

KLIMATOLÓGIAI STATISZTIKA FELADATOK

1. Tihanyban 22 év során 37 napon fordult elő 30 mm-t meghaladó 24 órás csapadék. Milyen valószínűséggel várható olyan év, amikor nem fordul elő 30 mm-t meghaladó 24 órás csapadékmennyiség? *(megoldás: 18,58 %)*
2. Egy hegycsúcsra telepítendő TV-torony műszaki tervezéséhez szükséges annak az ismerete, hogy mekkora a villámcsapás valószínűsége a csúcson. A környéken végzett megfigyelések szerint 8 év során 19 napon jegyezték fel villámcsapást hegycsúcson. Mekkora annak a valószínűsége, hogy egy évben 3 napon lesz villámcsapás a csúcson? *(megoldás: 20,7 %)*
3. Mi annak a valószínűsége, hogy egy adott helyen az év 12 hónapjából egynek sem lesz magasabb a középhőmérséklete a felső kvartilisnél? *(megoldás: 3,17 %)*
4. Winnipeg januári középhőmérséklete $-17,7\text{ °C}$, a középhőmérsékletek szórása $4,1\text{ °C}$. Normális eloszlást feltételezve határozzuk meg annak a közép-re szimmetrikus intervallumnak a végpontjait, amelyek közé az összes érték 50 %-a esik! *(megoldás: $[-20,49; -14,91]$)*
5. Egy bizonyos növényfaj létfeltételeihez szükséges, hogy a vegetációs időszakban uralkodó havi középhőmérsékletek legalább 40 %-a 12 °C fölött legyen. Az A és B észlelőhelyeken a vegetációs időszak havi közepeinek megfelelő paraméterei a következők:

$$A: m = 11,5\text{ °C}, \sigma = 1\text{ °C}$$

$$B: m = 11,0\text{ °C}, \sigma = 4\text{ °C}$$

Alkalmasak-e az észlelőhelyek az illető növényfaj termesztésére?
(megoldás: A: $P = 30,85\%$ \Rightarrow nem alkalmas; B: $P = 40,13\%$ \Rightarrow alkalmas)

6. Szegeden az 1901-1960 közötti 60 év adatai alapján a júniusi középhőmérséklet $20,5\text{ °C}$. Kizárólag a hőmérsékletek feltételezetten normális eloszlását felhasználva határozzuk meg a júniusi középhőmérsékletek szórását, ha tudjuk, hogy a vizsgált 60 június közül 11-nek volt a középhőmérséklete legalább 22 °C . *(megoldás: $\sigma = 1,67\text{ °C}$)*
7. Tekintsünk egy adott helyre vonatkozó több éves hőmérsékleti sort. Ez a hőmérsékleti sor havi közepekből áll. Annak a valószínűsége, hogy egy tetszőleges hónap középhőmérséklete a több éves sor közepe fölötti $0,5$. Kiválasztva egy tetszőleges évszakot, mi a valószínűsége annak, hogy abban egyetlen hónap középhőmérséklete sem lesz a több éves sor átlaga
 - a) felett?
 - b) alatt?*(megoldás: $a = b = 0,125$)*

8. Szombathelyen 140 év adatai alapján az áprilisi középhőmérséklet $9,7\text{ }^{\circ}\text{C}$, szórása $2,3\text{ }^{\circ}\text{C}$. Határozzuk meg az áprilisi középhőmérsékletek alsó és felső kvartilisét! (megoldás: $[8,1; 11,3]$)
9. Szegeden a júniusi középhőmérséklet $20,4\text{ }^{\circ}\text{C}$, a szórás $1,2\text{ }^{\circ}\text{C}$. Határozzuk meg annak a számtani középre szimmetrikus intervallumnak az alsó és felső határát, amelybe $2/3$ valószínűséggel esnek az értékek! (megoldás: $[19,32; 21,48]$)
10. Hódmezővásárhelyen a 20 mm-t meghaladó napi csapadék átlagos évi gyakorisága 4 nap. Mi a valószínűsége annak, hogy egyetlen napon sem fordul elő egy évben és annak, hogy 5 napon fordul elő egy évben 20 mm-t meghaladó csapadékösszeg? (megoldás: $1,8\%$; $15,6\%$)

11. Budapest belterületén és külterületén 1975 júliusának és augusztusának 21 órai hőmérsékletei az alábbi esetszámok szerint oszlottak meg:

hőmérséklet, $^{\circ}\text{C}$	16-18	18-20	20-22	22-24	24-26	26-28
belterület	5	10	16	18	10	3
külterület	8	14	25	10	5	0

Kimutatható-e, lényeges eltérés a belterület és a külterület esti hőmérsékleteinek eloszlásában? (megoldás: *nem mutatnak szignifikáns eltérést*)

12. Egy ipari városban levegőszűrő berendezésekkel csökkentették a levegőbe jutó égéstermék mennyiségét. A beavatkozás előtti 10 és a beavatkozás utáni 3 éven át végzett megfigyelések szerint januárban 13 órakor a jó, a közepes és rossz látástávolság az alábbi esetszámban volt megfigyelhető:

látástávolság	jó	közepes	rossz
beavatkozás előtt	78	124	108
beavatkozás után	35	43	15

Kimutatható-e a műszaki beavatkozás a város levegőjének tisztulásában? (megoldás: *kimutatható*)

13. Bresztben 60 év során a legcsapadékosabb évszakok megoszlása a következő volt:

évszak	tél	tavas	nyár	ősz
eset	16	11	13	20

Fenntartható-e az az állítás, hogy Bresztben a csapadékmaximum egyenlő eséllyel várható bármely évszakban? (megoldás: *az állítás fenntartható*)

14. Sopronban az 1971-1975 közötti 5 év júniusi napjai közül 82 volt csapadékos. Adjunk 95% -os megbízhatósági becslést a csapadékos nap valószínűségére júniusban! (megoldás: $[P_1; P_2] = [0,47; 0,63]$)

15. Pécssett 80 év megfigyelése alapján az augusztusi középhőmérséklet: 21,7 °C, a szórás: 1,3 °C. Az értékek az alábbi módon oszlanak meg:

hőmérséklet, °C	18-19	19-20	20-21	21-22	22-23	23-24	24-25
eset	2	7	12	22	23	9	5

Igazolható-e, hogy az adatok a normál eloszlás szerint oszlanak meg?
(megoldás: igazolható)

16. Orosházán hosszú megfigyelési sor alapján júliusban a 30 °C fölötti maximum hőmérsékletek bekövetkezési valószínűsége 30 %. Két év során előfordult 21 anticiklonális időjárású júliusi nap közül 14-en emelkedett a hőmérséklet 30 °C fölé. Jelentősen befolyásolja-e az anticiklonális időjárás a nyári hőség kialakulását?
(megoldás: jelentősen befolyásolja)

17. Siófokon 10 év összes júniusi napja közül 75-ön jegyezték föl 10 m s⁻¹-nél nagyobb szélökést. Ugyanezen időszak 60 zivataros napja közül 33-on fordult elő ekkora szélsébség. Kimondható-e, hogy zivataros napokon jelentősen nagyobb az erős szél bekövetkezési valószínűsége? (megoldás: kimondható)

18. San Cristobal (Galápagosz-szigetek) megfigyelő helyen az átlagosnál csapadékosabb március bekövetkezési valószínűsége 46 %. 11 olyan márciusi hónapból, amikor a környező tenger vizének hőmérséklete legalább 1 °C-kal melegebb volt a szokásosnál, 8 volt az átlagosnál csapadékosabb. Igazolható-e, hogy meleg tenger környezetében a szokásosnál több a csapadék? (megoldás: igazolható)

19. Budapesten az átlagosnál csapadékosabb január bekövetkezési valószínűsége 46 %. 14 átlagosnál hidegebb január közül 9 volt az átlagosnál csapadékosabb. Kimondható-e az információk alapján, hogy a hideg januárok a szokásosnál csapadékosabbak?
(megoldás: nem mondható ki)

20. Békéscsabán 80 évi megfigyelés alapján az októberi középhőmérséklet 12,4°C, a szórás 1,4 °C. Az adatok gyakorisági eloszlása a következő:

hőm, °C	7-8	8-9	9-10	10-11	11-12	12-13	13-14	14-15	15-16	16-17
eset	2	2	8	4	13	22	15	8	4	2

Igazolható-e az adatok normális eloszlás szerinti megoszlása? (megoldás: igazolható)

TÍPUSFELADATOK ÉS RÉSZLETES MEGOLDÁSI MENETÜK

1. BINOMIÁLIS ELOSZLÁSSAL KAPCSOLATOS FELADAT

1.1. Feladat:

Magyarországon szeptemberben az anticiklon-centrum makroszinoptikus helyzet bekövetkezési valószínűsége 21 %. Egymást követő 4 napot kiválasztva adjuk meg annak a valószínűségét, hogy ebből a 4 napból 3 napon fordul elő anticiklon-centrum időjárási helyzet!

Megoldási menet:

1. Alapkérdés: Adott egy p alapvalószínűségű alternatív esemény. n esetből k -szori bekövetkezése milyen valószínűséggel várható? Mivel az alapkérdés alkalmazható a feladatra, ezért az vagy a binomiális-, vagy a Poisson-eloszlás segítségével oldható meg.
2. Döntsük el a feladat típusát!
Ha $p > 0,03 \Rightarrow$ binomiális eloszlással számolunk
Ha $p < 0,03 \Rightarrow$ Poisson-eloszlással számolunk
Mivel $p = 21 \% = 0,21 \Rightarrow$ **az eloszlás típusa: binomiális**
3. Határozzuk meg a binomiális eloszlás paramétereit!
 $n = 4$
 $k = 3$
4. Helyettesítsünk be a binomiális eloszlás képletébe!

$$P(k; n) = \frac{n!}{k!(n-k)!} p^k (1-p)^{n-k} \quad (1.1.)$$

Innen:

$$P(3; 4) = \frac{4!}{3!(4-3)!} 0,21^3 (1-0,21)^{4-3} \quad (1.2.)$$

Azaz:

$$P(3; 4) = 4 * 0,21^3 * 0,79 = 0,029 \quad (1.3.)$$

5. Válaszoljunk a feladatra!

Tehát annak a valószínűsége, hogy Magyarországon a kiindulási feltételek mellett egymást követő 4 nap közül 3 napon fordul elő anticiklon-centrum időjárási helyzet: $P = 0,029$.

2. POISSON ELOSZLÁSSAL KAPCSOLATOS FELADAT

2.1. Feladat:

Nyíregyházán áprilisban 50 év alatt összesen 28 napon fordult elő fagy. Mi a valószínűsége a fagymentes áprilisknak Nyíregyházán?

Megoldási menet:

1. Alapkérdés: Adott egy p alapvalószínűségű alternatív esemény. n esetből k -szori bekövetkezése milyen valószínűséggel várható? Mivel az alapkérdés alkalmazható a feladatra, ezért az vagy a binomiális, vagy a Poisson-eloszlás segítségével oldható meg.

2. Döntsük el a feladat típusát!

Ha $p > 0,03 \Rightarrow$ binomiális eloszlással számolunk

Ha $p < 0,03 \Rightarrow$ Poisson-eloszlással számolunk

Mivel:

a keresett esemény, azaz a fagyos áprilisi napok száma: $k = 28$ nap

az összes esemény, azaz az összes vizsgált áprilisi napok száma:

$n = 50 \text{ év} * 30 \text{ nap} = 1500 \text{ nap}$

Ezért:

$$p = \frac{k}{n} = \frac{28}{50 * 30} < \frac{30}{50 * 30} = \frac{1}{50} = \frac{2}{100} = 0,02 < 0,03 \Rightarrow \text{az eloszlás típusa: Poisson}$$

3. Határozzuk meg a Poisson eloszlás paramétereit!

$k = 0$ (azaz 0 napon következzen be fagy egy tetszőleges – $n = 30$ nap tartamú – áprilisban)

$$n * p = 30 * \frac{28}{50 * 30} = \frac{28}{50} = 0,56$$

4. Helyettesítsünk be a Poisson eloszlás képletébe!

$$P(k; n * p) = \frac{(n * p)^k * e^{-(n * p)}}{k!} \quad (2.1.)$$

Innen:

$$P(0; 0,56) = \frac{0,56^0 * e^{-0,56}}{0!} = e^{-0,56} = \frac{1}{e^{0,56}} \quad (2.2.)$$

Mivel az e természetes logaritmus alapszáma: $e = 2,72$, így $P(0; 0,56) = 0,571$.

5. Válaszoljunk a feladatra!

Tehát annak a valószínűsége, hogy Nyíregyházán áprilisban a kiindulási feltételek mellett ne forduljon elő fagyos nap: $P = 0,571$.

3. NORMÁLIS ELOSZLÁSSAL KAPCSOLATOS FELADATOK

3.1. Feladat:

Szombathelyen az áprilisi középhőmérséklet $9,7\text{ }^\circ\text{C}$, a középhőmérsékletek szórása $2,3\text{ }^\circ\text{C}$. Mennyi a valószínűsége annak, hogy az áprilisi középhőmérséklet $8\text{ }^\circ\text{C}$ -nál alacsonyabb?

Megoldási menet:

1. Döntsük el a feladat típusát!

Mivel a középhőmérsékletek eloszlása normális, ezért *normális eloszlással kapcsolatos feladatról* van szó.

2. Adjuk meg az eloszlás paramétereit!

$$m = 9,7\text{ }^\circ\text{C}$$

$$\sigma = 2,3\text{ }^\circ\text{C}$$

3. Oldjuk meg *grafikusan* a feladatot!

Főrajzoljuk az m és σ paraméterekkel megadott normális eloszlás sűrűségfüggvényét. Bejelöljük a vízszintes tengelyen a $8\text{ }^\circ\text{C}$ -ot, s az annál kisebb értékekkel jellemzett görbe alatti terület a keresett valószínűség, azaz $F(x_a = 8\text{ }^\circ\text{C})$. Ugyanis:

$$F(x_a = 8\text{ }^\circ\text{C}) = P(x < x_a = 8\text{ }^\circ\text{C}) \quad (3.1.)$$

4. Oldjuk meg *numerikusan* a feladatot!

Elvégezzük az

$$x_a \longrightarrow \frac{x_a - m}{\sigma} = d_a \quad (3.2.)$$

transzformációt, amely tetszőleges $N(m \neq 0; \sigma \neq 1)$ eloszlást $N(m = 0; \sigma = 1)$ eloszlássá (standard normális eloszlássá) alakít. Erre a transzformációra azért van szükség, mert az $N(m = 0; \sigma = 1)$ eloszlásnak, és csak ennek ismert az eloszlásfüggvénye. Azaz az $F(x_a) = P(x < x_a)$ minden egyes x_a -ra csak az $N(m = 0; \sigma = 1)$ eloszlásra ismert, mely táblázatosan adott. Ily módon bármelyik normális eloszlással kapcsolatos feladat ennek a transzformációnak a segítségével oldható csak meg. Ez a transzformáció egy kölcsönösen egyértelmű megfeleltetés, mely az eredeti eloszlás minden egyes értékéből egy új értéket képez. Számunkra az $x_a = 8\text{ }^\circ\text{C}$, illetve az ennek megfelelő transzformált érték

$(x_a \longrightarrow \frac{x_a - m}{\sigma} = d_a = -0,74)$ az érdekes, mert a transzformációval előállított d_a független

változóhoz tartozó $F(d_a)$ függvényérték a standard normális eloszlás eloszlásfüggvényének a táblázatából kikereshető (tankönyv, 297. oldal, 5.4. táblázat; Péczely, 1979). Eszerint, lineáris interpolációval $F(d_a) = 18,6\%$.

Most alkalmazva az $F(x_a) = P(x < x_a)$ valószínűségi eloszlásfüggvény definícióját: az $x_a = 8\text{ }^\circ\text{C}$ az az érték, amelynél kisebb értékek előfordulási valószínűsége a mintában $18,6\%$. Vagyis képletben leírva: $F(8\text{ }^\circ\text{C}) = P(x < 8\text{ }^\circ\text{C}) = 18,6\%$.

5. Válaszoljunk a feladatra!

Tehát annak a valószínűsége, hogy Szombathelyen a kiindulási feltételek mellett $8\text{ }^\circ\text{C}$ -nál alacsonyabb legyen az áprilisi középhőmérséklet: 18,6%.

3.2. Feladat:

Szombathelyen az áprilisi középhőmérséklet $9,7\text{ }^\circ\text{C}$, a középhőmérsékletek szórása $2,3\text{ }^\circ\text{C}$. Határozzuk meg annak a számtani középére szimmetrikus intervallumnak az alsó és felső határát, amelybe 50 %-os valószínűséggel esnek az értékek!

Megoldási menet:

1. Döntsük el a feladat típusát!

Mivel a középhőmérsékletek eloszlása normális, ezért **normális eloszlással kapcsolatos feladatról** van szó.

2. Adjuk meg az eloszlás paramétereit!

$$m = 9,7\text{ }^\circ\text{C}$$

$$\sigma = 2,3\text{ }^\circ\text{C}$$

3. Oldjuk meg **grafikusan** a feladatot!

Főrajzoljuk az m és σ paraméterekkel megadott normális eloszlás sűrűségfüggvényét. Bejelöljük a vízszintes tengely fölé a minta középértéke által megfelezt, s a teljes minta 25-25 %-át tartalmazó intervallumokat. Ennek az intervallumnak a végpontjaira vagyunk kíváncsiak.

4. Oldjuk meg **numerikusan** a feladatot!

Elvégezzük a 3.1. feladtból már ismert

$$x_a \longrightarrow \frac{x_a - m}{\sigma} = d_a \quad (3.2.)$$

transzformációt, amely tetszőleges $N(m \neq 0; \sigma \neq 1)$ eloszlást $N(m = 0; \sigma = 1)$ eloszlássá (standard normális eloszlássá) alakít. Tudjuk továbbá, hogy minden egyes d_a -hoz tartozik egy és csak egy $F(d_a)$ a standard normális eloszlás eloszlásfüggvényének a táblázatából (tankönyv, 297. oldal, 5.4. táblázat; Péczely, 1979). Azaz: $d_a \longrightarrow F(d_a)$.

A 3.2. feladat azonban a 3.1. feladathoz képest fordított. Ugyanis ez esetben az $F(d_a)$ -t ismerjük, s a d_a -t kell meghatároznunk. Méghozzá két feladat megoldásáról van szó. A valószínűségi eloszlásfüggvény definíciójának figyelembe vételével egyrészt $F(d_{a1}) = 25\%$, amelyhez tartozó intervallumnak a d_{a1} alsó végpontját keressük; másrészt $F(d_{a2}) = 75\%$, amelyhez tartozó intervallumnak a d_{a2} felső végpontját keressük. Azaz:

$$\text{a) } F(d_{a1}) = 25\%, \longrightarrow d_{a1} = ? \quad (3.3.)$$

$$\text{b) } F(d_{a2}) = 75\%, \longrightarrow d_{a2} = ?$$

Most már egyszerű a feladatunk, hiszen az ismert $F(d_{a1})$ és $F(d_{a2})$ függvényértékekhez tartozó d_{a1} és d_{a2} független változókat kikeressük a már említett táblázatból (tankönyv, 297. oldal, 5.4. táblázat; Péczely, 1979). Ezt követően, a d_{a1} ($= -0,73$) és d_{a2} ($= +0,73$) értékek ismeretében a (3.2.) egyenlet segítségével az eredeti x_{a1} ($= 8,02$) és x_{a2} ($= +11,38$) értékek könnyen kiszámíthatók.

5. Válaszoljunk a feladatra!

Tehát Szombathelyen a kiindulási feltételek mellett áprilisban az a számtani középére szimmetrikus intervallum, amelybe 50 %-os valószínűséggel esnek az értékek, a következő: $(8,02\text{ }^\circ\text{C}; 11,38\text{ }^\circ\text{C})$.

4.1. χ^2 -PRÓBA TISZTA ILLESZKEDÉS-VIZSGÁLATTAL KAPCSOLATOS FELADAT

4.1. Feladat:

Budapesten az 1941-1960 közötti 20 év megfigyelései alapján az áprilisi maximum-hőmérséklet az alábbi gyakoriságban fordult elő a hónap első, illetve második felében:

	április	
	I. fele	II. fele
Észlelt gyakoriság (É)	5	15
Feltételezett gyakoriság (F)	10	10

Feltehetjük-e azt, hogy Budapesten az áprilisi maximum-hőmérséklet a hónap első, illetve második felében egyenlő eséllyel várható?

Megoldási menet:

1. Állítsuk föl a 0-hipotézist!

Mivel a feladatban eldöntendő kérdésre kell válaszolnunk, egy a „priori” (előzetes, a tapasztalattól független, a számításokat megelőző) feltevést teszünk. Eszerint azt mondjuk (minden hasonló kérdésfeltevés esetén), hogy az áprilisi maximum-hőmérsékletek nem különböznek lényegesen a hónap első, illetve második felében.

2. Döntsük el a feladat típusát!

1. közelítés:

Ahhoz, hogy ezt az előzetes (a priori) feltevésünk igaz, vagy hamis voltát statisztikai alapon eldönthessük, a χ^2 -próba módszerét alkalmazzuk a feladat megoldására.

Ha nincs lényeges eltérés, akkor ez az a priori feltevésünk szerint azt jelenti [azaz azt feltételezzük (F)], hogy 10 alkalommal a hónap első felében, 10 alkalommal pedig a hónap második felében lépett föl az áprilisi maximum-hőmérséklet.

2. közelítés:

A feladatban fölvetett kérdést úgy is megfogalmazhatjuk, hogy az adott 20 éves mintában észlelt (É) kéttagú eloszlás mennyire jól illeszkedik az általunk a 0-hipotézis révén feltételezett (F) kéttagú egyenletes eloszláshoz? Ezen utóbbi, módosított kérdésfelvetés révén a feladattípust pontosíthatjuk: χ^2 -próba, illeszkedésvizsgálat.

3. közelítés:

Mivel a feltételezett minta (F) – amelyhez az észlelt minta (É) illeszkedését vizsgáljuk – egyetlen elemével adott, ezért e feladat esetében **χ^2 -próba, tiszta illeszkedésvizsgálatról** beszélünk.

3. Helyettesítsünk be a χ^2 -próba képletébe!

A próba képlete a következő:

$$\chi^2 = \sum_{i=1}^n \frac{(\dot{E}_i - F_i)^2}{F_i} = \frac{(\dot{E}_1 - F_1)^2}{F_1} + \frac{(\dot{E}_2 - F_2)^2}{F_2} + \dots + \frac{(\dot{E}_n - F_n)^2}{F_n} \quad (4.1.)$$

Behelyettesítve:

$$\chi^2 = \sum_{i=1}^n \frac{(\hat{E}_i - F_i)^2}{F_i} = \frac{(5-10)^2}{10} + \frac{(15-10)^2}{10} = 2,5 + 2,5 = 5 \quad (4.2.)$$

Ahhoz, hogy az általunk imént kapott χ^2 -érték ismeretében dönthessünk a 0-hipotézis teljesedését, vagy nem teljesedését illetően, meg kell határoznunk a szabadsági fokok számát. A szabadsági fok (sz.f.) az általunk fölállított kontingencia-táblázatban heurisztikusan az oszloponként szabadon megválasztható paraméterek számát jelenti. Azaz:

$$\text{sz.f.} = o - 1 \quad (4.3.)$$

ahol o = az oszlopok száma a kontingencia-táblázatban.

A feladatunkban – mivel a kontingencia-táblázat oszlopainak a száma = 2, ezért: sz.f. = (2 - 1) = 1.

Ily módon, a kapott χ^2 -érték ($\chi^2 = 5$) és szabadsági fok (sz.f. = 1) mellett adott valószínűségi szinten meghatározhatjuk a 0-hipotézis teljesedését, vagy nem teljesedését a tankönyv, 315. oldalán található 5.11. táblázat alapján (Péczy, 1979).

A táblázatban található valószínűségi szintek (v.sz. = 10 %, 5 %, 1 %, 0,1 %) jelentése a következő. Ezek a valószínűségek az igaz 0-hipotézis elvetésének a valószínűségét jelentik. Azaz, ha pl. az 5 %-os valószínűségi szinten döntünk (általában ezt választjuk), akkor olyan küszöbérték ($\chi_{v.sz.}^{2;sz.f.} = \chi_{0,05}^{2;1} = 3,86$) tartozik az sz.f. = 1 értékhez, hogy 100 esetből átlagosan 5 esetben ennél a küszöbértéknél nagyobb számított χ^2 -értéket kapunk, s elvetjük a 0-hipotézist, holott az valójában igaz. Csupán az adatok véletlenszerű elrendeződése folytán kapunk olyan nagy χ^2 -értéket, hogy az túllépi a küszöböt (tankönyv, 315. oldal, 5.11. táblázat; Péczy, 1979).

Itt rögtön meg kell jegyezzük, hogy amikor e táblázat alapján döntünk, kétféle hibát követhetünk el: a) igaz 0-hipotézist elvetünk (elsőfajú hiba), illetve b) hamis 0-hipotézist elfogadunk (másodfajú hiba).

Ha – bármely tetszőleges szabadsági fok mellett – csökken a valószínűségi szint, akkor nő a χ^2 -küszöbérték. Ez azt jelenti, hogy ha csökken a valószínűségi szint, akkor csökken ugyan az igaz 0-hipotézis elvetésének a valószínűsége, vagyis az elsőfajú hiba (hiszen nő a χ^2 -küszöbérték!), másrészt viszont – ezzel párhuzamosan – nő a hamis 0-hipotézis elfogadásának a valószínűsége, vagyis a másodfajú hiba (pontosan amiatt, hogy nő a χ^2 -küszöbérték!). Tudnunk kell, hogy a mindenkori döntésünk a 0-hipotézis teljesedését, vagy nem teljesedését illetően csak statisztikai értelemben igaz. Ugyanis minden döntésünk tartalmaz bizonyos százalékban mind elsőfajú hibát, mind másodfajú hibát. Célunk az, hogy mindkét hibát minimalizáljuk.

Ha a χ^2 -próba képletébe történő behelyettesítést követően olyan nagy χ^2 -értéket kapunk, hogy az a 0,1 %-os valószínűségi szinten is szignifikáns, az azt jelenti, hogy ehhez a valószínűségi szinthez olyan magas χ^2 -küszöbérték ($\chi_{v.sz.}^{2;sz.f.}$) tartozik, hogy 1000 esetből átlagosan mindössze egy esetben vetünk el igaz 0-hipotézist. Ugyanakkor látnunk kell, hogy ha csökken a valószínűségi szint, akkor – ezzel párhuzamosan – nő a másodfajú hiba, amelynek értékéről közelebbit nem tudunk mondani.

Ha a χ^2 -próba képletébe történő behelyettesítést követően nagyon kicsi χ^2 -értéket kapunk, akkor elmondhatjuk, hogy (ha $\chi_{számított}^2 < \chi_{küszöbérték}^2$) teljesül az adott valószínűségi szinten a 0-hipotézis. Sőt, további számítással a 0-hipotézis teljesedésének a konkrét %-os valószínűsége is meghatározható.

A konkrét feladatunk esetében tehát $\chi^2 = 5$; sz.f. = 1; a választott valószínűségi szint: 5 %. A tankönyv 315. oldal, 5.11. táblázat alapján (Péczeley, 1979) azt kapjuk, hogy

$$\chi_{\text{számított}}^2 = 5,00 > \chi_{\text{küszöbérték}}^2 = \chi_{\text{v.sz.}}^{2;\text{sz.f.}} = \chi_{0,05}^{2;1} = 3,86 . \quad (4.4.)$$

A döntési kritériumunk a következő:

ha $\chi_{\text{számított}}^2 < \chi_{\text{küszöbérték}}^2$ ($= \chi_{\text{v.sz.}}^{2;\text{sz.f.}}$), akkor megtartjuk a 0-hipotézist,

ha $\chi_{\text{számított}}^2 > \chi_{\text{küszöbérték}}^2$ ($= \chi_{\text{v.sz.}}^{2;\text{sz.f.}}$), akkor elvetjük a 0-hipotézist a választott valószínűségi szinten.

4. Válaszoljunk a feladatra!

Számításaink alapján a 0-hipotézis nem teljesül. Tehát nem igaz az, hogy Budapesten áprilisban a maximum-hőmérséklet a hónap első, illetve második felében egyenlő eséllyel várható.

4.2. χ^2 -PRÓBA BECSLÉSES ILLESZKEDÉS-VIZSGÁLATTAL KAPCSOLATOS FELADAT

4.2. Feladat:

Békéscsabán 80 évi megfigyelés alapján az október középhőmérséklete 12,4 °C, s az októberi középhőmérsékletek szórása 1,4 °C. Az értékek osztályközös gyakorisági eloszlása az alábbi:

hőmérséklet, °C	7–8	8–9	9–10	10–11	11–12	12–13	13–14	14–15	15–16	16–17
gyak., db (É)	2	2	8	4	13	22	15	8	4	2
gyak., db (F)										

Igazolható-e, hogy az adatok a normális eloszlás szerint oszlanak meg?

Megoldási menet:

1. Állítsuk föl a 0-hipotézist!

Mivel a feladatban eldöntendő kérdésre kell válaszolnunk, egy a „priori” (előzetes, a tapasztalattól független, a számításokat megelőző) feltevést teszünk. Eszerint azt mondjuk, hogy nincs lényeges eltérés (mivel 0-hipotézist állítunk föl, ezért 0 az eltérés) a fenti táblázatban az észlelt osztályközös gyakorisági értékek (É), illetve a normális eloszlás feltételezésével számított osztályközös gyakorisági értékek (F) eloszlása között.

2. Döntsük el a feladat típusát!

1. közelítés:

Ahhoz, hogy ezt az előzetes (a priori) feltevésünk igaz, vagy hamis voltát statisztikai alapon eldönthessük, a χ^2 -próba módszerét alkalmazzuk a feladat megoldására.

2. közelítés:

Arra vagyunk kíváncsiak, hogy az eredeti minta osztályközös gyakorisági eloszlása mennyire jól illeszkedik a normalitás feltételezésével számított minta osztályközös gyakorisági eloszlásával. Tehát a feladat típusa illeszkedésvizsgálat.

3. közelítés:

Mivel a feltételezett minta elemeit (F) – amelyhez az észlelt minta (É) illeszkedését vizsgáljuk – az észlelt minta paramétereiből ($m = 12,4$ °C és $\sigma = 1,4$ °C) becsüljük, ezért a feladat esetében **χ^2 -próba, becsléses illeszkedésvizsgálatról** beszélünk.

3. Határozzuk meg a normalitás feltételezésével számított minta osztályközös feltételezett gyakorisági értékeit (F)!

Fontos megjegyezni, hogy a χ^2 -próba képletében az összeadandó tagok szélsőségesen nagy értékeit (ezáltal a potenciálisan torz számított χ^2 -értéket) elkerülendő, az észlelt (É) és a feltételezett (F) cellaelemek értéke nem lehet kisebb 5-nél. Hogy ezt szükség esetén elérjük, a szomszédos oszlopok cellaelemeit soronként összevonjuk. A későbbi kevesebb számolás miatt ezt az összevonást az 5-nél kisebb észlelt (É) értékek esetében már akkor elvégezzük, amikor a hozzájuk tartozó feltételezett (F) értékek még nem ismeretesek. Az összevonásokat mindaddig folytatjuk, amíg a legkisebb cellaelem értéke eléri, vagy meghaladja az 5-öt. Mivel a fentiek alapján a feladatban elvégezzük a szükséges összevonásokat, az alábbi kontingencia-táblázathoz jutunk:

hőmérséklet, °C	7–10	10–12	12–13	13–14	14–15	15–17
gyak., db (É)	12	17	22	15	8	6
gyak., db (F)						

Ily módon az összevonásokkal kapott – kevesebb oszlopból álló – kevesebb osztályközös gyakorisági érték, ennél fogva kevesebb számolás révén oldjuk meg a feladatot. Minden egyes (a normalitás feltételezésével) számított cellaelem (F-érték) meghatározása egy-egy normális eloszlással kapcsolatos feladat megoldását jelenti. Azaz, rendre:

3.1. *Határozzuk meg az észlelt minta adatai (cellaelemei) (É) ismeretében – azok feltételezeten normális eloszlása alapján – annak a valószínűségét, hogy az értékek a [7 °C – 10 °C] intervallumba esnek!*

Nyilván a 7 °C-nál kisebb értékek bekövetkezésének is lesz egy csekély valószínűsége, azonban ezt a töredékvalószínűséget hozzáadjuk a [7 °C – 10 °C] intervallumba esés valószínűségéhez. Ily módon a [7 °C – 10 °C] intervallumba esés valószínűsége megegyezik a 10 °C-nál kisebb értékek bekövetkezési valószínűségével a mintában. Ha ezt a $p_{10\text{ °C}} = F(x_a = 10\text{ °C}) = P(x < x_a = 10\text{ °C})$ valószínűséget meghatározzuk, akkor a $p = \frac{k}{n}$ formula felhasználásával a $k = n \cdot p$ osztályközös gyakoriság már kiszámítható (itt n a minta összes elemszáma, azaz n = 80).

Mivel a végtelen sok normális eloszlás közül csak az N (m = 0; σ = 1) eloszlásnak ismert az eloszlásfüggvénye, ezért – hogy megoldhassuk a feladatot – elvégezzük a már ismert

$$x_a \longrightarrow \frac{x_a - m}{\sigma} = d_a \quad (3.2.)$$

transzformációt, amely tetszőleges N (m ≠ 0; σ ≠ 1) eloszlást N (m = 0; σ = 1) eloszlássá (standard normális eloszlássá) alakít. Tudjuk továbbá, hogy minden egyes d_a -hoz tartozik egy és csak egy $F(d_a)$ a standard normális eloszlás eloszlásfüggvényének a táblázatából (tankönyv, 297. oldal, 5.4. táblázat; Péczely, 1979). Azaz: $d_a \longrightarrow F(d_a)$. Mivel az eredeti és a transzformált normális eloszlású sűrűségfüggvényekben az eredeti és a transzformált intervallumvégpontok közé eső görbe alatti területek (azaz valószínűségek) nem változnak, ezért $F(d_a) = F(x_a)$. Következésképpen az osztályközös valószínűségek így módon meghatározhatók, amelyekből az osztályközös gyakorisági értékek a $k = n \cdot p$ formulával kiszámíthatók.

A mi esetünkben $x_a = 10\text{ °C}$ lesz, azaz a vizsgált intervallum felső végpontja. Mivel $m = 12,4\text{ °C}$, és $\sigma = 1,4\text{ °C}$, ekkor:

transzformáció	d_a	$F(d_a)$	$P = F(x_b) - F(x_a) = P(x < x_b) - P(x < x_a)$	Feltételezett gyakoriság (F), db, $k = n \cdot p$	Felt. gyak. (F), db (kerekítve)
$\frac{x_a - m}{\sigma} = d_a = \frac{10 - 12,4}{1,4} = -\frac{2,4}{1,4} = -1,71 = d_a \rightarrow F(d_a) = 0,04$				$80 \cdot 0,04 = 3,2$	3

3.2. *Határozzuk meg az észlelt minta adatai (cellaelemei) (É) ismeretében – azok feltételezeten normális eloszlása alapján – annak a valószínűségét, hogy az értékek a [10 °C – 12 °C] intervallumba esnek!*

transzformáció	d_a	$F(d_a)$	$P = F(x_b) - F(x_a) = P(x < x_b) - P(x < x_a)$	Feltételezett gyakoriság (F), db, $k = n \cdot p$	Felt. gyak. (F), db (kerekítve)
$\frac{x_a - m}{\sigma} = d_a = \frac{12 - 12,4}{1,4} = -\frac{0,4}{1,4} = -0,28 = d_a \rightarrow F(d_a) = 0,39$			$0,39 - 0,04 = 0,35$	$80 \cdot 0,35 = 28,0$	28

3.3. Határozzuk meg az észlelt minta adatai (cellaelemei) (\hat{E}) ismeretében – azok feltételezeten normális eloszlása alapján – annak a valószínűségét, hogy az értékek a [12 °C – 13 °C] intervallumba esnek!

transzformáció	d_a	$F(d_a)$	$P = F(x_b) - F(x_a) = P(x < x_b) - P(x < x_a)$	Feltételezett gyakoriság (F), db, $k = n \cdot p$	Felt. gyak. (F), db (kerekítve)
$\frac{x_a - m}{\sigma} = d_a = \frac{13 - 12,4}{1,4} = \frac{0,6}{1,4} = 0,42 = d_a \rightarrow F(d_a) = 0,66$			$0,66 - 0,39 = 0,27$	$80 \cdot 0,27 = 21,6$	22

3.4. Határozzuk meg az észlelt minta adatai (cellaelemei) (\hat{E}) ismeretében – azok feltételezeten normális eloszlása alapján – annak a valószínűségét, hogy az értékek a [13 °C – 14 °C] intervallumba esnek!

transzformáció	d_a	$F(d_a)$	$P = F(x_b) - F(x_a) = P(x < x_b) - P(x < x_a)$	Feltételezett gyakoriság (F), db, $k = n \cdot p$	Felt. gyak. (F), db (kerekítve)
$\frac{x_a - m}{\sigma} = d_a = \frac{14 - 12,4}{1,4} = \frac{1,6}{1,4} = 1,14 = d_a \rightarrow F(d_a) = 0,87$			$0,87 - 0,66 = 0,21$	$80 \cdot 0,21 = 16,8$	17

3.5. Határozzuk meg az észlelt minta adatai (cellaelemei) (\hat{E}) ismeretében – azok feltételezeten normális eloszlása alapján – annak a valószínűségét, hogy az értékek a [14 °C – 15 °C] intervallumba esnek!

transzformáció	d_a	$F(d_a)$	$P = F(x_b) - F(x_a) = P(x < x_b) - P(x < x_a)$	Feltételezett gyakoriság (F), db, $k = n \cdot p$	Felt. gyak. (F), db (kerekítve)
$\frac{x_a - m}{\sigma} = d_a = \frac{15 - 12,4}{1,4} = \frac{2,6}{1,4} = 1,85 = d_a \rightarrow F(d_a) = 0,97$			$0,97 - 0,87 = 0,10$	$80 \cdot 0,10 = 8,0$	8

3.5. Határozzuk meg az észlelt minta adatai (cellaelemei) (\hat{E}) ismeretében – azok feltételezeten normális eloszlása alapján – annak a valószínűségét, hogy az értékek a [14 °C – 15 °C] intervallumba esnek!

Ez a feladatot viszont már egyszerűen meg tudjuk oldani. Ugyanis, ha az összes mintaelemszámból ($n = 80$) levonjuk a normalitás feltételezésével eddig kiszámított osztályközös gyakoriságokat (F-értékeket), akkor az utolsó osztályköz feltételezett gyakorisági értéke: $k = 80 - (3 + 28 + 22 + 17 + 8) = 80 - 78 = 2$ lesz. Nyilván az előző eljárás alkalmazásával ugyanezt az eredményt kapnánk.

Most írjuk be a feltételezett értékeket az összevonásokkal már leegyszerűsített táblázatunkba!

hőmérséklet, °C	7 – 10	10 – 12	12 – 13	13 – 14	14 – 15	15 – 17
gyak., db (\hat{E})	12	17	22	15	8	6
gyak., db (F)	3	28	22	17	8	2

Látjuk, hogy 5-nél kisebb feltételezett értékeket kaptunk a [7 °C – 10 °C], illetve a [15 °C – 17 °C] intervallumokban. Ezért újabb összevonásokra kerül sor. Fontos megjegyeznünk, hogy ha valamely oszlopban csak az egyik cellaelem kisebb 5-nél, akkor is annak mindkét cellaelemét összevonjuk a szomszédos oszlop megfelelő cellaelemével. Ennek figyelembe vételével a következő kontingencia-táblázathoz jutunk:

hőmérséklet, °C	7 – 12	12 – 13	13 – 14	14 – 17
gyak., db (É)	29	22	15	14
gyak., db (F)	31	22	17	10

4. Helyettesítsünk be a χ^2 -próba képletébe!

$$\chi^2 = \sum_{i=1}^n \frac{(\hat{E}_i - F_i)^2}{F_i} = \frac{(29-31)^2}{31} + \frac{(22-22)^2}{22} + \frac{(15-17)^2}{17} + \frac{(14-10)^2}{10} = \frac{4}{31} + 0 + \frac{4}{17} + \frac{16}{10} = 1,96$$

Abban az esetben, ha a feladat annak eldöntése, hogy egy adott minta tekinthető-e normális eloszlásúnak (jelen feladat), akkor az észlelt minta osztályközös gyakorisági értékeihez (\hat{E}_i) a feltételezett minta megfelelő osztályközös gyakorisági értékeit úgy kapjuk meg, hogy utóbbiakat az észlelt minta paramétereiből (m ; σ) becsüljük, miután feltettük, hogy az észlelt minta eloszlása normális. Ebben az esetben a szabadsági fokok meghatározás a következő:

$$\text{sz.f.} = o - b - 1,$$

ahol b = a becsült paraméterek száma.

Mivel a feladat alapján 2 becsült paraméterünk van (m és σ), a szabadsági fokok száma:

$$\text{sz.f.} = o - b - 1 = 4 - 2 - 1 = 1 .$$

Fontos megjegyezni, hogy a szabadsági fokokat mindig az összevonások után kapott oszlopszámok figyelembe vételével határozzuk meg!

Ezután a tankönyv, 315. oldal, 5.11. táblázata (Péczy, 1979) alapján döntünk a 0-hipotézisünk teljesedését, illetve nem teljesedését illetően:

$$\chi_{\text{számított}}^2 = 1,96 < \chi_{v.sz.}^{2;sz.f.} = \chi_{0,05}^{2;1} = 3,84 .$$

ahol $v.sz.$ a választott valószínűségi szint, azaz a mi esetünkben: $v.sz. = 0,05$.

5. Válaszoljunk a feladatra!

Mivel az általunk számított χ^2 -érték kisebb, mint a választott valószínűségi szinthez és a számított szabadsági fokhoz tartozó küszöbérték, ezért a 0-hipotézist elfogadjuk. Azaz nincs lényeges különbség az észlelt osztályközös gyakorisági értékek (\hat{E}), illetve a normális eloszlás feltételezésével számított osztályközös gyakorisági értékek (F) eloszlása között. Azaz, az észlelt minta normális eloszlásúnak tekinthető.

4.3. χ^2 -PRÓBA HOMOGENITÁS-VIZSGÁLATTAL KAPCSOLATOS FELADAT

4.3. Feladat:

Egy dombos területen két nyári hónapon át naponta mértük a hajnali minimum-hőmérsékletet egy kiválasztott domb tetején és a nála 30 m-rel mélyebben fekvő völgyfenéken. Az észlelt (É) értékek az alábbi osztályközös gyakoriságokban fordultak elő:

hőmérséklet, °C	6 – 8	8 – 10	10 – 12	12 – 14	14 – 16	16 – 18	18 – 20	sorösszeg(\sum_j)
dombtető (É)	1	5	13	12	18	7	4	60
völgyfenék (É)	7	10	20	12	6	5	–	60
oszlopösszeg(\sum_i)	8	15	33	24	24	12	4	120

Igazolható-e, hogy a dombtető és a völgyfenék hajnali minimum-hőmérsékleteinek eloszlásában nincs lényeges eltérés?

Megoldási menet:

1. Állítsuk föl a 0-hipotézist!

Mivel a feladatban eldöntendő kérdésre kell válaszolnunk, egy a „priori” (előzetes, a tapasztalattól független, a számításokat megelőző) feltevést teszünk. Eszerint azt mondjuk, hogy a dombtető és a völgyfenék hajnali minimum-hőmérsékleteinek eloszlása nem tér el lényegesen egymástól.

2. Döntsük el a feladat típusát!

1. közelítés:

Ahhoz, hogy ezt az előzetes (a priori) feltevéseink igaz, vagy hamis voltát statisztikai alapon eldönthessük, a χ^2 -próba módszerét alkalmazzuk a feladat megoldására.

2. közelítés:

Itt más a helyzet, mint a tiszta, illetve a becsléses illeszkedés-vizsgálat esetében. Ugyanis az utóbbiaknál rendelkezésünkre állt egy észlelt minta, s annak egy feltételezett mintához való illeszkedésének a jóságát vizsgáltuk. Viszont ennél a feladatnál mindkét minta észlelt adatokat tartalmaz. Emiatt a feladat más megközelítést igényel. Itt arra vagyunk kíváncsiak, hogy a két észlelt minta azonos alapsokaságból származik-e, azaz tekinthető-e azonos eloszlásúaknak, függetlenül az eloszlás típusától. Az ilyen típusú feladatokat a **χ^2 -próba, homogenitás-vizsgálat** segítségével oldjuk meg.

3. Határozzuk meg a χ^2 -próba alkalmazásához a hajnali minimum-hőmérsékletek feltételezett gyakorisági értékeit (F) mind a dombtetőn, mind a völgyfenéken!

Mielőtt hozzákezdénénk a feltételezett értékek meghatározásához, rögtön látjuk, hogy összevonásokra van szükség, mivel előfordulnak 5-nél kisebb értékek mindkét észlelt mintában. Az összevonások után az alábbi kontingencia-táblázatot kapjuk:

hőmérséklet, °C	6 – 10	10 – 12	12 – 14	14 – 16	16 – 20	sorösszeg(\sum_j)
dombtető (É)	6	13	12	18	11	60
völgyfenék (É)	17	20	12	6	5	60
oszlopösszeg(\sum_i)	23	33	24	24	16	120

Mivel a feladatban mindkét minta észlelt adatokat tartalmaz, ezért a χ^2 -próba, homogenitás-vizsgálat esetében a feltételezett értékek meghatározása mindkét észlelt mintára külön-külön, cellánként történik.

A feltételezett érték meghatározása egy tetszőleges cellára (F_{ij}) az imént kapott kontingencia-táblázat alapján a következő formulával történik:

$$F_{ij} = \frac{\sum_j * \sum_i}{\sum_{ij}} \quad (4.5.)$$

azaz egy adott cellához tartozó feltételezett értéket úgy kapunk meg, hogy az adott cella sorösszegét megszorozzuk az adott cella oszlopösszegével, s e szorzatot elosztjuk a minta összes elemszámával (ez a feladat szerint $n = 120$).

Határozzuk meg most minden egyes cellára a feltételezett értékeket!

$$F_{11} = \frac{60 * 23}{120} = 11,5; \quad F_{12} = \frac{60 * 33}{120} = 16,5; \quad F_{13} = \frac{60 * 24}{120} = 12; \quad F_{14} = \frac{60 * 24}{120} = 12; \quad F_{15} = \frac{60 * 16}{120} = 8$$

$$F_{21} = \frac{60 * 23}{120} = 11,5; \quad F_{22} = \frac{60 * 33}{120} = 16,5; \quad F_{23} = \frac{60 * 24}{120} = 12; \quad F_{24} = \frac{60 * 24}{120} = 12; \quad F_{25} = \frac{60 * 16}{120} = 8$$

Jól látható, hogy az azonos oszlophoz tartozó feltételezett cellaelem értékek a két mintában (a két sorban) azonosak. Azonban ez csak akkor van így, ha a két észlelt mintához tartozó sorösszegek megegyeznek. Ekkor tehát nem is kell külön kiszámolni a második sorra a feltételezett értékeket, hanem az azonos oszlopban, az első sorban kapott cellaértékeket írjuk be a második sorba is. Ha a két minta (két sor) sorösszege nem egyezik, akkor viszont a második sorban is ki kell számolni cellánként a feltételezett értékeket.

Írjuk be most a kapott feltételezett értékeket a megfelelő cellákba. A könnyebb megkülönböztetés érdekében cellánként az észlelt értékek normál betűvel a bal alsó sarokban, míg a feltételezett értékek dőlt betűvel a jobb felső sarokban találhatóak. Ily módon a következő kontingencia-táblázathoz jutunk:

hőmérséklet, °C	6 – 10	10 – 12	12 – 14	14 – 16	16 – 20	sorösszeg(\sum_j)
dombtető (É)	<i>11,5</i>	<i>16,5</i>	<i>12</i>	<i>12</i>	<i>8</i>	60
völgyfenék (É)	<i>11,5</i>	<i>16,5</i>	<i>12</i>	<i>12</i>	<i>8</i>	60
oszlopösszeg(\sum_i)	23	33	24	24	16	120

4. Helyettesítsünk be a χ^2 -próba képletébe!

Mivel az észlelt (\hat{E}) és a feltételezett (F) értékek minden egyes cellához adottak, ezért elvégezhetjük a cellánkénti behelyettesítést a χ^2 -próba képletébe. Eszerint:

$$\begin{aligned}\chi^2 &= 2 * \sum_{i=1}^n \frac{(\hat{E}_i - F_i)^2}{F_i} = 2 * \left[\frac{(6-11,5)^2}{11,5} + \frac{(13-16,5)^2}{16,5} + \frac{(12-12)^2}{12} + \frac{(18-12)^2}{12} + \frac{(11-8)^2}{8} \right] = \\ &= 2 * \left[\frac{30,25}{11,5} + \frac{12,25}{16,5} + 0 + 3 + \frac{9}{8} \right] = 15,0\end{aligned}$$

A szabadsági fokok (sz.f.) száma a (4.3.) egyenlet alapján:

$$\text{sz.f.} = (o - 1) = (5 - 1) = 4$$

Fontos megjegyezni, hogy a szabadsági fokokat mindig az összevonások után kapott oszlopszámok figyelembe vételével határozzuk meg!

Ezután a tankönyv, 315. oldal, 5.11. táblázata (Péczy, 1979) alapján döntünk a 0-hipotézisünk teljesedését, illetve nem teljesedését illetően:

$$\chi_{\text{számított}}^2 = 15,0 > \chi_{\text{v.sz.}}^{2;\text{sz.f.}} = \chi_{0,05}^{2;4} = 9,49$$

ahol v.sz. a választott valószínűségi szint, azaz a mi esetünkben: v.sz. = 0,05.

5. Válaszoljunk a feladatra!

Mivel az általunk számított χ^2 -érték nagyobb, mint a választott valószínűségi szinthez és a számított szabadsági fokhoz tartozó küszöbérték, ezért a 0-hiptézist elutasítjuk. Azaz a dombtető és a völgyfenék nyári hajnali minimum-hőmérsékleteinek eloszlása lényegesen különbözik egymástól.

5.1. VALÓSZÍNŰSÉGEK KONFIDENCIA INTERVALLUMÁVAL KAPCSOLATOS FELADAT

5.1. Feladat:

Egy tóparti megfigyelőhelyen a szabad vízfelület az észlelőponttól számított északkelet-délkeleti irányok által meghatározott 90°-os szektorba esik. A tapasztalat szerint nyáron a nappali órákban elég gyakori a tavi szél az állomáson. Hosszú megfigyelések alapján júliusban az óránkénti szélmegfigyelések szerint 30 % annak a valószínűsége, hogy az állomáson a fenti szektorból fúj a szél. 5 vizsgált év júliusi napjain déli 12 órakor az esetek 47 %-ában volt víz felőli szélirány.

Eltér-e ez a kis mintára kapott relatív gyakoriság oly mértékben a hosszú megfigyelési időszakra megállapított alapvalószínűségtől, hogy kimondhassuk a nappali tavi szél törvényszerű fellépését?

Megoldási menet:

1. Állítsuk föl a 0-hipotézist!

Mivel a feladatban eldöntendő kérdésre kell válaszolnunk, egy a „priori” (előzetes, a tapasztalattól független, a számításokat megelőző) feltevést teszünk. Eszerint azt mondjuk, hogy a kis mintára kapott relatív gyakoriság nem tér el lényegesen a hosszú megfigyelési időszakra vonatkozó alapvalószínűségtől. Azaz, azt mondjuk, hogy a déli órákban nem növekszik meg lényegesen a tó felőli szélirány relatív gyakorisága.

2. Döntsük el a feladat típusát!

E feladat elméleti háttere a következő. Ismert valamely esemény bekövetkezésének P valószínűsége egy teljes adatsokaságra. Majd bizonyos szempont szerint kiválasztunk részsokaságokat, s ezekre is meghatározzuk az esemény bekövetkezésének p valószínűségét (illetve – mivel általában kis elemszámú mintákról van szó – relatív gyakoriságát). Majd azt vizsgáljuk, hogy az esemény bekövetkezését előidéző ok ugyanúgy hatott-e a kiválasztott részsokaságokban, mint a teljes adatsokaságban.

Az ilyen típusú feladatok megoldása a *valószínűségek konfidencia intervallumának* meghatározásával lehetséges. Az eljárás kidolgozása Neumann János nevéhez fűződik.

3. Mutassuk be a módszer lényegét!

Legyen adott a teljes adatsokaságra valamely esemény P alapvalószínűsége. Válasszunk a teljes adatsokaságból véletlenszerűen n elemű részsokaságokat, majd ezen minták mindegyikére határozzuk meg az esemény valószínűségét (p) (azaz, kis mintákról lévén szó: relatív gyakoriságát). A kapott p értékek véletlenszerűen szóródnak P körül, s eloszlásukra a normális eloszlás tételezhető fel. Az n elemű részmintákra meghatározott p valószínűségek szórása (σ_p) az alábbi képlettel adható meg.

$$\sigma_p = \sqrt{\frac{p(1-p)}{n}} \quad (5.1.)$$

A konfidencia-intervallum P_1 alsó és P_2 felső határát a következő összefüggések szolgáltatják:

$$P_1 = p - d * \sigma_p \quad (5.2.)$$

$$P_2 = p + d * \sigma_p$$

A konfidencia-határokat adott valószínűségi szintre vonatkoztatjuk. Általában az 5 %-os, az 1 %-os, illetve a 0,1 %-os valószínűségi szinteket alkalmazzuk, amelyekhez tartozó d-értékek rendre 1,96, 2,58, illetve 3,29.

$[P_1; P_2] \Rightarrow$ a 0-hipotézist a választott valószínűségi szinten megtartjuk; $[P_1; P_2] \Rightarrow$ a 0-hipotézist a választott valószínűségi szinten elvetjük.

A választott valószínűségi szint – a χ^2 -próbával kapcsolatos feladatokhoz hasonlóan – az igaz 0-hipotézis elvetésének a valószínűségét jelenti. Tehát, ha pl. az 5 %-os valószínűségi szintet választjuk, akkor az ahhoz tartozó d-érték alapján számított $[P_1; P_2]$ konfidencia-intervallum olyan széles lesz, hogy 100 esetből átlagosan 5 esetben vetünk el igaz 0-hipotézist azáltal, hogy a véletlenszerű adatok alapján számított $[P_1; P_2]$ konfidencia-intervallumon kívülre esik P. Az is látható, hogy ha a valószínűségi szint (vagyis az igaz 0-hipotézis elvetésének a valószínűsége, ami azonos az elsőfajú hibával) csökken, akkor nő a hozzá tartozó d-érték. Ennélfogva a $[P_1; P_2]$ konfidencia-intervallum szélesebbé válik. Ez azt jelenti, hogy ha csökken az elsőfajú hiba, azzal párhuzamosan növekszik a másodfajú hiba (azaz a hamis 0-hipotézis elfogadásának az esélye). Ennek épp az az oka, hogy a konfidencia-intervallum ez esetben szélesebb lesz. Itt is fontos megjegyezni, hogy az elsőfajú hiba csökkenése a másodfajú hiba növekedésével jár és viszont. A velük kapcsolatos statisztikai eljárások döntési kritériumainak egyik fontos célja, hogy egyik se kerüljön túlsúlyba a másik rovására.

4. Alkalmazzuk a módszert a feladatra!

A feladat megoldásához szükséges paraméterek értékei a következők:

$$P = 30 \% = 0,3$$

$$p = 47 \% = 0,47$$

$$n = 5 * 31 = 155 \text{ (azaz 5 év júliusi napjainak a száma)}$$

E kiindulási paraméterek ismeretében helyettesítsünk be σ_p képletébe!

$$\sigma_p = \sqrt{\frac{p(1-p)}{n}} = \sqrt{\frac{0,47(1-0,47)}{155}} = 0,04$$

Ezután válasszuk az 5 %-os valószínűségi szintet, s határozzuk meg a konfidencia-intervallum végpontjait!

$$P_1 = p - d * \sigma_p = 0,47 - 1,96 * 0,04 = 0,39$$

$$P_2 = p + d * \sigma_p = 0,47 + 1,96 * 0,04 = 0,55$$

Innen azt kapjuk, hogy $P = 0,3$ $[P_1; P_2] = [0,39; 0,55]$.

5. Válaszoljunk a feladatra!

Tehát a megfigyelőhelyen a déli órában jelentősen megnő a tó felőli szélirány.

Hivatkozás

Péczely, Gy., 1979: Éghajlattan. Budapest: Tankönyvkiadó, 336 pp