

# Analiza przyczynowa poza metodą eksperymentalną. Dwa przykłady modeli przyczynowych wykraczających poza schemat eksperymentalny (wraz z rozwiązaniami statystycznymi)

Mariusz Trejtowicz, Katarzyna Jaśko

*Instytut Psychologii, Uniwersytet Jagielloński*

Celem artykułu jest omówienie dwóch problemów wnioskowania przyczynowego, w których interesujące zagadnienia teoretyczne wykluczają możliwość ustalenia przyczynowości w oparciu o skuteczność manipulacji realizowanej w ramach schematu eksperymentalnego. Pierwszy problem dotyczy analizy procesu przyczynowego, którego znanym w psychologii przykładem jest analiza mediacji. W kontekście analizy procesu przyczynowego szczególnie nacisk położony jest na analizę interpretacji efektów bezpośrednich, całkowitych oraz pośrednich w wynikach Modelu Równań Strukturalnych. Drugi problem odnosi się do przyczynowego uwikłania zmiennej zależnej we własny model wyjaśniający. Oszacowanie parametrów modelu przyczynowego możliwe jest z wykorzystaniem Mieszanego Modelu Liniowego.

*Słowa kluczowe:* przyczynowość, modelowanie przyczynowe, analiza procesu przyczynowego, analiza mediacji, modelowanie równań strukturalnych, Mieszany Model Liniowy, statystyka, metodologia

## Wprowadzenie

Analiza przyczynowa w nauce związana jest przede wszystkim z badaniami eksperymentalnymi. Badania eksperymentalne uważane są za złoty standard metodologii badań naukowych, jedyną metodę pozwalającą na pełną kontrolę zmiennej niezależnej i – co za tym idzie – pewne wnioskowanie o zależnościach przyczynowych. Metoda eksperymentalna ma jednak również pewne ograniczenia. Pomijając najłatwiej nasuwające się zastrzeżenia co do reprezentatywności prób w eksperymentach psychologicznych, wskazuje się na problemy wynikające z braku możliwości manipulacji wieloma interesującymi nas zmiennymi. Niemożliwe jest skłonienie ludzi do kon-

wersji religijnej, wstąpienia do sekty, zmiany płci, zmiany poglądów politycznych, zdobycia określonego poziomu wykształcenia, rozszerzenia lub zawężenia grupy bliskich przyjaciół. Naruszeniem klasycznego schematu eksperymentu jest także brak grupy kontrolnej, której uwzględnienie w części badań nie jest możliwe lub ewentualne wyniki uzyskane w tej grupie byłyby trudne do interpretacji. Innym ograniczeniem metody eksperymentalnej jest występowanie zakłóceń ze strony nieobserwowanych zmiennych lub ze strony umiejscowienia pomiaru na osi czasu, przed którymi nie zawsze uchroni nas precyzyjnie przemyślana manipulacja eksperymentalna czy restrykcyjna metodologia (McDonald, 2009). Omówienie tego rodzaju problemów metody eksperymentalnej nie jest tu jednak naszym celem. Uważamy, że dla większości z nich najlepszym rozwiązaniem jest doskonalenie procedury badawczej, zwiększanie trafności manipulacji oraz zmodyfikowane autoreplikacje (Wojciszke, 2004) prowadzące do nowych ustaleń empirycznych.

Analiza przyczynowa nie powinna być jednak utożsamiana wyłącznie z metodą eksperymentalną. Niektóre problemy analizy przyczynowej nie są możliwe do zreali-

---

Trejtowicz Mariusz, Instytut Psychologii, Uniwersytet Jagielloński, al. Mickiewicza 3, 31–120 Kraków,

e-mail: mariusz.trejtowicz@uj.edu.pl

Katarzyna Jaśko, Instytut Psychologii, Uniwersytet Jagielloński, al. Mickiewicza 3, 31–120 Kraków,

e-mail: katarzyna.jasko@uj.edu.pl

Korespondencję prosimy kierować na adres:

mariusz.trejtowicz@uj.edu.pl

zowania w ramach schematu eksperymentalnego, ponieważ manipulacja eksperymentalna kluczowymi zmiennymi wyjaśniającymi jest w nich logicznie niemożliwa do przeprowadzenia. W rezultacie nie ma ostrej różnicy pomiędzy wnioskowaniem przyczynowym na podstawie danych eksperymentalnych i danych korelacyjnych.

W artykule tym przedstawimy dwa przykłady problemów z zakresu analizy przyczynowej, w której zastosowanie czystego schematu eksperymentalnego do ustalenia przyczynowości staje się logicznie niemożliwe. Pierwszy z nich, obrazujący niemożność równoczesnej manipulacji powiązanych ze sobą zmiennymi niezależnymi, powinien być Czytelnikowi znany. Proponować będziemy jednak przyjrzenie się mu z nieco innej perspektywy, aniżeli jest on zwyczajowo omawiany. Drugi problem, związany z przyczynowym uwikłaniem zmiennej zależnej w swój własny model wyjaśniający, może stanowić nowość.

### **Problem 1. Analiza mediacji jako przykład logicznej niewykonalności manipulacji eksperymentalnej**

Analiza mediacji jest często wykorzystywanym modelem badań (Baron i Kenny, 1986; Hayes, 2009; MacKinnon, Fairchild i Fritz, 2007; Preacher i Hayes, 2008; Shrout i Bolger, 2002). Istotą hipotezy mediacyjnej jest wskazanie trzeciej zmiennej, która w całości lub częściowo pośredniczy w relacji przyczynowej pomiędzy zmienną niezależną a zmienną zależną, będącymi przedmiotem zainteresowania badacza. Popularność analizy mediacji w psychologii jest zrozumiała. Sens paradygmatu poznawczego sprowadza się wręcz do hipotezy mediacji wpływu przyczynowego bodźców z otoczenia na zachowanie poprzez procesy poznawcze. Naukowe myślenie o zachowaniu człowieka w naturalny sposób odwołuje się do procesów przyczynowych przebiegających przez różne zmienne z poziomu poznawczego, osobowościowego czy emocjonalnego.

Z perspektywy procedury statystycznej analiza mediacji sprowadza się do wykazania, że istniejąca pomiędzy zmienną niezależną a zmienną zależną korelacja rzędu zerowego całkowicie znika (lub co najmniej znacząco się zmniejsza) po wprowadzeniu do analizy trzeciej zmiennej. Jeśli uprawnione są stwierdzenia, że zmiana w zmiennej niezależnej jest przyczyną zmiany mediatora oraz że zmiana mediatora jest przyczyną zmiany zmiennej zależnej, mówimy o pośrednim efekcie przyczynowym i mediacji. Oryginalna, oparta na sekwencji modeli regresji procedura Barona i Kenny'ego została poddana dyskusji i wysunięte zostały zarzuty dotyczące w szczególności braku testu statystycznego efektu mediacji. Zaproponowano modyfikacje procedury mające na celu uzupełnienie tego braku: test Sobela, szacowanie przedziałów ufności efek-

tu pośredniego metodą *bootstrap*. Szczegółowe omówienie metody oraz bieżącej dyskusji znajdzie Czytelnik na przykład w artykule Preachera i Hayesa (2004). Naszym celem jest przyjrzenie się analizie mediacji z nieco innej perspektywy.

Analiza mediacji, w rezultacie specjalnego statusu mediatora, stanowi odejście od wzorca wnioskowania przyczynowego opartego na wyniku manipulacji eksperymentalnej. Zmienna niezależna w schemacie analizy mediacji może być manipulowana. Próba równoczesnej manipulacji zmienną niezależną oraz mediatorem, który jest zarówno zmienną zależną, jak i zmienną niezależną, prowadziłaby jednak do niekontrolowanych zakłóceń lub zmiany istoty modelu badawczego. W związku z tym hipoteza mediacyjna w nieunikniony sposób zawsze jest testowana w oparciu o korelacyjne ustalenie badawcze. Dla postawienia strzałki przyczynowej o określonym kierunku niezbędne jest dodatkowe uzasadnienie. Optymalnym rozwiązaniem jest sytuacja, w której dysponujemy danymi eksperymentalnymi (lub innymi wynikami badawczymi) dowodzącymi związku przyczynowego pomiędzy mediatorem a zmienną zależną i nie ma przesłanek dla założenia równoczesnego odwrotnego kierunku związku przyczynowego, czyli wpływu zmiennej zależnej na mediatora.

Czy z perspektywy wnioskowania przyczynowego manipulacja zmienną niezależną w badaniu mającym na celu ustalenie pośredniczącego mechanizmu przyczynowego dostarcza istotnej wartości? Jeśli dysponujemy co najmniej równie mocnymi przesłankami dla założenia kierunku przyczynowości pomiędzy zmienną niezależną a mediatorem (a w przypadku mediacji częściowej również pomiędzy zmienną niezależną a zmienną zależną), nie ma podstaw, by tak twierdzić. Już zatem w modelu przyczynowym uwzględniającym relacje pomiędzy trzema zmiennymi rozmywa się z perspektywy wnioskowania przyczynowego różnica pomiędzy danymi eksperymentalnymi i danymi korelacyjnymi. Przyznajemy, że pozostaje „praktyczna” różnica. Wnioskowanie przyczynowe w oparciu o dane korelacyjne, ze względu na większą liczbę relacji wymagających uzasadnienia na podstawie wiedzy dziedzinowej i poprzednich ustaleń badawczych, jest bardziej podatne na nadużycia oraz łatwiej może doprowadzić do błędnych wniosków. Błędne założenie kierunku strzałki przyczynowej w modelu ma jednak takie same konsekwencje niezależnie od tego, czy w schemacie badawczym mieliśmy zmienną manipulowaną, czy też dysponujemy danymi wyłącznie korelacyjnymi.

Skoro już w prostej analizie mediacji mamy do czynienia z wnioskowaniem przyczynowym na podstawie wyniku korelacyjnego, możliwości analiz przyczyno-

wych opartych na danych korelacyjnych z pewnością są warte uwagi. Tym bardziej że w ostatnim czasie rozwój metod zwiększających wiarygodność wnioskowania przyczynowego w oparciu o dane korelacyjne stanowi jeden z ciekawszych obszarów rozwoju metod statystycznych (Imbens i Wooldridge, 2007; Nichols, 2008; Rosenbaum, 2002; Winship i Morgan, 1999; stosowane w tym artykule pojęcie danych korelacyjnych oparte jest na tradycji metodologicznej psychologii, w cytowanej literaturze ekonometrycznej i statystycznej odpowiada mu termin: dane obserwacyjne). W ostatnich latach dla rozwoju tych metod duże znaczenie mają praktyczne problemy związane z ewaluacją skuteczności programów społecznych (Heckman i Vytlačil, 2007). Warte podkreślenia w tym kontekście jest również znaczenie teoretycznego osiągnięcia analizy przyczynowej, jakim jest ustalenie wystarczających kryteriów poprawnego wnioskowania o parametrach strukturalnego modelu przyczynowego (Pearl, 2000). Pozwala ono na lepszą identyfikację źródeł potencjalnych zakłóceń oszacowań parametrów modeli statystycznych.

Następny rozdział omawia przykład analizy procesu przyczynowego nieco bardziej rozbudowanego, aniżeli prosty przykład analizy mediacji (wpływ pośredni zakładany przez wiele zmiennych, kontrola zmiennych zakłócających). Przykład ten demonstruje typowe dla analizy przyczynowej problemy w interpretacji efektów bezpośrednich i pośrednich. Naturalnym środowiskiem dla testowania modeli przyczynowych są narzędzia do modelowania równań strukturalnych i przykład analityczny korzysta z tej metody statystycznej. Analiza przyczynowa oparta jest na danych korelacyjnych, pomimo to pozostawia niewiele wątpliwości co do kierunku relacji przyczynowo-skutkowych.

### **Przykład 1. Oszacowanie parametrów strukturalnego modelu przyczynowego**

Modelowanie równań strukturalnych (Kaplan, 2000) jest techniką statystyczną bazującą na testach dopasowania do danych modelu przyczynowego sformalizowanego w postaci ukierunkowanego grafu. Przykład analityczny, który przedstawiamy poniżej, został wykonany za pomocą oprogramowania Amos 17.0 (Arbuckle, 2006) firmy IBM SPSS. Wykorzystane dane odnoszą się do problemu wpływu płci na nierówności w wynagrodzeniu w pewnym przedsiębiorstwie. Analiza ma odpowiedzieć na pytanie, czy w przedsiębiorstwie tym mamy do czynienia z dyskryminacją płacową kobiet, a jeśli odpowiedź jest twierdząca, to jaka jest siła efektu dyskryminacji. Strukturalny model przyczynowy zakłada oddziaływanie czynnika płci przez szereg innych zmiennych związanych z szansami

zawodowymi kobiet (np. prawdopodobieństwo awansu na stanowisko menedżerskie).

Analizy opierają się na jednym z przykładowych plików danych oprogramowania IBM SPSS Statistics (znajdującym się w katalogu instalacji tego oprogramowania – w podkatalogu Examples; nazwa pliku: „Dane o zatrudnieniu.sav” lub *Employee data.sav* w wersji angielskiej). W tym miejscu zostały przedstawione kluczowe informacje dotyczące przykładu analitycznego oraz problemu interpretacji efektów bezpośrednich i pośrednich. Dane, kompletny opis wykonanych przekształceń oraz analiz (wraz ze zrzutami ekranowymi pozwalającymi na odtworzenie analiz w oprogramowaniu Amos) znajdują się na towarzyszącej artykułowi stronie internetowej <http://www.socialpsychologylab.eu/PS2010/>.

### **Model teoretyczny: zmienne w analizie**

W analizie uwzględniono pięć zmiennych. Zmienną niezależną jest *pleć pracownika*. Zmienna zależna, którą jest *aktualna płaca pracownika*, została zlogarytmizowana, aby znormalizować rozkład płac oraz doprowadzić relację pomiędzy zmiennymi wyjaśniającymi oraz zmienną zależną do liniowości. Logarytmizacja zmienia interpretację niestandardyzowanych wag regresji z kategorii zmian absolutnych do kategorii procentowych. Waga o wartości 0,04 interpretowana będzie jako przewidywanie przyrostu płacy o 4% z każdą zmianą zmiennej wyjaśniającej o jedną jednostkę. Logarytmizacja zmienia również interpretację wartości przewidywanej przez model dla kobiet i mężczyzn (ogólnie: dla kategorii zmiennych jakościowych w modelu). Średnia arytmetyczna logarytmów wartości pewnej zmiennej po przekształceniu wykładniczym, czyli odwróceniu logarytmizacji, stanowi średnią geometryczną wartości tej zmiennej. Przewidywane różnice procentowe dochodów mężczyzn i kobiet w modelu po logarytmizacji dochodu są zatem przewidywanymi różnicami procentowymi pomiędzy średnimi geometrycznymi rozkładów dochodów kobiet i mężczyzn. W przypadku rozkładu prawoskośnego, który wykazują dochody, średnia geometryczna jest lepszą miarą tendencji centralnej, aniżeli średnia arytmetyczna. Jest to zatem zmiana korzystna z perspektywy statystycznej. Warto jednak pamiętać o jej konsekwencjach interpretacyjnych. W prezentowanych danych przewidywana różnica 18% w modelu średniej geometrycznej odpowiada 36% przewidywanej różnicy dochodów w modelu średniej arytmetycznej.

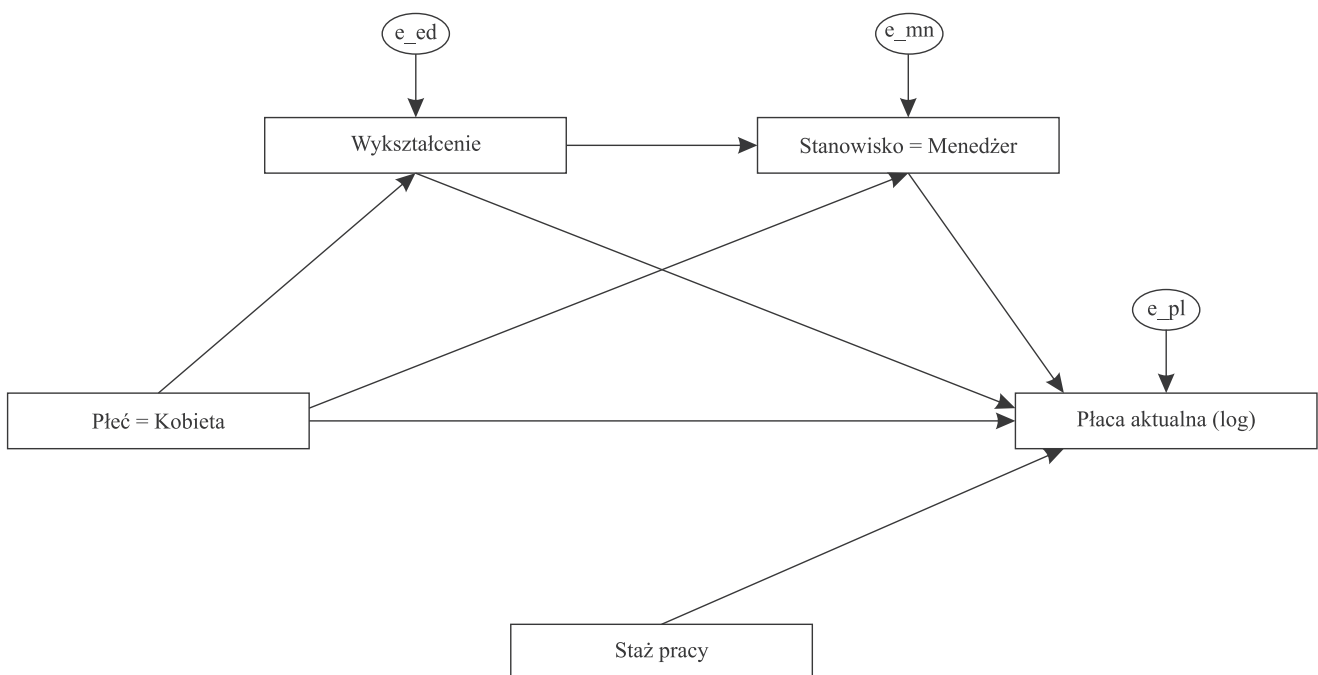
Założono dwa mechanizmy mediacji wpływu płci na wynagrodzenie. Pierwszy mechanizm mediacji zakłada, że kobiety różnią się od mężczyzn w zakresie nabytego *wykształcenia*, traktowanego jako wskaźnik kwalifikacji zawodowych (mierzone jako zmienna ilościowa w latach

nauki szkolnej). Dane pochodzą z lat 70. XX w. w USA i przeciętnie kobiety mają w tej próbie niższe wykształcenie (2 lata nauki szkolnej mniej); gdyby analizowana próba pochodziła z Polski, oczekiwalibyśmy raczej przeciętnie wyższego wykształcenia wśród kobiet. Drugi mechanizm mediacji przewiduje, że kobiety i mężczyźni mają różne *szanse awansu na stanowisko menedżerskie*, a zajmowane stanowisko pociąga za sobą różnice płac. Oprócz mechanizmów mediacji, założono także bezpośredni wpływ płci na płacę aktualną.

Ostatnia zmienna w analizie, *staż pracy*, wprowadzona została jako potencjalna zmienna zakłócająca. Układ relacji sprawia jednak, że jej uwzględnienie lub nie w modelu nie będzie w żaden sposób zmieniać relacji pomiędzy innymi zmiennymi (zmienna ta nie ma wpływu zakłócającego, jej kontrola nie jest potrzebna do poprawnego oszacowania pozostałych efektów). *Staż pracy* został uwzględniony po to, aby model miał kilka stopni swobody pozwalających nam na omówienie statystyk dopasowania modelu do danych, jego uwzględnienie ma zatem głównie cel dydaktyczny. Po wykluczeniu tej zmiennej mamy do czynienia z modelem wysyconym, dla którego ocena jakości modelu nieco się różni (model wysycony oraz omówienie tego zagadnienia znajduje się na stronie <http://www.socialpsychologylab.eu/PS2010/>).

Zakładane kierunki relacji przyczynowych pomiędzy zmiennymi wynikają z przebiegu procesu przyczynowego w czasie (nabyte wykształcenie poprzedza zatrudnienie, aktualna płaca zależy od wcześniejszego awansu zawodowego). Całość modelu teoretycznego przedstawia Rysunek 1.

Jeśli teoretyczny model przyczynowy jest trafny, czyli kierunek ścieżek przyczynowych został właściwie określony, model pozwala na (zgodne ze strukturą relacji przyczynowych rzeczywiście stojącą za danymi) oszacowanie dyskryminacji płacowej kobiet. Oszacowanie uwzględnia kontrolę wykształcenia pracownika, zróżnicowanych szans awansu na stanowisko menedżerskie oraz (zbędną) kontrolę stażu pracy. Model niekoniecznie oddaje w pełni zjawisko dyskryminacji płacowej kobiet w przedsiębiorstwie. Jeśli – na przykład – istnieje w tym przedsiębiorstwie dyskryminacja płciowa na etapie rekrutacji pracowników, możliwy wpływ zakłócający tego mechanizmu nie został uwzględniony. Dla dostępnych danych stanowi on możliwie najlepsze ujęcie wiedzy o procesie dyskryminacji. Z perspektywy analizy przyczynowej o wartości modelu stanowi możliwość udzielania na jego podstawie odpowiedzi na pytania kontrfaktyczne o konsekwencje pewnych zmian w danych.



Rysunek 1.  
Model teoretyczny wpływu płci na płacę.

### Analiza wyników krok po kroku

*Dopasowanie modelu.* Pierwszym krokiem analizy wyników modelowania strukturalnego jest przyjrzenie się statystykom dopasowania modelu (Tabela 1), które w raporcie wynikowym Amos można odnaleźć w grupie wyników *Model Fit*. Test chi-kwadrat (chi-kwadrat = 2,68,  $df = 3$ ,  $p = 0,444$ ) wskazuje, że nie ma statystycznie istotnej różnicy pomiędzy strukturą momentów statystycznych (kowariancji i średnich) oczekiwaną przez model statystyczny i strukturą obserwowaną w danych. Oprócz wartości testu chi-kwadrat, raport z modelowania strukturalnego powinien zawierać również co najmniej jeden z indeksów dopasowania modelu. W tym przypadku raportowany jest unormowany indeks dopasowania Bentlera–Bonnetta (*normed fit index*) *NFI Delta1*. Inne popularne indeksy dopasowania to nienormowany indeks Bentlera–Bonnetta (*NNFI*), znany również jako indeks Tuckera–Lewisa (i tak oznaczony w Amos: *TLI rho2*), oraz skorygowany indeks dobroci dopasowania (*AGFI*). W szczególności *AGFI* jest często używaną statystyką (np. w wynikach confirmacyjnej analizy czynnikowej). Indeks ten nie jest jednak wiarygodny (a w Amos nie jest w ogóle dostępny), jeżeli w modelu, oprócz struktury kowariancji, szacowane są również średnie. Interpretacja statystyk dopasowania wymaga nieco doświadczenia. Zasadniczo jednak wartość bliska 1 pokazuje, że mamy do czynienia z dobrze dopasowanym modelem. Wartość mniejsza niż 0,9 oznacza z kolei, że model może być błędnie wyspecyfikowany i że poprawa dopasowania jest możliwa (Bentler i Bonnett, 1980; Schumacker i Lomax, 2004).

Statystyki dopasowania przyjmują wysokie wartości wówczas, gdy ograniczenia nałożone na model znajdują uzasadnienie w danych. W przypadku omawianego modelu ograniczenia te dotyczą braku korelacji pomiędzy stażem pracy a innymi zmiennymi wyjaśniającymi. Oznacza to, że w tym przypadku statystyki dopasowania nie niosą żadnej treści istotnej z perspektywy teoretycznej.

Osobno zostanie omówiony skorygowany pierwiastek błędu średniokwadratowego (*root mean square error adjusted*, RMSEA). W raportowaniu wyników modelu strukturalnego obowiązkowe jest umieszczenie górnej granicy 90-procentowego (zwykle) przedziału ufności dla tej statystyki (w analizowanym modelu: 0,077), a często warto raportować również jej estymator punktowy (tu:  $< 1e^{-17}$ ). Zasada „kciuka” stosowana w interpretacji współczynnika (Hu i Bentler, 1999; Kline, 2005) mówi, że wartość RMSEA mniejsza niż 0,05 świadczy o dobrym dopasowaniu modelu, wartość większa niż 0,08 natomiast o dopasowaniu niesatysfakcjonującym. W przypadku omawianego modelu wartości raportowa-

Tabela 1.

Współczynniki dopasowania modelu

Chi-kwadrat	2,68 ( $df = 3$ ; $p = 0,444$ )
RMSEA (estymator punktowy)	0,000
RMSEA (górną granicą 90% przedziału ufności)	0,077
NFI Delta1	0,997

ne są satysfakcjonujące, choć nie idealne (górną granicą przedziału ufności bliska 0,08). Ważną dodatkową informacją zawartą w RMSEA jest ocena liczebności próby. Modele równań strukturalnych są bardziej zachłanne na dane, aniżeli wykonywana na tych samych danych metodą najmniejszych kwadratów analiza regresji czy analiza wariancji. W przypadku niesatysfakcjonującej liczebności próby górna granica przedziału ufności dla RMSEA będzie wypadać wysoko. Jej wartość powyżej 0,1, przy pozostałych wskaźnikach świadczących o dobrym dopasowaniu, wskazywać będzie na niewystarczającą liczebność próby i może budzić zastrzeżenia co do sensu użycia modelu strukturalnego dla takich danych.

*Analiza efektów bezpośrednich.* Informacja ta umieszczona jest w raporcie wynikowym w grupie *Estimates*, podgrupie *Scalars* i tabeli *Regression Weight*. Niestandardyzowane wagi regresji informują o wpływie zmiennych wyjaśniających na poszczególne zmienne wyjaśniane w modelu. W terminologii modelowania równań strukturalnych stosowanymi pojęciami są zmienne egzogenne i endogenne. Zmienne egzogenne to takie, które w modelu nie są wyjaśniane. Zmienną endogenną z kolei jest każda zmienna, do której prowadzi choćby jedna strzałka przyczynowa. Pojęcie wywodzi się z tego, że model strukturalny wyjaśnia 100% wariancji takiej zmiennej. Pewna część wariancji jest wyjaśniana przez zmienne wyjaśniające (zmienne egzogenne i/lub inne zmienne endogenne), reszta przypisywana jest nieobserwowanemu wpływowi innych zmiennych. Suma wpływu zmiennych nieobserwowanych oraz błędu pomiaru wyrażona jest pod postacią zmiennej latentnej (niemierzonej, w przeciwieństwie do zmiennych obserwowanych) dołączonej do modelu wyjaśniającego każdej zmiennej endogennej (zmienne *e\_ed*, *e\_mn* i *e\_pl* na Rysunku 1). Zmienna ta bywa często nieściśle określana składnikiem błędu, choć jej interpretacja jest szersza.

Przedmiotem zainteresowania są tutaj efekty płci. Interpretacja efektu bezpośredniego to wpływ zmiennej wyjaśniającej na zmienną wynikową przy hipotetycznym założeniu utrzymania pozostałych zmiennych w modelu

Tabela 2.  
Niestandaryzowane wagi regresji modelu

Ścieżka	Waga	Błąd standardowy	C.R.	p
Wykształcenie < – Płeć	-2,556	0,236	-10,84	< 0,001
Stanowisko = Menedżer < – Płeć	-0,070	0,033	-2,14	0,032
Stanowisko = Menedżer < – Wykształcenie	0,080	0,006	13,64	< 0,001
Płaca aktualna (log) < – Płeć	-0,070	0,009	-7,64	< 0,001
Płaca aktualna (log) < – Wykształcenie	0,021	0,002	10,54	< 0,001
Płaca aktualna (log) < – Stanowisko = Menedżer	0,238	0,013	17,93	< 0,001
Płaca aktualna (log) < – Staż pracy	0,00115	0,00040	2,86	0,004

wyjaśniającym na poziomie stałym. Okazuje się, że kobieta o takim samym wykształceniu, takim samym stażu pracy, pracująca na takim samym stanowisku co mężczyzna zarabia o 7,04% mniej niż on. Pamiętajmy, że – w związku z transformacją logarymiczną zmiennej zależnej – wartość ta pokazuje przewidywane różnice pomiędzy średnimi geometrycznymi rozkładów wynagrodzenia w grupach płci. Widzimy również, że prawdopodobieństwo awansu kobiety na stanowisko menedżerskie jest o 7,01% niższe niż prawdopodobieństwo awansu mężczyzny o takim samym wykształceniu. Oprócz ocen efektów bezpośrednich na podstawie niestandaryzowanych wag regresji możemy również posłużyć się statystykami wyrażonymi w kategoriach procentu wariancji wyjaśnionej. Znajdują się one w grupie wyników *Estimates*, podgrupie *Matrices* i w tabeli *Standardized Direct Effects*.

Efektom bezpośrednim jest efekt niezapośredniczony przez żadną zmienną obecną w modelu. Oczywiście, dla większości efektów bezpośrednich będziemy mogli wskazać mechanizmy pośredniczące na niższym poziomie wyjaśniania przyczynowego. Hipotetyczny mediator relacji bezpośredniej nie powinien być skorelowany z innymi zmiennymi uwzględnionymi w modelu. Jeśli jest on powiązany przyczynowo również z innymi zmiennymi, może mieć on wpływ zakłócający na wyniki modelu. W przypadku omawianego tutaj modelu wpływ taki można łatwo zaobserwować po usunięciu z modelu zmiennej *stanowisko*.

Intepretacja wpływu przyczynowego w modelu strukturalnym wymaga myślenia kontrfaktycznego i może być nieco bardziej skomplikowana, niż w analizie wyników Ogólnego Modelu Liniowego. W OML zakładamy, że kolejne zmienne niezależne wnoszą niezależny od siebie wkład do wyjaśnienia zmiennej zależnej. W modelu strukturalnym zmienne wyjaśniające mogą być dodatkowo powiązane ze sobą ścieżkami przyczynowo-skutkowymi. Na przykładzie omawianego tu modelu, przewi-

dywanie o 7% niższego wynagrodzenia kobiety, aniżeli mężczyzny, oznacza twierdzenie kontrfaktyczne o treści: gdyby ten mężczyzna był (w alternatywnym świecie) kobietą na tym samym stanowisku (przy wiedzy, że prawdopodobieństwo pracy na różnych stanowiskach jest zależne od płci), mającym to samo wykształcenie (przy wiedzy, że poziom wykształcenia zależy od płci) oraz mającym ten sam staż pracy, zarabiałby on o 7% mniej. Odnośnie do problemu różnic płacowych pomiędzy mężczyznami i kobietami możliwe są również inne pytania kontrfaktyczne. Ile zarabiałby mężczyzna, pracownik tego przedsiębiorstwa, gdyby urodził się kobietą? Ile zarabiałby mężczyzna, pracownik tego przedsiębiorstwa, gdyby pracodawcy i współpracownicy sądzili, że jest kobietą? Odpowiedzi na te pytania w kategoriach przewidywanej różnicy wynagrodzenia są również możliwe na podstawie wypracowanego modelu, ale będą oparte na innych efektach, aniżeli efekt bezpośredni.

*Analiza efektów całkowitych.* W omawianym modelu możemy chcieć przyrzeć się całkowitemu efektowi płci, czyli wpływie płci poprzez wszystkie ścieżki przyczynowe w obrębie modelu (grupa wyników *Estimates*, podgrupa *Matrices*, tabela *Total Effects*; dodatkowo tabela *Standardized Total Effects* informuje o wielkości efektu wyrażonego w kategoriach procentu wariancji wyjaśnionej). Kobiety zarabiają mniej nie tylko dlatego, że są kobietami (efekt bezpośredni), ale również dlatego, że rzadziej pracują na stanowiskach menedżerskich oraz mają niższe wykształcenie. Całkowity efekt płci (Tabela 3) informuje o obserwowanej różnicy płac pomiędzy kobietami i mężczyznami. Kobiety zarabiają o 18,79% mniej niż mężczyźni. Jeśli zatem mężczyzna, pracownik tego przedsiębiorstwa, urodziłby się kobietą, zarabiałby o 18,79% mniej, niż zarabia obecnie.

Tabela 3.  
Efekty całkowite

	Zmienne wyjaśniające			
	Płeć	Wykształcenie	Staż pracy	Stanowisko = Menedżer
Wykształcenie	-2,556			
Stanowisko = Menedżer	-0,2740	0,0798		
Płaca aktualna (log)	-0,1879	0,0395	0,0011	0,2376

*Analiza efektów pośrednich. Oszacowanie Efektu Dyskryminacji.* Tabele *Indirect Effects* oraz *Standardized Indirect Effects* (podgrupa *Matrices*, grupa *Scalars*) informują o efekcie pośrednim danej zmiennej na odpowiednią zmienną endogenną modelu strukturalnego. Przez efekt pośredni rozumiana jest suma efektów poprzez wszystkie ewentualne ścieżki oprócz ścieżki oddziaływania bezpośredniego. Nie zawsze ta informacja ma znaczenie teoretyczne. W tym przypadku interesujące jest oszacowanie, czy w przedsiębiorstwie mamy do czynienia z dyskryminacją płci w zakresie wysokości wynagrodzeń, a jeśli tak, to jaka jest wielkość tego efektu. Przekłada się to na kolejne pytanie kontrfaktyczne: jaką pensję otrzymywałby mężczyzna, pracownik tego przedsiębiorstwa, jeśli zostałby zatrudniony w przedsiębiorstwie jako kobieta, pracował w nim jako kobieta oraz – z perspektywy wszystkich zmiennych pośredniczących, jakie mogą mieć znaczenie dla wielkości wynagrodzenia – czuł, myślał i zachowywałby się jak kobieta?

Na to pytanie nie odpowiada efekt bezpośredni, całkowity ani pośredni. Interesujący nas efekt dyskryminacji płciowej w przedsiębiorstwie odnosi się do tego fragmentu procesu przyczynowego, który zachodzi w przedsiębiorstwie. Dyskryminacja płciowa jest zatem sumą bezpośredniego efektu płci na wynagrodzenie oraz efektu mediacji przez ścieżkę szans awansu na stanowisko menedżerskie. Przedsiębiorstwo w pełni sprawiedliwie przyznaje niższą płacę kobietom, jeśli wiąże się to z niższymi kwalifikacjami kobiet (tu: niższym wykształceniem).

Taka sytuacja, w której oszacowaniem interesującego nas efektu nie jest ani efekt całkowity, ani efekt bezpośredni, ale jakiś efekt częściowy, będący sumą kilku efektów w modelu, zdarza się często (Pearl, 2001). Interesującej nas wartości nie znajdziemy niestety nigdzie w raporcie wynikowym oprogramowania Amos i musimy je wyliczyć samodzielnie. Na szczęście jest to wyliczenie proste, oparte na iloczynach niestandardyzowanych wag regresji:

efekt dyskryminacji

= efekt bezpośredni płci + efekt mediacji poprzez

stanowisko = efekt bezpośredni płci + (efekt bezpośredni

płci na stanowisko · efekt bezpośredni stanowiska na płacę) =  $0,077 + 0,07007 \cdot 0,23756 = 0,07036 + 0,01665 = 0,08701$

Gdyby mężczyzna, pracownik analizowanego przedsiębiorstwa, był w tym przedsiębiorstwie traktowany jak kobieta na wszystkich etapach procesu przyczynowego ważnych dla wysokości uzyskiwanego wynagrodzenia, zarabiałby o 8,7% mniej. Wielkość efektu dyskryminacji płciowej w przedsiębiorstwie jest niższa aniżeli bezwzględne różnice w płacach kobiet i mężczyzn (efekt całkowity), ale wciąż znacząca.

A jaka powinna być różnica w wynagrodzeniach kobiet i mężczyzn, jeśli w przedsiębiorstwie nie występowałaby dyskryminacja płciowa? Różnica ta wynika z efektu pośredniego płci poprzez ścieżkę wykształcenia (efekt bezpośredni płci na wykształcenie · efekt całkowity wykształcenia na płacę, uwzględniający również ścieżkę oddziaływania wykształcenia przez różne szanse pracy na stanowisku menedżerskim). Po obliczeniach okaże się, że sprawiedliwa płaca kobiet byłaby wciąż o 10% mniejsza niż płaca mężczyzn. Przyczyną są różnice wykształcenia, za które nie odpowiada przedsiębiorstwo.

Możemy teraz zadać sobie kolejne pytanie kontrfaktyczne. Wymagać będzie ono zmiany jednej ze ścieżek w modelu. Jaki byłby efekt dyskryminacji, gdyby – inaczej aniżeli jest faktycznie – kobiety miały wyższe wykształcenie niż mężczyźni, przy pozostałych (zmiennych endogenicznych) niezmiennych? Po odwróceniu znaku ścieżki przyczynowej pomiędzy płcią a wykształceniem mielibyśmy do czynienia z dwoma przeciwstawnie działającymi wpływami płci na wysokość pensji: pozytywnym poprzez wykształcenie i negatywnym wpływem bezpośrednim poprzez nierówne szanse uzyskania stanowiska menedżerskiego. Efekt dyskryminacji byłby wówczas różnicą pomiędzy wyliczeniem różnicy sprawiedliwej (oczekiwalibyśmy wyższej płacy kobiet niż mężczyzn) a różnic związanych z dyskryminacją w obrębie przedsiębiorstwa. Byłby on z pewnością większy niż efekt całkowity. Co więcej, efekt całkowity mógłby być równy lub bliski 0. Gdybyśmy analizowali takie dane

z wykorzystaniem analizy regresji, obserwowalibyśmy efekt supresji. W modelu płacy na płeć różnice płacowe pomiędzy kobietami i mężczyznami nie byłyby widoczne. Pojawiłyby się one dopiero po włączeniu do modelu zmiennej *wykształcenie*.

Potencjalne zastosowania analizy efektów bezpośrednich, pośrednich oraz całkowitych w modelach strukturalnych są szerokie i mogą mieć istotne znaczenie praktyczne. Nośnym przykładem mogłoby być wyliczenie sprawiedliwego parytetu kobiet i mężczyzn w reprezentacjach politycznych na różnych szczeblach, uwzględniające możliwe różnice w kwalifikacjach kandydatek i kandydatów. Oczywiście, ze względu na niezrozumiałość takich obliczeń statystycznych oraz brak możliwości matematycznego sformułowania kryteriów kwalifikacji do sprawowania funkcji politycznych, oparcie parytetu na obliczeniach statystycznych może być co najwyżej akademickim przykładem i w praktyce jest niemożliwe do zrealizowania.

Na gruncie praktycznych zastosowań psychologii polityki, interesującym problemem mogłoby być przewidywanie wpływu poczucia zagrożenia na poparcie dla przywódców politycznych. Rozważane są dwa hipotetyczne mechanizmy pośredniczące wpływu poczucia zagrożenia. Z jednej strony poczucie zagrożenia powinno prowadzić do zwiększenia poziomu autorytarnego podporządkowania, które sprzyja poparciu dla liderów politycznych utożsamianych z wartościami tradycyjnymi (Altemeyer, 1996; zob. Jost, Glaser, Kruglanski i Sulloway, 2003; Sales, 1972). Z drugiej strony poczucie zagrożenia prowadzi do zwiększenia poziomu motywacji poznawczej do domykania (Kruglanski, 2004) i w konsekwencji do wzrostu poparcia dla obecnych przywódców, niezależnie od reprezentowanych przez nich wartości. Znakając parametry strukturalnego modelu przyczynowego, moglibyśmy pozwolić sobie na odpowiedź na pytanie, którego spośród możliwych rezultatów oczekiwać powinniśmy w efekcie wzbudzenia w społeczeństwie stanu zagrożenia.

### **Problem 2. Uwikłanie przyczynowe zmiennej zależnej**

Innym przykładem problemu analizy przyczynowej, logicznie uniemożliwiającym przeprowadzenie skutecznej manipulacji eksperymentalnej jedną ze zmiennych wyjaśniających, jest przyczynowe uwikłanie zmiennej zależnej w modelu wyjaśniającym tej zmiennej. Z taką sytuacją możemy mieć do czynienia w dwóch przypadkach:

- w nierekursywnych modelach przyczynowych zmienna zależna wpływa na jedną ze zmiennych wyjaśniających w modelu – mamy zatem do czynienia z pętlą sprzężenia zwrotnego;

- początkowy poziom zmiennej zależnej (lub poziom jej nieobserwowanych zmiennych wyjaśniających) może wpływać na wielkość efektu zmiennej niezależnej; odwołując się do terminologii Barona i Kenny'ego, możemy mieć do czynienia z efektem moderacji, ale moderatorem jest sama zmienna zależna.

Modelowanie sprzężenia zwrotnego może być realizowane z wykorzystaniem metody zmiennych instrumentalnych (dopasowanie metodą podwójnych najmniejszych kwadratów) lub szacowane w modelu równań strukturalnych metodą maksymalizacji wiarygodności (ML). Z perspektywy modelowania równań strukturalnych istnieje systematyczna monografia zagadnienia modeli nierekursywnych (Berry, 1984). Metodzie zmiennych instrumentalnych wiele uwagi poświęca się z kolei na gruncie ekonometrii (np. Angrist i Krueger, 2001; Heckman, 1997).

Tutaj chcielibyśmy zaprezentować problem odnoszący się do drugiego spośród tych efektów. Pojęcie moderacji w psychologii jest znane. Czy moderatorem może być jednak zmienna zależna? Jeśli zmienna zależna istniała przed rozpoczęciem się procesu przyczynowego, nie jest to trudne do wyobrażenia. Na przykład nawracanie zagorzałych katolików nie bardzo ma sens, zmiana postawy religijnej jest mało prawdopodobna. Również w przypadku zagorzałych ateistów działalność misyjna ma małe szanse doprowadzenia do zmian postaw. Prawdopodobieństwo wywołania zmiany jest jednak większe wśród osób niezdecydowanych, wątpliwych. W zależności od wyjściowego poziomu postawy religijnej, interwencja mająca na celu jej zmianę ma różne szanse powodzenia.

Wielkość efektu zmiennej niezależnej może zależeć od poziomu zmiennej zależnej w wielu obszarach życia społecznego i psychicznego. Efekty takie poddano już analizie na gruncie rzeczywistości społeczno-ekonomicznej (Heckman, Schmierer i Urzua, 2009; Heckman i Vytlačil, 1998). W psychologii społecznej z pewnością istnieją przesłanki badawcze dla hipotez o moderacyjnym uwikłaniu zmiennych zależnych. Na przykład atrakcyjność grupy wzrasta po uciążliwej inicjacji, ale zapewne efekt ten ma mniejszy wpływ na osoby, dla których grupa i tak była już bardzo atrakcyjna. W tym i podobnych przypadkach brak wiedzy o wyjściowym poziomie zmiennej zależnej może prowadzić do niedoszacowania siły efektu lub jego przeszacowania dla niektórych grup.

Innym przykładem będą sytuacje, w których spodziewamy się odwróconych efektów w zależności od początkowego poziomu zmiennej zależnej (interakcja krzyżowa). Na przykład:

- komplement ze strony osoby atrakcyjnej podwyższa jej atrakcyjność w naszych oczach, ale obniża postrze-



ganą atrakcyjność, jeśli początkowa ocena atrakcyjności była niska,

- bodziec dostarczający zewnętrznego źródła motywacji zwiększa motywację osób niezmotywowanych, ale obniża u osób już silnie zmotywowanych.

W podobnych sytuacjach brak uwzględnienia potencjalnego efektu moderacji ze strony zmiennej zależnej może prowadzić do nieuprawnionego wniosku o braku efektu przyczynowego zmiennej niezależnej. Efekt ten występuje jednak, choć jest on przeciwnie ukierunkowany na różnych poziomach wyjściowego stanu zmiennej zależnej.

Efekt moderacji ze strony początkowego poziomu zmiennej zależnej może być jednym z wyjaśnień różnic w wariancji zmiennej zależnej między grupą eksperymentalną i kontrolną lub heteroskedastyczności reszt modelu. Symulacje obrazujące ten związek znajdują się na stronie <http://www.socialpsychologylab.eu/PS2010/>. Oprócz wyjaśnień teoretycznych efektu moderacji ze strony zmiennej zależnej, jego przyczyna tkwić może również w narzędziu pomiarowym. Taki obraz danych (włącznie z obserwowanymi różnicami w wariancjach zmiennej zależnej na różnych poziomach zmiennych niezależnych) może być skutkiem wystąpienia w pomiarze efektu sufitowego lub podłogowego.

Istnieje kilka sposobów na zaobserwowanie lub wykazanie efektu moderacji ze strony początkowej wartości zmiennej zależnej. Oszacowanie parametrów modelu przyczynowego wymaga jednak specjalnego planu badawczego. Oszacowanie efektu moderacji ze strony zmiennej zależnej możliwe jest:

- w schemacie badawczym z grupą kontrolną i pretestem lub – jeśli podejrzewamy potencjalny wpływ pretestu na wyniki eksperymentu – w schemacie badawczym realizowanym na planie eksperymentalnym Solomona (dwie grupy zależne i niezależne w wersji z pretestem i bez) (Sawilowsky, Kelly, Blair i Markman, 1994);

- dla danych z wielokrotnym pomiarem zmiennej zależnej dla tego samego badanego.

W tej drugiej sytuacji analiza może być zrealizowana za pomocą Mieszanego Modelu Liniowego. Przy użyciu tej techniki statystycznej wykonany został przedstawiony poniżej przykład analityczny.

### **Przykład 2. Korelacja efektu zmiennej niezależnej i poziomu wyjściowego zmiennej zależnej**

Podstawowym zastosowaniem Mieszanych Modeli Liniowych (Gelman i Hill, 2007; Hox, 2002; Bryk i Raudenbush, 2002; w tym numerze *Psychologii Społecznej*: Radkiewicz i Zieliński; Zieliński) jest analiza danych, w których obserwacje nie są niezależne, a zatem zakła-

dana jest korelacja błędów pomiaru. Potrzeba takiego założenia pojawia się, gdy mamy wiele pomiarów pochodzących od tej samej osoby lub gdy dane mają strukturę hierarchiczną, na przykład badaliśmy zachowanie jednostek w grupach, a procesy grupowe lub cechy grupy mogą wpływać na interesujące nas zjawisko. Dla schematu z powtarzanymi pomiarami Mieszany Model Liniowy jest alternatywą dla Ogólnego Modelu Liniowego, mającą następujące przewagi:

- możliwość wykorzystania pełnej informacji z danych niepełnych (braki danych) oraz z pomiarów realizowanych w różnych momentach,

- dowolna specyfikacja modelu (Ogólny Model Liniowy wymaga włączenia do modelu czynników interakcji pomiędzy zmiennymi wewnątrz- i międzyobiektowymi),

- możliwość potraktowania parametrów modelu jako losowych efektów zagnieżdżonych w obrębie osoby, co pozwala na oszacowanie różnych parametrów modelu liniowego dla różnych jednostek (różnice indywidualne wśród badanych).

Dzięki tej ostatniej właściwości możliwe jest oszacowanie moderacji efektu zmiennej niezależnej przez wyjściowy poziom zmiennej zależnej.

### **Omówienie danych**

Przykład wykorzystuje dane z badań Belenky'ego i współpracowników (2003) dostępne jako dane przykładowe pakietu *lme4* oprogramowania R. Całość przygotowania danych do analiz oraz analizy wykonane zostały w oprogramowaniu R 2.8.1. Pełny skrypt analiz (zawierający dodatkowe porównania dla osób zainteresowanych zagadnieniem) jest dostępny na stronie <http://www.socialpsychologylab.eu/PS2010/>. Na stronie internetowej, oprócz analizy w R, ten sam model dopasowany jest również z wykorzystaniem IBM SPSS Statistics 18.0. Niestety, pełne odtworzenie w SPSS wyników analizy nie jest możliwe, ponieważ w oprogramowaniu tym nie ma możliwości uzyskania indywidualnych oszacowań parametrów modelu na poziomie jednostek, a co za tym idzie nie są możliwe dalsze, pogłębione analizy dla tych parametrów.

Dane pochodzą od 18 badanych, których czas reakcji testowano przez 10 kolejnych dni. Pierwszego dnia wszyscy badani byli wypoczęci i wyspani. Przez kolejne dziewięć nocy badacze pozwalali badanym na zaledwie 3 godziny snu. Oczekiwano, że czas reakcji badanych każdego dnia będzie się pogarszał. Rzeczywiście, średni efekt był zgodny z oczekiwaniami. Analizy pokazały również, że związek liczby dni deprywacji snu i czasu reakcji jest związkiem liniowym. Dlatego tylko taka hipoteza będzie

uwzględniona w modelu. Dane pokazują istotny czynnik indywidualnego zróżnicowania odporności badanych na deprywację snu. Wśród badanych były osoby, których czas reakcji ulegał znacznemu pogorszeniu, ale i tacy, wśród których nie obserwowano znaczących zmian w pomiarach dokonywanych w kolejnych dniach.

W przykładzie oryginalne dane wykorzystujemy jako grupę kontrolną dla hipotetycznego eksperymentu nad skutecznością środka medycznego, który ma przyspieszać reakcję bojową żołnierza oraz łagodzić skutki długotrwałego obciążenia organizmu. Dane z grupy eksperymentalnej zostały tak zasymulowane, aby zagwarantować silny efekt moderacji efektu eksperymentalnego przez zmienną zależną. Każda obserwacja z oryginalnych badań posłużyła jako źródło danych dla grupy eksperymentalnej, przy czym czas reakcji został obliczony według równania:

czas reakcji (grupa eksperym.) = czas reakcji (grupa kontrolna) – 20 ms (średni efekt manipulacji) – 0,5 · (centrowany bazowy czas reakcji: przewidywany z modelu)

Zmodyfikowany został również czas reakcji w dniu początkowym. Równanie to oznacza, że środek medyczny przyspieszał czas reakcji każdego badanego, ale obserwowana siła efektu zależała od początkowej wartości czasu reakcji i była tym większa (skrócenie czasu reakcji), im wyższa była początkowa wartość czasu reakcji. Wielkość efektu manipulacji waha się od –2,6 do –40,2 ms (odchyl. standard. = 10,6). Korelacja tej wartości z czasem reakcji badanego sprzed manipulacji jest bliska –1, ponieważ równanie jest w pełni deterministyczne. Niewielkie obniżenie współczynnika korelacji jest związane z wykorzystaniem w równaniu nie tyle faktycznych wartości czasu reakcji sprzed manipulacji, ile nieco różniących się od nich wartości przewidywanych z modelu statystycznego (szczegóły omówione w skrypcie analizy). Ponieważ analizować będziemy symulowane wyniki, znane są prawdziwe wartości parametrów struktury przyczynowej realizowanego eksperymentu. Średni efekt manipulacji wynosi –20 ms, istnieje również silna moderacja wiel-

kości efektu poprzez zmienną zależną: korelacja efektu i zmiennej zależnej jest bliska –1.

### Analiza wyników

Szacowany model przedstawia czas reakcji jako liniową funkcję liczby dni deprywacji snu (od 0 do 9) oraz wpływ efektu manipulacji eksperymentalnej. Każdy parametr modelu jest traktowany jako efekt losowy w obrębie badanego, a zatem średnia modelu (będąca czasem reakcji w dniu 0), efekt deprywacji snu (wzrost czasu reakcji z każdym dniem deprywacji) oraz efekt manipulacji eksperymentalnej mogą różnić się indywidualnie pomiędzy badanymi.

Interesuje nas poprawność oszacowań modelu. Efekt główny – różnica średniej pomiędzy grupą eksperymentalną i kontrolną jest szacowany zgodnie (Tabela 4). Najciekawszym wynikiem jest oszacowanie korelacji siły efektu i zmiennej zależnej. Przyjrzyjmy się indywidualnym oszacowaniom parametrów modelu dla badanych (Tabela 5). Zauważmy, że oszacowania indywidualnej średniej modelu różnią się znacznie pomiędzy grupami: kontrolną i eksperymentalną. Oszacowanie w grupie eksperymentalnej uwzględnia już efekt manipulacji eksperymentalnej, ponieważ nie wykonywaliśmy pretestu czasu reakcji. Mimo to wierzymy, że model będzie w stanie zgodnie oszacować korelację pomiędzy przewidywaną średnią a wielkością efektu manipulacji. Korelacje pomiędzy współczynnikami w obu grupach znacznie się różnią. Właściwym oszacowaniem jest korelacja dla grupy kontrolnej. Dlaczego? Stała w tej grupie jest oszacowaniem rzeczywistego średniego czasu reakcji badanego sprzed eksperymentu, podczas gdy w grupie eksperymentalnej jest funkcją tej wartości oraz manipulacji, ze względu na brak pretestu.

Zróżnicowane oszacowania siły efektu manipulacji dla jednostek w grupie kontrolnej nie są jednak wartościami faktycznie obserwowanymi. Faktycznie obserwowanymi wartościami są wartości 0, ponieważ efekt manipulacji w ogóle nie zachodzi w stosunku do badanych w grupie kontrolnej. Wartość oszacowanego przez model parametru należy interpretować w kategoriach kontryfaktycznych.

Tabela 4.  
Oszacowania efektów stałych modelu

	B	Błąd standardowy	Statystyka <i>t</i>
Stała	251,405	6,791	37,02
Liczba dni deprywacji snu	10,467	1,077	9,72
Manipulacja eksperymentalna	–20,000	7,970	–2,51

Tabela 5.  
Indywidualne oszacowania parametrów modelu dla osób badanych

Grupa kontrolna					Grupa eksperymentalna				
ID	Stała	B (liczba dni deprywacji snu)	B (manipulacja eksperymentalna)	B (manipulacja eksperymentalna): wartość prawdziwa	ID	Stała	B (liczba dni deprywacji snu)	B (manipulacja eksperymentalna)	
308	253,9	19,6	-21,1	-21,3	408	254,1	19,6	-21,3	
309	210,8	1,9	11,6	0,3	409	236,3	0,8	-18,0	
310	212,3	5,0	10,7	-0,5	410	237,5	4,0	-18,5	
330	274,9	5,7	-39,3	-31,7	430	258,1	6,4	-19,9	
331	273,5	7,4	-38,0	-31,1	431	258,0	8,1	-20,1	
332	260,4	10,2	-27,2	-24,5	432	254,3	10,5	-20,2	
333	268,2	10,6	-33,5	-28,4	433	256,9	10,7	-20,3	
334	244,2	11,5	-14,1	-16,4	434	249,3	11,3	-20,0	
335	250,7	-0,2	-20,6	-19,7	435	249,0	-0,1	-18,6	
337	286,5	19,0	-47,2	-37,5	437	264,7	20,0	-21,9	
349	226,3	11,6	0,2	-7,4	449	243,4	10,9	-19,6	
350	238,6	17,0	-9,0	-13,6	450	248,5	16,6	-20,6	
351	255,9	7,5	-23,9	-22,2	451	252,3	7,6	-19,7	
352	272,3	14,0	-36,4	-30,5	452	259,0	14,5	-20,9	
369	254,7	11,3	-22,5	-21,6	469	252,7	11,4	-20,2	
370	226,0	15,2	0,9	-7,3	470	244,0	14,5	-20,1	
371	252,2	9,5	-20,7	-20,4	471	251,4	9,5	-19,9	
372	263,7	11,7	-29,7	-26,2	472	255,7	12,1	-20,4	

Współczynnik korelacji B (manipulacja eksperymentalna) i stałej = 0,9995  
Współczynnik korelacji B (manipulacja eksperymentalna) i wartości prawdziwej = 0,9995

Współczynnik korelacji B (manipulacja eksperymentalna) i stałej = 0,7820

Gdyby któryś z badanych znalazł się w grupie eksperymentalnej, a nie w grupie kontrolnej, manipulacja eksperymentalna miałaby na niego taki efekt. Model mówi np., że gdyby badany nr 330 trafił do grupy eksperymentalnej, efekt zastosowania środka czynnego w miejsce placebo wynosiłby  $-39,3$  ms. Ponieważ znamy dokładny, deterministyczny wzór efektu manipulacji, możemy porównać przewidywania kontrfaktyczne z prawdziwymi przewidywaniami obliczonymi według tego wzoru. Przewidywania nie są identyczne, ale ich korelacja z wartościami prawdziwymi równa się 0,9995. Model dobrze opisuje rzeczywistość, w której zachodzi silne zjawisko moderacji efektu manipulacji przez zmienną zależną.

### Podsumowanie

W artykule zaprezentowane zostały dwa problemy analizy przyczynowej, w których strukturalny model przyczynowy stojący za danymi wykluczał zastosowanie czystej metody eksperymentalnej. W przypadku analizy

procesów przyczynowych, których prostym przykładem jest analiza mediacji, nie jest możliwa manipulacja mediatorami efektów. W przypadku przyczynowego uwikłania zmiennej zależnej, nie jest możliwa równoczesna obserwacja i manipulacja zmiennej zależnej.

Za prezentacją tych problemów stała myśl metodologiczna kładąca nacisk na myślenie przyczynowe o rzeczywistości, wyrażające się w stawianiu pytań kontrfaktycznych o przewidywanie stanu systemu dla określonych stanów zmiennych wyjaśniających lub przewidywanie zmian w analizowanym systemie dla określonych zmian w strukturze relacji przyczynowych. Aby możliwe były odpowiedzi na takie pytania, niezbędne są analizy statystyczne, których celem jest szacowanie parametrów strukturalnego modelu przyczynowego odzwierciedlającego stan wiedzy naukowej w zakresie interesującego nas zagadnienia. Jesteśmy przekonani, że – w obliczu myślenia w kategoriach tak rozumianej analizy przyczynowej – traci znaczenie granica między metodami badawczymi:

eksperymentalną i korelacyjną. Konsekwencję myślenia w kategoriach analizy przyczynowej przedstawiamy w tym artykule.

Sądzymy, że dalszą konsekwencją powinno być również zatarcie różnic pomiędzy technikami statystycznymi oraz podejściami statystycznymi (frekwencyjnym i Bayesowskim). Ideałem techniki statystycznej dla analizy przyczynowej byłby Ogólny Model Analizy Statystycznej pozwalający na założenie dowolnej struktury modelu przyczynowego, uwzględnienie w modelu dowolnej wiedzy wstępnej o prawdopodobnych wartościach parametrów modelu, nałożenie dowolnych ograniczeń na dopuszczalne oszacowania, założenie dowolnego poziomu pomiaru zmiennych, dowolnych rozkładów teoretycznych (lub rozkładu nieparametrycznego), dowolnych funkcji wiążących zmienne (liniowej, logarytmicznej itp.), a także symulowanie możliwych scenariuszy zdarzeń pozwalające na przejście od analizy statystycznej do przewidywań zachowania systemu dynamicznego (Nowak i Vallacher, 1998). Czekając na satysfakcjonujące rozwiązanie w tym zakresie, zaprezentowaliśmy dwie wciąż jeszcze dalekie od ideału metody statystyczne: Model Równań Strukturalnych i Mieszany Model Liniowy.

#### LITERATURA CYTOWANA

- Altemeyer, R. A. (1996). *The authoritarian specter*. Cambridge, MA: Harvard University Press.
- Angrist, J., Krueger, A. (2001) Instrumental variables and the search for identification: From supply and demand to natural experiments. *Journal of Economic Perspectives*, 15, 69–85.
- Arbuckle, J. L. (2006). *Amos 7.0 user's guide*. Chicago, IL: SPSS Inc.
- Baron, R. M., Kenny, D. A. (1986). The moderator-mediator variable distinction in social psychological research: Conceptual, strategic and statistical considerations. *Journal of Personality and Social Psychology*, 51, 1173–1182.
- Belenky, G., Wessensten, N. G., Thorne, D. R., Thomas, M. L., Sing, H. C., Redmond, D. P., Russo, M. B., Balkin, T. J. (2003). Patterns of performance degradation and restoration during sleep restriction and subsequent recovery: A sleep dose-response study. *Journal of Sleep Research*, 12, 1–12.
- Bentler, P. M., Bonnett, D. G. (1980). Significance tests and goodness of fit in the analysis of covariance structures. *Psychological Bulletin*, 88, 588–606.
- Berry, W. D. (1984). *Nonrecursive causal models (Quantitative applications in the social sciences)*. Thousand Oaks: Sage Publications.
- Bryk, A. S., Raudenbush, S. W. (2002). *Hierarchical linear models* (wyd. 2). Thousand Oaks: Sage Publications.
- Gelman, A., Hill, J. (2007). *Data analysis using regression and multilevel/hierarchical models*. Cambridge: Cambridge University Press.
- Hayes, A. F. (2009). Beyond Baron and Kenny: Statistical mediation analysis in the new millennium. *Communication Monographs*, 76, 408–420.
- Heckman, J. (1997). Instrumental variables: A study of implicit behavioral assumptions used in making program evaluations. *Journal of Human Resources*, 32, 441–462.
- Heckman, J. J., Schmieger, D. A., Urzua, S. S. (2009). *Testing the correlated random coefficient model (The National Bureau of Economic Research Working Paper Series)*. Working Paper 15463, <http://www.nber.org/papers/w15463>.
- Heckman, J. J., Vytlačil, E. J. (1998). Instrumental variables methods for the correlated random coefficient model: Estimating the average rate of return to schooling when the return is correlated with schooling. *Journal of Human Resources*, 33, 974–987.
- Heckman, J. J., Vytlačil, E. J. (2007). Econometric evaluation of social programs, part I: Causal models, structural models and econometric policy evaluation. W: J. Heckman, E. Leamer, (red.), *Handbook of econometrics* (t. 6B, s. 4779–4874). Amsterdam: Elsevier.
- Hox J. J. (2002). *Multilevel analysis: Techniques and applications*. Mahwah, NJ: Erlbaum.
- Hu, L., Bentler, P. M. (1999). Cutoff criteria for fit indexes in covariance structure analysis: Conventional criteria versus new alternatives. *Structural Equation Modeling*, 6, 1–55.
- Imbens, G., Wooldridge, J. (2007). *What's new in econometrics*. The National Bureau of Economic Research course notes. <http://www.nber.org/minicourse3.html>
- Jost, J. T., Glaser, J., Kruglanski, A. W., Sulloway, F. J. (2003). Political conservatism as motivated social cognition. *Psychological Bulletin*, 129, 339–375.
- Kaplan, D. (2000). *Structural equation modeling: Foundations and extensions (Advanced Quantitative Techniques in the Social Sciences series, 10)*. Thousand Oaks, CA: Sage.
- Kline, R. M. (2005). *Principles and practice of structural equations modeling*. New York: Guilford Press.
- Kruglanski, A. W. (2004). *The psychology of closed mindedness*. New York: Psychology Press.
- MacKinnon, D. P., Fairchild, A. J., Fritz, M. S. (2007). Mediation analysis. *Annual Review of Psychology*, 58, 593–614.
- McDonald, J. H. (2009). *Handbook of biological statistics* (wyd. 2). Baltimore, Maryland: Sparky House Publishing.
- Nichols, A. (2008). Causal inference with observational data. *Stata Journal*, 7, 507–541.
- Nowak, A., Vallacher, R. R. (1998). *Dynamical social psychology*. New York: Guilford Press.
- Pearl, J. (2000). *Causality: Models, reasoning, and inference*. Cambridge: Cambridge University Press.
- Pearl, J. (2001). Direct and indirect effects. *Proceedings of the Seventeenth Conference on Uncertainty in Artificial Intelligence* (s. 411–420). San Francisco: Morgan Kaufman.
- Preacher, K. J., Hayes, A. F. (2004). SPSS and SAS procedures for estimating indirect effects in simple mediation models. *Behavior Research Methods*, 36(4), 717–731.
- Preacher, K. J., Hayes, A. F. (2008). Asymptotic and resampling strategies for assessing and comparing indirect effects in

- multiple mediator models. *Behavior Research Methods*, 40, 879–891.
- Rosenbaum, P. R. (2002). *Observational studies*. New York: Springer.
- Sales, S. M. (1972). Economic threat as a determinant of conversion rates in authoritarian and nonauthoritarian churches. *Journal of Personality and Social Psychology*, 23, 420–428.
- Sawilowsky, S., Kelly, D. L., Blair, R. C., Markman, B. S. (1994). Meta-Analysis and the Solomon Four-Group Design. *Journal of Experimental Education*, 62, 361–376.
- Schumacker, R. E., Lomax, R. G. (2004). *A beginner's guide to structural equation modeling* (wyd. 2). Mahwah, NJ: Lawrence Erlbaum Associates.
- Shrout, P. E., Bolger, N. (2002). Mediation in experimental and nonexperimental studies: New procedures and recommendations. *Psychological Methods*, 7, 422–445.
- Winship, C., Morgan, S. L. (1999). The estimation of causal effects from observational data. *Annual Review of Sociology*, 25, 659–706.
- Wojciszke B. (2004). Systematycznie Modyfikowane Auto-replikacje: logika programu badań empirycznych w psy-

chologii. W: J. Brzeziński (red.). *Metodologia badań psychologicznych. Wybór tekstów* (s. 44–68). Warszawa: Wydawnictwo Naukowe PWN.

## Causal Analysis beyond the experimental method. Two examples of the nonexperimental causal models (with statistical solutions)

Mariusz Trejtowicz, Katarzyna Jaśko  
*Institute of Psychology, Jagiellonian University*

### Abstract

The article presents two examples of causal inferences in which theoretical problems exclude a possibility to infer causal relations from effects of experimental manipulation. The first example is a causal inference through mediation analysis. Particular emphasis has been placed on interpretation of direct, total and indirect effects in Structural Equation Modelling. The second example concerns the causal impact of a dependent variable on its own explanatory model. In this example estimation of the causal model parameters can be done through the Linear Mixed Model.

*Key words:* causality, causal modelling, causal process analysis, mediation analysis, Structural Equation Modelling, Linear Mixed Model, statistics, methodology