

Valószínűségszámítás előadás informatika BSC/A szakosoknak



2019/2020 2. félév

Zempléni András

zempleni@caesar.elte.hu

<http://zempleni.elte.hu>



Generátorfüggvény

- Legyen X nemnegatív egész értékű valószínűségi változó. A generátorfüggvénye
$$g_X(z) := E(z^X) = P(X=0) + zP(X=1) + z^2P(X=2) + \dots$$
- Tulajdonságai:
 - Véges, ha $|z| \leq 1$
 - Meghatározza az X eloszlását:
 - $P(X=0) = g_X(0)$
 - $P(X=1) = g_X'(0)$
 - $P(X=2) = g_X''(0)/2$ stb.
 - Ha X és Y függetlenek, nemnegatív egész értékűek: $g_{X+Y}(z) = g_X(z)g_Y(z)$, mert $E(z^{X+Y}) = E(z^X z^Y) = E(z^X) E(z^Y)$ a függetlenség miatt.



Példák

- Elfajult eloszlásra ($P(X=k)=1$): $g_X(z) = z^k$.
- Indikátorváltozóra $g_X(z) = pz + 1 - p$
- Binomiális eloszlásra $g_X(z) = (pz + 1 - p)^n$
- Poisson eloszlásra

$$E(z^X) = \sum_{k=0}^{\infty} z^k \frac{\lambda^k e^{-\lambda}}{k!} = e^{-\lambda} e^{\lambda z} = e^{\lambda(z-1)}$$



Karakterisztikus függvény

- Komplex értékű valószínűségi változók: $Z=X+iY$, ahol X és Y is valószínűségi változók.
- $E(Z):=E(X)+iE(Y)$.
- X (valós) valószínűségi változó karakterisztikus függvénye: $\varphi_X(t):=E(e^{itX})=E(\cos tX)+iE(\sin tX)$
- Tulajdonságai:
 - $\varphi_X(t)$ $\mathbf{R} \rightarrow \mathbf{C}$ függvény, mely minden X -re létezik.
 - $\varphi_X(0)=1$ minden X -re
 - $|\varphi_X(t)| \leq 1$ (mert $|E(e^{itX})| \leq E(|e^{itX}|)=1$)
 - Ha X és Y függetlenek, $\varphi_{X+Y}(t)=\varphi_X(t)\varphi_Y(t)$, mert $E(e^{it(X+Y)})=E(e^{itX}e^{itY})=E(e^{itX})E(e^{itY})$ a függetlenség miatt.



További tulajdonságok

- Ha $Y=aX+b$, akkor $\varphi_Y(t) = e^{ibt}\varphi_X(at)$
- Bizonyítás: $\varphi_Y(t) = E(e^{i(aX+b)t}) = e^{ibt} E(e^{iaXt}) = e^{ibt}\varphi_X(at)$.
- Kiszámítása az abszolút folytonos esetre:

$$\varphi_X(t) = \int_{-\infty}^{\infty} e^{itx} f(x) dx = \int_{-\infty}^{\infty} \cos(tx) f(x) dx + i \int_{-\infty}^{\infty} \sin(tx) f(x) dx$$

- Példa. Ha X egyenletes eloszlású a $[-1,1]$ intervallumon, akkor

$$\varphi_X(t) = \int_{-\infty}^{\infty} e^{itx} f(x) dx = \int_{-1}^1 \frac{\cos(tx)}{2} dx = \left[\frac{\sin tx}{2t} \right]_{-1}^1 = \frac{\sin t}{t}$$

- Általában is: φ_X valós, ha X eloszlása szimmetrikus a 0-ra.



További tulajdonságok/2

- A standard normális eloszlás karakterisztikus függvénye:

$$\varphi(t) = e^{-\frac{t^2}{2}}$$

- A karakterisztikus függvény meghatározza az eloszlást (azaz különböző eloszlásokhoz különböző karakterisztikus függvény tartozik).
- Taylor sorfejtés: tegyük fel, hogy $E(X^n)$ véges valamilyen $n \geq 1$ egész számra. Ekkor $t \rightarrow 0$ mellett

$$\varphi_X(t) = 1 + \frac{it}{1!} E(X) + \frac{(it)^2}{2!} E(X^2) + \dots + \frac{(it)^n}{n!} E(X^n) + o(t^n)$$

ahol $o(t^n)$ jelentése, hogy t^n -nel osztva is 0-hoz tart, ha $t \rightarrow 0$.



További tételek

Azaz $\varphi_X^{(k)}(0) = i^k E(X^k)$ és így a szokásos Taylor-sorfejtésből adódik a tétel.

- Ha φ karakterisztikus függvény, akkor egyenletesen folytonos.
- *Folytonossági tétel.* Legyen φ_n karakterisztikus függvények egy sorozata (jelölje Q_n a hozzá tartozó eloszlást). Ha φ_n pontonként konvergál egy φ -hez, mely a 0-ban folytonos, akkor φ is karakterisztikus függvény, és a hozzá tartozó eloszlás éppen a eloszlások Q gyenge határértéke.



Centrális határeloszlás tétel

- Legyenek $X_1, X_2, \dots, X_n, \dots$ független, azonos eloszlású valószínűségi változók. Tegyük fel, hogy $\sigma^2 = D^2(X)$ véges ($m := E(X_j)$). Tekintsük a standardizált összegüket:

$$Z_n := \frac{X_1 + \dots + X_n - nm}{\sqrt{n}\sigma}$$

Ekkor Z_n gyengén konvergál a standard normális eloszláshoz, azaz

$$P\left(\frac{X_1 + \dots + X_n - nm}{\sqrt{n}\sigma} < z\right) \rightarrow \Phi(z)$$

ahol Φ a standard normális eloszlás eloszlásfüggvénye.



Bizonyítás vázlat

- A folytonossági tétel miatt elegendő a Z_n karakterisztikus függvényére belátni, hogy $\varphi_n(t) \rightarrow \exp\{-t^2/2\}$.
- Ha $\psi(t)$ jelöli az $X_n - m$ karakterisztikus függvényét, akkor $X_1 + X_2 + \dots + X_n - nm$ karakterisztikus függvénye $\psi^n(t)$. Ebből

$$\varphi_n(t) = \left(\psi\left(\frac{t}{\sigma\sqrt{n}}\right) \right)^n$$

- A maradéktagos Taylor formula miatt

$$\psi(t) = 1 + it \frac{E(X - m)}{1!} + i^2 t^2 \frac{E(X - m)^2}{2!} + o(t^2) = 1 - \frac{\sigma^2}{2} t^2 + o(t^2)$$



Bizonyítás befejezése

$$\varphi_n(t) = \left(\psi\left(\frac{t}{\sigma\sqrt{n}}\right) \right)^n = \left(1 - \frac{\sigma^2}{2} \left(\frac{t}{\sigma\sqrt{n}}\right)^2 + o\left(\frac{t}{\sigma\sqrt{n}}\right)^2 \right)^n = \left(1 - \frac{t^2}{2n} + \frac{1}{n} o(1) \right)^n \rightarrow e^{-\frac{t^2}{2}}$$

Megjegyzés. A tételt tulajdonképpen már megfigyeltük a szimulációknál.



A nem azonos eloszlású eset

- Ekkor – a nagy számok törvényénél már látott okok miatt – erősebb feltételek kellene.
- A legegyszerűbb eset: ha $X_1, X_2, \dots, X_n, \dots$ független, egyenletesen korlátos valószínűségi változók (ekkor $\sigma_i^2 = D^2(X_i)$ véges, $m_i := E(X_i)$), akkor a standardizált összegük:

$$Z_n := \frac{X_1 + \dots + X_n - (m_1 + \dots + m_n)}{\sqrt{\sigma_1^2 + \dots + \sigma_n^2}}$$

Ha $\sigma_1^2 + \sigma_2^2 + \dots + \sigma_n^2 \rightarrow \infty$ akkor Z_n gyengén konvergál a standard normális eloszláshoz, azaz

$$P(Z_n < z) \rightarrow \Phi(z)$$

ahol Φ a standard normális eloszlás eloszlásfüggvénye.



Általánosítások

- Ha nem korlátosak a tagok, további feltételekre (pl. magasabb momentumok létezése, hasonló nagyságrendű összeadandók) van szükség.
- Gyenge, a Bernstein tételben látott összefüggőség esetére is általánosítható a tétel.



Konvergenciasebesség

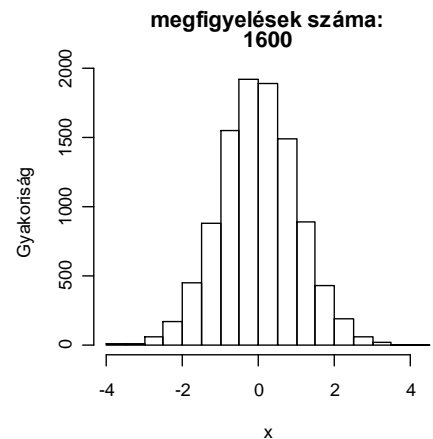



- Ha $X_1, X_2, \dots, X_n, \dots$ független, azonos eloszlású valószínűségi változók, t.f.h. $m=0, \sigma=1$, akkor

$$\sup_z \left| P\left(\frac{X_1 + \dots + X_n}{\sqrt{n}} < z\right) - \Phi(z) \right| \leq c \frac{E|X_1|^3}{\sqrt{n}}$$

- (Berry-Esséen tétel). $c=0,47$ a legjobb ismert érték.
- Gyakorlatban nagyon függ az eloszlás alakjától. Például az egyenletes eloszlásra $n=12$ elég jó közelítést ad, de az exponenciális eloszlásnál $n=50$ szükséges.

Centrális határeloszlás-tétel: független, azonos, egyenletes eloszlások standardizált összege ($n=25, 100, 400, 1600$)

Itt és a következő oldalakon az adott n számú véletlen számot generáltuk, standardizáltuk az összegüket, és ezt 10000-szor megismételtük minden esetben. Ezek után azt vizsgáltuk, hogy a kapott 10000 véletlen szám mennyire van közel a standard normális eloszláshoz.




Eloszlás illeszkedésének vizsgálata: Q-Q plot

A megfigyelt és az illesztett (G) eloszlás kvantiliseinek kétdimenziós ábrázolása. Eloszlásfüggvény q-kvantilise: az az érték, amelynél q valószínűséggel kapunk kisebbet: $G^{-1}(q)$

$$\left\{ \left(G^{-1}\left(\frac{k}{n+1}\right), X_k^{(n)} \right) : k = 1, 2, \dots, n \right\}$$

Q-Q plot, normális eloszlású mintára




Ha jó az illeszkedés, a pontok az átló közelében vannak

Eloszlás illeszkedésének vizsgálata: P-P plot





A megfigyelt és az illesztett eloszlás kétdimenziós ábrázolása

$$\left\{ \left(\frac{k}{n+1}, G(X_k^{(n)}) \right) : k = 1, 2, \dots, n \right\}$$

Ha jó az illeszkedés, a pontok az átló közelében vannak




Centrális határeloszlás-tétel: független, azonos, exponenciális eloszlások standardizált összege ($n=5,20,80,200$)



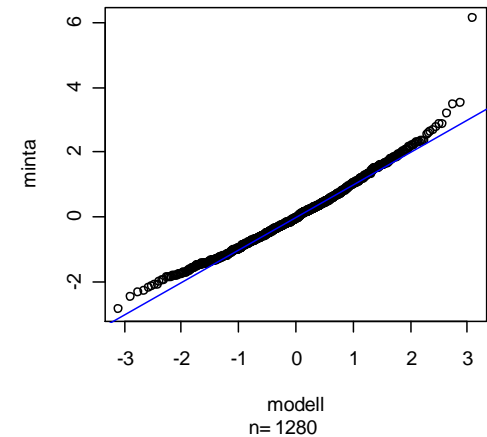
Centrális határeloszlás-tétel: független, azonos, Pareto ($k=3$) eloszlások standardizált összege ($n=80, 1280, 20000$)

Itt nagyon lassú a konvergencia

Q-Q plot, normalitásvizsgálatra



Q-Q plot, normalitásvizsgálatra



Q-Q plot, normalitásvizsgálatra

