, który praktycznie nigdy nie zamyka się w ciągu jednego roku (Leitner i in., 2007). Oba te wskaźniki są skorelowane na poziomie 0,92, jednak biorąc pod uwagę opisane powyżej zasady, zostały włączone do modelu. Wysoka korelacja wynika z tego, że uczelnie, które publikują dużo wartościowych publikacji, są często cytowane. Podkreślić należy, że zarówno wskaźnik liczby publikacji, jak i cytowań dotyczy tego samego okresu, a więc wskaźnik cytowań odnosi się w większym stopniu do publikacji z lat poprzedzających rok 2007. Z punktu widzenia oceny obszaru badawczego oba wskaźniki są bardzo istotne.

W obszarze działalności dydaktycznej, zmienna (N1) – stosunek liczby dyplomów licencjackich do liczby wszystkich dyplomów studiów I stopnia, na studiach stacjonarnych i niestacjonarnych, pośrednio odzwierciedla skalę studiów na kierunkach nietechnicznych, a więc z punktu widzenia realizacji misji uczelni technicznych wartość ta powinna być minimalizowana. Zmienna (R3) – stosunek łącznej liczby studentów stacjonarnych i niestacjonarnych studiujących na technicznych kierunkach studiów do liczby technicznych kierunków studiów, określa pośrednio aspekt kosztów kształcenia, gdyż wraz ze wzrostem liczby studentów na roku maleją koszty przypadające na jednego studenta, a więc ten wskaźnik powinien być maksymalizowany. Wskaźniki N1 i R3 są skorelowane na poziomie 0,66.

W obszarze rozwoju kadry, zmienna (R4) – liczba doktorantów przypadających na jednego samodzielnego pracownika, odzwierciedla zaangażowanie potencjalnych promotorów w proces doktoryzowania, a w przypadku, gdy promotorem jest doktor habilitowany wpływa pośrednio na termin uzyskania przez niego tytułu

profesora. Zmienna (R5) – stosunek liczby uzyskanych stopni doktora habilitowanego do liczby adiunktów, odzwierciedla skuteczność rozwoju kadry ze stopniem naukowym doktora. Natomiast zmienna (R6) – stosunek liczby uzyskanych doktoratów do liczby doktorantów i asystentów, jest miarą skuteczności rozwoju słuchaczy studiów doktoranckich i asystentów. Wszystkie te zmienne powinny być maksymalizowane. Zmienne R4 i R5 są skorelowane na poziomie 0,71, natomiast korelacja pozostałych zmiennych mieści się w przedziale 0,17–0,20.

Dla obszaru jakości zdefiniowano trzy wskaźniki. Zmienna (N2) – liczba dyplomów na studiach stacjonarnych i niestacjonarnych przypadająca na jednego nauczyciela akademickiego (od stopnia doktora wzwyż), powinna być minimalizowana, ponieważ w celu zapewnienia sprawności i wysokiej jakości procesu dyplomowania liczba dyplomantów na jednego promotora powinna być jak najmniejsza. Zmienna (N3) – stosunek liczby kierunków na studiach niestacjonarnych do liczby kierunków na studiach stacjonarnych, odzwierciedla skalę studiów prowadzonych odpłatnie. Studia niestacjonarne prowadzone są w mniejszym wymiarze godzinowym, a studenci nie mogą poświęcić takiej samej ilości czasu na pracę własną, co studenci stacjonarni – odbija się na to na jakości uzyskiwanych efektów kształcenia i stąd wartość tej zmiennej powinna być minimalizowana. Zmienna (R7) – stosunek liczby otwartych przewodów doktorskich do liczby uczestników studiów doktoranckich i asystentów, głównie opisuje skuteczność prowadzonych studiów doktoranckich. W czteroletnim cyklu tych studiów przewody doktorskie powinny być otwierane po drugim roku. Zmienna ta powinna być maksymalizowana, gdyż dostępne statystyki wskazują na małą skuteczność procesu realizacji tej formy studiów. Korelacja zmiennych z tego obszaru mieści się w przedziale 0,24–0,58.



W obszarze finansowym uwzględniono cztery zmienne określające strukturę kosztów i źródeł finansowania oraz skuteczność pozyskiwania środków ze źródeł zewnętrznych. Zmienna (N4) – stosunek liczby pracowników niebędących nauczycielami do liczby wszystkich pracowników, pośrednio określa koszty administracji i pracowników technicznych i powinna być minimalizowana. Zmienna (N5) – wysokość dotacji przypadająca na jednego nauczyciela akademickiego, pośrednio odzwierciedla koszty płac, które są dominującym kosztem funkcjonowania uczelni, a więc zmienna ta powinna być minimalizowana. Zmienna (N6) – stosunek wysokości dotacji do wielkości przychodów netto uczelni, odzwierciedla

zdolność uczelni do pozyskiwania przychodów ze źródeł zewnętrznych. Natomiast zmienna (R8) – wysokość przychodów własnych uczelni przypadająca na jednego nauczyciela akademickiego, odzwierciedla w sposób pośredni aktywność pracowników w pozyskiwaniu środków, np. w postaci grantów. Korelacja zmiennych w tym obszarze mieści się w przedziale 0,24–0,70.

### Wyniki pomiaru efektywności i ich interpretacja

Dla każdego z pięciu obszarów, zgodnie z metodyką opisaną w Aneksie 1, zostały wyliczone złożone wskaźniki CIs. Następnie obliczono jeden zagregowany wskaźnik

Tabela 2  
Ranking uczelni technicznych na podstawie złożonych wskaźników

Uczelnia	Miejsce w rankingu na podstawie wskaźników złożonych dla pięciu wyodrębnionych obszarów					Wskaźnik łączny CI <sub>t</sub>	
	Badania CI <sub>b</sub>	Dydaktyka CI <sub>d</sub>	Rozwój CI <sub>r</sub>	Jakość CI <sub>j</sub>	Finanse CI <sub>f</sub>	Wartość	Ranking
Politechnika Wrocławska	2	1	3	1	10	7,99	1
Politechnika Warszawska	1	2	2	6	5	7,84	2
Akademia Górniczo-Hutnicza	5	3	4	3	1	7,59	3
Politechnika Gdańska	3	4	1	5	15	7,25	4
Politechnika Poznańska	6	5	5	12	2	6,74	5
Politechnika Łódzka	4	10	6	4	8	6,70	6
Politechnika Śląska	8	8	8	7	7	6,23	7
Zachodniopomorski Uniwersytet Techniczny	7	12	7	2	18	5,85	8
Politechnika Krakowska	13	6	14	9	4	5,39	9
Politechnika Lubelska	9	7	10	11	11	5,36	10
Politechnika Częstochowska	12	14	9	8	6	5,22	11
Politechnika Rzeszowska	10	11	15	10	9	4,70	12
Politechnika Białostocka	11	13	13	13	12	4,39	13
Politechnika Świętokrzyska	16	9	18	17	13	3,76	14
Politechnika Opolska	14	15	11	14	14	3,67	15
Politechnika Radomska	18	16	12	16	17	3,16	16
Politechnika Koszalińska	15	17	16	15	16	3,06	17
Akademia Techniczno- Humanistyczna	17	18	17	18	3	2,80	18

odwzorowujący wszystkie analizowane obszary. Do obliczeń zastosowano jednokowe wartości wag dla wszystkich wskaźników cząstkowych, co jest jedną z części stosowanych metod agregacji (Paruolo, Saisana i Saltelli, 2013). Wyniki przedstawiono w Tabeli 2.

Uczelnie są uszeregowane według wartości łącznego złożonego wskaźnika  $CI_t$ , obliczonego na podstawie 5 wskaźników cząstkowych:  $CI_b$  – dla obszaru badań,  $CI_d$  – dla obszaru dydaktyki,  $CI_r$  – dla obszaru rozwoju,  $CI_j$  – dla obszaru jakości oraz  $CI_f$  – dla obszaru finansów. Takie obliczenia pozwalają na określenie pozycji uczelni, w każdym z wyróżnionych obszarów. Zastosowana metoda wykorzystująca złożone wskaźniki pozwala głównie na tworzenie rankingów, ale można również na jej podstawie wskazać silne i słabe obszary każdej uczelni. Jednakże trudno jest określić ilościowo konkretne kierunki zmian, jakie uczelnie powinny wprowadzić, aby poprawić swoją pozycję, a tym samym zwiększyć efektywność. Można dokonać analizy jakościowej, np. dla Akademii Techniczno-Humanistycznej, zajmującej ostatnie pozycje w rankingach, można wskazać, że jej mocną stroną jest obszar finansowy, w którym zajmuje pierwszą pozycję. Wynika to głównie z tego, że uczelnia ta ma najniższy wskaźnik liczby pracowników niebędących nauczycielami (39%), a więc i najniższe koszty administracji oraz najniższy wskaźnik dotacji na jednego nauczyciela akademickiego, co wynika pośrednio z jednego z najwyższych wskaźników udziału studentów niestacjonarnych w ogólnej liczbie studentów, a więc z dużych przychodów z odpłatnej dydaktyki. Politechnika Wrocławska, mimo pierwszego miejsca w ogólnym ranking, w obszarze finansowym zajmuje 10 miejsce. Wynika to m.in. z relatywnie wysokiego wskaźnika dotacji przypadającej na jednego nauczyciela akademickiego

i wysokiego udziału pracowników niebędących nauczycielami (49%).

Zastosowanie metody DEA pozwala na rozszerzenie analizy, poza opracowanie rankingu, przez wskazanie ilościowych zmian, jakie należy wprowadzić w każdym z czynników branych pod uwagę w analizie efektywności. Aby uwzględnić wszystkie wskazane wcześniej obszary, dokonano wyboru najbardziej reprezentatywnych zmiennych dla każdego z nich. Z zestawu 14 zmiennych wybrano 9 (2 nakłady i 7 rezultatów). Przy doborze zmiennych kierowano się zasadą, aby liczba porównywanych jednostek nie była niższa od łącznej liczby zmiennych uwzględnionych w modelu, oraz aby każdy z obszarów był reprezentowany. Zgodnie z wcześniejszym opisem są to zmienne: N3, N6, R1, R2, R3, R4, R5, R7, R8. Weryfikacji poprawności doboru zmiennych dokonano przez obliczenie złożonego wskaźnika dla tych 9 zmiennych. Uzyskano zadowalającą zgodność rankingów otrzymanych dla dwóch zestawów zmiennych, przedstawioną w Tabeli 3 (współczynnik korelacji dla rankingów z 14 i 9 zmiennymi wynosi 0,98).

Obliczenia efektywności zostały przeprowadzone z wykorzystaniem modelu DEA-SBM o zmiennych efektach skali, zorientowanego na rezultaty, którego opis znajduje się w Aneksie 2. Do obliczeń wykorzystano program DEA Solver LV(3). W danych opisujących uczelnie, w trzech przypadkach wystąpiły wartości zerowe rezultatów. Dotyczy to Politechniki Radomskiej i Świętokrzyskiej, w których nikt nie uzyskał habilitacji w badanym roku (rezultat R5), dodatkowo na drugiej z tych uczelni nie otworzono nowych przewodów doktorskich (rezultat R7). Wartości te zostały zamienione na małe wartości dodatnie (0,0001), co pozwoliło na uwzględnienie tych uczelni w analizie. W Tabeli 3 przedstawiono uzyskane wyniki efektywności oraz wynikający z nich ranking, wraz z porównaniem

Tabela 3

Wyniki pomiaru efektywności i porównanie rankingów uczelni technicznych

Uczelnie	Rankingi wg wartości $Cl_t$		Obliczenia efektywności DEA-SBM		
	14	9	Ranking	Wynik	Zbiór odniesienia
	zmiennych	zmiennych			
Politechnika Wrocławska	1	1	1	1	
Politechnika Warszawska	2	2	2	1	
Akademia Górniczo-Hutnicza	3	4	3	1	
Politechnika Gdańska	4	3	4	1	
Politechnika Łódzka	6	5	5	0,738	PWr (0,639), PW (0,361)
Politechnika Poznańska	5	6	6	0,650	PWr (0,879), PW (0,121)
Zachodniopomorski Uniwersytet Techniczny	8	8	7	0,616	AGH (0,764), PW (0,236)
Politechnika Śląska	7	7	8	0,611	PWr (0,710), PW (0,290)
Politechnika Częstochowska	11	9	9	0,485	PWr (1,0)
Politechnika Lubelska	10	11	10	0,466	PWr (1,0)
Politechnika Krakowska	9	12	11	0,435	PWr (1,0)
Politechnika Białostocka	13	13	12	0,416	PW (0,775), PWr (0,225)
Politechnika Rzeszowska	12	10	13	0,411	PWr (1,0)
Politechnika Opolska	15	15	14	0,303	PW (1,0)
Politechnika Koszalińska	17	17	15	0,235	PW (1,0)
Akademia Techniczno- -Humanistyczna	18	16	16	0,178	PWr (1,0)
Politechnika Świętokrzyska	14	14	17	0,022	PW (0,889), AGH (0,111)
Politechnika Radomska	16	18	18	0,003	PWr (1,0)

z dwoma rankingami stworzonymi na podstawie złożonych wskaźników. Dodatkowo przedstawiono zbiory odniesienia dla uczelni nieefektywnych, pokazujące, jak powinny wzorować się na uczelniach efektywnych, aby polepszyć swoje wskaźniki. Najbardziej efektywna uczelnia, Politechnika Wrocławska, znajduje się w zbiorze odniesienia 10 razy, z czego w sześciu przypadkach jest jedynym wzorcem dla uczelni nieefektywnych. Politechnika Warszawska wystąpiła 8 razy, z czego w dwóch przypadkach jest jedynym wzorcem dla nieefektywnych uczelni, a Akademia Górniczo-Hutnicza występuje w zbiorze odniesienia w dwóch przypadkach. Politechnika Gdańska, mimo wyniku efektywności o wartości równej jeden, nie znalazła się w zbiorze

odniesienia, zjawisko to określa się mianem tzw. efektywności domyślnej (*by default*; Tauer, Fried i Fry, 2007). Wartości podane w nawiasach to współczynniki intensywności, wskazujące udział technologii jednostek efektywnych, jaki musi być zastosowany, aby uczelnia nieefektywna osiągnęła pełną efektywność.

Model został poddany analizie wrażliwości w celu sprawdzenia wiarygodności uzyskanych wyników. Analiza wrażliwości jest powiązana ze źródłami niepewności, takimi jak: sposób normalizacji danych, schemat przypisywania wag, zasady agregacji, włączanie i wyłączenie wskaźników cząstkowych oraz uzupełnianie brakujących danych (Cherchyei in., 2006; Mascherini i Manca 2009). Z punktu widzenia proponowanego

w artykule modelu, analiza ograniczyła się do sprawdzenia istnienia jednostek odstających, co uczyniono poprzez wyłączenie kolejnych nieefektywnych uczelni ze zbioru i obserwację wpływu tego działania na pozycję pozostałych uczelni w rankingu. W wyniku przeprowadzonych obliczeń stwierdzono, że przesunięcia w rankingu następują co najwyżej o jedno miejsce, a więc można przyjąć, że wiarygodność wyników jest wystarczająca.

### Wykorzystanie wyników DEA do usprawnienia funkcjonowania uczelni

W Tabeli 4 przedstawione są wyniki projekcji uczelni nieefektywnych na granicę dobrych praktyk, tworzonej przez cztery uczelnie w pełni efektywne. Zgodnie z definicją efektywności DEA, oznacza to, że uczelnie nieefektywne osiągną efektywność równą jedności oraz będą miały zerowe nadwyżki nakładów i zerowe niedobory rezultatów. Wprowadzenie w tych uczelniach

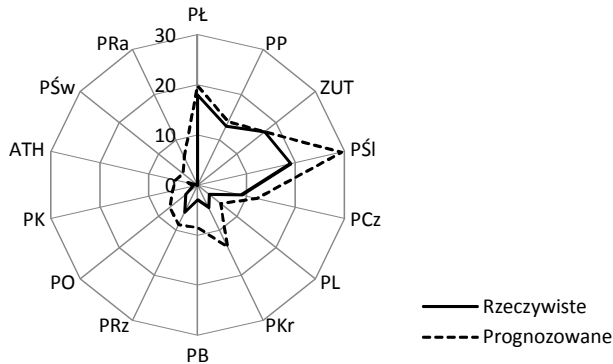
zmian, zgodnie z podanymi wartościami spowoduje, że osiągną one efektywność taką, jaką mają cztery uczelnie najlepsze.

Wykorzystując wartości procentowe pożądaných zmian, na podstawie danych źródłowych, określono wartości bezwzględne dla wskaźników. W przypadku rezultatu R5 (stosunku liczby uzyskanych stopni doktora habilitowanego do liczby adiunktów) dokonano przeliczenia na bezwzględną liczbę habilitacji, jakie powinny być uzyskiwane w ciągu roku. Wartości 999,9% w tabeli wynikają ze wspomnianych wcześniej zerowych wartości rezultatu R5 dla dwóch uczelni: Politechniki Radomskiej i Świętokrzyskiej. Wyniki przedstawiono na Rysunku 1.

Na dwóch wspomnianych wcześniej uczelniach, które nie miały w badanym roku żadnych habilitacji, powinno habilitować się odpowiednio: 6 i 4 pracowników rocznie. Różnica wynika z tego, że na Politechnice Radomskiej pracuje blisko dwa razy więcej doktorów niż na Świętokrzyskiej.

Tabela 4  
Projekcja uczelni nieefektywnych na granicę dobrych praktyk

Uczelnie	Wartość i kierunek zmian [w %]							
	R1	R2	R3	R4	R5	R7	R8	
Politechnika Łódzka	40,2	16,8	129,7	6,0	10,0	39,1	6,4	
Politechnika Poznańska	37,8	56,6	58,9	10,8	7,7	186,2	18,7	
Zachodniopomorski Uniwersytet Techniczny	38,1	16,4	197,2	14,4	0,0	5,9	163,7	
Politechnika Śląska	149,9	67,4	58,6	26,3	54,7	72,2	16,1	
Politechnika Częstochowska	229,2	95,6	241,7	14,3	34,3	66,7	60,9	
Politechnika Lubelska	187,7	78,7	107,8	217,6	95,6	70,4	44,2	
Politechnika Krakowska	197,1	210,0	72,2	135,4	175,8	85,1	32,9	
Politechnika Białostocka	386,0	70,9	131,0	97,8	182,6	0,0	114,6	
Politechnika Rzeszowska	167,7	102,8	77,0	500,2	45,8	78,7	32,3	
Politechnika Opolska	805,2	160,7	173,9	131,8	139,3	8,5	188,0	
Politechnika Koszalińska	806,6	210,9	310,8	116,3	418,1	91,4	328,1	
Akademia Techniczno- -Humanistyczna	937,8	480,0	303,8	718,4	128,2	556,2	108,2	
Politechnika Świętokrzyska	999,9	215,3	70,3	107,7	999,9	44,3	95,5	
Politechnika Radomska	999,9	702,8	321,1	867,0	999,9	999,9	189,0	




Rysunek 1. Liczba habilitacji uzyskanych w ciągu roku: rzeczywistych i koniecznych do uzyskania w tym samym okresie dla osiągnięcia pełnej efektywności.

Zachodniopomorski Uniwersytet Technologiczny jest jedyną z nieefektywnych uczelni, w której proces zdobywania stopni doktora habilitowanego przebiega prawidłowo. Największy przyrost jest wymagany dla Politechniki Śląskiej (z 19 do 29). Wynika to z faktu, że uczelnia ta ma liczbę doktorów porównywalną do trzech najlepszych uczelni, natomiast liczbę uzyskanych stopni doktora habilitowanego o ponad 30% niższą.


W przypadku działalności naukowej, mierzonej liczbą cytowań (R1) i publikacji (R2) przypadającą na jednego nauczyciela akademickiego, wszystkie nieefektywne uczelnie powinny zwiększyć R1 do poziomu

około 10 a R2 do poziomu 2,5. Ilustracja koniecznych zmian dla rezultatu R1 została przedstawiona na Rysunku 2.

Politechniki: Poznańska i Łódzka oraz Zachodniopomorski Uniwersytet Techniczny powinny uzyskać liczbę cytowań w okresie pięcioletnim o około 2–3 razy większą niż uzyskane w latach 2007–2011. W przypadku pozostałych uczelni konieczne jest zdecydowane podniesienie jakości publikowanych prac naukowych, aby uzyskać większą liczbę cytowań. Przykładowo, dla Politechniki Opolskiej i Koszalińskiej wymagane jest blisko dziesięciokrotne zwiększenie wartości tego rezultatu. W podobny sposób



Rysunek 2. Liczba cytowań przypadająca na jednego nauczyciela akademickiego: rzeczywista i konieczna dla osiągnięcia pełnej efektywności.



Rysunek 3. Liczba doktorantów przypadających na jednego samodzielnego pracownika naukowego: rzeczywista i konieczna dla uzyskania pełnej efektywności.

przedstawiają się wymagania w stosunku do zwiększenia liczby publikacji przypadających na jednego nauczyciela akademickiego (R2).

Rysunek 3 ilustruje stopień wykorzystania potencjału uczelni w zakresie realizacji studiów doktoranckich, na podstawie liczby doktorantów przypadających na samodzielnego pracownika naukowego (R4). Politechniki: Łódzka, Poznańska, Śląska, Częstochowska oraz Zachodniopomorski Uniwersytet Techniczny dobrze wykorzystują swój potencjał w obszarze doktoryzowania, a wymagana zmiana jest kilkunastoprocentowa. Natomiast Politechniki: Rzeszowska, Radomska oraz Akademia Techniczno-Humanistyczna powinny zwiększyć kilkakrotnie liczbę doktorantów przypadającą na jednego promotora. Tak zróżnicowana sytuacja jest częściowo determinowana posiadanymi przez poszczególne uczelnie uprawnieniami akademickimi.

We wszystkich uczelniach nieefektywnych, w porównaniu do uczelni efektywnych, obserwuje się zbyt małą liczbę studentów przypadającą na kierunek studiów. Duża liczba kierunków niewątpliwie uatrakcyjnia ofertę edukacyjną uczelni, jednakże z punktu widzenia efektywności ekonomicznej realizacji procesu dydaktycznego jest to zjawisko negatywne. Dla wybranych trzech uczelni

efektywnych i czterech nieefektywnych przedstawiono podstawowe charakterystyki ilustrujące ten problem (Tabela 5).

W dużych uczelniach, osiągających pełną efektywność, zachowana jest odpowiednia relacja między liczbą studentów a liczbą prowadzonych kierunków studiów. Przy założeniu średniego 2,5-letniego cyklu kształcenia (3–3,5 roku dla studiów I stopnia i 1,5–2 lata dla studiów II stopnia) w uczelniach efektywnych na roku każdego kierunku studiuje średnio ok. 250–300 studentów, podczas gdy w uczelniach nieefektywnych ok. 80. W celu zilustrowania różnicy w kosztach, przyjęto hipotetycznie grupę 240 studentów studiujących na roku, w dwóch uczelniach. Na jednej cała grupa studiuje na jednym kierunku, a na drugiej na trzech kierunkach, po 80 osób na każdym. Zakładając, że w roku akademickim jest 300 godzin wykładów w programie studiów dla każdego kierunku, najogólniej można to zinterpretować w ten sposób, że w tym drugim przypadku, przy tej samej liczbie studentów realizowana jest trzykrotnie większa liczba godzin wykładowych. Tym samym koszt zajęć wykładowych na jednego studenta jest w tym przypadku trzykrotnie wyższy.

Tabela 5

Podstawowe charakterystyki dotyczące obszaru kształcenia w wybranych uczelniach


Uczelnia	Efektywność	Liczba studentów	Liczba nauczycieli	Liczba kierunków stac./niestac.	Liczba kierunków technicznych stac./niestac.	Udział kierunków technicznych	Studenci na kierunek w 2011 r.	Studenci na kierunek prognoza
Politechnika Wrocławska	1	33 775	1 933	29/13	25/12	0,88	804	
Politechnika Warszawska	1	33 125	2 187	28/19	23/15	0,80	705	
Akademia Górniczo-Hutnicza	1	34 248	2 154	35/20	28/17	0,82	623	
Zachodniopomorski								
Uniwersytet Techniczny	0,558	12 940	1 079	37/23	31/17	0,80	215	642
Politechnika Koszalińska	0,240	9 244	524	24/20	15/12	0,61	210	804
Akademia Techniczno- -Humanistyczna	0,185	7 282	399	17/18	9/9	0,51	208	804
Politechnika Radomska	0,003	8 125	508	27/18	9/8	0,38	180	804

Liczba kierunków studiów prowadzonych na Politechnice Radomskiej i Koszalińskiej jest porównywalna z Politechniką Wrocławską i Warszawską, jednakże przy około czterokrotnie mniejszej liczbie studentów i nauczycieli akademickich, co musi też wpływać na jakość procesu kształcenia. Uczelnie najmniej efektywne mają również znacznie bardziej rozwinięte kształcenie na studiach niestacjonarnych, na co wskazuje liczba kierunków, jak również stosunek liczby studentów niestacjonarnych do liczby studentów ogółem: dla uczelni efektywnych mieści się w zakresie 17–24%, a dla nieefektywnych (poza ZUT) przyjmuje wartości z od 33 do 37%. Ważnym czynnikiem wpływającym na nieefektywność uczelni jest udział kierunków technicznych w ogólnej liczbie kierunków (łącznie dla studiów stacjonarnych i niestacjonarnych). W uczelniach efektywnych kierunki techniczne są dominujące, z udziałem w zakresie 80–88%, natomiast w najmniej efektywnej Politechnice Radomskiej nie przekraczają 40%. Warto też zwrócić uwagę na udział studentów na kierunkach technicznych w ogólnej

liczbie studentów, który na uczelniach efektywnych mieści się w przedziale 91–95%, a na nieefektywnych 44–51%.

Powyższe uwagi nie odnoszą się do Zachodniopomorskiego Uniwersytetu Technicznego, który, co prawda nie jest efektywny, ale poza liczbą studentów przypadających na jeden kierunek studiów, wszystkie pozostałe parametry ma zbliżone do uczelni efektywnych. Poprawa efektywności w obszarze dydaktyki jest możliwa, oczywiście nie przez zwiększenie liczby studentów, ale przez zredukowanie liczby kierunków.

Słabością wszystkich studiów doktoranckich jest mała liczba otwieranych przewodów w relacji do liczby doktorantów. W przypadku Politechniki Wrocławskiej wskaźnik ten przyjmuje wartość 23%, a w przypadku Akademii Górniczo-Hutniczej wartość 20%. Wśród uczelni nieefektywnych dobre wyniki pod tym względem notują: Zachodniopomorski Uniwersytet Techniczny i Politechnika Opolska, natomiast Akademia Techniczno-Humanistyczna ma otwarty jeden przewód na 28 doktorantów, a Politechnika Radomska nie ma ani jednego na 34 doktorantów



Rysunek 4. Stosunek liczby otwartych przewodów do liczby doktorantów: rzeczywisty i konieczny dla uzyskania pełnej efektywności.


(w latach 2009–2010 w Akademii Techniczno-Humanistycznej były otwarte 4 przewody, natomiast w Politechnice Radomskiej nie był otwarty żaden). Ilustracja tego wskaźnika dla uczelni nieefektywnych znajduje się na Rysunku 4.

Publiczne uczelnie finansowane są głównie z dotacji, jednakże środki z budżetu nie wystarczają na ich utrzymanie. Lepsze uczelnie pozyskują środki z grantów i przemysłu, natomiast słabsze, nieprowadzące badań na odpowiednim poziomie, nie mają szans na ich pozyskanie. W zasadzie wszystkie uczelnie pozyskują również środki z odpłatnych form studiów, jednakże

w uczelniach nieefektywnych skala studiów niestacjonarnych jest większa, co wcześniej było zasygnalizowane. Ten problem zilustrowano na Rysunku 5.

### Podsumowanie

W artykule dokonano pomiaru i oceny efektywności uczelni technicznych, wskazując jednocześnie na sposób wykorzystania wyników, pozwalający na wskazanie kierunków zmian, jakie są wymagane dla poszczególnych uczelni nieefektywnych, aby osiągnęły pełną efektywność, co określa się mianem projekcji uczelni



Rysunek 5. Przychody własne uczelni przypadające na nauczyciela akademickiego: rzeczywiste i konieczne dla uzyskania pełnej efektywności (w tys. zł).



nieefektywnych na granicę dobrych praktyk, wyznaczanych przez uczelnie najlepsze. Badania efektywności metodami nieparametrycznymi nie powinny ograniczać się jedynie do stworzenia rankingów, gdyż głównym celem powinno być określenie przyczyn nieefektywności, jak również wskazanie kierunków zmian, jakie należy wprowadzić w uczelniach nieefektywnych, aby ich sytuacja uległa poprawie.

Istotną sprawą w tego typu badaniach jest dobór odpowiedniego modelu i jego weryfikacja przed ostatecznym dokonaniem oceny. Stosowanie modeli radialnych jest proste, jednakże należy mieć świadomość, że dopuszczają one zerowe wagi dla nakładów i rezultatów, a więc w wielu przypadkach, nawet przy kilku zmiennych, na wynik wpływa niewielka ich liczba. Oznacza to, że w obliczeniach wyniku efektywności nie są uwzględniane wszystkie czynniki na nią wpływające.

Metoda zastosowana w artykule, poza rankingami, pozwala na identyfikację źródeł nieefektywności. W modelu uwzględniono łączny wpływ wszystkich procesów realizowanych w szkołach wyższych. Zwrócono również uwagę na realizację misji uczelni technicznej, prowadzenia dydaktyki w zakresie kierunków technicznych. Ostatnia z uczelni Politechnika Radomska w 2012 r. zmieniła nazwę na Uniwersytet Technologiczno-Humanistyczny, co w świetle uzyskanych wyników jest w pełni uzasadnione. Wydaje się, że podobna zmiana może być wprowadzona również w innych najmniej efektywnych uczelniach technicznych, co lepiej odwzoruje profil ich działalności dydaktycznej.

### Literatura

- Abbott, M. i Doucouliagos, H. (2004). Research Output of Australian Universities. *Education Economics*, 12(3), 251–265.
- Antonowicz, D. i Gorlewski, B. (2011). *Demograficzne tsunami. Raport na temat wpływu zmian demograficznych na szkolnictwo wyższe do 2020 roku*. Warszawa: Instytut Rozwoju Kapitału Intelektualnego im. Sokratesa.
- Charnes, A., Cooper, W. W. i Rhodes, E. (1978). Measuring the efficiency of decision making units. *European Journal of Operational Research*, 6(2), 429–444.
- Cherchye, L., Moesen, W., Rogge, N., Van Puyembroeck, T., Saisana, M., Saltelli A., Liska, R. i Tarantola, S. (2006). *Creating composite indicators with DEA and robustness analysis: the case of the Technology Achievement Index*. Pobrano z: <http://www.econ.kuleuven.ac.be/ew/academic/econover/Papers/DPS0603.pdf>
- Coelli, T., Rao, P., O'Donnell, Ch. i Battese, G. (2005). *An introduction to efficiency and productivity analysis*. New York, NY: Springer.
- 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 Zhu, J. (2011). *Handbook on Data Envelopment Analysis*. New York, NY: 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, NY: Springer.
- Ćwiąkała-Małyś, A. (2010). *Pomiar efektywności procesu kształcenia w publicznym szkolnictwie akademickim*. Wrocław: Wydawnictwo Uniwersytetu Wrocławskiego.
- Debreu, G. (1951). The coefficient of resource utilization. *Econometrica*, 19(3), 273–292.
- Decancq, K. i Lugo, M. A. (2010). *Weights in multidimensional indices of well-being: an overview*. Discussions Paper Series (DPS) 10.06., Leuven: Center for Economic Studies, Katholieke Universiteit Leuven.
- Despotis, D. K. (2005). Measuring human development via Data Envelopment Analysis: the case of Asia and the Pacific. *Omega – The International Journal of Management Science*, 33(5), 385–390.
- Domagała, A. (2007). Metoda Data Envelopment Analysis jako narzędzie badania względnej efektywności technicznej. *Badania operacyjne i decyzje*, 3–4, 21–34.
- Dziennik Ustaw Nr 84 (2011). *Ustawa z dnia 18 marca 2011 r. o zmianie ustawy – Prawo o szkolnictwie wyższym, ustawy o stopniach nauko-*

- wych i tytule naukowym oraz o stopniach i tytule w zakresie sztuki oraz o zmianie niektórych innych ustaw.
- Farell, M. J. (1957). The measurement of productive efficiency. *Journal of the Royal Statistical Society*, 120(3), 253–290.
- Filippetti, A. i Peyrache, A. (2011). The patterns of technological capabilities of countries: a dual approach using composite indicators and Data Envelopment Analysis. *World Development*, 39(7), 1108–1121.
- Główny Urząd Statystyczny (2012). *Szkoły wyższe i ich finanse w 2011 roku*. Warszawa: GUS.
- Główny Urząd Statystyczny (2013). Bank Danych Lokalnych. Pobrano z: <http://www.stat.gov.pl/bdl>
- Guzik, B. (2009a). *Podstawowe modele DEA w badaniu efektywności gospodarczej i społecznej*. Poznań: Wydawnictwo Uniwersytetu Ekonomicznego w Poznaniu.
- Guzik, B. (2009b). Podstawowe możliwości analityczne modelu CCR-DEA. *Badania operacyjne i decyzje*, 1, 55–75.
- Haas, D. A. i Murphy, F. H. (2003). Compensating for non-homogeneity in decision-making units in data envelopment analysis. *European Journal of Operational Research*, 144(3), 530–544.
- Hollingsworth, B. i Smith, P. (2003). Use of ratios in data envelopment analysis. *Applied Economics Letters*, 10(11), 733–735.
- Kao, C. i Hung, H. T. (2008). Efficiency analysis of university departments. An empirical study. *Omega - The International Journal of Management Science*, 36(4) 653–664.
- Kempkes, G. i Pohl, C. (2010). The efficiency of German universities – some evidence from non-parametric and parametric methods. *Applied Economics*, 42(16), 2063–2079.
- Koopmans, T. C. (1951). Analysis of production as an efficient combination of activities. W: T. C. Koopmans (red.), *Activity analysis of production and allocation*. New York, NY: Wiley.
- Leitner, K. H., Prikoszovits, J., Schaffhauser-Linzatti, M., Stowasser, R. i Wagner, K. (2007). The impact of size and specialization on universities' department performance: a DEA analysis applied to Austrian universities. *Higher Education*, 53(4), 517–538.
- Liu, J. S., Lu, L. Y. Y., Lu, W. M. i Lin, B. J. Y. (2013). A survey of DEA applications. *Omega - The International Journal of Management Science*, 41(5), 893–902.
- Lukman, R., Krajnc, D. i Glavic, P. (2010). University ranking using research, educational and environmental indicators. *Journal of Cleaner Production*, 18(7), 619–628.
- Lovell, K. C. A. (1995). Measuring the macroeconomic performance of the Taiwanese economy. *International Journal of Production Economics*, 39(1–2), 165–178.
- Manca, A. R., Governatori, M. i Mascherini, M. (2010). *Towards a set of composite indicators on flexicurity: a comprehensive approach*. European Union: European Commission, Joint Research Centre.
- Mansfield, E. (1995). Academic research underlying industrial innovations: sources, characteristics, and financing. *The Review of Economics and Statistics*, 77(1), 55–65.
- Marginson, S. (2014). University Rankings and Social Science. *European Journal of Education*, 49(1), 45–59.
- Mascherini, M. i Manca A. R. (2009). *Towards a set of composite indicators on flexicurity: the composite indicator on active labour market policies*. European Commission: Joint Research Centre, European Communities.
- Mohamad, N. H. i Said, F. B. (2011). Comparing macroeconomic performance of OIC member countries. *International Journal of Economics and Management Sciences*, 3(1), 90–104.
- Murias, P., de Miguel, J. C. i Rodriguez, D. (2008). A Composite indicator for university quality assesment: the case of Spanish higher education system. *Social Indicators Research*, 89(1), 129–146.
- OECD (2008). *Handbook on constructing composite indicators. Methodology and user guide*. Paris: OECD Publishing.
- Paruolo, P., Saisana, M. i Saltelli, A. (2013). Ratings and rankings: voodoo or science? *Journal of the Royal Statistical Society. Series A, Statistics in Society*, 176(3), 609–634.
- Ranking szkół wyższych* (2013). Pobrano z: <http://www.perspektywy.pl/>
- Saisana, M., d'Hombres, B. i Saltelli, A. (2011). Rickety numbers: volatility of university rankings and policy implications. *Research Policy*, 40(1), 165–177.
- Salter, A. J. i Martin, B. R. (2001). The economic benefits of publicly funded basic research: a critical review. *Research Policy*, 30(3), 509–532.
- Shen, Y., Ruan, D., Hermans, E., Brijs, T., Wets, G. i Vanhoof, K. (2011). Modeling qualitative data

- in data envelopment analysis for composite indicators. *International Journal of System Assurance Engineering and Management*, 2(1), 21–30.
- Shwartz, M., Burgess, J. F. i Berlowitz, D. (2009). Benefit-of-the-doubt approaches for calculating a composite measure of quality. *Health Services and Outcomes Research Methodology*, 9(4), 234–251.
- Stiglitz, J. E. (2004). *Ekonomia sektora publicznego*. Warszawa: Wydawnictwo Naukowe PWN.
- Tarantola, S. i Mascherini, M. (2009). *Handbook on constructing composite indicators*. San Sebastian: EUSTAT–Euskal Estatistika Erakundea–Instituto Vasco de Estadística.
- Tauer, L. W., Fried, H. O. i Fry, W. E. (2007). Measuring efficiencies of academic departments within a college. *Education Economics*, 15(4), 473–489.
- Tone, K. (2001). A slacks-based measure of efficiency in data envelopment analysis. *European Journal of Operational Research*, 130(3), 498–509.
- Zrelli, N. i Hamida1 B. (2013). Efficiency and quality in higher education. A dynamic analysis. *Research in Applied Economics*, 5(4), 116–130.

### Podziękowania

Autorzy pragną podziękować za wnikliwe i inspirujące do dalszych poszukiwań uwagi recenzentów.

### Aneks 1. Metoda złożonych wskaźników

Złożone wskaźniki pozwalają na agregację wielu cząstkowych wskaźników w jedną miarę, pozwalającą na porównywanie wielu obiektów. Integrują one duże ilości informacji, w przejrzystym i zrozumiałym formacie, który jest łatwy do interpretacji dla odbiorców (Shen i in., 2011). Mają one zastosowanie zarówno w wymiarze kształtowania polityk, jak i w podejmowaniu decyzji o znaczeniu operacyjnym. Metodyka tworzenia CIs została opracowana przez OECD (2008), a przykładami jej wykorzystania mogą być: wskaźnik rozwoju społecznego (Human Development Index, HDI; Despotis, 2005) czy też model oceny możliwości technologicznych (Technological Capabilities, Filippetti i Peyrache, 2011). Na

podobnych zasadach buduje się też wszelkiego rodzaju rankingi, również uczelni wyższych, np. coroczny ranking czasopisma „Perspektywy”.

Budowa CIs wymaga określenia czynników wpływających na badane zjawisko, a tworzenie wskaźnika złożonego musi być poprzedzone normalizacją danych wejściowych. Do normalizacji można zastosować metodę Min–Max, która w podstawowej wersji sprowadza wartości wszystkich zmiennych do przedziału [0, 1].

$$I_{i\_norm} = \frac{I_i - I_{min}}{I_{max} - I_{min}} \quad (1)$$

gdzie:

$I_{i\_norm}$  – znormalizowana wartość  $i$ -tego elementu wektora wskaźników cząstkowych;

$I_i$  – wartość  $i$ -tego elementu wektora wskaźników cząstkowych;

$I_{min}$  – wartość minimalna wskaźnika cząstkowego;

$I_{max}$  – wartość maksymalna wskaźnika cząstkowego.

Na potrzeby analizy dokonano modyfikacji sposobu normalizacji w celu zachowania jednolitego kierunku preferencji (Mohamad i Said, 2011). Dla wskaźników cząstkowych, których większe wartości są oceniane pozytywnie (rezultaty), przyjęto transformację:

$$I_{i\_norm} = \frac{9(I_i - I_{min})}{I_{max} - I_{min}} + 1 \quad (2)$$

Dla wskaźników, których mniejsze wartości wskaźników cząstkowych są oceniane pozytywnie (nakłady) przyjęto transformację:

$$I_{i\_norm} = \frac{9(I_{max} - I_i)}{I_{max} - I_{min}} + 1 \quad (3)$$

Znormalizowane wartości należą do przedziału [1, 10]. Wskaźnik złożony jest sumą ważoną znormalizowanych wskaźników cząstkowych:

$$CI_r = \sum_{q=1}^Q w_q I_{qr} \quad (4)$$

gdzie:

$CI_r$  – wartość wskaźnika złożonego dla obiektu  $r$ -tego;

$w_q$  – waga  $q$ -tego wskaźnika cząstkowego;

$I_{qr}$  – wartość znormalizowanego  $q$ -tego wskaźnika cząstkowego dla  $r$ -tego obiektu

dla:  $r = 1, \dots, R$  –  $R$  to liczba obiektów uwzględnionych w analizie (liczba porównywanych uczelni)

oraz  $q = 1, \dots, Q$  –  $Q$  to liczba wskaźników cząstkowych (łączna liczba rezultatów i nakładów).

Wagi przyjmowane są najczęściej na podstawie opinii eksperckich (Shwartz, Burgess i Berlowitz, 2009), jednakże w wielu zastosowaniach przyjmuje się wagi jednakowe dla wszystkich czynników (np. Despotis, 2005; Manca, Governatori i Mascherini, 2010).

## Aneks 2. Nieparametryczna metoda DEA

Nieparametryczna metoda DEA wykorzystuje programowanie liniowe, nieuwzględniające wpływu czynnika losowego i błędów pomiaru, a także niewymagające określenia zależności funkcyjnej między nakładami a rezultatami, ani wag, jakie mają być przypisane do poszczególnych nakładów i rezultatów. Optymalne wagi są obliczane na podstawie danych, a nie ustalane subiektywnie (Cooper, Seiford i Tone, 2007).

Badanie efektywności wykorzystujące DEA polega na wyznaczeniu obiektów wzorcowych i przyrównywaniu do nich pozostałych obiektów. Stąd stwierdza się, że DEA sprawdza efektywność względną obiektów, zwanych jednostkami decyzyjnymi (*Decision Making Units*, DMU). Jednostki są „decyzyjne”, gdyż mają wpływ na poziom ponoszonych nakładów i uzyskiwanych rezultatów (Domagała, 2007).

Najbardziej ogólnie, modele stosowane w DEA można podzielić na dwie grupy: radialne i nieradialne. Dwa podstawowe, najczęściej stosowane modele radialne, 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 i in., 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, jak i nadwyżki nakładów i niedobory rezultatów są zerowe. Istnieje możliwość zastosowania modeli nieradialnych, które pozwalają na uwzględnienie luzów w obliczeniach efektywności (Cooper, Seiford i Zhu, 2011). W artykule zastosowano miarę efektywności bazującą na luzach (Slack Based Measure, SBM), która przyjmuje wartości z przedziału  $[0, 1]$ , eliminując niezerowe luzy nakładów i rezultatów (Cooper i in., 2007; Tone, 2001).

Model DEA-SBM, przy obliczaniu wyniku efektywności, w sposób bezpośredni, uwzględnia luzy nakładów i rezultatów (Cooper i in., 2011). Efektywność  $\rho_o^*$  dla DMU<sub>*o*</sub> = ( $x_o$ ,  $y_o$ ) według modelu SBM zorientowanego na rezultaty, ze zmiennymi efektami skali, jest definiowana:

$$\frac{1}{\rho_o^*} = \max_{\lambda, s^-, s^+} 1 + \frac{1}{s} \sum_{r=1}^s \frac{s_r^+}{y_{ro}} \quad (5)$$

z warunkami:

$$\begin{aligned} x_{io} &= \sum_{j=1}^n x_{ij} \lambda_j + s_i^- & (i = 1, \dots, m) \\ y_{ro} &= \sum_{j=1}^n y_{rj} \lambda_j - s_r^+ & (r = 1, \dots, s) \end{aligned} \quad (6)$$

$$\lambda_j \geq 0 (\forall j) \quad s_i^- \geq 0 (\forall i) \quad s_r^+ \geq 0 (\forall r) \quad (7)$$

$$\sum_{j=1}^n \lambda_j = 1 \quad (8)$$

gdzie:

$x_j, y_j$  – wektory nakładów i rezultatów DMU<sub>j</sub>,  
dla  $j = 1, \dots, n$ ;

$n$  – liczba DMU;

$s_i^-$  – nadwyżki nakładów dla  $i = 1, \dots, m$ ;

$m$  – liczba nakładów;

$s_r^+$  – niedobory rezultatów dla  $r = 1, \dots, s$ ;

$s$  – liczba rezultatów;

$\lambda_j$  – współczynnik intensywności dla DMU<sub>j</sub>.

Wymaga się, aby nakłady i rezultaty miały wartości większe od zera. DMU<sub>o</sub> = ( $x_o, y_o$ ) jest efektywna, jeżeli  $\rho_o^* = 1$ , co oznacza, że niedobory rezultatów są równe zero, natomiast nadwyżki nakładów mogą być niezerowe.

Model SBM wymaga, aby wszystkie wartości rezultatów i nakładów były większe od zera. W przypadku występowania wartości zerowych, jednym ze sposobów spełnienia tego założenia jest zastąpienie wartości zerowych bardzo małą liczbą dodatnią (Cooper i in., 2011), co zapobiega konieczności usunięcia DMU z analizy.

Podkreśla się (Cooper i in., 2007), że jednym z głównych celów badania DEA jest projekcja nieefektywnych DMU na granicę produkcji, dla przypadku, gdy nakłady są traktowane jako zasoby potrzebne do

wyprodukowania rezultatów. Chociaż DEA ma silne powiązanie z ekonomiczną teorią produkcji, jest również szeroko wykorzystywana do analizy porównawczej (*benchmarkingu*). W tym przypadku, efektywne DMU, zdefiniowane przez DEA, nie tworzą „granicy produkcji”, lecz prowadzą do stworzenia „granicy najlepszych praktyk”. W tym przypadku nakłady nie są traktowane jako zasoby potrzebne do osiągnięcia określonych rezultatów. Poszczególne zmienne są zaklasyfikowane do nakładów, jeżeli niższe poziomy ich wartości, z punktu widzenia celu badania, są pozytywnie oceniane, a do rezultatów, jeżeli wyższe poziomy ich wartości są pozytywnie oceniane (Cook, Tone i Zhu, 2014).

Przy doborze modelu ważne jest określenie jego orientacji. Zależy ona od tego, czy celem badania jest redukcja nakładów przy zachowaniu przynajmniej obecnego poziomu rezultatów, tzw. orientacja na nakłady, czy też skupienie się na maksymalizacji rezultatów przy zachowaniu, co najwyżej obecnego poziomu nakładów, tzw. orientacja na rezultaty (Cooper i in., 2007).

Użyteczność metody DEA potwierdzają jej zastosowania w różnych domenach, takich jak sektor bankowy, opieka zdrowotna czy edukacja. Podstawowym celem tych badań jest identyfikacja źródeł nieefektywności, tworzenie rankingów DMU, ocena efektywności programów lub polityk, jak również tworzenie ilościowych podstaw do relokacji zasobów itp. (Liu, Lu, Lu i Lin, 2013).