

Historia Rachunku Prawdopodobieństwa i Statystyki

WYKŁAD VII: Ronald Fisher

MiNI PW, semestr zimowy

Ronald Fisher (1890-1962)

Studiował matematykę i astronomię w Cambridge.

Od 1919 r statystyk w Rothamsted Experimental Station, gdzie stworzył znany departament statystyki.

W 1933 w University College Karl Pearson przechodzi na emeryturę i kierowany przez niego Departament Statystyki zostaje podzielony na dwa:

- ▶ Departament Statystyki (kierownik: Egon Pearson);
- ▶ Departament Eugeniki (kierownik: Ronald Fisher);

1943-1957 profesor genetyki na Uniwersytecie w Cambridge.

1957-1960 Research Fellow Uniwersytetu w Adelaidzie.

Nie był nigdy profesorem statystyki.

Główne osiągnięcia

Książka: *Statistical Methods for Research Workers* (1925) i wiele następnych uzupełnianych wydań.

- ▶ podstawy statystyki teoretycznej (rodzina parametryczna, dostateczność, ..)
- ▶ planowanie eksperymentu;
- ▶ metoda randomizacji;
- ▶ metoda największej wiarygodności i jej optymalność;
- ▶ testy dla małych prób;
- ▶ studentyzacja i jej wykorzystanie;
- ▶


Ronald Fisher (1890-1962)




Ronald Fisher (1890-1962)




Ronald Fisher (1890-1962)




Ronald Fisher (1890-1962)



Ronald Fisher (1890-1962)



Ronald Fisher (1890-1962)



Rothamsted Experimental Station



Główne spory

- ▶ Fisher versus Pearson (miał rację);
- ▶ Fisher versus Mendel (miał rację);
- ▶ Fisher versus Neyman (?);
- ▶ Fisher versus Jeffreys (?);
- ▶ Fisher versus Barnard (nie miał).

Liczba stopni swobody i statystyka χ^2

$$\chi_1^2 = \sum_{i=1}^k \frac{(n_i - np_i)^2}{np_i} = \sum_{i=1}^k \frac{n_i^2 + n^2 p_i^2 - 2nn_i p_i}{np_i} = \sum_{i=1}^k \frac{n_i^2}{np_i} - n.$$

$$\chi_2^2 = \sum_{i=1}^k \frac{(n_i - n\hat{p}_i)^2}{n\hat{p}_i} = \sum_{i=1}^k \frac{n_i^2}{n\hat{p}_i} - n.$$

Podejście parametryczne Fishera:

$$p_i = p_i(\theta), \hat{p}_i = p_i(\hat{\theta}).$$

Liczba stopni swobody i statystyka χ^2

Rozwiniecie $\chi_1^2 - \chi_2^2$ wykorzystujace $(\Delta\theta = \theta - \hat{\theta})$

$$\frac{1}{p_i(\theta)} - \frac{1}{p_i(\hat{\theta})} = -\frac{p_i'(\hat{\theta})}{p_i^2(\hat{\theta})}\Delta\theta + \frac{1}{2}\left(\frac{2}{(p_i^2(\hat{\theta}))^3}[p_i'(\hat{\theta})]^2 - \frac{1}{p_i^2(\hat{\theta})}p_i''(\hat{\theta})\right)(\Delta\theta)^2$$

Daje w efekcie

$$\chi_1^2 - \chi_2^2 \approx \frac{(\theta - \hat{\theta})^2}{\sigma_{\hat{\theta}}^2}.$$

Testy niezależności

W szczególności dla testów niezależności w tablicy kontyngencji $I \times J$ liczba stopni swobody wynosiła $(I - 1) \times (J - 1)$ a nie $I \times J - 1$ jak twierdził K. Pearson.

Fisher (1926): analiza 11688 tablic 2×2 wygenerowanych przez E. Pearsona dla niezależnych cech binarnych.

Srednia wartość statystyki chi kwadrat wyniosła $1.00001 \approx E(\chi_1^2)$ a nie $\approx 3 = E(\chi_3^2)$

Dane Mendla

Mendel analizował zależność koloru od genotypu:

groszek zielony: aa (a-gen recesywny) 25%

groszek żółty: aA i A (A-gen dominujący) 75%

R. Fisher połączył wyniki 84 niezależnych wyników eksperymentów Mendla (tablice 2×2). Sumaryczny $\chi^2 = 42$.

$$\chi_{84}^2 \sim (84, 2 \times 84)$$

i $\sqrt{(2 \times 84)} \approx 13$.

$$P(\chi_{84}^2 \leq 42) = 0.99996$$

Tylko w 4 przypadkach na 100 000 można otrzymać lepszy wynik przy spełnieniu hipotezy zerowej !

Metoda największej wiarogodności

Próbował udowodnić, że estymator NW jest optymalny (ma najmniejszą wariancję) wykorzystując to, że jest statystyką dostateczną.

Rozumowanie: S i T dwie statystyki dla parametru $\theta \in \Theta$. T - jest dostateczna. Załóżmy, że

$$(S, T) \sim N(\theta, \theta, \sigma_S, \sigma_T, \rho).$$

Wtedy

$$E(S|T = t) = \theta + \rho \frac{\sigma_S}{\sigma_T} (t - \theta)$$

Jeśli T - dostateczna, to prawa strona nie zależy od t . Zatem

$$\rho \frac{\sigma_S}{\sigma_T} = 1$$

i stąd

$$\sigma_T = \rho \sigma_S \leq \sigma_S.$$

T ma minimalną wariancję ! Problemy:

Estymator NW może nie istnieć, może nie być statystyką dostateczną ..