

Adatok rendezése és "első" elemzése


(Az adatgyűjtés fogalmát, lehetőségeit és a minta elemek számát, összetételét rit. nem foglalkozunk.)

kiinduló probléma: adott egy adatsor (minta) és ezrekből kéne mintánál többet megtudni.

$x_1, x_2, \dots, x_n$ n elemű adatsor Azet: keres küll. értéket van

1. lépés: Hogyan helyezkednek el a ndmepensek?

$x_{min}, x_{max}, R := x_{max} - x_{min}$ meghat. a
(adatsor szélessége)



2. lépés: rendezett minta meghat. a: $x_1^* \leq x_2^* \leq \dots \leq x_n^*$

3. lépés: 1. táblázat ellenőrzése:

i	x_i^*	H_i (abs. gyak.)	$h_i = \frac{H_i}{n}$ (rel. gyak.)	$\sum_{j=1}^i h_j$ (összetett rel. gyak.)
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
K				
		$\sum_{i=1}^K H_i = n$	$\sum_{i=1}^K h_i = 1$	

(K ~ a küll. mintaelemek ndme)

4. lépés: a kvantilis meghat. a: $x_{0.25}, x_{0.5} = Me, x_{0.75}$
alsó kvantilis median felső kvantilis

$x_p := x_{p(n+1)}$ ha $p \cdot (n+1)$ egész ndm $(0 < p < 1)$ p -kvantilis
 $x_p := \frac{1}{2} [x_{[p(n+1)]} + x_{[p(n+1)]+1}]$ ha $p \cdot (n+1)$ nem egész

$D =$ módusz meghat. a: (lehet több is) D ~ a legnagyobb gyakoriságú adat

öt-ndmes ömepés: $x_{min}, x_{0.25}, Me, x_{0.75}, D$ mepedése

Jddr van fogelmunk arról, hogy az $[x_{min}, x_{max}]$ int. kon hogyan helyezkednek el a mintaelemek.

5. lépés: empirikus sűrűség-és elenés fr. 2 felrajzolsa az 1. tábl. seg. vel
(histogram)



Tördeli jellemzők meghatározása

2

középérték (által., számítási útmutató)

$$\bar{X} = \frac{\sum_{i=1}^n x_i}{n}$$

(az 1. tábl. segítségével)

A feladatokra javasolt feleletel típusai

1. Pl. $x_{min}, x_{max}, R, D, x_{0.25}, M_e, x_{0.75} = ?$
 1. tábl. -t adja meg $\bar{X} = ?$ (rajzolja le ezeket a négyeseket!)
 rajzolja fel az empirikus sűrűség és eloszlás f. 2. lépés!

10
 [a] 1, 3, 3, 3, 3, 4, 2, 3, 4, 3, 4, 2, 3, 1, 4, 1, 3, 2, 3, 2, 2, 5, 3, 1, 2, 4, 2, 2, 4, 1, 4, 1, 2, 2, 3, 3, 2, 4, 3, 3, 4, 5, 1, 1, 5, 4, 2, 5 (stat. vizsgálattal)

b) 4, 1, 4, 4, 1, 2, 2, 3, 5, 1, 4, 5, 5, 4, 5, 2, 4, 2, 1, 3, 2, 2, 2, 5, 5, 1, 1, 4, 3, 2, 4, 1, 5, 2, 3, 4, 4, 1, 2, 2, 3, 4, 4, 1, 4, 2, 3, 5, 1, 4, 2, 2, 3, 5, 2, 3 (hol van az adatok fele?)

c) en naplalda-csapat tagjai magassága (cm)
 183, 181, 183, 180, 182, 182, 185, 182, 184, 179, 182, 184, 180, 181, 179, 180, 182, 180, 181, 183

d) en telefonfülle kihívásokról (naponta hívások száma)
 1, 1, 2, 0, 6, 4, 3, 1, 1, 0, 0, 3, 4, 3, 2, 2, 1, 1, 2, 3, 3, 0, 0, 0, 4, 3, 2, 1, 2, 6, 3, 3, 3, 0, 4, 1, 2, 2, 6, 2, 2

(csapat-e, h. min 4 edzővel van 60%-on?)

e) en is élelmiszerboltban naponta eladott friss liter tej ad. számai


3, 4, 0, 0, 2, 3, 3, 1, 2, 2, 2, 5, 4, 5, 7, 7, 8, 8, 3, 3, 6, 7, 3, 2, 1, 7, 5, 5, 4, 1, 3, 8, 7, 5, 5, 4, 3, 3, 4, 4, 3, 3, 3, 2, 5, 5, 4, 3, 3, 3, 3, 4, 8, 7, 7, 5, 4, 1, 1, 3, 0, 0, 1, 0, 0, 4, 3, 2, 1, 2, 1, 4, 0, 0, 1, 1, 1, 1, 5, 0, 1, 0, 2, 2, 3, 1, 3, 6, 6, 7, 6, 3, 4, 3, 2, 3, 1, 5, 3, 3, 2

(arab 4-es meg a friss tej átlagát, ha a napi legkevesebb 70%-on min 2 db-t el tud adni. Jelen-e?)

(A) eset, (sok adat, de előbb keres a kih. értéke (≤ 10))

Box-plot elnevezése (kiugró vagy hibás adatok vizsgálata, kiemelése)

Mire jó még: a minta vizuális megjelölése
kih. minták vizuális összehasonlítása



elnevezés:

kvartil távolság:

$$[x_{0.75} - x_{0.25}] = IQR$$

(lehet vizuálisan is ábrázolni!)

1. Pl. / b) (1. szim.) kétszűrű el a Box-plot elnevezés!

$$\text{legnagyobb normál adat} \leq x_{0.75} + 1.5(x_{0.75} - x_{0.25}) = 4 + 1.5 \cdot (4 - 2) = 4 + 3 = 7$$

a legnagyobb normál adat, amely ≤ 7 az (5)

$$\text{legrisebb normál adat} \geq 2 - 1.5 \cdot 2 = 2 - 3 = -1$$

a legrisebb normál adat, amely ≥ -1 az (1)

extrem kis adatok
-55 -42

legrisebb normál adat
1 2 3 4 5
 $x_{0.25}$ $x_{0.5}$ $x_{0.75}$

legnagyobb normál adat

extrem nagy adatok
44 51 351


4.

(Ifh.) as ontdekt opged' homaar

1. lépés: ontddlyos megfigat-a, K megadés-a

$a \leq x_{\min}$, $b \geq x_{\max}$, a, b értékeit úgy választjuk meg, hogy $\left(\frac{b-a}{K}\right)$

"Eppsen" entel legen



(K=4 seton)

az ontdlyl ontdpontjai : $a_0 := a \leq x_{\min}$

$$a_k := b \geq x_{\max}$$

$$[a_{i-1}, a_i) \sim i, \text{ oddly}$$

$$i=1, \dots, K$$

$i = 1, \dots, K$

Minden adottat, amely az i ontalysa bil az u.n. ontalysközpelpel: u_i

Értékel helyettesítéim. Így ármavezettük a (B) szet az (A) szet.

Tekst a tondbilarnan at (u_i) ontally köpettel ndmoluul.



(keves szil. érték) Előhagyjuk az onddiápropeket a rendezett mintától.

Az 1. táblázat ellen az esetben:

i	ontdlyer $[a_i, a_{i-1})$	ontdlyözép u_i	gratoniszap (H_i)	rel-grat. (h_i)	ömegzett rel-grat. $\sum_{j=1}^i h_j$

A tabláskabel mephatdrozhetó : alsó-, felső kvartilis, medián, módusz, átlag
 érdekelt az osztályközepesek számával

A tapasztolati műveltség- és előkészítő képzés az orvostudományok területén



3. ea. középértékek és az ingadozás mérése

5.

Középérték (helyetnumbó)

átlagos

① $\bar{X} = \frac{1}{n} \sum_{i=1}^n x_i$
számítási közép

② $\bar{X}_g \sim$ geometriai közép

$$\bar{X}_g = \sqrt[n]{x_1 \cdot x_2 \cdot \dots \cdot x_n}$$

③ $\bar{X}_h \sim$ harmonikus közép

$$\bar{X}_h = \frac{n}{\sum_{i=1}^n \frac{1}{x_i}}$$

④ $\bar{X}_q \sim$ négyzetes közép

$$\bar{X}_q = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}$$

helyzeti középérték

M_e, D
(extra adatokra érzéketlen)

érdekes a nagyon kis értékre
amikor hánldjuk, ha az érték szorosa értelmezhető
ill. ha az átlag-számítás érték exponenciálisan
növel vagy csökken (pl. relatív változások
átlagosát)

érdekes a nagyon kis értékre
amikor hánldjuk, ha az érték reciprokainak
össze számításához
(főleg index számítás esetén)

érdekes a nagyon nagy értékre
amikor hánldjuk, ha lehetne pos. és neg.
érték is, de az érték abszolút nagysága
értékes

Egy adott mintánál az átlagok közötti nagyságrendi sorrend:

$$x_{\min} < \bar{X}_h < \bar{X}_g < \bar{X} < \bar{X}_q < x_{\max}$$

(feltéve, hogy nem 0-adat)
azonos

1. pp. Egy kereskedő cég a forgalmát évente növelni tudta az

(ea-n) alábbiak szerint: (%-on mindig az előző évhez viszonyítva)

1990 → 1991	107%-ra
1991 → 1992	102%-ra
1992 → 1993	108%-ra
1993 → 1994	111%-ra
1994 → 1995	105%-ra

terhara az átlag évi növekedés és
az átlag évi növekedési ütem?

2. Egy kereskedőben mért a kereslet, az alábbi eredményeket kaptuk:

x_i	55	65	75	85	95	105	115	125
H_i	3	6	15	21	12	4	2	1
h_i	0,047	0,094	0,234	0,328	0,158	0,062	0,031	0,016

$$N = 64$$

$$\bar{X}, \bar{X}_g, \bar{X}_h, \bar{X}_q = ?$$

$$M_e, D = ? \quad \text{elválasztás!}$$

⑥

$$\overline{x}, \overline{x_g}, \overline{x_h}, \overline{x_q} = ?$$

$$\mu_{\mathbb{D}} = ?$$

① terjedelem: $R := X_{\max} - X_{\min}$ (adatszélesség)

③ dtops absolut eltér: $\Delta := \frac{1}{n} \sum_{i=1}^n |x_i - \bar{x}|$ (rözpeltés)

$$\text{Var}^{\text{rel}} = \sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \quad (\text{empirische Varianz})$$

⑥ relative no. of $v = \frac{\sigma}{x}$ (or % length $v = \frac{\sigma}{x} \cdot 100\%$)
(tapantolati raddus epittthet)

$$- \left[\sigma^2 = \left(\frac{1}{n} \sum_{i=1}^n x_i^2 \right) - \bar{x}^2 \right] = \overline{x^2} - \bar{x}^2$$

R	
1QT	
Δ	
σ_n	
σ_n^*	
V	

$x_i^* H_i$	H_i	$(x_i - \bar{x})$	$(x_i - \bar{x})^2$	$(x_i - \bar{x})^2 \cdot H_i$

$\sum_{i=1}^n (x_i - \bar{x})^2 \cdot H_i = n \cdot s^2$


$\bar{x} = \frac{1}{n} \sum x_i$

ellbl ndmelyur $\sigma \rightarrow t$ & $\sigma^* t$,
 & $v-t$

4. eo Alakmutatószámok: aszimmetria jellemző mutatói
lepultság


Probléma, Adott adatok/minta esetén először is az empirikus sűrűségfüggvény képe.
 Az lenne a "várható", ha az $\bar{x}$ körül szimmetria legyen, azaz "normális".

Az u.n. normális eloszlás sűrűségfüggvénye a Gauss-féle hengerpólya leghíresebb példája.



Ezzel hasonlítjuk az adott adatokhoz kapott empirikus sűrűségfüggvényt.


1. kérdés Milyen lehet az empirikus sűrűségfüggvény szimmetria szempontjából?
 egymódú
 szimmetrikus
 aszimmetrikus
 többmódú
 U-alakú
 M-alakú




aszimmetrikus

merőlejtű

balra elhúzó




jobbra elhúzó




erősen

J-alakú


fordított J-alakú




2. kérdés Milyen lehet az empirikus sűrűségfüggvény lapultság/nyúvottság szempontjából?



erős



(lapult)lapos



A fenti adatok leírásánál segítene az u.n. alakmutató számok

Aszimmetria - mérőszámok egymódú sűrűségfüggvény esetén

a) Ha f szimmetrikus $\Rightarrow \bar{x} = D = Me$

b) Milyen a jó mérőszám? $\leftarrow$ dimenzió nélküli
 szimmetrikus esetben 0

$$1) \tilde{F} = \frac{(x_{0,75} - Me) - (Me - x_{0,25})}{(x_{0,75} - Me) + (Me - x_{0,25})}$$

a fél- és alsó kvantilis mediánból mért távolságai különbségének és összegének a hányadosa

All. $-1 \leq \tilde{F} \leq 1$ ha $ \tilde{F} > 0,3 \Rightarrow$ nemtörőd a közép	ha f norm. $\Rightarrow \tilde{F} = 0$ ha f balra elhúzó $\Rightarrow \tilde{F} < 0$ ha f jobbra $\Rightarrow \tilde{F} > 0$
---	--

2) Pearson-index: $P := \frac{\bar{x} - Me}{\sigma}$

All. he f. szim. $\Rightarrow P = 0$

he f. balra elnyúló $\Rightarrow P < 0$

he f. jobbra " $\Rightarrow P > 0$

p-nel $\neq$ köldtja, de he $|P| > 1 \Rightarrow$ erős az aszimmetria

3) ferdeség: $\gamma := \frac{\beta_3}{\sigma^3}$, ahol $\beta_3 := \frac{\left(\sum_{i=1}^n (x_i - \bar{x})^3\right) \frac{1}{n}}{\sqrt{\left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2\right)^3}}$

$\left[\beta_3 := \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3 \right]$
n.n. centrális harmadik momentum

(ahol $\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$)

All. he f. szim. $\Rightarrow \gamma = 0$

he f. balra elnyúló $\Rightarrow \gamma < 0$

he f. jobbra " $\Rightarrow \gamma > 0$

III A minisérp. mesederségi mérőszáma: Gesz,

$Gesz := \frac{\beta_4}{\sigma^4} - 3$

$\left(\beta_4 := \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4 \right)$

centrális 4. momentum

All. he $Gesz = 0 \Rightarrow$ "normális" v. töreps mesederségi"

he $Gesz < 0 \Rightarrow$ lapultabb (a normálisnál)

he $Gesz > 0 \Rightarrow$ túlszórabb (a normálisnál)

Az alábbiakban nézzük a 3. tábl. szerint számoltakat:

i	x_i	H_i	$x_i - \bar{x}$	$(x_i - \bar{x})^2 \cdot H_i$	$(x_i - \bar{x})^3 \cdot H_i$	$(x_i - \bar{x})^4 \cdot H_i$
		$\bar{x}$	σ^2		β_3	β_4
p			γ		$Gesz$	

PP.

1. adatsor

leadási határidő: 2. előadás

1, 3, 3, 3, 3, 4, 2, 3, 4, 4, 3, 4, 2, 3, 1, 4, 1, 3, 2, 2, 3, 2, 2, 5, 3, 1, 2, 4, 2, 2, 4, 1, 4, 1, 2, 2, 3, 3, 2, 4, 3, 3, 4, 5, 1, 1, 5, 4, 2, 5 (n=50)

a) $x_{\min} = ?$, $x_{\max} = ?$, $R = ?$

b) írja fel a rendezett mintát! $x_{0,25} = ?$, $x_{0,5} = ?$, $x_{0,75} = ?$, kvartil-ból számolva

c) készítse el az 1. táblázatot:

i	érték: x_i	abszolút gyak.	relatív gyak.	összegzett rel. gyak.
		H_i	h_i	$\sum_{j=1}^i h_j$

d) rajzolja fel a rel. gyak. i-polygont (=tápnézetű sűrűségfüv.-t)
histogramot!

e) rajzolja fel az összegzett rel. gyak. i-polygont (=tápnézetű eloszlásfüv.-t)
histogramot!

f) $\bar{x} = ?$, $Me = ?$, $D = ?$

2. adatsor (Hozd. vizsgán elért ömportörtem: 0,60)

18, 16, 25, 21, 18, 46, 24, 27, 23, 10
11, 10, 29, 17, 21, 19, 17, 18, 28, 31
14, 46, 21, 18, 23, 11, 42, 39, 19, 30
43, 14, 29, 16, 35, 21, 12, 28, 14, 32
51, 7, 42, 24, 21, 18, 37, 25, 33, 25

a) $n = ?$, $R = ?$, $x_{\min} = ?$, $x_{\max} = ?$

b) adjon meg egy $[a, b]$ intervallust, úgy, hogy
minden adat benne legyen és $\frac{b-a}{5}$
köznyelven értelmezhető legyen!

c) omé $[a, b]$ -t 5 egyenlő részre osztva

leljen az osztályok. Adja meg az osztályközöspontot és részlete el az 1. tábl.

d) $u_{\min} = ?$, $u_{\max} = ?$, $R_u = ?$

$u_{0,25} = ?$, $u_{0,75} = ?$, $Me_u = u_{0,5} = ?$

e) Rajzolja fel a tápnézetű sűrűség- és eloszlásfüv.-t!

3. adatsor

4, 1, 44, 1, 2, 2, 35, 6, 4, 5, 5, 4, 5, 2, 4, 2, 1, 3, 2, 2, 2, -55, 1, 1, 4, 3, 2, 4, 1, 5, 2, 3, 4, 4, 1,
2, 2, 3, 4, 4, 1, -42, 3, 51, 4, 2, 2, 3, 5, 2, 3

a) $x_{\min}$, $x_{\max}$, R , $\bar{x}$, D , Me

b) készítse el a Box-Plot ábrát!


Minden példában adja meg
 Δ , σ , $\bar{x}$ és $q_{0,25}$ értékeit is!

$$x_{0125} = x_{13}^*$$

$$H_e = x_{015} = \frac{x_{25}^* + x_{26}^*}{2}$$

$$x_{0175} = x_{37}^*$$

$$\frac{1}{4} : \frac{3}{4}$$



$$x_{925} = f \cdot \frac{(n+1)}{4}$$

$$x_{015} = \frac{n+1}{4} \cdot 2$$

$$x_{0175} = \frac{n+1}{4} \cdot 3$$

$$\frac{51}{4} = 12,8$$

$$x_{925} = \frac{x_{12}^* + x_{13}^*}{2}$$

$$p : (1-p)$$

x_{0125} -nél $\frac{1}{4}$ iselt adatok és $\frac{3}{4}$ nemelt adatok aránya: 1 : 3
 x_{0175} -nél $\frac{1}{4}$ iselt adatok és $\frac{3}{4}$ nemelt adatok aránya: 1 : 3
 x_{925} -nél $\frac{1}{4}$ iselt adatok és $\frac{3}{4}$ nemelt adatok aránya: 1 : 3

1 : 1