

# Hipotézis tesztről egy prekogníciós kísérlet ürügyén

Hraskó Péter<sup>1</sup>

## 1.A kísérlet és hagyományos kiértékelése

A prekogníciós kísérletet, amelyről szó lesz, *Vassy Zoltán* végezte el [1]. A kísérletben egy pszeudo-véletlen generátor gyors egymásutánban 0 és 1 karaktereket generált. A kísérleti személy feladata az volt, hogy *előre jelezze*, amikor a generált karakter 1-s *lesz* (a részleteket ld. az idézett cikkben).

Mindegyik kísérleti személy egy ülésben  $n = 36$  próbát tett és összesen  $N = 100$  ülés történt. Az egyes üléseken a találatok számát  $x_i$ -vel jelöljük ( $i = 0, 1, 2, \dots, 100$ ). Az eredményeket az alábbi táblázat tartalmazza:

23	22	27	20	13	13	16	20	14	20
19	20	20	20	21	17	20	23	14	16
17	11	23	17	12	22	21	15	24	13
17	16	16	22	18	18	20	15	12	17
22	12	21	19	24	20	14	20	16	23
20	17	22	26	15	18	17	16	14	24
21	17	23	19	15	18	24	20	16	20
19	25	17	19	20	17	18	20	18	21
14	16	18	14	21	21	22	16	13	14
22	20	20	17	16	20	15	14	18	24

## A találatok száma az egyes üléseken

(az egy oszlopban található adatok egy adott kísérleti személyhez tartoznak, de a továbbiakban ennek nem lesz jelentősége).

Elfogadott világképünk szerint a kísérleti személy nem tudhatja előre, milyen karaktert ad ki a generátor a következő pillanatban, ezért azt várjuk, hogy a találat valószínűségét a  $p = 1/2$  valószínűségű binomiális eloszlás írja le, amelynek varianciája  $1/4$ -del egyenlő. Egy ülésre kivetítve ez átlagosan 18 találatot jelent  $\sigma_0^2 = 36 \times 1/4 = 9$  varianciával. Az eloszlás jó közelítésben gaussianak vehető. Ez a *null-hipotézisünk*, amelyet tesztelni kívánunk.

---

<sup>1</sup>Ez a cikk nem születhetett volna meg azok nélkül a diskussziók nélkül, amelyeket az évek során Gábor fiammal folytattam, elsősorban a Randi-alapítvány keretei között tervezett, de soha meg nem valósult nagyszabású homeopátia-teszt kapcsán.

Az empirikus átlag 18.46-tal egyenlő, amely 5%-os szinten nem szignifikáns (a 0.1914  $p$ -érték nagyobb 0.05-nél). A khi-négyzet-próba ([2] 7.fejezet) azonban mást mutat. A mintából képzett  $\chi^2$  ugyanis<sup>2</sup>

$$\chi^2 = \frac{\sum_1^{100} (x_i - 18)^2}{\sigma_0^2} = 136.8889. \quad (1)$$

A [2] B.6 táblázata szerint ez az érték 1%-os szinten *szignifikáns* (a  $p$ -érték majdnem pontosan 0.01-gyel egyenlő). A szignifikancia-tesztek mára kialakult felfogása szerint ez arra utal, hogy a null-hipotézist el kell vetni és a prekogníció lehetőségét komolyan kell venni. Vassy cikkének címében a második rész erre utal.

## 2.A bayesi megközelítés

Létezik azonban egy másik kiértékelési eljárás is. A kísérlet indítéka nyilván annak megvizsgálása volt, hogy a null-hipotézis (amelyet a továbbiakban  $A$ -hipotézisnek fogunk nevezni) érvényes-e. A khi-négyzet-próba szignifikanciája következtében ez kétségesse vált, és a kísérletezőben megfogalmazódott egy alternatív  $B$  hipotézis, amely szerint a szórás lehet nagyobb, mint amennyi az  $A$ -hipotézis alapján várható. A kísérlet eredménye megengedi, hogy az egyszerűség kedvéért az átlagra a  $B$  hipotézisben is megtartsuk a 18 találatot.

A kérdés mármost nyilván így fogalmazható meg: melyik a valószínűbb, az  $A$  vagy a  $B$  hipotézis?

Jelöljük a két hipotézis valószínűségét  $\text{val}(A|\mathcal{D}, I)$ -vel és  $\text{val}(B|\mathcal{D}, I)$ -vel<sup>3</sup>. A  $\mathcal{D}$  a mért  $x_i$  találat-számokat reprezentálja (data), az  $I$  pedig az összes lényeges háttér-információt. A  $\text{val}(A|\mathcal{D}, I)$  eszerint az  $A$  hipotézis valószínűsége a táblázatban összefoglalt  $\mathcal{D}$  mérési adatok és a lényeges háttér-információk figyelembe vételével, és természetesen hasonló jelentése van a  $\text{val}(B|\mathcal{D}, I)$  valószínűségnek is. A továbbiakban a  $\text{val}(B|\mathcal{D}, I)/\text{val}(A|\mathcal{D}, I)$

---

<sup>2</sup>Ha a 18 átlagot a 18.45 empirikus átlaggal helyettesítjük, a  $\chi^2$ -re a 134.5378 értéket kapjuk. A szignifikancia szint szempontjából a különbség lényegtelen. Mivel a következő fejezetben a (1) alakra lesz szükségünk, erre tartjuk fenn a  $\chi^2$  jelölést.

<sup>3</sup>A  $\text{val}()$  függvény első argumentuma mutatja, minek a valószínűségéről van szó, a második pedig azt, hogy ez a valószínűség milyen feltételek mellett érvényes. Mivel minden valószínűséget egyöntetűen a  $\text{val}()$  szimbólummal jelölünk, csak az argumentumból derül ki, milyen valószínűségről van szó.

*hányados* becslését tűzzük ki célul a [3] könyv 4.fejezetének gondolatmenete alapján.

A Bayes-tétel felhasználásával a két valószínűséget átalakíthatjuk a következő módon:

$$\begin{aligned}\text{val}(B|\mathcal{D}, I) &= \frac{\text{val}(\mathcal{D}|B, I) \cdot \text{val}(B|I)}{\text{val}(\mathcal{D}|I)} \\ \text{val}(A|\mathcal{D}, I) &= \frac{\text{val}(\mathcal{D}|A, I) \cdot \text{val}(A|I)}{\text{val}(\mathcal{D}|I)}.\end{aligned}$$

A számlálók első tényezője a mért adatok valószínűsége a  $B$  ill. az  $A$  hipotézis érvényessége esetén. Látni fogjuk, hogy a hipotéziseink alapján ezt a két valószínűséget ki lehet számítani. A számlálók második tényezője a hipotézisek valószínűsége a mérési adatok figyelembevétele nélkül, azaz a mérés elvégzése előtt. Ezeket az  $A$  és a  $B$  *a priori* valószínűségének hívjuk. A baloldali (keresett) mennyiségek ugyanezen hipotézisek valószínűségei a mérés eredményének figyelembe vételével (*a posteriori* valószínűségek).

Végül a nevező, amely mindkét törtben ugyanaz, a  $\mathcal{D}$  mérési eredmény valószínűsége bármilyen hipotézis mellett. Ha  $A, B, C, D, E \dots$  az összes egymást kizáró hipotézis, amely  $\mathcal{D}$ -t megengedi, akkor  $\text{val}(\mathcal{D}|I)$  a  $\mathcal{D}$  adathalmaznak a hipotézisek valószínűségével súlyozott valószínűsége:

$$\begin{aligned}\text{val}(\mathcal{D}|I) &= \text{val}(\mathcal{D}|A, I) \cdot \text{val}(A|I) + \text{val}(\mathcal{D}|B, I) \cdot \text{val}(B|I) + \\ &+ \text{val}(\mathcal{D}|C, I) \cdot \text{val}(C|I) + \text{val}(\mathcal{D}|D, I) \cdot \text{val}(D|I) + \dots\end{aligned}$$

Arról természetesen szó sem lehet, hogy ezt valamilyen módon megbecsüljük, de erre nincs is szükség, mert a  $\text{val}(B|\mathcal{D}, I)/\text{val}(A|\mathcal{D}, I)$  törtből kiesik:

$$\frac{\text{val}(B|\mathcal{D}, I)}{\text{val}(A|\mathcal{D}, I)} = R \cdot \frac{\text{val}(B|I)}{\text{val}(A|I)}, \quad (2)$$

amelyben

$$R = \frac{\text{val}(\mathcal{D}|B, I)}{\text{val}(\mathcal{D}|A, I)} \quad (3)$$

az u.n. *Bayes-arány*. A mérés analízise a Bayes-arány számértéke alapján történik.

Az  $A$  hipotézis szerint  $\text{val}(\mathcal{D}|A, I)$  az  $1/2$  valószínűséghez tartozó binomiális eloszlás, amelyet a

$$\text{val}(\mathcal{D}|A, I) = \frac{1}{\sigma_0^N (2\pi)^{N/2}} e^{-\frac{\sum (x_k - \mu)^2}{2\sigma_0^2}} \quad (4)$$

Gauss-eloszlással közelítünk ( $N = 100$ ,  $\sigma_0^2 = n/4 = 9$ ,  $\mu = n/2 = 18$ ).

A  $\text{val}(\mathcal{D}|B, I)$  számítása nem ilyen egyszerű. Ez ugyanis nem egy határozott varianciájú Gauss-eloszlás, mert a  $B$  hipotézis szerint a populációban valamilyen eloszlásban létezik egy olyan (feltehetően prekognícióval kapcsolatos) képesség, amely abban nyilvánul meg, hogy a prekogníciós kísérlet üléseiben a találatok  $\sigma$  varianciája *nagyobb vagy egyenlő*, mint a binomiális eloszláshoz tartozó  $\sigma_0^2$  érték. Az elsődleges valószínűségünk tehát  $\text{val}(\mathcal{D}, \sigma|B, I)$ , amely  $\sigma$ -ban is egy valószínűség (pontosabban valószínűségi sűrűség), amelyről csupán annyit tudunk, hogy csak  $\sigma \geq \sigma_0$ -nál különbözik zérustól. A kísérletünk azonban csak a  $\mathcal{D}$  adatokat (az  $x_k$ -kat), szolgáltatja, ezért a  $\text{val}(\mathcal{D}|B, I)$  valószínűséget  $\text{val}(\mathcal{D}, \sigma|B, I)$ -ből a  $\sigma$  szerinti marginalizálással kapjuk:

$$\text{val}(\mathcal{D}|B, I) = \int_{\sigma_0}^{\infty} d\sigma \text{val}(\mathcal{D}, \sigma|B, I).$$

A feltételes valószínűség definíciója alapján az integrandust át lehet alakítani a következő módon:

$$\text{val}(\mathcal{D}|B, I) = \int_{\sigma_0}^{\infty} d\sigma \text{val}(\mathcal{D}|\sigma, I) \text{val}(\sigma|B, I), \quad (5)$$


amelyben  $\text{val}(\sigma|B, I)$  a  $\sigma$  sűrűsége a  $B$  hipotézis és a háttér-információk figyelembevételével. Ezek alapján csak annyit tudunk, hogy

1.  $\sigma < \sigma_0$ -nál  $\text{val}(\sigma|B, I) = 0$ ,
2.  $\text{val}(\sigma_0|B, I) \neq 0$  (mert  $B$  szerint a populációban lehetnek olyanok, akik a prekogníciós tesztben a véletlennek megfelelő eredményt produkálják), és
3.  $\int_{\sigma_0}^{\infty} d\sigma \text{val}(\sigma|B, I) = 1$ .

A 3. feltétel azt követeli, hogy amikor  $\sigma \rightarrow \infty$ , a  $\text{val}(\sigma|B, I)$  legalább olyan gyorsan tartson nullához, mint  $1/\sigma^2$ , ezért egy lehetséges választás a következő:

$$\text{val}(\sigma|B, I) = \frac{(\lambda + 1)\sigma_0^{\lambda+1}}{\sigma^{\lambda+2}} \quad (\lambda \geq 0). \quad (6)$$

A  $\lambda$  értékét tetszőlegesen választhatjuk, de ezt az önkényességet ki tudjuk küszöbölni úgy, hogy az analízisben *az összes nemnegatív*  $\lambda$ -ra tekintettel leszünk.



A Bayes-hányados  $\lambda$ -függése  $\chi^2=136.8889$ -nél

A (6) választás természetesen nem az egyedül lehetséges. Választhatnánk helyette pl. a  $(\lambda/\sigma_0)e^{-\lambda(\sigma-\sigma_0)/\sigma_0}$  függvényeket is, amelyek a végtelenben gyorsabban válnak nullává, mint a (6) család. Ebben a dolgozatban azonban ez utóbbit fogjuk használni.

A Bayes-arány a mért  $\chi^2$ -től, a minta  $N$  nagyságától és a  $\lambda$  paramétertől függ. Az  $R = R(\chi^2, N, \lambda)$  számítását a Függelékben vázoljuk. Az ábra az  $R(136.8889, 100, \lambda)$  függvényt mutatja.

Mint látható, a Bayes-arány sehol sem nő 0.5 fölé. Ebből az következik, hogy a  $B$  hipotézis valószínűsége az  $A$  valószínűségéhez képest nem válik nagyobbá a tárgyalt mérés következtében.

### 3. Diszkusszió

A két előző fejezet összehasonlításakor az első dolog, ami szembe ötlik az, hogy egymásnak ellentmondó konklúzióval zárulnak, a második pedig az, hogy a hagyományos eljárás olyan fogalmakkal operál ( $p$ -érték, khi-négyzet-próba), amelyeknek a megértése nem lehetséges a matematikai statisztika elég alapos ismerete nélkül, míg a bayesi módszerben a valószínűségszámításnak csak a legegyszerűbb fogalmait használtuk. Ez utóbbi módszerben viszont az jelenti a gondot, hogy a valószínűségekhez, amelyekkel operáltunk, nem rendelhető pontos számérték. Valóban, egy hipotézis valószínűsége bizonyos feltételek mellett teljesen más jellegű, mint annak valószínűsége, hogy a ma-

gyarkártya csomagból pirosat húzzunk, vagy hogy egy radioaktív atom a következő másodpercben elbomoljon. Ezekben az esetekben tetszőleges számú megfigyelést végezhetünk azonos körülmények között, és a vizsgált esemény valószínűségét egyenlőnek vehetjük az esemény bekövetkeztének *relatív gyakoriságával*, amelyet ráadásul sok esetben (pl. az előbb idézett első példában, és nagyon gyakran a másodikban is) előre ki tudunk számítani. Egy hipotézis valószínűségénél, vagy egy pszichológiai tulajdonság valamilyen mértékű megléténél erről természetesen szó sem lehet.

Érdekes módon ennek ellenére a kérdést, amelyből a 2. fejezetben kiindultunk (hogy t.i. melyik valószínűbb: az  $A$  vagy a  $B$  hipotézis) tökéletesen értelmesnek érezzük, nagyon gyakran feltesszük magunknak vagy másoknak, és *kvalitatíve* meg is válaszoljuk pl. így: „Az  $A$  sokkal valószínűbb mint a  $B$ ”, vagy „mindkettőt nagyjából egyenlően valószínűnek tarthatjuk”. Sokszor még egyetlen hipotézis kapcsán is kijelentjük, hogy „egyáltalán nem valószínű”, de alighanem az ilyen esetekben is meghúzódik a háttérben valamilyen viszonyítási alap.

Nagy kérdés, hogy a valószínűségszámítás formalizmusa (a feltételes valószínűség definíciója, a Bayes-tétel, stb) alkalmazható-e az ilyen *szubjektív valószínűségekre*. Ha nem, akkor a 2. fejezetet totál értelmetlenségnek kellene minősítenünk. De több gondolatmenet is ismeretes (a legfontosabb nevek itt *F. P. Ramsey, H. Jeffreys, R. T. Cox*), amely arra a következtetésre jut, hogy a valószínűségszámítás alkalmazható az olyan kvalitatív jellegű valószínűségekre is, amelyek nem értelmezhetők relatív gyakoriságként. Ez azért van így, mert a valószínűségszámítás axiómái összhangban vannak a tudományos következtetés logikájával ([3], [4]), és a valószínűségszámítás az ilyen esetekben tulajdonképpen a tudományos következtetés (részleges) formalizálása.

A *fogadás* az a tipikus helyzet, amikor a szubjektív valószínűség számokban is kifejeződik, ezért amikor szubjektív valószínűségekkel dolgozunk, célszerű a valószínűség helyett az  *$\mathcal{O}$  esélyhányadosról* (oddszról) beszélni. Ha arra fogadok, hogy a magyarkártya csomagból a legközelebbi húzásnál piros jön ki, és a bukmékernek felajánlom, hogy erre 1-t teszek 10 ellenében, akkor a bukméker bizonyosan visszautasítaná, mert nyilván ráfizetne. Ha viszont azt mondja, hogy ha én 1-t teszek, akkor ő hajlandó 2-t tenni, akkor én nem fogok belemenni a dologba. Üzletet csak akkor köthetünk, ha én 1-t teszek a bukméker 3-a ellenében (ez volna az „igazságos fogadás”), de ekkor nem lenne semmi értelme az egésznek, mert hosszú távon mindketten a pénzünknel maradnánk.

Fogadásokat azonban mégis kötnek, többnyire olyan esetekben, amikor a

valószínűséget nem lehet pontosan tudni<sup>4</sup> (a klasszikus példa a lóverseny). Mi áll ilyenkor a fogadás háttérében? Az egyik lehetőség az, hogy mindkét fél megtippeli az „igazságos fogadás” arányát, és a fogadó igyekszik ezt csökkenteni (a példában 1/3 helyett 1/10-et ajánl), a bukméker pedig növelni (1/3 helyett 1/2-re). Az már a körülményeken múlik, milyen arányban állapodnak végül meg. Egy másik lehetőségre a példa a *Nyolcvan nap alatt a Föld körül*-ből Phileas Fogg egy az egyhez arányú fogadása öt barátjával, amelynek a tétje 20000 font volt. Mindkét fél bízott az esélyeiben, de tudatában volt annak, hogy komoly kockázatot vállal. Fogg valószínűleg úgy gondolta, hogy reálisan fogadhat mondjuk 2:1 vagy 3:1 arányban, a barátai pedig, hogy (Fogg nézőpontjából megfogalmazva) az 1:2, 1:3 arány vállalható. Ebből születhetett a legegyszerűbb 1:1 arányú megállapodás. Itt tehát két különböző szubjektív valószínűség kompromisszumáról van szó, nem pedig egyetlen többé-kevésbé ismert arány torzításáról.

Hogyan függ össze az oddsz a valószínűséggel? A kártyás példában az  $\mathcal{O}$  esélyhányados az 1:3 arány. Annak valószínűsége, hogy pirosat húzunk,  $p = 1/4$ -del, annak valószínűsége pedig, hogy más színt húzunk,  $q = 1 - p = 3/4$ -del egyenlő. Az esélyhányados  $p/q$ -val egyenlő:  $\mathcal{O} = p/q = p/(1 - p)$ . Ebből kifejezhetjük a valószínűséget:  $p = \mathcal{O}/(1 + \mathcal{O})$ . Ha elfogadjuk, hogy a fogadások valamilyen szubjektív esélyhányados alapján születnek és ez konkrét összegekben realizálódik, akkor ugyanilyen alapon a szubjektív valószínűségnek is tulajdoníthatunk valamilyen értéket, ha nem is pontosat.

Térjünk most vissza a prekogníciós kísérlethez. Az előző fejezetben csak az  $A$  és a  $B$  hipotézissel foglalkoztunk, de nem zártuk ki annak lehetőségét, hogy más hipotézisek is szóba jöhetnek. Ezt a lehetőséget továbbra is fenntartva megállapodhatunk abban, hogy mostantól csak az  $A$  és a  $B$  hipotézisre koncentrálunk. Ezt a megállapodásunkat a háttér-információ részének fogjuk tekinteni, ezért a háttér-információra  $I$  helyett az  $I_r$  (redukált) jelet fogjuk használni. A  $\text{val}(B|\mathcal{D}, I_r)$  és a  $\text{val}(A|\mathcal{D}, I_r)$  valószínűségek összege nyilván 1-gyel egyenlő és ugyanez igaz a  $\text{val}(B|I_r)$  és a  $\text{val}(A|I_r)$  valószínűségek összegére is. Az *arányaik* azonban nem változhatnak, ezért pl.

$$\text{val}(B|\mathcal{D}, I_r) = \frac{\text{val}(B|\mathcal{D}, I)}{\text{val}(B|\mathcal{D}, I) + \text{val}(A|\mathcal{D}, I)},$$

---

<sup>4</sup>Lehetséges olyan fogadás is, amikor a valószínűségek pontosan ismertek. A lottozó például úgy köt fogadást a Szerencsejáték RT-vel, hogy pontosan ki tudja számítani az esélyeit és ráadásul azzal is tisztában van, hogy a Szerencsejáték RT folyamatosan nyer az ügyleten.

és hasonló képlet érvényes a másik három valószínűségre is.

A (2) ezután a következő formában is felírható:

$$\mathcal{O}'/\mathcal{O} = R, \quad (7)$$

amelyben  $\mathcal{O} = \text{val}(B|I_r)/\text{val}(A|I_r)$  a  $B$  esélyhányadosa az  $A$ -val szemben a kísérlet elvégzése előtt (prior oddsz),  $\mathcal{O}' = \text{val}(B|\mathcal{D}, I_r)/\text{val}(A|\mathcal{D}, I_r)$  pedig ugyanez a mérési eredmények ismeretében (poszterior oddsz). A (2)-nak ez az alakja plasztikusabban fejezi ki a képlet tartalmát, mint a korábbi, mert már a formájával azt sugallja, hogy az  $R$  pontos számértékének nincs jelentősége. Ezért fogalmaztuk már az előző fejezet végén az  $R(\lambda)$  görbéből levonható tanulságot a konkrét számértékek felhasználása nélkül, amelyet most így ismételhünk meg: A vizsgált mérés változatlanul hagyja a  $B$  és az  $A$  hipotézisek esélyhányadosát.

De hogy lehet ez? Az  $A$  hipotézis alapján  $\chi^2$ -re 100 körüli értéket várunk a ténylegesen mért 137-tel szemben, amit határozottan jelentős különbségnek érzünk. Nem túlzottan kicsi ez az  $R \approx 0.5$  ehhez a várához képest?

Az  $R \approx 0.5$  egyáltalán nem olyan nagyon kicsi. A  $\chi^2 = 100$ -hoz ugyanis *sokkal kisebb*  $R$  tartozik, mint 0.5: a  $\lambda = 0$ -hoz és a  $\lambda = 10$ -hez tartozó érték pl.  $R(100, 0, 100) = 6.067385 \cdot 10^{-5}$  és  $R(100, 10, 100) = 0.03424274$ . Ha ilyen  $R$ -t kaptunk volna, ebből a  $B$  esélyhányadosának lényeges csökkenése következett volna. A mért  $R \approx 0.5$  ezeknél legalább egy nagyságrenddel nagyobb. De a Bayes-módszer logikája szerint ez a tetemes növekedés se elég ahhoz, hogy a bizalmunkat határozottan a  $B$  felé fordítsa, amikor eredetileg nem tudunk választani a két hipotézis között (vagyis amikor az apriori oddsz kb. 1-gyel egyenlő). Amikor pedig ez az apriori oddsz már önmagában nagyon kicsi, mint a vizsgált esetben, akkor továbbra is ugyanolyan kicsi marad.

A hagyományos kiértékelési eljárás a bayesitől nagyon eltérő elveken alapul. Az alapvető különbség az, hogy csak olyan valószínűségeket fogad el, amelyeknek (legalább elvben) pontos számértékük van. Ebben az eljárásban ezért a hipotézisek valószínűsége nem fordulhat elő. De a kérdés, amire választ kell adnia, változatlanul az, hogy melyik valószínűbb: az  $A$  vagy a  $B$  hipotézis. A hagyományos statisztikában ezeket nullhipotézisnek és ellenhipotézisnek hívják. Az [1]-ben követett kiértékelésben azonban, amelyet az 1. fejezetben ismertettünk, nem volt ellenhipotézis, ezért csak az lehetett a vizsgálat tárgya, hogy mennyire valószínű a nullhipotézis önmagában (*Fisher-teszt*). Ezzel a típusú kérdésfeltevéssel sajnos mindmáig nagyon gyak-

ran lehet találkozni még a referált tudományos folyóiratokban is, hiába hangsúlyozzák már régóta a statisztikusok, hogy egy hipotézis érvényességét csak egy ellenhipotézishez viszonyítva lehet vizsgálat tárgyává tenni (*Pearson-Neyman-teszt*).

Azonban, mint mondtuk, a hagyományos statisztika valójában sohasem operál maguknak a hipotéziseknek a valószínűségével, ezért a Fisher-teszt sem ezt a valószínűséget vizsgálja. Amikor arra a következtetésre jut, hogy a nullhipotézis mondjuk 1%-os szinten szignifikáns, akkor ennek az az értelme, hogy az ilyen típusú ítéleteknek csak legfeljebb 1 százaléka téved a statisztikus. Vagyis minden száz eset közül, amelyeket 1%-s szinten szignifikánsnak talál, csak egyetlen esetben bizonyul a nullhipotézis mégis érvényesnek (de azt persze nem lehet tudni, melyikben). Az a valószínűség tehát, amelyen a szignifikancia tesztek alapulnak, nem a vizsgált hipotézisre, hanem a pontosan szabályozott statisztikai eljárásra vonatkozik. Ez utóbbiakat ugyanis nagyon sokszor meg lehet ismételni, ezért értelmezhető rájuk valószínűség a relatív gyakoriság alapján.

A hagyományos és a bayesi statisztika között ílymódon alapvető különbség van és egyáltalán nem meglepő, hogy sokszor jutnak ellentétes következtetésre. Ez történt a prekogníciós kísérlet esetében is. Sőt, egészen általános formában megmutatható, hogy amikor a minta mérete nő, és a Fisher-teszt folyamatosan szignifikáns ugyanazon  $p$ -érték mellett, akkor biztosan ellentétbe kerülnek egymással (*Jeffreys-Lindley paradoxon*).

A prekogníciós kísérletben ez a következőt jelenti. Tegyük fel, hogy a kísérletet újra meg újra megismételjük, ezért a minta  $N$  mérete egyre nagyobbá válik. Tegyük fel azt is, hogy a Fisher-tesztet is mindig elvégezzük, amikor a minta észrevehető mértékben megnő, és mindig azt találjuk, hogy ugyanon  $p = 0.01$  érték mellett szignifikáns. A teszt hagyományos értelmezése szerint ez újra és újra megerősít abban, hogy a nullhipotézist el kell vetni. A Függelekben azonban megmutatjuk, hogy ugyanekkor az  $R$  nullához tart. De ha a Bayes-arány nulla, akkor a  $B$  hipotézis esélye az  $A$ -val szemben nulla, tehát az  $A$  nullhipotézis korrekt. Az ellentmondás nyilvánvaló.

De melyik következtetés a hihetőbb? A bayesi felfogás mellett elsősorban az szól, hogy azon a valószínűségen alapul, amely a vizsgálat tárgyát képezi. Egy további érv mellette, hogy a hagyományos statisztikában elismerik: A  $p$ -értéket a minta növelésével csökkenteni kell. Ez a bayesi érvelés helyességének hallgatólagos beismerése, amely kikezdi a hagyományos hipotézis tesztek talán legfontosabb motivációját, a szubjektív elem kiküszöbölését.

A szubjektív elem kiküszöbölésének az igénye vezetett oda, hogy — leg-

alább is a nemstatisztikus kutatók kezében — a statisztikai tesztek teljesen mechanikussá, technikai jellegűvé váltak (misztifikálódtak, ahogy a [2] 162. oldalán olvashatjuk). A bayesi megközelítésnek nem lebecsülendő előnye, hogy ezt a tendenciát nem támogatja, mert minden konkrét eset külön elemzést igényel (hasonlítsuk csak össze ebből a szempontból az 1. és a 2. fejezetet). Az is fontos körülmény, hogy a Bayes-arányra csak akkor kaphatunk számértéket, ha a hipotézisek állításait matematikai formába tudjuk önteni. Ezért sokkal nehezebb összemosni a kísérletben vizsgált hipotézist azzal az elmélettel, amely a hipotézis alapjául szolgál. A 2. fejezetben az  $A$  hipotézisen a (4) normálegoszlást, a  $B$  hipotézisen pedig a (6) függvényvel súlyozott normál eloszlást értettük, nem pedig azt, hogy „nincs prekogníció” és „van prekogníció”. A kísérletre csak abban az esetben tekinthetnénk úgy, hogy *ez utóbbi* alternatívára vonatkozik, ha létezne egy legalább kiindulópontnak tekinthető elméleti elképzelés arról, hogy hogyan okozhatja a prekogníció a  $p = 1/2$ -hez tartozó binomiális eloszlás kiszélesedését a  $p$  értékének megváltozása nélkül. A statisztika *önmagában* nem képes létrehívni ilyen elméletet, csak már többé-kevésbé határozottan körvonalazott elméletek tartalmi elemzéséhez szolgáltatathat támpontokat.

## Függelék

Az  $R(\chi^2, N, \lambda)$  képletének levezetésére helyettesítsük (5)-be a (6) függvényt:

$$\text{val}(\mathcal{D}|B, I) = \int_{\sigma_0}^{\infty} d\sigma \frac{1}{\sigma^N (2\pi)^{N/2}} e^{-\frac{\sum (x_k - \mu)^2}{2\sigma^2}} \cdot \frac{(\lambda + 1)\sigma_0^{\lambda+1}}{\sigma^{\lambda+2}}. \quad (8)$$

A  $\sum (x_k - \mu)^2$  összeget az (1) alapján helyettesítsük  $\chi^2 \sigma_0^2$ -tel, majd pedig térjünk át a  $\sigma$  integrációs változóról a  $t$  változóra a  $\sigma = \sigma_0 \chi / \sqrt{t}$  képlet szerint:

$$\text{val}(\mathcal{D}|B, I) = \frac{(\lambda + 1)}{\sigma_0^N (2\pi)^{N/2} \chi^{N+\lambda+1}} \int_0^{\chi^2} dt \cdot t^{\frac{N+\lambda-1}{2}} e^{t/2}. \quad (9)$$

Az integrandus normálás erejéig a  $\chi^2$ -eloszlás

$$f(t, \nu) = \frac{1}{2^{\nu/2} \Gamma(\frac{\nu}{2})} t^{\frac{\nu}{2}-1} e^{-t/2} dt \quad (10)$$

sűrűségfüggvénye  $\nu = (N + \lambda + 1)$ -nél, az integrál maga pedig az eloszlásfüggvény, amelyet  $F(\chi^2, \nu)$ -vel fogunk jelölni.

Fejezzük ki most a (9)-ben a  $t$ -integrált az  $F(\chi^2, N + \lambda + 1)$  függvényen keresztül. A gamma-függvényre pedig használhatjuk az aszimptotikus alakját, amely ([6], (6.1.39))

$$\Gamma(z) \sim \sqrt{2\pi} e^{-z} z^{z-1/2}.$$

Végül az így átalakított  $\text{val}(\mathcal{D}|B, I)$ -t, valamint a  $\text{val}(\mathcal{D}|A, I)$  (4) képletét helyettesítsük be (3)-ba. Ezt kapjuk:

$$R(\chi^2, N, \lambda) \sim 2\sqrt{2\pi} \frac{\lambda + 1}{N + \lambda + 1} e^{\frac{1}{2}[\chi^2 - (N + \lambda + 1)]} \left( \frac{N + \lambda + 1}{\chi^2} \right)^{\frac{N + \lambda + 1}{2}} F(\chi^2, N + \lambda + 1). \quad (11)$$

Ezt a képletet használtuk az  $R$ -függvény számítására.

A Jeffreys-Lindley paradoxon igazolásához [6] (26.4.16) képletét használhatjuk, amely nagy szabadsági foknál lehetővé teszi az adott  $p$ -értékhez tartozó  $\chi_p^2$  kiszámítását:

$$\chi_p^2 \sim \frac{1}{2}(x_p + \sqrt{2\nu - 1})^2 \quad (\nu > 100)$$

(az  $x_p$  a nulla átlagú, egységnyi szórású normál eloszlás adott  $p$ -értékhez tartozó kritikus argumentuma). Helyettesítsük ezt  $\nu = (N + \lambda + 1)$ -nél (11)-be, vegyük figyelembe, hogy  $F(\chi_p^2, N + \lambda + 1) = 1 - p$ , és tartsunk  $N$ -nel végtelenhez. Az  $N$ -ben vezető tagokat megtartva azt találjuk, hogy  $R$   $1/e^{N/2}$ -ként tart a nullához.

## Irodalom

- [1] Z. Vassy, *Experimental Study of Precognitive Timing — Indication of a Radically Noncausal Operation*, Journal of Paraphysiology, Vol. 54, 299 (1990).
- [2] Reiczigel Jenő, Harnos Andrea, Solymosi Norbert *Biostatistika* (Pars, 2007)
- [3] D. S. Sivia (with J. Skilling) *Data Analysis* (Oxford University Press, 2006)
- [4] C. Howson and P. Urban: *Scientific Reasoning: The Bayesian Approach*, 3. edition, Open Court, 2006
- [5] Pólya György *A plauzibilis következtetés elmélete. A matematikai gondolkodás művészete II.* Gondolat 1989, XV. fejezet.
- [6] M. Abramowitz and I. A. Stegun, Handbook of Mathematical Functions