



Główny
Urząd Statystyczny

V Kongres Statystyki Polskiej

Metoda *Know Thyself*, dydaktyczna integracja, mikroekonomii statystyki, etyki i filozofii

[i nie tylko mikroekonomii]

Dr hab. Tomasz Kopczewski


*Wydział Nauk Ekonomicznych
Uniwersytetu Warszawskiego*



UNIwersYTET
WARSZAWSKI



WYDZIAŁ NAUK
EKONOMICZNYCH



DALL-E

Cele:

Zaprezentować metodę Know Thyself – spójne podejście łączące mikroekonomię, statystykę, filozofię i etykę w dwukierunkowy przepływ wiedzy między dydaktyką a badaniami.

Włączyć narzędzia data-science (R, R-studio, Markdown) oraz symulacje Monte Carlo do nauczania przedmiotów społecznych, tak aby studenci od razu doświadczali pracy badawczej

Wykorzystać nowoczesne rozwiązania IT – interaktywne raporty dashboard(ShinyApp) automatyczne analizy danych – by wspierać uczenie się oparte na odkrywaniu

Przedstawić studium przypadku od eksperymentu klasowego przez analizę statystyczną po publikację wyników, ilustrując pełny cykl theory $\leftrightarrow$ education.

Pokazać, jak prawo Newcomba-Benforda pomaga wykrywać „fake data” i „fake research” oraz kształtować etos rzetelności danych.

Rdzeń metody – opowieść o człowieku

Metoda dydaktyczna **Know Thyself** powstała z doświadczeń w prowadzeniu zajęć z mikroekonomii i opiera się na założeniu, że ekonomia to zbiór opowieści o ludzkich wyborach ukrytych w podręcznikach i artykułach. Razem ze studentami odszyfrowujemy te narracje i krytycznie je dekonstruujemy, a nicią spinającą cały proces jest statystyka – język, który pozwala „historyjkom” przełożyć się na dane, a intuicjom na testowalne hipotezy.

Statystyka pełni tu rolę wspólnego alfabetu. Humanisci korzystają z niej, by kwantyfikować literackie metafory, studenci STEM – by modelować i wizualizować dane eksperymentalne, a badacze społeczni – by łączyć eksperymenty ekonomiczne z psychologią i socjologią. W rezultacie każdy uczestnik znajduje własną ścieżkę zrozumienia mechanizmów gospodarowania, posługując się narzędziami statystycznymi jako uniwersalnym kluczem do narracji o człowieku.


Rdzeń metody – opowieść o człowieku

Modele ekonomiczne, choć zapisane w języku matematyki, są tak naprawdę opowieściami o człowieku i społeczeństwie (McCloskey 1983; Morgan 2012). Sztuczna inteligencja potęguje dziś ich zasięg i siłę oddziaływania (Spitale et al. 2023). Statystyka pozwala odróżnić narracje zakorzenione w danych od czystej retoryki (Visionlearning 2024).


Najpierw trzeba zidentyfikować te historie – z podręczników, artykułów czy mediów – aby potem konfrontować je z własnym doświadczeniem. Następnie uczymy się świadomie zarządzać konsekwencjami przyjętych narracji w życiu i gospodarce (Shiller 2019).

Poznaj siebie – flipped classroom w praktyce

Przed zajęciami studenci biorą udział w krótkim **badaniu ad-hoc** online (eksperymentcie), przyjmując „bierną” rolę „jednostki badanej”.



Po eksperymencie proszeni są o ocenę swoich wyborów: czy były zgodne z teorią ekonomii? W ten sposób powstaje *information gap* – poczucie poznawczej deprywacji (Loewenstein 1994), które uruchamia **science curiosity** (Kahan 2017).



Ciekawość zaspokajamy podczas wykładu oraz dzięki **spersonalizowanemu raportowi online**, konfrontując modele teoretyczne z rzeczywistymi zachowaniami uczestników.

Cel: Zasypywanie luki między opisem (Description) a doświadczeniem (Experience)

Description–Experience Gap Różnica między tym, jak formujemy sądy i podejmujemy decyzje na podstawie cudzych opisów (teorii, statystyki, relacji), a tym, jak reagujemy po bezpośrednim zetknięciu się z całkowicie nową, nieznaną wcześniej sytuacją (Hertwig & Erev 2009, 2013). Luka ta dotyczy nie tylko ryzyka, lecz wszelkich fenomenów, których nie zdążyliśmy jeszcze doświadczyć – od mechanizmów rynkowych po codzienne wybory konsumenckie.

Od nauki ku transformacji Systematyczne konfrontowanie teorii z własnym przeżyciem może prowadzić do transformative experience – chwili, w której zdobyta wiedza zmienia sposób postrzegania świata i przyszłe decyzje (Paul 2014).

Kwestie „techniczne”

Wspólnie z dr. Robertem Borowskim przygotowaliśmy aplikację **LabSEE.com**, która umożliwia prowadzenie eksperymentów, ankiet i testów w środowiskach m-learning oraz e-learning. System został wstępnie zintegrowany z platformami Moodle i BigBlueButton, dzięki czemu łączy kurs, wideokonferencję i interaktywną sesję badawczą w jednym ekosystemie.



Kwestie „techniczne”

Podczas zajęć teoria jest natychmiast konfrontowana z danymi z ad hoc eksperymentów, a uczestnicy otrzymują zarówno podsumowania zbiorcze, jak i wyniki indywidualne.

W porównaniu z tradycyjnymi materiałami dydaktycznymi gromadzenie, analiza i wizualizacja danych wymagają więcej czasu, jednak zautomatyzowane narzędzia IT — RStudio, R Markdown oraz ekosystem CRAN — usprawniają ten proces, przekształcając surowe dane w interaktywne raporty i prezentacje. Studenci dostają zanonimizowane dane i projekty w R do samodzielnego uruchomienia.

Raw data

payment	id	Name	Group	Role	Profit	ProfitTotal	Payment	PaymentTotal	mind	sex	number	action	avg	avgert	closest
1	6	Robert	ALL		5	5	5	5	5	M	13	user	20.1955555555556	18.797037037037	13
1	2	Robert	ALL		0	0	0	0	50	F	32	user	20.1955555555556	18.797037037037	13
1	9	Tk	ALL		0	0	0	0	24	M	34	user	20.1955555555556	18.797037037037	13
1	1	tk	ALL		0	0	0	0	28	M	6	user	20.1955555555556	18.797037037037	13
1	5	tk	ALL		0	0	0	0	7	M	34	user	20.1955555555556	18.797037037037	13
1	7	tk	ALL		0	0	0	0	25	F	34	user	20.1955555555556	18.797037037037	13
1	4	Boby	ALL		0	0	0	0	75	F	12	user	20.1955555555556	18.797037037037	13
1	8	Imobile	ALL		0	0	0	0	13	F	4570	user	20.1955555555556	18.797037037037	13
1	3	tk	ALL		0	0	0	0	59	F	43	user	20.1955555555556	18.797037037037	13

Markdown
self-publishing system



R-CRAN



Kwestie „techniczne” – dlaczego warto pokazać warsztat nawet tym, którzy nie zajmują się statystyką?

Nowe technologie (big data, AI, machine learning) na stałe wchodzą do codziennych decyzji społecznych i gospodarczych. Ujawnienie narzędzi – kodu, źródeł danych, procedur analitycznych – pozwala wszystkim uczestnikom, także spoza środowiska statystycznego, przejść od postawy biernej do aktywnej:

	Postawa bierna	Postawa aktywna
Relacja z algorytmami	Akceptacja rekomendacji „na wiarę”	Krytyczne pytanie o logikę modelu i dane wejściowe
Użycie danych	Konsumpcja gotowych wniosków	Samodzielna eksploracja, replikacja i weryfikacja
Efekt edukacyjny	Ograniczona autonomia poznawcza	Świadome wykorzystywanie technologii do samopoznania i podejmowania decyzji

Kwestie „techniczne” – dlaczego warto pokazać warsztat nawet tym, którzy nie zajmują się statystyką?

Dlaczego to działa?

- Przezrzystość – odkryty warsztat buduje zaufanie i pozwala zrozumieć ograniczenia modeli.
- Transfer umiejętności – nawet podstawowa znajomość narzędzi (R Markdown) ułatwia komunikację między specjalistami i laikami.
- Empowerment – możliwość samodzielnego eksperymentowania z kodem wzmacnia autonomię poznawczą w świecie zdominowanym przez algorytmy.

Case study – opowieści wyodrębniane z ...

Nasza intuicja losowości zwykle zatrzymuje się na tasowaniu kart czy rzucie kostką: spodziewamy się rozkładu jednostajnego albo, w najlepszym razie, rozkładu Gaussa (Mlodinow 2008). Tymczasem prawdziwe dane bywają zaskakująco „dzikie” – pełne grubych ogonów i nieregularnych klastrów, dalekie od „normalności” (Taleb 2007).

Podręczniki ekonomii milczą o *fake data* i *fake research*, choć już klasyczne „*How to Lie with Statistics*” ostrzega, że największe kłamstwa kryją się w liczbach (Huff 1954)

Case study – opowieść, która przechodzi w doświadczenie i refleksje

By zdemaskować uproszczone narracje o losowości i statystyce, uczestnicy biorą udział w asynchronicznym badaniu składającym się z dwóch etapów:

Eksperyment „Oszukaj fiskusa”, w którym trzeba wygenerować fikcyjne deklaracje podatkowe, aby nie zostać złapany na oszustwie. Jest to bezpośrednie zderzenie teorii (Prawo Benforda) z własnym działaniem ogranicza description–experience gap (Hertwig & Erev 2009). Nawet kojażenie tego prawa nie pomaga w tej części eksperymentalnej – wszyscy zostali złapani.

Ankieta mierzy, na ile uczestnicy czują się przygotowani do rozpoznawania *fake data* i *fake research*. Studium przypadku łączy więc praktyczne doświadczenie z autorefleksją nad wiarygodnością danych i stanowi jednocześnie badanie „świadomości” statystycznej studentów.

Case study – eksperyment

Sam eksperyment polega na wypełnieniach 60 pozycji liczbami o określonej ilości cyfr. Cel eksperymentu to wygenerowanie danych, które **nie zostaną oznaczone czerwoną flagą** – mają wyglądać tak, jakby pochodziły z prawdziwej firmy lub zjawisk naturalnych. Zajmuje około 10 min.

W badaniu zastosowano unikalna socjotechnikę – pytanie o **pseudonim** dzięki któremu: i) łatwe jest odszukanie własnego rezultatu w raporcie zbiorczym ii) jest zagwarantowana pełna anonimowość uczestników.

Miesiąc 1/4

Wprowadź wartości fałszywych faktur. Może to być dowolna liczba; Nie chodzi o końcówki i grosze, więc podaj z zaokrągleniem do złotych.
Musisz podać takie liczby, które wydają się być generowane przez czynniki naturalne/losowe, a nie są wymyślone przez Ciebie.

1. Wydatki na materiały biurowe (liczby dwucyfrowe)
a b c d


2. Wydatki na sprząatanie (liczby 3-cyfrowe)
a b c d

3. Wydatki na analizy zewnętrzne (liczby 5-cyfrowe)
a b c d

4. Wydatki na marketing (liczby 5-cyfrowe)
a b

5. Wydatki na usługi prawne (liczby 6-cyfrowe)
a

Kliknij, aby przejść dalej
Next



Wyniki eksperymentu opublikujemy na stronie (jako animację). Podaj unikalny nick, dzięki któremu i) rozpoznasz swój wynik i) pozostaniesz anonimowy.

Pseudonim eksperymentalny

Intuicja nie jest dobra – szczególnie w przypadku losowości



W raporcie online znajdują się m.in.:

- przykłady rozkładów danych naturalnych (animacja)
- omówienie prawa Benforda
- wbudowany detektor testujący „prawdziwość” wygenerowanych przez uczestników danych
-


Każda osoba może odszukać swój wynik za pomocą podanego pseudonimu i sprawdzić, czy intuicja przetrwała konfrontację z testem Benforda.

https://microeconomics.shinyapps.io/Report_tax_EN_0_8/

Prawo Benforda; testowanie oszustw i jakości danych

Prawo Benforda W większości naturalnych zbiorów danych pierwsze cyfry nie są równomierne: „1” pojawia się $\approx 30\%$, „2” $\approx 17\%$, ... „9” $\approx 5\%$. Znaczne odstępstwa od tego rozkładu sygnalizują możliwe fałszerstwo lub niską jakość danych. Jak wykorzystujemy to prawo w raporcie?

- automatyczny detektor porównuje zgłoszone wartości z rozkładem Benforda i oznacza odstępstwa czerwoną flagą,
- szare środkowe linie na wykresie pokazują oczekiwaną częstość, czerwone krzyżyki – rzeczywiste dane uczestnika,
- każdy sprawdza swój rezultat pod pseudonimem; brak flagi = prawo Benforda spełnione $\rightarrow$ możliwość odebrania nagrody.



Case study – eksperyment

Znajomość prawa Benforda to jedno, a umiejętność wykorzystania tej wiedzy do stworzenia „wiarygodnych” liczb – to drugie. Weź udział w **wyzwaniu** dostępnym przez następny miesiąc: wygeneruj deklaracje podatkowe tak, by detektor Benforda stworzony w raporcie nie podniósł czerwonej flagi.

Zeskanuj kod QR lub wejdź na stronę badania:
<https://labsee.com/lab/4136/gus>

Sprawdź, czy potrafisz przekroczyć lukę między opisem a doświadczeniem.



Case study – ankieta o „fake data” (wprowadzenie)


Druga część badania koncentruje się na subiektywnym postrzeganiu wiarygodności danych w różnych dziedzinach nauki i na praktykach, które uczestnicy badania stosują, by chronić się przed *fake data* i *research*.

W pierwszej sekcji uczestnicy **oceniają**, jak powszechne ich zdaniem jest zjawisko fałszowania danych w naukach przyrodniczych, społecznych, medycynie, ekonomii oraz inżynierii.

Następnie odpowiadają, jak **często sprawdzają rzetelność pozyskanych zbiorów danych**, czy biorą **pod uwagę dostępność materiałów replikacyjnych** i jak oceniają **własne umiejętności** wykrywania sfałszowanych danych. Ostatnie pytanie weryfikuje, czy rozpoznawali procedurę (prawo Benforda), która ujawniła próby fałszowania w pierwszym etapie eksperymentu.

Oceny studentów Data Science – gdzie „fake data” boli najbardziej?

Analiza ankiety pokazuje, że uczestnicy kierunku Data Science widzą problem fałszowania danych najwyraźniej w naukach społecznych i ekonomii (mediany odpowiednio ≈ 70 i ≈ 50 pkt), podczas gdy nauki przyrodnicze i inżynieria oceniane są jako relatywnie bezpieczniejsze (≈ 30 i 40 pkt).



Oceny studentów Data Science – gdzie „fake data” boli najbardziej?

Taki wynik powinien być sygnałem alarmowym dla badaczy w tych dziedzinach; **wiarygodność** można podnieść jedynie przez systematyczne udostępnianie danych i kodów w **otwartych repozytoriach**, zgodnie z wytycznymi polityki „Data & Code” (AEA, 2019) oraz praktyką pakietów replikacyjnych w czołowych czasopismach (Camerer i in., 2016).

Warto zauważyć, że literatura koncentruje się dziś głównie na oddziaływaniu *fake news* na młodzież (Vraga & Tully, 2021; Koltay, 2017), natomiast systematycznych badań nad *fake data* wciąż brakuje, mimo rosnących obaw o kryzys replikacyjności (Open Science Collaboration, 2015). Dlatego wyniki tej ankiety mogą stanowić impuls do dalszych, empirycznych analiz, jak fałszywe dane i badania wpływają na postrzeganie nauk społecznych przez młodych ludzi.

Case study – deklaracje ≠ kompetencje

Ankietowani studenci Data Science deklarują, że weryfikują wiarygodność pozyskanych zbiorów i zwracają uwagę na materiały replikacyjne. W praktyce jednak [w części eksperymentalnej] tylko niewielki odsetek ($\approx 15\%$) przewidział zastosowanie prawa Newcomba–Benforda – jednego z najprostszych testów jakości danych (Nigrini, 2012).

Ta rozbieżność wskazuje na **lukę kompetencyjną**: świadomość problemu *fake data* nie przekłada się jeszcze na umiejętność jego wykrywania.

Wnioski sugerują potrzebę włączenia krótkich, praktycznych modułów o testach jakości danych do kursów metodologicznych, zwłaszcza w naukach społecznych i ekonomii, które respondenci ocenili jako najbardziej zagrożone fałszerstwami. W raporcie znajdują się wskazówki jak to zrobić.

Dziękuję za uwagę



Materiały i nagrania seminariów, w których krok po kroku omawiam zastosowania metody *Know Thyself*, są dostępne na platformie e-learning **Wydziału Nauk Ekonomicznych UW**. Zachęcam do skorzystania z udostępnionych plików, kodów i prezentacji – wszystkie pozostają otwarte do samodzielnej eksploracji po zalogowaniu. Info na LinkedIn

Od września odświeżam materiały i powtarzam seminaria.

Kontakt: tkopczewski@wne.uw.edu.pl

