

---

***WNISKOWANIE BAYESOWSKIE***  
***WPROWADZENIE W MIARĘ BEZBOLESNE :)***

Łukasz Kwiatkowski

Katedra Ekonometrii i Badań Operacyjnych

## Plan wykładu

- 1) Prawdopodobieństwo – *revisited*
- 2) Dwa podejścia do wnioskowania statystycznego
- 3) Statystyka bayesowska – wyróżniki
- 4) Wnioskowanie bayesowskie – to „lepsze”
- 5) Bayesowski model statystyczny – krok po kroku
- 6) Jeden mem mówi więcej niż tysiąc słów...

## Prawdopodobieństwo – *revisited*

- Pytanie 1: Jakie jest prawdopodobieństwo, że jutro między 7:00 a 9:00 spadnie deszcz?

## Prawdopodobieństwo – *revisited*

- Pytanie 2: Mam w ręce monetę 5 zł. Jakie są szanse, że jeśli nią rzucę, to wypadnie orzeł?

## Prawdopodobieństwo – *revisited*

### ➤ Interpretacje prawdopodobieństwa:

- „**klasyczna**” – prawdopodobieństwo „obiektywne”, częstościowe (definicja Andrieja Kołmogorowa, doprecyzowująca tę zaproponowaną wcześniej przez Richarda von Misesa), rozumiane jako **idealizacja częstości względnej**; zwane także „**fizycznym**”, ale p-stwo **NIE jest jakąś cechą fizyczną**, immanentnie związaną z i określającą jakiś „obiekt” (np. monetę, urnę czy kurs walutowy), zdarzenie czy zdanie logiczne (hipotezę)
- **bayesowska** – prawdopodobieństwo jest miarą subiektywnego stopnia przekonania/pewności co do zajścia jakiegoś zdarzenia (losowego, tj. obarczonego niepewnością) czy prawdziwości pewnej hipotezy

→ Prawdopodobieństwo jest jak ... – każdy ma swoje ;) ALE nie oznacza to jakiegoś dogmatyzmu (*Moje prawdopodobieństwo jest „najmniejsze”, i za Chiny Ludowe go nie zmienię!*)

→ P-stwo ma 2 swoje źródła: wychodzimy od **p-stwa *a priori*** (czyli przed doświadczeniem, eksperymentem, przed wglądem w dane, w empirię), a następnie modyfikujemy je wraz z napływającymi danymi = aktualizacja wiedzy („mojej” wiedzy, rozumianej tu jako „moje” wyobrażenie o kształtowaniu się niepewności odnośnie danego zdarzenia/hipotezy itp.)

→ Statystyka bayesowska oferuje w pełni formalny, zgodny z podstawowymi zasadami rachunku prawdopodobieństwa (wychodząc od definicji wg. Pierre Simone de Laplace), wewnętrznie spójny (koherentny) – choć też nie pozbawiony pewnych paradoksów – sposób modyfikacji mojej wiedzy *a priori* w *a posteriori* (tj. po doświadczeniu, po wglądzie w dane/obserwacje), czyli sposób wyznaczania „mojej” końcowej wiedzy, poprzez połączenie wiedzy *a priori* z informacją płynącą z obserwacji (co jest zgodne z neurofizjologią procesu uczenia się :)

Nie zawsze „a priori” oznacza od razu „Bayesa” :)



## Prawdopodobieństwo – *revisited*

### ➤ Powtórzmy:

- P-stwo jest matematycznym sposobem wyrażania „mojego” (zatem subiektywnego) stopnia przekonania (a tym samym stopnia *niepewności*)
  - Na gruncie statystyki bayesowskiej prawdopodobieństwo ma interpretację subiektywistyczną
- P-stwo ulega modyfikacji (w wyniku procesu „uczenia się”, aktualizacji wiedzy) – od wiedzy/informacji wstępnej (tzw. *a priori*, czyli przed wglądem w dane/obserwacje) do wiedzy końcowej (tj. *a posteriori*, czyli uwzględnieniu informacji zawartej w danych; ang. *evidence*)
  - W modelowaniu parametrycznym (np. regresji) owa „wiedza”/niepewność dotyczyć będzie *parametrów modelu*
- Matematyczny dowód istnienia i jednoznaczności p-stwa jako miary subiektywnego stopnia przekonania nie jest trywialny, ALE JEST :) (XX w.: Morris H. DeGroot, Bruno de Finetti, Leonard Savage)

## Dwa podejścia do wnioskowania statystycznego

- Dwa wiodące – istnieją jeszcze inne koncepcje...
- Te dwie wzmiankowane w tym miejscu bazują, odpowiednio, na „klasycznej” i bayesowskiej interpretacji prawdopodobieństwa:

- **Statystyka „klasyczna”** – inaczej: niebayesowska, częstościowa (ang. *frequentist statistics/inference, frequentist approach to statistics*):

- Jerzy Spława Neyman (1894-1984) – przedziały ufności
- Ronald Fisher (1890-1962) – MNW

- **Statystyka bayesowska** (ang. *Bayesian statistics/inference, Bayesian approach to statistics*):

- **Thomas Bayes** (1702-1760) – angielski matematyk i duchowny; twórcą jako tako nie jest, ale autorem sławnego **wzoru Bayesa** (na p-stwo warunkowe; opublikowanego pośmiertnie):

$$\Pr(A|B) = \frac{\Pr(A \cap B)}{\Pr(B)} = \frac{\Pr(B|A) \Pr(A)}{\Pr(B)}$$

- Pierre Simone de Laplace (1749-1827) – pierwsza formalna definicja p-stwa

→ Chronologicznie podejście bayesowskie jest bardziej „klasyczne” niż podejście „klasyczne” ;)

→ Odnowiciele bayesizmu: Harold Jeffreys, Bruno de Finetti, Leonard Savage, Arnold Zellner





## Statystyka bayesowska – wyróżniki

- Podejście bayesowskie do statystyki odróżnia się od ujęcia wnioskowania „klasycznego” w co najmniej kilku aspektach, wśród których za fundamentalne można uznać:
  - Od strony epistemologii (czyli filozofii poznania): subiektywną – w odróżnieniu od częstościowej – interpretację p-stwa
    - p-stwo jako miara „mojego” stopnia niepewności – najbardziej adekwatną metodą do wyrazu/ujęcia tej niepewności okazują się rozkłady prawdopodobieństwa
  - Od strony „technicznej”: wszystkie elementy modelu statystycznego (tj. zarówno dane, jak i – UWAGA – parametry!) są zmiennymi losowymi  $y = X\beta + \varepsilon$ 
    - dla tych, których nie dowierzają w to, co słyszą powtórzmy: na gruncie bayesowskim PARAMETRY są ZMIENNYMI LOSOWYMI
    - przypomnijmy: na gruncie „klasycznym” parametry są... (?)
- Analogia pomiędzy parametrami (bayesowskiego) modelu statystycznego a położeniem elektronu (fizyka kwantowa)
- Tak więc na gruncie bayesowskim parametry modelu mają swoje... rozkłady prawdopodobieństwa
  - Nie ma więc potrzeby konstruowania czegoś takiego jak estymator (=funkcja danych, która ma „ustrzelić” nieznaną, stałą wartość parametru), choć na gruncie bayesowskim także (o ile chcemy) możemy wyznaczać oceny punktowe parametrów (czyli punktowe wskazania jego położenia) – jako wartość oczekiwana/mediana/modalna *rozkładu* – ale już nie estymatora, tylko bezpośrednio parametru (wydaje się bardziej naturalne :)

## Wnioskowanie bayesowskie – to „lepsze” ;)

### ➤ Zasadniczo, statystyka bayesowska:

- daje po prostu pełny obraz kształtowania się **niepewności** co do możliwych wartości parametrów (poprzez bezpośrednio *ich* – a nie estymatora – rozkłady prawdopodobieństwa), a o to właśnie chodzi w statystyce (← nauka o niepewności, a nie – by tak rzec – o ocenach punktowych)
- wewnątrznie spójne (najbardziej ze wszystkich podejść do wnioskowania statystycznego, choć w dalszym ciągu nie jest wolne od pewnych paradoksów)
- bardzo wymierna i już teraz namacalna dla Państwa korzyść z WB: w końcu naturalnie brzmiące interpretacje przedziałów „ufności” (zwanym w statystyce bayesowskiej *przedziałami wiarygodności*; ang. *credible intervals*)

➤ Choć „lepsze”, to jednak jego zwolennikom/twórcom/propagatorom niezczędzono batów na przestrzeni dziejów. Te przeplatająco-ścierające się dzieje statystyki bayesowskiej i „klasycznej” to istna „Moda na sukces”...

→ Sharon B. McGrayne, (2011), *The Theory That Would Not Die: How Bayes' Rule Cracked the Enigma Code, Hunted Down Russian Submarines, and Emerged Triumphant from Two Centuries of Controversy*, Yale University Press

## Bayesowski model statystyczny – krok po kroku

- Patrz materiał „Podstawowe pojęcia.pdf” (Moodle, w sekcji „Materiały pomocnicze”)
- We wnioskowaniu statystycznym (każdym parametrycznym, nie tylko bayesowskim) mamy zasadniczo dwa obiekty: dostępne **dane** (obserwacje) i **parametry** (pomijamy prognozowanie, gdzie mamy jeszcze *obserwacje niedostępne*):

- **Dane** – wektor obserwacji dostępnych:

$$y = (y_1 \ y_2 \ \dots \ y_T)' \in \underbrace{Y}_{\substack{\text{przestrzeń} \\ \text{obserwacji}}} \subseteq \mathbb{R}^T$$

- dla  $y$  zakładamy, że zostały „wygenerowane” zgodnie z pewnymi założeniami (np. KMNRL), przyjmując dla nich tzw. **model próbkowy** (ang. *sampling model*) albo inaczej **rozkład próbkowy**, czyli rozkład obserwacji, przy założeniu konkretnych (choć o nieznanach wartościach) parametrów,  $\theta$  – przykładowo w KMNRL:

$$p(y|\beta, \sigma^2) = f_N^T(y|X\beta, \sigma^2 I_T) = (2\pi)^{-\frac{T}{2}} (\sigma^2)^{-\frac{T}{2}} \exp \left\{ -\frac{1}{2\sigma^2} (y - X\beta)' (y - X\beta) \right\}$$

- $p(x)$  – **notacja rodzajowa**: funkcja gęstości / masy rozkładu prawdopodobieństwa zmiennej  $x$
- ten „mechanizm powstawania obserwacji” – jeśli spojrzeć na niego tak, jakby argumentem były parametry, a nie obserwacje – to zarazem **funkcja wiarygodności** (ang. *likelihood function*),  $L_y(\theta)$ :

$$\underbrace{L_y(\theta)}_{\substack{\text{funkcja} \\ \text{wiarygodności}}} = \underbrace{p(y|\theta)}_{\substack{\text{rozkład/model} \\ \text{próbkowy}}}$$

- Uwaga:  $y$  jako wektor losowy (wektorowa zmienna losowa, wektor zmiennych losowych) ORAZ  $y$  jako *realizacja* tego wektora (notacyjnie tego tu nie rozróżniamy)


## Bayesowski model statystyczny – krok po kroku

- Patrz materiał „Podstawowe pojęcia.pdf” (Moodle, w sekcji „Materiały pomocnicze”)
- We wnioskowaniu statystycznym (każdym parametrycznym, nie tylko bayesowskim) mamy zasadniczo dwa obiekty: dostępne **dane** (obserwacje) i **parametry** (pomijamy prognozowanie, gdzie mamy jeszcze *obserwacje niedostępne*):

- **Parametry** – wektor (wszystkich) **parametrów** danego modelu:

$$\theta = (\theta_1 \theta_2 \dots \theta_s) \in \underbrace{\Theta}_{\substack{\text{przestrzeń} \\ \text{parametrów}}} \subseteq \mathbb{R}^s$$

- przypomnijmy, że „tu”:  $\theta$  – wektor losowy (a nie nieznanych stałych, jak w ujęciu częstościowym)



# Urov Bayesov

model bayesovski

n. problemov / f. nezgodnosti


$$p(\theta | y) = \frac{p(y, \theta)}{p(y)}$$

R. a posteriorni

bnepova p'ostoš' e  
observnaci

o volitady T'ecme,  
bnepove i usumhove

$$p(y | \theta) p(\theta) \rightarrow R. a priori$$




$D(\beta_1 | y)$

$$\hat{\beta}_1 = Mo(\beta_1 | y) \approx E(\beta_1 | y) \approx Me(\beta_1 | y)$$

# Inyltard 1

Mech  $y_t | \lambda \sim \text{Exp}(\lambda), t=1, \dots, T$



n. unyltardniny  
o par.  $\lambda > 0$

Wyznemy  $p(\lambda | y)$ .

$$p(\lambda | y) = \frac{p(y, \lambda)}{p(y)} = \frac{p(y | \lambda) p(\lambda)}{p(y)}$$

ingrediente :

$y_t \perp y_s, t \neq s$

**Ad 1)**

$$p(y | \lambda) = p(y_1, y_2, \dots, y_T | \lambda) = \prod_{t=1}^T p(y_t | \lambda) =$$

$$e^a \cdot e^b \cdot e^c = e^{a+b+c}$$

$$= \prod_{t=1}^T (\lambda e^{-\lambda y_t}) = \lambda^T \cdot e^{-\lambda \sum_{t=1}^T y_t}$$

$$\Rightarrow p(y | \lambda) = \lambda^T e^{-\lambda \sum_{t=1}^T y_t}$$

$$\underbrace{a \cdot a \cdot \dots \cdot a}_{\neq T} =$$

$$\prod_{t=1}^T (a \cdot b_t) = \left( \prod_{t=1}^T a \right) \cdot \left( \prod_{t=1}^T b_t \right) = a^T \prod_{t=1}^T b_t$$

Ad 2) (n. a priori)



parametry wliczeni a priori  
= hiperparametry


→ Superne są by  $p(\lambda) = f_G(\lambda | a, b)$

$$= \frac{b^a}{\Gamma(a)} \lambda^{a-1} e^{-b\lambda}$$

dalejichs zadanych  
samodzielne  $a, b > 0$

proporcjonalne do

$$\Rightarrow p(\lambda | y) = \frac{p(y | \lambda) p(\lambda)}{p(y)} \propto p(y | \lambda) p(\lambda) =$$



state normalna pęstość n. a posteriori  
(bo nie zależy od  $\lambda$ )

nie mam, ale... po nie potęgujesz i)

$$= \lambda^T e^{-\lambda \sum_{t=1}^T y_t} \cdot \frac{b^a}{\Gamma(a)} \lambda^{a-1} e^{-b\lambda} \propto \lambda^{a+T-1} e^{-\lambda(b + \sum_{t=1}^T y_t)}$$

state

→ Podsum.:  $p(\lambda|y) \propto \underbrace{\lambda^{a+T-1} e^{-\lambda(b + \sum_{t=1}^T y_t)}}_{\text{jądro rozkładu a posteriori}}$

jądro rozkładu  
a posteriori

→ Pytanie:

Czy jest to jądro jakiegoś  
mniejszego rozkładu postera?

→ Odp.: Tak: rozkładu gamma

→ zatem  $p(\lambda|y) = f_G(\lambda|\bar{a}, \bar{b})$ , gdzie  $\bar{a}, \bar{b}$  - "nowe"  
parametry rozkładu gamma

$$\begin{aligned} \bar{a} &= a + T \\ \bar{b} &= b + \sum_{t=1}^T y_t \end{aligned}$$

to same rodzaje rozkładów, co a priori - gamma  
(bo n. a priori jest tu - dla wyznaczonyj  
f. wiaryg. - rozkładem sprzężonym)

ten n. a posteriori reprezentuje naszą wiedzę (po ujęciu  
"dane") "wiedzę" / niepewności dot. param.  $\lambda$ .



- $E(\lambda|y)$
- $M_0(\lambda|y)$
- $Me(\lambda|y)$
- $D(\lambda|y)$
- $Q_1(\lambda|y), Q_2(\lambda|y)$   
i. e.

} Charakteristykū n. a posteriori  
+  
uzlves funkcijū gēstacū