

**Szacowanie efektu  
oddziaływania polityki rolnej  
na wartość dodaną  
z wykorzystaniem  
propensity score matching**





INSTYTUT EKONOMIKI ROLNICTWA  
I GOSPODARKI ŻYWNOŚCIOWEJ  
PAŃSTWOWY INSTYTUT BADAWCZY

# **Szacowanie efektu oddziaływania polityki rolnej na wartość dodaną z wykorzystaniem propensity score matching**

*Autorzy:*

*dr Agata Sielska*

*mgr Aleksandra Pawłowska*



**ROLNICTWO POLSKIE I UE 2020+  
WYZWANIA, SZANSE, ZAGROŻENIA, PROPOZYCJE**

**Warszawa 2016**

Autorzy są pracownikami Instytutu Ekonomiki Rolnictwa i Gospodarki Żywnościowej – Państwowego Instytutu Badawczego.  
Publikacja afiliowana jest do dorobku IERiGŻ-PIB.

Pracę zrealizowano w ramach tematu: **Źródła wzrostu oraz ewolucja struktur i roli sektora rolno-spożywczego w perspektywie po 2020 roku** w zadaniu: *Opracowanie metodyki oceny i monitorowanie zmian wskaźnika rezultatu dla PROW 2014-2020 w postaci relacji wartości dodanej brutto do rocznej jednostki pracy (GVA/AWU).*

Celem pracy jest weryfikacja merytoryczna i obliczeniowa przyjętej metodyki analizy danych FADN do ustalenia efektu oddziaływania wsparcia inwestycji na wartość wskaźnika rezultatu (GVA/AWU). Dokonano zarysu problematyki związanej z przeprowadzonym badaniem oraz przesłankami dla wspierania inwestycji w gospodarstwach rolnych. Wykorzystując metodę łączenia danych, dokonano próby pomiaru efektu oddziaływania wsparcia inwestycji na wydajność czynnika pracy w polskich gospodarstwach rolnych w oparciu o dane historyczne.

Recenzent

*prof. dr hab. Izabella Kudrycka, Wyższa Szkoła Finansów i Zarządzania w Warszawie*

Korekta

*Joanna Gozdera*

Redakcja techniczna

*Leszek Ślipki*

Projekt okładki

*IERiGŻ-PIB*

ISBN 978-83-7658-631-1

*Instytut Ekonomiki Rolnictwa i Gospodarki Żywnościowej  
– Państwowy Instytut Badawczy  
ul. Świętokrzyska 20, 00-002 Warszawa  
tel.: (22) 50 54 444  
faks: (22) 50 54 757  
e-mail: [dw@ierigz.waw.pl](mailto:dw@ierigz.waw.pl)  
<http://www.ierigz.waw.pl>*

## Spis treści

<b>Wprowadzenie .....</b>	<b>7</b>
<b>1. Znaczenie wydajności w rolnictwie dla wzrostu gospodarczego.....</b>	<b>9</b>
1.1. Zwiększenie produkcji jako zagadnienie decyzyjne producenta .....	9
1.2. Kanały wpływu wzrostu produktywności rolnictwa na ogólną sytuację gospodarki – ujęcie teoretyczne .....	14
1.3. Rola wartości dodanej w pomiarze wzrostu .....	28
1.3.1. Wartość dodana w ujęciu teoretycznym.....	28
1.3.2. Wartość dodana w ujęciu empirycznym .....	32
<b>2. Idea podejścia kontrfaktycznego jako narzędzia ewaluacji .....</b>	<b>40</b>
2.1. Ograniczenia zastosowania modeli regresji oraz metod naiwnych w badaniu wpływu .....	40
2.1.1. Modele regresji.....	40
2.1.2. Metody naiwne .....	44
2.2. Istota podejścia kontrfaktycznego .....	49
2.3. <i>Propensity Score Matching</i> jako metoda łączenia obserwacji .....	58
2.3.1. Łączenie na podstawie wielu i jednej cech .....	58
2.3.2. Łączenie na podstawie prawdopodobieństwa .....	65
2.3.3. Pomiar efektów oddziaływania .....	68
2.4. Specyfikacja wektora <i>propensity score</i> z wykorzystaniem modeli logitowych i probitowych – wprowadzenie teoretyczne .....	71
<b>3. Kwantyfikacja efektu dopłat do inwestycji na wydajność czynnika pracy .....</b>	<b>80</b>
3.1. Problem warunków koniecznych.....	80
3.2. Szacowanie prawdopodobieństwa uzyskania dopłat do inwestycji .....	82
3.3. Wybór zmiennych bilansujących grupę eksperymentalną i kontrolną... 95	
3.4. Szacowanie przeciętnego efektu oddziaływania wobec jednostek poddanych oddziaływaniu (ATT) .....	97
<b>Podsumowanie .....</b>	<b>109</b>
<b>Bibliografia.....</b>	<b>111</b>



## Wprowadzenie

Niniejszą pozycję poświęcono rozważaniom dotyczącym produktywności czynnika pracy, której wzrost – uznawany za istotny czynnik postępu – powinien zostać odzwierciedlony we wzroście jego wynagrodzenia [Patra, Nayak, 2012; Wells, Krugman, 2012]. Przyjmuje się, że wzrost ten może być konsekwencją podejmowanych przez producentów inwestycji, pozwalających na zwiększenie zaangażowania czynnika kapitału rzeczowego u producentów rolnych [Rembisz, Sielska, 2014b].

Ze względu na pozytywne implikacje wzrostu wydajności czynnika pracy, proces ten znajduje się w obszarze zainteresowania polityki. W przypadku polityki rolnej promowanie wzrostu wydajności odbywa się poprzez wdrażanie instrumentów zwiększających możliwości podejmowania działań inwestycyjnych w gospodarstwie rolnym. Przykładowo, w Programie Rozwoju Obszarów Wiejskich na lata 2014-2020 jest to poddziałanie 4.1 pt. „Wsparcie inwestycji w gospodarstwach rolnych”. Skala wydatków związanych z publicznym wsparciem inwestycji oraz szerokie zainteresowanie beneficjentów świadczą o istotności podejmowanych działań [por. Mickiewicz, Wawrzyniak, 2010].

Należy jednak uwzględnić, iż wprowadzenie instrumentu polityki wiąże się z ponoszeniem określonych kosztów. Wskazane zatem jest, by koszty te poddawane były procesowi ewaluacji, który pozwoliłby na wycenę realnych korzyści płynących z wdrożenia określonych programów, przysługując się zwiększeniu jakości, skuteczności i spójności interwencji [Olejniczak, 2007].

Dokonanie takiej oceny wydaje się być zadaniem nietrywialnym [Sielska et al., 2015]. Mimo iż sprawdzenie występowania w gospodarce efektu pożądanego przez politykę nie jest skomplikowane, to ustalenie, czy zmiana ta jest skutkiem analizowanego instrumentu polityki wymaga pogłębionej analizy, której wyniki obarczone są niepewnością.

Mierniki wykorzystywane w procesie ewaluacji powinny spełniać pewne ustalone kryteria [Dorward, 2013]. Wskazuje się tutaj przede wszystkim na adekwatność do celów założonych w prowadzonej polityce. Wartość miernika powinna bowiem przekazywać w sposób jasny i zrozumiały, do jakiego stopnia spełniony został deklarowany cel. Ponadto, ze względu na aspekt aplikacyjny, mierniki te powinny być możliwe do użycia w różnych zbiorowościach w celu dokonania odpowiednich porównań oraz zostać skonstruowane w taki sposób, by możliwe było obliczenie ich wartości na podstawie dostępnych danych. Podobnie Michalek [2012b] podnosi kwestie konieczności ustalenia prawdziwego związku przyczynowo-skutkowego (ang. *true causation*), następnie odseparowania od badanego zjawiska potencjalnego wpływu efektów zewnętrznych oraz agregacji możliwych skutków polityki zachodzących nie tylko w sferze ekonomicznej, ale również społecznej czy środowiskowej.

Metodą wyznaczającą standard oceny wpływu efektu oddziaływania wprowadzonej interwencji jest eksperyment zrandomizowany. Istotą tego podejścia jest zapewnienie losowego przydziału jednostek do grupy eksperymentalnej lub kontrolnej, gwarantując tym samym niezależność wpływu czynnika na rezultat od przynależności jednostki do jednej z dwóch grup [Heckman, Vytlačil, 2007]. Na gruncie nauk społecznych przeprowadzenie kontrolowanego eksperymentu z randomizacją jest jednak niemożliwe lub jest w znaczący sposób utrudnione. Rozwiązaniem problemu nielosowego podziału jednostek jest zastosowanie narzędzi quasi-eksperymentalnych, takich jak estymacja przez dopasowanie (lub inaczej: estymacja przez łączenie). Jak zauważa bowiem Szulc [2012, s. 309], „estymacja przez dopasowanie umożliwia uzyskanie oszacowań, które za pomocą klasycznych metod są dostępne jedynie w przypadku eksperymentów losowych, czyli takich, w których na przykład osoby poddane działaniu leku są dobierane losowo do obu porównywanych grup z tej samej populacji”.

Niniejsza praca składa się z dwóch głównych części. Pierwsza część, a zarazem pierwszy rozdział stanowi zarys problematyki związanej z przeprowadzonym badaniem oraz przesłankami dla wspierania inwestycji w gospodarstwach rolnych, tj. ze znaczeniem wydajności w rolnictwie dla wzrostu gospodarczego. Odnosimy się tu do podstaw ekonomicznych leżących u podłoża wsparcia wzrostu wydajności w rolnictwie. Nawiązujemy krótko do ujęcia opartego na zagadnieniu decyzyjnym producenta oraz do teoretycznego i modelowego ujęcia kanałów wpływu wzrostu produktywności rolnictwa na ogólną sytuację gospodarki. W ostatniej części rozdziału przedmiotem uwagi staje się rola wartości dodanej w pomiarze wzrostu. Część ta zilustrowana jest danymi pochodzącymi z ogólnodostępnych baz.

Przedmiotem drugiej części pracy jest podejście modelowe służące kwantyfikacji wpływu dopłat do inwestycji na kształtowanie się wartości dodanej. Ta część podzielona została na dwa rozdziały, z których pierwszy, o charakterze teoretycznym dotyczy idei leżącej u podstaw badania wpływu. Zestawiamy ze sobą metody, jakie mogą być wykorzystane do prowadzenia tego rodzaju ocen, uwzględniając zarówno modele regresji, oparte na prostych porównaniach metody naiwne oraz podejście *propensity score matching* (łączenie według prawdopodobieństwa), które umożliwia odpowiednio szeroki zakres wnioskowania w badaniach niecharakteryzujących się losowością. Głównym celem drugiego rozdziału jest zatem ogólne zakreślenie idei leżących u podstaw wspomnianej metody.

W rozdziale trzecim dokonano pomiaru efektu oddziaływania wsparcia inwestycji na wydajność czynnika pracy w polskich gospodarstwach rolnych w oparciu o dane historyczne. Praca zakończona jest podsumowaniem, w którym odniesiono się do poruszanych tematów oraz sumarycznie omówiono uzyskane wyniki.



# 1. Znaczenie wydajności w rolnictwie dla wzrostu gospodarczego

## 1.1. Zwiększenie produkcji jako zagadnienie decyzyjne producenta

Zwiększanie produkcji nie jest, zgodnie z teorią ekonomii klasycznej, celem producenta. Pozostaje jednakże w związku z maksymalizacją zysku i w takim kontekście zostanie opisane w niniejszej części pracy.

Jak zauważają Sielska i in. [2015], prowadząc rozumowanie w kontekście funkcji produkcji można wyróżnić kilka podstawowych potencjalnych źródeł wzrostu, wynikających bezpośrednio z samej idei takiego opisu procesów wytwórczych. Pierwszym elementem, który może skutkować przyrostem produkcji jest zwiększenie nakładów czynników produkcji. Ponieważ funkcja produkcji musi spełniać założenie, zgodnie z którym charakteryzuje się dodatnimi, malejącymi pochodnymi, zwiększenie nakładów danego czynnika pozwoli osiągnąć wyższą produkcję:

$$Y = f(x_1, x_2, \dots, x_n) + \varepsilon$$

gdzie:

$Y = f(\cdot)$  – funkcja produkcji,

$x_i$  –  $i$ -ty czynnik produkcji,

$\varepsilon$  – składnik losowy

oraz:


$$\forall i \quad \frac{\partial Y}{\partial x_i} > 0$$

Proces ten nie może jednak oczywiście trwać nieskończenie długo, ze względu na ograniczenia natury technicznej i istotę procesów produkcyjnych, wymagające angażowania czynników w pewnych ustalonych proporcjach. Ograniczenie to odzwierciedlane jest formalnie poprzez ustalenie warunku ujemnych drugich pochodnych funkcji produkcji, zgodnie z którym każdy kolejny jednostkowy przyrost nakładów określonego czynnika pociąga za sobą coraz mniejsze przyrosty produkcji.

$$\forall i, j, i \neq j \quad \frac{\partial^2 Y}{\partial x_i \partial x_j} < 0$$


Proces ten zilustrowano poniżej (rysunki 1-3) na przykładzie często używanych w analizach ekonomicznych potęgowych funkcji produkcji typu Cobb-Douglasa.

**Rysunek 1. Przyrost produkcji dla wzrastających nakładów czynników w przypadku funkcji o malejących efektach skali**




Źródło: opracowanie własne.

**Rysunek 2. Przyrost produkcji dla wzrastających nakładów czynników w przypadku funkcji o stałych efektach skali**



Źródło: opracowanie własne.

**Rysunek 3. Przyrost produkcji dla wzrastających nakładów czynników w przypadku funkcji o rosnących efektach skali**



Źródło: opracowanie własne.

Zwiększanie produkcji za sprawą zwiększania nakładów wymaga przyrostu obu czynników, co w konsekwencji powoduje dla producenta wzrost kosztu:

$$\Delta x_i > 0 \Rightarrow \Delta x_i \cdot c_{xi} > 0$$

$$\Delta C(Y, c_{x1}, c_{x2}, \dots, c_{xn}) > 0$$

gdzie:

$c_{xi}$  – cena czynnika  $x_i$ ,

$C(\cdot)$  – funkcja kosztu.

Opłacalność zwiększenia zaangażowania czynnika produkcji zależy od relacji zysku wynikającego z przyrostu produkcji do zmiany kosztów. Racjonalnie postępujący producent będzie dążyć do zwiększania zaangażowania czynnika dopóki osiąga z tego tytułu zysk:

$$\Pi = c_Y \cdot Y(x_1, x_2, \dots, x_n) - C(Y, c_{x1}, c_{x2}, \dots, c_{xn}) \rightarrow \max$$

p.w.

$$\forall i \quad x_i, c_{xi}, c_Y > 0$$

gdzie:

$\Pi$  – funkcja zysku,

$c_Y$  – cena otrzymywana.

Warunki optymalności zapisać można jako:

$$c_Y \cdot \frac{\partial Y}{\partial x_i} - \frac{\partial C(Y, c_{x1}, c_{x2}, \dots, c_{xn})}{\partial x_i} = c_Y \cdot \frac{\partial Y}{\partial x_i} - \frac{\partial Y}{\partial x_i} \cdot \frac{\partial C(Y, c_{x1}, c_{x2}, \dots, c_{xn})}{\partial x_i} =$$

$$= \frac{\partial Y}{\partial x_i} \cdot \left( c_Y - \frac{\partial C(Y, c_{x1}, c_{x2}, \dots, c_{xn})}{\partial x_i} \right)$$

$$c_Y = \frac{\partial C(Y, c_{x1}, c_{x2}, \dots, c_{xn})}{\partial x_i}$$

Analogicznie do warunków zapisanych w [Sielska et al., 2015] oraz [Rembisz, Sielska, 2015] można zatem zapisać:

$$\frac{\frac{\partial C(Y, c_{x1}, c_{x2}, \dots, c_{xn})}{\partial x_i}}{c_Y} < 1 \Rightarrow \Delta S_Y > 0$$

$$\frac{\frac{\partial C(Y, c_{x1}, c_{x2}, \dots, c_{xn})}{\partial x_i}}{c_Y} > 1 \Rightarrow \Delta S_Y < 0$$

$$\frac{\frac{\partial C(Y, c_{x1}, c_{x2}, \dots, c_{xn})}{\partial x_i}}{c_Y} = 1 \Rightarrow \Delta S_Y = 0$$

gdzie:

$S_Y(\cdot)$  – funkcja podaży.

Drugim warunkiem jest wyczerpanie przez producenta możliwości zwiększenia produkcji jedynie za sprawą zwiększania nakładów czynników, a zatem przypadek, w którym:

$$\frac{\partial Y}{\partial x_i} = 0$$

Jak piszą Rembisz i Sielska [2015], w długim okresie zwiększanie wytwarzanej produkcji taką ekstensywną drogą powodować będzie nacisk na wzrost poziomu cen otrzymywanych. Skutkiem takiej sytuacji dla producenta może być zmniejszenie opłacalności prowadzonych działań, dla pozostałych uczestników systemu gospodarczego wiązać się będzie z naciskiem na wzrost wynagrodzenia czynnika pracy, w dążeniu do utrzymania dotychczasowej sytuacji konsumenta.

Alternatywną metodą zwiększania uzyskiwanej produkcji jest wzrost o intensywnym charakterze wynikający z odmiennej organizacji procesów wytwarzania, co umożliwi producentowi uzyskiwanie większej produkcji z takich samych nakładów bądź też obniżenie nakładów, by ograniczyć koszty:

$$Y'(x_1, x_2, \dots, x_n) > Y(x_1, x_2, \dots, x_n)$$

gdzie:

$Y'(\cdot), Y(\cdot)$  – funkcje produkcji.

Jest to, *de facto*, zmiana technologii wytwarzania. Sama w sobie nie jest ona obserwowalna [Mundlak, Butzer, Larson, 2012], badać można ją jedynie pośrednio, analizując skutki jej zmian (obserwując przyrost produkcji, którego nie można przypisać zmianom nakładów). Przyjmuje się, że zmiana technologii może wynikać z przyrostu wiedzy [Zegar, 2012], zmiany kapitału ludzkiego [Mundlak, Butzer, Larson, 2012].

Taka zmiana produkcji oznacza poprawę wartości takich wskaźników opisujących procesy produkcyjne, jak wydajność czy efektywność i może być również obserwowana za ich pośrednictwem:

$$\exists i \quad \frac{Y'}{x_i} > \frac{Y}{x_i}$$

$$e_{Y'} > e_Y$$

gdzie:

$e_Y = f\left(\frac{Y}{x_1}, \frac{Y}{x_2}, \dots, \frac{Y}{x_n}\right)$  – efektywność produkcji  $Y$ .

Zgodnie z [Rembisz, Sielska, 2015] nie występuje wówczas nacisk na zwiększenie ceny rynkowej wytworzonych dóbr, zaś przy założeniu, że cena ta początkowo nie ulegnie zmianie, zmiana technologii na bardziej wydajną oznaczać będzie poprawę sytuacji producenta z punktu widzenia wartości jego funkcji celu, tj. zysku:

$$\begin{aligned} & c_Y \cdot Y'(x_1, x_2, \dots, x_n) - C(Y', c_{x1}, c_{x2}, \dots, c_{xn}) \\ & > c_Y \cdot Y(x_1, x_2, \dots, x_n) - C(Y, c_{x1}, c_{x2}, \dots, c_{xn}) \end{aligned}$$

$$\begin{aligned} & Y'(x_1, x_2, \dots, x_n) - C(Y', c_{x1}, c_{x2}, \dots, c_{xn}) \\ & > Y(x_1, x_2, \dots, x_n) - C(Y, c_{x1}, c_{x2}, \dots, c_{xn}). \end{aligned}$$

Producent ma zatem możliwość uzyskania wyższego zysku z takich samych nakładów.

Możliwość wytwarzania większego produktu z dotychczasowego nakładu czynników powoduje nacisk na wzrost wynagrodzeń czynników produkcji:

$$\Delta \left( \frac{\partial Y}{\partial x_i} \right) > 0 \Rightarrow \Delta c_{x_i} > 0.$$

Jest to zgodne z warunkiem równowagi producenta, wedle którego ceny płacone czynnikom produkcji powinny być uzależnione od wydajności i produktywności krańcowych tych czynników:

$$\frac{\partial Y}{\partial x_i} \cdot c_Y = f(c_{x_i}).$$

## **1.2. Kanały wpływu wzrostu produktywności rolnictwa na ogólną sytuację gospodarki – ujęcie teoretyczne**

Rembisz i Floriańczyk [2014, s. 41] zauważają, że „w ogólnych modelach wzrostu, gdyby brać je bezpośrednio, rolnictwo traktowane jest najczęściej jako oddzielny sektor, najczęściej – w modelach dualnych – jako w istocie ogranicznik wzrostu lub rezerwuuar przesuwalnych czynników, jak czynnik kapitału czy akumulacja środków kapitałowych”. Zawarta w niniejszym podrozdziale analiza teoretyczna będzie prowadzona w takim właśnie kontekście, tj. uwaga skoncentrowana będzie na wpływie rolnictwa na produkcję wytwarzaną w pozostałych sektorach oraz na występujących między nimi powiązaniach.

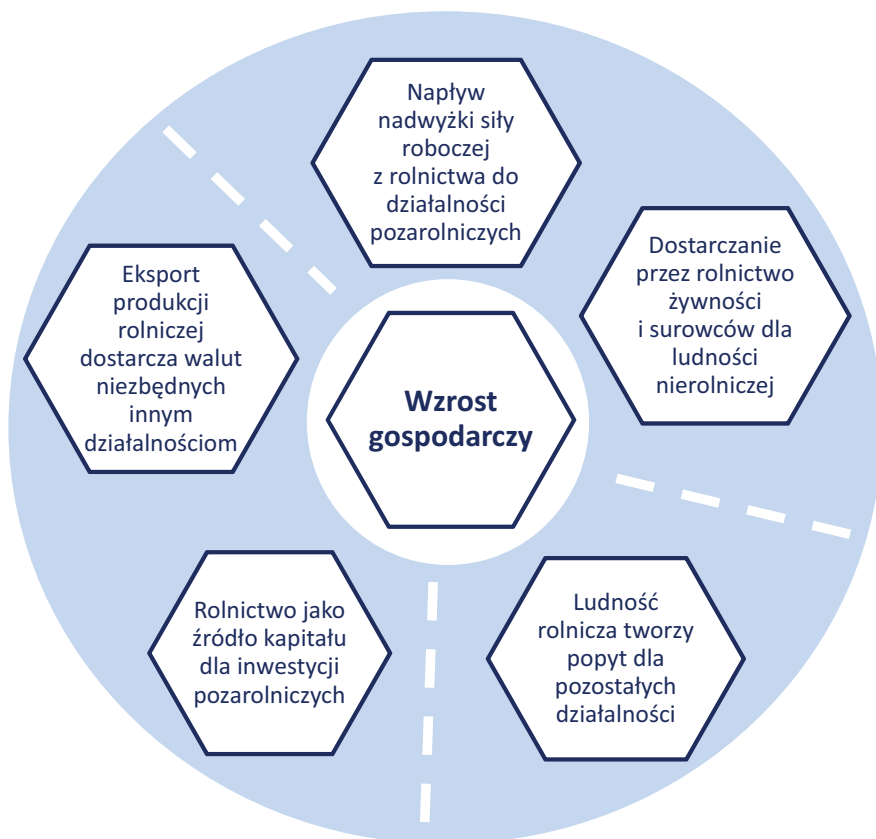
W szczególny sposób uwzględniony zostanie wpływ wynikający ze wzrostu produktywności lub wydajności czynnika pracy, będącej obok wzrostu produktywności czynnika ziemi jednym z dwóch podstawowych źródeł wzrostu produkcji rolniczej [por. Rembisz, Floriańczyk, 2014].

Jak zauważają na podstawie rozważań prowadzonych w aspekcie historycznym Cameron i Neal [2004], rolnictwo może determinować wystąpienie wzrostu gospodarczego na kilka sposobów, które przedstawiono schematycznie na rysunku 4.

Jak się wydaje, przy przyjęciu podziału gospodarki na dwa sektory, rolniczy oraz pozarolniczy, kanały wpływu tego pierwszego na wzrost gospodarczy mogą wynikać z trzech podstawowych czynników. Pierwszym z nich jest kanał, który można określić ogólnie jako podażowy. Rolnictwo, po osiągnięciu odpowiedniej stopy produktywności pracy może bowiem zredukować zatrudnienie lub zniwelować konieczność jego wzrostu dla utrzymania odpowiednie-

go poziomu produkcji. Powstająca w ten sposób w sektorze rolniczym nadwyżka siły roboczej może stworzyć dodatkową podaż pracy w działalnościach pozarolniczych.

**Rysunek 4. Sposoby wpływu zwiększonej produktywności w rolnictwie na wzrost gospodarczy**



Źródło: opracowanie własne na podstawie [Cameron, Neal, 2004].

Jeżeli zatem wraz z upływem czasu rośnie produktywność czynnika pracy, to w konsekwencji przepływu tego czynnika zmniejszać się będzie stosunek zatrudnionych w rolnictwie i poza nim, co można ująć następująco:

$$\partial \frac{Y_R}{L_R} / \partial t > 0 \Rightarrow \partial \frac{L_R}{L_{NR}} / \partial t < 0$$

gdzie:

- $Y_R$  – produkcja sektora rolniczego,
- $L_R$  – siła robocza zatrudniona w rolnictwie,
- $L_{NR}$  – siła robocza zatrudniona poza rolnictwem,
- $t$  – zmienna czasowa.

To z kolei powoduje, przy ustalonej funkcji produkcji obrazującej relacje kształtujące procesy wytwórcze poza sektorem rolniczym, wzrost produktywności tego sektora:

$$\partial \frac{Y_{NR}}{L_{NR}} / \partial t > 0$$

gdzie:

- $Y_{NR}$  – produkcja sektora nierolniczego.

Zgodnie z prawidłowościami teorii mikroekonomii, taka zmiana wydajności będzie skutkować, przy innych czynnikach niezmiennych, wzrostem wynagrodzenia czynnika pracy:

$$\partial \frac{Y_{NR}}{L_{NR}} / \partial t > 0 \Rightarrow \frac{\partial C_{L_{NR}}}{\partial t} > 0$$

gdzie:

- $C_{L_{NR}}$  – wynagrodzenie czynnika pracy zatrudnionego poza rolnictwem.

Wzrost wynagrodzenia tego czynnika skutkuje z kolei, w oparciu o oczywiste zależności, zwiększeniem dochodów do dyspozycji ludności zatrudnionej w działalnościach pozarolniczych. Wzrost dochodów do dyspozycji powoduje zaś zwiększenie popytu zgłaszanego przez tę ludność.

$$\frac{\partial C_{L_{NR}}}{\partial t} > 0 \Rightarrow \frac{\partial m_{L_{NR}}}{\partial t} > 0 \Rightarrow \frac{\partial D_{L_{NR}}(Y_R, Y_{NR})}{\partial t} > 0$$

gdzie:

- $m_{L_{NR}}$  – dochody czynnika pracy zatrudnionego poza rolnictwem,
- $D_{L_{NR}}(\cdot)$  – funkcja popytu ludności zatrudnionej poza rolnictwem.



Wydaje się wartym zaznaczenia w tym miejscu, że mimo iż zgodnie z prawem Engla, wzrostowi dochodów towarzyszy spadek udziałów wydatków przeznaczonych na zakup produktów żywnościowych, zależność ta nie jest w sensie ogólnym tożsama ze spadkiem zgłaszanego na te produkty popytu. Zjawisko malejącego popytu dotyczyć będzie oczywiście produktów względnie niskiej jakości, które określa się mianem dóbr niższego rzędu bądź ostatnich, jednak w ogólnym ujęciu przyjąć można, że wzrostowi dochodu towarzyszy, przynajmniej przez pewien czas, wzrost popytu na produkty wytwarzane w obu sektorach. Założenie to jest szczególnie zasadne w sytuacji, w której w stanie początkowym ludność z pewnych powodów (zbyt niskie dochody, zbyt mała podaż) nie mogła zaspokoić swojego popytu na produkty żywnościowe zaliczane do kategorii dóbr normalnych. Można zatem w pewnym uproszczeniu uznać, że „możliwości wzrostu popytu na dobra żywnościowe w wyniku wzrostu dochodów (...) mają miejsce głównie w przypadku niskich dochodów” [Sielska et al., 2015, s. 14].

Wzrost zgłaszanego popytu powoduje z kolei wzrost spodziewanego przez producentów poziomu zysku i – w konsekwencji – zwiększenie produkcji:

$$\frac{\partial D_{LNR}(Y_R, Y_{NR})}{\partial t} > 0 \Rightarrow \frac{\partial \Pi(Y_R)}{\partial t} > 0, \frac{\partial \Pi(Y_{NR})}{\partial t} > 0 \Rightarrow \frac{\partial Y_R}{\partial t} > 0, \frac{\partial Y_{NR}}{\partial t} > 0$$

gdzie:

$\Pi(\cdot)$  – funkcja zysku z danej wytworzonej produkcji.

W tym miejscu można nawiązać do modelu Lewisa, zgodnie z założeniami którego rolnictwo pełni rolę sektora stagnacyjnego, tradycyjnego, w przeciwieństwie do sektora nierolniczego. Jak piszą Rembisz i Floriańczyk [2014, s. 34], „drugi sektor dla swojej ekspansji wykorzystuje relatywnie tanie nadwyżkowe zasoby czynnika pracy pochodzące z sektora rolnictwa”. Może stosować taką drogę zwiększania swojej produkcji, dopóki nie wyczerpią się możliwości drenażu tego czynnika.

Kluczowe w tym podejściu są dwa elementy: istnienie nadwyżki siły roboczej w rolnictwie oraz – do czego nie odnosiliśmy się wcześniej – jej niska (niższa niż w drugim sektorze) wydajność. Migracja pracy do sektora nierolniczego rodzi konsekwencje w postaci wzrostu zysku w tym sektorze, co umożliwia funkcjonującym w nim producentom zmianę technik wytwarzania na bardziej kapitałochłonne, co prowadzi do wzrostu wydajności pracy. Wydajność wzrasta również w sektorze rolnym, co bezpośrednio wynika z obniżenia nakładów pracy. Skutkiem tego procesu jest niwelowanie różnic wydajności i wynagrodzeń między sektorami [Rembisz, Floriańczyk, 2014].

Drugą stroną oddziaływania, które określiliśmy mianem podażowego jest wpływ poprzez podaż nie siły roboczej, ale dóbr konsumpcyjnych i inwestycyjnych. Rolnictwo może bowiem przy rosnącej produktywności zwiększyć podaż surowców dla sektorów pozarolniczych i żywności dla zatrudnionych w nim:

$$\frac{\partial \frac{Y_R}{L_R}}{\partial t} > 0 \Rightarrow \frac{\partial S_{L_{NR}}(Y_R)}{\partial t} > 0$$

gdzie:

$S_{L_{NR}}(\cdot)$  – funkcja podaży wytworzonej produkcji przeznaczonej dla sektora nierolniczego.

Do drugiego z wymienionych elementów, tj. podaży żywności, odnieśliśmy się już wcześniej, jako skutku zwiększonego popytu możliwego do zaspokojenia dzięki wzrostowi dochodów. W tym momencie akcentujemy drugie z potencjalnych źródeł wzrostu tej podaży, tj. wzrost produktywności. Zakładamy zatem, że zmiany zasobów siły roboczej dostępnej do prowadzenia produkcji rolniczej nie ulegają zmniejszeniu do stopnia, który umożliwia jedynie utrzymanie dotychczasowego poziomu wytwarzania.

Kolejny kanał wpływu określić można jako kanał popytowy. Jak piszą Cameron i Neal [2004], ludność zatrudniona w rolnictwie może być traktowana przez pozostałe sektory jako rynek zbytu na oferowane przez nie produkty. Wynika to z dwóch przesłanek.

Pierwszą jest wzrost wynagrodzenia, a w konsekwencji i dochodów ludności zatrudnionej w rolnictwie, będący prostym następstwem rosnącej produktywności tego czynnika wytwórczego, zgodnie ze wspomnianymi już regułami optymalizacji decyzji przez producenta w rozumieniu mikroekonomicznym:

$$\frac{\partial \frac{Y_R}{L_R}}{\partial t} > 0 \Rightarrow \frac{\partial C_{L_R}}{\partial t} > 0 \Rightarrow \frac{\partial m_{L_R}}{\partial t} > 0 \Rightarrow \frac{\partial D_{L_R}(Y_R, Y_{NR})}{\partial t} > 0$$

gdzie:

$C_{L_R}$  – wynagrodzenie czynnika pracy zatrudnionego w rolnictwie,

$m_{L_R}$  – dochody czynnika pracy zatrudnionego w rolnictwie,

$D_{L_R}(\cdot)$  – funkcja popytu zgłaszanego przez ludność zatrudnioną w rolnictwie.

Oczywiście, jak widać z zapisanej wyżej relacji, wzrost popytu dotyczy produktów wytworzonych w obu działalnościach, akcentujemy jednak przyrost związany z produktami o charakterze pozarolniczym ze względu na fakt prowadzenia analizy w kontekście wzrostu w całej gospodarce.

Istotne w tym przypadku stają się również relacje cenowe między produktami wytworzonymi w poszczególnych sektorach. Wyższa produktywność wiązać się może przy ustalonych nakładach pracy ze wzrostem podaży. Większa dostępność dóbr żywnościowych skutkuje natomiast spadkiem ich ceny relatywnej. Zjawisko to powoduje u konsumentów skutek w postaci wzrostu dochodu relatywnego, co wiąże się z lepszymi możliwościami zaspokojenia zgłaszanego popytu:

$$\Delta S(Y_R) > 0 \Rightarrow \Delta \left( \frac{c_{Y_R}}{c_{Y_{NR}}} \right) < 0 \Rightarrow \Delta \left( \frac{c_{Y_R}}{m_{L_{NR}}} \right) < 0, \Delta \left( \frac{c_{Y_R}}{m_{L_R}} \right) < 0$$

gdzie:

$S(\cdot)$  – funkcja podaży danej wytworzonej produkcji,

$c_{Y_R}$  – cena rynkowa produktów rolniczych,

$c_{Y_{NR}}$  – cena rynkowa produktów nierolniczych,

$m_{L_{NR}}$  – dochody czynnika pracy zatrudnionego poza rolnictwem.

Ostatnią z grup, jakie można wyróżnić na podstawie czynników zaprezentowanych przez Camerona i Neala [2004], jest wpływ poprzez oddziaływanie finansowe. Rolnictwo może zostać bowiem, jak wskazują przywoływani autorzy, traktowane jako źródło kapitału dla inwestycji. W tym kontekście można wyróżniać zarówno finansowanie umożliwiające dzięki dobrowolnemu lokowaniu pieniędzy, jak i w pewnym zakresie kształtowane odgórnie przez system podatkowy. Również inne analizy danych historycznych wskazują na to, że historycznie kapitał akumulował się początkowo w rolnictwie, które było głównym źródłem gromadzenia zarówno kapitału, jak i siły roboczej. Zgromadzone zasoby przyczyniają się do rozwoju innych działalności.

$$\partial \frac{Y_R}{L_R} / \partial t > 0 \Rightarrow \frac{\partial S(K_R)}{\partial t} > 0 \Rightarrow \frac{S(K_R)}{S(K_{NR})} > 0$$

gdzie:

$S(K_R)$  – funkcja podaży kapitału w rolnictwie,

$S(K_{NR})$  – funkcja podaży kapitału poza rolnictwem.

Zgodnie z powyższym wzorem, wzrost produktywności pracy w rolnictwie przyczynia się zarazem do zwiększenia podaży kapitału w tym sektorze, a także, w konsekwencji, przy innych czynnikach pozostających na ustalonym poziomie, we wzroście stosunku dostępnego kapitału w rolnictwie do kapitału dostępnego dla producentów w innych działalnościach.

W przypadku inwestycji dobrowolnych w działalności pozarolniczej, wydaje się, że za podstawowy bodziec do tego rodzaju postępowania można uznać wysokie prognozowane stopy zwrotu na nowym rynku w sytuacji wysokich cen na dobra pozażywnościowe wynikających z niskiej w początkowych fazach podaży tychże.

Zwiększenie produktywności i wynikające z niego w konsekwencji zwiększenie popytu powoduje, jak wskazano wyżej, wzrost zysku osiąganego dzięki sprzedawanej produkcji. W konsekwencji, wzrasta również podstawa opodatkowania.

$$\frac{\partial \Pi(Y_R)}{\partial t} > 0, \frac{\partial \Pi(Y_{NR})}{\partial t} > 0 \Rightarrow \frac{\partial T_R}{\partial t} > 0, \frac{\partial T_{NR}}{\partial t} > 0$$

gdzie:

$T_R$  – wpływy podatkowe z sektora rolniczego,

$T_{NR}$  – wpływy podatkowe z sektora nierolniczego.

Przy założeniu że celem państwa jest stymulacja kolejnych działów gospodarki, tj. w tym wypadku wytwarzania produktów o charakterze nierolniczym, do czego nawiązywaliśmy już wcześniej, i wzrost produktywności pracy w tych sektorach, wiąże się to z nowymi możliwościami przeprowadzenia inwestycji. Analogicznie do wyżej prowadzonych rozważań, proces ten można przedstawić następująco:

$$\frac{\partial T_R}{\partial t} > 0, \frac{\partial T_{NR}}{\partial t} > 0 \Rightarrow \frac{\partial I_{NR}}{\partial t} > 0 \Rightarrow \frac{\partial \frac{Y_{NR}}{L_{NR}}}{\partial t} > 0, \frac{\partial Y_{NR}}{\partial t} > 0$$

gdzie:

$I_{NR}$  – inwestycje w sektorze nierolniczym.

Dalszy wzrost produktywności pracy i produkcji w rolnictwie za sprawą odpowiednich inwestycji również jest w takim ujęciu możliwy:

$$\frac{\partial T_R}{\partial t} > 0, \frac{\partial T_{NR}}{\partial t} > 0 \Rightarrow \frac{\partial I_R}{\partial t} > 0 \Rightarrow \frac{\partial \frac{Y_R}{L_R}}{\partial t} > 0, \frac{\partial Y_R}{\partial t} > 0$$

gdzie:

$I_R$  – inwestycje w sektorze rolniczym.

Istotny jest także wpływ wzrostu produktywności rolnictwa na wzrost gospodarczy osiągnięty za pośrednictwem finansowania zagranicznego, co odgrywa szczególnie znaczącą rolę w sytuacji występowania barier w rozwoju produkcji pozarolniczej wynikających z lokalnych niedoborów koniecznych czynników produkcji. Wyższa produktywność rolnictwa przekładająca się na wyższą podaż rodzi możliwość przeznaczenia części produkcji rolnej na eksport.

$$\frac{\partial \frac{Y_R}{L_R}}{\partial t} > 0 \Rightarrow \frac{\partial S_K(Y_R)}{\partial t} > 0$$

$$\frac{S_K(Y_R)}{D_K(Y_R)} > 1 \Rightarrow S_Z(Y_R) > 0$$

gdzie:

- $S_K(Y_R)$  – funkcja podaży produktów rolniczych na rynek krajowy,
- $D_K(Y_R)$  – funkcja popytu na produkty rolnicze na rynku krajowym,
- $S_Z(Y_R)$  – funkcja podaży produktów rolniczych na rynek zagraniczny.

Działanie takie powoduje napływ obcych walut, które z kolei umożliwiają działalnościom pozarolniczym zaspokojenie popytu na takie dobra inwestycyjne i surowce, które są lokalnie niedostępne, umożliwiając w kolejnym etapie zwiększenie produkcji pozarolniczej:

$$\begin{aligned} \Delta X_{1Z} &> 0 \\ S_Z(Y_R) > 0 &\Rightarrow \Delta X_{2Z} > 0 \\ &\dots \\ \Delta X_{nZ} &> 0 \end{aligned}$$

$$\Delta Y_{NR} > 0 \Rightarrow S(Y_{NR})$$

gdzie:

$Y_{NR} = f(X_{1L}, X_{2L}, \dots, X_{nL}, X_{1Z}, X_{2Z}, \dots, X_{nZ}, \varepsilon)$  – funkcja produkcji pozarolniczej,

$X_{1Z}, X_{2Z}, \dots, X_{nZ}$  – czynniki produkcji o zasobach lokalnie ograniczonych,  
 $X_{1L}, X_{2L}, \dots, X_{nL}$  – czynniki produkcji o zasobach lokalnie dostępnych,  
 $\varepsilon$  – składnik losowy.

W podejściach uwzględniających wiele sektorów, wpływ wzrostu produkcji w jednym na pozostałe można rozważać w dwóch ujęciach. Zgodnie z pierwszym, można założyć, że wzrost produkcji nie wynika ze zmian technologicznych i postępu, a jest jedynie skutkiem wykorzystania przez producentów większych nakładów czynników produkcji. Wówczas w przypadku, w którym istnieją niewykorzystane zasoby czynnika produkcji, można uznać, że nie występują w krótkim okresie podażowe bariery dla wzrostu.

W przypadku, w którym zmiany wolumenu wytwarzanej produkcji wynikają ze zmian zachodzących w technologii, możliwe jest przewyciężenie niedoboru pewnych czynników produkcji, np. poprzez nadanie charakteru czynnika wytwórczego czemuś, co dotychczas nie mogło zostać z powodzeniem wykorzystane w procesie wytwórczym.

Przy upraszczającym założeniu, że wielkość produkcji (globalnej) można wyrazić jako funkcję dwóch czynników produkcji, spośród których jednym jest praca, drugim zaś nakład kapitału rzeczowego, odzwierciedlający zużycie pośrednie produktów wytworzonych w innych działach gospodarki, oraz przyjmując standardowe założenia dotyczące funkcji produkcji, wzrost jednego z czynników będzie skutkował przyrostem wytwarzanego produktu.

$$Y_j = f_j(\mathbf{x}_{i,j}, \varepsilon)$$

gdzie:

$Y_j = f_j(\cdot)$  – funkcja produkcji dla  $j$ -tego sektora,

$\mathbf{x}_{i,j} = [x_{1,j}, x_{2,j}, \dots, x_{n,j}]^T$  – wektor zużycia pośredniego w  $j$ -tym sektorze produktów wytworzonych w pozostałych ( $i = 1, 2, \dots, n$ ) sektorach,

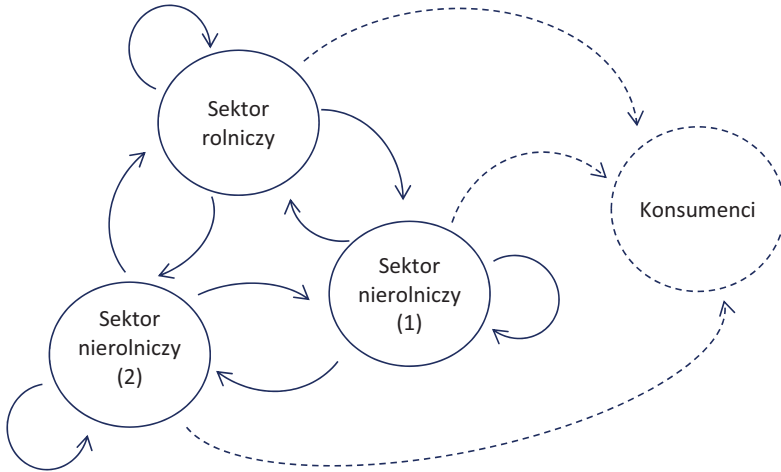
$\varepsilon$  – składnik losowy.

$$\forall i \quad \frac{\partial Y_j}{\partial x_{i,j}} > 0$$

Przy niezerowych nakładach pozostałych czynników produkcji, wzrost nakładów jednego z nich skutkuje wzrostem produkcji.

W przypadku systemu gospodarczego składającego się z trzech sektorów, przepływ wytworzonego produktu między gałęziami można zilustrować rysunkiem 5.

**Rysunek 5. Przepływ produktu między sektorami gospodarki**



Źródło: opracowanie własne.

Część z wytworzonej produkcji (produkcji globalnej), która nie zostaje przekazana na cele produkcyjne do innych sektorów (produkcja końcowa, finalna), trafia do konsumentów, podnosząc tym samym ich użyteczność. Dzięki tym relacjom między poszczególnymi branżami, wzrost produkcji globalnej w jednym z sektorów ma skutki w pozostałych. Zwiększenie produkcji umożliwia nie tylko przekazanie większej ilości wytworzonych produktów na rynek dóbr i usług konsumpcyjnych, umożliwiając przyrost użyteczności konsumentów z użytkowania zakupionych dóbr oraz zwiększając przychody producentów, ale i skierowanie większej produkcji do pozostałych branż, co z kolei umożliwia im zwiększenie wytwarzanej produkcji.

$$\Delta x_{R,i} > 0$$

$$\Delta X_R > 0 \Rightarrow \Delta \left( X_R - \sum_i x_{R,i} \right) > 0$$

$$\Delta \left( X_R - \sum_i x_{R,i} \right) > 0 \Rightarrow \Delta U \left( X_R - \sum_i x_{R,i} \right) > 0$$

$$\Delta x_{i,j} > 0$$

$$\Delta x_{R,i} > 0 \Rightarrow \Delta X_i > 0 \Rightarrow \Delta \left( X_i - \sum_i x_{i,j} \right) > 0$$

$$\Delta \left( X_i - \sum_i x_{i,j} \right) > 0 \Rightarrow \Delta U \left( X_i - \sum_i x_{i,j} \right) > 0$$

gdzie:

$x_{i,j}$  - przepływ produktu z  $i$ -tej do  $j$ -tej branży,

$X_i$  - produkcja globalna w  $i$ -tej branży,

$U(\cdot)$  - funkcja użyteczności,

$X_i - \sum_i x_{i,j}$  - różnica produkcji globalnej i popytu pośredniego na produkcję  $i$ -tej gałęzi (produkcja finalna  $i$ -tej gałęzi).

Zjawisko przepływów między gałęziami (branżami, sektorami) gospodarki można zilustrować w prosty sposób przy wykorzystaniu modelu Leontiewa [Leontief, 1936]. Dla danej produkcji globalnej:

$$\begin{cases} X_R = x_{R,R} + x_{R,PR1} + x_{R,PR2} + Y_R \\ X_{PR1} = x_{PR1,R} + x_{PR1,PR1} + x_{PR1,PR2} + Y_{PR1} \\ X_{PR2} = x_{PR2,R} + x_{PR2,PR1} + x_{PR2,PR2} + Y_{PR2} \end{cases}$$

gdzie:

$Y_i$  - produkcja finalna w  $i$ -tej branży (różnica produkcji globalnej i popytu pośredniego na produkcję  $i$ -tej gałęzi),

$R$  - sektor rolniczy,

$PR1$  - pierwszy sektor nierolniczy,

$PR2$  - drugi sektor nierolniczy.

Koszty produkcji wytworzonej w danym sektorze można opisać macierzą przedstawiającą stosunki zużycia pośredniego w  $i$ -tej gałęzi do wielkości wytworzonej produkcji. Udziały produkcji wytworzonej w poszczególnej gałęzi i przekazanej do innych branż są opisane odpowiednimi ilorazami:

$$A = \begin{bmatrix} \frac{x_{R,R}}{X_R} & \frac{x_{R,PR1}}{X_{PR1}} & \frac{x_{R,PR2}}{X_{PR2}} \\ \frac{x_{PR1,R}}{X_R} & \frac{x_{PR1,PR1}}{X_{PR1}} & \frac{x_{PR1,PR2}}{X_{PR2}} \\ \frac{x_{PR2,R}}{X_R} & \frac{x_{PR2,PR1}}{X_{PR1}} & \frac{x_{PR2,PR2}}{X_{PR2}} \end{bmatrix}$$

gdzie:

$A$  - macierz struktury kosztów.



Ponieważ:

$$\forall i \quad X_i - \sum_i x_{i,j} = Y_i$$

system gospodarczy można zapisać jako:

$$X = AX + Y$$

$$(I - A)X = Y$$

gdzie:

$X = [X_1 \ X_2 \ \dots \ X_n]^T$  – wektor produkcji globalnej,

$Y = [Y_1 \ Y_2 \ \dots \ Y_n]^T$  – wektor produkcji końcowej,

$I$  – macierz jednostkowa.

Wpływ zmiany produkcji globalnej na końcową można natomiast przedstawić za pomocą zależności [Gruszczyński, Kuszewski, Podgórska, 2009]:

$$L(X + \Delta X) = Y + \Delta Y$$

$$L\Delta X = \Delta Y$$

gdzie:

$L = I - A$  – macierz Leontiewa.

$$L = I - A = \begin{bmatrix} 1 - \frac{x_{R,R}}{X_R} & -\frac{x_{R,PR1}}{X_{PR1}} & -\frac{x_{R,PR2}}{X_{PR2}} \\ \frac{x_{PR1,R}}{X_R} & 1 - \frac{x_{PR1,PR1}}{X_{PR1}} & -\frac{x_{PR1,PR2}}{X_{PR2}} \\ -\frac{x_{PR2,R}}{X_R} & -\frac{x_{PR2,PR1}}{X_{PR1}} & 1 - \frac{x_{PR2,PR2}}{X_{PR2}} \end{bmatrix}$$

Siła wpływu wzrostu wydajności pracy w rolnictwie na pozostałe sektory zależy w takim ujęciu od struktury powiązań między branżami, tj. kształtowania się przepływów między branżami i ich materiałochłonności.

Ponieważ w modelu Leontiewa zakłada się stałość stosunku zużycia pośredniego do wytworzonej produkcji (stałość udziału kosztów materiałowych), nie dopuszcza on możliwości modelowania zmian produkcji globalnej wynikającej z postępu technologicznego, rozumianego w tym ujęciu jako zmiana procesów wytwarzania, a jedynie wpływ zwiększonych nakładów (zjawiska, określanego w pierwszej części niniejszej pracy mianem ekstensywnego wzrostu

produkcji). Wzrost taki przekłada się jednakże również na zwiększenie globalnej produkcji finalnej, chociaż powoduje spadki produkcji finalnej w gałęziach nieoświadczających wzrostu produkcji globalnej. Wynika to z faktu zwiększonego zapotrzebowania na produkty tych gałęzi ze strony sektorów wzrostowych.

Jednostkowy przyrost produkcji globalnej w rolnictwie ( $\Delta X_R = 1$ ), przy niezmienionej produkcji pozostałych branż, skutkuje zatem zmianą produkcji końcowej gospodarki o:

$$1 - \frac{x_{R,R}}{X_R} - \frac{x_{PR1,R}}{X_R} - \frac{x_{PR2,R}}{X_R} = X_R - x_{R,R} - x_{PR1,R} - x_{PR2,R}$$

ponieważ:

$$L\Delta X = \begin{bmatrix} 1 - \frac{x_{R,R}}{X_R} & -\frac{x_{R,PR1}}{X_{PR1}} & -\frac{x_{R,PR2}}{X_{PR2}} \\ -\frac{x_{PR1,R}}{X_R} & 1 - \frac{x_{PR1,PR1}}{X_{PR1}} & -\frac{x_{PR1,PR2}}{X_{PR2}} \\ -\frac{x_{PR2,R}}{X_R} & -\frac{x_{PR2,PR1}}{X_{PR1}} & 1 - \frac{x_{PR2,PR2}}{X_{PR2}} \end{bmatrix} \cdot \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix} = \begin{bmatrix} 1 - \frac{x_{R,R}}{X_R} \\ -\frac{x_{PR1,R}}{X_R} \\ -\frac{x_{PR2,R}}{X_R} \end{bmatrix}$$

Z własności modelu przepływów międzygałęziowych (w szczególności z równania kosztów [Gruszczyński, Kuszewski, Podgórska, 2009]) wynika, że wielkość tej zmiany produkcji końcowej w całym systemie gospodarczym nie może być ujemna.

Podobne rozumowanie można przeprowadzić dla zmiany produkcji globalnej spowodowanej zmianą wydajności jednego (lub więcej) czynników wytwórczych, w tym wypadku jednak bez odwoływania się do modelu Leontiewa, ponieważ analiza takiego przypadku wiązałaby się z koniecznością uzmiennienia macierzy struktury kosztów.

Ze względu na cel analizy, załóżmy, że wielkość produkcji (globalnej) można, w odróżnieniu od poprzedniego przypadku, wyrazić jako funkcję dwóch czynników produkcji, spośród których jednym jest praca, drugim zaś nadal pozostaje nakład kapitału rzeczowego, który odzwierciedla zużycie pośrednie produktów wytworzonych w innych działach gospodarki:

$$Y'_i = f_i(x_{i,j}, L_i, \varepsilon)$$

gdzie:

$Y'_i = f_i(\cdot)$  – funkcja produkcji  $i$ -tego sektora,

$L_i$  – nakład pracy w  $i$ -tym sektorze.

$$\begin{cases} X_R = x_{R,R} + x_{R,PR1} + x_{R,PR2} + Y_R \\ X_{PR1} = x_{PR1,R} + x_{PR1,PR1} + x_{PR1,PR2} + Y_{PR1} \\ X_{PR2} = x_{PR2,R} + x_{PR2,PR1} + x_{PR2,PR2} + Y_{PR2} \end{cases}$$

$$\begin{cases} X_R = f(x_{R,R}, x_{PR1,R}, x_{PR2,R}, L_R) \\ X_{PR1} = f(x_{R,PR1}, x_{PR1,PR1}, x_{PR2,PR1}, L_{PR1}) \\ X_{PR2} = f(x_{R,PR2}, x_{PR1,PR2}, x_{PR2,PR2}, L_{PR2}) \end{cases}$$

Zgodnie ze standardowymi założeniami dotyczącymi funkcji produkcji:

$$\forall i, j \quad \frac{\partial Y'_i}{\partial x_{i,j}} > 0$$

oraz

$$\frac{\partial Y'_i}{\partial L_i} > 0$$

Wzrost wydajności pracy można zapisać w takim ujęciu jako możliwość wytworzenia większego produktu przy ustalonych nakładach czynników, tj. zmianę postaci funkcji opisującej procesy produkcji:

$$\Delta \left. \frac{Y'_i}{L_i} \right|_{\substack{x_{i,j}=const \\ L_i=const}} > 0$$

Wzrost wydajności pracy w sektorze rolniczym spowoduje w pierwszym okresie zwiększenie produkcji globalnej tego sektora o  $\Delta X_R$ :

$$\Delta \left. \frac{Y'_R}{L_R} \right|_{\substack{x_{R,j}=const \\ L_R=const}} > 0 \Rightarrow \Delta X_R > 0$$

Przy założeniu stałości struktury powiązań między sektorami, tj. stałości udziałów produkcji wytworzonej w  $i$ -tej gałęzi przekazanej do innych branż do globalnej produkcji danej gałęzi, sektory będą dysponowały w kolejnym okresie większymi nakładami produktów pośrednich  $x_{i,j}$ :

$$\Delta X_R > 0 \Rightarrow \Delta x_{R,j} > 0$$

Ponieważ, zgodnie z założeniem, funkcja produkcji charakteryzuje się przyjmowaniem przez pierwsze pochodne dodatnich wartości, w konsekwencji zmianie ulegnie również produkcja wytwarzana w pozostałych sektorach:

$$\Delta x_{R,j} > 0 \Rightarrow \Delta X_j > 0.$$

### **1.3. Rola wartości dodanej w pomiarze wzrostu**

#### **1.3.1. Wartość dodana w ujęciu teoretycznym**

Wartość dodana jest zmienną powszechnie wykorzystywaną w analizach zjawisk gospodarczych, zarówno w ujęciu mikro-, jak i makroekonomicznym. Zazwyczaj definiuje się ją w oparciu o wynagrodzenia i dochody czynników produkcji. W rezultacie można wykorzystywać ją zarówno jako podstawę wnioskowania na temat wydajności czynników, co zwłaszcza znajduje zastosowanie dla czynnika pracy [por. Sielska et al., 2015], jak i w badaniach dochodów tego czynnika [Bowler, 1985].

W ujęciu makroekonomicznym wartość dodana jest traktowana jako jeden ze sposobów pomiaru produktu globalnego brutto gospodarki, który zgodnie z teorią powinien być równy sumie wartości dóbr i usług wyprodukowanych w danej gospodarce, a zatem sumie wartości dodanych, pojawiających się w kolejnych fazach wytwarzania produktów finalnych [Auerbach, Kotlikoff, 1998; Wells, Krugman, 2012].


Jak zauważają Sielska i in. [2015, s. 78], „statystycznie w rachunku tworzenia PKB wartość dodana jest nieco mniejsza od PKB, choć jest jego najistotniejszą składową”. W niniejszej pracy nie odnosimy się szerzej do szczegółowych kwestii związanych ze sposobami pomiaru samej wartości dodanej i jej składowych, ponieważ rozważania takie znaleźć można w [Sielska et al., 2015]. Warto jedynie nadmienić, że statystyka państwowa dostarcza danych dotyczących sekcji Rolnictwo, leśnictwo, łowiectwo, rybactwo<sup>1</sup>, czyli szerszego zbioru działalności niż samo rolnictwo. Analogiczne wyniki dla samego rolnictwa uzyskać można drogą szacowania. Przykład potencjalnych rozbieżności między wynikami uzyskanymi z tych dwóch źródeł stanowi rysunek 6, na którym przedstawiono porównanie dynamiki wartości dodanej w dziale Rolnictwo, leśnictwo, łowiectwo, rybactwo i sektorze rolniczym w latach 2010-2013 (2010=1).

---

<sup>1</sup> Jest to sekcja A wg Polskiej Klasyfikacji Działalności (PKD).

Zmienne wykorzystane do tego zestawienia wyrażone zostały w cenach bieżących, sednem jest jednak w tym wypadku nie analiza samych zmian w czasie, ale wskazanie na różnice wynikające z odmiennego zdefiniowania badanego sektora.

**Rysunek 6. Porównanie dynamiki wartości dodanej w dziale Rolnictwo, leśnictwo, łowiectwo, rybactwo i sektorze rolniczym w latach 2010-2013 (2010=1)**



Źródło: opracowanie własne na podstawie [Sielska et al., 2015].

Wartość dodaną w odniesieniu do określonego produktu można zdefiniować w ogólny sposób, jako:

$$c_Y - \sum_i \left( c_Y^i - \sum_j c_{x_j}^i \cdot x_j^i \right)$$

gdzie:

- $c_Y^i$  – cena produktu na  $i$ -tym etapie procesu wytwórczego,
- $c_{x_j}^i$  – wynagrodzenie czynnika  $x_j$  na  $i$ -tym etapie procesu wytwórczego,
- $x_j^i$  – czynnik  $x_j$  wykorzystywany na  $i$ -tym etapie procesu wytwórczego,

zaś w odniesieniu do  $n$ -sektorowej gospodarki, jako sumę wartości dodanych wytworzonych w poszczególnych gałęziach:

$$\sum_{k=1}^n \left( c_Y^k - \sum_i \left( c_Y^{k,i} - \sum_j c_{x_j}^{k,i} \cdot x_j^{k,i} \right) \right)$$

gdzie:

$c_Y^k$  – cena produktu wytworzonego w  $k$ -tym sektorze,

$c_Y^{k,i}$  – cena produktu  $k$ -tego sektora na  $i$ -tym etapie procesu wytwórczego,

$x_j^{k,i}$  – czynnik  $x_j$  wykorzystywany na  $i$ -tym etapie procesu wytwórczego w  $k$ -tym sektorze,

$k = 1, \dots, n$  – indeks sektora.

Rozpatrywana w takim ujęciu wartość dodana opisuje nadwyżkę wartości produktu nad kosztami jego wytworzenia, jej zmiany odpowiadać będą zatem zmianom procesów wytwórczych. W przypadku wzrostu wartości dodanej wyróżnić możemy dwa źródła: obniżkę kosztów lub wzrost cen otrzymywanych na poszczególnych etapach. Przy założeniu że ceny rynkowe produktów finalnych wynikają z oceny użyteczności dokonanej przez konsumentów  $c_Y = f(U(Y))$ , a zależność ta jest rosnąca, oba stanowią odzwierciedlenie korzystnych zmian zachodzących u producentów.

Alternatywnie, jak wskazaliśmy wyżej, wartość dodana może być traktowana jako zmienna opisująca dochody czynników produkcji. Sedno takiej interpretacji wynika z przedstawionych wyżej prawidłowości, zgodnie z którymi wynagrodzenie czynnika powinno odpowiadać jego produktywności:

$$c_{x_i} = \frac{\partial Y}{\partial x_i} \cdot c_Y$$

W tym ujęciu:

$$\sum_i c_{x_i} \cdot x_j^i$$

W szczególnie sposób w pracy poświęcono uwagę wartości dodanej w przeliczeniu na jednostkę pracy ze względu na rolę, jaką wydajność ta odgrywa w procesach wzrostu, do którego to aspektu odnosiliśmy się już wcześniej. Można dodać, że czynnik ten traktowany był od dawna jako ten, który umożliwia powstanie nadwyżki w gospodarce [Bartkowiak, 2008]. Przyjmowano bowiem, że wzrost produkcji stanowi konsekwencję specjalizacji pracy, a więc jest pochodną zmian organizacji procesów wytwórczych [Bartkowiak, 2008]. W ujęciu wykorzystującym funkcję produkcji jest to odzwierciedlone w zmianach postaci funkcyjnej opisującej procesy produkcji lub jej parametrów.

Warto nadmienić również, że czynnik pracy nie powinien być rozpatrywany całkowicie oddzielnie od czynnika kapitału, ze względu na powiązania

między czynnikami w procesie produkcyjnym. Technologie mniej lub bardziej pracochłonne różni bowiem nie tylko wielkość nakładów czynnika pracy, ale również rodzaj towarzyszących mu innych czynników. Jak pisze Lazzarini [2008], w zależności od tego, jak duże jest wykorzystanie pracy może być wymagany inny kapitał. Jest to swego rodzaju utrudnienie substytucji w procesach produkcyjnych.

Mimo to obecnie zauważalny jest trend, zgodnie z którym producenci dążą do coraz szerszej substytucji czynnika pracy czynnikiem kapitału, co można zauważyć szczególnie w przypadku krajów wysoko rozwiniętych, w których koszty czynnika pracy są wysokie [Rembisz, Sielska, 2015].

Kapitał, jak wskazuje się w literaturze przedmiotu, stanowi istotną podstawę wzrostu produktywności pracy. Poprawa technicznego uzbrojenia pracy umożliwia wzrost produkcji:

$$\frac{\Delta K}{\Delta L} > 1 \Rightarrow \Delta Y > 0$$

Przy ustalonych nakładach czynnika pracy konsekwencją jest oczywiście przyrost jej produktywności.

Z kolei sam przyrost kapitału, co od strony teoretycznej przywoływane jest m.in. w modelu Harroda-Domara, jest funkcją inwestycji podejmowanych przez producentów:

$$\Delta I > 0 \Rightarrow \Delta K > 0$$

Zwiększony kapitał pozwala efektywniej wykorzystać czynnik pracy, co skutkuje przyrostem wartości dodanej.

Wartość dodana nie tylko odzwierciedla zatem sedno wzrostu, ale należy również do podstawowych zmiennych, których wartości są publikowane, zarówno dla gospodarki ogółem, jak i jej sektorów. Dane stanowiące podstawę do analiz są więc dostępne, chociaż pochodzące z różnych źródeł nie muszą być między sobą porównywalne. Dla przykładu można przywołać zmiany metodyki wyznaczania wartości dodanej na pracującego wg GUS, tj. przejście ze standardów ESA 1995 na ESA 2010 wprowadzone rozporządzeniem Parlamentu Europejskiego i Rady nr 549/2013 z dnia 21.05.2013 r. Za istotne zmiany, które mogą wywierać wpływ na wartość dodaną brutto można uznać m.in. uwzględnienie w nadwyżce operacyjnej brutto wyceny produkcji na własne cele finalne dla producentów rynkowych czy uwzględnienie szacunku szarej gospodarki, tj. legalnej produkcji ukrytej w zarejestrowanych podmiotach gospodarczych, a także wartości usług świadczonych przez osoby fizyczne w ramach wykonywania

pracy nierejestrowanej [*Rocznik Statystyczny Rzeczypospolitej Polskiej*, 2014; Sielska et al., 2015].

W kontekście niniejszej pracy szczególną uwagę należy zwrócić również na różnice występujące między definicją zgodną z wytycznymi Agencji Restrukturyzacji i Modernizacji Rolnictwa (ARiMR), dotyczącą wartości dodanej stanowiącej podstawę oceny skuteczności wsparcia uzyskiwanego przez gospodarstwa rolne z PROW oraz definicją obowiązującą w FADN. Rozbieżności dotyczą m.in. kwestii uwzględniania jednolitej płatności obszarowej, z tytułu zazielenienia lub dotacji do kosztów produkcji. Kwestie te omówiono bardziej szczegółowo w [Sielska et al., 2015].


### **1.3.2. Wartość dodana w ujęciu empirycznym**

Powyższe rozważania można zilustrować na podstawie danych w skali makroekonomicznej. Ze względu na ograniczony zakres niniejszego opracowania, którego głównym przedmiotem jest analiza w ujęciu mikroekonomicznym, odnosimy się w tym momencie jedynie do ogólnych tendencji i trendów, jakie można zauważyć w kształtowaniu się wartości dodanej oraz zmiennych pokrewnych. Analizie mikroekonomicznej poświęcona zostanie natomiast ostatnia część niniejszej pracy.

Warto zauważyć, że udział wartości dodanej wykreowanej w rolnictwie w PKB wybranych krajów europejskich w 2014 r. zmalał w porównaniu do 1995 r. (rysunek 7). Mediana tego miernika spadła o ok. 2 punkty procentowe (z 4,36% do 2,35%). Podobne wnioski można wyciągnąć analizując udział zatrudnienia w tym sektorze w ogólnym zatrudnieniu (rysunek 8). W tym wypadku spadek mediany wynosił 4 punkty procentowe (z 8% do 3,9%). Jak można zauważyć, dla obu zmiennych spadek ten był znaczący. Nie znalazł on jednak odzwierciedlenia w zróżnicowaniu między krajami, które mierzone pozycyjnym współczynnikiem zmienności w przypadku wartości dodanej spadło o ponad 18 punktów procentowych, zaś dla udziału pracy wzrosło o blisko 16 punktów procentowych.




**Rysunek 7. Wartość dodana rolnictwa jako część PKB w wybranych krajach europejskich w 1995 r. i 2014 r.**



Źródło: opracowanie własne na podstawie danych Banku Światowego.

**Rysunek 8. Zatrudnienie w rolnictwie jako część zatrudnienia ogółem w wybranych krajach europejskich w 1995 r. i 2014 r.**

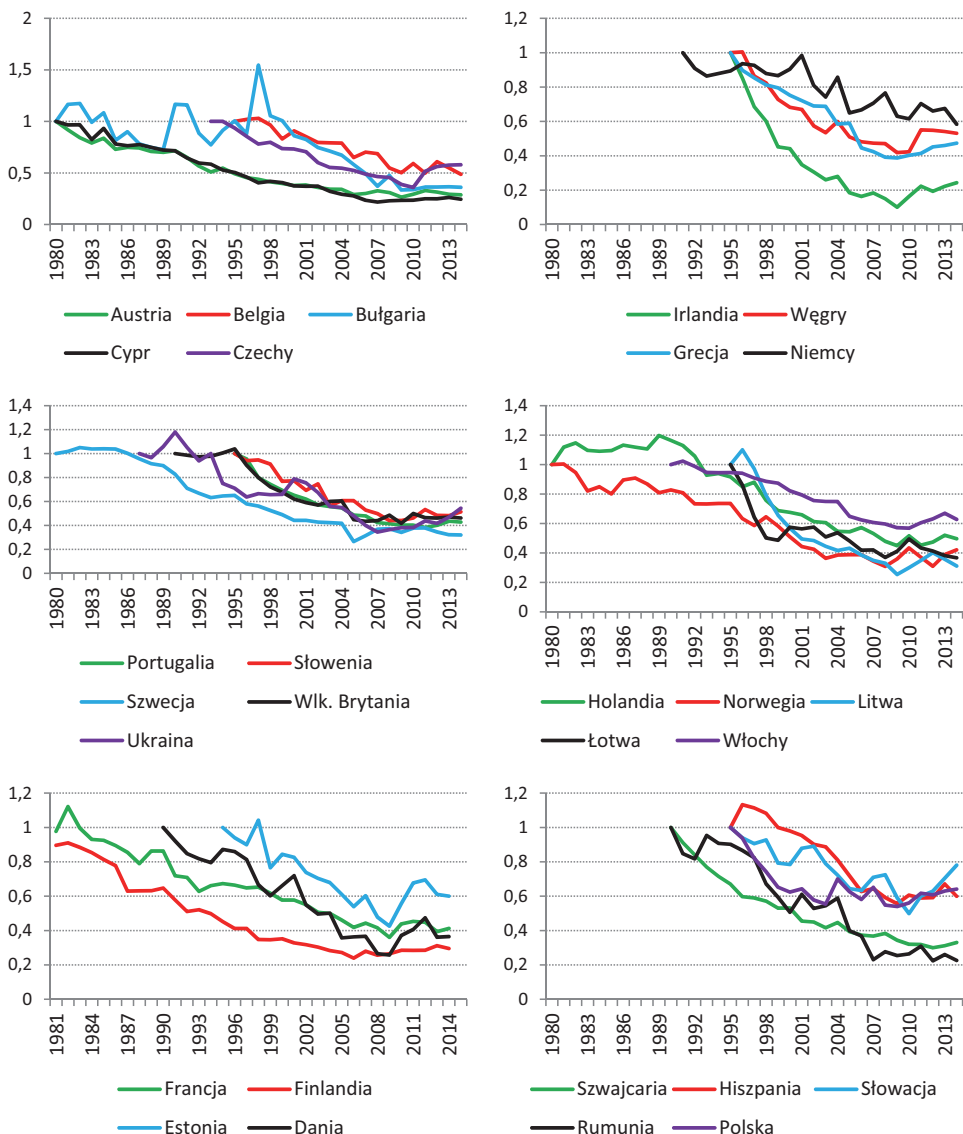


Źródło: opracowanie własne na podstawie danych Banku Światowego.

Dla obu omawianych wskaźników zmiany, mimo pewnych wahań, zachodziły stopniowo przez cały analizowany okres. Na rysunkach 9-10 zaprezentowano indeksy dynamiki udziału wartości dodanej w rolnictwie w PKB oraz zatrudnienia w rolnictwie w zatrudnieniu ogółem w dłuższym okresie, co pozwala zauważyć długookresowe trendy spadkowe w przypadku obu tych zmiennych. Ze względu na różną długość dostępnych szeregów czasowych, dynamikę obliczano w stosunku do pierwszej niezerowej obserwacji. Udział wartości do-

danej wykreowanej w rolnictwie w stosunku do PKB był w 2014 r. o blisko 45% niższy niż w latach bazowych. W 2014 r. wynosił on przeciętnie 2,34% w porównaniu do 4,35% w 1995 r., pierwszym, w którym dostępne były dane dla całej badanej grupy.

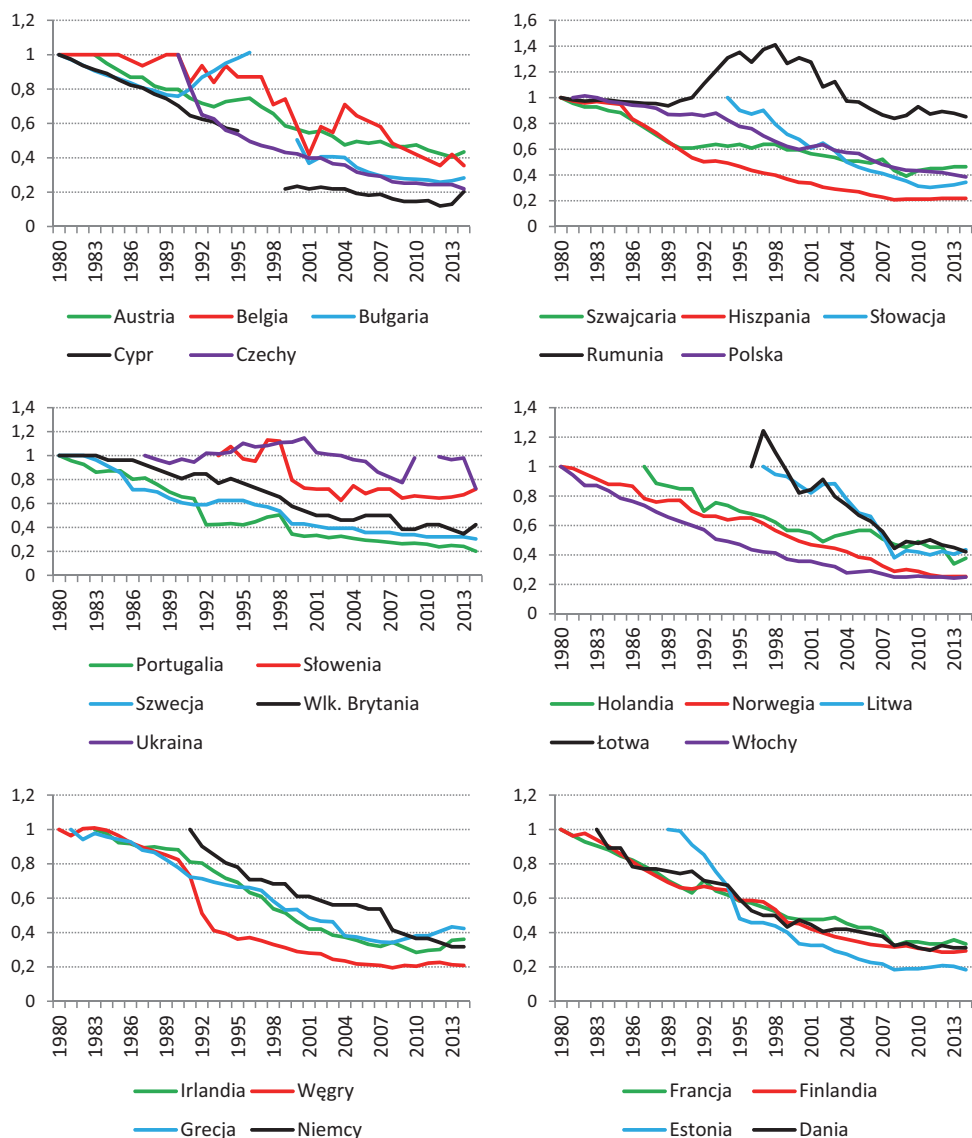
**Rysunek 9. Wartość dodana rolnictwa jako część PKB w wybranych krajach europejskich (pierwsza niezerowa obserwacja=1)**



Źródło: opracowanie własne na podstawie danych Banku Światowego.

Z kolei udział rolnictwa w zatrudnieniu w analizowanej grupie krajów spadł w 2014 r. o ok. 34 % w porównaniu do bazowych lat. W 2014 r. wynosił przeciętnie 3,9%, w porównaniu do 7,9% w 1995 r. Obie zmiany są zgodne z wnioskami wynikającymi z analizy teorii.

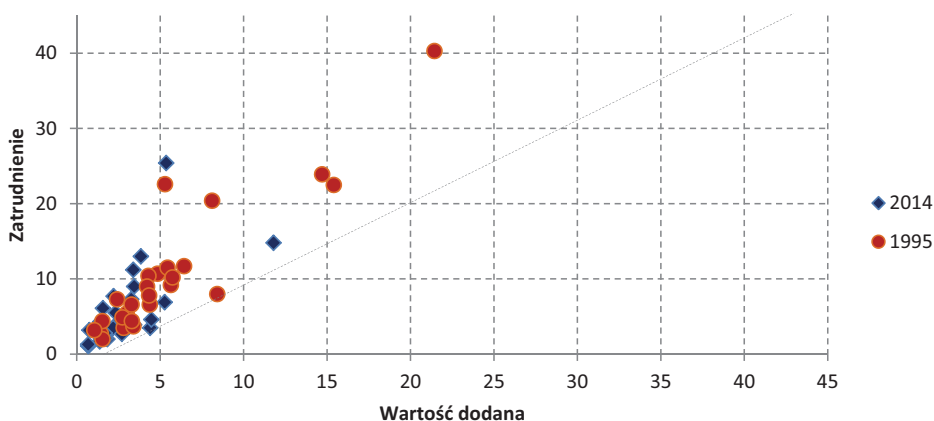
**Rysunek 10. Zatrudnienie w rolnictwie jako część ogólnego zatrudnienia w wybranych krajach europejskich (pierwsza niezerowa obserwacja=1)**



Źródło: opracowanie własne na podstawie danych Banku Światowego.

Zbadano również zróżnicowanie krajów ze względu na obie rozważane cechy łącznie. Jak można zauważyć na rysunku 11, rozproszenie w 2014 r. zmalało w porównaniu do 1995 r.

**Rysunek 11. Zatrudnienie w rolnictwie jako część zatrudnienia ogółem oraz udział wartości dodanej w rolnictwie w PKB w wybranych krajach europejskich w 1995 r. i 2014 r.**



Źródło: opracowanie własne na podstawie danych Banku Światowego.

Aby nie ograniczać się jedynie do analizy graficznej, obliczono miarę podobieństwa dla badanej grupy krajów. W tym celu przyjęto, że każdemu krajowi, opisanemu dwiema cechami, odpowiada punkt z przestrzeni dwuwymiarowej oraz wyznaczono macierz odległości tych punktów w metryce euklidesowej zgodnie ze wzorem:

$$d(\mathbf{x}, \mathbf{y}) = \sqrt{\sum_{i=1}^n |x_i - y_i|^2}$$


gdzie:

$x_i, y_i$  – współrzędne  $i$ -tego punktu (odpowiednio udział zatrudnienia w rolnictwie w zatrudnieniu ogółem oraz wartości dodanej w rolnictwie w wartości PKB w  $i$ -tym kraju).

Przeciętna odległość w 1995 r. mierzona medianą wynosiła 6,13, natomiast w 2014 r. zmalała do 3,53, co potwierdza wniosek o tym, że analizowane kraje zbliżyły się do siebie ze względu na badane cechy. Jak wskazują wyniki zaprezentowane na rysunku 12, w badanym okresie zachodziła konwergencja.

Kraje stawały się coraz bardziej podobne ze względu na udział zatrudnienia w rolnictwie w ogólnym zatrudnieniu oraz udział wartości dodanej powstałej w rolnictwie w PKB. Podobieństwo, mierzone średnią oraz medianą z odległości między krajami mierzonej w metryce euklidesowej, stabilizowało się w ostatnich latach.


**Rysunek 12. Konwergencja wybranych krajów europejskich ze względu na zatrudnienie w rolnictwie jako część zatrudnienia ogółem oraz udział wartości dodanej w rolnictwie w PKB w latach 1995-2014**



Źródło: opracowanie własne na podstawie danych Banku Światowego.

Istotnym czynnikiem, który może dostarczyć wielu informacji o efektywności procesów gospodarczych, zwłaszcza w kontekście alokacji i podziału jest stosunek wydajności i wynagrodzenia w odpowiednich sektorach gospodarki. Teoretyczne podstawy znaczenia tego zjawiska przedstawiono wcześniej, do problemu odnoszą się także publikacje dotyczące jednostkowych kosztów pracy [Rembisz, Sielska, 2014a, 2014b]. W niniejszej pracy ograniczymy się do analizy przeprowadzonej dla Polski. Przedmiotem badania jest porównanie udziału wynagrodzenia pracy w wartości dodanej w poszczególnych gałęziach polskiego przemysłu. Jest to zatem ujęcie nieco odmienne od przywoływanych wyżej.

**Rysunek 13. Dynamika udziału wynagrodzenia w wartości dodanej w poszczególnych sektorach polskiej gospodarki (1998=1)**




Źródło: opracowanie własne na podstawie danych OECD.

Jak można zauważyć na podstawie rysunku 13, udział wynagrodzenia w wartości dodanej w Polsce wzrastał jedynie w przypadku sektora usług. W rolnictwie odnotowano spadek wartości tego wskaźnika, co jest zgodne ze zmianami zachodzącymi w innych krajach UE (rysunek 14).

Jak zwraca uwagę Wojtyła [2009, s. 50], „udział zysków i płac w PKB wiąże się w istotny sposób z podstawowymi dylematami makroekonomicznymi na poziomie gospodarki narodowej: mniejsze nierówności w podziale dochodów mogą oznaczać wyższy udział czynnika „praca” w PKB, ale jednocześnie wyższe bezrobocie i większą presję inflacyjną”. Implikacje braku zrównoważonego poziomu produktywności i wynagrodzenia w skali sektorowej wiążą się również z kwestią międzysektorowego przepływu siły roboczej.

**Rysunek 14. Dynamika udziału wynagrodzenia w wartości dodanej w rolnictwie w wybranych krajach europejskich (1998=1)**



Źródło: opracowanie własne na podstawie danych OECD.

## 2. Idea podejścia kontrfaktycznego jako narzędzia ewaluacji

### 2.1. Ograniczenia zastosowania modeli regresji oraz metod naiwnych w badaniu wpływu

#### 2.1.1. Modele regresji

Zależność pomiędzy wartością dodaną na jednostkę pracy oraz instrumentami polityki może być rozpatrywana w różnych sferach. Wszystkie one posiadają pewne zalety i ograniczenia związane z możliwością ich wykorzystania.

Po pierwsze, warto zauważyć, że w odniesieniu do ewaluacji programów polityki rolnej, przedmiotem zainteresowania badacza staje się nie samo kształtowanie się oraz zachowanie wskaźnika rezultatu, jakim jest w rozważanym w pracy przypadku wartość dodana na jednostkę pracy (GVA/AWU), ale to jej zachowanie, które pozostaje wynikiem zewnętrznego oddziaływania ze strony polityki rolnej<sup>2</sup>. Zasadniczo zmienia to poziom złożoności prowadzonej analizy. O ile bowiem badanie samych zmian zachodzących w odniesieniu do danego wskaźnika nie jest samo w sobie skomplikowane, to już wyszczególnienie tego ich aspektu, który wynika z wpływu wyodrębnionego czynnika egzogenicznego stanowi wyzwanie. Wymaga ono bowiem wyodrębnienia tzw. rzeczywistego związku przyczynowo-skutkowego (ang. *true causation*) [Michalek, 2012b], co w analogii do rozważań prowadzonych na gruncie teorii ekonomii można traktować jako swoistą analogię i rozwinięcie zasady *ceteris paribus*.

Tymczasem nie ulega wątpliwości, że ze względu na złożoność procesów gospodarczych obserwowalne zjawiska posiadają liczne przyczyny i pozostają efektem oddziaływania wielu czynników pobocznych. Wyodrębnienie ich w analizie empirycznej wymaga spełnienia określonych założeń.

Najprostszym sposobem przeprowadzenia analizy skoncentrowanej na zależności poszczególnych zjawisk wydaje się zastosowanie metod regresji. Jak zauważa Szulc [2012], pewną słabością modeli regresji jest to, że są one metodami parametrycznymi i wymagają przyjęcia założenia dotyczącego postaci funkcyjnej.

---

<sup>2</sup> Mimo iż rozważania w tym rozdziale mają charakter teoretyczny, nie należy zapominać, że u ich podstaw leży zagadnienie oceny wpływu instrumentów polityki rolnej na kształtowanie się stosunku wartości dodanej brutto do rocznej jednostki pracy (GVA/AWU) w polskich gospodarstwach rolnych. Z tego powodu w pracy dla określenia cechy, na którą wpływ podlega ocenie, stosuje się zamiennie terminy „zmienna wynikowa” i „wskaźnik rezultatu”.



Metody regresji można również traktować jako pewien rodzaj analizy pośredniej, w której badanej zmiennej objaśnianej przyporządkowuje się potencjalne determinanty (zmienne objaśniające). Dostępne i powszechnie wykorzystywane testy istotności oszacowań zmiennych oraz postaci funkcyjnej pozwalają na uzyskanie analitycznej postaci badanej zależności, w formie:

$$Y = f(X_1, X_2, \dots, X_n, \varepsilon)$$

gdzie:

$Y$  – zmienna objaśniana,

$X_1, X_2, \dots, X_n$  – zmienne objaśniające,


$\varepsilon$  – składnik losowy.

W zależności od wybranego do użycia w prowadzonym badaniu modelu regresji możliwe jest wprowadzenie do analizy oddziaływania między zmiennymi w czasie, współzależności w przestrzeni lub efektów wynikających z oddziaływania indywidualnych cech badanych jednostek.

Stosowanie do oceny wpływu prostych modeli regresji nie spełnia warunku wyodrębnienia prawdziwej przyczynowości. Do wartości statystyk, które świadczyłyby o istotności i akceptowalności określonych aspektów modelu wystarcza odpowiednio silna korelacja zmiennych. Można w tym miejscu odnieść się do metody selekcji zmiennych Hellwiga, która wręcz bazuje na sile związków korelacyjnych [por. Kopiński, Porębski, 2014; Gruszczyński, Podgórska, 2003].

Wówczas zjawiskiem korzystnym jest słaba korelacja w zbiorze zmiennych objaśniających oraz mocna korelacja w parach typu zmienna objaśniająca – zmienna objaśniana. Korelacja, na podstawie której można wnioskować o współzależności w czasie i przestrzeni nie oznacza jednak zależności przyczynowo-skutkowej. Ilustruje to schemat zamieszczony na rysunku 15, na którym przedstawiono zależność wartości zmiennej  $Y$  od rzeczywistych determinant ( $Z_1, \dots, Z_n, X_n$ ) oraz od predyktorów wykorzystanych w modelu regresji, tradycyjnie oznaczonych przez  $X_i$ , gdzie  $i = 1, \dots, n$ .

## Rysunek 15. Zależności korelacyjne i przyczynowo-skutkowe



Źródło: opracowanie własne.

Jak wskazują Guo i Fraser [2015], w przypadku wystąpienia między parą zmiennych korelacji mogą istnieć trzy przyczyny, którymi można wyjaśnić taki związek. Pierwszą jest zależność obu tych zmiennych od trzeciej, dotychczas nie uwzględnionej w analizie, ale determinującej przyjmowane przez nie wartości. Wówczas między bezpośrednio badanymi czynnikami nie występuje związek przyczynowo-skutkowy, mimo istnienia między nimi korelacji. Pozostałe dwa sugerowane przez przywołanych autorów wyjaśnienia odnoszą się już do zależności przyczynowo-skutkowych. Możliwe jest jednak zarówno, że wartości pierwszej zmiennej stanowią efekt oddziaływania drugiej, jak i może wystąpić sytuacja odwrotna. Zatem nawet jeśli występuje korelacja i ma ona źródło w związku przyczynowym, nie mówi nic o kierunku tej relacji. Pozostaje on do ustalenia na podstawie, przykładowo, wiedzy eksperckiej.

Lazarsfeld [1959; za: Guo, Fraser, 2015], wyszczególniając trzy kryteria, na podstawie których można zdefiniować istnienie zależności przyczynowo-skutkowej, odnosi się do wspomnianych już wyżej aspektów:

- 1) przyczyna musi zachodzić przed skutkiem,
- 2) przyczyna i skutek muszą być skorelowane,
- 3) korelacja nie może być wyjaśniona istnieniem wspólnej determinanty dla badanych zmiennych.

Powyższe kryteria oznaczają, że korelacja, choć konieczna, nie jest wystarczająca, i nie powinno być możliwe wyjaśnienie jej w inny sposób niż istnieniem zależności przyczynowo-skutkowej.

Badanie wpływu wybranego czynnika za pomocą modelu regresji wymaga wprowadzenia reprezentującej oddziaływanie zmiennej w formie zmiennej dychotomicznej lub jako zmienną obrazującą to oddziaływanie w ujęciu wartościowym (w odniesieniu do przedmiotu niniejszej pracy możliwościami tym odpowiadają odpowiednio: zmienna zerojedynkowa opisująca fakt uzyskania przez dane gospodarstwo wsparcia oraz kwota tego wsparcia wyrażona w pieniądzu).

W tym drugim przypadku potencjalnie możliwa jest interpretacja wpływu krańcowego przyrostu wartości determinanty na kształtowanie się badanej zmiennej. Natomiast w pierwszym przypadku przedmiotem zainteresowania staje się nie skutek jednostkowej zmiany wartości determinanty, ale sam fakt wystąpienia danego czynnika dla rozpatrywanych obserwacji.

$$D_i = \begin{cases} 1 & \text{jeśli } i - \text{ty obiekt poddano oddziaływaniu} \\ 0 & \text{wpp.} \end{cases}$$

gdzie:

$D_i$  – zmienna zerojedynkowa odnosząca się do badanego działania.

W niniejszej pracy skoncentrowano się na takim właśnie ujęciu.

Standardowo zamieszczana w podręcznikach ekonometrii interpretacja wiąże się z porównaniem wartości uzyskanej dla obserwacji poddanej oddziaływaniu w odniesieniu do obserwacji scharakteryzowanej takimi samymi wartościami cech, ale nie będącej obiektem oddziaływania. Należy zwrócić uwagę na to, że poza wskazanym wcześniej problemem korelacji i zależności przyczynowo-skutkowej, w modelu tego typu powinien zostać ujęty sposób wyboru obserwacji do grupy poddanej oddziaływaniu oraz niebędącej pod jego wpływem. Trzcíński [2009] zauważa bowiem, że w przypadku gdy w modelu nie jest uwzględniony sposób doboru jednostek do grupy poddanej oddziaływaniu, może wystąpić korelacja składnika losowego i zmiennej zerojedynkowej. Powodem takiej sytuacji jest fakt, iż wartość, jaką w przypadku indywidualnej obserwacji przyjmuje zmienna zerojedynkowa stanowi efekt wartości innych zmiennych, które nie zostały włączone do modelu, wobec czego ich wpływ na zmienną objaśnianą pozostaje reprezentowany w nim przez składnik losowy. Skutkuje to brakiem spełnienia jednego z założeń Metody Najmniejszych Kwadratów<sup>3</sup>.

Proste modele regresji umożliwiają ocenę wpływu jedynie w kategoriach przeciętnych, zaś nałożenie przy interpretacji założenia niezmienności innych

---

<sup>3</sup> Zgodnie z założeniami Metody Najmniejszych Kwadratów (MNK) przyjmuje się, że:

1. Zmienne objaśniające są nielosowe, tj. niezależne od składnika losowego (nie występuje korelacja składnika losowego ze zmiennymi objaśniającymi);
2. Składnik losowy ma zerową wartość oczekiwaną i skończoną, stałą wariancję;
3. Zmienne objaśniające są wolne od współliniowości (macierz zmiennych objaśniających ma pełny rząd kolumnowy);
4. Składnik losowy ma rozkład normalny.

Trzy pierwsze założenia muszą być spełnione, aby estymator uzyskany Metodą Najmniejszych Kwadratów miał własności wymienione w twierdzeniu Gaussa-Markowa, natomiast ostatnie z wymienionych założeń przyczynia się do ułatwienia weryfikacji modelu [Gruszczyński, Kuszewski, Podgórska, 2009].

czynników wydaje się w takim wypadku założeniem bardzo mocnym. Można przywołać bowiem liczne przykłady sytuacji, w których zmienna zerojedynkowa, opisująca fakt poddania jednostek badanemu oddziaływaniu, podlega zmianom łącznie z pozostałymi zmiennymi. Przykładowo, w przypadku szkoleń mających za zadanie przyczynić się do poprawy pozycji kursanta na rynku pracy, często finansowanych ze środków publicznych i podlegających ewaluacji, zmieniają się nie tylko cechy kandydata mające bezpośredni wpływ na zarobki, takie jak znajomość języków, umiejętność wykorzystywania specjalistycznego sprzętu itd. Uczestnictwo w kursie może przyczynić się również do zmiany zachowania kandydata poszukującego pracy, co, chociaż samo w sobie nie jest przedmiotem kursu, może rzutować na uzyskiwane przez niego warunki zatrudnienia.

### 2.1.2. Metody naiwne

Drugą grupą metod oceny wpływu, do której chcemy się odnieść są tzw. metody naiwne<sup>4</sup>. Przedstawiony w tej części przegląd oparto na pracy [Michalek, 2012a].

Metody naiwne bazują na prostych, nieskomplikowanych algorytmach. Uwzględniamy je w pracy, aby zwrócić uwagę na niebezpieczeństwa i problemy wynikające z ich zastosowania w przypadku prowadzenia ewaluacji.

Podstawą oceny wpływu wybranego oddziaływania jest porównanie wartości przyjmowanych przez zmienną wynikową (wskaźnik rezultatu) w przypadku wystąpienia oddziaływania i dla jego braku. Warto jednak zauważyć, że takie proste zestawienie wartości nie jest wystarczające, istnieje bowiem szereg czynników wpływających na kształtowanie się badanej zmiennej. Najbardziej istotne naszym zdaniem problemy, jakie często napotyka się stosując metody naiwne, zilustrowano schematycznie na rysunku 16.

W obu przedstawionych na schemacie sytuacjach (wystąpienia zewnętrznego oddziaływania, którego wpływ jest przedmiotem oceny oraz jego braku), wartości zmiennej wynikowej zależne są od cech opisujących zarówno badany obiekt, jak i jego otoczenie. Ponieważ obserwacje mają miejsce w czasie, dla uproszczenia wyróżniliśmy dwa momenty czasowe ( $t$ , w którym nie wystąpiło oddziaływanie, którego efekt poddany jest badaniu, oraz  $t+1$ , w którym część obiektów została poddana badanemu oddziaływaniu, a ono samo pojawia się wśród determinant wartości przyjmowanych przez zmienną wynikową). Zarówno cechy danego obiektu, jak i jego otoczenia mogą się zmieniać wraz z upływem czasu, zaś w przyjętym na schemacie ujęciu zmiany

---

<sup>4</sup> Określenie nie ma charakteru deprecjonującego, jest terminem przyjmowanym w literaturze w przypadku metod opierających się na prostych algorytmach.

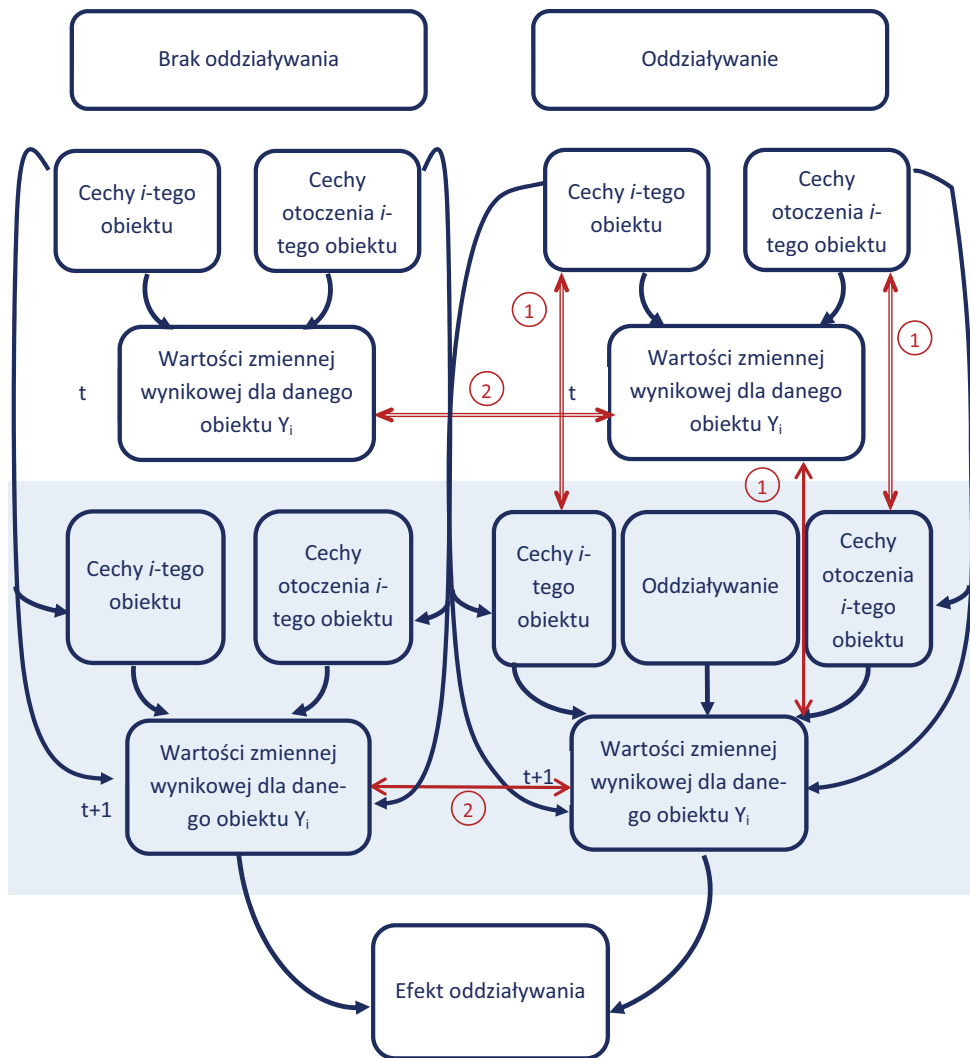
te uzależnione są od stanu poprzedzającego. Oba te uwarunkowania dodatkowo wpływają na siebie nawzajem.

Ma to oczywiście uzasadnienie w empirii. Uwarunkowania ekonomiczne podlegają pewnej ewolucji wraz ze zmianami zachodzącymi w całej gospodarce, co w zwykłej sytuacji jest zjawiskiem podlegającym określonym regułom, możliwym do zaobserwowania i – w pewnym zakresie – prognozowania. Zmiany zachodzące w danym obiekcie również stanowią pochodną poprzedzającego stanu (np. dochody osiągane przez jednostkę w okresie  $t+1$  wynikać mogą z wykształcenia zdobytego w okresie  $t$ , podobnie jak inwestycje w gospodarstwie podjęte w okresie  $t+1$  można traktować jako efekt oszczędności dokonanych w momencie  $t$  itd.).

Zarówno uwarunkowania z okresu  $t$ , jak i  $t+1$  mają w naszym ujęciu wpływ na kształtowanie się wartości zmiennej wynikowej  $Y$ . Efekt wpływu może zatem być dość intuicyjnie oceniony na podstawie porównania wartości tej zmiennej w grupie obiektów poddanych wpływowi i dla jednostek, dla których żaden wpływ nie wystąpił. Schemat pozwala jednak zaznaczyć założenia przyjmowane w metodach naiwnych, które przyczyniają się do powstawania zbędnych komplikacji lub wręcz błędów we wnioskowaniu.

Pierwszym aspektem, na który chcemy zwrócić uwagę, jest wybór wartości zmiennej wynikowej, jakie będą podstawą porównań. Porównanie to może być bowiem dokonane zarówno w ujęciu dynamicznym (w czasie), jak i w przekrojowym (skoncentrowanym na różnicach pomiędzy badanymi jednostkami). W tym pierwszym, oznaczonym na schemacie pojedynczymi strzałkami opatrzonymi numerem 1, porównywane są wartości zmiennej wynikowej dla tej samej grupy obiektów przed i po wystąpieniu interwencji (wartości z okresu  $t+1$  zestawiane są z wartościami z okresu  $t$ ). W takim podejściu nie są w ogóle uwzględniane nie tylko informacje dotyczące obiektów niepoddanych oddziaływaniu, ale i zależności dynamiczne pomiędzy uwarunkowaniami i między uwarunkowaniami a zmienną wynikową.

**Rysunek 16. Schemat wpływu oddziaływania i innych czynników na kształtowanie się wartości zmiennej wynikowej w czasie**



- ↔ podstawa porównań
- wpływ
- ↔ tożsamość

Źródło: opracowanie własne.

Pierwsza z rozpatrywanych metod opiera się zatem na prostym porównaniu wartości zmiennej wynikowej przed i po wystąpieniu oddziaływania:

$$Y_{i,t+1} - Y_{i,t}$$

dla:

$$D_{i,t} = 0, D_{i,t+1} = 1$$

gdzie:

$D_{i,t}$  – zmienna zerojedynkowa opisująca fakt poddania  $i$ -tego obiektu oddziaływaniu w okresie  $t$ ,

$Y_{i,t}$  – zmienna wynikowa dla  $i$ -tego obiektu w okresie  $t$ .

Wprawdzie analiza prowadzona jest tutaj w ujęciu dynamicznym, ale popełniany jest w tym wypadku błąd związany z brakiem wyodrębnienia zależności przyczynowo-skutkowej. Pod uwagę bierze się bowiem tylko jeden z przedstawionych wcześniej warunków występowania zależności przyczynowo-skutkowej wg. Lazarsfelda [1959], tj. następstwo w czasie.

Zakłada się, że jedynym czynnikiem różnicującym okres przed wystąpieniem wpływu i po zaistnieniu oddziaływania jest samo oddziaływanie i tylko ono może wpływać na wartość zmiennej wynikowej (wskaźnika rezultatu), co na schemacie zilustrowano podwójnymi strzałkami opatrzonymi numerem 1. Neguje się istnienie innych zmian, np. wynikających z otoczenia niezwiązanego z oddziaływaniem lub będących efektem procesów endogenicznych zachodzących w badanym obiekcie:

$$X'_{i,t} = X'_{i,t+1}$$

$$X''_{i,t} = X''_{i,t+1}$$

gdzie:

$X'_{i,t}$  – wektor wartości cech  $i$ -tego obiektu w okresie  $t$ ,

$X''_{i,t}$  – wektor wartości cech otoczenia  $i$ -tego obiektu w okresie  $t$ .

Jest to pierwszy z zasygnalizowanych już przez nas i oznaczonych na schemacie przypadków.

W sytuacji, kiedy porównywanie dokonywane jest jedynie w ujęciu przekrojowym (tj. wartości uzyskane w okresie  $t+1$  dla obiektów poddanych oddziaływaniu zestawione zostają z wartościami z tego samego okresu dla obiektów niepoddanych wpływowi), który oznaczono na schemacie strzałkami

opatrzoną cyfrą 2, przyjmowane jest założenie, zgodnie z którym bez wystąpienia oddziaływania wartości zmiennej wynikowej dla wszystkich obiektów kształtowałyby się w taki sam sposób.

Dotyczy to drugiego z przytoczonych przez Michalka [2012a] przykładów, tj. między obiektami poddanymi i niepoddanymi oddziaływaniu. Należy nadmienić, że w takim wypadku, w przeciwieństwie do poprzednio omawianej metody, możliwa jest ocena jedynie przeciętnego wpływu, zdefiniowanego poniższym wzorem, nie można natomiast ustalić wpływu dla wybranego obiektu (można go jedynie przybliżyć za pomocą tej średniej wartości).

$$\bar{W} = \frac{1}{n_1} \sum_i Y_{i,t+1} |_{D_{i,t+1}=1} - \frac{1}{n_0} \sum_i Y_{i,t+1} |_{D_{i,t+1}=0}$$

gdzie:

$\bar{W}$  – średni wpływ oddziaływania w badanej grupie,

$n_1$  – liczebność grupy obiektów poddanych oddziaływaniu,

$n_0$  – liczebność grupy obiektów niepoddanych oddziaływaniu.

Wówczas dla indywidualnego obiektu przyjąć można, że:

$$W_i = \bar{W}$$

gdzie:

$W_i$  – wpływ oddziaływania na  $i$ -ty obiekt.

Cytowany autor zwraca uwagę na istotny problem związany z tym podejściem, a mianowicie na fakt, iż odpowiednie dane dotyczące grupy obiektów nieobjętych oddziaływaniem nie zawsze są dostępne [Michalek, 2012a]. Jest to jednak, jak się wydaje, mniej istotny problem, mimo iż brak należycie wyznaczonych odpowiedników dla badanych obiektów wpływa na wiarygodność uzyskanych wyników. Niemniej jednak istnieją metody, za pomocą których wśród obiektów, dla których  $D_{i,t+1} = 0$ , można wyznaczyć odpowiednie jednostki będące podstawą porównania z grupą poddaną wpływowi. Będą one wykorzystane w niniejszej pracy.

Bardziej wart odnotowania jest fakt, że rezygnacja z wyznaczenia odpowiedniej grupy do przeprowadzenia porównania oznacza przyjęcie w tym toku analizy założenia, zgodnie z którym jedynym czynnikiem wpływającym na wartości zmiennej wynikowej jest wystąpienie oddziaływania, zaś w przypadku jego braku wartości zmiennych wynikowych kształtowałyby się w obu grupach tak samo, a zatem można przypuszczać, że:



$$X'_{i,t+1}|_{D_{i,t+1}=1} = X'_{i,t+1}|_{D_{i,t+1}=0}$$

$$X''_{i,t+1}|_{D_{i,t+1}=1} = X''_{i,t+1}|_{D_{i,t+1}=0}$$

Podobnie jak w poprzednim przykładzie, jeśli nie zostanie zagwarantowane spełnienie tego założenia, to nie ma podstaw do wnioskowania o istnieniu zależności przyczynowo-skutkowej, nawet w przypadku wystąpienia zróżnicowania w wartościach zmiennej wynikowej dla obu grup.

Trzecia z omawianych przez Michalka [2012a] metod naiwnych jest zbliżona do powyższej, a porównanie ponownie dokonywane jest w ujęciu przekrojowym. Tym razem jednak wynik uzyskany dla obiektów poddanych oddziaływaniu porównywany jest z wartościami zmiennej wynikowej uzyskanymi dla całej badanej grupy, tj. zarówno obiektów poddanych, jak i niepoddanych oddziaływaniu:

$$\bar{W}_{0,1} = \frac{1}{n_1} \sum_i Y_{i,t+1}|_{D_{i,t+1}=1} - \frac{1}{n_1 + n_0} \sum_i (Y_{i,t+1}|_{D_{i,t+1}=1} + Y_{i,t+1}|_{D_{i,t+1}=0})$$

$$\bar{W}_{0,1} = \frac{1}{n_1} \sum_i Y_{i,t+1}|_{D_{i,t+1}=1} - \frac{1}{n_1 + n_0} \sum_i (Y_{i,t+1})$$

gdzie:

$\bar{W}_{0,1}$  – średni wpływ oddziaływania w badanej grupie względem całej próby.

Podejście takie, jak zauważa Michalek [2012a], posiada tę samą słabość co poprzednio rozważane, związaną z założeniem o stałości cech i wynikającej z niej jednakowości kształtowania się zmiennej wynikowej w hipotetycznym przypadku braku wystąpienia interwencji w obu grupach, a dodatkowo wiąże się z trudnościami interpretacyjnymi.

## 2.2. Istota podejścia kontrfaktycznego

Wobec utrudnień pojawiających się w związku z potencjalnym zastosowaniem do oceny wpływu modeli regresji, w literaturze do tego typu badań stosuje się tzw. podejście kontrfaktyczne, które traktować można jako swoiste rozszerzenie zasady *ceteris paribus*. Zgodnie z nią bowiem przedmiotem analizy jest zmiana (wpływ) jednego czynnika przy założeniu stałych wartości pozostałych zmiennych i niezmienności innych uwarunkowań. Zgodnie z tym ujęciem

wpływ danego czynnika może zostać zbadany jako różnica występująca między dwoma przypadkami: sytuacją, w której wpływ wystąpił (dany obiekt poddano oddziaływaniu, zaś w rozważanym w pracy przypadku – dane gospodarstwo uzyskało wsparcie w ramach PROW) a stanem, w którym wpływ nie wystąpił (obiektu nie poddano oddziaływaniu, co oznacza, że rozpatrywane gospodarstwo nie uzyskało wsparcia).

Podejście bazuje na tzw. wynikach kontrfaktycznych, czyli potencjalnych, hipotetycznych rezultatach możliwych do osiągnięcia, gdyby stan poddania danego obiektu oddziaływaniu był inny niż zaobserwowany.

Porównaniu podlega zatem realizacja pewnej zmiennej wynikowej (wartość, wpływ, który jest przedmiotem badania – w rozważanym w niniejszej pracy przypadku wartość wskaźnika rezultatu) w sytuacji, w której wystąpił wpływ i w przypadku jego braku. W analizie wpływu dla jednego wybranego obiektu efekt oddziaływania może zostać zdefiniowany jako różnica:

$$W_i = Y_{1i} - Y_{0i}$$

gdzie:

$Y_{1i}$  – wartość zmiennej wynikowej dla  $i$ -tego obiektu poddanego oddziaływaniu,  
 $Y_{0i}$  – wartość zmiennej wynikowej w przypadku braku oddziaływania na  $i$ -ty obiekt.

W ogólnym ujęciu natomiast wartość wskaźnika rezultatu dla danego obiektu zapisać można wykorzystując zdefiniowaną wcześniej zmienną dychotomiczną określającą istnienie wpływu. Zmienna wynikowa przyjmuje postać:

$$Y_i = D_i Y_{1i} + (1 - D_i) Y_{0i}$$

gdzie:

$Y_i$  – wartość zmiennej wynikowej dla  $i$ -tego obiektu.

Jak wskazuje Michalek [2012a] wartości zmiennej wynikowej w obu przypadkach, zarówno w przypadku wystąpienia oddziaływania, jak i przy jego braku, pozostają zależne również od innych czynników i mogą być modelowane jako:

$$Y_{1i} = f_1(\mathbf{X}_i) + \varepsilon_{1i}$$

$$Y_{0i} = f_0(\mathbf{X}_i) + \varepsilon_{0i}$$


gdzie:

$f_1, f_0$  – funkcje łączące wynik oddziaływania z cechami analizowanego obiektu,

$\mathbf{X}_i$  – wektor cech  $i$ -tego obiektu niepodlegających wpływowi oddziaływania,  $\varepsilon_{1i}, \varepsilon_{0i}$  – zmienne losowe, spełniające warunek:  $E(\varepsilon_{1i}) = E(\varepsilon_{0i}) = 0$ .

Co jest oczywiste, pełne empiryczne zbadanie wpływu w tym ujęciu nie jest możliwe z tej przyczyny, że tylko jeden z analizowanych stanów jest możliwy do zaobserwowania (rysunek 17). Dany obiekt (gospodarstwo rolne) albo jest objęty oddziaływaniem, albo nie podlega wpływowi. Co zrozumiałe więc, obie sytuacje nie mogą wystąpić jednocześnie, analityk zaś staje w sytuacji braku danych [por. Michalek, 2012b; Strawiński, 2009].

**Rysunek 17. Wartości obserwowalne i hipotetyczne zmiennej wynikowej**



Źródło: opracowanie własne.

Trudność ta pojawia się w literaturze pod nazwą fundamentalnego problemu wnioskowania przyczynowego [Michalek, 2012b; Trzciniński, 2009] i za jej sprawą wnioskowanie dotyczące przyczyn nie może zostać przeprowadzone wprost. Różnica wartości zmiennej wynikowej musi zatem uwzględniać oszacowania przybliżające nieobserwowalne wartości zmiennych, tj. przyjąć postać [por. Szulc, 2012]:

$$W_i = \begin{cases} Y_{1i} - \hat{Y}_{0i} & \text{jeśli } D_i = 1 \\ \hat{Y}_{1i} - Y_{0i} & \text{wpp.} \end{cases}$$

gdzie:

$\hat{Y}_{0i}$  – oszacowanie potencjalnej wartości zmiennej wynikowej, jaka wystąpiłaby w przypadku braku oddziaływania na  $i$ -ty obiekt,

$\hat{Y}_{1i}$  – oszacowanie potencjalnej wartości zmiennej wynikowej, jaka wystąpiłaby w przypadku objęcia  $i$ -tego obiektu oddziaływaniem.

W przypadku objęcia obiektu oddziaływaniem obserwowalną wartość  $Y_{1i}$  porównuje się z oszacowaną wartością  $\hat{Y}_{0i}$ , jaka wystąpiłaby w sytuacji, w której oddziaływanie dla danego obiektu by nie wystąpiło. W przypadku gospodarstw

nieuzyskujących wsparcia w ramach PROW sytuacja uległaby odwróceniu, estymowane byłyby wartości wskaźnika rezultatu w hipotetycznym przypadku wystąpienia wsparcia.

Odrębną kwestią pozostaje ustalenie podstaw do oszacowania brakujących wartości. Jednym z rozwiązań jest wykorzystanie znanej zasady *ceteris paribus* oraz prognozowanie wartości zmiennej wynikowej dla danego obiektu na podstawie cech opisujących zarówno sam obiekt, jak i jego otoczenie przed wystąpieniem oddziaływania. W rozważanym w pracy przypadku oznacza to dokonanie prognozy na podstawie cech gospodarstwa i cech otoczenia zaobserwowanych przed uzyskaniem wsparcia. Zakłada się zatem, że wszystkie badane cechy w przypadku braku wsparcia rozwijałyby się zgodnie z dotychczasowymi trendami.

Podjęcie to rodzi pewne komplikacje, do których krótko się w tym punkcie należy odnieść. Po pierwsze wymagałoby ono zgromadzenia odpowiedniego zbioru danych obejmujących nie tylko wszelkie potencjalne determinanty kształtowania się zmiennej wynikowej, ale również zmienne stanowiące predyktory dla tychże determinant. Dodatkowo, uzyskane szeregi czasowe powinny być wystarczająco długie, aby umożliwić wyznaczenie trendów i dokonanie na ich podstawie wiarygodnych prognoz. Co więcej, omawiane podejście wymagałoby przyjęcia bardzo mocnego założenia dotyczącego stabilności wykorzystywanych zmiennych w czasie. Nie wszystkie zmiany trendów i otoczenia gospodarczego można jednak przewidzieć, podobnie jak nie można przewidzieć wszystkich zmian, które mogą zajść w samym badanym gospodarstwie i mieć wpływ na wartość wskaźników rezultatu. Z tego właśnie powodu, w omawianym w pracy badaniu przyjęto inne podejście, bazujące na modelowaniu prowadzonym w ujęciu kontrfaktycznym.

W statystyce, jak zauważają Guo i Fraser [2015], jako źródłowe dla tego podejścia przywoływane są zwykle prace autorstwa Neymana [1923] i Rubina [1973], chociaż w literaturze znaleźć można również odwołania do Roya [1951] lub Quandta [1972; por. Strawiński, 2014]. Zakłada ono oszacowanie nieobserwowalnych wyników na podstawie dostępnych obserwacji w próbie bez rozszerzania zakresu zmiennych i zakresu czasowego, jakie wymagane byłoby w przypadku konieczności dokonania prognoz opisaną wyżej metodą.

Podjęcie zakłada, że analityk dysponuje już zbiorem danych, które nie dotyczą eksperymentu losowego. Nie odnosi się więc do takich aspektów, jak planowanie badania czy losowanie jednostek, które zostaną objęte wpływem badanego czynnika. W pierwszym kroku zgromadzone dane grupowane są w dwa rozłączne zbiory na podstawie zaobserwowanych wartości zmiennych dychotomicznych  $D_i$ . W pierwszej grupie, dla której  $D_i = 1$ , gromadzi się ob-

serwacje obiektów poddanych oddziaływaniu, grupa ta określana jest mianem eksperymentalnej. Obserwacje niepoddane oddziaływaniu, dla których  $D_i = 0$ , trafiają do tzw. grupy kontrolnej<sup>5</sup>.

Strawiński [2014, s. 15] jako jeden z fundamentów analizy kontrfaktycznej podaje fakt, zgodnie z którym „przydział jednostki do grupy eksperymentalnej albo kontrolnej odbywa się w sposób niezależny od wyniku oddziaływania”. Oznacza to przyjęcie założenia, że w ramach badanego zjawiska nie występują czynniki, które mają wpływ jednocześnie i na sam fakt wystąpienia oddziaływania, i na wynik tegoż<sup>6</sup>. Określane jest to mianem randomizacji [Strawiński, 2014]. W odniesieniu do badanego zjawiska założenie takie pozwala wnioskować o wpływie na podstawie zgromadzonych i analizowanych danych, wyklucza się bowiem istnienie innych determinant kształtowania się wskaźnika rezultatu, które z jakiegoś powodu nie podlegają obserwacji.

W ujęciu ogólnym można powiedzieć, że za nieobserwowalną wartość zmiennej wynikowej ( $Y_{1i}$  bądź  $Y_{0i}$ , w zależności od tego, do której grupy zaklasyfikowany został  $i$ -ty obiekt) dla pojedynczego obiektu przyjmuje się następnie wartość tej zmiennej uzyskaną dla jednostki, która należy do drugiej grupy, ale jest najbardziej podobna do analizowanego obiektu ze względu na inne cechy. Opracowanie analizy opartej na łączeniu podobnych obserwacji w celu porównania uzyskanych przez nie wyników przypisuje się Royowi i Rubinowi [Strawiński, 2014].

W idealnym przypadku analityk dysponowałby wówczas parą identycznych obiektów, różniących się jedynie wartościami dwóch zmiennych:  $D_i$  oraz zmiennej wynikowej  $Y_i$ :

$$\begin{cases} \mathbf{X}_i = \mathbf{X}_j \\ D_i \neq D_j \\ Y_{1i} \neq Y_{0i} \end{cases} \quad \text{dla } i \neq j$$

gdzie:

$\mathbf{X}_i$  – wektor cech  $i$ -tego obiektu<sup>7</sup>.

<sup>5</sup> Nazewnictwo zostało przyjęte z nauk medycznych, w których często stosuje się proponowane w pracy ujęcie kontrfaktyczne, ze względu na niemożność zapewnienia odpowiedniej losowości w badaniach z przyczyn etycznych lub logistycznych [Perkins, 2000]. Bogatą listę pozycji bibliograficznych zawierają m.in. prace [Stürmer et al., 2006; Weitzen et al., 2004].

<sup>6</sup> Są to tzw. zmienne zakłócające (ang. *confounders*).

<sup>7</sup> W dotychczasowych rozważaniach ujmowaliśmy oddzielnie cechy badanego obiektu oraz cechy jego otoczenia. Można zatem przyjąć, że dla  $\mathbf{X}' = [X'_1, \dots, X'_{n'}]$  oraz  $\mathbf{X}'' = [X''_1, \dots, X''_{n''}]$  wektor cech  $\mathbf{X}$  przyjmie postać:  $\mathbf{X} = [X'_1, \dots, X'_{n'}, X''_1, \dots, X''_{n''}]$ .

Przy czym, zakładając w powyższym zapisie, że  $Y_{1i} \neq Y_{0i}$ , przyjmujemy jednocześnie założenie, zgodnie z którym wpływ badanego oddziaływania rzeczywiście istnieje.

Po znalezieniu par obiektów najbardziej do siebie podobnych, z których jeden pochodzi z grupy kontrolnej, a drugi eksperymentalnej, jedna z wartości zmiennej wynikowej pozyskiwana jest bezpośrednio ze zgromadzonych danych, zaś wartości tej zmiennej dla drugiego obiektu z pary przyjmowane są jako hipotetyczne (przybliżenie dla badanego obiektu w przypadku innego stanu).

Dla pary obiektów  $(i, j)$ , takich, że:  $i \neq j$  oraz  $\mathbf{X}_i = \mathbf{X}_j$ <sup>8</sup>:

$$\hat{Y}_{0i} = Y_{0j}|_{D_j=0}$$

$$\hat{Y}_{1i} = Y_{1j}|_{D_j=1}$$

W konsekwencji efekt oddziaływania (wpływ) na wynik osiągnięty przez indywidualny  $i$ -ty obiekt może być wyrażony jako:

$$W_i = \begin{cases} Y_{1i} - Y_{0j}|_{D_j=0} & \text{jeśli } D_i = 1 \\ Y_{1j}|_{D_j=1} - Y_{0i} & \text{wpp.} \end{cases}$$

Wspomniane wyżej połączenie obiektów w pary jest oczywiście przybliżeniem mającym służyć lepszej ilustracji toku postępowania w analizach kontryfaktycznych. W przypadku badań empirycznych często okazuje się, że rozwiązanie takie nie jest możliwe. Przyczyny takiego stanu rzeczy mogą leżeć w nierównej liczebności grupy eksperymentalnej i kontrolnej (część obiektów nie może mieć odpowiedników) lub w zróżnicowaniu obserwacji należących do obu grup.

W odniesieniu do pierwszego przypadku wydaje się, że można z dużą dozą pewności stwierdzić, iż będzie on występował często w praktyce, zwłaszcza przy ewaluacji programów finansowanych ze środków publicznych. Mają one bowiem ograniczony zasięg i obejmują jedynie część populacji. Znacznie liczniejsza będzie w takiej sytuacji grupa kontrolna. Jak jednak zauważa w oparciu o pracę Rubina [1973] Strawiński [2014], sytuacja taka ma również dobre strony, ponieważ zwiększa się precyzja oszacowania.

---

<sup>8</sup> Ponownie odwołujemy się tu do wskazanego już wyżej przypadku idealnego, w którym analityk jest w stanie połączyć w pary obiekty o jednakowych wartościach cech. W praktyce warunek  $\mathbf{X}_i = \mathbf{X}_j$  nie jest możliwy do spełnienia i zastępowany jest kryterium minimalnej odległości między wektorami wartości cech  $d(\mathbf{X}_i, \mathbf{X}_j)$ , gdzie  $d(\cdot)$ , oznacza odległość mierzoną zgodnie z pewną metryką:  $\min_j d(\mathbf{X}_i, \mathbf{X}_j)$  [por. Michalek, 2012a].

W drugim przypadku możliwe jest, że  $i$ -ty obiekt nie ma odpowiednika, ponieważ najbardziej zbliżona do niego obserwacja z drugiej grupy jest charakteryzowana przez znacząco odmienne wartości cech:

$$\min_j d(\mathbf{X}_i, \mathbf{X}_j) > d^{max}$$

gdzie:

$d^{max}$  – wartość odległości świadcząca o maksymalnym dopuszczalnym różnicowaniu cech  $i$ -tego oraz  $j$ -tego obiektu.

W takiej sytuacji obserwacje mogą zostać oczywiście przyjęte jako odpowiedniki i połączone w parę, jednak dokonanie na ich podstawie oszacowania hipotetycznego efektu oddziaływania będzie obarczone dużym błędem, wynikającym z braku wyraźnego podobieństwa pod względem innych cech. W takiej sytuacji, odrzucenie obserwacji może mieć lepszy wpływ na jakość uzyskanych wyników niż potencjalne kontynuowanie badania z jej uwzględnieniem.

Zatem ze względu na problemy związane z łączeniem obserwacji w pary jeden do jednego w praktyce często dopuszcza się, by danemu obiektowi został przyporządkowany więcej niż jeden odpowiednik, zaś odpowiedniki te podlegają odpowiedniemu przeważeniu (zakłada się często, że wagi sumują się do jedności). Wówczas zapisane wyżej formuły przyjmują postać podaną poniżej.

Dla zbioru obiektów  $(i, j_1, \dots, j_n)$  takich, że:  $\forall k, l (i \neq j_k \wedge j_l \neq j_k)$  oraz  $\forall k \mathbf{X}_i = \mathbf{X}_{j_k}$ <sup>9</sup>:

$$\hat{Y}_{0i} = \sum_{j=1}^{n_i} w_j \cdot Y_{0j} |_{D_j=0}$$

$$\hat{Y}_{1i} = \sum_{j=1}^{n_i} w_j \cdot Y_{1j} |_{D_j=1}$$

gdzie:

$w_j$  – waga  $j$ -tego obiektu,

$n_i$  – liczba odpowiedników  $i$ -tego obiektu.

---

<sup>9</sup> Ponownie odwołujemy się tu, do wskazanego już wyżej przypadku idealnego, w którym analityk jest w stanie połączyć w pary obiekty o jednakowych wartościach cech. W praktyce warunek  $\mathbf{X}_i = \mathbf{X}_j$  nie jest możliwy do spełnienia i zastępowany jest kryterium minimalnej odległości między zbiorami cech  $d(\mathbf{X}_i, \mathbf{X}_j)$ , gdzie  $d(\cdot)$ , oznacza odległość mierzoną zgodnie z pewną metryką.

Wpływ oddziaływania w przypadku wybranego obiektu może być natomiast modelowany jako:

$$W_i = \begin{cases} Y_{1i} - \sum_{j=1}^{n_i} w_j \cdot Y_{0j}|_{D_j=0} & \text{jeśli } D_1 = 1 \\ \sum_{j=1}^{n_i} w_j \cdot Y_{1j}|_{D_j=1} - Y_{0i} & \text{wpp.} \end{cases}$$

Z powyższymi rozważaniami wiąże się istotna trudność napotykana w ramach prowadzenia analiz kontrfaktycznych. Problemem jest mianowicie zapewnienie odpowiedniego zbilansowania cech obiektów zaklasyfikowanych do obu grup. Istnieją dwie przyczyny istotności bilansu.


Po pierwsze, jak można zauważyć, z samego rozwinięcia zasady *ceteris paribus* i ustalenia szeregu cech na stałym poziomie podczas analizy wartości wskaźnika rezultatu, dla poprawnej oceny wyniku oddziaływania na kształtowanie się zmiennej wynikowej należy zapewnić warunki, w których zmienna odpowiedzialna za poddanie oddziaływaniu będzie stanowiła jedyny czynnik istotnie różnicujący grupę kontrolną i eksperymentalną. Abstrahuje się w tym momencie od wartości przyjmowanych przez zmienną wynikową, na którą wpływ poddany jest analizie.

Druga przyczyna, mocno związana z pierwszą, odnosi się do konieczności łączenia obiektów w pary. Zbliżone rozkłady cech przyczyniają się do zwiększenia szansy na znalezienie odpowiedników dla obserwacji z grupy eksperymentalnej.

Przykładowe rozkłady cech w dwóch grupach obserwacji przedstawiono schematycznie na rysunku 18.



**Rysunek 18. Zbliżone rozkłady cech w grupach kontrolnej i eksperymentalnej**



*Źródło: opracowanie własne.*

Warto zwrócić uwagę na fakt niemożności zaobserwowania wszystkich cech danej jednostki, co pociąga za sobą brak pewności co do spełnienia kryterium *true causation*. W przypadku zmiennych niepoddanych obserwacji nie można wykluczyć bowiem, że stanowią one determinanty kształtowania się wartości wskaźnika rezultatu ( $Y$ ) i wartości zmiennych dychotomicznych opisujących wpływ ( $D$ ). Zatem nawet w przypadku, w którym w toku analizy zostanie uzyskany bilans cech opisujących obiekty z grup eksperymentalnej i kontrolnej, przy wnioskowaniu nie można uzyskać pewności dotyczącej wpływu oddziaływania na wartości zmiennej wynikowej. Z tego powodu przyjmuje się, że podobieństwo rozkładów cech powinno występować zarówno w przypadku cech obserwowalnych, jak i nieobserwowalnych [por. Heckman, Ichimura, Todd, 1997], przy czym w tym drugim przypadku jego istnienie jest niemożliwe do zweryfikowania empirycznego. Może jednak zostać zapewnione poprzez odpowiednią konstrukcję prowadzonego badania [Strawiński, 2014].

Jak można zauważyć na podstawie [Michalek, 2012a], zapewnienie odpowiedniego połączenia między parami obserwacji powoduje, że metoda analizy wpływu przestaje być uważana za metodę naiwną, w której zmiana wartości zmiennej wynikowej dla grupy eksperymentalnej zestawiana jest z analogiczną

zmianą wyznaczoną dla arbitralnie wybranych obiektów z grupy kontrolnej. Oszacowanie wpływu w ujęciu przeciętnym przyjmuje postać:

$$\bar{W}_{DID} = \left( \frac{1}{n_1} \sum_i Y_{i,t+1} |_{D_{i,t+1}=1} - \frac{1}{n_1} \sum_i Y_{i,t} |_{D_{i,t+1}=1} \right) - \left( \frac{1}{n_0} \sum_i Y_{i,t+1} |_{D_{i,t+1}=0} - \frac{1}{n_0} \sum_i Y_{i,t} |_{D_{i,t+1}=0} \right)$$

Podsumowując powyższe rozważania, można zauważyć, że kluczowym aspektem jest dobór obserwacji, na podstawie których dokonuje się porównania wartości zmiennej wynikowej. Należy uwzględnić nie tylko potencjalną zmienność w czasie uwarunkowań wpływających na kształtowanie się tej zmiennej, ale trzeba wziąć pod uwagę także cechy danego obiektu (i otoczenia, w którym funkcjonuje).

Odpowiednie łączenie obserwacji pozwala na ustalenie, że założenie stałości wybranych uwarunkowań jest spełnione, zaś jedyną determinantą mającą znaczący wpływ na kształtowanie się wartości wskaźników rezultatu jest zewnętrzne oddziaływanie będące przedmiotem oceny. Metoda łączenia danych, która zostanie wykorzystana w pracy zakłada, że „wszystkie jednostki poddane działaniu programu posiadają swój odpowiednik znajdujący się poza programem (...). Oznacza to, że (...) dla każdego uczestnika programu, istnieje z niezerowym prawdopodobieństwem co najmniej jedna jednostka znajdująca się poza programem o identycznych cechach” [Strawiński, 2009, s. 235]. Możliwe jest zatem wybranie właściwych odpowiedników dla obserwacji z grupy eksperymentalnej.

## 2.3. *Propensity Score Matching* jako metoda łączenia obserwacji

### 2.3.1. Łączenie na podstawie wielu i jednej cech

Wybór z grupy kontrolnej odpowiedników dla obiektów z grupy eksperymentalnej jest, jak zauważyliśmy wcześniej, kluczowym aspektem analizy wpływu.

Najprostszą metodą wyboru odpowiednich par obserwacji jest porównanie ich cech. Ponieważ, co oczywiste, mniejsza liczba kryteriów jest znacznie łatwiejsza do analizy, można sugerować dokonanie porównania na podstawie wartości pewnej funkcji  $f(\cdot): R^n \rightarrow R$ , gdzie  $n$  oznacza liczbę zmiennych charakte-

ryzujących dany obiekt. Intuicyjnym rozwiązaniem ze względu na łatwość interpretacji jest w takim wypadku wybór jako funkcji  $f(\cdot)$  określonej miary odległości.

Należy przy tym mieć jednak na uwadze fakt, że wybór metryki, w której mierzony będzie dystans między obserwacjami również ma istotne znaczenie. Metryki różnią się bowiem między sobą reakcją na niektóre wartości zmiennych. Warunkiem, który muszą spełniać wszystkie jest warunek przyjęcia zerowej wartości dla takich samych wartości zmiennych, tj.:

$$d(\mathbf{x}, \mathbf{x}) = 0$$

Powinny one również spełniać warunki symetrii (gwarantujący, że kolejność uwzględniania obiektów nie ma wpływu na końcowy wynik):

$$d(\mathbf{x}, \mathbf{y}) = d(\mathbf{y}, \mathbf{x})$$

oraz nierówności trójkąta:

$$d(\mathbf{x}, \mathbf{y}) \leq d(\mathbf{x}, \mathbf{z}) + d(\mathbf{y}, \mathbf{z}).$$

Często wykorzystywane są odległości mierzone w metryce euklidesowej, zgodnie ze wzorem<sup>10</sup>:

$$d(\mathbf{x}, \mathbf{y}) = \sqrt{\sum_{i=1}^n |x_i - y_i|^2}$$

metryce Manhattan (miejskiej):

$$d(\mathbf{x}, \mathbf{y}) = \sum_{i=1}^n |x_i - y_i|^2$$

oraz Czebyszewa:

$$d(\mathbf{x}, \mathbf{y}) = \max_i |x_i - y_i|.$$

Na ich przykładzie można zwrócić uwagę na wskazany wyżej problem odmiennego traktowania zmiennych. Metryka Czebyszewa uwzględnia w istocie jedynie te cechy (współrzędne)<sup>11</sup>, które w największym stopniu różnicują po-

---


<sup>10</sup> Ponieważ niektóre metryki występują w literaturze pod różnymi nazwami, wzory metryk i podstawowe nazwy w tym rozdziale przyjmujemy za pracą [Paśko, Setlak, 2015].

<sup>11</sup> Porównywane obiekty traktujemy w tym rozdziale jako punkty z przestrzeni  $n$ -wymiarowej, gdzie  $n$  oznacza liczbę cech (zmiennych) opisujących dany obiekt, obserwowal-

równywane obiekty. Wartości pozostałych zmiennych nie są brane pod uwagę, algorytm wyklucza je bowiem w momencie, w którym pojawia się różnica co do modułu większa od dotychczasowego maksimum. W przeciwieństwie do tego przypadku, posługując się odległościami mierzonymi według metryki euklidesowej lub Manhattan (miejskiej), bierze się pod uwagę wszystkie współrzędne, przy czym za większe różnice nakładana jest większa „kara”.

Przykładowe różnice w odległościach punktów w zależności od wybranej metryki przedstawiono na rysunku 19<sup>12</sup>.

**Rysunek 19. Porównanie odległości punktów  $X$  i  $Y_1$  oraz  $Y_2$  w wybranych metrykach**



Źródło: opracowanie własne.

Zróznicowane wartości odległości między punktami wyznaczone w różnych metrykach nabierają jeszcze większego znaczenia, kiedy weźmie się pod uwagę fakt, że jednym z celów cząstkowych przyjętych w opisywanym w pracy podejściu jest wybór odpowiedników dla obiektów z grupy eksperymentalnej, tj. takich jednostek z grupy kontrolnej, które są do nich w jak największym stopniu podobne. Oznacza to nie tylko, że należy wiązać ze sobą obiekty, między którymi odległość jest najmniejsza, ale sama wartość przyjmowana przez

nych i uwzględnionych w analizie. Ponieważ współrzędnymi punktów są w tym ujęciu wartości poszczególnych zmiennych, będziemy używać tych pojęć zamiennie.


<sup>12</sup> Przykłady metryk do porównania zaczerpnięto z pracy [Paśko, Setlak, 2015], w której wskazane zostały przykłady wykorzystania ich w badaniach.

funkcję  $d(\mathbf{x}, \mathbf{y})$  zaczyna odgrywać bardziej istotną rolę. Należy bowiem ustalić, co sygnalizowaliśmy już we wcześniejszych rozważaniach, od którego punktu podobieństwo obiektów nie może już być uznane za znaczące, przez co nie powinny one służyć do porównań.

Szulc [2012] oraz Michalek [2012b] opisują kilka podejść pozwalających na łączenie obiektów i zawężenie zakresu zróżnicowania między jednostkami połączonymi w odpowiednie pary lub większe zbiory<sup>13</sup>.

Zgodnie z cytowanymi pracami, można podczas łączenia wykorzystać metodę najbliższego sąsiada [Szulc, 2012; Michalek, 2012b] bez dodatkowych warunków. W parę łączy się wówczas dwa obiekty, dla których odległość jest najmniejsza, co ilustruje rysunek 20, na którym połączoną parę obiektów oznaczono obramowaniem. Jest to opisywany wyżej przypadek.

**Rysunek 20. Wiązanie w pary metodą najbliższego sąsiada w przypadku dwóch cech**



Źródło: opracowanie własne.

Alternatywnie, w przypadku, w którym prowadzący badanie zakłada łączenie typu jeden do wielu<sup>14</sup>, jako odpowiedniki dla obiektu z grupy eksperymentalnej dobierane są kolejne obiekty z grupy kontrolnej o najmniejszej odległości od analizowanej obserwacji. Schemat postępowania można zapisać zatem w poniższych krokach:

- 1) Ustalić rodzaj wiązania (typ oraz jeśli wiązanie nie ma charakteru 1-1 również liczbę dopuszczalnych odpowiedników);
- 2) Obliczyć odległości obiektu z grupy eksperymentalnej od kolejnych obiektów z grupy kontrolnej;

<sup>13</sup> W cytowanych pracach metody omawiane są w kontekście łączenia zmiennych na podstawie wartości przyjmowanych przez *propensity score*, wydaje się jednak, że te same podejścia mogłyby zostać zastosowane w hipotetycznym przypadku, w którym odpowiedniki wybiera się na podstawie odległości obliczonej dla wielu cech.

<sup>14</sup> Łączenie jeden do wielu (1-n) polega na wyznaczeniu dla jednej obserwacji z grupy eksperymentalnej wielu odpowiedników z grupy kontrolnej.

- 3) W przypadku wiązania 1-1 połączyć dany obiekt z grupy eksperymentalnej z obiektem z grupy kontrolnej, od którego odległość była minimalna;
- 4) W przypadku wiązania 1-n połączyć dany obiekt z grupy eksperymentalnej z obiektem z grupy kontrolnej, od którego odległość była minimalna;
- 5) Powtórzyć krok 4 aż do wyczerpania dopuszczalnej liczby odpowiedników.


Kolejne omawiane metody łączenia wiążą się już z nałożeniem dodatkowych warunków celem wyeliminowania sytuacji, w której powiązane zostaną potencjalne pary obiektów zbytnio się różniących wartościami cech. Są to odpowiednio: metoda promienia [Szulc, 2012] oraz suwmiarki (ang. *caliper*) [Szulc, 2012; Michalek, 2012b].

Warunek nakładany w metodzie promienia dotyczy maksymalnej dopuszczalnej odległości między obiektem z grupy eksperymentalnej i jego potencjalnymi odpowiednikami. Wartość przyjmowana przez to ograniczenie może zostać wyznaczona na podstawie wiedzy eksperckiej albo w oparciu o zgromadzone dane. Schemat postępowania w metodzie promienia można zilustrować w sposób analogiczny do przedstawionego powyżej w następujących czterech krokach:

- 1) Ustalić górne ograniczenie odległości między obiektem z grupy eksperymentalnej a jego odpowiednikami;
- 2) Obliczyć odległości obiektu z grupy eksperymentalnej od kolejnych obiektów z grupy kontrolnej;
- 3) Wykluczyć z grupy obiektów ze zbioru kontrolnego te jednostki, dla których obliczona odległość jest większa od przyjętego maksimum;
- 4) Połączyć dany obiekt z grupy eksperymentalnej z obiektami pozostałymi w grupie kontrolnej.

Graficzna ilustracja została przedstawiona na rysunku 21, na którym pokazano wybór obiektów z grupy kontrolnej dla wyróżnionego obiektu z grupy eksperymentalnej. W interpretacji graficznej dany obiekt z grupy kontrolnej staje się środkiem okręgu o pewnym ustalonym promieniu  $r$ , zaś wszystkie obserwacje z grupy eksperymentalnej znajdujące się od niego w odległości nie większej niż ustalone maksimum  $r^*$ , przyjmowane są jako odpowiedniki. Na rysunku oznaczono je czerwonym obramowaniem.


### Rysunek 21. Wiązanie w pary metodą promienia w przypadku dwóch cech



Źródło: opracowanie własne.

W takim wypadku dochodzić może, rzecz jasna, do sytuacji, w której te same obserwacje z grupy kontrolnej są przyjmowane za odpowiedniki dla więcej niż jednego obiektu z grupy eksperymentalnej. Na rysunku 22 takim przykładem jest punkt zaznaczony fioletowym obramowaniem.

### Rysunek 22. Wiązanie wiele do jednego na podstawie dwóch cech




Źródło: opracowanie własne.

Opisywana przez Szulca [2012] metoda suwmiarki (obcięcia) to swoiste połączenie obu powyższych podejść, bowiem poza górnym ograniczeniem dla odległości przyjmowany jest w takim wypadku również warunek ustalonej liczby odpowiedników dla obiektu z grupy eksperymentalnej. Etapy analizy mają zatem na celu:

- 1) Ustalić górne ograniczenie odległości między obiektem z grupy eksperymentalnej a jego odpowiednikami;
- 2) Ustalić liczbę dopuszczalnych odpowiedników;
- 3) Obliczyć odległości obiektu z grupy eksperymentalnej od kolejnych obiektów z grupy kontrolnej;
- 4) Wykluczyć z grupy obiektów ze zbioru kontrolnego te jednostki, dla których obliczona odległość jest większa od przyjętego maksimum;
- 5) Połączyć dany obiekt z grupy eksperymentalnej z obiektem pozostałym w grupie kontrolnej, od którego odległość była minimalna;
- 6) Powtórzyć krok 5 do wyczerpania liczby dopuszczalnych odpowiedników.

Na rysunku 23 zaprezentowano ilustrację graficzną dla tego przypadku. Mimo iż dla trzech obiektów z grupy kontrolnej odległość od obiektu z grupy eksperymentalnej nie przekracza ustalonego maksimum  $r^*$ , jako odpowiedniki zostaną wybrane dwa, dla których odległość ta jest najmniejsza. Podobnie jak poprzednio, oznaczono je czerwonym obramowaniem.


**Rysunek 23. Wiązanie w pary metodą suwmiarki w przypadku dwóch cech (dla dwóch dopuszczalnych odpowiedników)**



Źródło: opracowanie własne.


Łączenie na podstawie wielu cech rodzi komplikacje wynikające ze złożoności obliczeniowej. Dlatego też sugerowanym rozwiązaniem jest dobór par odpowiadających sobie obserwacji na podstawie jednej wybranej cechy, która zawierałaby w sobie informacje przekazywane przez wszystkie istotne uwzględnione w badaniu zmienne (rysunki 24-25).

**Rysunek 24. Wiązanie w pary metodą najbliższego sąsiada w przypadku jednej cechy**



Źródło: opracowanie własne.

**Rysunek 25. Wiązanie w pary metodą promienia w przypadku jednej cechy**



Źródło: opracowanie własne.

Idea ta wykorzystywana jest w podejściu łączenia według prawdopodobieństwa (ang. *propensity score matching*).



### 2.3.2. Łączenie na podstawie prawdopodobieństwa

U podstaw metody łączenia według prawdopodobieństwa, jak określa się niekiedy metodę *propensity score matching*, leży problem wymiarowości. W przypadku badań o charakterze nieeksperymentalnym, z jakim najczęściej mamy do czynienia, dla prawidłowego przeprowadzenia wnioskowania dotyczącego wpływu, konieczne jest przyjęcie pewnych założeń [Szulc, 2012; Michalek, 2012a], które łącznie określane są jako *strongly ignorable treatment assignment* [Rosenbaum, Rubin, 1983; za: Michalek, 2012a].

Po pierwsze zakłada się, że zgromadzony zbiór danych uwzględnia wszystkie cechy, które wywierają wpływ na zmienną wynikową ( $Y$ ). Nie wystąpi zatem sytuacja, w której jakaś determinanta wartości zmiennej wynikowej nie jest obserwowana.

W takim przypadku, jak pisze Szulc [2012, s. 316-317], „jednakowy rozkład zmiennych  $X$  w grupie poddanej zabiegowi i w grupie kontrolnej jest wtedy równoważny losowemu, ze względu na  $Y$ , doborowi obserwacji do obu grup”. Oznacza to, że dla danych wartości cech obiektów fakt poddania oddziaływaniu nie jest uzależniony od zmiennej wynikowej.

$$(Y_1, Y_0) \perp D | X$$

gdzie:

- $\perp$  – oznaczenie niezależności,
- $X$  – wektor cech  $i$ -tego obiektu<sup>15</sup>.

Założenie to, określane mianem założenia warunkowej niezależności<sup>16</sup>, traktowane jest jako dość kontrowersyjne [Michalek, 2012a], zaś Szulc [2012, s. 317] zauważa, że „(...) nawet w wersji słabej, jest założeniem dość mocnym i bardzo rzadko spełnianym przy posługiwaniu się rzeczywistymi danymi. Ponadto, nie istnieją testy pozwalające na jego formalną weryfikację”.

Drugim wymaganym założeniem jest założenie przenikania (ang. *overlap assumption*), zgodnie z którym wśród zgromadzonych danych nie ma przypadków wystąpienia takich wartości zmiennych, które przyjmowane są tylko w jednej z grup (tylko w grupie eksperymentalnej lub tylko w grupie kontrolnej).

---

<sup>15</sup> Podobnie jak wcześniej można ująć w tym miejscu łącznie cechy badanego obiektu oraz jego otoczenia.

<sup>16</sup> W cytowanych pracach występują pewne rozbieżności dotyczące nazewnictwa. Michalek [2012a] odnosi się do omawianego założenia, określając je terminem *unconfoundedness assumption*, zaś Szulc [2012] podaje anglojęzyczną nazwę *conditional independence assumption*. Inne wykorzystywane w literaturze nazwy przywołuje też Strawiński [2014].

Próba powinna być zatem skonstruowana w taki sposób, by dla każdego obiektu można było znaleźć właściwy odpowiednik. Formalnie warunek ten zapisuje się jako:

$$P(D = 1|X) \in (0,1)$$

gdzie:

$P(\cdot)$  – prawdopodobieństwo.

Oznacza to, że nie występuje zmienna, dla której  $P(D = 1|X^*) = 0$  lub  $P(D = 1|X^*) = 1$ , czyli nie istnieje idealny predyktor poddania oddziaływaniu<sup>17</sup>.

Jak wskazują Stürmer i in. [2006, s. 438], „zastosowanie wielowymiarowej analizy zmiennych zakłócających (...) można prześledzić wstecz do (pracy – przyp. aut.) Miettinena z 1976 r. (...). W 1983 r. Rosenbaum i Rubin wprowadzili ideę propensity score (...)”. Wprowadzili oni pojęcie tzw. wektorów bilansujących, stanowiących odpowiedź na jeden z problemów napotykanych przy prowadzeniu analizy kontrfaktycznej. Za Strawińskim [2014, s. 29-30] można bowiem zauważyć, że: „w randomizowanych eksperymentach wartość oddziaływania w grupach eksperymentalnej i kontrolnej może być porównywana bezpośrednio, ponieważ jednostki w obu grupach są podobne. W eksperymentach, które nie są randomizowane, bezpośrednie porównywanie obu grup może prowadzić do nieprawdziwych wniosków, gdyż jednostki w obu grupach mogą się różnić w sposób systematyczny”.

Wektor bilansujący zdefiniować można jako:

$$b(X^*)$$

gdzie:

$X^* \subset X$  – podzbiór cech obiektów będących zmiennymi warunkującymi (ang. *conditioning variables*)<sup>18</sup>.

Stanowi on zatem funkcję cech badanych obiektów. Dodatkowo, zakłada się, że warunkowy rozkład  $X^*$  przy danym  $b(X^*)$  jest niezależny od faktu poddania bądź nie oddziaływaniu:

$$X^* \perp D|_{b(X^*)}$$

---

<sup>17</sup> Lub, ze względu na charakter zmiennych  $D$ , braku poddania oddziaływaniu.

<sup>18</sup> Jako wartości zmiennych warunkujących dla  $i$ -tego obiektu przyjmuje się wartości wybranych cech tego obiektu w okresie, w którym nie wystąpiło jeszcze badane oddziaływanie.

Jest on zatem jednakowy dla obu badanych grup – kontrolnej i eksperymentalnej i pozwala osiągnąć porównywalność obiektów zaklasyfikowanych do tych grup.

Szczególnym przypadkiem wektora bilansującego jest tzw. *propensity score*, definiowany jako prawdopodobieństwo poddania wybranego obiektu badanemu oddziaływaniu, wyznaczone z uwzględnieniem wartości obserwowalnych cech  $\mathbf{X}_i^*$ :

$$b_{PS}(\mathbf{X}_i^*) = P(D = 1 | \mathbf{X}_i^* = \mathbf{x}_i^*)$$

gdzie:

- $b_{PS}(\cdot)$  – wektor bilansujący w postaci *propensity score*,
- $\mathbf{X}_i^*$  – macierz zmiennych warunkujących  $i$ -tego obiektu.

Dla zmiennych losowych  $Y$  i  $\mathbf{X}^*$  oraz dychotomicznej zmiennej  $D$ , opisującej fakt poddania oddziaływaniu, wartość *propensity score* można zapisać jako [Michalek, 2012a]:

$$b_{PS}(\mathbf{X}^*) = P(D = 1 | \mathbf{X}^*) = E(D | \mathbf{X}^*)$$


Ponadto, jeśli fakt poddania oddziaływaniu jest niezależny od  $\mathbf{X}^*$ , jest również niezależny od *propensity score* [Michalek, 2012a]. Jak zauważa cytowany autor, wykorzystywanie w badaniach jedynie wartości *propensity score*, bez posuwania się do bardziej wyrafinowanych analiz uwzględniających bezpośrednio zmienne warunkujące jest w zupełności wystarczające i pozwala na uwzględnienie wszystkich potrzebnych informacji [Michalek, 2012a].

Kolejne kroki analizy efektu oddziaływania przy użyciu metody *propensity score matching* zaprezentowano schematycznie na rysunku 26<sup>19</sup>. Jak można zauważyć, ponieważ wartość *propensity score* może być interpretowana jako prawdopodobieństwo poddania obiektu oddziaływaniu w zależności od jego cech [Stürmer et al., 2006], pojawia się pewne pole do rozszerzenia analizy o dodatkowe wnioski na pośrednich etapach.

---

<sup>19</sup> Bardziej rozbudowany schemat kolejnych etapów analizy przy wykorzystaniu metody *propensity score matching* zaprezentowany jest w opracowaniu [Investment Support under Rural Development Policy, 2014].

**Rysunek 26. Kolejne etapy analizy efektu oddziaływania metodą *propensity score matching***



Źródło: opracowanie własne na podstawie [Pan, Bai, 2015].

### 2.3.3. Pomiar efektów oddziaływania

W ostatnim etapie przeprowadzona zostanie analiza efektu oddziaływania (wpływu dopłat do inwestycji na kształtowanie się wartości dodanej w wybranych grupach gospodarstw rolnych). Prezentowane podejście umożliwia ocenę efektu oddziaływania w różnych aspektach. Odniesiemy się do trzech z nich, mając jednak świadomość, że nie wyczerpujemy tym samym dostępnych możliwości [por. Guo, Fraser, 2015].

Pierwszy aspekt dotyczy wpływu oddziaływania na obiekty, które zostały mu poddane. Jest on intuicyjnie zgodny z ideą oceny wpływu. Efekt ten mierzony jest za pomocą wartości przeciętnego wyniku oddziaływania w odniesieniu do jednostek poddanych temu oddziaływaniu (ang. *average treatment effect on treated*,  $ATT^{20}$ ). Jako wielkość bazową dla porównania zmiany wartości zmiennej wynikowej w grupie eksperymentalnej przyjmuje się wartości tej zmiennej

<sup>20</sup> Należy zaznaczyć, że w literaturze przedmiotu występują różne akronimy dla omawianych efektów. Przykładowo, Guo i Fraser [2015] określają przeciętny wynik oddziaływania w odniesieniu do jednostek poddanych oddziaływaniu akronimem *TT*, zaś przeciętny wynik oddziaływania na jednostki niepoddane oddziaływaniu – akronimem *TUT*.

w grupie kontrolnej. Utrzymując wcześniejsze oznaczenie  $W$  jako efektu oddziaływania,  $ATT$  zdefiniować można jako<sup>21</sup>:

$$W_{ATT} = E(Y_{1i} - Y_{0i} | D_i = 1) = E(Y_{1i} | D_i = 1) - E(Y_{0i} | D_i = 1)$$

$W_{ATT}$  stanowi różnicę dwóch wartości oczekiwanych. Pierwsza z nich odnosi się do wartości zmiennej wynikowej w przypadku objęcia jednostek oddziaływaniem, pod warunkiem że dana jednostka była poddana oddziaływaniu. Jest to wielkość obserwowalna. Druga wartość oczekiwana odnosi się do wartości zmiennej wynikowej w przypadku, w którym oddziaływanie nie wystąpiło, pod warunkiem, że obiekt został poddany oddziaływaniu. Ta wartość z kolei jest hipotetyczna i nieobserwowalna, musi zostać przybliżona na podstawie zgromadzonych danych.

W odniesieniu do rozważanego w niniejszej pracy zagadnienia wpływu instrumentów polityki rolnej (dopłat do inwestycji) na kształtowanie się wartości zmiennej wynikowej (GVA/AWU), wartość miernika  $W_{ATT}$  można traktować jako przeciętną zmianę wartości dodanej w grupie beneficjentów programu wsparcia, wynikającą z uzyskiwania tego wsparcia.

Alternatywnie, przedmiotem badania może być również wpływ oddziaływania na wszystkie analizowane jednostki, bez względu na to, czy były one jego obiektem, czy nie. Efekt taki mierzony jest za pomocą wskaźnika określanego jako przeciętny wynik oddziaływania na wszystkie badane jednostki (ang. *average treatment effect, ATE*):

$$W_{ATE} = [E(Y_{1i}) - E(Y_{0i}) | D_i = 1] + [E(Y_{1i}) - E(Y_{0i}) | D_i = 0]$$

Obliczając tę wartość, bierze się pod uwagę różnicę przeciętnych wartości zmiennej wynikowej dla wystąpienia oddziaływania i jego braku pod warunkami, że oddziaływanie ( $D_i = 1$ ) wystąpiło oraz pod warunkiem braku oddziaływania ( $D_i = 0$ ). Również tutaj, podobnie jak w powyższym przypadku występują hipotetyczne wartości zmiennej wynikowej, które należy oszacować na podstawie zgromadzonych danych.

Wartość  $W_{ATE}$  interpretowana jest jako wynik, jaki zostałyby osiągnięty, gdyby obiekty były losowo obejmowane wpływem oddziaływania. Jak jednak można zauważyć, miernik ten nie jest zwykle istotny z punktu widzenia oceny wprowadzanego instrumentu polityki, bowiem w takich badaniach przedmiotem zainteresowania staje się oddziaływanie na beneficjentów [Caliendo, 2006], tj.  $ATT$ .

---

<sup>21</sup> Jak podaje Strawiński [2014], jest to nieobciążony estymator właściwego miernika  $ATT$  w przypadku, w którym nie występuje zjawisko samoselekcji.

Oba powyższe mierniki są najczęściej używane do oceny wpływu. Jak zauważa Michalek [2012b], wykorzystując podejście kontrfaktyczne można również wyznaczyć przeciętny efekt, jaki wywiera oddziaływanie na obiekty, które nie zostały mu poddane. Jest to tzw. przeciętny wynik oddziaływania na jednostki niepoddane oddziaływaniu (ang. *average treatment effect on the untreated, ATU*):

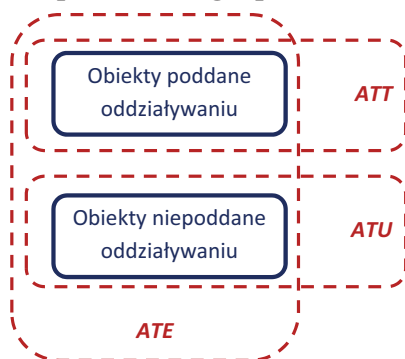
$$W_{ATU} = E(Y_{1i} - Y_{0i} | D_i = 0) = E(Y_{1i} | D_i = 0) - E(Y_{0i} | D_i = 0)$$

Miernik ten ma konstrukcję zbliżoną do *ATT*, różnica dotyczy postaci warunku. W przypadku przeciętnego wyniku oddziaływania na jednostki niepoddane oddziaływaniu warunkiem jest, co oczywiste, brak wystąpienia oddziaływania ( $D_i = 0$ ). Ponownie, wzór uwzględnia wartości hipotetyczne, takie jak wartości zmiennej wynikowej w przypadku wystąpienia oddziaływania warunkowane jego brakiem.

Jak zauważa Caliendo [2006], wartości miernika mogą nieść interesującą informację o tym, jaki wpływ wywarłoby rozszerzenie grupy objętej oddziaływaniem na jednostki, których dotychczas ono nie objęło.

Zastosowanie mierników do analizy efektów polityki względem wybranych obiektów można przedstawić schematycznie jak na rysunku 27.

**Rysunek 27. Zastosowanie mierników do analizy efektu oddziaływania dla odpowiednich grup obiektów**



Źródło: opracowanie własne.

Przedmiotem naszej uwagi w niniejszej pracy będzie pierwszy z efektów, *ATT*, ilustrujący wpływ programu na jego beneficjentów.

## 2.4. Specyfikacja wektora *propensity score* z wykorzystaniem modeli logitowych i probitowych – wprowadzenie teoretyczne

Kwestią wymagającą rozstrzygnięcia, stosując metodę łączenia według prawdopodobieństwa, jest dobór charakterystyk do wektora *propensity score*. Jak zauważa Strawiński [2014, s. 52], „na podstawie prac teoretycznych wiadomo, że powinny się w nim znaleźć wszystkie charakterystyki posiadające wpływ na prawdopodobieństwo znalezienia się jednostki w grupie eksperymentalnej”. Holmes [2014] wskazuje na cztery powszechnie stosowane metody estymacji wartości wektora prawdopodobieństwa oddziaływania, tj. regresję logistyczną, analizę dyskryminacyjną, regresję ze sztuczną zmienną zależną oraz regresję probitową.

W niniejszej pracy wyboru charakterystyk dokonano na podstawie wyników estymacji modeli logitowych, dlatego też poniżej przedstawiono niezbędne wprowadzenie teoretyczne do tej klasy modeli. Podano ich zapis matematyczny, metodę estymacji, sposób oceny ich jakości oraz interpretacji uzyskanych wyników.

Model logitowy (lub probitowy) stanowi standardowe podejście do analizy dwumianowej zmiennej objaśnianej<sup>22</sup>. Rozważany jest model regresji:

$$y_i^* = \beta_0 + \sum_{j=1}^k \beta_j x_{ij} + u_i$$

gdzie:

$y_i^*$  – nieobserwowalna (ukryta, ang. *latent variable*) zmienna objaśniana, obserwuje się jedynie binarną zmienną  $y_i$ <sup>23</sup>, przyjmującą wartość 1 (jeśli  $y_i^* > 0$ ) lub 0 (w przeciwnym przypadku), z prawdopodobieństwem:

$$p_i = P(y_i) = p_i^{y_i} (1 - p_i)^{1-y_i}$$

$\beta_{0...k}$  – parametry strukturalne modelu,

---

<sup>22</sup> Do analizy zmiennej binarnej wykorzystuje się również m.in. liniowy model prawdopodobieństwa (LMP). Jednakże ze względu na przyjęcie założenia, iż zmienna objaśniana jest zmienną ukrytą, adekwatnie do przeprowadzonej w pracy analizy empirycznej, omówiono jedynie model logitowy i probitowy.

<sup>23</sup> Vittinghoff i in. [2005] podają założenia, jakie w modelu logitowym powinna spełniać zmienna wynikowa  $y_i$ :

1.  $y_i$  pochodzi z rozkładu Bernoulliego (dwumianowego),
2.  $E[y^*|x] = P(x) = \beta_0 + \sum_{j=1}^k \beta_j x_{ij}$ ,
3. Wartości zmiennej zależnej są statystycznie niezależne.

$x_{ij}$  – wartość  $j$ -tej zmiennej objaśniającej dla  $i$ -tej obserwacji,  
 $u_i$  – składnik losowy modelu (reszta) dla  $i$ -tej obserwacji.

Różnica między modelem logitowym a probitowym polega na specyfikacji rozkładu składnika losowego w równaniu modelu. Jeżeli funkcja wiążąca jest dystrybuantą rozkładu normalnego, model regresji jest modelem probitowym, natomiast dla rozkładu logistycznego – modelem logitowym.

**Tabela 1. Postać modelu logitowego i modelu probitowego**

Model	Prawdopodobieństwo
logitowy	$p_i = \frac{e^{\beta_0 + \sum_{j=1}^k \beta_j x_{ij}}}{1 + e^{\beta_0 + \sum_{j=1}^k \beta_j x_{ij}}}$
probitowy	$p_i = \int_{-\infty}^{\beta_0 + \sum_{j=1}^k \beta_j x_{ij}} \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} dt$

Źródło: opracowanie własne na podstawie [Maddala, 2008].

W przypadku modelu probitowego nie można przedstawić zależności między prawdopodobieństwem a kombinacją zmiennych objaśniających w postaci „wygodnego” wyrażenia analitycznego (patrz tabela 1). Tymczasem dla modelu logitowego można zapisać funkcję odwrotną do dystrybuanty  $F$  jako liniową funkcję zmiennych objaśniających:

$$F^{-1}(p_i) = \ln \frac{p_i}{1 - p_i} = \beta_0 + \sum_{j=1}^k \beta_j x_{ij}$$

Modelowaniu nie podlega więc prawdopodobieństwo, ale szansa (ang. *odds*), tj. iloraz prawdopodobieństw występowania pewnego zdarzenia oraz jego braku<sup>24</sup>. Wartość funkcji odwrotnej do  $F$  w modelu logitowym nazywa się logitem, zaś w modelu probitowym – analogicznie – probitem. Na przykładzie modelu logitowego można zauważyć, że jeżeli prawdopodobieństwa wystąpienia zdarzenia i jego braku są jednakowe ( $p_i = 0,5$ ), to logit równa się zero. Dla prawdopo-


<sup>24</sup> Iloraz szans mierzy prawdopodobieństwo, że  $y_i = 1$  w stosunku do prawdopodobieństwa, że  $y_i = 0$ . „Prawdopodobieństwo” jest tu rozumiane jako „szansa”, stąd mówi się o logarytmie ilorazu szans, a nie logarytmie ilorazu prawdopodobieństw. Należy jednak podkreślić, że „na ogół szansa (...) oznacza od razu iloraz prawdopodobieństw. Jeśli prawdopodobieństwo sukcesu równa się 0,8, to „szansa na sukces” wynosi 4 do 1, czyli jest właśnie ilorazem prawdopodobieństw” [Gruszczyński, Kuszewski, Podgórska, 2009, s. 167].



bieństwa zajścia zdarzenia mniejszego niż 0,5 logit jest ujemny, natomiast w przeciwnym przypadku – dodatni.

Dystrybuanty rozkładów logistycznego i normalnego przedstawiono, w uproszczeniu, na rysunku 28. Mają one kształt „krzywej typu S”. Są do siebie bardzo podobne, z wyjątkiem wartości początkowych i końcowych, czyli tzw. ogonów. Stąd, jak zauważa Maddala [2008], model logitowy i probitowy dają zwykle zbliżone wyniki<sup>25</sup>.

**Rysunek 28. Model logitowy i model probitowy**



Źródło: opracowanie własne.

Należy jednak podkreślić, że ze względu na różne wariancje w rozkładzie logistycznym ( $var(u_i) = \pi^2/3$ ) i normalnym ( $var(u_i) = 1$ )<sup>26</sup>, oszacowania parametrów w modelach logitowym i probitowym nie są bezpośrednio porównywalne. Maddala [2008, s. 373] wskazuje, iż w tym celu „otrzymane dla modelu logitowego oceny  $\beta_j$  powinny być pomnożone przez  $\sqrt{3}/\pi$ ”, chociaż według Amemiya [1981] lepszym przybliżeniem dla rozkładów logistycznego i standardowego normalnego byłoby pomnożenie ocen parametrów modelu logitowego przez 0,625.

Ze względu na nieliniową postać funkcyjną, modele logitowe i probitowe szacuje się Metodą Największej Wiarygodności (MNW), zaproponowaną po raz pierwszy przez Fishera [1922]. Jak wykazał Pratt [1981], funkcja wiarygodności jest wklęsła i nie posiada wielokrotnych maksimumów, dlatego też poszukiwanie największej wartości funkcji można rozpocząć dla dowolnych wartości początkowych jej parametrów [Maddala, 2008]. Estymując parametry strukturalne

<sup>25</sup> Rozbieżności w otrzymanych wynikach dla modelu logitowego i modelu probitowego mogą wynikać z „dysponowania dużymi próbkami (zapewniającymi wystarczająco dużo obserwacji dla „ogonów”)” [Maddala, 2008, s. 373].

<sup>26</sup> Normalizując  $\sigma$  na poziomie 1.

modelu, wykorzystuje się funkcję wiarygodności, zdefiniowaną jako [Zhang, Singer, 1999]:

$$L(\beta, y) = \prod_{y_i=1} p_i \prod_{y_i=0} (1 - p_i) = \prod_{i=1}^n p_i^{y_i} (1 - p_i)^{1-y_i}$$

Do znalezienia wektora oszacowań parametrów strukturalnych maksymalizujących funkcję wiarygodności, pochodne cząstkowe  $L(\beta, y)$  po  $\beta_j$  muszą być równe zeru, a więc musi zostać spełniony warunek [Harrel, 2001]:

$$\begin{aligned} \frac{\partial L(\beta, y)}{\partial \beta_j} &= 0 \\ - \sum_{i=1}^n \frac{1}{1 + e^{\beta_0 + \sum_{j=1}^k \beta_j x_{ij}}} e^{\beta_0 + \sum_{j=1}^k \beta_j x_{ij}} x_{ij} + \sum_{i=1}^n y_i x_{ij} &= 0 \\ \sum_{i=1}^n (y_i - p(x_i, \beta_0, \beta_1, \dots, \beta_k)) x_{ij} &= 0 \end{aligned}$$

W wyniku maksymalizacji funkcji  $L(\beta, y)$  otrzymuje się oszacowania  $\hat{\beta}$  dla parametrów strukturalnych modelu. Zarówno dla modelu logitowego, jak i probitowego, estymator otrzymany Metodą Największej Wiarygodności ma asymptotyczny rozkład normalny. Testy istotności dla pojedynczego parametru opierają się zatem na statystyce o rozkładzie normalnym z wartością oczekiwaną równą 0 i wariancją równą 1. Istotność całego modelu bada się natomiast za pomocą testu ilorazu wiarygodności. Statystyka testu ma postać [Gruszczyński, 2012]:

$$LR = 2(\ln L_{UR} - \ln L_R)$$

gdzie:

$$LR \sim \chi_k^2,$$

$L_{UR}$  – wartość funkcji wiarygodności dla pełnego modelu,

$L_R$  – wartość funkcji wiarygodności dla modelu tylko z wyrazem wolnym.

Weryfikowana jest hipoteza zerowa:

$$H_0: \beta_1 = \beta_2 = \dots = \beta_k = 0$$

wobec hipotezy alternatywnej  $H_1: \sim H_0$ , w której przyjmuje się, że wszystkie parametry przy zmiennych są istotnie różne od 0, a więc są istotne statystycznie.

Efekty wpływu (jednostkowych) zmian wartości zmiennych objaśniających na prawdopodobieństwo zajścia zdarzenia wyznacza się według formuły [Maddala, 2008]:

$$\frac{\partial p_i}{\partial x_{ij}} = \begin{cases} \beta_j p_i (1 - p_i) & \text{dla modelu logitowego} \\ \beta_j \varphi \left( \beta_0 + \sum_{j=1}^k \beta_j x_{ij} \right) & \text{dla modelu probitowego} \end{cases}$$

gdzie:  $\varphi(\cdot)$  – funkcja gęstości standardowego rozkładu normalnego.

Powyższe równania można przekształcić do postaci:

$$\frac{\partial p_i}{\partial x_{ij}} = \begin{cases} \beta_j \frac{e^{\beta_0 + \sum_{j=1}^k \beta_j x_{ij}}}{\left[ 1 + e^{\beta_0 + \sum_{j=1}^k \beta_j x_{ij}} \right]^2} & \text{dla modelu logitowego} \\ \beta_j \frac{1}{\sqrt{2\pi}} e^{-\frac{(\beta_0 + \sum_{j=1}^k \beta_j x_{ij})^2}{2}} & \text{dla modelu probitowego} \end{cases}$$

Efekt krańcowej zmiany  $j$ -tej zmiennej objaśniającej nie jest stały, a zależy od wartości wszystkich zmiennych objaśniających [Gruszczyński, Kuszewski, Podgórska, 2009]. Jednakże, podobnie jak w modelach liniowych, znak oszacowania parametru stojącego przy  $j$ -tej zmiennej określa kierunek jej wpływu na zmienną objaśnianą, tj.:

- dla  $\alpha_j > 0$  wzrost (spadek)  $j$ -tej zmiennej objaśniającej wiąże się ze wzrostem (spadkiem) szans zajścia zdarzenia  $y = 1$ ,
- dla  $\alpha_j < 0$  wzrost (spadek)  $j$ -tej zmiennej objaśniającej wiąże się ze spadkiem (wzrostem) szans zajścia zdarzenia  $y = 1$ .

Do interpretacji wyników oszacowań skonstruowanego modelu logitowego można również wykorzystać iloraz szans (ang. *odds ratio*) postaci [Gruszczyński, 2012]:

$$\frac{\Omega(\mathbf{x}^j, x_j + 1)}{\Omega(\mathbf{x}^j, x_j)} = e^{\beta_j}$$

gdzie:

$\Omega(\cdot)$  – logit,

$\mathbf{x}^j$  – wektor zmiennych objaśniających bez zmiennej  $x_j$ .

Wartość ilorazu szans większa (mniejsza) od 1 oznacza, że wraz ze wzrostem zmiennej objaśnianej o jednostkę prawdopodobieństwo zajścia modelowanego zdarzenia rośnie (spada) o  $|e^{\beta_j} - 1| \cdot 100\%$ <sup>27</sup>. Należy pamiętać, że interpretacji podlegać mogą tylko te zmienne, dla których przedział ufności dla ilorazu szans nie zawiera wartości 1 [Kleinbaum, Klein, 2010].

Jakość dopasowania modelu logitowego lub probitowego do danych można ocenić za pomocą mierników typu  $R^2$  (pseudo- $R^2$ ) lub tablicy trafności klasyfikacji i krzywej ROC [Gruszczyński, 2012]. Pierwszy miernik stanowi analogiczną miarę do wskaźnika determinacji  $R^2$  dla modeli liniowych – jego wartości mieszczą się w przedziale [0,1], przy czym wyższa wartość oznacza lepsze dopasowanie modelu. Przykładowymi miarami pseudo- $R^2$  są [Gruszczyński, 2012]:

1. pseudo- $R^2$  McFaddena [1974]:

$$R_M^2 = 1 - \frac{\ln L_{fit}}{\ln L_0}$$

gdzie:

$L_{fit}$  – funkcja wiarygodności dla modelu pełnego,

$L_0$  – funkcja wiarygodności dla modelu zredukowanego do wyrazu wolnego.

2. pseudo- $R^2$  McKelveya i Zavoina [1975]:

$$R_{MZ}^2 = \frac{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i^* - \bar{y}^*)^2}{\frac{\pi^2}{3} + \frac{1}{n} \sum_{i=1}^n (\hat{y}_i^* - \bar{y}^*)^2}$$

gdzie:

$$\hat{y}_i^* = \hat{\beta}_0 + \sum_{j=1}^k \hat{\beta}_j x_{ij}$$

3. pseudo- $R^2$  największej wiarygodności [Maddala, 1983]<sup>28</sup>:

<sup>27</sup> Jest to interpretacja w przypadku zmiennych ilościowych. Dla zmiennych jakościowych interpretuje się wartość ilorazu szans dla danej kategorii zmiennej w odniesieniu do ustalonej kategorii referencyjnej tej zmiennej.

<sup>28</sup> Miara ta nie osiąga wartości 1.

$$R_{NM}^2 = 1 - \left( \frac{L_0}{L_{fit}} \right)^{\frac{2}{N}}$$

gdzie:

$N$  – wielkość próby.

4. pseudo- $R^2$  Cragga i Uhlera [1970]:

$$R_{CU}^2 = \frac{R_{NM}^2}{\max R_{NM}^2}$$

gdzie:

$$\max R_{NM}^2 = 1 - (L_0)^{\frac{2}{N}}$$

Gruszczyński [2012] podkreśla, że wskazane miary nie powinny być jednak interpretowane jak wskaźnik  $R^2$  dla modelu liniowego. Należy je interpretować zgodnie z ich definicjami, a więc w kontekście funkcji użyteczności.

Drugim zwyczajowo stosowanym sposobem jest sprawdzenie jakości dopasowania modelu, odwołując się do jego trafności prognozowania. Prognoza odnosi się do oszacowanego prawdopodobieństwa  $\hat{p}_i$ . Zazwyczaj, określając zdolność predykcyjną modelu, przyjmuje się próg odcięcia na poziomie 0,5. Oznacza to, że jeżeli  $\hat{p}_i \geq 0,5$ , to prognoza  $\hat{y}_i = 1$ , natomiast  $\hat{p}_i < 0,5$ , to  $\hat{y}_i = 0$ . Na tej podstawie generowana jest tablica trafności klasyfikacji, zestawiająca wartości prognozowane z rzeczywistymi (tabela 2).

**Tabela 2. Tablica trafności klasyfikacji**

Wartości rzeczywiste	Wartości prognozowane	
	$\hat{y} = 1$	$\hat{y} = 0$
$y = 1$	TP	FN
$y = 0$	FP	TN

Źródło: opracowanie własne.

Na podstawie tak skonstruowanej tablicy można obliczyć współczynnik trafności klasyfikacji<sup>29</sup> (ang. *accuracy rate*), tzw. skuteczność reguły decyzyjnej, zgodnie z formułą<sup>30</sup>:

<sup>29</sup> Miara ta stanowi pochodną współczynnika  $R^2$ , ponieważ „procent trafnych prognoz to tak zwany zliczeniowy R-kwadrat pomnożony przez 100” [Gruszczyński, 2012, s. 91].

<sup>30</sup> Przeglądu wszystkich miar jakości reguł predykcyjnych dokonuje Harańczyk [2010].

$$AR = \frac{TP + TN}{TP + FN + FP + TN}$$

gdzie:

TP – liczba obserwacji, dla których zaobserwowano i przewidziano stan wyróżniony<sup>31</sup>,

TN – liczba obserwacji, dla których nie zaobserwowano ani nie przewidziano stanu wyróżnionego,

FN – liczba obserwacji, dla których zaobserwowano, ale nie przewidziano stanu wyróżnionego,

FP – liczba obserwacji, dla których nie zaobserwowano, ale przewidziano stan wyróżniony.

Jak wynika z tabeli 2, konstruując model prognozujący można popełnić dwa rodzaje błędów. Pierwszy polega na błędnej klasyfikacji „jedynek” ( $\hat{y}_i = 0$ , podczas gdy  $y_i = 1$ ), drugi natomiast na błędnej klasyfikacji „zer” ( $\hat{y}_i = 1$ , podczas gdy  $y_i = 0$ ).

Minimalizację tych błędów prezentuje krzywa ROC (ang. *Receiver Operating Characteristic*, patrz rysunek 29), pokazująca zależność między tzw. czułością (ang. *sensitivity*,  $Sn$ )<sup>32</sup> a swoistością (lub inaczej: specyficznością, ang. *specificity*,  $Sp$ )<sup>33</sup>. Wykres powstaje poprzez zaznaczenie na układzie współrzędnych czułości i specyficzności modelu dla każdego możliwego progu odcięcia. Jeżeli krzywa ROC dla danego modelu znajduje się powyżej linii  $y = x$ , charakteryzującej losowo klasyfikujący model, jakość modelu jest zadowalająca. Punkt na krzywej ROC położony najbliżej punktu (0,1) wskazuje próg odcięcia, dla którego liczba błędnie sklasyfikowanych obserwacji będzie minimalna [Harańczyk, 2010].

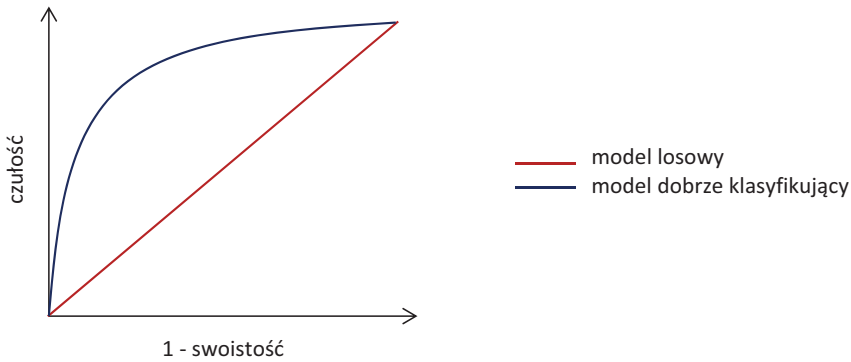
---

<sup>31</sup> Przez stan wyróżniony rozumie się sytuację, kiedy  $y = 1$ .

<sup>32</sup>  $Sn = \frac{TP}{TP+FN}$

<sup>33</sup>  $Sp = \frac{TN}{TN+FP}$

**Rysunek 29. Krzywa ROC**



Źródło: opracowanie własne.

Krzywa ROC umożliwia porównanie modeli predykcyjnych między sobą. Zwykle w tym celu wylicza się AUC (ang. *area under curve*), tj. pole pod krzywą ROC. Im większa wartość wskaźnika AUC, tym model trafniej klasyfikuje obserwacje. Dla modelu losowego AUC wynosi 0,5, natomiast dla modelu idealnie prognozującego AUC równe jest 1.

### 3. Kwantyfikacja efektu dopłat do inwestycji na wydajność czynnika pracy

#### 3.1. Problem warunków koniecznych

Szacując efekt oddziaływania metodą łączenia według prawdopodobieństwa, podstawowym zadaniem badacza jest poprawna konstrukcja sztucznej grupy odniesienia. Jak wskazuje Rubin [1973], zapewnia to „zredukowanie obciążenia i zwiększenie precyzji uzyskanych wyników” [za: Strawiński, 2009, s. 234]. Stąd, w związku z pomiarem efektu oddziaływania dopłat do inwestycji na wydajność czynnika pracy w polskich gospodarstwach rolnych w latach 2008-2013, przedstawiono w zarysie warunki konieczne do uzyskania wsparcia w analizowanym okresie.

W Programie Rozwoju Obszarów Wiejskich na lata 2007-2013 (PROW 2007-2013) wsparcie dla inwestycji w polskich gospodarstwach rolnych udzielane było w ramach dwóch działań osi 1 pt. „Poprawa konkurencyjności sektora rolnego”. Pierwszym działaniem było „Ułatwienie startu młodym rolnikom” (działanie 112), drugim natomiast – „Modernizacja gospodarstw rolnych” (działanie 121).

Celem działania 112 była intensyfikacja zmian strukturalnych w polskim rolnictwie, ułatwiając przejmowanie bądź zakładanie gospodarstw rolnych przez osoby młode o odpowiednich kwalifikacjach zawodowych. Jak podaje Ministerstwo Rolnictwa i Rozwoju Wsi (MRiRW), o dopłaty w ramach działania 112 mogły ubiegać się osoby [PROW 2007-2013, 2016]:

1. między 18. a 40. rokiem życia,
2. posiadające odpowiednie kwalifikacje zawodowe,
3. rozwijające działalność rolniczą według złożonego biznesplanu,
4. ubezpieczone w KRUS przez co najmniej 1 rok od wypłaty pomocy,
5. prowadzące objęte pomocą gospodarstwo rolne przez co najmniej 5 lat od dnia wypłaty pomocy.

Ponadto, przyjmowane gospodarstwo rolne powinno:

1. mieć powierzchnię użytków rolnych nie mniejszą niż średnia krajowa, ale nie większą niż 300 ha,
2. stanowić (obecnie lub w przyszłości) własność lub dzierżawę beneficjenta,
3. spełnić standardy w zakresie higieny, ochrony środowiska i warunków utrzymania zwierząt w gospodarstwie.



Z kolei celem działania 121 było wsparcie modernizacji gospodarstw, aby zwiększyć ich efektywność, wykorzystując lepiej dostępne czynniki produkcji. Mogło to nastąpić na drodze wprowadzenia nowych technologii, poprawy jakości produkcji, różnicowania działalności rolniczej, czy też zharmonizowania warunków produkcji rolnej z wymogami dotyczącymi m.in. ochrony środowiska naturalnego. Dopłaty w ramach działania 121 przyznawane były na konkretne inwestycje, które [PROW 2007-2013, 2016]:

1. przyczynią się do wzrostu wartości dodanej brutto w gospodarstwie lub poprawy sytuacji w gospodarstwie w zakresie ochrony środowiska, warunków utrzymania zwierząt, higieny i bezpieczeństwa produkcji bądź infrastruktury drogowej,
2. są uzasadnione pod względem wysokości kosztów,
3. nie mają charakteru inwestycji odtworzeniowej.

Dodatkowo, wielkość ekonomiczna gospodarstwa, którego dotyczy inwestycja powinna wynosić co najmniej 4 ESU (ang. *European Size Unit*), a osoba je prowadząca powinna posiadać odpowiednie kwalifikacje zawodowe, chyba że jest jednocześnie beneficjentem działania „Ułatwienie startu młodym rolnikom” w ramach PROW 2007-2013.

Wśród tak zdefiniowanych wymogów otrzymania wsparcia w ramach działań 112 i 121, Zieliński i in. [2011] wskazują następujące warunki o charakterze ilościowym, które powinny spełniać porównywane ze sobą gospodarstwa rolne:

- dla działania „Ułatwienie startu młodym rolnikom”, wiek właściciela gospodarstwa rolnego nie powinien przekraczać 40 roku życia, natomiast powierzchnia użytków rolnych powinna być nie większa niż 300 ha i nie mniejsza niż krajowa średnia powierzchnia użytków rolnych w gospodarstwie,
- dla działania „Modernizacja gospodarstw rolnych”, wiek właściciela gospodarstwa nie powinien przekraczać 60 roku życia, natomiast wielkość ekonomiczna gospodarstwa powinna wynosić co najmniej 4 ESU.

W badaniu, którego wyniki przedstawiono w dalszej części pracy, dysponowano zagregowanymi danymi dotyczącymi dopłat do inwestycji. W związku z tym należy uwzględnić, iż w latach 2008-2013, dla których przeprowadzono badanie, otrzymanie wsparcia dla inwestycji było możliwe do uzyskania również w ramach m.in. PROW 2004-2006. Dlatego też w pracy nie uwzględniono warunków ograniczających dla analizowanych gospodarstw rolnych.

### 3.2. Szacowanie prawdopodobieństwa uzyskania dopłat do inwestycji

Pomiar przeciętnego efektu oddziaływania wspierania inwestycji w polskich gospodarstwach rolnych na wydajność czynnika pracy (GVA/AWU) rozpoczęto od specyfikacji wektora prawdopodobieństwa oddziaływania. W tym celu zbudowano modele logitowe, za pomocą których szacowano wpływ wszystkich możliwych kombinacji ze zbioru wybranych 19 zmiennych (patrz tabela 3) na binarną zmienną objaśnianą, wyrażającą otrzymanie (lub brak) dopłat do inwestycji. Wyboru modelu dokonywano na podstawie wartości współczynnika trafności klasyfikacji *AR*, stosując próg odcięcia równy 0,5.

**Tabela 3. Charakterystyka zmiennych objaśniających**

Nazwa zmiennej (wg FADN)	Rodzaj zmiennej	Charakterystyka
TF8	nominalna	Typ rolniczy gospodarstwa zgodnie z typologią FADN (kategorie: uprawy polowe, uprawy ogrodnicze, winnice, uprawy trwałe, krowy mleczne, zwierzęta trawożerne, zwierzęta ziarnożerne, mieszanane) <sup>34</sup>
ES6	porządkowa	Klasa wielkości ekonomicznej gospodarstwa rolnego zgodnie z typologią FADN (kategorie: bardzo małe (2-8 tys. euro), małe (8-25 tys. euro), średnio-małe (25-50 tys. euro), średnio-duże (50-100 tys. euro), duże (100-500 tys. euro), bardzo duże (powyżej 500 tys. euro) <sup>35</sup>
WYK	porządkowa	Wykształcenie rolnika (kategorie: podstawowe, zasadnicze nierolnicze, zasadnicze rolnicze, średnie nierolnicze, średnie rolnicze, wyższe nierolnicze, wyższe rolnicze) <sup>36</sup>
WIEK	porządkowa	Wiek rolnika (w latach)

<sup>34</sup> Przy interpretacji modeli logitowych kategorię referencyjną stanowią gospodarstwa specjalizujące się w uprawach polowych.

<sup>35</sup> Przy interpretacji modeli logitowych kategorię referencyjną stanowią gospodarstwa o wielkości ekonomicznej 2-8 tys. euro.

<sup>36</sup> Przy interpretacji modeli logitowych kategorię referencyjną stanowią gospodarstwa, w których kierujący nimi rolnik posiadał wykształcenie podstawowe.

SE025	ciągła	Powierzchnia użytków rolnych (w ha)
SE074	ciągła	Powierzchnia użytków rolnych wyłączona z produkcji (w ha)
SE080	ciągła	Stan średni w roku zwierząt utrzymywanych w gospodarstwie rolnym (w LU)
SE265	ciągła	Zużycie wewnętrzne w ramach działalności operacyjnej gospodarstwa rolnego (w zł)
SE365	ciągła	Koszty zaangażowania czynników zewnętrznych w procesie produkcyjnym (w zł)
SE436	ciągła	Aktywa trwałe i obrotowe stanowiące własność rolnika (w zł)
SE485	ciągła	Wartość zobowiązań krótko- i długoterminowych (w zł)
SE506	ciągła	Zmiana wartości kapitału własnego w ciągu roku obrachunkowego (w zł)
SE510	ciągła	Średnia wartość kapitału gospodarstwa rolnego (w zł)
SE516	ciągła	Inwestycje brutto (w zł)
SE521	ciągła	Inwestycje netto (w zł)
SE526	ciągła	Przepływ pieniężny I (w zł) = sprzedaż produktów + inne przychody + sprzedaż zwierząt – koszty ogółem – koszty zakupu zwierząt + saldo dopłat i podatków dotyczących działalności operacyjnej + saldo dopłat i podatków dotyczących inwestycji
SE530	ciągła	Przepływ pieniężny II (w zł) = przepływ pieniężny I + sprzedaż środków trwałych – zakupy i inwestycje w środkach trwałych + stan zobowiązań na koniec roku – stan zobowiązań na początek roku
SE605	ciągła	Dopłaty do działalności operacyjnej bez dopłat do inwestycji (w zł)
SE621	ciągła	Dopłaty rolnośrodowiskowe (w zł)

Źródło: opracowanie własne na podstawie [Floriańczyk, Osuch, Płonka, 2015].

W niniejszej pracy przyjęto założenie, że efekty wsparcia inwestycji występują z rocznym opóźnieniem, a na fakt przyznania dopłaty wpływa zbiór cech danego gospodarstwa rolnego z poprzedniego roku. W związku z tym pewne zmienne (cechy gospodarstwa) z roku  $t$  będą wpływać na otrzymanie dopłat do

inwestycji w roku  $t+1$ , których wynikiem będzie wartość wskaźnika rezultatu GVA/AWU w roku  $t+2$ .

Estymacja modeli logitowych pozwoliła wskazać, oddzielnie dla każdego okresu, zbiór predyktorów, tj. cech umożliwiających prognozowanie wartości zmiennej objaśnianej. Na rysunkach 30-35 zaprezentowano wartości ilorazu szans wraz z ich 97,5% przedziałem ufności. Na niebiesko oznaczono zmienne, które w przypadku wzrostu ich wartości (o jednostkę) wpływają dodatnio na szansę otrzymania przez gospodarstwo rolne dopłat do inwestycji, natomiast na czerwono zmienne wpływające na tę szansę ujemnie.

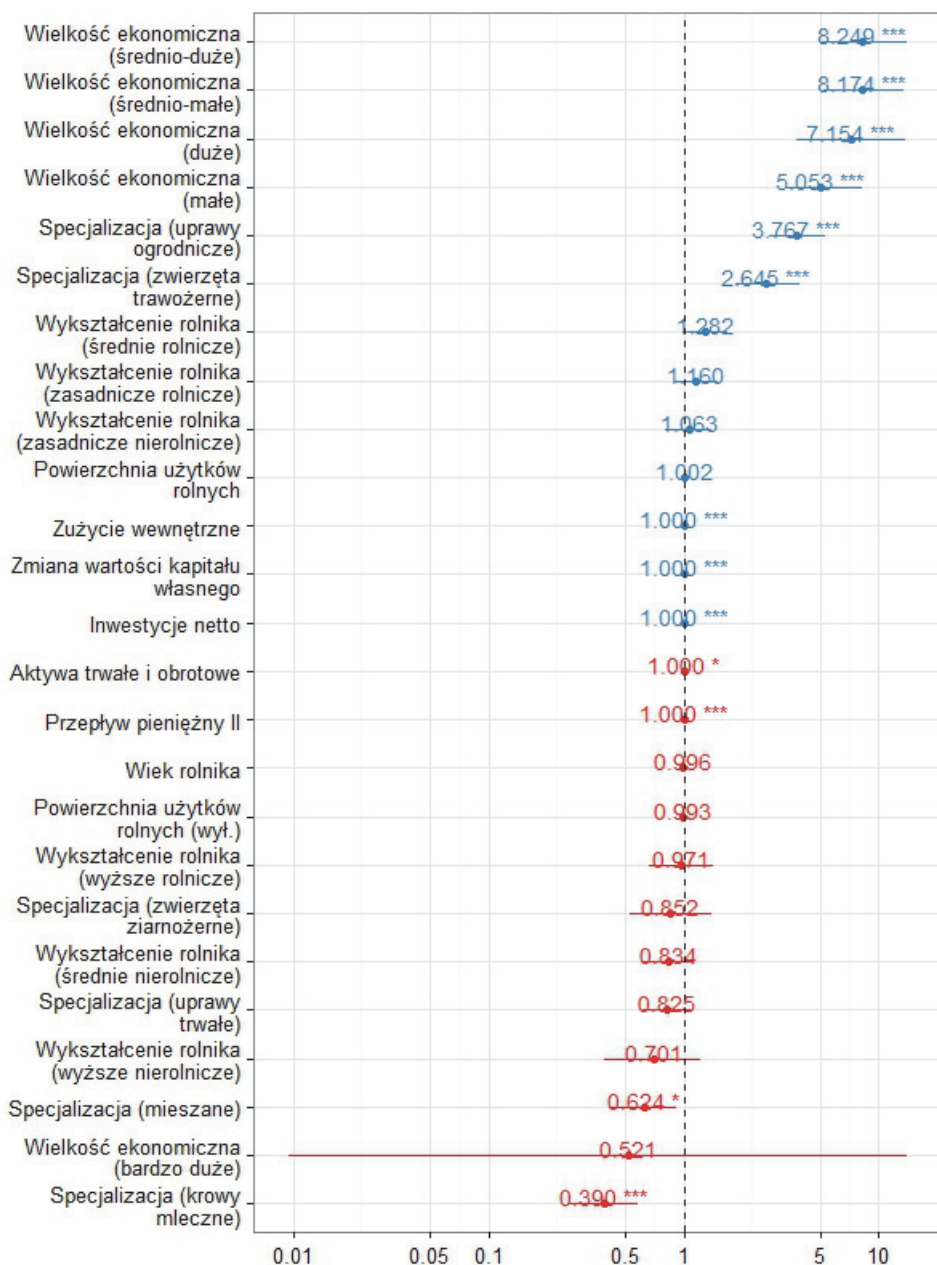
W modelu szacującym prawdopodobieństwo otrzymania wsparcia dla inwestycji w 2007 r. – na podstawie wartości cech gospodarstw rolnych z 2006 r. – uzyskano najwyższą trafność klasyfikacji na poziomie 0,7803, a więc na 100 obserwacji zbudowany model błędnie klasyfikował ok. 22 jednostki (rysunek 30). Istotnie dodatni wpływ na szansę otrzymania wsparcia miały takie cechy gospodarstwa, jak: wielkość ekonomiczna, wielkość zużycia wewnętrznego, przyrost kapitału własnego oraz wartość inwestycji netto. Negatywnie na zmienną objaśnianą wpływały natomiast wartość aktywów trwałych i obrotowych oraz przepływu pieniężnego II.

Gospodarstwa rolne specjalizujące się w uprawach ogrodniczych miały około czterokrotnie, a w hodowli zwierząt trawożernych ponad dwukrotnie wyższą szansę na otrzymanie wsparcia niż gospodarstwa specjalizujące się w uprawach polowych. Z kolei dla gospodarstw o typie rolniczym „krowy mleczne” oraz „mieszane”, prawdopodobieństwo otrzymania wsparcia spadło o odpowiednio 62 i 37%.

Gospodarstwa, których wielkość ekonomiczna mieściła się w kategorii „małe”, „średnio-małe”, „średnio-duże” lub „duże”, cechowały się od około pięcio- do dziewięciokrotnie wyższą szansą na otrzymanie dopłat do inwestycji. Wyjątek stanowiły gospodarstwa rolne o wielkości powyżej 500 tys. euro, dla których szansa wsparcia w kolejnym roku spada o około 51%. Wpływ pozostałych istotnych zmiennych na prawdopodobieństwo otrzymania dopłat zanotowano na poziomie około jednej stutysięcznej procenta, dlatego też nie dokonano ich interpretacji.

Dla okresu 2007-2008 otrzymano model logitowy o trafności klasyfikacji na poziomie 0,7495 (rysunek 31). Za zmienne istotne uznano: wielkość ekonomiczną gospodarstwa, powierzchnię użytków rolnych, wielkość zużycia wewnętrznego, wartość aktywów (trwałych i obrotowych), zobowiązań (krótko- i długoterminowych) oraz przepływu pieniężnego I i II.


**Rysunek 30. Iloraz szans dla modelu logitowego (dla wartości zmiennej zależnej w 2007 r.)**



Oznaczenia: \*\*\* - p-value poniżej 0,001, \*\* - poniżej 0,01, \* - poniżej 0,05.

Źródło: opracowanie własne.

**Rysunek 31. Iloraz szans dla modelu logitowego (dla wartości zmiennej zależnej w 2008 r.)**



Oznaczenia: \*\*\* - p-value poniżej 0,001, \*\* - poniżej 0,01, \* - poniżej 0,05.

Źródło: opracowanie własne.

Na wzrost prawdopodobieństwa otrzymania w 2008 r. wsparcia inwestycji wpłynęła przede wszystkim wielkość ekonomiczna gospodarstwa. Najwyższe (około 12-krotnie wyższe) szanse na otrzymanie dopłat miały gospodarstwa o wielkości ekonomicznej z przedziału 25-100 tys. euro.

Podobnie jak w poprzednim okresie, niewielki dodatni wpływ na szansę otrzymania wsparcia miała wielkość zużycia wewnętrznego w ramach działalności operacyjnej gospodarstwa. Z kolei odwrotnie do poprzedniego okresu, wpływ wartości aktywów trwałych i obrotowych był ujemny. Dodatkowo, wartość przepływu pieniężnego I wpłynęła dodatnio na szansę otrzymania dopłat, podczas gdy wartość przepływu pieniężnego II wpływała już na tę szansę negatywnie.

Model dla okresu 2008-2009 poprawnie sklasyfikował około 76 na 100 obserwacji (rysunek 32). Zmiennymi, których wartość istotnie wpływała na fakt otrzymania wsparcia były: rodzaj specjalizacji gospodarstwa, wielkość zużycia wewnętrznego, wartość inwestycji (netto i brutto) oraz wysokość dopłat do działalności operacyjnej gospodarstwa.

Największy wpływ miał typ gospodarstwa rolnego, pozostałe zmienne determinowały natomiast szansę otrzymania wsparcia w niewielkim stopniu. Specjalizowanie się w uprawach ogrodniczych oraz hodowli zwierząt trawożernych wiązało się z około dwukrotnie wyższymi szansami na uzyskanie wsparcia dla inwestycji w gospodarstwie, podczas gdy dla gospodarstw specjalizujących się w uprawach trwałych, hodowli krów mlecznych oraz zwierząt ziarnożernych szansa ta była niższa o odpowiednio 46, 40 i 32% od kategorii referencyjnej. Warto zaznaczyć, że identyczny kierunek wpływu (dodatni lub ujemny) określonej specjalizacji gospodarstw rolnych zanotowano również dla modelu z okresu 2006-2007 (por. rysunki 30 i 32).

**Rysunek 32. Iloraz szans dla modelu logitowego (dla wartości zmiennej zależnej w 2009 r.)**

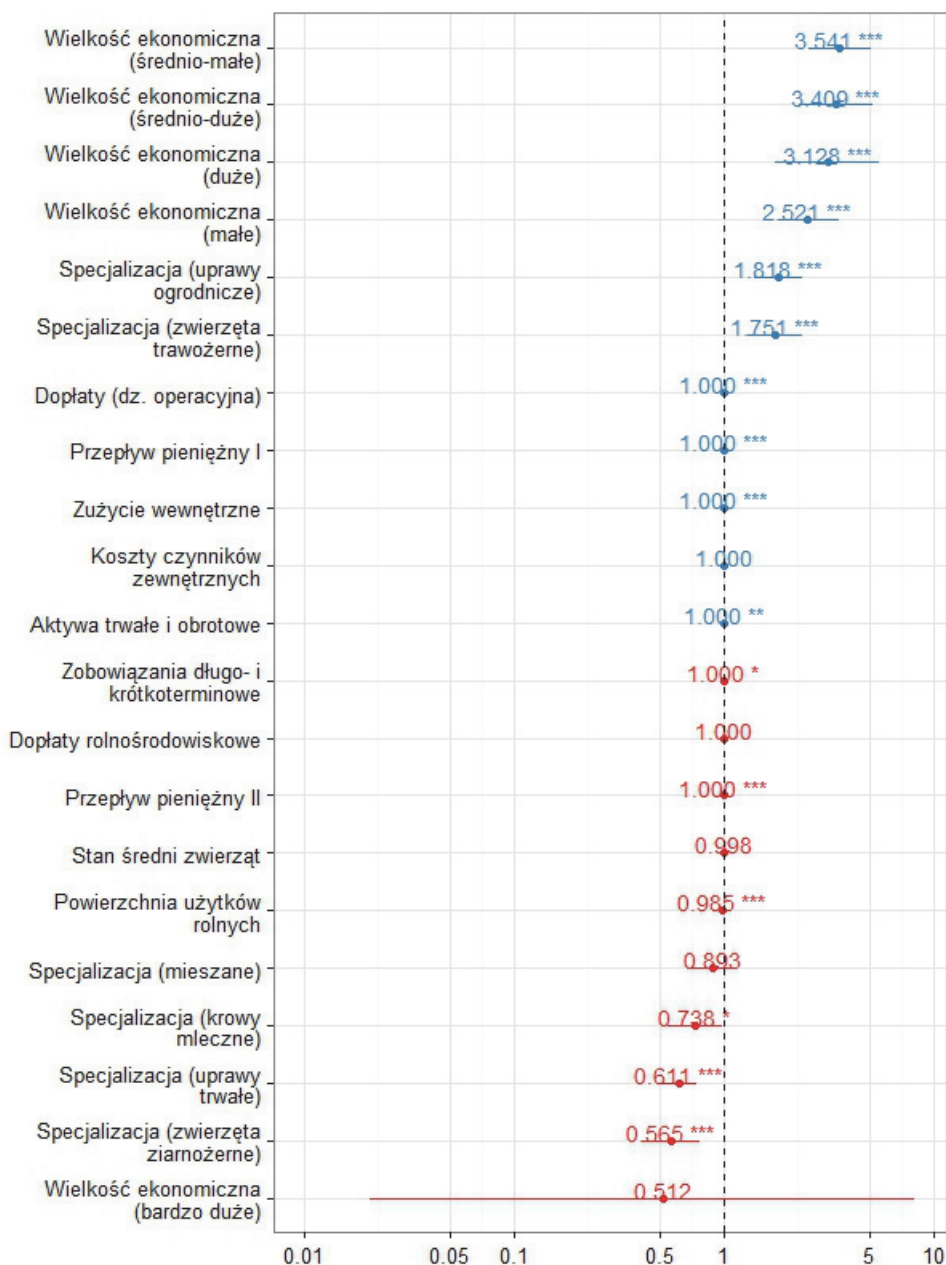


Oznaczenia: \*\*\* - p-value poniżej 0,001, \*\* - poniżej 0,01, \* - poniżej 0,05.

Źródło: opracowanie własne.



**Rysunek 33. Iloraz szans dla modelu logitowego (dla wartości zmiennej zależnej w 2010 r.)**



Oznaczenia: \*\*\* - p-value poniżej 0,001, \*\* - poniżej 0,01, \* - poniżej 0,05.

Źródło: opracowanie własne.

Zbliżoną trafność klasyfikacji uzyskano dla modelu z okresu 2009-2010 (rysunek 33). Podobnie jak w poprzednich latach, zmiennymi wpływającymi w sposób statystycznie istotny na badane prawdopodobieństwo były: rodzaj specjalizacji i wielkość ekonomiczna gospodarstwa, powierzchnia użytków rolnych, wielkość zużycia wewnętrznego, wartość aktywów (trwałych i obrotowych), zobowiązań (krótko- i długoterminowych) i przepływu pieniężnego I oraz wysokość dopłat na rzecz działalności operacyjnej gospodarstwa.

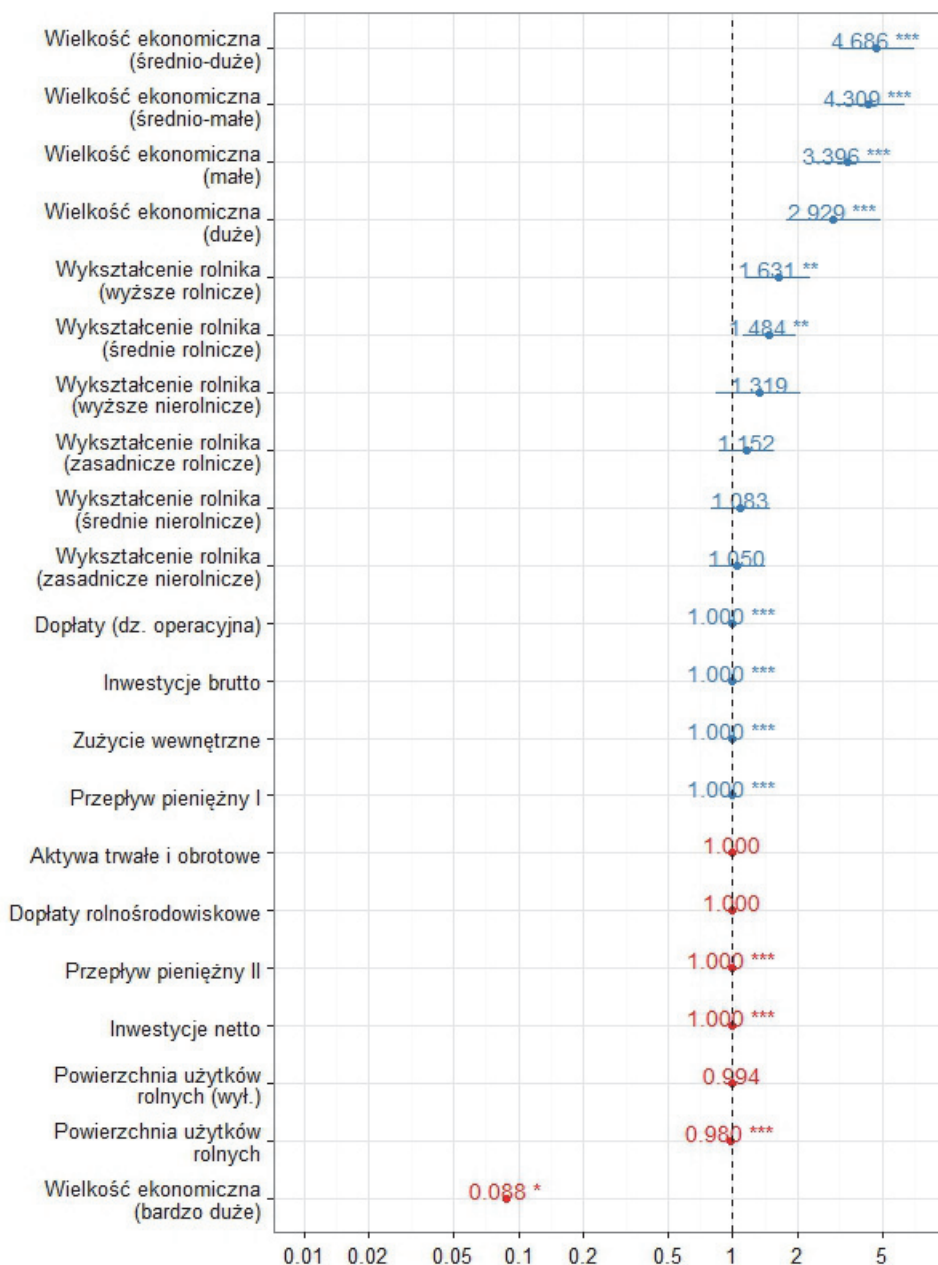
Ponownie, to dla gospodarstw specjalizujących się w uprawach ogrodniczych oraz hodowli zwierząt trawożernych szansa na otrzymanie wsparcia była wyższa, przy czym w tym przypadku odpowiednio o 82 i 75%. Dla gospodarstw z pozostałych specjalizacji szansa uzyskania dopłat do inwestycji była o około 30% niższa w porównaniu do gospodarstw z kategorii referencyjnej.

W przypadku wielkości ekonomicznej, dla gospodarstw z przedziału 8-500 tys. euro zanotowano prawie trzykrotnie wyższą szansę na otrzymanie wsparcia. Wpływ pozostałych zmiennych był znikomy, jednak należy odnotować, że chociaż nadal ujemny, wpływ powierzchni użytków rolnych był wyższy (co do wartości bezwzględnej) niż w poprzednim okresie (por. rysunki 31 i 33). Tutaj, zwiększenie powierzchni o 1 ha wpływało na spadek szans na otrzymanie wsparcia o około 1,5%.

Dla lat 2010-2011 uzyskano model o trafności klasyfikacji na poziomie 0,747 (rysunek 34). Istotnie dodatnio wpłynęły takie cechy gospodarstwa, jak: wielkość ekonomiczna, wykształcenie rolnika kierującego gospodarstwem, wielkość zużycia wewnętrznego, wartość inwestycji brutto i przepływu pieniężnego I oraz wysokość dopłat do działalności operacyjnej gospodarstwa. Negatywny wpływ miały natomiast powierzchnia użytków rolnych, wartość inwestycji netto oraz przepływu pieniężnego II.

Największy wpływ na otrzymanie wsparcia miała wielkość ekonomiczna gospodarstwa. Gospodarstwa o wielkości 8-100 tys. euro miały co najmniej trzykrotnie wyższe szanse, przy czym najwyższą szansę miały gospodarstwa sklasyfikowane jako „średnio-duże”. Istotne było również posiadanie przez rolnika wykształcenia średniego lub wyższego rolniczego, które zwiększało szansę na otrzymanie dopłat do inwestycji o odpowiednio 48 i 63%. Negatywnie na szacowane prawdopodobieństwo wpływała natomiast powierzchnia użytków rolnych, bowiem z każdym kolejnym hektarem szansa na otrzymanie wsparcia malała o około 2%.


**Rysunek 34. Iloraz szans dla modelu logitowego (dla wartości zmiennej zależnej w 2011 r.)**



Oznaczenia: \*\*\* - p-value poniżej 0,001, \*\* - poniżej 0,01, \* - poniżej 0,05.

Źródło: opracowanie własne.

**Rysunek 35. Iloraz szans dla modelu logitowego (dla wartości zmiennej zależnej w 2012 r.)**



Oznaczenia: \*\*\* - p-value poniżej 0,001, \*\* - poniżej 0,01, \* - poniżej 0,05.

Źródło: opracowanie własne.

Model skonstruowany dla okresu 2011-2012 klasyfikował poprawnie około 77 na 100 obserwacji (rysunek 35). O wzroście szansy otrzymania dopłat do inwestycji decydowało: wykształcenie rolnika, wielkość zużycia wewnętrznego, średnia wartość kapitału gospodarstwa, wartość inwestycji brutto i przepływu pieniężnego I oraz wysokość dopłat do działalności operacyjnej gospodarstwa. Spadkowi szacowanego prawdopodobieństwa towarzyszyły z kolei takie cechy gospodarstwa, jak: powierzchnia użytków rolnych, wartość inwestycji netto oraz przepływu pieniężnego II. Istotny statystycznie był również wpływ specjalizacji gospodarstwa, przy czym był on niejednoznaczny.

W przypadku wykształcenia rolnika, ponownie kategoriami istotnie wpływającymi na szansę otrzymania wsparcia było wykształcenie średnie i wyższe rolnicze. Rolnicy prowadzący gospodarstwo rolne mieli o odpowiednio 50 i 89% wyższe szanse na dopłaty niż posiadający wykształcenie podstawowe. Biorąc pod uwagę specjalizację gospodarstwa, dodatni wpływ na szacowane prawdopodobieństwo miały gospodarstwa specjalizujące się w uprawach ogrodniczych oraz hodowli zwierząt trawożernych, zwiększając je dwukrotnie. Dla gospodarstw specjalizujących się w uprawach trwałych oraz hodowli krów mlecznych, szansa na otrzymanie dopłaty spadała o odpowiednio 26 i 53%.

**Tabela 4. Wzrost (spadek) szans otrzymania dopłat do inwestycji ze względu na istotne zmienne**

Cecha gospodarstwa	Rok	2006	2007	2008	2009	2010	2011
		-	-	-	-	-	-
		2007	2008	2009	2010	2011	2012
Specjalizacja:							
uprawy ogrodnicze	+277%			+170%	+82%		+98%
uprawy trwałe				-46%	-39%		-26%
krowy mleczne	-61%			-40%	-27%		-53%
zwierzęta trawożerne	+164%			+99%	+75%		+138%
zwierzęta ziarnożerne				-32%	-44%		
mieszane	-38%						
Wielkość ekonomiczna:							
małe	+405%	+542%			+152%	+240%	
średnio-małe	+717%	+1069%			+254%	+331%	
średnio-duże	+725%	+1161%			+241%	+369%	
duże	+615%	+810%			+213%	+193%	
bardzo duże						-92%	
Wykształcenie rolnika:							
średnie rolnicze						+48%	+50%
wyższe rolnicze						+63%	+89%

cd. tab. 4

Powierzchnia użytków rolnych (wzrost o 10 ha)		-2,73%		-15,4%	-19,8%	-8,01%
Zużycie wewnętrzne (wzrost o 1000 zł)	+0,825%	+0,75%	+0,69%	+0,52%	+0,69%	+0,3%
Aktywa trwałe i obrotowe (wzrost o 1000 zł)	-0,03%	+0,03%		+0,01%		
Zobowiązania krótko- i długoterminowe (wzrost o 1000 zł)		-0,08%		-0,05%		
Zmiana wartości kapitału własnego (wzrost o 1000 zł)	+0,62%					
Średnia wartość kapitału (wzrost o 1000 zł)						+0,03%
Inwestycje brutto (wzrost o 1000 zł)			+1,21%		+1,33%	+1,65%
Inwestycje netto (wzrost o 1000 zł)	+0,23%		-1,11%		-1,24%	-1,62%
Przepływ pieniężny I (wzrost o 1000 zł)		+0,36%		+0,57%	+0,42%	+0,13%
Przepływ pieniężny II (wzrost o 1000 zł)	-0,42%	-0,48%		-0,68%	-0,57%	-0,27%
Dopłaty do działalności operacyjnej (wzrost o 1000 zł)			+0,36%	+1,28%	+1,57%	+0,61%

Źródło: opracowanie własne.

Podsumowując dotychczasowe wyniki (patrz tabela 4), w modelach logitowych służących specyfikacji wektorów *propensity score*, maksymalną trafność klasyfikacji osiągnęto dla modeli z 7-12 predyktorami. Skonstruowane modele trafnie klasyfikowały od 74 do 78 na 100 obserwacji, co daje satysfakcjonujący wynik.

W przypadku specjalizacji, większe szanse na otrzymanie dopłat do inwestycji miały te gospodarstwa, w których zajmowano się uprawami ogrodniczymi oraz hodowlą zwierząt trawożernych, mniejsze szanse natomiast te, w których zajmowano się uprawami trwałymi oraz hodowlą krów mlecznych. Jeżeli chodzi o wielkość ekonomiczną, mimo porządkowego charakteru, nie można było wskazać jednoznacznie kierunku wpływu zmiennej na szacowane prawdopodobieństwo. Wykształcenie rolnika kierującego gospodarstwem okazało się być istotnym predyktorem dopiero w dwóch ostatnich okresach, tj. przy szacowaniu wpływu wybranych cech gospodarstwa w 2010 r. i 2011 r. na otrzymanie dopłat do inwestycji w 2011 r. i 2012 r. Należy jednak zwrócić uwagę, iż statystycznie

istotne dla szacowanego prawdopodobieństwa było posiadanie wykształcenia średniego lub wyższego rolniczego. Bez znaczenia było natomiast wykształcenie średnie czy wyższe, ale o specjalizacji niezwiązanej z rolnictwem.

Wśród zmiennych o charakterze ilościowym, dodatni wpływ na szansę dostania wsparcia dla inwestycji miała wielkość zużycia wewnętrznego oraz wysokość uzyskanych w poprzednim roku dopłat do działalności operacyjnej gospodarstwa. Negatywnie oddziaływała natomiast powierzchnia użytków rolnych oraz wysokość inwestycji w ujęciu netto. Ponadto, o ile wartość przepływu pieniężnego I wpływała pozytywnie na szansę otrzymania w kolejnym roku dopłat do inwestycji, to już wartość przepływu pieniężnego II (różniącego się o wartość sprzedaży środków trwałych oraz zakupy i inwestycje w środkach trwałych) na tę szansę wpływała negatywnie.

### **3.3. Wybór zmiennych bilansujących grupę eksperymentalną i kontrolną**

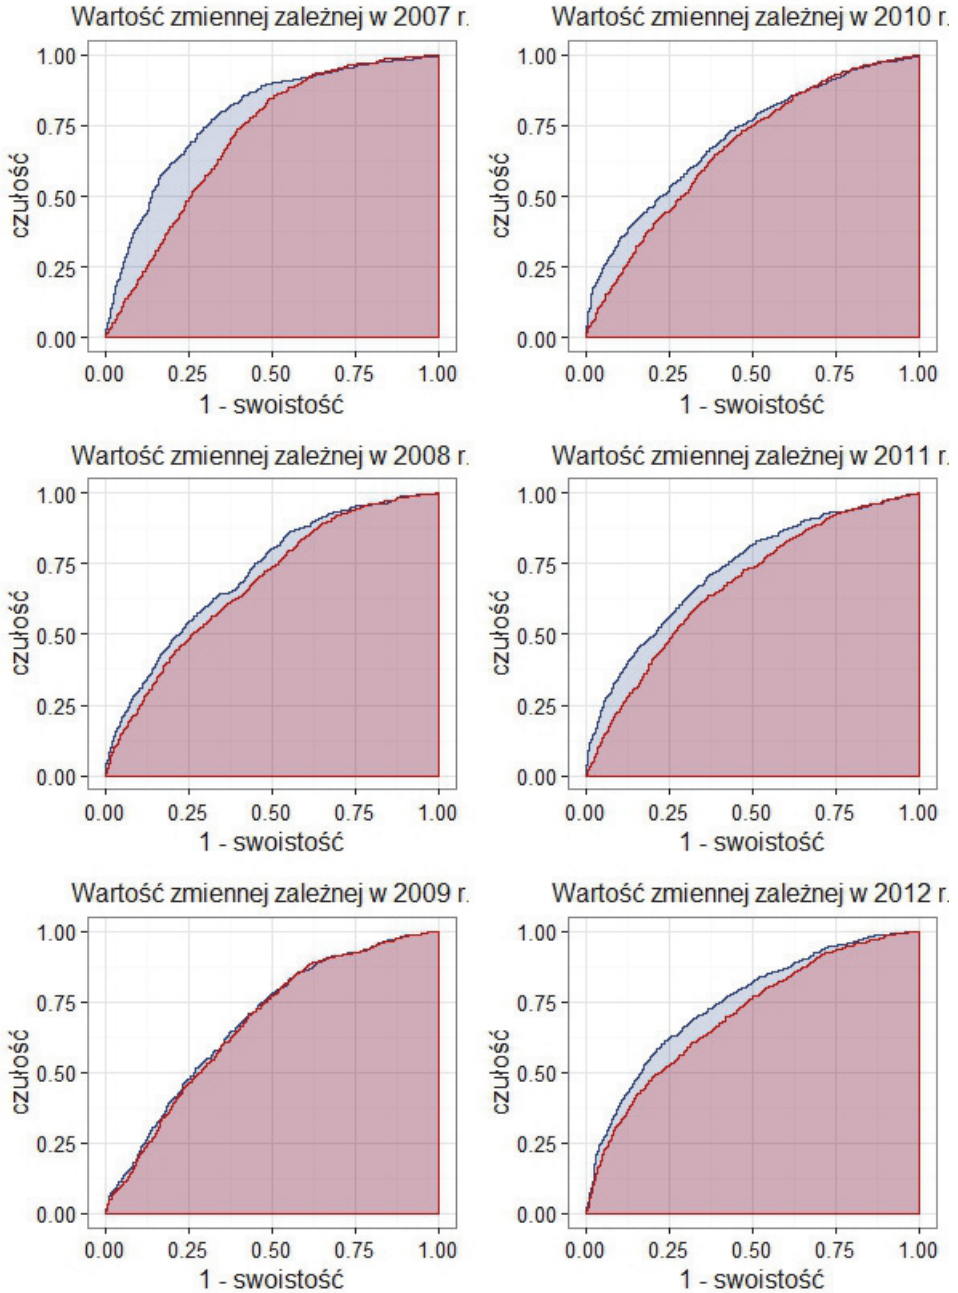
Kierując się rekomendacjami Heckmana, Ichimury i Todda [1997] proponujących wykorzystanie własności predykcyjnych charakterystyk [za: Strawiński, 2014], przy konstrukcji wektora *propensity score* wybrano taką kombinację zmiennych<sup>37</sup>, dla których współczynnik trafności klasyfikacji prognoz był najwyższy.

Jak zauważa Trzciniński [2009], podstawowym celem *propensity score matching* nie jest jednak predykcja, ale zbalansowanie cech badanych obiektów w taki sposób, by zapewnić podobny ich rozkład w grupie poddanej oddziaływaniu danej determinanty i w grupie tym oddziaływaniem nieobjętej. W związku z tym, w przypadku braku dobrego zbalansowania osiągniętego dla modelu o najlepszej trafności klasyfikacji, w pracy do dalszej analizy wybiera się model logitowy o gorszej trafności, ale zapewniający lepsze zbilansowanie obserwowalnych charakterystyk między grupą eksperymentalną a kontrolną.

---

<sup>37</sup> Jak stwierdza Strawiński [2009, s. 235] za Rosenbaumem i Rubinem [1983] „znajomość stanu uczestnictwa w programie warunkowo względem cech (...) nie powinna determinować wartości zmiennej wynikowej”, dlatego też wśród rozważanych zmiennych objaśniających nie znalazły się charakterystyki będące składowymi wartości dodanej brutto na roczną jednostkę pracy.

**Rysunek 36. Krzywe ROC dla estymowanych modeli logitowych**



Źródło: opracowanie własne.



Słuszność zastosowanego podejścia oceniono na podstawie krzywych ROC (patrz rysunek 36). Linia niebieską oznaczono krzywą ROC dla najlepiej klasyfikującego modelu, czerwoną – dla modelu zapewniającego zbalansowanie wybranych cech w grupie eksperymentalnej i kontrolnej. Przebieg krzywych wskazuje, iż otrzymano ostatecznie zbilansowane zbiory kosztem niewielkiego wzrostu błędnie klasyfikowanych obserwacji, który nie przekroczył 4 punktów procentowych.

### 3.4. Szacowanie przeciętnego efektu oddziaływania wobec jednostek poddanych oddziaływaniu (ATT)

W ostatnim etapie zmierzono przeciętny efekt oddziaływania dopłat do inwestycji na wydajność czynnika pracy (GVA/AWU) za pomocą metody *propensity score matching*. Zastosowano algorytm genetyczny oparty na minimalizacji uogólnionej wersji metryki Mahalanobisa, zdefiniowanej jako [Diamond, Sekhon, 2013]:

$$d(X_i, X_j) = \sqrt{(X_i - X_j)^T \left(S^{-\frac{1}{2}}\right)^T W S^{-\frac{1}{2}} (X_i - X_j)}$$

gdzie:

$W$  – macierz wag,

$S$  – macierz kowariancji dla  $X$ ,

$S^{-\frac{1}{2}}$  – dekompozycja Cholesky’ego dla macierzy  $S$ , np.  $S = S^{-\frac{1}{2}} \left(S^{-\frac{1}{2}}\right)^T$ .

Przy łączeniu obserwacji według prawdopodobieństwa zastosowano metodę wybierania obserwacji z grupy kontrolnej ze zwracaniem (ang. *replace*). W konsekwencji dana jednostka z grupy kontrolnej mogła zostać połączona z więcej niż jedną jednostką z grupy eksperymentalnej. Dodatkowo, uwzględniono możliwość występowania tzw. powiązań (ang. *ties*) między obserwacjami z grupy eksperymentalnej i kontrolnej. Stąd, jeżeli do jednostki z grupy eksperymentalnej są podobne dwie (lub więcej) jednostki z grupy kontrolnej, to każda z tych jednostek zostaje w równy sposób przeważona<sup>38</sup> i połączona z obserwacją z grupy eksperymentalnej [Sekhon, 2011].

<sup>38</sup> Oznacza to, że suma wag jest równa 1, a zatem liczba obserwacji w grupie kontrolnej pozostaje taka sama jak w grupie eksperymentalnej.

Pomiar efektu oddziaływania wsparcia inwestycji na wydajność czynnika pracy rozpoczęto od doboru zmiennych do wektora *propensity score* dla każdego analizowanego okresu. Wybrano takie charakterystyki, które pozwoliły z grupy jednostek niepoddanych oddziaływaniu wybrać obserwacje do grupy kontrolnej będące „podobne” do grupy eksperymentalnej. Stąd, traktując grupę kontrolną jako kontrfaktyczną dla grupy eksperymentalnej, możliwy był w dalszym etapie pomiar przeciętnego efektu oddziaływania dopłat do inwestycji na wydajność czynnika pracy w gospodarstwach rolnych.

W tabelach 5-10 przedstawiono statystyki podsumowujące dla przeprowadzonego łączenia obserwacji, ukazując przede wszystkim różnice w średnich wartościach zmiennych z wektora *propensity score* w grupie eksperymentalnej i niepoddanej oddziaływaniu (przed łączeniem) oraz grupie eksperymentalnej i kontrolnej (po łączeniu). Dodatkowo, na rysunkach 37-42 zaprezentowano standaryzowane różnice średnich<sup>39</sup>, pokazując skalę rozbieżności w wartościach zmiennych między grupą niepoddaną oddziaływaniu a kontrolną.

Dla okresu 2006-2008, tj. szacując wielkość oddziaływania dopłat do inwestycji otrzymanych w 2007 r. na GVA/AWU w 2008 r. na podstawie cech gospodarstwa z 2006 r., w wektorze *propensity score* uwzględniono ostatecznie takie cechy gospodarstwa rolnego, jak: specjalizacja i wielkość ekonomiczna gospodarstwa, wiek rolnika kierującego gospodarstwem, powierzchnia użytków rolnych, wielkość zużycia wewnętrznego oraz wartość aktywów trwałych i obrotowych (patrz tabela 5)<sup>40</sup>.

**Tabela 5. Zbilansowanie zbiorów (dla wartości wskaźnika rezultatu w 2008 r.)**

Cecha gospodarstwa rolnego	Przed łączeniem			Po łączeniu		
	$\bar{x}_T$	$\bar{x}_C$	Standaryzowana różnica średnich	$\bar{x}_T$	$\bar{x}_C$	Standaryzowana różnica średnich
Wiek rolnika (w latach)	41,5	42,3	-9,3	41,5	41,7	-1,9

<sup>39</sup> Standaryzowana różnica średnich (ang. *standardized mean difference*) jest ilorazem różnicy średnich wskaźnika rezultatu w grupach eksperymentalnej i kontrolnej (lub niepoddanej oddziaływaniu) oraz odchylenia standardowego dla tego wskaźnika, liczonego dla wszystkich obserwacji [Faraone, 2008].


<sup>40</sup> Ze względu na jakościowy charakter zmiennych takich, jak: specjalizacja, wielkość ekonomiczna i wykształcenie rolnika, w tabelach 5-10 nie zamieszczano informacji o tych zmiennych.

Powierzchnia użytków rolnych (w ha)	36,8	28,6	20,6	36,8	36,7	0,2
Zużycie wewnętrzne (w tys. zł)	26,2	16,4	37,1	26,2	26,1	0,3
Aktywa trwałe i obrotowe (w tys. zł)	625,7	474,9	27,6	625,7	625,5	0,04

$\bar{x}_T$  – średnia w grupie eksperymentalnej,  $\bar{x}_C$  – średnia w grupie niepoddanej oddziaływaniu lub kontrolnej.

Źródło: opracowanie własne.

**Rysunek 37. Standaryzowana różnica średnich (dla wartości wskaźnika rezultatu w 2008 r.)**



Źródło: opracowanie własne.

Jak wskazano w tabeli 5, beneficjentami otrzymanych dopłat do inwestycji byli, średnio rzecz ujmując, rolnicy w wieku ok. 41 lat, dysponujący 36,8 ha ziemi użytkowanej rolniczo. Wartość produktów roślinnych i zwierzęcych wytworzonych i zużytych w ramach działalności operacyjnej ich gospodarstw wynosiła przeciętnie 26,2 tys. zł, natomiast wartość aktywów kształtowała się na poziomie 625,7 tys. zł. W gospodarstwach rolnych, które nie dostały wspomnianego wsparcia, średni wiek rolnika kierującego gospodarstwem wyniósł ok. 42 lata. Powierzchnia użytków rolnych w gospodarstwie liczyła przeciętnie 28,6 ha. Wielkość zużycia wewnętrznego równa była 16,4 tys. zł, natomiast wartość ak-

tywów rolnika 474,9 tys. zł. Pod względem wybranych obserwowalnych charakterystyk, grupy poddane i niepoddane oddziaływaniu różniły się przede wszystkim pod względem wielkości zużycia wewnętrznego oraz aktywów ogółem, co ilustruje rysunek 37.

W okresie 2007-2009 gospodarstwa rolne porównywane były na podstawie ich wielkości ekonomicznej, powierzchni użytków rolnych, wielkości zużycia wewnętrznego oraz wartości przepływu pieniężnego I (patrz tabela 6).

**Tabela 6. Zbilansowanie zbiorów (dla wartości wskaźnika rezultatu w 2009 r.)**


Cecha gospodarstwa rolnego	Przed łączeniem			Po łączeniu		
	$\bar{x}_T$	$\bar{x}_C$	Standaryzowana różnica średnich	$\bar{x}_T$	$\bar{x}_C$	Standaryzowana różnica średnich
Powierzchnia użytków rolnych (w ha)	38,3	28,7	22,7	38,3	37,6	1,5
Zużycie wewnętrzne (w tys. zł)	35,8	20,7	37,2	35,8	35,4	0,9
Przepływ pieniężny I (w tys. zł)	108,3	80,5	22,3	108,3	105,8	2,0

$\bar{x}_T$  – średnia w grupie eksperymentalnej,  $\bar{x}_C$  – średnia w grupie niepoddanej oddziaływaniu lub kontrolnej.

*Źródło: opracowanie własne.*

W gospodarstwach rolnych, które otrzymały dopłaty do inwestycji, użytkowano rolniczo średnio 38,3 ha ziemi. Wytworzono i zużyto produkty roślinne i zwierzęce o wartości średnio 35,8 tys. zł. Wartość przepływu pieniężnego I wyniosła natomiast 108,3 tys. zł. Dla gospodarstw rolnych, które w 2008 r. nie dostały dotacji, średnia powierzchnia użytków rolnych wyniosła z kolei 28,7 ha. W ramach działalności operacyjnej wytworzono i zużyto w tych gospodarstwach produkty roślinne i zwierzęce o wartości 20,7 tys. zł. Przepływ pieniężny I równy był natomiast 80,5 tys. zł. Gospodarstwa rolne różniły się zatem przede wszystkim pod względem wielkości zużycia wewnętrznego (patrz rysunek 38).

**Rysunek 38. Standaryzowana różnica średnich (dla wartości wskaźnika rezultatu w 2009 r.)**



Źródło: opracowanie własne.

Dla okresu 2008-2010 wektor *propensity score* składał się z obserwowalnych charakterystyk, takich jak: specjalizacja gospodarstwa, wielkość zużycia wewnętrznego, wartość aktywów trwałych i obrotowych oraz inwestycji netto (parz tabela 7).

**Tabela 7. Zbilansowanie zbiorów (dla wartości wskaźnika rezultatu w 2010 r.)**


Cecha gospodarstwa rolnego	Przed łączeniem			Po łączeniu		
	$\bar{x}_T$	$\bar{x}_C$	Standaryzowana różnica średnich	$\bar{x}_T$	$\bar{x}_C$	Standaryzowana różnica średnich
Zużycie wewnętrzne (w tys. zł)	35,5	21,5	33,4	35,5	35,2	0,8
Aktywa trwałe i obrotowe (w tys. zł)	763,2	560,6	31,0	763,2	756,4	1,0
Inwestycje netto (w tys. zł)	15,8	3,2	11,4	15,8	14,4	1,2

$\bar{x}_T$  – średnia w grupie eksperymentalnej,  $\bar{x}_C$  – średnia w grupie niepoddanej oddziaływaniu lub kontrolnej.

Źródło: opracowanie własne.

W gospodarstwach poddanych oddziaływaniu wytworzono i zużyto produkty roślinne i zwierzęce o przeciętnej wartości 35,5 tys. zł. Wartość aktywów trwałych i obrotowych w tych gospodarstwach obliczona była na średnio 763,2 tys. zł. Wysokość inwestycji w ujęciu netto wyniosła natomiast 15,8 tys. zł. Gospodarstwa, które nie otrzymały wsparcia dla inwestycji, charakteryzowały się zaś przeciętnym zużyciem wewnętrznym na poziomie 21,5 tys. zł. Wartość aktywów w tych gospodarstwach wynosiła z kolei średnio 560,6 tys. zł, a inwestycji netto 3,2 tys. zł. Standaryzując wyniki, gospodarstwa poddane i niepoddane oddziaływaniu różniły się między sobą przede wszystkim pod względem wielkości zużycia wewnętrznego (patrz rysunek 39).

**Rysunek 39. Standaryzowana różnica średnich (dla wartości wskaźnika rezultatu w 2010 r.)**



*Źródło: opracowanie własne.*

W okresie 2009-2011 gospodarstwa rolne porównywano na podstawie ich specjalizacji i wielkości ekonomicznej, powierzchni użytków rolnych, wielkości zużycia wewnętrznego oraz wartości aktywów trwałych i obrotowych (patrz tabela 8).

Przeciętna powierzchnia użytków rolnych wyniosła 42,8 ha w grupie gospodarstw, które otrzymały dopłaty oraz 32,0 ha w pozostałych gospodarstwach. Zużycie wewnętrzne kształtowało się w obu grupach na poziomie odpowiednio 30,1 i 19,7 tys. zł, a wartość aktywów trwałych i obrotowych na poziomie 1441,9 i 992,5 tys. zł. Wnioskując z rysunku 40, przed połączeniem obserwacji, gospodarstwa rolne różniły się między sobą przede wszystkim pod względem wartości aktywów trwałych i obrotowych.


**Tabela 8. Zbilansowanie zbiorów (dla wartości wskaźnika rezultatu w 2011 r.)**

Cecha gospodarstwa rolnego	Przed łączeniem			Po łączeniu		
	$\bar{x}_T$	$\bar{x}_C$	Standaryzowana różnica średnich	$\bar{x}_T$	$\bar{x}_C$	Standaryzowana różnica średnich
Powierzchnia użytków rolnych (w ha)	42,8	32,0	23,4	42,8	43,2	-0,8
Zużycie wewnętrzne (w tys. zł)	30,1	19,7	28,8	30,1	29,2	2,7
Aktywa trwałe i obrotowe (w tys. zł)	1441,9	992,5	35,6	1441,9	1429,1	1,0

$\bar{x}_T$  – średnia w grupie eksperymentalnej,  $\bar{x}_C$  – średnia w grupie niepoddanej oddziaływaniu lub kontrolnej.

Źródło: opracowanie własne.

**Rysunek 40. Standaryzowana różnica średnich (dla wartości wskaźnika rezultatu w 2011 r.)**



Źródło: opracowanie własne.

W okresie 2010-2012 obserwacje z grupy poddanej i niepoddanej oddziaływaniu łączono na podstawie wartości cech, takich jak: wielkość ekonomiczna gospodarstwa, powierzchnia użytków rolnych oraz wartość przepływu pieniężnego I (patrz tabela 9).


**Tabela 9. Zbilansowanie zbiorów (dla wartości wskaźnika rezultatu w 2012 r.)**

Cecha gospodarstwa rolnego	Przed łączeniem			Po łączeniu		
	$\bar{x}_T$	$\bar{x}_C$	Standaryzowana różnica średnich	$\bar{x}_T$	$\bar{x}_C$	Standaryzowana różnica średnich
Powierzchnia użytków rolnych (w ha)	45,8	31,5	30,0	45,8	45,8	0,6
Przepływ pieniężny I (w tys. zł)	145,5	92,7	34,4	145,5	145,1	0,2

$\bar{x}_T$  – średnia w grupie eksperymentalnej,  $\bar{x}_C$  – średnia w grupie niepoddanej oddziaływaniu lub kontrolnej.

Źródło: opracowanie własne.

**Rysunek 41. Standaryzowana różnica średnich (dla wartości wskaźnika rezultatu w 2012 r.)**



Źródło: opracowanie własne.

Wśród gospodarstw, które otrzymały dopłaty do inwestycji, przeciętna powierzchnia użytkowanej rolniczo ziemi wynosiła 45,8 ha. W pozostałych gospodarstwach wielkość ta kształtowała się natomiast na poziomie 31,5 ha. Uśredniona wartość przepływu pieniężnego I dla gospodarstw poddanych oddziaływaniu wyniosła 145,5 tys. zł, a w pozostałych gospodarstwach 92,7 tys. zł. Wyliczona standaryzowana różnica średnich wskazuje, że przed zastosowaniem łączenia obserwacji, grupa poddana i niepoddana oddziaływaniu różniły się między sobą głównie pod względem wartości przepływu pieniężnego I (patrz rysunek 41).



W okresie 2011-2013, gospodarstwa łączono natomiast na podstawie ich specjalizacji, wykształcenia rolnika, wielkości zużycia wewnętrznego, wartości inwestycji netto i przepływu pieniężnego I oraz wysokości dopłat dotyczących działalności operacyjnej gospodarstwa (patrz tabela 10).

**Tabela 10. Zbilansowanie zbiorów (dla wartości wskaźnika rezultatu w 2013 r.)**

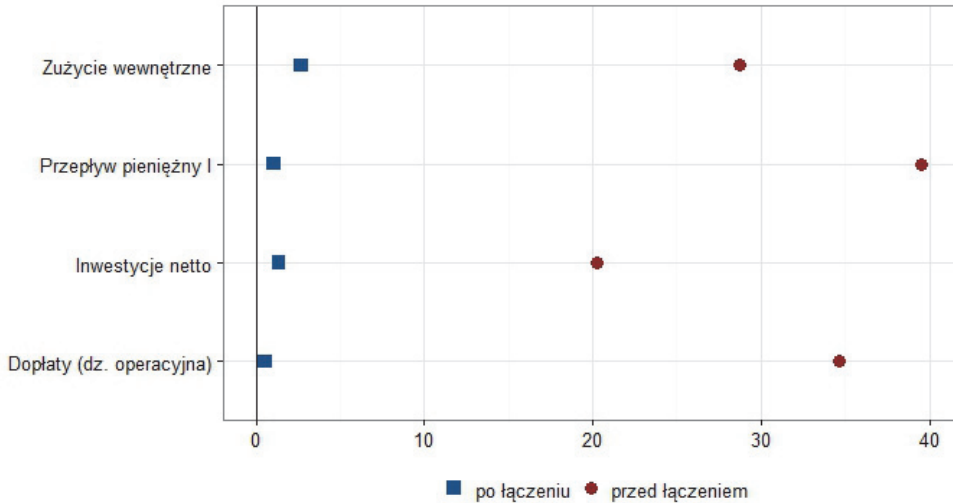
Cecha gospodarstwa rolnego	Przed łączeniem			Po łączeniu		
	$\bar{x}_T$	$\bar{x}_C$	Standaryzowana różnica średnich	$\bar{x}_T$	$\bar{x}_C$	Standaryzowana różnica średnich
Zużycie wewnętrzne (w tys. zł)	38,9	24,2	28,7	38,9	37,5	2,7
Inwestycje netto (w tys. zł)	33,7	3,5	20,3	33,7	31,7	1,3
Przepływ pieniężny I (w tys. zł)	168,2	100,8	39,6	168,2	166,4	1,0
Dopłaty (dz. operacyjna) (w tys. zł)	61,5	39,5	34,7	61,5	61,2	0,5

$\bar{x}_T$  – średnia w grupie eksperymentalnej,  $\bar{x}_C$  – średnia w grupie niepoddanej oddziaływaniu lub kontrolnej.

Źródło: opracowanie własne.

W gospodarstwach rolnych będących beneficjentami wsparcia dla inwestycji wytworzono i zużyto produkty pochodzenia roślinnego i zwierzęcego o wartości średnio 38,9 tys. zł. Inwestycje w ujęciu netto wyniosły przeciętnie 33,7 tys. zł, natomiast wartość przepływu pieniężnego I ukształtowała się na poziomie 168,2 tys. zł. W rok przed otrzymaniem wsparcia dla inwestycji gospodarstwa te otrzymały dopłaty na ich działalność operacyjną w wysokości średnio 61,5 tys. zł. W pozostałych gospodarstwach z kolei przeciętne zużycie wewnętrzne wyniosło 24,2 tys. zł, inwestycje netto 3,5 tys. zł, przepływ pieniężny I 100,8 tys. zł, a dopłaty w ramach działalności operacyjnej 39,5 tys. zł. Różnica między grupami gospodarstw, które otrzymały i nie otrzymały dopłat do inwestycji, wynikała zatem przede wszystkim z wartości przepływu pieniężnego I (patrz rysunek 42).

**Rysunek 42. Standaryzowana różnica średnich (dla wartości wskaźnika rezultatu w 2013 r.)**



Źródło: opracowanie własne.

W rezultacie łączenia standaryzowane różnice wyraźnie zmniejszyły się, osiągając pożądane wartości bliskie zeru. Dla każdego z analizowanych okresów uzyskano zatem wektory bilansujące rozkład cech w grupie eksperymentalnej i kontrolnej (patrz załącznik 1).

W tabeli 11 pokazano oszacowania wpływu otrzymania dopłat do inwestycji na wydajność czynnika pracy metodą łączenia 1-1 według wektora prawdopodobieństwa poddania oddziaływaniu.

**Tabela 11. Oszacowania ATT dla GVA/AWU**

Rok	2008	2009	2010	2011	2012	2013
Oszacowanie ATT	-1844,1	976,28	-352,37	-759,23	-3121,4	-1945,5
Odchylenie standardowe oszacowania ATT	910,52	938,38	1272,2	1424	1657,9	1618,4
p-value	0,043	0,298	0,782	0,594	0,060	0,229

Źródło: opracowanie własne.

Wyniki pokazują, że jedynie dla okresu 2006-2008 różnica w wydajności czynnika pracy między gospodarstwami, które otrzymały i nie otrzymały wsparcia dla inwestycji była znaczna. Wówczas, w efekcie uzyskania dotacji gospodarstwo osiągało wydajność czynnika pracy przeciętnie niższą o 1844,1 zł/AWU i wynik ten był istotny statystycznie. W stosunku do gospodarstw rolnych niebędących beneficjentami wsparcia, najwyższy przeciętny efekt dopłat (ATT) odnotowano w latach 2007-2009, natomiast najniższy w latach 2010-2012. W 2009 r. zaobserwowano wyższą wydajność czynnika pracy o 976,23 zł/AWU, z kolei w 2012 r. niższą o 3121,4 zł/AWU.

Jak wskazują wartości p-value, przy poziomie istotności  $\alpha = 0,05$  należy uznać, że wyniki te nie były istotne statystycznie, co bezpośrednio wynika z wysokich błędów standardowych szacunków. Niemniej jednak, ze względu na ujemne efekty dopłat na wartość dodaną (GVA/AWU), sprawdzono wielkość efektu wsparcia inwestycji na roczną zmianę wydajności czynnika pracy (patrz tabela 12)<sup>41</sup>.

**Tabela 12. Oszacowania ATT dla zmiany GVA/AWU**

Rok \	2008	2009	2010	2011	2012	2013
Oszacowanie ATT	-0,013	0,093	0,137	0,171	0,106	0,22401
Odchylenie standardowe oszacowania ATT	0,027	0,102	0,169	0,101	0,092	0,28635
p-value	0,635	0,363	0,419	0,091	0,248	0,43404

*Źródło: opracowanie własne.*

Wyniki wskazują, iż gospodarstwa rolne otrzymujące dopłaty do inwestycji notowały w kolejnych latach coraz wyższy względny przyrost wydajności czynnika pracy. Wyjątek stanowił jedynie 2012 r. Co więcej, nie licząc 2008 r., wyższy wzrost wydajności czynnika pracy występował w gospodarstwach, które dostały dopłaty do inwestycji. Największa różnica wystąpiła w 2013 r., kiedy to w gospodarstwach rolnych otrzymujących wsparcie, przyrost wartości dodanej (GVA/AWU) był o około 22 punkty procentowe wyższy niż w gospodarstwach niebędących beneficjentami wsparcia.

<sup>41</sup> Ponownie przyjęto, iż pewien zbiór cech z roku  $t$  będzie wpływał na prawdopodobieństwo otrzymania dopłat do inwestycji w roku  $t+1$ , których efektem będzie roczny przyrost wskaźnika rezultatu w roku  $t+2$ .

Ponownie, przyjmując  $\alpha = 0,05$ , oszacowania efektu oddziaływania wobec jednostek poddanych oddziaływaniu okazały się nieistotne statystycznie, co wynikało z relatywnie wysokich błędów standardowych tych oszacowań.

## Podsumowanie

W prezentowanej monografii poruszono kwestię roli inwestycji w kreowaniu zmian wydajności czynnika pracy w gospodarstwach rolnych. Podjęto próbę pomiaru efektu oddziaływania wsparcia inwestycji w ramach instrumentów polityki rolnej na wartość dodaną w przeliczeniu na jednostkę pracy. Przedstawiono wprowadzenie teoretyczne do narzędzi analizy statystycznej służących kwantyfikacji tego wpływu oraz zaprezentowano ich zastosowanie w oparciu o dane historyczne.

Dobór narzędzi statystyczno-ekonometrycznych, pozwalających na wyodrębnienie egzogenicznego czynnika odpowiedzialnego za zmianę wartości badanego wskaźnika wydaje się być zadaniem nietrywialnym. Badacz musi bowiem wyodrębnić tzw. rzeczywisty związek przyczynowo-skutkowy, a więc musi niejako prowadzić rozważania analogicznie do zasady *ceteris paribus*.

Najprostszym sposobem prowadzenia analizy skoncentrowanej na zależności poszczególnych zjawisk wydaje się być zastosowanie metod regresji. Pewną słabością tej metody jest jednak konieczność przyjęcia założenia odnośnie postaci funkcyjnej modelu, co zwykle nie jest możliwe do ustalenia *a priori*. Drugą kategorią metod oceny wpływu są tzw. metody naiwne, bazujące na prostych porównaniach wartości badanego wskaźnika bezpośrednio w grupie jednostek poddanych i niepoddanych oddziaływaniu. Podejście to, podobnie jak poprzednie, wiąże się z koniecznością przyjęcia założenia o stałości pozostałych cech wpływających na badany wskaźnik i wynikającej z nich jednakowości kształtowania się zmiennej wynikowej w hipotetycznym przypadku braku występowania interwencji w obu grupach.

Wobec utrudnień pojawiających się w związku z potencjalnym zastosowaniem do oceny wpływu modeli regresji, w literaturze do tego typu badań rekomenduje się podejście kontrfaktyczne, w szczególności zastosowaną w niniejszej pracy metodę łączenia według prawdopodobieństwa (*propensity score matching*). Podejście bazuje na tzw. analizie stanów kontrfaktycznych, a więc przyjęciu pewnych potencjalnych, hipotetycznych rezultatów możliwych do osiągnięcia, gdyby stan poddania danego obiektu oddziaływaniu był inny niż zaobserwowany. Wyznaczenie stanu kontrfaktycznego dla jednostki poddanej oddziaływaniu odbywa się poprzez znalezienie jej odpowiednika – pod względem wybranych obserwowalnych charakterystyk – w grupie jednostek, które oddziaływania danego czynnika nie doświadczyły.

W oparciu o dane historyczne zaprezentowano wstępne wyniki działania algorytmu. Badanie podzielono na sześć okresów, przyjmując założenie, że pewne cechy gospodarstwa z roku  $t$  będą wpływać na otrzymanie dopłat do in-

westycji w roku  $t+1$ , których wynikiem będzie wartość wskaźnika rezultatu (wydajności czynnika pracy) w roku  $t+2$ . Wyniki analizy wskazały, że o ile efekt oddziaływania dopłat do inwestycji na poziom wydajności czynnika pracy w grupie gospodarstw będących beneficjentami tego wsparcia był (zwykle) ujemny, to już efekt oddziaływania tego wsparcia na roczny przyrost wydajności był dodatni. Należy jednak pokreślić, że ze względu na wysokie błędy standardowe szacunków, różnice między grupą poddaną a niepoddaną oddziaływaniu nie były znaczące. Biorąc pod uwagę, iż analizowano instrument polityki, którego celem *explicite* nie było wsparcie wydajności pracy w gospodarstwach rolnych w uwzględnionym okresie, wynik ten wydaje się być uzasadniony.

## Bibliografia

1. Amemiya T., *Qualitative Response Models: A Survey*, Journal of Economic Literature, vol. XIX, 1981, s. 1483-1536.
2. Auerbach A.J., Kotlikoff L.J., *Macroeconomics – An Integrated Approach (2nd Edition)*, MIT Press, Cambridge 1998.
3. Bartkowiak R., *Historia myśli ekonomicznej*, wydanie II zmienione, PWE, Warszawa 2008.
4. Bowler I.R., *Agriculture Under the Common Agricultural Policy: A Geography*, Manchester University Press, Manchester 1985.
5. Caliendo M., *Microeconomic Evaluation of Labour Market Policies*, Springer Science & Business Media, Berlin 2006.
6. Cameron R., Neal L., *Historia gospodarcza świata od paleolitu do czasów najnowszych*, Książka i Wiedza, Warszawa 2004.
7. Cragg J.G., Uhler R.S., *The demand for automobiles*, Canadian Journal of Economics, vol. 3, 1970, s. 386-406.
8. Diamond A., Sekhon J.S., *Genetic Matching for Estimating Causal Effects: A General Multivariate Matching Method for Achieving Balance in Observational Studies*, Review of Economics and Statistics, vol. 95, no. 3, 2013, s. 932-945.
9. Dorward A., *Agricultural labour productivity, food prices and sustainable development impacts and indicators*, Food Policy, vol. 39, 2013, s. 40-50.
10. Faraone S.V., *Interpreting Estimates of Treatment Effects. Implications for Managed Care*, Pharmacy and Therapeutics, Vol. 33, No. 12, 2008, s. 700-711.
11. Fisher R.A., *On the Mathematical Foundations of Theoretical Statistics*, Philosophical Transactions of the Royal Society, vol. 222, 1922, s. 309-68.
12. Floriańczyk Z., Osuch D., Płonka R., *Wyniki Standardowe 2014 uzyskane przez gospodarstwa rolne uczestniczące w Polskim FADN. Część I. Wyniki Standardowe*, IERiGŻ-PIB, Warszawa 2015.
13. Gruszczyński M., *Modele zmiennych jakościowych dwumianowych*, [w:] *Mikroekonometria. Modele i metody analizy danych indywidualnych*, pr. zbior. pod red. M. Gruszczyński, Wydawnictwo Wolters Kluwer, Warszawa 2012, s. 71-122.
14. Gruszczyński M., Podgórska M., *Ekonometria*, Szkoła Główna Handlowa w Warszawie – Oficyna Wydawnicza, Warszawa 2003.

15. Gruszczyński M., Kuszewski T., Podgórska M., *Ekonometria i badania operacyjne. Podręcznik dla studiów licencjackich*, Wydawnictwo Naukowe PWN, Warszawa 2009.
16. Guo S., Fraser M.W., *Propensity score analysis. Statistical methods and applications*, SAGE Publications, Thousand Oaks 2015.
17. Harańczyk G., *Krzywe ROC, czyli ocena jakości klasyfikatora i poszukiwanie optymalnego punktu odcięcia*, StatSoft Polska, 2010, s. 79-89, [http://www.statsoft.pl/Portals/0/Downloads/Krzywe\\_ROC\\_czyli\\_ocena\\_jakosci.pdf](http://www.statsoft.pl/Portals/0/Downloads/Krzywe_ROC_czyli_ocena_jakosci.pdf)
18. Harrel F.E., *Regression Modeling Strategies With Applications to Linear Models, Logistic Regression, and Survival Analysis*, Springer Series in Statistics, Springer, New York 2001.
19. Heckman J., Ichimura H., Todd P., *Matching as an Econometric Evaluation Estimator: Evidence from Evaluating a Job Training Program*, *The Review of Economic Studies*, vol. 64, no. 4, 1997, s. 605-654.
20. Heckman J., Vytlačil E., *Econometric Evaluation of Social Programs, Part I: Casual Models, Structural Models and Policy Evaluation*, [w:] *Handbook of Econometrics*, pr. zbior. pod red. J. Heckman, E. Leamer, t. 6B, Elsevier, Amsterdam 2007, s. 4779-4874.
21. Holmes W.M., *Using Propensity Scores in Quasi-Experimental Designs*, SAGE Publications, Thousand Oaks 2014.
22. *Investment Support under Rural Development Policy*, European Commission, Final Report, 2014, [http://ec.europa.eu/agriculture/evaluation/rural-development-reports/2014/investment-support-rdp/fulltext\\_en.pdf](http://ec.europa.eu/agriculture/evaluation/rural-development-reports/2014/investment-support-rdp/fulltext_en.pdf)
23. Kleinbaum D.G., Klein M., *Logistic Regression. A Self-Learning Text, Statistics for Biology and Health*, Springer, New York 2010.
24. Kopiński A., Porębski D., *Zastosowanie metody Hellwiga do konstrukcji modelu ekonometrycznego dla stóp zwrotu funduszy inwestycyjnych*, *Annales Universitatis Mariae Curie-Skłodowska Lublin-Polonia, Sectio H.*, vol. XLVIII, no. 3, 2014, s. 147-156.
25. Lazarsfeld P.F., *Problems in methodology*, [w:] *Sociology today: Problems and prospects*, pr. zbior. pod red. R.K. Merton, L. Broom, L.S. Cottrell Jr., vol. 1, New York 1959, s. 39-72.
26. Lazzarini A., *The Cambridge Capital Controversy In Historical Perspective And Some Un Settled Analytical Issues*, artykuł na podstawie rozprawy doktorskiej obronionej w Università degli Studi Roma Tre w 2008 r., <http://pendientedemigracion.ucm.es/centros/cont/descargas/documento18933.pdf>






27. Leontief W.W., *Quantitative input and output relations in the economic system of the United States*, The Review of Economics and Statistics, vol. 18, no. 3, 1936, s. 105-125.
28. Maddala G.S., *Limited dependent and qualitative variables in econometrics*, Cambridge University Press, Cambridge 1983.
29. Maddala G.S., *Ekonometria*, Wydawnictwo Naukowe PWN, Warszawa 2008.
30. McFadden D.L., *Conditional logit analysis of qualitative choice behaviour*, [w:] *Frontiers in econometrics*, pr. zbior. pod red. P. Zarembka, Academic Press, New York 1974, s. 105-142.
31. McKelvey R.D., Zavoina W., *A statistical model for the analysis of ordinal level dependent variables*, Journal of Mathematical Sociology, vol. 4, iss. 1, 1975, s. 103-120.
32. Michalek J., 2012a, *Counterfactual impact evaluation of EU rural development programmes – Propensity Score Matching methodology applied to selected EU Member States. Volume 1: A micro-level approach*, European Commission, Joint Research Centre, Institute for Prospective Technological Studies, Luxembourg 2012.
33. Michalek J., 2012b, *Counterfactual impact evaluation of EU rural development programmes – Propensity Score Matching methodology applied to selected EU Member States. Volume 2: A regional approach*, European Commission, Joint Research Centre, Institute for Prospective Technological Studies, Luxembourg 2012.
34. Mickiewicz A., Wawrzyniak B.M., *Przebieg i realizacja działania „Modernizacja gospodarstw rolnych” w ramach PROW na lata 2007–2013*, Zeszyty Naukowe SGGW - Ekonomia i Organizacja Gospodarki Żywnościowej, nr 86, 2010, s. 55-67.
35. Mundlak Y., Butzer R., Larson D.F., *Heterogeneous technology and panel data: The case of the agricultural production function*, Journal of Development Economics, vol. 99, iss. 1, 2012, s. 139-149.
36. Neyman J., *O zastosowaniu teorii prawdopodobieństwa do eksperymentów rolniczych. Eseje o regulach. Część 9*, Roczniki Nauk Rolniczych, nr X, 1923, s. 1-51.
37. Olejniczak K., *Teoretyczne podstawy ewaluacji ex-post*, [w:] A. Haber (red.) *Ewaluacja ex-post. Teoria i praktyka badawcza*, Polska Agencja Rozwoju Przedsiębiorczości, Warszawa 2007, s. 15-41.
38. Pan W., Bai H. (eds.), *Propensity Score Analysis. Fundamentals and development*, The Guilford Press, New York 2015.


39. Paśko Ł., Setlak G., *Wpływ wybranych metryk na wynik badania skupisk*, *Studia Informatica*, vol. 36, no. 1 (119), 2015, s. 31-45.
40. Patra S., Nayak S.R., *A theoretical study on the relationship between wages and labor productivity in industries*, *International Journal of Economics and Research*, vol. 3, iss. 3, 2012, s. 157-163.
41. Perkins S.M., Tu W., Underhill M.G., Zhou X.-H., Murray M.D., *The use of propensity scores in pharmacoepidemiologic research*, *Pharmacoepidemiology and Drug Safety*, vol. 9, 2000, s. 93-101.
42. Pratt J.W., *Concavity in the Log-Likelihood*, *Journal of the American Statistical Association*, vol. 76, 1981, s. 137-159.
43. *Program Rozwoju Obszarów Wiejskich na lata 2007-2013*, Ministerstwo Rolnictwa i Rozwoju Wsi, Warszawa 2016.
44. Quandt R., *A New Approach to Estimating Switching Regressions*, *Journal of the American Statistical Association*, vol. 67, no. 338, 1972, s. 306-310.
45. Rembisz W., Floriańczyk Z., *Modele wzrostu gospodarczego w rolnictwie*, IERiGŻ-PIB, Warszawa 2014.
46. Rembisz W., Sielska A., *Wybrane wskaźniki ekonomiczne w rolnictwie jako skutek długookresowej polityki rolnej i uwarunkowań popytowych*, *Program Wieloletni 2011-2014*, nr 133, IERiGŻ-PIB, Warszawa 2014a.
47. Rembisz W., Sielska A., *Renta polityczna a inwestycje oraz relacje wynagrodzenia i wydajności czynnika pracy u producentów rolnych [w:] WPR a konkurencyjność polskiego i europejskiego sektora żywnościowego*, pr. zbior. pod red. A. Kowalski, M. Wigier, B. Wieliczko, *Program Wieloletni 2011-2014*, nr 146, IERiGŻ-PIB, Warszawa 2014b, s. 15-27.
48. Rembisz W., Sielska A., *Mikroekonomia współczesna*, Vizja Press & IT, Warszawa 2015.
49. *Rocznik Statystyczny Rzeczypospolitej Polskiej*, GUS, Warszawa 2014.
50. Rosenbaum P.R., Rubin D.B., *The central role of the propensity score in observational studies for causal effects*, *Biometrika*, vol. 70, no. 1, 1983, s. 41-55.
51. Roy A.D., *Some thoughts on the distribution of earnings*, *Oxford Economic Papers. New Series*, vol. 3, no. 2, 1951, s. 135-146.
52. Rubin D., *Matching to Remove Bias in Observational Studies*, *Biometrics*, vol. 29, 1973, s. 159-183.
53. Sekhon J.S., *Multivariate and Propensity Score Matching Software with Automated Balance Optimization: The Matching Package for R*, *Journal of Statistical Software*, vol. 42, no. 7, 2011, s. 1-52.

54. Sielska A., Kuszewski T., Pawłowska A., Bocian M., *Wpływ polityki rolnej na kształtowanie się wartości dodanej*, Program Wieloletni 2015-2019, nr 9, IERiGŻ-PIB, Warszawa 2015.
55. Strawiński P., *Łączenie danych z dynamicznym obciążeniem. Wyniki wstępne*, Metody Ilościowe w Badaniach Ekonomicznych, t. 10, z. 1, 2009, s. 232-242.
56. Strawiński P., *Propensity score matching. Własności małopróbkowe*, Wydawnictwo Uniwersytetu Warszawskiego, Warszawa 2014.
57. Stürmer T., Joshi M., Glynn R.J., Avorn J., Rothman K.J., Schneeweiss S., *A review of the application of propensity score methods yielded increasing use, advantages in specific settings, but not substantially different estimates compared with conventional multivariable methods*, Journal of Clinical Epidemiology, vol. 59, no. 5, 2006, s. 437-447.
58. Szulc A., *Ocena efektu oddziaływania: estymacja przez dopasowanie*, [w:] *Mikroekonometria. Modele i metody analizy danych indywidualnych*, pr. zbior. pod red. M. Gruszczyński, Wydawnictwo Wolters Kluwer, Warszawa 2012, s. 309-336.
59. Trzeciński R., *Wykorzystanie techniki propensity score matching w badaniach ewaluacyjnych*, Polska Agencja Rozwoju Przedsiębiorczości, Warszawa 2009.
60. Weitzen S., Lapane K.L., Toledano A.Y., Hume A.L., Mor V., *Principles for modeling propensity scores in medical research: a systematic literature review*, Pharmacoepidemiology and Drug Safety, vol. 13, 2004, s. 841-853.
61. Wells R., Krugman P., *Makroekonomia*, Wydawnictwo Naukowe PWN, Warszawa 2012.
62. Wojtyła A., *Przyczyny i implikacje zmian w udziale zysków i płac w PKB*, Gospodarka Narodowa, Nr 9, 2009, s. 49-66.
63. Vittinghoff E., Glidden D.V., Shiboski S.C., McCulloch C.E., *Regression Methods in Biostatistics. Linear, Logistic, Survival, and Repeated Measures Models*, Springer, New York 2005.
64. Zegar J.S., *Współczesne wyzwania rolnictwa*, Wydawnictwo Naukowe PWN, Warszawa 2012.
65. Zhang H., Singer B., *Recursive Partitioning in the Health Sciences*, Springer, New York 1999.
66. Zieliński M., Sobierajewska J., Mirkowska Z., Osuch D., *Ekspertyza pt. Wyznaczenie wartości dodanej brutto dla gospodarstw korzystających z pomocy w ramach PROW 2007-2013*, Zamawiający: Ministerstwo Rolnictwa i Rozwoju Wsi, Wykonawca: IERiGŻ-PIB, Grudzień 2011.



## Załącznik 1. Rozkład obserwowalnych charakterystyk


Wartość wskaźnika rezultatu w 2008 r.








Wartość wskaźnika rezultatu w 2009 r.








Wartość wskaźnika rezultatu w 2010 r.







Wartość wskaźnika rezultatu w 2011 r.








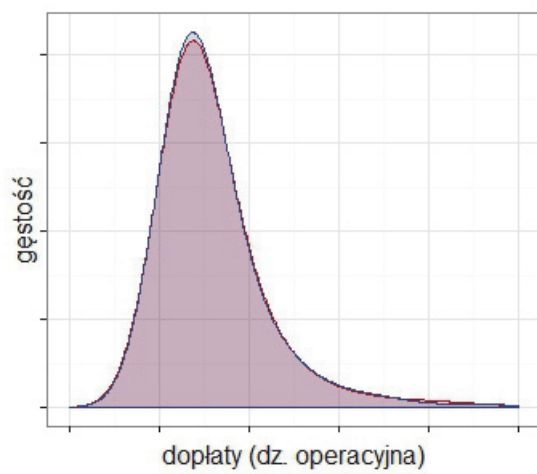
Wartość wskaźnika rezultatu w 2012 r.





### Wartość wskaźnika rezultatu w 2013 r.





*Źródło: opracowanie własne.*



**EGZEMPLARZ BEZPŁATNY**

*Nakład 800 egz., ark. wyd. 6,5  
Druk i oprawa: EXPOL Włocławek*