

PRACE NAUKOWE
Uniwersytetu Ekonomicznego we Wrocławiu nr 309
RESEARCH PAPERS
of Wrocław University of Economics No. 309

Spółeczno-gospodarcze aspekty statystyki

Redaktorzy naukowi

Zofia Rusnak
Edyta Mazurek



Wydawnictwo Uniwersytetu Ekonomicznego we Wrocławiu
Wrocław 2013

Redaktor Wydawnictwa: Joanna Szynal

Redaktor techniczny: Barbara Łopusiewicz

Korektor: Barbara Cibis

Łamanie: Beata Mazur

Projekt okładki: Beata Dębska

Publikacja jest dostępna w Internecie na stronach:

www.ibuk.pl, www.ebscohost.com,

The Central and Eastern European Online Library www.ceeol.com,

a także w adnotowanej bibliografii zagadnień ekonomicznych BazEkon

http://kangur.uek.krakow.pl/bazy_ae/bazekon/nowy/index.php

Informacje o naborze artykułów i zasadach recenzowania znajdują się na stronie internetowej Wydawnictwa

www.wydawnictwo.ue.wroc.pl

Kopiowanie i powielanie w jakiegokolwiek formie wymaga pisemnej zgody Wydawcy

© Copyright by Uniwersytet Ekonomiczny we Wrocławiu
Wrocław 2013

ISSN 1899-3192

ISBN 978-83-7695-398-4

Wersja pierwotna: publikacja drukowana

Druk: Drukarnia TOTEM

Spis treści

Wstęp	9
Tadeusz Bednarski: Rola Jerzego Sławy-Neymana w kształtowaniu metod statystycznej analizy przyczynowości	11
Filip Borowicz: Ocena możliwości uzupełnienia danych BAEL informacjami ze źródeł administracyjnych w celu dokładniejszej analizy danych o bezrobociu	19
Mariusz Donocik, Bogdan Kisiała, Mirosław Mróz, Beata Detyna, Jerzy Detyna: Przydatność testów nieparametrycznych Kruskala-Wallisa i mediany w długoterminowej ocenie parametrów kruszyw melafirowych	27
Mariusz Donocik, Bogdan Kisiała, Mirosław Mróz, Beata Detyna, Jerzy Detyna: Karty kontrolne w ocenie jakości kruszyw dla budownictwa drogowego.....	42
Czesław Domański: Uwagi o procedurach weryfikacji hipotez z brakuącą informacją.....	54
Stanisław Heilpern: Zależne procesy ryzyka.....	62
Artur Lipieta, Barbara Pawelek, Jadwiga Kostrzewska: Badanie struktury wydatków w ramach wspólnej polityki UE z wykorzystaniem analizy korespondencji.....	78
Agnieszka Marciniuk: Dwa sposoby modelowania stopy procentowej w ubezpieczeniach życiowych	90
Beata Bieszk-Stolorz, Iwona Markowicz: Model nieproporcjonalnej intensywności Coxa w analizie bezrobocia	114
Edyta Mazurek: Statystyczna analiza podatku dochodowego od osób fizycznych.....	127
Katarzyna Ostasiewicz: Awersja do nierówności w modelowaniu użytkowania dóbr wspólnych.....	159
Piotr Peternek: Porównanie kart kontrolnych indywidualnych pomiarów uzyskanych z wykorzystaniem uogólnionego rozkładu lambda oraz krzywych Johnsona	179
Małgorzata Podogrodzka: Starzenie się ludności a płodność w Polsce w latach 1991-2010 – ujęcie regionalne	192
Renata Rasińska, Iwona Nowakowska: Jakość życia studentów w aspekcie znajomości wskaźników zrównoważonego rozwoju	203

Maria Rosienkiewicz, Jerzy Detyna: Analiza efektywności metod wyboru zmiennych objaśniających do budowy modelu regresyjnego	214
Jerzy Śleszyński: National Welfare Index – ocena nowego miernika rozwoju trwałego i zrównoważonego	236
Maria Szmuksta-Zawadzka, Jan Zawadzki: Wykorzystanie oszczędnych modeli harmonicznych w prognozowaniu na podstawie szeregów czasowych o wysokiej częstotliwości w warunkach braku pełnej informacji.....	261
Anna Zięba: O możliwościach wykorzystania metod statystycznych w badaniach nad stresem	278

Summaries

Tadeusz Bednarski: Role of Jerzy Sława-Neyman in statistical inference for causality	18
Filip Borowicz: Assessing the possibility of supplementing the Polish LFS data with register records for more detailed unemployment data analysis.	26
Mariusz Donocik, Bogdan Kisiała, Mirosław Mróz, Beata Detyna, Jerzy Detyna: Usefulness of nonparametric Kruskal-Wallis and median tests in long-term parameters assessment of melaphyre crushed rocks	41
Mariusz Donocik, Bogdan Kisiała, Mirosław Mróz, Beata Detyna, Jerzy Detyna: Control charts in the assessment of aggregates quality for road construction.....	53
Czesław Domański: Some remarks on the procedures of the verification of hypotheses under incomplete information.....	61
Stanisław Heilpern: Dependent risk processes	77
Artur Lipieta, Barbara Pawelek, Jadwiga Kostrzewska: Study of the structure of expenditure under the EU's common policy using correspondence analysis	89
Agnieszka Marciniuk: Two ways of stochastic modelling of interest rate in life insurances	113
Beata Bieszk-Stolorz, Iwona Markowicz: The Cox non-proportional hazards model in the analysis of unemployment.....	126
Edyta Mazurek: Statistical assessment of Personal Income Tax	158
Katarzyna Ostasiewicz: Inequality aversion in modeling the use of common pool resources	178
Piotr Peternek: Comparison of control charts of individual measurements based on general Lambda distribution and Johnson curves.....	191
Małgorzata Podogrodzka: The ageing of the population and fertility in Poland in the years 1991-2010 by voivodeships.....	202
Renata Rasińska, Iwona Nowakowska: Students' life quality in terms of knowledge of sustainable development indicators	213

Maria Rosienkiewicz, Jerzy Detyna: Efficiency analysis of chosen methods of explanatory variables selection within the scope of regression model construction.....	235
Jerzy Śleszyński: <i>National Welfare Index</i> – assessment of a new measure of sustainable development.....	260
Maria Szmuksta-Zawadzka, Jan Zawadzki: The application of harmonic models in forecasting based on high frequency time series in condition of lack of full information.....	277
Anna Zięba: About statistical methods in the study on stress	284

Tadeusz Bednarski

Uniwersytet Wrocławski

ROLA JERZEGO SPŁAWY-NEYMANA W KSZTAŁTOWANIU METOD STATYSTYCZNEJ ANALIZY PRZYCZYNOWOŚCI

Streszczenie: W roku 1923 Jerzy Spława-Neyman opublikował w Rocznikach Nauk Rolniczych (tom X) pracę poświęconą uzasadnieniu zastosowań rachunku prawdopodobieństwa do doświadczeń polowych. Praca ta dotarła do szerszej społeczności statystycznej w roku 1990 i uznano ją za pionierskie osiągnięcie w sferze metodologii statystycznej dla analizy związków przyczynowych. Celem niniejszego opracowania jest przybliżenie tych wyników Neymana w kontekście współczesnych metod badania przyczynowości opartej na pojęciu kontrfaktyczności.

Słowa kluczowe: wnioskowanie statystyczne, analiza przyczynowa, Jerzy Spława-Neyman, historia statystyki.

1. Wstęp

Przyczynowość zdarzeń w rozumieniu potocznym kojarzymy z nieuchronnym lub wielce prawdopodobnym następstwem zdarzeń. W skali jednostki wiedza o związkach przyczynowych stanowi życiowe doświadczenie, w skali społecznej wypełnia ona naukę i szeroko rozumianą kulturę. W psychologii przyczynowość wiąże się z tak zwanym myśleniem kontrfaktycznym, czyli wyobrażeniem alternatywnego względem obserwowanej rzeczywistości biegu zdarzeń. Procesy decyzyjne jednostek, instytucji czy nawet państwa są w istocie oparte na takim myśleniu. Na przykład wprowadzając bardziej rygorystyczne przepisy ruchu drogowego, oczekujemy większego bezpieczeństwa na drogach. Rząd, inicjując zmiany w prawie podatkowym, liczy na większe dochody państwa. Rada Polityki Pieniężnej, zmieniając stopy procentowe, jest przekonana o tym, że realizuje założony cel inflacyjny i stabilizuje procesy gospodarcze. Część ekonomistów jest przekonana, że nadmierna inflacja w dłuższej perspektywie wpływa na wzrost bezrobocia.

Decyzje społeczno-gospodarcze, oparte na wiedzy przyczynowej, kształtowane są wielopłaszczyznowo, z jednej strony przez sferę interesów publicznych i politycznych, a z drugiej – poprzez opinie eksperckie. Mimo że często dotyczą one bar-

dzo ważnych problemów społecznych, to nie są poprzedzane wnikliwymi badaniami naukowymi, które oceniałyby bardziej obiektywnie skuteczność proponowanych rozwiązań. Źródłem tego obiektywizmu mogłyby być, i w niektórych krajach są, stosowne badania statystyczne.

Historia empirycznej analizy związków przyczynowych jest niemal tożsama z historią wnioskowania statystycznego. Najważniejszym terenem zastosowań statystycznych w pierwszych dekadach XX wieku było doświadczalnictwo rolnicze. Problemy społeczne implikowane przez biedę i niedożywienie starano się rozwiązywać zarówno w sferze organizacji życia społecznego, jak i w obszarze doskonalenia kultury rolnej: mechanizacji, nawożenia, selekcji odmian. Tak ważne w tamtym czasie metody organizacji doświadczalnictwa w rolnictwie były opracowywane przez „ojców” statystyki – Fishera i Splawę-Neymana – i na tej bazie, po części, tworzyli oni współczesną statystykę.

2. Kontrfaktyczna teoria przyczynowości i eksperymenty rolnicze

Budowa narzędzi służących identyfikacji związków przyczynowych wymaga co najmniej precyzyjnej definicji pojęcia „przyczynowości”. Filozofia, od czasów Arystotelesa, borykała się z problemem jej klarowności. Trudność polegała w szczególności na tym, że każda próba „głębszego” zdefiniowania przyczynowości miała swoje konsekwencje logiczne sięgające podstawowych wyobrażeń o świecie, a te z natury rzeczy były kontrowersyjne. Tak więc, jak ktoś zauważył, z biegiem wieków przyczynowość była ujmowana w tak różnorodny sposób, że jedynym wspólnym elementem tych dokonań pozostał sam termin „przyczynowość”. Dopiero David Hume (1711-1776) „ustabilizował” proces ewolucji pojęcia, uwzględniając w zrównoważony sposób rolę ludzkiej percepcji, dedukcji i wyobraźni. John Stuart Mill (1843), najbardziej wpływowy brytyjski filozof XIX wieku, stwierdzając, że „obserwacja bez eksperymentu pozwala ustalić współwystępowanie zdarzeń, ale nie przyczynowość” (cytat z pracy Hollanada [1986]), otworzył niejako przestrzeń dla nowej metodologii statystycznej – wnioskowania statystycznego.

To właśnie kontrfaktyczna teoria przyczynowości wypracowana na gruncie badań filozoficznych (Lewis 1973) wydaje się w istocie najbliższa powszechnemu wyobrażeniu o sprawczych związkach zdarzeń. W wyabstrahowanej formie redukuje się ona do następującej definicji:

Zdarzenie A jest przyczyną zdarzenia B, jeśli A zawsze poprzedza B i, co więcej, bez A nie nastąpi B.

Jest to, wobec złożoności procesów badanych w praktyce, raczej dogodny punkt odniesienia niż precyzyjna definicja, ponieważ zwykle przyczyna jest zespołem czynników lub zdarzeń i wielość ta dotyczy także skutku. Co więcej, nie ujmuje ona bezpośrednio pojęcia zagregowanego skutku, czyli potencjalnej reakcji wielu jedno-

stek badanej populacji. Nie zawiera ona także jasnej możliwości sprzężenia zwrotnego pomiędzy zdarzeniami.

Do postulatu Milla o niezbędności eksperymentu dla ustalenia przyczynowości dodano w latach dwudziestych poprzedniego stulecia nowy element – randomizację. Jeśli, dla przykładu, chciano zbadać wpływ dwóch różnych metod uprawy pszenicy na wielkość plonów, to pole eksperymentalne dzielono na względnie małe jednorodne poletka, a następnie drogą losowania poletka te przypisano poszczególnym uprawom. Jeżeli badamy dziś wpływ nowego leku przeciwbólowego na wybraną kategorię pacjentów, to pacjenci ci powinni zostać podzieleni drogą losowania na dwie grupy: zabiegową i kontrolną. Randomizacja była i jest jedyną dostępną i uniwersalną drogą ujednoczenia wpływu innych, nieznanych czynników w grupie zabiegowej i kontrolnej, które w przeciwnym razie mogłyby potęgować lub osłabiać wyniki doświadczenia, doprowadzając do fałszywego obrazu rzeczywistości. Randomizacja umożliwiała więc weryfikację przyczynowości według nakazu zasady kontrfaktycznej.

Fisher [1918] z racji swoich eugenicznych kompetencji używał jawnej argumentacji kontrfaktycznej:

Jeśli mówimy „Ten chłopiec jest wysoki, ponieważ dobrze odżywił się”, to nie tylko śledzimy przyczynę i skutek, ale także sugerujemy, że byłby niższy, gdyby odżywił się gorzej.

Był on też największym i najbardziej znaczącym orędownikiem randomizacji. Uważał, że doświadczenia bez randomizacji mają znikomą wartość poznawczą.

Choć metoda randomizacji, jak niektórzy uważają, była w pierwszych dekadach dwudziestego wieku kojarzona przez niektórych statystyków zajmujących się doświadczalnictwem z możliwością jej matematycznego opisu, to w praktyce funkcjonowała ona w wyniku zaleceń autorytetów. Jerzy Sława-Neyman jako pierwszy zbudował dogodny język prawdopodobieństwa dla opisu eksperymentów, w których posługiwano się randomizacją. Dzięki temu możliwa stała się kontrola dokładności wyników, bardziej efektywne planowanie eksperymentów i – co ważniejsze – jasna interpretacja wyników. Swoje pierwsze przemyślenia na ten temat opisał w języku polskim w roku 1923 w *Rocznikach Nauk Rolniczych*, w tomie X, gdy był zatrudniony w Państwowym Naukowym Instytucie Rolniczym w Bydgoszczy. Istotne fragmenty tej pracy dotarły do szerokiej społeczności statystycznej dopiero w roku 1990, przetłumaczone przez Dabrowską i Speeda dla „*Statistical Science*”.

3. Neymanowski probabilistyczny model doświadczeń rolniczych

Pionierskie wyniki Jerzego Sławy-Neymana, związane z kontrfaktyczną analizą przyczynowości, łatwiej jest przedstawić we współczesnym ujęciu tej analizy, opracowanym przez Rubina [1974; 1975; 1978], Imbensa i Rubina [1997] oraz Hollanda [1986].

Przyjmijmy, że U oznacza populację badanych jednostek. Dla wylosowanej jednostki u , niech $Y(u)$ będzie zmienną losową mierzącą skutek o rozkładzie prawdopodobieństwa zależnym od tego, czy jednostka podlega przyczynie t (zabieg) czy przyczynie c (kontrola). Każdej jednostce eksperymentalnej możemy więc przypisać dwie zmienne losowe $Y_t(u)$ i $Y_c(u)$, potencjalne wyniki eksperymentu, z których tylko jeden jest obserwowany. Celem badacza jest oszacowanie wartości oczekiwanej różnicy

$$E(Y_t(u) - Y_c(u)),$$

którą rozumiemy jako zagregowany efekt przyczynowy dla przyczyn t i c , ale której *de facto* nie obserwujemy na żadnej jednostce badanej populacji. Wartość oczekiwana różnicy jest różnicą wartości oczekiwanych, a te z kolei możemy bez trudu szacować za pomocą dwóch niezależnych prób losowych, z których jedna będzie stanowiła grupę zabiegową, a druga kontrolną. Jest to przykład najprostszego eksperymentu, który jest równoważny procesowi randomizacji dzielącemu próbą na dwie, na przykład równoliczne grupy: zabiegową i kontrolną. Istotne jest w nim pojęcie potencjalnych wyników, wprowadzone z powodu niemożności jednoczesnego zaobserwowania skutków wykluczających się przyczyn. Rubin [1975; 1978] rozważał ten i wiele innych, bardziej złożonych eksperymentów, których celem było badanie związków przyczynowych. Jego najistotniejszym wkładem w statystyczną metodykę analizy przyczynowości było jej pojęciowe uporządkowanie i poszerzenie na przypadek danych obserwacyjnych, gdzie proces randomizacji był znacznie ograniczony.

Neyman nie zajmował się badaniem danych obserwacyjnych. Nie było też takiej potrzeby w przypadku doświadczalnictwa rolniczego, a analiza danych klinicznych lub społecznych, gdzie możliwości próbkowania były ograniczone, stanowiły wtedy problem drugorzędny. Skupiał się on na interpretacji wyników eksperymentu rolniczego. W pierwotnie rozważanym przez niego przypadku chodziło o ocenę różnic plonów dla v odmian, z których każda mogła być wysiana na większym obszarze o niejednorodnej glebie. Żeby zniwelować wpływ jakości gleby na wielkość plonów, duże pole dzielono na m jednorodnych poletek. Neyman rozważał więc potencjalne plony Y_{ij} odpowiadające i -tej odmianie na j -tym poletku. Potencjalne plony nie były przez niego traktowane jak zmienne losowe, były one pojmowane jako oczekiwane plony odpowiadające warunkom uprawy j -tego poletka. Najlepszą oceną plonu z całego pola dla i -tej odmiany była według niego wartość

$$a_i = \frac{1}{m} \sum_{j=1}^m Y_{ij},$$

a „efekty przyczynowe” pomiędzy i -tą i k -tą odmianą stanowiły różnice $a_i - a_k$. W rozumowaniu tym prawdopodobieństwo i zmienne losowe pojawiają się w momencie, gdy uświadomimy sobie, że każde poletko może być obsiane wyłącznie przez jedną odmianę i że proces kojarzenia odmian i poletek powinien być całkowi-

cie przypadkowy. Neyman rozważa przypadek kompletnie zrandomizowanego eksperymentu, gdzie mamy $m = v \times n$ poletek, a każda odmiana pojawia się na n poletkach. Zauważa on, że

$$E\left(\frac{1}{n} \sum_{l=1}^n X_{i,i_l} - \frac{1}{n} \sum_{l=1}^n X_{k,k_l}\right) = a_i - a_k,$$

gdzie $X_{i,i_1}, \dots, X_{i,i_n}$ oraz $X_{k,k_1}, \dots, X_{k,k_n}$ stanowią próby odpowiadające i -tej oraz j -tej odmianie, losowane bez zwracania z populacji $\{Y_{ij}, i = 1, \dots, v, j = 1, \dots, m\}$ potencjalnych plonów. Dokładność estymacji poszczególnych efektów zależy od wariancji powyższej różnicy średnich. Im większa liczba poletek m i mniejsza liczba odmian v , tym prostsza analitycznie jest sytuacja. Mała liczba poletek wymusza bowiem uwzględnienie zależności pomiędzy zmiennymi. Neyman zwraca na to uwagę i, przedstawiając swój model statystyczny, wiąże praktykę planowania eksperymentów z opisem probabilistycznym pozwalającym na głębszą interpretację wyników.

Neyman w swojej historycznej pracy przygotowuje czytelnika do szczegółowego opisu modelu statystycznego, wprowadzając podstawową wiedzę z zakresu rachunku prawdopodobieństwa. Interesujące może być to, że opis ten jest w swojej strukturze niemal identyczny z tym, który przedstawia się w obecnych podręcznikach akademickich z zakresu wnioskowania statystycznego, i to niezależnie od obszaru zastosowań (!). Część jego pionierskiej prezentacji odnosi się do pojęcia „prawdziwej wartości” plonów, gdzie wiąże ją on z wartością oczekiwaną zmiennej losowej. Istota Neymanowskiego rozumowania w opisie i analizie dokładności planowanych eksperymentów była w późniejszym okresie przez wielu intensywnie rozwijana, o czym pisze w swojej monografii Scheffé [1959] i nie uległa istotnej zmianie do dnia dzisiejszego. Dlatego w pełni zasadnym jest i tutaj stwierdzenie Fienberga i Tanura [1995], odnoszące się do pracy Neymana z roku 1925:

Wielką zasługą Neymana było zbudowanie pomostu pomiędzy „beznamiętną” matematyką wartości oczekiwanych a rzeczywistym planowaniem eksperymentów i efektywnym wnioskowaniem statystycznym.

Neyman udoskonalił swój probabilistyczny model eksperymentów z randomizacją z roku 1923 i przedstawił go w roku 1935 na posiedzeniu Sekcji Badawczej Przemysłu i Rolnictwa Królewskiego Towarzystwa Statystycznego. Mimo niewątpliwej oryginalności i wartości prezentowanych wyników wykład został bardzo nieprzychylnie przyjęty przez Fishera, który był uważany za wielki autorytet statystyczny. Zdaniem Lenhard [2006] moment ten miał daleko idący wpływ na dalszy rozwój statystyki. Nigdy nie dowiemy się, jak owocna mogłaby być współpraca Fishera i Neymana. Z biegiem lat powszechnie doceniono wkład Neymana w teorię eksperymentów statystycznych. On sam [Neyman 1979] obszernie wyjaśnia dominującą i inicjującą rolę Fishera w teorii eksperymentu, a swój udział ujmuje następująco [Ried 1982]:

Moje teoretyczne podejście do randomizacji w doświadczalnictwie rolniczym i do randomizacji w ogóle rozumiem jako warunek niezbędny do pełnego (probabilistycznego) zrozumienia wyników. To nie to samo, co stwierdzenie, że doświadczenie bez randomizacji ma znikomą wartość poznawczą. Ten punkt widzenia zawdzięczamy Fisherowi i uważam, że jest on jednym z największych jego osiągnięć.

Właśnie ten motyw „zrozumienia wyników” sprawił, że Neyman – nie pisząc jawnie o problematyce przyczynowości, chociaż w domyśle taki był oczywisty cel eksperymentów – używał pojęcia „potencjalnych” plonów (wyników), które to pojęcie jest punktem wyjścia obecnego spojrzenia na statystykę przyczynowości. Rubin [1990] w komentarzu do tłumaczenia pracy Neymana z roku 1923 pisze:

Prośba zabrania głosu w dyskusji o tym dokumencie [mowa o pracy Neymana z roku 1923] jest dla mnie zaszczytem. Umieszcza on bowiem Neymana w gronie największych myślicieli dziedziny i wyjaśnia współczesnym statystykom zainteresowanym analizą przyczynowości, ile mają mu do zawdzięczenia.

Według komentarza Reid [1982] Neyman bardzo skromnie oceniał wartość swojej historycznej pracy:

Wydawał się zawsze deprecjonować wyniki uzyskane w Bydgoszczy (1923), twierdząc, że jeśli miały w sobie coś istotnego, to nie było to kilka formuł na wartości oczekiwane (przy różnych założeniach eksperymentalnych). Nowością był model probabilistyczny doświadczeń rolniczych...

4. Analiza przyczynowości dziś

Analiza przyczynowości w ujęciu statystycznym staje się coraz pilniejszym wyzwaniem współczesnej statystyki, aspirującej do obiektywnego arbitra w ocenie ważnych kwestii i rozwiązań o daleko idących skutkach społecznych. Jest nie mniejszym wyzwaniem intelektualnym niż tak popularna dziś eksploratywna analiza, skupiająca się na poszukiwaniu inspirujących struktur w dużych i wielkowymiarowych zbiorach danych, struktur, które doprowadziłyby nas do istotnych odkryć naukowych. Rubin [2004], oceniając obecną sytuację badań statystycznych związanych z przyczynowością, stwierdza, że:

Wnioskowanie przyczynowe jest obszarem szybkiego i ekscytującego rozwoju w statystyce. Na szczęście czas myślenia „statystyka mówi nam tylko o stopniu współwystępowania, a współwystępowanie to nie przyczynowość” mamy już za sobą.

Literatura poświęcona zagadnieniom przyczynowości w ujęciu statystycznym jest bardzo obszerna. Obejmuje ona także popularne w modelowaniu ekonometrycznym równania strukturalne i tak zwaną analizę ścieżek, bardziej dostosowaną do zastosowań przyrodniczych i medycznych. Całościowe podejście do analizy przyczynowej w kontekście ekonometrycznej ewaluacji polityk gospodarczych i spo-

lecznych oraz bogatą bibliografię z tym związaną można znaleźć u Heckmana [2001] oraz Heckmana i Vytlačil [2008]. Najbardziej ogólne teoretycznie podejście do przyczynowości w ujęciu probabilistycznym reprezentuje Pearl [2009] uhonorowany w roku 2011 nagrodą A.M. Turinga za fundamentalny wkład w dziedzinę sztucznej inteligencji poprzez rozwój rachunku dla probabilistycznego i przyczynowego rozumowania. Ujęcie kontrfaktyczne nie jest więc jedynym składnikiem statystycznej metodologii kauzalnej. Jest jednak jej najbardziej podstawowym i niezbywalnym składnikiem.

Podziękowania i uwagi. Autor dziękuje profesorowi Tadeuszowi Calińskiemu i profesor Dorocie Dąbrowskiej za pomoc w dotarciu do oryginału pracy Jerzego Sławy-Neymana z roku 1923. Dziękuje także profesorowi Calińskiemu za cenne komentarze i uwagi redakcyjne.

Tłumaczenia cytowanych fragmentów innych prac nie zawsze są dosłowne. Są podane w sposób umożliwiający zrozumienie ich istoty bez szczegółowej wiedzy kontekstowej.

Literatura

- Dabrowska D.M., Speed T.P. (translation), *Neyman J. 1923. On the Application of Probability Theory to Agricultural Experiments. Essay on Principles. Section 9*, "Statistical Science" 1990, vol. 5, pp. 465-472.
- Fienberg S.E., Tanur J.M., *Reconsidering Neyman on experimentation and sampling: Controversies and fundamental contributions*. "Probability and Mathematical Statistics" 1995, vol 15, pp. 47-60.
- Fisher R.A., *The causes of human variability*, "Eugenics Rev." 1918, 10, pp. 213-220.
- Heckman J.J., *Econometrics Counterfactuals and Causal Models*, International Statistical Institute, Seoul, South Korea 2001, draft.
- Heckman J.J., Vytlačil E.J., *Econometric Evaluation of Social Programs, Part 1: Causal Models, Structural Models and Econometric Policy Evaluation*, "Handbook of Econometrics" 2008, vol. 6B, pp. 4780-4808.
- Holland P.W., *Statistics and Causal Inference*, "Journal of the American Statistical Association. Theory and Methods" 1986, vol. 81, no. 396, pp. 945-960.
- Imbens G.W. and Rubin D. B., *Bayesian Inference for Causal Effects in Randomized Experiments*, "The Annals of Statistics" 1997, vol. 25, no. 1, pp. 305-327.
- Lenhard, J., *Models and Statistical Inference: The Controversy between Fisher and Neyman-Pearson*. "Brit. J. Phil. Sci." 2006, vol. 57, pp. 69-91.
- Mill J.S., *A system of Logic*, 1984.
- Neyman J., *Narodzinny statystyki matematycznej*, „Wiadomości Matematyczne” 1979, nr 22, ss. 91-106.
- Pearl J., *Causal inference in statistics: An overview*, "Statistics Survey" 2009, vol. 3, pp. 96-146.
- Reid C., *Neyman from Life*, Springer, New York 1982.
- Rubin D.B., *Estimating causal effects of treatments in randomized and nonrandomized studies*, "Journal of Educational Psychology" 1974, vol. 66, pp. 688-701.
- Rubin D.B., *Bayesian inference for causality: the importance of randomization*, Proc. Social Statistics Section. Am. Statist. Assoc. 1975, pp. 233-239.

- Rubin D.B., *Bayesian inference for causal effects. The role of randomization*, "Ann. Statist." 1978, vol. 7, pp. 34-58.
- Rubin D.B., *Comment: Neyman (1923) and Causal Inference in Experiments and Observational Studies*, "Statistical Science" 1990, vol. 5, pp. 472-480.
- Rubin D.B., *Direct and Indirect Causal Effects via Potential Outcomes*, "Scandinavian Journal of Statistics" 2004, vol. 31, pp. 161-170.
- Scheffé H., *The Analysis of Variance*, John Wiley & Sons, New York 1959.
- Splawa-Neyman J., *Próba uzasadnienia zastosowań rachunku prawdopodobieństwa do doświadczeń polowych*, „Roczniki Nauk Rolniczych i Leśnych” 1923, nr 10, s. 1-51.
- Splawa-Neyman J., *Contributions of the theory of small samples drawn from a finite population*, "Biometrika" 1925, vol. 17, pp. 472-479.
- Splawa-Neyman J. with co-operation of Iwazkiewicz K. and Kołodziejczyk S., *Statistical Problems In Agricultural Experimentation*, Supplement to the Journal of the Royal Statistical Society 1935, vol. II, No 2.

ROLE OF JERZY SPŁAWA-NEYMAN IN STATISTICAL INFERENCE FOR CAUSALITY

Summary: In 1923 Jerzy Splawa-Neyman published in *the Roczniki Nauk Rolniczych* a paper devoted to applications of probability theory to agricultural experiments. The work written in Polish language reached a wider international statistical community in 1990 and was recognized as a pioneering achievement in the field of statistical causal analysis. The aim of this work is to present Neyman's ideas in the context of modern counterfactual approach to statistical causality analysis.

Keywords: statistical inference, statistical causality analysis, Jerzy Splawa-Neyman, history of statistics.