

# Rozłączność przedziałów ufności jako kryterium weryfikacji hipotez statystycznych

Tomasz Żółtak

Institut Badań Edukacyjnych

24.09.2018

# Wprowadzenie

# Motywacja

- Namysł nad sposobem wizualizacji *trzyletnich wskaźników EWD*.
  - Dwuwymiarowe obszary ufności wykorzystywane do charakteryzowania poszczególnych szkół, ale również do wnioskowania o istotności różnic między szkołami lub istotności zmian w czasie.
  - Bardzo niszowy temat.
- Problem ogólny:
  - Jako badacze stawiamy i weryfikujemy statystycznie hipotezy korzystając z procedury Neymana-Pearsona.
  - Ale na wykresach pokazujemy przedziały ufności.  
W szczególności na wykresach obrazujących efekty brzegowe w modelach regresji.


## Powszechnie znany związek

W sytuacji gdy:

- Możemy przyjąć, że rozkład statystyki z próby jest symetryczny (np. normalny).
- Wariancja rozkładu statystyki z próby nie wynika z hipotezy zerowej.

Jeśli przedział ufności dla parametru wyznaczony na poziomie ufności  $\gamma = 1 - \alpha$  nie obejmuje wartości  $c$ , to w dwustronnym teście na poziomie istotności  $\alpha$  odrzucona zostanie  $H_0$  głosząca, że populacyjna wartość parametru jest równa  $c$ .


Przykładowo - weryfikacji hipotezy dot. średniej populacyjnej:



## Często występująca pokusa

Wykres efektów brzegowych (*marginal effects at the mean*) z 95% PU:

W modelu regresji zmienną niezależną był dodatkowo wynik testu inteligencji. Przy obliczaniu prezentowanych wartości ustalono jej wartość w średniej dla analizowanej zbiorowości.



**Czy płeć różnicuje osiągnięcia uczniów z matematyki w zasadniczych szkołach zawodowych?**

Czy różnica widoczna na wykresie jest statystycznie istotna?

## Model regresji

Osiągnięcia z matematyki 3615 uczniów polskich szkół pogimnazjalnych, mierzone testem PISA z 2009 r., przewidywane są ze względu na:

- wynik testu inteligencji ogólnej (zmienna ciągła *RAVEN WYN*),
- płeć (zmienna binarna *PLECchłopak*: 0-dziewczyna, 1-chłopak),
- typ szkoły (trzy zmienne binarne: *TYP\_SZK...*),
- interakcje płci i typu szkoły (trzy zmienne binarne *PLECchłopak:TYP\_SZK...*).

parametr	wartość	bł. std.	t	ist.
$b_0$ stała	194,55	7,77	25,04	0,00
$b_1$ RAVEN_WYN	7,14	0,15	47,48	0,00
$b_2$ PLECchłopak	35,34	2,64	13,37	0,00
$b_3$ TYP_SZKliceum profilowane	-72,12	8,98	-8,03	0,00
$b_4$ TYP_SZKtechnikum	-47,94	3,88	-12,37	0,00
$b_5$ TYP_SZKzasadnicza zawodowa	-97,34	5,31	-18,34	0,00
$b_6$ PLECchłopak:TYP_SZKliceum profilowane	11,95	11,92	1,00	0,32
$b_7$ PLECchłopak:TYP_SZKtechnikum	1,12	4,94	0,23	0,82
$b_8$ PLECchłopak:TYP_SZKzasadnicza zawodowa	-23,42	6,22	-3,77	0,00

## Co chcemy obliczyć?

Na wykresie widzimy:

- Średnie wyniki dziewczyn w ZSZ (przy ustalonej wartości  $RAVEN\_WYN$ ):  

$$b_{kZSZ} = b_0 + b_1 E(RAVEN\_WYN) + b_5$$
- Średnie wyniki chłopaków w ZSZ (przy ustalonej wartości  $RAVEN\_WYN$ ):  

$$b_{mZSZ} = b_0 + b_1 E(RAVEN\_WYN) + b_2 + b_5 + b_8$$

Interesującą nas różnicę między płciami w ZSZ opisuje:

- $r_{ZSZ} = b_{mZSZ} - b_{kZSZ} = b_2 + b_8$

parametr	wartość	bł. std.	t	ist.
$b_0$ stała	194,55	7,77	25,04	0,00
$b_1$ RAVEN_WYN	7,14	0,15	47,48	0,00
$b_2$ PLECchłopak	35,34	2,64	13,37	0,00
$b_3$ TYP_SZKliceum profilowane	-72,12	8,98	-8,03	0,00
$b_4$ TYP_SZKtechnikum	-47,94	3,88	-12,37	0,00
$b_5$ TYP_SZKzasadnicza zawodowa	-97,34	5,31	-18,34	0,00
$b_6$ PLECchłopak:TYP_SZKliceum profilowane	11,95	11,92	1,00	0,32
$b_7$ PLECchłopak:TYP_SZKtechnikum	1,12	4,94	0,23	0,82
$b_8$ PLECchłopak:TYP_SZKzasadnicza zawodowa	-23,42	6,22	-3,77	0,00



## Jakie jest oszacowanie błędu standardowego tej statystyki?

Jak dobrze wiadomo:  $D^2(X \pm Y) = D^2(X) + D^2(Y) \pm 2Cov(X, Y)$

Na podstawie macierzy kowariancji parametrów modelu:

	$b_0$	$b_1$	$b_2$	$b_3$	$b_4$	$b_5$	$b_6$	$b_7$	$b_8$
$b_0$	60,38	-1,14	-1,11	-8,96	-7,03	-15,42	3,75	2,18	2,96
$b_1$	-1,14	0,02	-0,03	0,12	0,09	0,25	-0,02	0,01	-0,01
$b_2$	-1,11	-0,03	6,99	2,49	2,54	2,31	-6,92	-6,96	-6,94
$b_3$	-8,96	0,12	2,49	80,72	3,13	4,05	-80,15	-2,60	-2,69
$b_4$	-7,03	0,09	2,54	3,13	15,02	3,62	-2,74	-14,65	-2,68
$b_5$	-15,42	0,25	2,31	4,05	3,62	28,18	-2,90	-2,55	-25,42
$b_6$	3,75	-0,02	-6,92	-80,15	-2,74	-2,90	142,05	6,94	6,95
$b_7$	2,18	0,01	-6,96	-2,60	-14,65	-2,55	6,94	24,43	6,95
$b_8$	2,96	-0,01	-6,94	-2,69	-2,68	-25,42	6,95	6,95	38,63

możemy więc obliczyć:  $D(r_{ZSZ}) = \sqrt{D^2(b_2) + D^2(b_8) + 2Cov(b_2, b_8)} =$   
 $\sqrt{D^2(b_{mZSZ}) + D^2(b_{kZSZ}) - 2Cov(b_{mZSZ}, b_{kZSZ})}$

parametr	wartość	bł. std.	(ko)wariancja	t	ist.
$r_{ZSZ}$	11,92	5,63	31,74	2,12	0,03
$b_{kZSZ}$	443,06	4,96	24,56		
$b_{mZSZ}$	454,98	3,20	10,24		
$2Cov(b_{kZSZ}, b_{mZSZ})$			3,07		

## Czy to w ogóle kiedyś działa?

- Aby reguła *rozłącznych przedziałów ufności* działała, suma szerokość PU dla dwóch efektów brzegowych musiałby być równa szerokości PU dla różnicy, co jest równoważne:

$$D(r_{ZSZ}) = D(b_{kZSZ}) + D(b_{mZSZ})$$

- Taka równość zachodzi **w dwóch specyficznych przypadkach**:

①  $D(b_{kZSZ}) = 0$  lub  $D(b_{mZSZ}) = 0$

Sytuacja tożsama z przyrównywaniem do znanej stałej  $c$ .

Ten warunek będzie **w przybliżeniu spełniony**, gdy:

$$D(b_{kZSZ}) \gg D(b_{mZSZ}) \text{ lub } D(b_{kZSZ}) \ll D(b_{mZSZ})$$

Ale i to jest niezwykle nietypowa sytuacja.

②  $cor(b_{kZSZ}, b_{mZSZ}) = -1$

- Ale w ogólności **nie ma podstaw, by tego oczekiwać!**
- Generalnie  $D(r_{ZSZ}) < D(b_{kZSZ}) + D(b_{mZSZ})$ , a rozbieżność jest tym większa, im bardziej:
  - zbliżone są do siebie wartości błędów standardowych porównywanych efektów brzegowych,
  - korelacja porównywanych efektów brzegowych odbiega od -1.

Jak sobie radzić?


## Kilka możliwych rozwiązań

- Nie rysować wykresów, gdy mówimy o weryfikacji hipotez dotyczących różnicy wartości (kombinacji liniowych) parametrów modelu.

## Kilka możliwych rozwiązań

- Nie rysować wykresów, gdy mówimy o weryfikacji hipotez dotyczących różnicy wartości (kombinacji liniowych) parametrów modelu.
- *Przeskalować* (przemnożyć) szerokość rysowanych przedziałów ufności o czynnik  $\frac{D(r_{\bullet})}{D(b_{k\bullet})+D(b_{m\bullet})}$

## Przeskalowanie PU - ilustracja



TYP_SZK	$\frac{D(r_{\bullet})}{D(b_{k\bullet}) + D(b_{m\bullet})}$
liceum ogólnokształcące	0,70
liceum profilowane	0,71
technikum	0,72
zasadnicza zawodowa	0,69

## Kilka możliwych rozwiązań


- Nie rysować wykresów, gdy mówimy o weryfikacji hipotez dotyczących różnicy wartości (kombinacji liniowych) parametrów modelu.
- *Przeskalować* (przemnożyć) szerokość rysowanych przedziałów ufności o czynnik  $\frac{D(r_{\bullet})}{D(b_{k\bullet})+D(b_{m\bullet})}$ 
  - **Problem 1.:** na jednym wykresie każdy efekt brzegowy możemy porównać tylko z jednym innym efektem brzegowym.
  - **Problem 2.:** łatwo może wprowadzić odbiorcę w błąd - wykres wygląda jak typowy wykres z PU dla efektów brzegowych, ale nim nie jest.

## Kilka możliwych rozwiązań

- Nie rysować wykresów, gdy mówimy o weryfikacji hipotez dotyczących różnicy wartości (kombinacji liniowych) parametrów modelu.
- *Przeskalować* (przemnożyć) szerokość rysowanych przedziałów ufności o czynnik  $\frac{D(r_{\bullet})}{D(b_{k\bullet})+D(b_{m\bullet})}$ 
  - Problem 1.: na jednym wykresie każdy efekt brzegowy możemy porównać tylko z jednym innym efektem brzegowym.
  - Problem 2.: łatwo może wprowadzić odbiorcę w błąd - wygląda jak typowy wykres z PU dla efektów brzegowych, ale nim nie jest.
- Narysować wykres z testowanymi różnicami i PU dla tych różnic.



## Wykres różnic parami z PU



Na wykresie pominięto 12 par efektów brzegowych, w których jednocześnie różniły się od siebie wartości zmiennej *PLEC* i zmiennej *TYP\_SZK*.

## Kilka możliwych rozwiązań

- Nie rysować wykresów, gdy mówimy o weryfikacji hipotez dotyczących różnicy wartości (kombinacji liniowych) parametrów modelu.
- *Przeskalować* (przemnożyć) szerokość rysowanych przedziałów ufności o czynnik  $\frac{D(r_{\bullet})}{D(b_{k\bullet})+D(b_{m\bullet})}$ 
  - Problem 1.: na jednym wykresie każdy efekt brzegowy możemy porównać tylko z jednym innym efektem brzegowym.
  - Problem 2.: łatwo może wprowadzić odbiorcę w błąd - wygląda jak typowy wykres z PU dla efektów brzegowych, ale nim nie jest.
- Narysować wykres z testowanymi różnicami i PU dla tych różnic.
  - I to rozwiązanie polecam.

## Modele z nieliniową funkcją łączącą

- *Przeskalować* (przemnożyć) szerokość rysowanych przedziałów ufności o czynnik  $\frac{D(r_{\bullet})}{D(b_{k\bullet})+D(b_{m\bullet})}$ 
  - Problem 1.: na jednym wykresie każdy efekt brzegowy możemy porównać tylko z jednym innym efektem brzegowym.
  - Problem 2.: łatwo może wprowadzić odbiorcę w błąd - wygląda jak typowy wykres z PU dla efektów brzegowych, ale nim nie jest.
- Narysować wykres z testowanymi różnicami i PU dla tych różnic.
  - I to rozwiązanie polecam.

W regresjach z nieliniową funkcją łączącą (np. logistycznej, probitowej, Poissona, ujemnej dwumianowej) żadne z powyższych rozwiązań **nie pozwala przygotować wykres, na którym efekty byłyby przedstawione na skali zmiennej zależnej** (bez przyjęcia dodatkowych arbitralnych założeń).

Koniec

Dziękuję za uwagę!

Tomasz Żółtak  
t.zoltak@ibe.edu.pl