

Kovácsné Székely Iлона*

CSATLAKOZÁSI PONTOK
A VALÓSZÍNŰÉGSZÁMÍTÁS ÉS A STATISZTIKA OKTATÁSÁBAN

A statisztika alapfogalmainak és módszereinek megértése és helyes alkalmazása elképzelhetetlen valószínűségyszámítási alapok nélkül. Bemutatásra kerül egy pár fogalom, amelyet a hallgatók nehezen értenek meg és / vagy rosszul alkalmaznak. Tekintsünk ehhez néhány példát.

A minta és a minta realizáció fogalmát a hallgató gyakran azonosnak tekinti.

A statisztikai minta az X valószínűségi változóra vonatkozó véges számú független megfigyelés eredménye $X=(X_1, X_2, \dots, X_n)$, ahol X_i -k független, azonos eloszlású valószínűségi változók.

A minta realizációja a megfigyelések számszerűsített értékei: (x_1, x_2, \dots, x_n)

Példa: Jelölje X 10 légitársaság gépeivel Budapestre érkező utasok számát (ezer fő) 2002-ben. Megadjuk a 10 elemű minta realizációját:

$X_1=42,5$ $X_2=31,6$ $X_3=34,9$ $X_4=32,0$ $X_5=72,6$
 $X_6=48,8$ $X_7=21,3$ $X_8=57,4$ $X_9=110,5$ $X_{10}=17,4$

A minta elemei, a valószínűségi változók számértékeket vesznek fel. Ezek az értékek változnak mintáról mintára. A minta függvényei is valószínűségi változók: mintaátlag, szórás, mintabeli arány, tapasztalati sűrűség- és eloszlásfüggvény stb.

A centrális határeloszlás tétel fontos alkalmazást nyer a matematikai statisztikában.

A CENTRÁLIS HATÁRELOSZLÁS TÉTELE

Ha X_1, X_2, \dots, X_n azonos eloszlású, független és véges szórású valószínűségi változók, $E(X_i)=m$, $D(X_i)=\sigma$ ($i=1,2,\dots,n$) akkor

$$\lim_{n \rightarrow \infty} P \left(\frac{\sum_{i=1}^n X_i - n \cdot m}{\sigma \cdot \sqrt{n}} < x \right) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{u^2}{2}} du$$

A MINTAKÖZÉP ELOSZLÁSA

Legyen X valószínűségi változó várható értéke $E(X)=m$ és szórása $D(X)=\sigma$. X -re vonatkozó (X_1, X_2, \dots, X_n) mintából számított

* BGF KVIFK Módszertani Intézet, főiskolai adjunktus.

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

mintaközép közel normális eloszlású, ha az n mintanagyság elég nagy (centrális határeloszlás tétel), mégpedig $E(\bar{X}) = m$ és $D(\bar{X}) = \frac{\sigma}{\sqrt{n}}$.

Az \bar{X} mintaátlag paramétereinek kiszámítása:

$$E(\bar{X}) = E\left(\frac{\sum_{i=1}^n X_i}{n}\right) = \frac{1}{n} \sum_{i=1}^n E(X_i) = \frac{1}{n} \cdot n \cdot m = m$$

$$E(\bar{X}) = m$$

Az X_1, X_2, \dots, X_n valószínűségi változók függetlenek, így

$$D^2(\bar{X}) = D^2\left(\frac{\sum_{i=1}^n X_i}{n}\right) = \frac{1}{n^2} \sum_{i=1}^n D^2(X_i) = \frac{1}{n^2} \cdot n \cdot \sigma^2 = \frac{\sigma^2}{n}$$

$$D(\bar{X}) = \frac{\sigma}{\sqrt{n}}$$

A normális eloszláson sok statisztikai próba alapszik. A normális eloszlással kapcsolatos számításokat a standard eloszlás táblázatával tudjuk elvégezni, amihez a változók standardizálására van szükség. Például a hipotézisvizsgálat során használt z -próbafüggvény eloszlása standard normális eloszlású. Az \bar{X} változót standardizáljuk: $Z = \frac{\bar{X} - m}{\frac{\sigma}{\sqrt{n}}}$

A Z változó paramétereinek kiszámítása:

$$E(Z) = E\left(\frac{\bar{X} - m}{\frac{\sigma}{\sqrt{n}}}\right) = \frac{m - m}{\frac{\sigma}{\sqrt{n}}} = 0$$

$$D^2\left(\frac{\bar{X} - m}{\frac{\sigma}{\sqrt{n}}}\right) = \frac{\frac{\sigma^2}{n}}{\frac{\sigma^2}{n}} = 1$$

A FÜGGETLENSÉG ÉS KORRELÁTLANSÁG FOGALMA

Ha X és Y valószínűségi változók **függetlenek**, akkor $\rho(X, Y) = 0$

$$\rho(X, Y) = \frac{E(X \cdot Y) - E(X) \cdot E(Y)}{D(X) \cdot D(Y)} = \frac{E(X)E(Y) - E(X) \cdot E(Y)}{D(X) \cdot D(Y)} = 0$$

Példával szemléltetem a következő állítást: **ha a korrelációs együttható $\rho = 0$ akkor X és Y valószínűségi változók általában nem függetlenek, ilyenkor korrelátlanoknak mondjuk.**

KÜLKERESKEDELMI FŐISKOLAI FÜZETEK, 13.

Példa

Az (X, Y) vektorvalószínűségi változó egyenletesen veszi fel az $(1, 1)$ $(1, 0)$ $(0, 1)$ $(1, 2)$ értékeket.

- a) Független-e X és Y valószínűségi változó?
 b) Határozzuk meg $\rho(X, Y)$ korrelációs együttható értékét!

Megoldás:

Meghatározzuk az (X, Y) vektorvalószínűségi változó együttes eloszlását (r_{ij}) és peremeloszlásait (p_i ; q_j):

X/Y	0	1	2	$p_i = \sum_j r_{ij}$
0	0	0,2	0	0,25
1	0,25	0,25	0,25	0,75
$q_j = \sum_i r_{ij}$	0,25	0,50	0,25	1

a) $P(X=0, Y=0)=0 \neq P(X=0) \cdot P(Y=0)=0,25 \cdot 0,25 \Rightarrow X$ és Y valószínűségi változók **nem függetlenek.**

b) $E(X)=0,75$ $E(X^2)=0,75$ $D^2(X)=0,75-0,75^2=0,1875$
 $E(Y)=1$ $E(Y^2)=1,5$ $D^2(Y)=1,5-1=0,5$
 $E(X \cdot Y)=0,75$

$$\rho(X, Y) = \frac{E(X \cdot Y) - E(X) \cdot E(Y)}{\sqrt{D(X) \cdot D(Y)}} = \frac{0,75 - 0,75 \cdot 1}{\sqrt{0,1875 \cdot 0,5}} = 0$$

X és Y valószínűségi változók **korrelálatlanok.**

Igen fontos tulajdonsága azonban a síkbeli normális eloszlásnak: a kétdimenziós normális eloszlás esetén, ha a változók korrelálatlanok, akkor függetlenek is.

Az (X, Y) vektorvalószínűségi változó normális eloszlású, ha sűrűségfüggvénye:

$$h(x, y) = \frac{1}{2\pi \sigma_1 \sigma_2 \sqrt{1-\rho^2}} \exp \left\{ -\frac{1}{2(1-\rho^2)} \left[\frac{(x-m_1)^2}{\sigma_1^2} - 2\rho \frac{(x-m_1)(y-m_2)}{\sigma_1 \sigma_2} + \frac{(y-m_2)^2}{\sigma_2^2} \right] \right\}$$

$E(X)=m_1$, $E(Y)=m_2$, $D(X)=\sigma_1$, $D(Y)=\sigma_2$, $D(X)=\sigma_1$, ρ a korrelációs együttható. Ha $\rho=0$ vagyis az X és Y változók korrelálatlanok, akkor

$$h(x, y) = \frac{1}{\sigma_1 \sqrt{2\pi}} \exp \left\{ -\frac{(x-m_1)^2}{2\sigma_1^2} \right\} \cdot \frac{1}{\sigma_2 \sqrt{2\pi}} \exp \left\{ -\frac{(y-m_2)^2}{2\sigma_2^2} \right\}$$

$h(x, y)=f(x)g(y)$, ez pedig éppen az X és Y valószínűségi változók függetlenségét jelenti. Vegyük észre, hogy a síkbeli normális eloszlás peremeloszlásai egydimenziós normális eloszlásúak általában is. $X \sim N(m_1, \sigma_1)$ és $Y \sim N(m_2, \sigma_2)$.

KOVÁCSNÉ SZÉKELY I.: CSATLAKOZÁSI PONTOK ...

A kétdimenziós normális eloszlás esetén a regressziós függvény lineáris.

$$Y = m_2 + \rho \frac{\sigma_2}{\sigma_1} (X - m_1)$$

Az Y valószínűségi változó $X=x$ -re vonatkozó feltételes várható értéke meghatározható a feltételes sűrűségfüggvényből, amely szintén normális eloszlású.

A regressziós függvény az $E(Y-g(x))^2 \rightarrow \min$ feladat megoldása, ahol $g(x)=E(Y | X = x)$ az Y valószínűségi változó X -re vonatkozó feltételes várható értéke. Y valószínűségi változó X -re vonatkozó feltételes sűrűségfüggvénye meghatározható:

$$g(y|x) = \frac{h(x,y)}{f(x)} = \frac{1}{\sigma_2 \sqrt{2\pi} \cdot \sqrt{1-\rho^2}} \exp \left\{ -\frac{1}{2 \sigma_2^2 \cdot (1-\rho^2)} \left[Y - \left(m_2 + \rho \frac{\sigma_2}{\sigma_1} (X - m_1) \right) \right]^2 \right\}$$

$$E(Y|X=x) = m_2 + \rho \frac{\sigma_2}{\sigma_1} (X - m_1)$$

Ez a pár példa is jól bizonyítja, hogy a statisztikai módszerek megértésének alapvető feltétele a valószínűségszámítás alapfogalmainak ismerete.