

ROMAN KONARSKI

INTERPRETACJA PRZYCZYNOWA
WYNIKÓW ANALIZY STATYSTYCZNEJ

Artykuł prof. Brzezińskiego jest ważnym głosem w dyskusji na temat roli i praktyki stosowania statystyki w badaniach psychologicznych. W moim komentarzu rozwijam wątek interpretacji przyczynowej wyników analizy statystycznej (AS), który jest tylko śladowo obecny w wiodącym artykule.

Zaprezentowana analiza terminu „istotności” oraz przyczynowej interpretacji wyników AS wymaga szczegółowego wyjaśnienia i pogłębienia. Prof. Brzeziński operacjonalizuje istotność zmiennej niezależnej (np. w analizie regresji) jako część wariacji w zmiennej zależnej tłumaczoną wariacją w zmiennej niezależnej. Tak zdefiniowana „istotność” jest jednocześnie utożsamiana z efektem przyczynowym zmiennej niezależnej. Ponieważ analiza przyczynowa jest centralnym elementem wyjaśnienia naukowego (np. Cartwright, 2002), poświęcam temu wątkowi mój komentarz.

Przed rozpoczęciem rozważań nad problemem interpretacji przyczynowej wyników AS musimy określić perspektywę filozoficzną, z której wyniki badań są interpretowane. Z punktu widzenia naukowego instrumentalizmu (Stanford, 2006) analiza przyczynowa zjawisk (i wyników badań) psychologicznych nie jest celem badania empirycznego. Wyniki badań nie odnoszą się ani do prawdy, ani do rzeczywistości psychologicznej, a jedynie do postępu naukowego i akumulacji wiedzy. W tym aspekcie analiza przyczynowa wyników AS hamuje postęp nauki przez nakładanie zbędnych ograniczeń na wyjaśnienie naukowe. Jedynymi kryteriami oceny jakości badania empirycznego jest osiągnięcie dużego efektu (np. mierzonego współczynnikiem R^2) oraz replikacja otrzymanych wy-

ników badań w przyszłości. W konsekwencji ani forma planu badawczego, ani szczegóły modelu statystycznego nie są istotne, gdyż wyjaśnienie naukowe jest synonimiczne z predykcją.

Złoty okres instrumentalizmu, rozwijanego przez empirystów logicznych Koła Wiedeńskiego, jest dzisiaj przeszłością zarówno w głównym nurcie filozofii nauki (Cartwright, 2002), jak i psychologii (Haig, 2005). Instrumentalizm jest zastąpiony realizmem naukowym, w którym prawdziwość lub izomorfizm teorii ze zjawiskiem psychologicznym jest głównym kryterium oceny teorii. Z tej perspektywy zastosowany model statystyczny formalizuje kluczowe relacje postulowane przez teorię zjawiska psychologicznego, a AS odnosi się do analizy modelu tego zjawiska. W ten sposób analiza przyczynowa efektów postulowanych w modelu staje w centrum uwagi wyjaśnienia naukowego. Parametry modelu są parametrami przyczynowymi, określającymi siłę oddziaływania lub wpływ jednej zmiennej psychologicznej na inną zmienną. W konsekwencji zastosowany plan badawczy oraz wykorzystany model statystyczny nabierają krytycznego znaczenia.

Chociaż analiza przyczynowa jest znacznie ułatwiona w przypadku prawdziwego eksperymentu, to zdecydowana większość badań empirycznych w psychologii polega na pasywnej obserwacji pozbawionej krytycznego elementu randomizacji. Stan ten jest powodowany zarówno czynnikami praktycznymi, jak i etycznymi. Prawdziwy eksperyment służy jednak jako „złoty standard” w interpretacji przyczynowej wyników pasywnej obserwacji.

W dalszej części mojego komentarza posłużę się przykładem modelu regresji. W tym ujęciu zmienna niezależna, która pozostaje pod kontrolą badacza, jest określana zmienną ustaloną. Osoby badane są przypisane do poziomów zmiennej ustalonej za pomocą procesu losowego (randomizacji). Zmienna niezależna, która nie pozostaje pod kontrolą badacza, jest określana zmienną losową. Osoby badane są przypisane do poziomów zmiennej losowej za pomocą nieznanego, lecz deterministycznego procesu selekcji. Dla uproszczenia prezentacji wszystkie zmienne są wyrażone w formie odchyleń od średnich wartości.

W swoim przewodnim artykule prof. Brzeziński dzieli zmienne niezależne na kontrolowane i niekontrolowane. Zmienne kontrolowane są źródłem wariacji wyjaśnionej, a zmienne niekontrolowane są źródłem wariacji niewyjaśnionej, zwanej także wariacją resztową lub wariacją błędu. Jako kontrast proponuję podział zmiennych niezależnych na mierzone i niemierzone. Zmienne mierzone dzielą się na, scharakteryzowane w poprzednim paragrafie, zmienne ustalone i zmienne losowe. Zmienne mierzone to te, które są brane pod uwagę w analizowanym modelu statystycznym. Są one źródłem wariacji wyjaśnionej. Zmienne

niemierzone nie są składnikiem modelu i ich efekt jest źródłem wariacji niewyjaśnionej lub wariacji resztowej.

Aby wyjaśnić złożoność zagadnienia interpretacji przyczynowej, rozważmy następujący model regresji prostej:

$$Y = \beta_{yx}^* X^* + \varepsilon^* \quad (0.1)$$

Ponieważ osoby badane są przypisane do poziomów zmiennej X^* za pomocą randomizacji, zmienna ta jest ustalona. W konsekwencji współczynnik regresji β_{yx}^* ma interpretację przyczynową jako efekt bezpośredni zmiennej X^* na zmienną Y . Zauważmy, że powyższa interpretacja przyczynowa parametru β_{yx}^* jest możliwa, ponieważ ustalenie predyktora X^* urealistycznie spełnienie koniecznego warunku przyczynowego $E(X^* \varepsilon^*) = 0$ albo zera kowariancji między zmienną niezależną a resztami regresji. W przeciwieństwie do tez przedstawionych w wiodącym artykule, założenie istotności predyktora lub $R_{YX^*}^2 > 0$ jest jedynie warunkiem koniecznym, ale niewystarczającym dla interpretacji przyczynowej efektu zmiennej X^* na Y .

Teraz rozważmy następujący model regresji:

$$Y = \beta_{yx} X + \varepsilon \quad (0.2)$$

w którym X jest zmienną losową. W konsekwencji musimy przyjąć, że zmienna wyjaśniająca jest skorelowana z przyczynami nieuwjętymi w modelu, $E(X\varepsilon) \neq 0$. Współczynnik β_{yx} nie może być uważany za efekt przyczynowy, ponieważ $\beta_{yx} \neq \beta_{yx}^*$, chyba że $E(X\varepsilon) = 0$. Problem wnioskowania przyczynowego polega na tym, że założenie odnośnie do braku korelacji między predyktorem i resztami regresji nie jest założeniem statystycznym. Nie może być ono zweryfikowane w danych użytych do oszacowania danego modelu regresji. Ponadto w zależności od kierunku i wielkości tej korelacji oraz korelacji między Y i X prawdziwy efekt przyczynowy może być zerowy, mniejszy od zera lub większy od zera.

Niektórzy badacze wierzą, że rozwinięcie modelu w równaniu (0.2) poprzez dodanie zmiennej (lub zmiennych) kontrolnej Z

$$Y = \beta_{yx.z} X + \gamma Z + e \quad (0.3)$$

przybliży oszacowaną wartość współczynnika $\beta_{yx.z}$ do prawdziwej wartości efektu przyczynowego. Niestety tak nie jest, chociaż rozwinięcie listy predyktorów o Z zazwyczaj zwiększy moc wyjaśniającą modelu, $R_{YX.Z}^2 \geq R_{YX}^2$. Zwróćmy jednak uwagę, że lista założeń przyczynowych jest teraz dłuższa: $E(X\mathbf{e}) = 0$ i $E(Z\mathbf{e}) = 0$. Innymi słowy, założenia przyczynowe określają, że każdy predyktor zawarty w modelu nie jest skorelowany z resztami regresji.

Celem tego komentarza jest zwrócenie uwagi na złożoność warunków pozwalających na wnioskowanie przyczynowe z pasywnych obserwacji. Określenie szczegółowych kryteriów pozwalających na interpretację przyczynową oszacowań parametrów złożonych modeli statystycznych jest obecnie obszarem szybkiego i fascynującego rozwoju. Obecnie najbardziej obiecującą strategią jest teoria kierunkowych niecyklicznych grafów (*directed acyclical graphs*) rozwijana przez Pearla (2000, 2002, 2010).

LITERATURA CYTOWANA

- Cartwright, N. (2002). *From causation to explanation and back. Technical report 09/03*. LSE: Centre for Philosophy of Natural and Social Science.
- Haig, B. D. (2005). Psychology needs realism, not instrumentalism. *American Psychologist*, 60, 344-345.
- Pearl, J. (2000). *Causality, models, reasoning, and inference*. Cambridge: Cambridge University Press.
- Pearl, J. (2002). Causal inference in the health sciences: A conceptual introduction. *Health Services & Outcome Research Methodology*, 2, 189-220.
- Pearl, J. (2010). The foundations of causal inference. *Sociological Methodology*, 40, 1, 75-149.
- Stanford, P. K. (2006). Instrumentalism. W: S. Sarkar, J. Pfeifer (red.), *The philosophy of science: An Encyclopedia* (s. 400-405). New York: Routledge.