

A LEHMANN PRÓBÁRÓL

ZAJTA AURÉL¹

A LEHMANN-próba két minta összehasonlítására szolgál. A próba a nem-paraméteres módszerek közé, pontosabban: a rendezett minták elméletébe tartozik, és a WILCOXON-próba továbbfejlesztésének tekinthető.

Definíciók és jelölések

A két összehasonlítandó minta közül az egyiknek elemeit ξ_i -vel ($i = 1, 2, \dots, m$), a másiknak az elemeit η_k -val ($k = 1, 2, \dots, n$) jelöljük. A minták elemszámai, m és n nem szükségképpen egyenlők. A ξ_i , ill. η_k mintavételi változók eloszlásfüggvényeit $F(x)$ -szel, ill. $G(x)$ -szel jelöljük; ezekről feltesszük, hogy folytonosak. Így zérussal egyenlő annak a valószínűsége, hogy a ξ_i és η_k változók együttesében két változó értéke megegyezzzék, s ezért jogosan tételezhetjük fel, hogy valamennyi ξ_i és η_k különböző. Ebből viszont tovább következik, hogy a ξ_i és η_k változók, külön-külön és együttesen is, szigorúan növekvő sorozatba rendezhetők.

A nagyság szerint rendezett ξ -változók közül az i -ediket ξ_i^* -gal, s hasonlóképp az η -változók rendezett sorában a k -adikat η_k^* -gal jelöljük. Ha a két mintát egyesítjük és ismét nagyság szerint növekvő sorozatba rendezzük, a ξ_i^* , ill. η_k^* változók pozíciója általában megváltozik, rangszámaik általában nagyobbak, mint az eredeti i , ill. k rangszámok (sorszámok). A ξ_i^* új rangszámát r_i -vel, az η_k^* új rangszámát pedig s_k -val jelölve, fennáll, hogy

$$(1) \quad i + k = \begin{cases} r_i, & \text{ha } \eta_k^* < \xi_i^* < \eta_{k+1}^*, \\ s_k, & \text{ha } \xi_i^* < \eta_k^* < \xi_{i+1}^*. \end{cases}$$

A minták eloszlásfüggvényeit (az ún. empirikus eloszlásfüggvényeket) $F_m(x)$ -szel, ill. $G_n(x)$ -szel jelöljük. Ezek definíciója, mint ismeretes, a következő:

$$(2) \quad F_m(x) = \begin{cases} 0, & \text{ha } x \leq \xi_1^*, \\ \frac{i}{m}, & \text{ha } \xi_i^* < x \leq \xi_{i+1}^*, \\ 1, & \text{ha } \xi_m^* < x, \end{cases}$$

¹ Agrártudományi Egyetem.

$$(2a) \quad G_n(x) = \begin{cases} 0, & \text{ha } x \leq \eta_1^*, \\ \frac{k}{n}, & \text{ha } \eta_k^* < x \leq \eta_{k+1}^*, \\ 1, & \text{ha } \eta_n^* < x. \end{cases}$$

Szükségünk lesz még a z_{ik} és \bar{z}_{ik} karakterisztikus változókra. Ezeket az alábbi módon értelmezzük:

$$(3) \quad z_{ik} = \begin{cases} 0, & \text{ha } \eta_k < \xi_i, \\ 1, & \text{ha } \eta_k > \xi_i. \end{cases}$$

$$(4) \quad \bar{z}_{ik} = 1 - z_{ik} = \begin{cases} 0, & \text{ha } \eta_k < \xi_i, \\ 1, & \text{ha } \eta_k > \xi_i. \end{cases}$$

Figyelemre méltó, hogy míg az empirikus eloszlásfüggvények definíciói a rendezett mintaelemek alapján történtek, addig a z_{ik} definíciójához az eredeti mintaelemeket használtuk fel.

Bevezetés

A LEHMANN-próbánál, akárcsak a WILCOXON próbánál, nullhipotézisnek az $F(x) = G(x)$ hipotézist, alternatív hipotézisnek pedig az ettől különböző hipotéziseket nevezzük, tehát minden alternatív hipotézisnél legalább egy mérhető halmazon $F(x) \neq G(x)$. Amíg azonban a WILCOXON próbánál az

$$(5) \quad I_1 = \int_{-\infty}^{\infty} (G(x) - F(x)) dF(x).$$

Stieltjes-integrált becsüljük meg, melynek értéke alternatív hipotézis esetén is zérussá válhat, a LEHMANN-próbánál lényegében az

$$(6) \quad I_2 = \int_{-\infty}^{\infty} (G(x) - F(x))^2 dF(x)$$

integrált becsüljük, amely csak a két eloszlásfüggvény egyezése esetén tűnhet el. A két eloszlásfüggvény különböző volta viszont mindig egy irányban (pozitív irányban) tolja el az I_2 értékét, amiből következik, hogy az I_2 becslésére szolgáló mennyiségnek is csak a pozitív irányú eltéréséből következtethetünk a két eloszlásfüggvény különböző voltára, más szóval: a próba egyoldalú.

A LEHMANN- és a WILCOXON-próba rendstatisztikai jellege abból a tényből fakad, hogy az I_2 és az I_1 Stieltjes-integrálok becsléséhez nincs szükségünk a mintaelemek tényleges értékeire, csupán egymáshoz viszonyított helyzetükre, ezt pedig a rangszámok egyértelműen meghatározzák. Az I_2 -vel kapcsolatos becslés céljára LEHMANN [1] és RÉNYI [2] más-más kifejezést adtak; a RÉNYITŐL származó W lényegesen egyszerűbb, mint a LEHMANN-féle L -vel jelölt kifejezés. Az L és W között egyszerű lineáris kapcsolat áll fenn:

$$(7) \quad L = 2W - 1.$$

Ezt CSÁKI E. ismerte fel először [3], s ezzel bebizonyította, hogy a RÉNYI által javasolt próba azonos a LEHMANN-próbával.

E cikkben új bizonyítást adom a (7) összefüggésnek, s ezenkívül megadok egy harmadik statisztikai függvényt is (ezt V -vel fogjuk jelölni) a próba végrehajtására, mely bizonyos szempontból még a RÉNYI-féle W -nél is egyszerűbb. Végül kiszámítom a W szórásnégyzetét az általános esetben (tehát alternatív hipotézis esetén), ahonnan $G(x) = F(x)$ helyettesítésre könnyen adódik a szórásnégyzetnek nullhipotézis teljesülése esetén érvényes képlete.

1. §. A próba alapjául szolgáló kifejezések

A LEHMANN-féle L -függvény eredeti definíciója:

$$(8) \quad \frac{L_1 + L_2}{\binom{m}{2} \binom{n}{2}},$$

ahol L_1 jelenti azon $(\xi_i, \xi_j, \eta_k, \eta_l)$ elemnégyek számát, melyekre az

$$\eta_k < \xi_i, \eta_k < \xi_j, \eta_l < \xi_i, \eta_l < \xi_j$$

egyenlőtlenségek egyidejűleg teljesülnek, s hasonlóképpen L_2 jelenti azon $(\xi_i, \xi_j, \eta_k, \eta_l)$ elemnégyesek számát, melyekre az

$$\eta_k > \xi_i, \eta_k > \xi_j, \eta_l > \xi_i, \eta_l > \xi_j$$

egyenlőtlenségek egyszerre teljesülnek. A bevezetett karakterisztikus változókkal L_1 és L_2 a következőképp írható:

$$(9) \quad \begin{cases} L_1 = \sum_{i,j,k,l} z_{ik} z_{il} z_{jk} z_{jl}, \\ L_2 = \sum_{i,j,k,l} \bar{z}_{ik} \bar{z}_{il} \bar{z}_{jk} \bar{z}_{jl}, \end{cases}$$

megjegyezve, hogy itt (és a továbbiakban mindenütt) az egyező helyen álló de eltérő módon jelölt indexek egyúttal eltérő értékű indexeket is jelentenek

A képletekből látható, hogy az $\frac{L_1}{\binom{m}{2} \binom{n}{2}}$ kifejezéssel a $z_{ik} z_{il} z_{jk} z_{jl}$ szorzat

várható értékét, az $\frac{L_2}{\binom{m}{2} \binom{n}{2}}$ kifejezéssel pedig a $\bar{z}_{ik} \bar{z}_{il} \bar{z}_{jk} \bar{z}_{jl}$ várható értékét

becsüljük meg. Mivel pedig

$$(10) \quad \begin{cases} \mathbf{M}(z_{ik} z_{il} z_{jk} z_{jl}) = 2 \int_{-\infty}^{\infty} G^2(x) (1 - F(x)) dF(x), \\ \mathbf{M}(\bar{z}_{ik} \bar{z}_{il} \bar{z}_{jk} \bar{z}_{jl}) = 2 \int_{-\infty}^{\infty} F^2(x) (1 - G(x)) dG(x), \end{cases}$$

kis számítással azonnal adódik, hogy

$$(11) \quad \mathbf{M}(L) = \frac{1}{3} + 2 \int_{-\infty}^{\infty} (G(x) - F(x))^2 dF(x) = \frac{1}{3} + 2I_2.$$

A RÉNYI-féle W -kifejezés definíciója egyszerűbb:

$$(12) \quad W = \frac{W_1}{m \binom{n}{2}} + \frac{W_2}{n \binom{m}{2}}.$$

Itt W_1 jelenti azon (ξ_i, η_k, η_l) elemhármak számát, amelyekre

$$\eta_k < \xi_i \text{ és } \eta_l < \xi_i$$

egyidejűleg teljesül, s hasonlóképp W_2 jelenti azon (ξ_i, ξ_j, η_k) elemhármak számát, amelyekre

$$\eta_k > \xi_i \text{ és } \eta_k > \xi_j$$

egyszerre teljesül. A W_1 és W_2 karakterisztikus változókkal így fejezhetők ki:

$$(13) \quad \begin{cases} W_1 = \sum_{i,k,l} z_{ik} z_{il}, \\ W_2 = \sum_{i,j,k} \bar{z}_{ik} \bar{z}_{jk}. \end{cases}$$

Ezeknek megfelelően a $\frac{W_1}{m \binom{n}{2}}$ -vel a $z_{ik} z_{il}$ szorzat várható értékét, a $\frac{W_2}{n \binom{m}{2}}$ -vel

pedig a $\bar{z}_{ik} \bar{z}_{jk}$ szorzat várható értékét becsüljük meg. Minthogy pedig

$$(14) \quad \begin{cases} \mathbf{M}(z_{ik} z_{il}) = \int_{-\infty}^{\infty} G^2(x) dF(x), \\ \mathbf{M}(\bar{z}_{ik} \bar{z}_{jk}) = \int_{-\infty}^{\infty} F^2(x) dG(x), \end{cases}$$

kis számítással most azt kapjuk, hogy

$$(15) \quad \mathbf{M}(W) = \frac{2}{3} + \int_{-\infty}^{\infty} (G(x) - F(x))^2 dF(x) = \frac{2}{3} + I_2.$$

A (11)-ből és (15)-ből következik az

$$\mathbf{M}(L) = 2\mathbf{M}(W) - 1,$$

ill.

$$\mathbf{M}(2W - L - 1) = 0$$

összefüggés. Ebből már sejteni lehet, hogy a $(2W - L - 1)$ mennyiségnek nemesak a várható értéke, hanem az értéke is zérus, azaz a (7) is fennáll.² Ennek bizonyítását a 2. pontban végezzük el. A bizonyítás a W és L explicit alakjainak összehasonlításával történik, ezért előbb az explicit alakokat adjuk közre:

$$(16) \quad \begin{cases} L_1 = \frac{1}{2} \cdot \sum_{i=1}^m (r_i - i)(r_i - i - 1)(m - i), \\ L_2 = \frac{1}{2} \cdot \sum_{k=1}^m (s_k - k)(s_k - k - 1)(n - k), \end{cases}$$

$$(17) \quad \begin{cases} W_1 = \frac{1}{2} \cdot \sum_{i=1}^n (r_i - i)(r_i - i - 1), \\ W_2 = \frac{1}{2} \cdot \sum_{k=1}^n (s_k - k)(s_k - k - 1). \end{cases}$$

E rangszámok függvényeként megadott formulák könnyen beláthatók a fentebb közölt definíciók alapján.

2. §. Identikus összefüggések levezetése

Az (1) összefüggést felhasználva, rendre kiszámítjuk az empirikus eloszlásfüggvényekből képezett alábbi Stieltjes-integrálokat:

$$(18) \quad \int_{-\infty}^{\infty} G_n(x) dF_m(x) = \sum_{i=1}^m \frac{k}{n} \cdot \frac{1}{m} = \frac{1}{nm} \cdot \sum_{i=1}^m (r_i - i),$$

$$(19) \quad \int_{-\infty}^{\infty} F_m(x) dG_n(x) = \sum_{k=1}^n \frac{i}{m} \cdot \frac{1}{n} = \frac{1}{mn} \cdot \sum_{k=1}^n (s_k - k),$$

$$(20) \quad \int_{-\infty}^{\infty} G_n^2(x) dF_m(x) = \sum_{i=1}^m \left(\frac{k}{n}\right)^2 \cdot \frac{1}{m} = \frac{1}{n^2 m} \cdot \sum_{i=1}^m (r_i - i)^2,$$

$$(21) \quad \int_{-\infty}^{\infty} F_m^2(x) dG_n(x) = \sum_{k=1}^n \left(\frac{i}{m}\right)^2 \cdot \frac{1}{n} = \frac{1}{m^2 n} \cdot \sum_{k=1}^n (s_k - k)^2,$$

² A várható értékek között fennálló összefüggésből tulajdonképpen szintén következik a megfelelő statisztikai függvények közötti hasonló összefüggés, ha alkalmazzuk Lehmann és Scheffé egy lemmáját (vö. [1] vagy [3], 314. o.).

$$(22) \quad \int_{-\infty}^{\infty} F_m(x) dG_n^2(x) = \sum_{k=1}^n \frac{i}{m} \cdot \left\{ \left(\frac{k}{n} \right)^2 - \left(\frac{k-1}{n} \right)^2 \right\} =$$

$$= \frac{1}{mn^2} \cdot \sum_{k=1}^n (s_k - k)(2k - 1),$$

$$(23) \quad \int_{-\infty}^{\infty} G_n(x) dF_m^2(x) = \sum_{i=1}^m \frac{k}{n} \cdot \left\{ \left(\frac{i}{m} \right)^2 - \left(\frac{i-1}{m} \right)^2 \right\} =$$

$$= \frac{1}{nm^2} \cdot \sum_{i=1}^m (r_i - i)(2i - 1),$$

$$(24) \quad \int_{-\infty}^{\infty} G_n^2(x) dF_m^2(x) = \sum_{i=1}^m \left(\frac{k}{n} \right)^2 \cdot \frac{2i-1}{m^2} = \frac{1}{n^2 m^2} \cdot \sum_{i=1}^m (r_i - i)^2 \cdot (2i - 1),$$

$$(25) \quad \int_{-\infty}^{\infty} F_m^2(x) dG_n^2(x) = \sum_{k=1}^n \left(\frac{i}{m} \right)^2 \cdot \frac{2k-1}{n^2} = \frac{1}{m^2 n^2} \cdot \sum_{k=1}^n (s_k - k)^2 \cdot (2k - 1).$$

A parciális integrálás képletét alkalmazva, a (18)- és (19)-ből az alábbi eredményt nyerjük:

$$\int_{-\infty}^{\infty} G_n(x) dF_m(x) + \int_{-\infty}^{\infty} F_m(x) dG_n(x) = \left[G_n(x) \cdot F_m(x) \right]_{-\infty}^{\infty} =$$

$$= 1 = \frac{1}{nm} \cdot \sum_{i=1}^m (r_i - i) + \frac{1}{mn} \cdot \sum_{k=1}^n (s_k - k),$$

azaz

$$(26) \quad \sum_{i=1}^m (r_i - i) + \sum_{k=1}^n (s_k - k) = mn.$$

Hasonló összefüggéseket kapunk a (20)–(22), (21)–(23), ill. a (24) és (25) összevetésével:

$$(27) \quad \sum_{i=1}^m (r_i - i)^2 + \sum_{k=1}^n (s_k - k)(2k - 1) = n^2 m,$$

$$(28) \quad \sum_{k=1}^n (s_k - k)^2 + \sum_{i=1}^m (r_i - i)(2i - 1) = m^2 n,$$

$$(29) \quad \sum_{i=1}^m (r_i - i)^2 (2i - 1) + \sum_{k=1}^n (s_k - k)^2 (2k - 1) = m^2 n^2.$$

Megjegyezzük, hogy a (26) közvetlenül is levezethető:

$$\begin{aligned} \sum_{i=1}^m (r_i - i) + \sum_{k=1}^n (s_k - k) &= \sum_{t=1}^{m+n} t - \sum_{i=1}^m i - \sum_{k=1}^n k = \\ &= \frac{1}{2} (m+n)(m+n+1) - \frac{1}{2} m(m+1) - \frac{1}{2} n(n+1) = mn. \end{aligned}$$

Fentebb mégis azért alkalmaztuk az integrálokkal történő levezetést, hogy ezzel a módszert bemutassuk.

A kapott identitások kombinációjából újabbakat nyerhetünk. Adjuk össze a (29) és (26) megfelelő oldalait és vonjuk ki ezekből a (27) és (28) megfelelő oldalait. Az összevonások elvégzése és 4-gyel való osztás után az alábbi összefüggés származik:

$$\begin{aligned} \frac{1}{2} \cdot \sum_{i=1}^m (r_i - i)(r_i - i - 1)(i - 1) + \frac{1}{2} \cdot \sum_{k=1}^n (s_k - k)(s_k - k - 1)(k - 1) = \\ = \binom{m}{2} \cdot \binom{n}{2}. \end{aligned}$$

Ennek felhasználásával és a (17)-re való tekintettel a LEHMANN-féle L -függvény a következő alakra hozható:

$$\begin{aligned} L &= \frac{\frac{1}{2} \cdot \sum_{i=1}^m (r_i - i)(r_i - i - 1)(m - 1) + \frac{1}{2} \cdot \sum_{k=1}^n (s_k - k)(s_k - k - 1)(n - 1) - \binom{m}{2} \binom{n}{2}}{\binom{m}{2} \binom{n}{2}} = \\ &= \frac{\sum_{i=1}^m (r_i - i)(r_i - i - 1)}{m \binom{n}{2}} + \frac{\sum_{k=1}^n (s_k - k)(s_k - k - 1)}{n \binom{m}{2}} - 1, \end{aligned}$$

amiről már nem nehéz felismerni, hogy $(2W - 1)$ -gyel egyenlő (vö. (12) és (17)). Ezzel a (7) azonosságot bebizonyítottuk.

További újabb identitásokhoz jutunk, ha a (27), ill. (28) megfelelő oldaliból kivonjuk a (26) megfelelő oldalait:

$$(30) \quad \sum_{i=1}^m (r_i - i)(r_i - i - 1) + 2 \sum_{k=1}^n (s_k - k)(k - 1) = nm(n - 1),$$

$$(31) \quad \sum_{k=1}^n (s_k - k)(s_k - k - 1) + 2 \sum_{i=1}^m (r_i - i)(i - 1) = nm(m - 1).$$

Ha bevezetjük a következő jelöléseket:

$$V_1 = \sum_{i=1}^m (r_i - i) (i - 1), \quad (32)$$

$$V_2 = \sum_{k=1}^n (s_k - k) (k - 1),$$

ezeknek és a (17) alatti összefüggéseknek figyelembevételével a (30) és (31) így is írható:

$$W_1 + V_2 = m \binom{n}{2}, \quad (33)$$

$$W_2 + V_1 = n \binom{m}{2}.$$

Amennyiben tehát a

$$V = \frac{V_1}{nm(m-1)} + \frac{V_2}{mn(n-1)} \quad (34)$$

képlettel definiálunk új statisztikai függvényt, ez szintén felhasználható a próba céljára, mivel a W -vel a következő kapcsolatban áll:

$$V = 1 - \frac{W}{2}. \quad (35)$$

A (35)-ös összefüggés a (12), (33) és (34) összevetéséből adódik.

Néhány megjegyzés az új kifejezéssel kapcsolatban. A (34)-gyel definiált V azért tekinthető egyszerűbbnek a W -nél, mivel a rangszámoknak csak lineáris kifejezéseit tartalmazza. Ez mindenképp előtti az elméleti számításoknál jelenthet előnyt, mivel a próba gyakorlati alkalmazásánál felmerülő numerikus számításoknál a W könnyebben számítható ki, mint a V , annak ellenére, hogy a rangszámokban kvadratikus. A V -nek a gyakorlatban való felhasználásánál ügyelni kell arra is, hogy a nullhipotézis nem-teljesülésére most a negatív irányú eltéréstől következtetünk, tekintettel a (35)-re.

Az L -hez és W -hez hasonlóan a V is definiálható a mintaváltozók nagyságrendi eseményei segítségével. V_1 jelenti azon (η_k, ξ_i, ξ_j) elemhármasok számát, melyekre

$$\eta_k < \xi_j, \quad \xi_i < \xi_j$$

és V_2 azon (ξ_i, η_k, η_l) elemhármasok számát, melyekre

$$\xi_i < \eta_l, \quad \eta_k < \eta_l$$

egyidejűleg teljesül. Tekintettel azonban arra, hogy

$$\mathbf{P}(\eta_k < \xi_j, \xi_i < \xi_j) = \int_{-\infty}^{\infty} G(x) F(x) dF(x),$$

és

$$\mathbf{P}(\xi_i < \eta_l, \eta_k < \eta_l) = \int_{-\infty}^{\infty} F(x) G(x) dG(x),$$

a V -vel tulajdonképpen a jobboldalakon álló két integrál összegét becsüljük meg, azaz

$$\mathbf{M}(V) = \int_{-\infty}^{\infty} G(x) F(x) dF(x) + \int_{-\infty}^{\infty} F(x) G(x) dG(x),$$

vagy a parciális integrálások megfelelő alkalmazásával:

$$\mathbf{M}(V) = \frac{2}{3} - \frac{1}{2} \cdot \int_{-\infty}^{\infty} (G(x) - F(x))^2 \cdot dF(x) = \frac{2}{3} - \frac{1}{2} \cdot I_2,$$

teljes összhangban a (35)-tel és (15)-tel.

3. §. A W szórásnégyzetének kiszámítása

Alternatív hipotézis esetén a három statisztikai függvény (L , W és V) közül aránylag a W szórásnégyzete határozható meg legkönnyebben, az is csak akkor, ha a (12) és (13) alakokból indulunk ki. A (12)-ből következik:

$$(36) \quad \mathbf{D}^2(W) = \frac{1}{m^2 \cdot \binom{n}{2}} \cdot \mathbf{D}^2(W_1) + \frac{1}{n^2 \binom{m}{2}} \cdot \mathbf{D}^2(W_2) + \frac{2 \text{Cov}(W_1, W_2)}{mn \binom{m}{2} \binom{n}{2}}.$$

Cov-val a zárójelbe tett két változó kovarianciáját jelöltük, ennek definíciója

$$\text{Cov}(\zeta_1, \zeta_2) = \mathbf{M}\{(\zeta_1 - \mathbf{M}(\zeta_1))(\zeta_2 - \mathbf{M}(\zeta_2))\}.$$

A (36) szerint a W szórásnégyzetéhez a W_1 és W_2 kovarianciáját és szórásnégyzeteit kell előbb meghatározni.

A W_1 szórásnégyzetének kiszámítását az alábbi számításmenet mutatja:

$$W_1 = \sum_{i,k,l} z_{ik} z_{il},$$

$$(37) \quad \mathbf{D}^2(W_1) = \mathbf{M}\left[\left(\sum_{i,k,l} z_{ik} z_{il}\right)^2\right] - \left[\mathbf{M}\left(\sum_{i,k,l} z_{ik} z_{il}\right)\right]^2,$$

$$\mathbf{M}\left(\sum_{i,k,l} z_{ik} z_{il}\right) = \sum_{i,k,l} \mathbf{M}(z_{ik} z_{il}) = m \binom{n}{2} \cdot p_2,$$

$$\begin{aligned} \left(\sum_{i,k,l} z_{ik} z_{il}\right)^2 &= \sum_{i,k,l} z_{ik}^2 z_{il}^2 + 2 \sum z_{ik} z_{il} z_{jk} z_{jl} + 2 \sum z_{ik_1} z_{il} z_{jk_2} z_{jl} + \\ &+ 2 \sum z_{ik_1} z_{il_1} z_{jk_2} z_{jl_2} + 2 \sum z_{ik_1} z_{il} z_{ik_2} z_{il} + 2 \sum z_{ik_1} z_{il_1} z_{ik_2} z_{il_2}, \end{aligned}$$

$$(38) \quad \left\{ \begin{array}{l} \mathbf{M}(\sum z_{ik}^2 z_{il}^2) = m \binom{n}{2} \cdot p_2, \\ \mathbf{M}(2 \sum z_{ik} z_{il} z_{jk} z_{jl}) = 2 \binom{m}{2} \binom{n}{2} (2 p_2 - 2 p_{21}), \\ \mathbf{M}(2 \sum z_{ik_1} z_{il} z_{jk_2} z_{jl}) = 2 \binom{m}{2} n(n-1)(n-2) \cdot 2s, \\ \mathbf{M}(2 \sum z_{ik_1} z_{il_1} z_{jk_2} z_{jl_2}) = 2 \binom{m}{2} \binom{n}{2} \binom{n-2}{2} \cdot p_2^2, \\ \mathbf{M}(2 \sum z_{ik_1} z_{il} z_{ik_2} z_{il}) = 2 m \binom{n}{2} \cdot (n-2) \cdot p_2, \\ \mathbf{M}(2 \sum z_{ik_1} z_{il_1} z_{ik_2} z_{il_2}) = 2 r \cdot \frac{1}{2} \cdot \binom{n}{2} \binom{n-2}{2} \cdot p_4. \end{array} \right.$$

A jobboldalokon szereplő betűjelek (p_2, p_{21}, s, p_3, p_4) különféle integrálokat jelentenek; pontos jelentésüket a cikk végén levő táblázatban foglaltuk össze. A kapott eredményeknek a (37)-be való behelyettesítésével és az egyszerűsítések elvégzésével azt kapjuk, hogy

$$(39) \quad \mathbf{D}^2(W_1) = m \binom{n}{2} \cdot \left\{ \begin{array}{l} p_2 + 2(m-1)(p_2 - p_{21}) + 4(m-1)(n-2)s - \\ - m(2n-3)p_2^2 + \frac{1}{2}(n-2)(n-3)(p_4 - p_2^2) + 2(n-2)p_3 \end{array} \right\}.$$

Teljesen analóg módon nyerhető a W_2 szórásnégyzete is:

$$(40) \quad \begin{aligned} \mathbf{D}^2(W_2) &= \\ &= n \binom{m}{2} \cdot \left\{ \begin{array}{l} \bar{p}_2 + 2(n-1)(\bar{p}_2 - \bar{p}_{21}) + 4(n-1)(m-2)\bar{s} - \\ - n(2m-3)\bar{p}_2^2 + \frac{1}{2}(m-2)(m-3)(\bar{p}_4 - \bar{p}_2^2) + 2(m-2)\bar{p}_3 \end{array} \right\}. \end{aligned}$$

A W_1 és W_2 kovarianciájának kiszámítása céljából a W_2 -t a

$$W_2 = \sum_{i,j,k} (1 - z_{ik})(1 - z_{jk})$$

alakba írva vonjuk be a számításba. A számítás menete

$$\begin{aligned} \text{Cov}(W_1, W_2) &= \sum \text{Cov}\{z_{ik}, z_{il}, (1 - z_{ik})(1 - z_{jk})\} + \\ &+ \sum \text{Cov}\{z_{ik}, z_{il}, (1 - z_{ik_2})(1 - z_{jk_2})\} + \sum \text{Cov}\{z_{ik_1} z_{il_1}, (1 - z_{ik_2})(1 - z_{jk_2})\}, \end{aligned}$$

$$(41) \quad \left\{ \begin{aligned} \sum \text{Cov} \{z_{ik} z_{il}, (1 - z_{ik})(1 - z_{jk})\} &= 4 \binom{m}{2} \binom{n}{2} \cdot (-p_2 \bar{p}_2), \\ \sum \text{Cov} \{z_{ik_1} z_{il}, (1 - z_{ik_2})(1 - z_{jk_2})\} &= \\ &= 2 \binom{m}{2} \binom{n}{2} (n-2) (-s - p_{31} - p_2 \bar{p}_2 + p_2), \\ \sum \text{Cov} \{z_{i_1 k} z_{i_1 l}, (1 - z_{i_2 k})(1 - z_{jk})\} &= \\ &= \sum \text{Cov} \{(1 - \bar{z}_{i_1 k})(1 - \bar{z}_{i_1 l}), \bar{z}_{i_2 k} \bar{z}_{jk}\} = \\ &= 2 \binom{m}{2} \binom{n}{2} (m-2) (-\bar{s} - \bar{p}_{31} - p_2 \bar{p}_2 + \bar{p}_2), \end{aligned} \right.$$

tehát végül is

$$(42) \quad \text{Cov}(W_1, W_2) = -2 \binom{m}{2} \binom{n}{2} \cdot \left(\begin{array}{l} 2 p_2 \bar{p}_2 + (n-2)(s + p_{31} + p_2 \bar{p}_2 - p_2) + \\ + (m-2)(\bar{s} + \bar{p}_{31} + p_2 \bar{p}_2 - \bar{p}_2) \end{array} \right).$$

A W szórásnégyzete ezek után már könnyen kapható, mivel a nyert eredményeket ((39), (40) és (42)) csak be kell helyettesíteni a (36)-ba.

Nullhipotézis esetén a képletek nagyban leegyszerűsödnek. Ha az említett táblázatból a p_2, p_{21}, p_3 , stb. integrálok nullhipotézis esetére kiszámított értékeit a képletekbe behelyettesítjük, az alábbi eredményeket kapjuk:

$$(43.a) \quad \mathbf{D}^2(W_1) = \frac{1}{90} m \binom{n}{2} (m+n+1)(4n-3),$$

$$(43.b) \quad \mathbf{D}^2(W_2) = \frac{1}{90} n \binom{m}{2} (m+n+1)(4m-3),$$

$$(44) \quad \text{Cov}(W_1, W_2) = -\frac{4}{45} \binom{m}{2} \binom{n}{2} (m+n+1),$$

s ezeknek megfelelően:

$$(45) \quad \mathbf{D}^2(W) = \frac{1}{45} \cdot \frac{(m+n+1)(m+n-2)}{m(m-1)n(n-1)}.$$

Ami a kész alakban megadott (38), ill. (41) alatti közbeeső eredményeket illeti, ezekkel kapcsolatban csak annyit jegyzünk meg, hogy a z_{ik} karakterisztikus változókból alkotható különféle szorzatok várható értékei a közölt táblázat integráljaival adhatók meg. A megfelelő számítások részletezése túlságosan hosszúvá nyújtaná a dolgozatot, ezért itt azt elhagyjuk.

Az integrálok táblázata

Az integrál jele	Az integrál kifejezése	Az integrál értéke nullhipotézis esetén
p_2	$\int_{-\infty}^{\infty} G^2(x) dF(x)$	$\frac{1}{3}$
\bar{p}_2	$\int_{-\infty}^{\infty} F^2(x) dG(x)$	$\frac{1}{3}$
p_3	$\int_{-\infty}^{\infty} G^3(x) dF(x)$	$\frac{1}{4}$
\bar{p}_3	$\int_{-\infty}^{\infty} F^3(x) dG(x)$	$\frac{1}{4}$
$p_{21} = \frac{1}{2} - \bar{p}_{21}$	$\int_{-\infty}^{\infty} G^2(x) F(x) dF(x) = \frac{1}{2} - \int_{-\infty}^{\infty} F^2(x) G(x) dG(x)$	$\frac{1}{4}$
p_4	$\int_{-\infty}^{\infty} G^4(x) dF(x)$	$\frac{1}{5}$
\bar{p}_4	$\int_{-\infty}^{\infty} F^4(x) dG(x)$	$\frac{1}{5}$
p_{31}	$\int_{-\infty}^{\infty} G^3(x) F(x) dF(x)$	$\frac{1}{5}$
\bar{p}_{31}	$\int_{-\infty}^{\infty} F^3(x) G(x) dG(x)$	$\frac{1}{5}$
s	$\int_{-\infty}^{\infty} G(x_2) \cdot \left\{ \int_{-\infty}^{x_2} G^2(x_1) dF(x_1) \right\} dF(x_2)$	$\frac{1}{15}$
\bar{s}	$\int_{-\infty}^{\infty} F(x_2) \cdot \left\{ \int_{-\infty}^{x_2} F^2(x_1) dG(x_1) \right\} dG(x_2)$	$\frac{1}{15}$

(Béérkezett : 1959. szeptember 29.)

IRODALOM

- [1] LEHMANN, E. L.: „Consistency and unbiasedness of certain nonparametric tests.” *Ann. Math. Stat.* **22** (1951) 165—180.
- [2] RÉNYI A.: „Újabb kritériumok két minta összehasonlítására.” *Alk. Mat. Int. közleményei* **2** (1953) 243—265.
- [3] CSÁKI E.: „A Wilcoxon-statisztika két módosításáról.” *MTA Mat. Kut. Intézet Közleményei* **4** (1959) 313—319.

ON THE LEHMANN TEST

A. ZAJTA

Abstract

In order to eliminate the deficiencies of the Wilcoxon test, LEHMANN [1] and RÉNYI [2] developed new tests which are consistent with any alternative hypothesis of the null hypothesis. Since the expressions L and W — proposed by LEHMANN and RÉNYI to perform the test — differ from each other, the two procedures have, for a long time, been considered as two separate tests. It was just recently that CSÁKI [3] realized their identity, the relationship between L and W being a simple linear one:

$$L = 2W - 1.$$

In the present paper, a new proof of this connection is given and a third expression (V) is put forward to perform the test. The new expression is, in certain respects, even simpler than W in that it contains only linear functions of the rank numbers (Paragraph 2.). In addition, the variance of W is calculated for the general case from which a formula (45), suitable for the substitution $G(x) = F(x)$ and valid for the case of the null hypothesis may be derived.

О ПРОБЕ LEHMANN-A

A. ZAJTA

Резюме

Чтобы освободиться от недостатков пробы WILCOXON-а, LEHMANN [1] и RÉNYI [2] построили новую пробу, консистентную относительно всех альтернативных гипотез гипотезы нуля. Так как выражения L и W , предложенные LEHMANN-ом и RÉNYI для проведения пробы, отличаются друг от друга, долгое время эти две пробы считались различными, и лишь недавно E. CSÁKI [3] заметил, что они тождественны, так как между L и W имеет место простое линейное соотношение

$$L = 2W - 1.$$

В настоящей работе дается новое доказательство этого соотношения и дается третье выражение (V) для проведения пробы. Новое выражение с некоторой точки зрения проще чем W , так как содержит лишь линейные функции ранговых чисел (пункт 2). Кроме того вычисляется дисперсия W в общем случае, откуда в случае $G(x) = F(x)$ получается формула (45), справедливая в случае гипотезы нуля.