

1 Cursul de teoria probabilităților an II

1.1 Lecția 1

Mă bazez pe faptul că s-a făcut deja un curs de Teoria măsurii. Deci se știe ce e (Ω, K, μ)

Așadar (Ω, K, P) este un spațiu cu o măsură specială, care are proprietatea că $P(\Omega) = 1$

Consecință: $P(A^c) = 1 - P(A)$.

Notez consecvent complementara cu un $^c : A^c = \Omega \setminus A$

Caracteristici ale unui spațiu probabilitizat - sau, poftim, câmp de probabilitate, accept și denumirea asta:

1. Ω este mulțimea evenimentelor elementare. Ele reprezintă mulțimea rezultatelor posibile ale unui experiment mental.

Exemple.

- arunc un zar de n ori: $\Omega = \mathbb{Z}_6^n$; dacă arunc n zaruri e la fel
- arunc o monedă de n ori: $\Omega = \mathbb{Z}_2^n$; dacă arunc n monede e la fel
- aștept pînă iese un 6 la aruncarea cu un zar: $\Omega = \mathbb{Z}_6^n$;
- se ia un număr întreg "la întâmplare": $\Omega = \mathbb{Z}$; dacă se iau n numere întregi atunci $\Omega = \mathbb{Z}^n$
- se ia un punct oarecare în plan/spațiu: $\Omega = \mathbb{R}^2/\mathbb{R}^3$
- se ia un arc de cerc la întâmplare: Ω este cercul trigonometric

2. K este σ -algebra evenimentelor. Un eveniment este o colecție de evenimente elementare. Dacă Ω este cel mult numărabil, este bine: atunci se ia $K = P(\Omega)$. Adică σ -algebra totală. Dacă nu, e mai complicat. Multe probabilități au proprietatea că $P(\{\varpi\}) = 0$ pentru orice $\varpi \in \Omega$. Astea nu se pot construi pe $P(\Omega)$ fiindcă este o teoremă a lui Ulam care spune că dacă o măsură pe $P(\Omega)$ neglijează toate punctele și Ω este nenumărabilă, atunci măsura e identic nulă. Exemplu tipic $\Omega = \mathbb{R}, K = B(\mathbb{R}) = \sigma(Top(\mathbb{R}))$, sau $\Omega = \mathbb{R}^n, K = B(\mathbb{R}^n) = \sigma(Top(\mathbb{R}^n)) = (B(\mathbb{R}))^{\otimes n}$ dar asta fără demonstrație)

3. Cea mai simplă probabilitate cu puțință este și cea mai simplă măsură cu puțință: este δ_a definită de $\delta_a(A) = 1_A(a)$

Fapt 31. Dacă $(P_n)_n$ sunt probabilități pe spațiul măsurabil (Ω, K) și dacă $p_n \geq 0$ au proprietatea că $\sum p_n = 1$, atunci $P := \sum_n p_n P_n$ este de asemenea probabilitate

Fapt 32. Deci dacă $(p_n)_n$ sunt ponderi de sumă 1, atunci $P = \sum_n p_n \delta_{x_n}$ este o probabilitate. Ea se numește **probabilitate discretă**.

Fapt 33. Dacă Ω este cel mult numărabilă, atunci toate probabilitățile pe $(\Omega, P(\Omega))$ sunt discrete.

Fapt 34. Dacă Ω este finită, atunci probabilitatea $P = \frac{\sum_{\varpi \in \Omega} \delta_{\varpi}}{|\Omega|}$ se numește probabilitatea clasică sau repartitia uniformă și se notează cu $U(\Omega)$. Așadar $U(\Omega)(A) = \frac{|A|}{|\Omega|} = \frac{\text{nr cazuri favorabile}}{\text{nr cazuri posibile}}$

Fapt 35. Dacă P, Q sunt două probabilități pe (Ω, K) atunci mulțimea $E = E(P, Q) := \{A \in K : P(A) = Q(A)\}$ satisface axiomele

(i) $\emptyset \in E$: (ii) $A \in E \implies A^c \in E$: (iii) $A_n \in E \forall n$ disjuncte $\implies \cup_n A_n \in E$

Seamăna cu axiomele σ -algebrei. O asemenea familie de mulțimi se numește U-sistem. Cum intersecția de U-sisteme este de asemenea un U-sistem, are sens să definim $U(M)$ ca fiind intersecția tuturor U-sistemelor care conțin familia de mulțimi $M \subset P(\Omega)$. Faptul de bază este

$$P|_M = Q|_M \implies P|_{U(M)} = Q|_{U(M)}$$

TEOREMĂ. Dacă M este stabil la intersecții finite, atunci $U(M) = \sigma(M)$

Fapt 36. JARGON. Dacă se zice: se ia un punct **la întâmplare** dintr-o mulțime finită se subînțelege că probabilitatea la care ne referim este cea uniformă. Dacă mulțimea este un compact din $\Omega \subset \mathbb{R}^n$ de măsură Lebesgue nenulă și finită se subînțelege că probabilitatea ca punctul să fie într-o mulțime boreliană A este egală cu $P(A) = \frac{\lambda^n(A \cap \Omega)}{\lambda^n(\Omega)}$; aici λ^n este măsura Lebesgue în $\mathbb{R}^n$. Dacă $n = 1$, ea se numește lungime; dacă $n=2$ se numește arie iar dacă $n=3$ se numește volum.

Pariu cinstit: $P(A) = \frac{1}{2}$; favorabil dacă $P(A) \geq \frac{1}{2}$; nefavorabil dacă $P(A) \leq \frac{1}{2}$

Exerciții.

1. Se aruncă un zar de 3 ori. Care e probabilitatea ca numerele să fie toate diferite? Să vină în ordine? să nu existe două numere vecine?

2. Un segment de lungime 1 se împarte la întâmplare în trei segmente. Care e probabilitatea ca ele să vină în ordine crescătoare? descrescătoare? să se poată forma cu ele un triunghi?

3. Se ia la întâmplare un număr de 3 cifre. Care e probabilitatea să fie par? divizibil cu 3? cu 4? dar ca să aibă cifrele puse în ordine crescătoare?

4. Se ia un număr natural la întâmplare. Care e probabilitatea să fie par (NONSENS!!)

1.2 Lecția 2. Variabile aleatoare

Fie (Ω, K) și $(E, \mathcal{E})$ două spații măsurabile. O funcție $X : \Omega \rightarrow E$ care este $K - E$ măsurabilă se numește variabilă aleatoare cu valori în E . Dacă scriem doar "variabilă aleatoare" fără alte epetete se subînțelege că $(E, \mathcal{E}) = (\mathbb{R}, \mathcal{B}(\mathbb{R}))$

Dacă $(E, \mathcal{E}) = (\mathbb{R}^n, \mathcal{B}(\mathbb{R}^n))$ spunem că X este un vector aleator n -dimensional. Dacă $n=2$ spunem că X este un punct aleator.

Proprietăți.

1. Dacă $(F, \mathcal{F})$ este un spațiu măsurabil, $X : \Omega \rightarrow E$ este o variabilă aleatoare și $f : E \rightarrow F$ este măsurabilă, atunci $f(X)$ este o variabilă aleatoare cu valori în F

2. Dacă X, Y sunt variabile aleatoare și $f : \mathbb{R}^2 \rightarrow \mathbb{R}$ este măsurabilă (de exemplu dacă e continuă) atunci $f(X, Y)$ este de asemenea variabilă aleatoare. Deci $X+Y, X-Y, XY, X/Y, \max(X, Y), \min(X, Y), 1_B(X)$ etc sunt toate variabile aleatoare

3. Fie $L(\Omega, K)$ mulțimea variabilelor aleatoare de pe spațiul măsurabil (Ω, K) . Atunci

(i) $L(\Omega, K)$ este o algebră de funcții reale care este și latice

(ii) Dacă $(X_n)_n$ este un șir de variabile aleatoare și $\liminf X_n \in R$ (respectiv $\limsup X_n \in R$) atunci $\liminf X_n$ este o variabilă aleatoare (respectiv $\limsup X_n$ este variabilă aleatoare).

4. X este un vector aleator n -dimensional dacă și numai dacă toate componentele sale X_k sunt variabile aleatoare

Repartiția unei variabile aleatoare. Deși mă enervează ff tare, în ultima vreme am ajuns să accept și denumirea "distribuția" în loc de "repartiția". Totuși, distribuție înseamnă altceva. Francezii fac diferența (repartiție = loi, rușii la fel, repartiție=raspredelenie, nemții la fel (verteilung), polonezii la fel (rozklad) iar românii de la ASE și politehnică s-au imbecilizat și zic distribuție.

Fie (Ω, K) și (E, E) două spații măsurabile și $X : \Omega \rightarrow E$ o variabilă aleatoare. Probabilitatea $P \circ X^{-1} : E \rightarrow [0, 1]$ definită prin $P \circ X^{-1}(B) = P(X^{-1}(B))$ se numește repartiția lui X .

1. Scopul suprem al teoriei probabilităților este să se găsească repartiția unei variabile aleatoare

2. Dacă discutăm de variabile aleatoare fără alte epitete, repartițiile lor sunt probabilități pe dreaptă. Mulțimea lor o notăm cu $\text{Pr}(\mathbb{R}, B(\mathbb{R}))$. În acest caz repartiția $P \circ X^{-1}$ o notăm cu F_X (mai aproape de notațiile internaționale). Deci $F_X(B) = P(X \in B)$. În loc să scriem $F_X((-\infty, x])$ scriem $F_X(x)$ și spunem că avem de a face cu **funcția de repartiție** a lui X . Cu puțină atenție **nu există pericol de confuzie**: Dacă $F \in \text{Pr}(\mathbb{R}, B(\mathbb{R}))$, atunci $F(x) := F((-\infty, x])$

3. Orice funcție $F : \mathbb{R} \rightarrow \mathbb{R}$ crescătoare, continuă la dreapta cu proprietatea că $F(-\infty) = 0, F(\infty) = 1$ este o funcție de repartiție. Adică există o probabilitate $\mu \in \text{Pr}(\mathbb{R}, B(\mathbb{R}))$ astfel ca $F(x) = \mu((-\infty, x])$ pt orice $x \in \mathbb{R}$ (demonstrația este cam lunguță - eu le-am zis că iese din teorema lui Caratheodory).

4. Reguli de calcul. $F((a, b]) = F(b) - F(a); F(\{a\}) = F(a) - F(a-0); F((a, b)) = F(b-0) - F(a); F((x, \infty)) = 1 - F(x) = \overline{F(x)} = \overline{F(x)}$ etc. Important pentru cultura generală: $\overline{F(x)}$ se numește **coda** sau **funcția de supraviețuire** și se notează de actuari cu ${}_x p_0$.

5. Două repartiții F și G coincid dacă și numai dacă $F(x) = G(x)$ pt orice x . Demonstrația e ușoară: $B(\mathbb{R}) = U(M)$ unde $M = \{(-\infty, x] : x \in \mathbb{R}\}$ este stabilă la intersecții finite.

Deci $F(x) = G(x)$ pt orice $x \implies F|_M = G|_M \implies F|_{U(M)} = G|_{U(M)} \implies F|_{\sigma(M)} = G|_{\sigma(M)} \implies F = G$

5. Dacă F_X este repartiție discretă, spunem că X este discretă; dacă funcție de repartiție F_X este continuă spunem că X este continuă. Orice repartiție $F \in \text{Pr}(\mathbb{R}, B(\mathbb{R}))$ se scrie unic sub forma $F = pF_c + qF_d$ unde $p, q \geq 0, p+q = 1, F_c$ este continuă și F_d este discretă. În vorbe: orice repartiție este o **mixtură** dintre una discretă și una continuă.

6. Dacă se poate scrie $F(x) = \int p1_{(-\infty, x]} d\lambda$ spunem că F este **absolut continuă**. O condiție suficientă este ca F să fie continuă și derivabilă pe porțiuni. Atunci $p = F'$. Un mod de a scrie acest lucru acceptat internațional este: $dF_X(x) = p(x) dx$.

7. Repartițiile didactice sunt sau discrete sau absolut continui. Cele clasice poartă câte un nume: uniformă, binomială, Poisson, etc
8. Ce e de făcut cînd se dă comanda "Să se calculeze repartiția lui X"?
81. În general încercăm să calculăm $P(X \leq x)$
82. Dacă X este discretă încercăm să calculăm $P(X = x)$
83. Dacă X este absolut continuă, încercăm să calculăm densitatea lui X .

9. **Cuantilele.** Se notează cu $F^{-1}(p)$. A nu se confunda cu inversa: de regulă o funcție de repartiție $\mathbb{R} \rightarrow [0, 1]$ NU este bijectivă.. Cuantila superioară $F^{-1+}(p) = \sup\{x : F(x) \leq p\}$; Cuantila inferioară $F^{-1-}(p) = \inf\{x : F(x) \geq p\}$

General: $x \in F^{-1}(p) \iff F(x-0) \leq p \leq F(x) \iff x \in [F^{-1-}(p), F^{-1+}(p)]$.
Cu excepția unei mulțimi cel mult numărabile de valori $p \in (0, 1)$ cuantila superioară coincide cu cea inferioară

10. **Simularea.** Dacă U este o variabilă aleatoare repartizată Uniform(0, 1) atunci $X = F^{-1}(U)$ este o variabilă aleatoare cu repartiția F . Adică $U \sim U(0, 1) \implies F^{-1}(U) \sim F$

11. **Predicție.** Ne asumăm un risc ε și vrem să prezicem un interval $I = (a, b]$ unde va fi variabila aleatoare care să aibă probabilitatea mai mare sau egală cu $1 - \varepsilon$. Acesta este un **interval de predicție de risc $\leq \varepsilon$** . Intervalul standard de risc ε este $I = (F^{-1}(\frac{\varepsilon}{2}), F^{-1}(1 - \frac{\varepsilon}{2})]$. Cu cât e mai scurt, cu atât e mai bun. De exemplu, dacă $X \sim \text{Exp}(1)$, atunci $F^{-1}(p) = -\ln(1-p) = \ln \frac{1}{1-p}$. Deci un interval de predicție de risc 1% este $I = (\ln \frac{1}{1-\frac{1}{200}}, \ln \frac{1}{1-\frac{1}{200}}] = (.00512, 5.2983]$

iar unul de risc 0.01% ar fi (.00005, 9.9035]

Exercitii 1. Schema bilei revenite ($\text{Bin}(n, p)$) ; schema bilei nerevenite ($\text{Hyper}(a, n, k)$) ; $\text{Poisson}(\lambda) = \lim_n \text{Bin}(n, \frac{\lambda}{n})$

2. $U \sim U(0, \frac{1}{\lambda}) \implies -\ln U \sim \text{Exp}(\lambda)$;

3. Reguli de lucru cu densități. Dacă $p = p_X$ este densitatea lui X atunci

$$p_{aX+b}(x) = \frac{1}{|a|} p\left(\frac{x-b}{a}\right) ; p_{X^2}(x) = \frac{1_{[0, \infty)}(x)}{2} (p(\sqrt{x}) + p(-\sqrt{x})) ; p_{e^X}(x) = \frac{1_{[0, \infty)}(x)}{x} p(\ln x) ; p_{\ln X}(x) = e^x p(e^x) \text{ etc}$$

4. Ceva drăguț. Fie $Y = \widehat{X} \pmod{k}$. Ce repartiție are Y ? Zicem $Y \sim \begin{pmatrix} 0 & 1 & 2 & 3 \\ P_0 & P_1 & P_2 & P_3 \end{pmatrix}$

Dacă $X \sim \text{Negbin}(1, p)$ sau Geometric(p) este foarte ușor. Cele k valori sunt descrescătoare la negbin, la geometric e un pic diferit. $P_0 = p(q^3 + q^7 + \dots) = \frac{pq^3}{1-q^4}$. $P_1 = \frac{p}{1-q^4}$, $P_2 = \frac{pq}{1-q^4}$, $P_3 = \frac{pq^2}{1-q^4}$. Cel mai probabil este 1. Dacă $X \sim \text{Bin}(n, p)$ e mai complicat: se face cu radacinile de ordin k ale unității $\varepsilon_j = \cos \frac{2j\pi}{k} + i \sin \frac{2j\pi}{k}$, $j = 0, 1, \dots, k-1$ și se speculează faptul că $\varepsilon_\alpha \varepsilon_\beta = \varepsilon_{\alpha \oplus \beta}$ unde $\alpha \oplus \beta$ este adunarea din $\mathbb{Z}_k$

$$\begin{aligned} (q+p)^n &= q^n + C_n^1 q^{n-1} p + C_n^2 q^{n-2} p^2 + \dots + C_n^{k-1} q^{n-k+1} p^{k-1} + \dots \\ (q+p\varepsilon_1)^n &= q^n + \varepsilon_1 C_n^1 q^{n-1} p + \varepsilon_2 C_n^2 q^{n-2} p^2 + \dots + \varepsilon_{k-1} C_n^{k-1} q^{n-k+1} p^{k-1} + \dots \\ (q+p\varepsilon_2)^n &= q^n + \varepsilon_2 C_n^1 q^{n-1} p + \varepsilon_4 C_n^2 q^{n-2} p^2 + \dots + \varepsilon_{k-2} C_n^{k-1} q^{n-k+1} p^{k-1} + \dots \\ &\dots \end{aligned}$$

$$(q + p\varepsilon_{k-1})^n = q^n + \varepsilon_{k-2} C_n^1 q^{n-1} p + \varepsilon_{k-3} C_n^2 q^{n-2} p^2 + \dots + \varepsilon_1 C_n^{k-1} q^{n-k+1} p^{k-1} +$$

....

Adunăm

$$kP(Y=0) = (q+p)^n + (q+p\varepsilon_1)^n + \dots + (q+p\varepsilon_{k-1})^n$$

$$kP(Y=1) = (q+p)^n + \varepsilon_{k-1} (q+p\varepsilon_1)^n + \dots + \varepsilon_1 (q+p\varepsilon_{k-1})^n$$

etc

Iese ceva interesant doar în cazurile k=2,3,4. Cazul k=2 este banal

$$\text{Cazul k=3: } \varepsilon_1 = \cos \frac{2\pi}{3} + i \sin \frac{2\pi}{3} = \frac{-1+i\sqrt{3}}{2}, \varepsilon_2 = \cos \frac{4\pi}{3} + i \sin \frac{4\pi}{3} = \frac{-1-i\sqrt{3}}{2}$$

$$3P(Y=0) = (q+p)^n + (q+p\varepsilon_1)^n + (q+p\varepsilon_2)^n = 1 + 2 \operatorname{Re} (q+p\varepsilon_1)^n$$

$$3P(Y=1) = (q+p)^n + \varepsilon_2 (q+p\varepsilon_1)^n + \varepsilon_1 (q+p\varepsilon_2)^n = 1 + 2 \operatorname{Re} \varepsilon_2 (q+p\varepsilon_1)^n$$

$$3P(Y=2) = (q+p)^n + \varepsilon_1 (q+p\varepsilon_1)^n + \varepsilon_2 (q+p\varepsilon_2)^n = 1 + 2 \operatorname{Re} \varepsilon_1 (q+p\varepsilon_1)^n$$

$$\text{Scriem } q+p\varepsilon_1 = q+p \frac{-1+i\sqrt{3}}{2} = q-\frac{p}{2} + i \frac{p\sqrt{3}}{2} = r e^{i\phi} \text{ cu } r = \sqrt{p^2 - pq + q^2} = \sqrt{1-3pq}$$

$$\text{De unde } (q+p\varepsilon_1)^n = (1-3pq)^{\frac{n}{2}} e^{in\phi}, \varepsilon_2 (q+p\varepsilon_1)^n = (1-3pq)^{\frac{n}{2}} e^{i(n\phi + \frac{4\pi}{3})}, \varepsilon_1 (q+p\varepsilon_1)^n = (1-3pq)^{\frac{n}{2}} e^{i(n\phi + \frac{2\pi}{3})} \text{ și rezultă}$$

$$3P(Y=0) = 1 + 2(1-3pq)^{\frac{n}{2}} \cos n\phi$$

$$3P(Y=1) = 1 + 2(1-3pq)^{\frac{n}{2}} \cos (n\phi + \frac{4\pi}{3})$$

$$3P(Y=2) = 1 + 2(1-3pq)^{\frac{n}{2}} \cos (n\phi + \frac{2\pi}{3})$$

Ce e interesant este că niciodată cele trei probabilități nu pot coincide.

Cazul k=4. $\varepsilon_1 = i, \varepsilon_2 = -1, \varepsilon_3 = -i$. Fie $P_j = P(Y=j)$.

$$4P_0 = (q+p)^n + (q+p\varepsilon_1)^n + (q+p\varepsilon_2)^n + (q+p\varepsilon_3)^n = 1 + (q+pi)^n + (q-p)^n + (q-pi)^n$$

$$4P_1 = (q+p)^n + \varepsilon_3 (q+p\varepsilon_1)^n + \varepsilon_2 (q+p\varepsilon_2)^n + \varepsilon_1 (q+p\varepsilon_3)^n = 1 - i(q+pi)^n - (q-p)^n + i(q-pi)^n$$

$$4P_2 = (q+p)^n + \varepsilon_2 (q+p\varepsilon_1)^n + (q+p\varepsilon_2)^n + \varepsilon_2 (q+p\varepsilon_3)^n = 1 - (q+pi)^n + (q-p)^n - (q-pi)^n$$

$$4P_3 = (q+p)^n + \varepsilon_1 (q+p\varepsilon_1)^n + \varepsilon_2 (q+p\varepsilon_2)^n + \varepsilon_3 (q+p\varepsilon_3)^n = 1 + i(q+pi)^n - (q-p)^n - i(q-pi)^n$$

sau, daca scriem $q+pi = e^{i\phi}$

$$4P_0 = 1 + (q-p)^n + 2 \operatorname{Re} (q+pi)^n = 1 + (q-p)^n + 2(1-3pq)^{\frac{n}{2}} \cos n\phi$$

$$4P_1 = 1 - (q-p)^n + 2 \operatorname{Re} i(q-pi)^n = 1 - (q-p)^n - 2(1-3pq)^{\frac{n}{2}} \cos (n\phi + \frac{\pi}{2})$$

$$4P_2 = 1 + (q-p)^n - 2 \operatorname{Re} (q-pi)^n = 1 + (q-p)^n - 2(1-3pq)^{\frac{n}{2}} \cos (n\phi)$$

$$4P_3 = 1 - (q-p)^n + 2 \operatorname{Re} i(q+pi)^n = 1 - (q-p)^n + 2(1-3pq)^{\frac{n}{2}} \cos (n\phi + \frac{\pi}{2})$$

Rezultatul final este

$$Y^{\sim} \begin{pmatrix} 0 & 1 & 2 & 3 \\ \frac{1+(q-p)^n+2(1-3pq)^{\frac{n}{2}} \cos n\phi}{4} & \frac{1-(q-p)^n+2(1-3pq)^{\frac{n}{2}} \sin n\phi}{4} & \frac{1+(q-p)^n-2(1-3pq)^{\frac{n}{2}} \cos n\phi}{4} & \frac{1-(q-p)^n-2(1-3pq)^{\frac{n}{2}} \sin n\phi}{4} \end{pmatrix}$$

Ar putea fi toate egale?

$$\text{daca } \cos n\phi = 0, \sin n\phi = 1 \text{ rezultă } Y^{\sim} \begin{pmatrix} 0 & 1 & 2 & 3 \\ \frac{1+(q-p)^n}{4} & \frac{1-(q-p)^n+2(1-3pq)^{\frac{n}{2}}}{4} & \frac{1+(q-p)^n}{4} & \frac{1-(q-p)^n-2(1-3pq)^{\frac{n}{2}}}{4} \end{pmatrix}$$

Nu pot fi egale niciodata

Dar daca $X^{\sim} \text{Poisson}(\lambda)$ și $Y = \hat{X} \pmod{k}$?

Rețeta este aceeași

$$ke^\lambda P_0 = e^\lambda + e^{\lambda \varepsilon_1} + \dots + e^{\lambda \varepsilon_{k-1}}, ke^\lambda P_1 = e^\lambda + \varepsilon_{k-1} e^{\lambda \varepsilon_1} + \dots + \varepsilon_1 e^{\lambda \varepsilon_{k-1}}, ke^\lambda P_2 = e^\lambda + \varepsilon_{k-2} e^{\lambda \varepsilon_1} + \dots + \varepsilon_2 e^{\lambda \varepsilon_{k-1}}, \text{etc}$$

Dacă $k = 3$ avem

$$3P_0 = 1 + e^{\lambda(\varepsilon_1-1)} + e^{\lambda(\varepsilon_2-1)} = 1 + 2 \operatorname{Re} e^{\lambda(\varepsilon_1-1)}$$

$$3P_1 = 1 + \varepsilon_2 e^{\lambda(\varepsilon_1-1)} + \varepsilon_1 e^{\lambda(\varepsilon_2-1)} = 1 + 2 \operatorname{Re} \varepsilon_2 e^{\lambda(\varepsilon_1-1)},$$

$$3P_2 = 1 + \varepsilon_1 e^{\lambda(\varepsilon_1-1)} + \varepsilon_2 e^{\lambda(\varepsilon_2-1)} = 1 + 2 \operatorname{Re} \varepsilon_1 e^{\lambda(\varepsilon_1-1)}$$

$$\text{Dar } e^{\lambda(\varepsilon_1-1)} = e^{\lambda \left(\frac{-1+i\sqrt{3}}{2} - 1 \right)} = e^{-\frac{3\lambda}{2}} e^{\frac{i\sqrt{3}\lambda}{2}}, \varepsilon_1 e^{\lambda(\varepsilon_1-1)} = e^{-\frac{3\lambda}{2}} e^{\frac{i\sqrt{3}\lambda}{2} + \frac{2\pi}{3}}, \varepsilon_2 e^{\lambda(\varepsilon_1-1)} = e^{-\frac{3\lambda}{2}} e^{\frac{i\sqrt{3}\lambda}{2} + \frac{4\pi}{3}}$$

Deci

$$P_0 = \frac{1+2e^{-\frac{3\lambda}{2}} \cos \frac{\sqrt{3}\lambda}{2}}{3}$$

$$P_1 = \frac{1+2e^{-\frac{3\lambda}{2}} \cos \left(\frac{\sqrt{3}\lambda}{2} + \frac{2\pi}{3} \right)}{3}$$

$$P_2 = \frac{1+2e^{-\frac{3\lambda}{2}} \cos \left(\frac{\sqrt{3}\lambda}{2} + \frac{4\pi}{3} \right)}{3}$$

Și nici acum nu pot fi niciodată egale. Abaterea de la $\frac{1}{3}$ este întotdeauna mai mică decât $2e^{-\frac{3\lambda}{2}}$

De exemplu, dacă

$$\lambda = \frac{2\pi}{3\sqrt{3}} \Rightarrow Y^\sim \begin{pmatrix} 0 & 1 & 2 \\ 0.38768 & 0.22464 & 0.38768 \end{pmatrix}; \lambda = 1 \Rightarrow Y^\sim \begin{pmatrix} 0 & 1 & 2 \\ 0.4297 & 0.18701 & 0.38327 \end{pmatrix}$$

$$\lambda = 2 \Rightarrow Y^\sim \begin{pmatrix} 0 & 1 & 2 \\ 0.328 & 0.30763 & 0.36437 \end{pmatrix}; \lambda = 3 \Rightarrow Y^\sim \begin{pmatrix} 0 & 1 & 2 \\ 0.32699 & 0.33319 & 0.33982 \end{pmatrix}$$

$$\lambda = \frac{8\pi}{3\sqrt{3}} \Rightarrow Y^\sim \begin{pmatrix} 0 & 1 & 2 \\ 0.3331 & 0.3338 & 0.3331 \end{pmatrix}$$

5. Simulari. Să se simuleze o variabilă aleatoare repartizată Pareto: $F(x) = \min\left(\left(\frac{a}{x}\right)^n, 1\right)$. Etc.

$$F(x) = 1 - \left(\frac{a}{x}\right)^n \text{ dacă } x \geq a. \text{ Cuantilele sunt soluțiile ecuațiilor } 1 - \left(\frac{a}{x}\right)^n = p \iff \frac{a}{x} = (1-p)^{\frac{1}{n}} \iff x = a(1-p)^{-\frac{1}{n}}$$

Deci $X = a(1-U)^{-\frac{1}{n}}$. Cum U și $1-U$ au aceeași repartiție $U(0,1)$, putem pune $X = aU^{-\frac{1}{n}}$

6. Simulați $X^\sim \text{Bin}(1, p)$. De exemplu $X = \min\left(\left[\frac{U}{1-p}\right], 1\right)$

7. Simulați $X^\sim \text{Hyper}(a, n, k)$. Aici e mai greu, trebuie simulată o urnă. Instrucțiunea `sample(n,k)` din R face aceasta: simulează extragerea a k bile din n bile fără revenire. Un scurt script care simulează repartiția în cauză este următorul

```
a=10;n=15;t=a+n;k=19
```

```
omega=sample(t,k);x=length(which(omega<=a));x
```

Se simulează extragerea a 15 bile din 25 de bile, din care 10 sunt albe și 15 sunt negre.

$$\text{După 100 de simulări am obținut tabelul de frecvențe } \text{table}(x) = \begin{pmatrix} 3 & 4 & 5 & 6 & 7 & 8 & 9 \\ 1 & 8 & 16 & 25 & 29 & 17 & 4 \end{pmatrix}$$

$$\text{pe care îl putem compara cu adevărata repartiție } X^\sim \frac{1}{100} \begin{pmatrix} 0 & 1 & 2 & 3 & 4 & 5 \\ \frac{10}{326876} & \frac{375}{81719} & \frac{23625}{163438} & \frac{136500}{81719} & \frac{716625}{81719} & \frac{171990}{7429} \end{pmatrix}$$

$$X^\sim \frac{1}{100} \begin{pmatrix} 0 & 1 & 2 & 3 & 4 & 5 \\ 0.00001 & 0.00459 & 0.14455 & 1.6704 & 8.7694 & 23.151 & 32.154 & 23.624 & 8.8589 & 1.5312 & 0.0 \end{pmatrix}$$

1.3 Lecția 3. Integrala

Dacă (Ω, K, P) este un spațiu probabilitizat și X este o variabilă aleatoare, $\int X dP$ se notează cu EX .

Proprietăți specifice

1. $\int 1_A dP = P(A)$
2. $\int 1 dP = 1$
3. Inegalitatea lui Jensen. Dacă $f : I \rightarrow \mathbb{R}$ este convexă, $X : \Omega \rightarrow I \subset \mathbb{R}$ este o variabilă aleatoare, atunci $Ef(X) \geq f(EX)$
4. Inegalitatea normelor. Dacă $1 \leq p \leq q \leq \infty$ atunci $\|X\|_p \leq \|X\|_q$. Ca atare $L^p(\Omega, K, P) \subset L^q(\Omega, K, P) \subset L^\infty(\Omega, K, P)$
5. Dacă $\text{Supp}(P)$ nu este finit, atunci toate spațiile L^p sunt diferite iar incluziunea $L^\infty(\Omega, K, P) \subset \bigcap_{p < \infty} L^p(\Omega, K, P)$ este strictă

6. Cum calculăm EX .

Formula de transport

$$Eg(X) = \int g dF_X = \begin{cases} \sum_{x \in I} g(x) p(x) & \text{dacă } X \text{ este discretă, } F_X = \sum_{x \in I} p(x) \delta_x \\ \int_{-\infty}^{\infty} g(x) p(x) dx & \text{dacă } X \text{ este absolut continuă, } dF_X(x) = p(x) dx \end{cases}$$

7. Comutarea dintre medie și limită

7.1. Teorema lui Beppo-Levi:

Dacă $X_n \nearrow X, X_n \geq Z, EZ \neq -\infty \implies EX_n \nearrow EX$.

Dacă $X_n \searrow X, EX_n \geq Z, EZ \neq \infty \implies EX_n \searrow EX$.

7.2. Teorema Lui Lagrange: $X_n \rightarrow X, |X_n| \geq Z, E|Z| \neq \infty \implies EX_n \rightarrow EX$.

8. Dar de ce să calculăm media?

A. Din necesități de predicție. Nu întotdeauna știm să calculăm funcția de repartiție ca să dăm un interval de predicție la un risc dat, ε . Sunt mai multe cazurile în care putem calcula EX

B. Fiindcă trebuie să putem aproxima o variabilă aleatoare cu un număr (de exemplu o primă de asigurare sau un preț). Se pune problema să găsim **cea mai bună constantă cu care să putem aproxima o variabilă aleatoare**. Dacă punem problema așa, ne trebuie un criteriu de optim: după ce cunosc că o constantă a este mai bună ca altă constantă, b ? Un asemenea criteriu este dat de regulă de o distanță: calculăm distanța de la constanta a la variabila aleatoare X și vrem să fie cât mai mică. Pe diverse submulțimi de variabile aleatoare există mai multe asemenea distanțe deja studiate. Cele mai la îndemână sunt distanțele din $L^p(\Omega, K, P) : d_p(a, X) = \|X - a\|_p$. Așadar, dacă știm că variabila $X \in L^p(\Omega, K, P)$ putem căuta acea constantă a care minimizează funcția $d_p(x) = \|X - a\|_p$.

Formal, cea mai bună constantă din punctul de vedere L^p este $a = \arg \min d_p$

Dacă $p = 1$, obținem $a = \text{Median}(X)$

Dacă $p = 2$ obținem $a = EX$

Dacă $p = \infty$ obținem $a = \text{Midrange}(X) = \frac{1}{2}(m + M)$ unde

$m = \text{essinf} X := \sup\{x : F_X(x) = 0\}$, $M = \text{esssup} X := \inf\{x : F_X(x) = 1\}$

Cît de bună este aproximarea?

8. Inegalitatea lui Cebîșev. Cantitatea $d_2^2(EX) = E(X - EX)^2 = EX^2 - E^2X$ se numește varianța lui X și se notează cu $\text{Var}(X)$ sau $\sigma^2(X)$. Atunci $\sigma(X)$ se numește abaterea medie pătratică a lui X .

În plus, are loc inegalitatea $P(|X - EX| \geq k\sigma(X)) \leq \frac{1}{k^2}$

Aceasta este inegalitatea lui Cebîșev.

Scrisă pozitiv, ea devine

$$P(EX - k\sigma(X) \leq X \leq EX + k\sigma(X)) \geq 1 - \frac{1}{k^2}$$

formă care este simplă și ușor de înțeles. Deși inegalitatea în sine este foarte slabă.

Exerciții 1. Dintr-o urnă cu bilele numerotate $0, \frac{1}{n}, \frac{2}{n}, \dots, \frac{n-1}{n}$ se scot două bile (cu sau fără înlocuire). Fie X maximul lor și Y minimul lor. Să se calculeze $EX, EY, \text{Var} X, \text{Var} Y$. Treceți la limită

2. Se iau două numere la întâmplare între 0 și 1. Fie X maximul lor și Y minimul lor. Aceeași problemă ca și mai sus

3. Diverse probleme luate absolut oricum: se ia o funcție F care să fie pe undeva crescătoare, se potrivește din x și y ca să fie funcție de repartiție, i se calculează apoi densitatea (dacă are - 99% că vi se va da o funcție continuă) și i se calculează media și varianța

1.4 Lecția 4. Procedee de calcul al mediei

1. Funcția generatoare de momente (mgf)

Momentul de ordin n este prin definiție numărul $\mu_n = EX^n$. Funcția generatoare de momente este $m_X(t) = Ee^{tX}$. Notăm $D_X = \{t \in R : m_X(t) \neq \infty\}$. Dacă $D_X = R$ variabila e cu coadă foarte scurtă, dacă $D_X = \{0\}$ este cu coadă lungă. Pentru variabile aleatoare pozitive D_X conține întotdeauna intervalul $(-\infty, 0]$. Dacă există $h > 0$ astfel ca $m_X(t) < \infty$ pentru orice $x < h$ atunci spunem că X are coadă medie. În general X are coadă medie dacă există $h > 0$ astfel ca $Ee^{t|X|} < \infty$ pentru orice $x < h$

1.1 Dacă X are coadă medie, atunci are toate momentele absolute finite: $X \in \bigcap_{1 \leq p < \infty} L^p$

Evident, dacă există k ca $E|X|^k = \infty$ și $t > 0$, atunci $m_X(t) = E \sum_{n=0}^{\infty} t^n \frac{|X|^n}{n!} = \sum_{n=0}^{\infty} t^n \frac{E|X|^n}{n!}$ (Beppo - Levi) $\geq t^k \frac{E|X|^k}{k!} = \infty$.

1.2. Dacă X are coadă medie atunci putem scrie $m_X(t) = \sum_{n=0}^{\infty} t^n \frac{EX^n}{n!}$ (putem comuta limita cu suma datorită teoremei lui Lebesgue, seria fiind dominată de $e^{t|X|}$). Dacă putem dezvoltă în serie pe m_X obținem momentele lui X .

1.3. Exemple.

1.3.1. $X \sim \text{Exp}(\lambda) \implies m_X(t) = \frac{\lambda}{\lambda - t}, 1D_X = (-\infty, \lambda)$; are coadă medie. Dezvoltăm în serie

$m_X(t) = 1 + \frac{t}{\lambda} + \frac{t^2}{\lambda^2} + \dots$ și identificăm seria cu $m_X(t) = 1 + t\mu_1 + \frac{t^2\mu_2}{2!} + \dots$; rezultă $\mu_n = \frac{n!}{\lambda^n}$

$$1.3.2.. X \sim N(0, 1) \iff m_X(t) = e^{\frac{t^2}{2}} \text{ (e ușor: } m_X(t) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{tx - \frac{x^2}{2}} dx = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{-\frac{x^2 - 2tx + t^2}{2} + \frac{t^2}{2}} dx = e^{\frac{t^2}{2}} \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{-\frac{(x-t)^2}{2}} dx = e^{\frac{t^2}{2}} \cdot 1)$$

$$\text{Deci } m_X(t) = e^{\frac{t^2}{2}} = 1 + \frac{t^2}{2} + \frac{t^4}{2^2 2!} + \dots + \frac{t^{2n}}{n! 2^n} + \dots = 1 + t\mu_1 + \frac{t^2\mu_2}{2!} + \frac{t^3\mu_3}{3!} + \dots + \frac{t^{2n}\mu_{2n}}{(2n)!} + \dots$$

$$\text{Deci } \mu_{2n+1} = 0 \text{ pentru orice număr natural } n \text{ iar } \frac{\mu_{2n}}{(2n)!} = \frac{1}{n! 2^n} \iff \mu_{2n} = \frac{(2n)!}{n! 2^n} = 1 \cdot 3 \cdot 5 \cdot \dots \cdot (2n-1) = (2n-1)!!$$

1.3.3. Repartiția normală. Dacă $Z \sim N(0, 1)$ atunci variabila $X = \mu + \sigma Z$ are densitatea $p_X(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$, funcția generatoare de momente $m_X(t) = e^{t\mu + \frac{t^2\sigma^2}{2}}$, funcția caracteristică $\phi_X(t) = e^{it\mu - \frac{t^2\sigma^2}{2}}$. Aceasta este repartiția normală de medie μ și varianță σ^2 . Ea se notează cu $N(\mu, \sigma^2)$.

2. Funcția generatoare de cumulanți (cgf)

Are formula $k_X = \ln m_X$

E interesantă fiindcă $k'_X(0) = \mu_1, k''_X(0) = \mu_2 - \mu_1^2 = \text{Var}(X), k'''_X(0) = E(X - \mu_1)^3$

3. Funcția caracteristică

Corectează marele defect al mgf-ului: acela că D_X nu e una și aceeași multime pentru orice X .

$$\phi_X(t) = Ee^{itX} = E\cos(tX) + iE\sin(tX)$$

În plus există și

Teorema de unicitate: $\phi_X = \phi_Y \iff F_X = F_Y$

Pe vremuri o demonstram și pe asta.

4. Funcția generatoare

Se folosește pentru variabile aritmetice, adică $X : \Omega \rightarrow \mathbb{N}$

$$g_X : [0, 1] \rightarrow \mathbb{R}_+, g_X(x) = Ex^X = \sum_{n=0}^{\infty} P(X=n) x^n.$$

Proprietatea ei cea mai importantă este că prin derivare se obțin momentele factoriale

$$g_X^{(n)}(1-0) = EX(X-1)\dots(X-n+1)$$

Orice funcție analitică $g : [0, 1] \rightarrow \mathbb{R}_+$ cu proprietatea că $g(1) = 1$ și care are toate derivatele pozitive este funcția generatoare a unei probabilități pe $(\mathbb{N}, P(\mathbb{N}))$.

Consecințe

$$g_X(0) = P(X=0); EX = g'_X(1-0); \text{Var}(X) = g''_X(1-0) + g'_X(1) - g'_X(1)^2$$

Exemple

$$4.1. \text{ Repartiția Hipergeometrică } \text{Hyper}(a, n, k) = \sum_{j=0}^k \frac{C_a^j C_n^{k-j}}{C_{a+n}^k} \delta_j. \text{ Funcția sa}$$

$$\text{generatoare } g_{a,n,k} \text{ nu are o formă analitică cunoscută: } g_{a,n,k}(x) = \sum_{j=0}^k \frac{C_a^j C_n^{k-j}}{C_{a+n}^k} x^j$$

Dar se poate folosi cu succes datorită recurenței $g'_{a,n,k}(x) = k \frac{a}{a+n} g_{a-1,n,k-1}(x)$ și a faptului că orice funcție generatoare are proprietatea că $g(1) = 1 : g'(1) =$

$EX = k \frac{a}{a+n}, g''(1) = EX(X-1) = k(k-1) \frac{a}{a+n} \frac{a-1}{a+n-1}$. Astfel $\text{Var}(X) = k(k-1) \frac{a}{a+n} \frac{a-1}{a+n-1} + k \frac{a}{a+n} - \left(k \frac{a}{a+n}\right)^2 = k \frac{a}{a+n} \left(\frac{(k-1)(a-1)}{a+n-1} + 1 - k \frac{a}{a+n}\right)$ sau, cu notațiile $p = \frac{a}{a+n}, q = \frac{n}{a+n}$ găsim

$$EX = kp, \text{Var}(X) = kpq \frac{a+n-k}{a+n-1} = kpq \left(1 - \frac{k-1}{a+n-1}\right)$$

4.2. Repartiția Binomială $\text{Bin}(k, p)$ are funcția generatoare foarte simplă:
 $g(x) = (q + px)^k$ unde $q = 1 - p$. Deci

$$EX = kp, \text{Var}(X) = kpq$$

Dacă raportul $\frac{k}{a+n}$ este mic, se poate aproxima Hipergeometrica cu Binomiala.

4.3. Repartiția Poisson (λ): $g_X(x) = e^{\lambda(x-1)}$. deci

$EX = \text{Var}(X) = \lambda$. Este legea evenimentelor rare: dacă $kp = \lambda$ și p este foarte mic, se poate aproxima Binomiala cu Poisson. Momentele factoriale formează o progresie geometrică.

4.4. Repartițiile geometrică și Negbin: $g_{\text{Geoma}(p)}(x) = \frac{px}{1-qx}$ și $g_{\text{Negbin}(1,p)}(x) = \frac{p}{1-qx}$

5. Formula de integrare prin părți. Lucrul cu cozile.

5.1. Fie $X \geq 0$ o variabilă aleatoare și $g : \mathbb{R} \rightarrow \mathbb{R}$ o funcție continuă derivabilă pe porțiuni. Presupunem că $g(X) \in L^1$.

Atunci este valabilă formula

$\text{Eg}(X) = g(0) + \int_0^\infty g'(y) \underline{F}(y) dy$ unde $\underline{F}(y) = P(X > y)$ este coada (dreaptă) a lui Y .

Exemple: $EX = \int_0^\infty \underline{F}(y) dy, E(X-a)_+ = \int_a^\infty \underline{F}(y) dy, E \min(X, a) = \int_0^a \underline{F}(y) dy$ (aici se subînțelege că $a \geq 0$!)

Demonstrație. Plecăm de la formula Leibniz Newton. Aici λ este măsura Lebesgue

$g(X) - g(0) = \int_0^X g'(y) dy = \int g'(y) 1_{[0,X]}(y) d\lambda(y) = \int g'(y) 1_{[0,X]}(y) d\lambda(y)$ (măsura Lebesgue neglijează punctele!!)

$$= \int g'(y) 1_{[0,\infty)}(y) 1_{(y,\infty)}(X) d\lambda(y)$$

Deci, aplicând teorema lui Fubini (am presupus în ipoteză că $g(X) \in L^1(P)$)

$$\iff g'(y) 1_{(y,\infty)}(X) \in L^1(P \otimes \lambda)$$

$$\begin{aligned} \text{Eg}(X) - g(0) &= \int \left(\int g'(y) 1_{[0,\infty)}(y) 1_{(y,\infty)}(X) d\lambda(y) \right) dP = \int \left(\int g'(y) 1_{[0,\infty)}(y) 1_{(y,\infty)}(X) dP \right) d\lambda(y) \\ &= \int g'(y) 1_{[0,\infty)}(y) \left(\int 1_{(y,\infty)}(X) dP \right) d\lambda(y) = \int_0^\infty g'(y) \left(\int 1_{(y,\infty)}(X) dP \right) d\lambda(y) = \\ &= \int_0^\infty g'(y) P(X > y) dy. \end{aligned}$$

5.2. Fie $X \geq 0$ o variabilă aleatoare și $g : \mathbb{R} \rightarrow \mathbb{R}$ o funcție continuă derivabilă pe porțiuni. Presupunem că $g(X) \in L^1$.

Atunci este valabilă formula

$\text{Eg}(X) = \int_0^\infty (g'(y) \underline{F}(y) - g'(-y) F(-y)) dy$ unde $\underline{F}(y) = P(X > y), F(y) = P(X \leq y)$

Demonstrație. Scriem $X = X_+ - X_-$. Atunci $g(X) = g(X_+) + g(-X_-)$ și aplicăm formula de dinainte.

Exemplu: $EX = \int_0^\infty (\underline{F}(y) - F(-y)) dy$. Interpretare geometrică.

Exerciții. Calculați diverse medii și varianțe.

Arătați că dacă X este o variabilă aleatoare aritmetică, $EX = \sum_{n=0}^{\infty} P(X > n)$, $EX^2 = \sum_{n=0}^{\infty} (2n+1) P(X > n)$ etc

1.5 Lecția 5. Vectori aleatori

Dacă $X : \Omega \rightarrow \mathbb{R}^n$ este un vector aleator, repartiția sa F_X este o probabilitate pe $(\mathbb{R}^n, B(\mathbb{R}^n))$

Cum o descriem?

1. Funcția de repartiție. Se definește la fel ca în cazul unidimensional, cu aceeași convenție

$$F_X(x) = P(X \leq x) := P(X_1 \leq x_1, X_2 \leq x_2, \dots, X_n \leq x_n); F_X(B) = P(X \in B)$$

Nu e ușor de lucrat cu ea. Oricum, rezultatul unidimensional $F_X = F_Y \iff F_X(x) = F_Y(x)$ pt orice $x \in \mathbb{R}^n$ se păstrează.

Motivul? Mulțimea M a intervalelor $(-\infty, x]$ este stabilă la intersecții finite (evident $(-\infty, x] \cap (-\infty, y] = (-\infty, \min(x, y)]$!!) și generează mulțimile din $B(\mathbb{R}^n) = B(\mathbb{R})^{\otimes n}$

Cazul $n = 2$. $X = (X_1, X_2)$, $x = (x_1, x_2)$, $F_X(x) = P(X_1 \leq x_1, X_2 \leq x_2) = F_X((-\infty, x_1] \times (-\infty, x_2])$ deci

$$F_X((a_1, b_1] \times (a_2, b_2]) = F_X(a_1, a_2) + F_X(b_1, b_2) - F_X(a_1, b_2) - F_X(a_2, b_1)$$

Proprietăți. $F : \mathbb{R}^2 \rightarrow [0, 1]$ este o funcție de repartiție bidimensională dacă și numai dacă

$$\alpha. F(-\infty, y) = F(x, -\infty) = 0 \text{ pentru orice } x, y \in \mathbb{R}$$

$$\beta. x \mapsto F(x, \infty), y \mapsto F(\infty, y) \text{ sunt funcții de repartiție unidimensionale}$$

$$\gamma. F(a_1, a_2) + F(b_1, b_2) - F(a_1, b_2) - F(a_2, b_1) \geq 0 \text{ pentru orice } a_1 \leq b_1, a_2 \leq b_2.$$

Exemplu.

1. 1. Dacă $F_X = \delta_{(a,b)}$ (repartiția Dirac în punctul a, b) atunci $F_X(x, y) = 1_{[a, \infty) \times [b, \infty)}(x, y) = 1_{[a, \infty)}(x) 1_{[b, \infty)}(y)$. Consecință: dacă $F_X = \sum_j p_j \delta_{(a_j, b_j)}$

$$\text{atunci } F_X(x, y) = \sum_j p_j 1_{[a_j, \infty)}(x) 1_{[b_j, \infty)}(y)$$

1.2. Se iau două numere la întâmplare, U și V intervalul $[0, 1]$. Fie $X = \min(U, V)$, $Y = \max(U, V)$.

$$\text{Atunci } P(X \leq x, Y \leq y) = P(\min(U, V) \leq x, \max(U, V) \leq y) = P(((U \leq x) \cup (V \leq x)) \cap (U \leq y, V \leq y))$$

$$= P((U \leq \min(x, y), V \leq y) \cup (U \leq y, V \leq \min(x, y)))$$

$$= P(U \leq \min(x, y), V \leq y) + P(U \leq y, V \leq \min(x, y)) - P(U \leq \min(x, y), V \leq \min(x, y)) =$$

$$2y \min(x, y) - \min(x, y)^2$$

$$\text{Deci } F(x, y) = \begin{cases} 2xy - y^2 & \text{dacă } 0 \leq x \leq y \leq 1 \\ y^2 & \text{dacă } 0 \leq y \leq x \leq 1 \end{cases}$$

$$\text{Dacă } x \geq 1 \text{ sau } y \geq 1 \text{ avem } F(x, y) = 2 \min(x, y) - \min(x, y)^2$$

O funcție de repartiție $G : [0, 1]^2 \rightarrow [0, 1]$ cu proprietatea că $G(x, 1) = G(1, x) = x$ se numește **copulă**.

De exemplu $G(x, y) = xy$ sau $G(x, y) = \min(x, y)$ sunt copule.

1.3 Exercițiu. Arătați că $F(x, y) = \max(x, y)$ NU este o funcție de repartiție. Într-adevăr, dacă $a_1 = a_2, b_1 = b_2$ atunci

$$\max(a_1, a_2) + \max(b_1, b_2) - \max(a_1, b_2) - \max(a_2, b_1) = a + b - b - b = a - b < 0.$$

2. Repartițiile didactice sunt cele discrete sau absolut continue.

Repartiția este discretă dacă, la fel ca în cazul unidimensional, se poate scrie sub forma $F_X = \sum_{x \in A} p(x) \delta_x$ unde $A \subset \mathbb{R}^n$ este o mulțime cel mult numărabilă.

Un criteriu suficient ca acest lucru să se întâmple este ca $X(\Omega)$ să fie o mulțime cel mult numărabilă.

Repartiția este absolut continuă dacă există o funcție nenegativă și măsurabilă $p : \mathbb{R}^n \rightarrow \mathbb{R}_+$ cu proprietatea că $F_X(B) := P(X \in B) = \int p 1_B d\lambda^n$. Orice funcție $p \geq 0$ cu proprietatea că $\int p d\lambda^n = 1$ este o densitate.

2.1. O urnă are a_1 bile de culoarea 1, a_2 bile de culoarea 2, ..., a_n bile de culoarea n . Se extrag k bile. X_1 sunt de culoarea 1, X_2 sunt de culoarea 2, ..., X_n sunt de culoarea n .

Care este repartiția vectorului $X = (X_j)_{1 \leq j \leq n}$?

Dacă bila nu se pune la loc, evident $P(X = x) = \frac{C_{a_1}^{x_1} C_{a_2}^{x_2} \dots C_{a_n}^{x_n}}{C_{a_1 + a_2 + \dots + a_n}^k}$ dacă $x_1 + \dots + x_n = k, x_j \geq 0 \quad \forall 1 \leq j \leq n$ sau $P(X = x) = 0$ altfel.

Dacă bila se pune la loc, atunci $P(X = x) = \frac{k!}{x_1! \dots x_n!} p_1^{x_1} p_2^{x_2} \dots p_n^{x_n}$ în aceleași condiții. Aici $p_j = \frac{a_j}{a_1 + a_2 + \dots + a_n}$.

2.2. Se aruncă un punct X la întâmplare într-o mulțime $B \subset \mathbb{R}^n$ măsurabilă. Presupunem că $\lambda^n(B) \in (0, \infty)$. Atunci

$F_X(A) = P(X \in A) = \frac{\lambda^n(A \cap B)}{\lambda^n(B)}$ este absolut continuu și are densitatea $p = \frac{1_B}{\lambda^n(B)}$.

3. Majoritatea vectorilor aleatori au repartiții care nu sunt nici discrete, nici absolut continue.

De exemplu, dacă luăm o variabilă aleatoare ξ absolut continuă și formăm vectorul $X = (\xi, \xi)$, acesta va avea o repartiție care nu este discretă (căci $P(X = x) = 0$ pentru orice x) dar nici absolut continuă, deoarece este concentrată pe diagonală $\Delta = \{(x, x) : x \in \mathbb{R}\}$. Dacă $F(t) = P(\xi \leq t)$ este funcția de repartiție a lui ξ , atunci $F_X(x, y) = P(\xi \leq \min(x, y)) = F(\min(x, y))$

4. **Repartițiile marginale.** Fie X un vector aleator n -dimensional. Repartiția componentei X_j se numește marginala j a lui F_X . Dacă am ști funcția de repartiție F_X , atunci este evident că

$$F_{X_j}(x_j) = P(X_j \leq x_j) = P(X_1 \leq \infty, \dots, X_{j-1} \leq \infty, X_j \leq x_j, X_{j+1} \leq \infty, \dots, X_n \leq \infty) = F_X(\infty, \dots, \infty, x_j, \infty, \dots, \infty)$$

Dacă X este absolut continuu, atunci X_j sunt de asemenea absolut continui.

Dacă $F_X = p \cdot \lambda^n$, atunci $p_{X_j}(x_j) = \int \dots \int p(x_1, \dots, x_{j-1}, x_j, x_{j+1}, \dots, x_n) dx_1 \dots dx_{j-1} dx_{j+1} \dots dx_n$

De exemplu

$$\begin{aligned} & - \text{în cazul } n = 2 : p_{X_1}(x_1) = \int p(x_1, x_2) dx_2, p_{X_2}(x_2) = \int p(x_1, x_2) dx_1 \\ & - \text{în cazul } n = 3 : p_{X_1}(x_1) = \int \int p(x_1, x_2, x_3) dx_2 dx_3, p_{X_2}(x_2) = \int \int p(x_1, x_2, x_3) dx_1 dx_3, \\ & p_{X_3}(x_3) = \int \int p(x_1, x_2, x_3) dx_1 dx_2 \end{aligned}$$

Reciproc nu este adevărat, vezi punctul 3 de mai sus. Deși ξ este absolut continuă, vectorul (ξ, ξ) nu este.

4.1. O urnă are a_1 bile de culoarea 1, a_2 bile de culoarea 2, ..., a_n bile de culoarea n . Se extrag k bile. X_1 sunt de culoarea 1, X_2 sunt de culoarea 2, ..., X_n sunt de culoarea n .

Care este repartițiile marginale ale vectorului $X = (X_j)_{1 \leq j \leq n}$?

R. Dacă nu se pune bila la loc sunt Hypergeometric($a_j, N - a_j, k$) cu $N = a_1 + a_2 + \dots + a_n$

Dacă se pune bila la loc sunt Binomial (k, p_j)

4.2. X este repartizat uniform pe discul unitate $D = \{(x, y) : x^2 + y^2 \leq 1\}$. Care sunt densitățile marginale?

R. $p_{X_1}(x) = \int 1_D(x, y) dy = \frac{1}{\pi} \int_{-\sqrt{1-x^2}}^{\sqrt{1-x^2}} dy = \frac{2\sqrt{1-x^2}}{\pi} 1_{(-1,1)}(y)$, $p_{X_2} = p_{X_1}$

5. **Aproximarea cu constante.** Lucrurile se complică deoarece funcția $f(X, t) = d(t, X)$ căreia trebuie să îi găsim punctul de minim $\text{argmin} f$ se poate defini în multe feluri. Dacă însă X este din L^2 (adică toate componentele sale sunt din L^2) și luăm distanța euclidiană + norma din L^2 atunci

$$f(X, t) = \sqrt{E \sum_{k=1}^n (X_j - t_j)^2}$$
 și lucrurile se petrec la fel ca în cazul unidimensional:

$$\text{Argmin} f = \text{Argmin} f^2 = \text{Argmin} \left(\sum_{k=1}^n (X_j - t_j)^2 \right) = (EX_1, \dots, EX_n)$$

Acest vector se notează cu EX . Atunci $f(X, EX) = \sqrt{\sum_{k=1}^n \text{Var}(X_j)} := \sigma^2$

Analogul inegalității lui Cebîșev: $P(\|X - EX\| \geq k\sigma) \leq \frac{1}{k^2}$

(Același argument: $\sigma^2 = E\|X - EX\|^2 \geq E(\|X - EX\|^2 1_{(\|X - EX\| \geq k\sigma)}) \geq k^2 \sigma^2 P(\|X - EX\| \geq k\sigma)$)

Exemplu: O urnă are a bile de albe, n bile negre, r bile roșii. Se extrag k bile. X sunt albe, Y sunt negre. Faceți o predicție asupra vectorului $Z = (X, Y)$

R1. Bila nu se pune înapoi. $EZ = \left(kp_a, k\frac{n}{a+n+r}\right)$, $\text{Var}(X) = kp_a q_a \frac{a+n+r-k}{a+n+r-1}$, $\text{Var}(Y) = kp_n q_n \frac{a+n+r-k}{a+n+r-1}$

Am notat cu $p_a = \frac{a}{a+n+r}$, $q_a = 1 - p_a = \frac{n+r}{a+n+r}$, $p_n = \frac{n}{a+n+r}$, $q_n = 1 - p_n = \frac{a+r}{a+n+r}$

Atunci $P(\|Z - (kp_a, kp_n)\| \geq 5\sqrt{kp_a q_a \frac{a+n+r-k}{a+n+r-1} + kp_n q_n \frac{a+n+r-k}{a+n+r-1}}) \leq \frac{1}{25} = 4\%$

Concret: $a = n = r = 1200 = k \implies p_a = p_n = \frac{1}{3}$, $EZ = (400, 400)$, $\sigma = \frac{2400\sqrt{2}}{3\sqrt{3599}} = 18.859$.

Deci $P(\|Z - (400, 400)\| \geq 94.295) \leq 4\%$. Putem paria, cu riscul de a pierde pariul mai mic decât 4% că Z se află în interiorul cercului de centru $(400, 400)$ și rază 95.

R2. Bila se pune înapoi. Acum $EZ = \left(kp_a, k\frac{n}{a+n+r}\right)$ dar $\text{Var}(X) = kp_a q_a$, $\text{Var}(Y) = kp_n q_n$

În aceleași ipoteze de dinainte $\sigma = \sqrt{\frac{4}{9}1200} = 23.094$ deci $P(\|Z - (400, 400)\| \geq 115.47) \leq 4\%$

6. Portofolii. Covarianță. Vectorul $X = (X_j)_{1 \leq j \leq n}$ poate fi interpretat ca fiind o piață financiară, în care X_j să reprezinte profitul obținut în urma unui leu investit. Dacă în această piață se investesc s_j lei în poziția j și $S = \sum_{j=1}^n s_j$, atunci vectorul $s = (s_1, \dots, s_n)$ se numește *portofoliu de volum* S . Variabila aleatoare $\xi = \sum_{j=1}^n s_j X_j$ se numește *valoarea* portofoliului, media sa $E\xi$ este *randamentul portofoliului* iar varianța sa $\text{Var}\xi$ este numit de unii *risc* portofoliului.

Randamentul este ușor de calculat: $E\xi = \sum_{j=1}^n s_j EX_j$. Varianța lui introduce în calcul așa numita *matrice de covarianță*.

Definiție. Matricea $(c_{i,j})_{1 \leq i,j \leq n} = C = \text{Cov}(X) = (EX_i X_j - EX_i EX_j)_{1 \leq i,j \leq n}$ se numește *matricea de covarianță* a vectorului X .

Fapte evidente. $\text{Var}\xi = \sum_{i,j=1}^n s_i s_j c = s' C s$. Matricea C este semipozitiv definită iar funcția $V(s) = s' C s$ este convexă, deoarece matricea sa hessiană $\left(\frac{\partial^2}{\partial s_i \partial s_j}\right)_{i,j}$ coincide cu C .

Demonstrație: Evident

7. Formula de transport. Formal, este aceeași din cazul unidimensional. Dacă $f : \mathbb{R}^n \rightarrow \mathbb{R}$ este o funcție măsurabilă și $f(X) \in L^1$, atunci $Ef(X) = \int f dF_X$

În cele două cazuri didactice - discret sau absolut continuu - e cam la fel. Doar dacă X este absolut continuu apare variați $Ef(X) = \int f p d\lambda^n$.

Exemple. $EX_j = \int_{\mathbb{R}^n} x_j p(x_1, \dots, x_n) dx_1 \dots dx_n$, $EX_i X_j = \int_{\mathbb{R}^n} x_i x_j p(x_1, \dots, x_n) dx_1 \dots dx_n$ etc

8. Funcția generatoare de momente: $m_X(t) = Ee^{\sum_{j=1}^n t_j X_j}$. Are sens să se lucreze cu ea dacă $Ee^{\delta \sum_{j=1}^n |X_j|} < \infty$ pentru un $\delta > 0$.

Atunci $EX = \nabla_{m_X}(0)$, $EX_i X_j = \frac{\partial^2 m_X}{\partial t_i \partial t_j}(0) = H_{m_X}(0)$ iar $\text{Cov}(X) = H_{m_X}(0) - \nabla_{m_X}(0) \nabla_{m_X}(0)'$. H se numește matricea hessiană - din anul I de facultate.

Funcția caracteristică: $\phi_X(t) = Ee^{i \sum_{j=1}^n t_j X_j}$

Funcția generatoare (are sens doar pentru vectori stocastici aritmetici, adică cu valori în $\mathbb{N}^n$).

$$g_X(x) = \sum_j x_1^{j_1} x_2^{j_2} \dots x_n^{j_n} P(X = (j_1, j_2, \dots, j_n))$$

Atunci $EX = \nabla g(1)$, iar dacă $i \neq j$, atunci $EX_i X_j = \frac{\partial^2 g}{\partial t_i \partial t_j}(1)$. Dacă $i = j$ avem $\frac{\partial^2 g}{\partial t_i^2}(1) = EX(X_i - 1) = EX^2 - EX$ sau, în scriere matriceală $H_g(1) = (EX_i X_j - \delta_{i,j} EX_i)_{i,j}$.

Obținem formula $\text{Cov}(X) = H_g(1) - \nabla g(1) \nabla g(1)' + (\delta_{i,j} EX_i)_{i,j}$

Exerciții. Să se calculeze $EX, \text{Cov}(X)$ în cât mai multe cazuri.

9. Portofoliu optim - varianta Markowitz. Utilitatea portofoliului este $U(s) = E s' X - \frac{r}{2} \text{Var}(s' x) = s' \mu - \frac{r}{2} s' C s$ unde $\mu = EX$, $C = \text{Cov}(X)$, $r \geq 0$ este coeficientul de aversiune la risc.

Exemplu de calcul. La exemplul 2.1, varianta cu bila pusă la loc, se zice că X are repartiția multinomială $\text{Mult}(k, p_1, p_2, \dots, p_n)$. Atunci $g_X(x) = \sum_{j_1, \dots, j_n \geq 0, \sum_{\alpha=1}^n j_\alpha = k} \frac{k!}{j_1! \dots j_n!} p_1^{j_1} p_2^{j_2} \dots p_n^{j_n} =$

$(p_1 x_1 + p_2 x_2 + \dots + p_n x_n)^k$ (de aceea i se spune repartiția multinomială!) deci

$$\nabla g(x) = k(p_1 x_1 + p_2 x_2 + \dots + p_n x_n)^{k-1} \begin{pmatrix} p_1 \\ p_2 \\ \dots \\ p_k \end{pmatrix} \Rightarrow EX = k \begin{pmatrix} p_1 \\ p_2 \\ \dots \\ p_k \end{pmatrix}$$

$$Hg(x) = k(k-1)(p_1 x_1 + p_2 x_2 + \dots + p_n x_n)^{k-2} \begin{pmatrix} p_1^2 & p_1 p_2 & \dots & p_1 p_n \\ p_2 p_1 & p_2^2 & \dots & p_2 p_n \\ \dots & \dots & \dots & \dots \\ p_n p_1 & p_n p_2 & \dots & p_n^2 \end{pmatrix} \Rightarrow$$

$$Hg(1) = k(k-1) \begin{pmatrix} p_1^2 & p_1 p_2 & \dots & p_1 p_n \\ p_2 p_1 & p_2^2 & \dots & p_2 p_n \\ \dots & \dots & \dots & \dots \\ p_n p_1 & p_n p_2 & \dots & p_n^2 \end{pmatrix}$$

$$\text{Deci } \text{Cov}(X) = Hg(1) + (np_i \delta_{i,j})_{i,j} - EX(EX)' = k \begin{pmatrix} p_1 q_1 & -p_1 p_2 & \dots & -p_1 p_n \\ -p_2 p_1 & p_2 q_2 & \dots & -p_2 p_n \\ \dots & \dots & \dots & \dots \\ -p_n p_1 & -p_n p_2 & \dots & p_n q_n \end{pmatrix}$$

Deci în cazul unui portofoliu $\xi = \sum s_j X_j$

$$\text{Var} \xi = k \left(\sum_{j=1}^n s_j^2 p_j q_j - \sum_{i \neq j=1}^n s_i s_j p_i p_j \right)$$

Exerciții.

1. Se dă densitatea $p(x, y) = (ax + by) 1_{(0,1)}(x) 1_{(0,1)}(y)$. Găsiți condiția ca p să fie densitate, media și covarianța. Același lucru pentru cât mai multe exemple găsite de dv.

2. Același lucru pentru $p(x, y) = c 1_C(x, y)$ unde C este o mulțime de arie finită din plan. De exemplu $C = \text{co}(0, 1, i)$ sau $C = \text{co}(0, 1, i, 2 + 2i)$

1.6 Lecția 6. Probabilitate condiționată.

1. Definiție. Fie $(\Omega, \mathbf{K}, P)$ un spațiu probabilitat și $A \in \mathbf{K}$ un eveniment de probabilitate nenulă, $P(A) \neq 0$.

Atunci definim $P(B|A) = \frac{P(A \cap B)}{P(A)}$ și citim "probabilitatea lui B condiționată de A "

2. Dacă notăm $P_A(B) = P(B|A)$ obținem un nou spațiu probabilitat $(\Omega, \mathcal{L}, P_A)$.

Integrala față de P_A se calculează după formula $\int X dP_A = \frac{\int X 1_A dP}{P(A)}$ și se notează $E(X|A)$ demonstrația imediată cu metoda celor 4 pași)

O variabilă aleatoare Y cu proprietatea că $P(Y \in B) = P(X \in B|A)$ se notează (abuziv!) $Y = (X|A)$

Exemplu. **Timpul remanent de viață.** Dacă T este o variabilă aleatoare pozitivă, o putem interpreta ca fiind timpul de viață al unui organism sau aparat. Atunci variabila aleatoare $T_x = (T - x|T > x)$ se numește timpul remanent de viață la vârsta x . Așadar $P(T_x > t) = \frac{P(T > t+x)}{P(T > x)}$ și se obișnuiește a se nota cu $t p_x$.

3. Formula lui Bayes. Fie $(H_n)_n$ o partiție cel mult numărabilă a lui Ω (adică $m \neq n \implies H_m H_n = \emptyset$ și $\bigcup_n H_n = \Omega$) formată evenimente neneglijabile, adică $P(H_n) \neq 0$. Presupunem cunoscute probabilitățile $P(A|H_n)$. Atunci

$$P(H_i|A) = \frac{P(A|H_i)P(H_i)}{\sum_n P(A|H_n)P(H_n)}$$

Evenimentele H_n se numesc *ipoteze*, probabilitățile $P(A|H_n)$ formează *modelul*, probabilitățile $(P(H_n))_n$ se numesc probabilitățile *apriori* iar probabilitățile $(P(H_n|A))_n$ se numesc probabilitățile *aposteriori*.

Exemplu. Populația României se compune din 50% bisericoși, 40% neutri și 10% atei. Dintre bisericoși 50% respectă postul mare, dintre neutri îl respectă 20% iar dintre atei 1%. Cineva este văzut că mănâncă un cîrnat chiar în vinerea mare. Ce este el? bisericos? neutru? ateu?

Soluție. Cele trei ipoteze sunt H_1 = bisericos, H_2 = neutru, H_3 = ateu. Probabilitățile apriori sunt $P(H_1) = .5, P(H_2) = .4, P(H_3) = .1$

A = individul care mănâncă un cîrnat în vinerea mare

Modelul este $P(A|H_1) = .5, P(A|H_2) = .8, P(A|H_3) = .99$

Atunci

$$P(H_1|A) = \frac{P(A|H_1)P(H_1)}{\sum_n P(A|H_n)P(H_n)} = \frac{.5 \cdot .5}{.5 \cdot .5 + .8 \cdot .4 + .99 \cdot .1} = 0.37369, P(H_2|A) = \frac{.8 \cdot .4}{.5 \cdot .5 + .8 \cdot .4 + .99 \cdot .1} = 0.47833, P(H_3|A) = \frac{.99 \cdot .1}{.5 \cdot .5 + .8 \cdot .4 + .99 \cdot .1} = 0.14798$$

Cel mai probabil este că păcătosul este neutru, apoi că este un bisericos împins de Satana iar cel mai puțin probabil e să fie ateu.

4. **Probabilitatea condiționată de o partiție cel mult numărabilă.**

Fie $\mathbf{P} = (A_n)_n$ o partiție cel mult numărabilă a lui Ω . Atunci $P(B|\mathbf{P})$ este prin definiție variabila aleatoare $Y = \sum_n P(B|A_n) 1_{A_n}$ cu convenția de bun simț că dacă $P(A_n) = 0$, atunci $P(B|A_n) 1_{A_n} = 0$.

Observație importantă: $EP(B|\mathbf{P}) = P(B)$: într-adevăr, $EY = \sum_n P(B|A_n)E1_{A_n} = \sum_n P(B \cap A_n) = P(B)$

Observație importantă: dacă $\mathcal{F}$ este σ -algebra generată de $\mathbf{P}$, atunci Y este $\mathcal{F}$ -măsurabilă.

Mai mult, dacă X este o variabilă aleatoare, atunci notăm, abusiv, $Y = (X|\mathbf{P}) = \sum_n (Y|A_n) 1_{A_n}$ o variabilă aleatoare cu proprietatea că $P(Y \in B|\mathbf{P}) = P(X \in B|\mathbf{P}) = \sum_n P(X \in B|A_n) 1_{A_n}$.

Observație importantă: $E(X|\mathbf{P}) = \sum_n E(Y|A_n) P(A_n) = EY$ și, în plus, Y este $\mathcal{F}$ -măsurabilă.

5. Repartiția **condiționată**. Fie $Z = (X, Y)$ un vector aleator în care $Y \sim \begin{pmatrix} y_1 & y_2 & \dots \\ p_1 & p_2 & \dots \end{pmatrix}$ este discretă. Atunci notăm $(X|Y)$ variabila aleatoare $\sum_n (X|Y = y_n) 1_{(Y=y_n)}$. Dacă $\mathcal{F}$ este σ -algebra generată de Y , atunci $(X|Y)$ este de asemenea $\mathcal{F}$ -măsurabilă.

6. Media condiționată. **Abordarea riguroasă**. Fie $\mathcal{F}$ o σ -algebră inclusă în $\mathbf{K}$ și fie $X \in L^1(\Omega, \mathbf{K}, P)$. Atunci $E(X|\mathcal{F})$ este *prin definiție* o variabilă aleatoare, Y , cu proprietatea că Y este $\mathcal{F}$ -măsurabilă și $E(X1_A) = E(Y1_A)$ pentru orice $A \in \mathcal{F}$. Probabilitatea condiționată a mulțimii $B \in \mathbf{K}$, $P(B|\mathcal{F})$ este *prin definiție* variabila aleatoare, $Y = E(1_B|\mathcal{F})$, adică o variabilă aleatoare $\mathcal{F}$ -măsurabilă cu proprietatea că $E(Y1_A) = P(A \cap B)$ pentru orice $A \in \mathcal{F}$. Dacă $\mathcal{F}$ este σ -algebra generată de o partiție cel mult numărabilă, $\mathbf{P}$, atunci verificați (este imediat!) că $E(X|\mathcal{F}) = \sum_{H \in \mathbf{P}} E(X|H) 1_H$ iar $P(B|\mathcal{F}) = \sum_{H \in \mathbf{P}} P(B|H) 1_H$.

Exemplu. $\Omega = \mathbb{Z}_n^2$, $\mathbf{P} = \{\{j\} \times \mathbb{Z}_n : j \in \mathbb{Z}_n\}$, $B = \{(i, j) \in \Omega : i \leq j\}$. Atunci $P(B|\sigma(\mathbf{P})) = \sum_{j=0}^{n-1} \frac{n-j}{n} 1_{\{j\} \times \mathbb{Z}_n}$.

Dacă $\mathcal{F} = \sigma(Y)$ unde Y este o variabilă aleatoare, atunci orice variabilă aleatoare Z care este $\mathcal{F}$ -măsurabilă este de forma $X = h(Y)$. (Verificați pentru $X = 1_A$, apoi pentru $X = \sum_n a_n 1_{A_n}$).

Așadar $E(X|\mathcal{F})$ trebuie să fie o funcție de forma $h(Y)$ cu proprietatea că $E(Xg(Y)) = E(h(Y)g(Y))$ pentru orice g măsurabilă și mărginită (verificați! în definiția inițială $g = 1_A$, $A \in \sigma(Y) \iff A = Y^{-1}(B)$ cu B o mulțime boreliană de pe dreapta reală, deci $g = 1_B$; etc). De aceea se obișnuiește notația $E(X|Y)$ în loc de $E(X|\sigma(Y))$.

Definiție. Variabila aleatoare $E(X|Y)$ se numește regresia lui Y asupra lui X .

7. Proprietăți ale mediei condiționate

7.0 Liniaritate, monotonie

7.1 Dacă $\mathcal{F}_1 \subset \mathcal{F}_2$ atunci $E(E(X|\mathcal{F}_2)|\mathcal{F}_1) = E(X|\mathcal{F}_1)$ - proprietatea de proiecție. Caz particular: $E(E(X|\mathcal{F}_2)) = EX$

7.2 Dacă $Y \in L^\infty(\mathcal{F})$ atunci $E(XY|\mathcal{F}) = YE(X|\mathcal{F})$ - variabilele $\mathcal{F}$ -măsurabile se comportă precum constantele

7.3 Jensen. $E(f(X)|\mathcal{F}) \geq f(E(X|\mathcal{F}))$ dacă f este convexă și $f(X) \in L^1$

7.4 Beppo - Levi. Dacă $X_n \nearrow X$ și $X_1 \in L^1$ atunci $E(X_n|\mathcal{F}) \nearrow E(X|\mathcal{F})$ cu excepția posibilă a unei mulțimi neglijabile

7.5 Proprietatea de optim: dacă $X \in L^2$, atunci $E(X - E(X|\mathcal{F}))^2 \leq E(X - Y)^2$ pentru orice $Y \in L^2(\mathcal{F})$

Caz particular: $E(X - E(X|Y))^2 \leq E(X - g(Y))^2$ pentru orice g funcție măsurabilă cu proprietatea că $g(Y) \in L^2$.

De aceea, $E(X|Y)$ se mai numește *estimatorul Bayesian exact* dat de Y asupra lui X .

7. Formule pentru repartiția condiționată.

Uneori - în cazurile didactice - repartitia condiționată - deci și media/varianța condiționată etc se pot calcula.

7.1. Cazul discret. Vectorul este $Z = (X, Y)$. Fie $p_{X,Y}(i, j) = P(X = i, Y = j)$.

Atunci $p_{X|Y=j}(i) = \frac{P(X=i, Y=j)}{P(Y=j)} = \frac{p_{X,Y}(i, j)}{\sum_{\alpha} p_{X,Y}(\alpha, j)}$, $p_{Y|X=i}(j) = \frac{P(X=i, Y=j)}{P(X=i)} = \frac{p_{X,Y}(i, j)}{\sum_{\beta} p_{X,Y}(i, \beta)}$

7.2. Cazul absolut continuu. Densitatea lui Z este $p_{X,Y}$. Atunci:

densitatea lui X este $p_X(x) = \int_{-\infty}^{\infty} p_{X,Y}(x, t) dt$

densitatea lui Y este $p_Y(y) = \int_{-\infty}^{\infty} p_{X,Y}(s, y) ds$

densitatea lui $(X|Y = y)$ este $p_{X|Y=y}(x) = \frac{p_{X,Y}(x, y)}{\int_{-\infty}^{\infty} p_{X,Y}(x, t) dt}$

densitatea lui $(Y|X = x)$ este $p_{Y|X=x}(y) = \frac{p_{X,Y}(x, y)}{\int_{-\infty}^{\infty} p_{X,Y}(s, y) ds}$

Justificare. Stricto sensu, nu se poate scrie $P(Y \in B|X = x)$ deoarece $P(X = x) =$

0. Dar are sens să gândim $P(Y \leq y|X = x)$ ca fiind $\lim_{\varepsilon \rightarrow 0} \frac{P(Y \leq y|x-\varepsilon \leq X \leq x+\varepsilon)}{P(x-\varepsilon \leq X \leq x+\varepsilon)} = \lim_{\varepsilon \rightarrow 0} \frac{\int_{x-\varepsilon}^{x+\varepsilon} \int_{-\infty}^y p_{X,Y}(u, v) dudv}{\int_{x-\varepsilon}^{x+\varepsilon} \int_{-\infty}^{\infty} p_{X,Y}(u, v) dudv} = \lim_{\varepsilon \rightarrow 0} \frac{\int_{x-\varepsilon}^{x+\varepsilon} f(u) du}{2\varepsilon} = f(x)$. Presupunem

că acesta este cazul și, atunci avem mai departe $P(Y \leq y|X = x) = \frac{\int_{-\infty}^y f(x, v) dv}{\int_{-\infty}^{\infty} f(x, v) dv}$.

Dacă o derivăm în y , găsim densitatea $p_{Y|X=x}(y) = \frac{f(x, y)}{\int_{-\infty}^{\infty} f(x, v) dv}$

În aceste două situații este valabilă $\mathfrak{R}$

$E(g(X)|Y = y) = \sum g(x) p_{X|Y=y}(x) = \frac{\sum g(x) p_{X,Y}(x, y)}{\sum_{\alpha} p_{X,Y}(\alpha, y)}$ (cazul discret)

$E(g(X)|Y = y) = \int g(x) p_{X|Y=y}(x) dx = \int \frac{g(x) f(x, y)}{\int_{-\infty}^{\infty} f(x, v) dv} dx$ (cazul absolut continuu)

1. (a) i. A. Exerciții

1. Se da $p(x, y) = (ax + by) 1_{(0,1)}(x, y)$. Condiția ca p să fie densitate lui $Z = (X, Y)$, repartițiile marginale, media, covarianța, portofoliu optim = $\text{Argmin} U$ pentru $U(s, t) = E\xi - r \text{Var}(\xi)$ cu $\xi = sX + tY$

2. Aceeași problemă pentru $p(x, y, z) = (ax + by + cz) 1_{(0,1)}(x, y, z)$

3. Sau pentru $P \circ Z^{-1} = \text{Uniform}(\{(i, j) \in \mathbb{Z}_4^2 : i \leq j\})$, sau $\text{Uniform}(\{(i, j) \in \mathbb{Z}_4^2 : i + j \leq 4\})$

4. Sau pentru $X \sim \text{Polynomial}(4, p, q, r)$

5. Sau cât mai multe exerciții în două sau trei dimensiuni inventate de dv

$\mathcal{F}$

1.7 Lecția 7. Independența

1.7.1 A. Două obiecte

Definiții. Fie (Ω, K, P) un spațiu probabilitizat și $A, B \in K$.

1. Spunem că A este independent de B (și scriem $A \amalg B$) dacă și numai dacă $P(A \cap B) = P(A)P(B)$

Observație. Dacă $P(A) \neq 0$, atunci faptul că $A \amalg B$ este echivalent cu $P(B|A) = P(B)$. Intuitiv, apariția lui A nu afectează probabilitatea de apariție

a evenimentului B . Sau, obținerea unei informații asupra lui A nu are nici o valoare: nu schimbă datele problemei.

Observație. Evenimentul sigur $A = \Omega$ sau cel imposibil $A = \emptyset$ sunt independente de orice alt eveniment.

2. Fie $\mathbf{M}_1$ și $\mathbf{M}_2$ două familii de evenimente incluse în $\mathcal{K}$. Spunem că $\mathbf{M}_1$ și $\mathbf{M}_2$ sunt independente (și notăm $\mathbf{M}_1 \amalg \mathbf{M}_2$) dacă $A \amalg B$ pentru orice $A \in \mathbf{M}_1$ și $B \in \mathbf{M}_2$.

3. **Propoziția 1.** Dacă $\mathbf{M}_1 \amalg \mathbf{M}_2$, atunci U-sistemele generate vor fi din nou independente: $U(\mathbf{M}_1) \amalg U(\mathbf{M}_2)$. În particular, dacă $\mathbf{M}_1$ și $\mathbf{M}_2$ sunt stabile la intersecții finite, atunci σ -algebrele generate vor fi de asemenea independente: $\sigma(\mathbf{M}_1) \amalg \sigma(\mathbf{M}_2)$.

4. Fie $X : \Omega \rightarrow E, Y : \Omega \rightarrow F$ două variabile aleatoare, unde $(E, \mathbf{E})$ și $(F, \mathbf{F})$ sunt două spații măsurabile oarecare. Atunci spunem că X este independentă de Y (și scriem $X \amalg Y$) dacă și numai dacă σ -algebrele generate sunt independente, adică dacă $X^{-1}(\mathbf{E}) \amalg X^{-1}(\mathbf{F})$.

Formulări echivalente

a. $X \amalg Y$

b. $\sigma(X) \amalg \sigma(Y)$

c. $P(X \in A, Y \in B) = P(X \in A)P(Y \in B)$ pentru orice $A \in \mathbf{E}, B \in \mathbf{F}$.

d. $P \circ (X, Y)^{-1} = P \circ X^{-1} \otimes P \circ Y^{-1}$

5. **Cum verificăm dacă $X \amalg Y$?**

a. Algoritm general: verificăm egalitatea $P(X \in A, Y \in B) = P(X \in A)P(Y \in B)$ pentru orice $A \in \mathbf{E}, B \in \mathbf{F}$.

b. În cazul variabilelor aleatoare reale: de verificat că $P(X \leq x, Y \leq y) = P(X \leq x)P(Y \leq y)$ pentru orice $x, y \in \mathbb{R}$.

Adică dacă $F_{X,Y} = F_X \otimes F_Y$.

c. Dacă variabilele sunt discrete: de verificat că $P(X = x, Y = y) = P(X = x)P(Y = y)$ pentru orice $x \in E, y \in F$

d. În cazul real: dacă X este discretă, de verificat că $P(X = x, Y \leq y) = P(X = x)P(Y \leq y)$ pentru orice $x, y \in \mathbb{R}$

e. În cazul real: dacă (X, Y) are densitatea p , de verificat că se poate scrie $p(x, y) = p_1(x)p_2(y)$

Adică dacă $p_{X,Y} = p_X \otimes p_Y$. Dacă notăm $\text{supp}(p) = Cl((x, y) : p(x, y) > 0)$, o condiție necesară ca acest lucru să se întâmple este ca $\text{supp}(p)$ să fie de forma $A \times B$.

6. **Proprietăți.**

a. Dacă X, Y sunt independente, atunci $f(X)$ și $g(Y)$ sunt de asemenea independente pentru orice f, g măsurabile.

Precis: dacă $X : \Omega \rightarrow E, Y : \Omega \rightarrow F$ sunt independente și $f : E \rightarrow E', g : F \rightarrow F'$ sunt măsurabile, atunci $f(X) \amalg g(Y)$

Consecințe: Dacă $E = \mathbb{R}^n, F = \mathbb{R}^m$ atunci $1_A(X) \amalg 1_B(Y)$ pentru orice $A \in \mathbf{E}, B \in \mathbf{F}, a'X \amalg b'Y$ pentru orice $a \in \mathbb{R}^n, b \in \mathbb{R}^m$ etc

b. Dacă $X \in L^1$ și $Y \in L^1$ sunt independente, atunci $XY \in L^1$; (deoarece $E|XY| = E|X|E|Y|$, vezi formula de transport) și sunt și necorelate. Independența implică necorelare. Reciproc, dacă sunt necorelate, nu rezultă că

sunt independente - de exemplu dacă (X, Y) este repartizat uniform pe discul unitate . Totuși, dacă X și Y au doar două valori, necorelarea implică independență.

c. Dacă X, Y sunt independente, $g : \mathbb{R}^2 \rightarrow \mathbb{R}$ este măsurabilă, $g(X, Y) \in L^1$, atunci $Eg(X, Y|X = x) = \int g(x, y) dF_Y(y)$

Ca atare avem de exemplu, $P(X \geq Y) = E(P(X \geq Y|X)) = EF_Y(X) = \int F_Y(x) dF_X(x)$ etc.

Dacă, de exemplu, X este repartizată $\text{Exp}(\lambda)$, $P(X \geq Y) = EP(X \geq Y|Y) = Ee^{-\lambda Y} = m_{Y_+}(\lambda)$, unde m_{Y_+} este mgf-ul lui Y_+ .

d. Dacă X este independentă de Y , atunci $E(X|Y) = EX$. Sau, reformulat: Dacă X este independentă de σ -algebra $\mathbf{F}$, atunci $E(X|\mathbf{F}) = EX$. Într-adevăr, măsurabilitatea este evidentă, la fel ca și egalitatea $E(X1_B) = E((EX)1_B) = P(B)EX$. Reciproca este falsă: dacă $E(X|Y) = EX$ nu rezultă că $X \perp Y$. De exemplu dacă $(X, Y) \sim \begin{pmatrix} (0,0) & (1,0) & (2,0) & (1,1) & (2,0) & (2,1) & (2,2) \\ \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{3} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} \end{pmatrix}$, atunci $(X|Y=0) \sim (X|Y=1) \sim \text{Uniform}(\mathbb{Z}_3)$, $(X|Y=1) = 1$ deci $E(X|Y) = EX = 1$ deși evident că $X \sim \begin{pmatrix} 0 & 1 & 2 \\ \frac{2}{9} & \frac{5}{9} & \frac{2}{9} \end{pmatrix}$ nu este independentă de $Y \sim \text{Uniform}(\mathbb{Z}_3)$.

1.7.2 B. O mulțime oarecare obiecte

Definiții

1. **Evenimente.** Evenimentele $(A_\alpha)_{\alpha \in I}$, unde I este o mulțime oarecare de indici sunt independente dacă $P\left(\bigcap_{\beta \in J} A_\beta\right) = \prod_{\beta \in J} P(A_\beta)$ pentru orice mulțime de indici $J \subset I$ care este finită.

2. **Familii de mulțimi.** Fie $(\mathbf{M}_\alpha)_{\alpha \in I}$ o familie de mulțimi din $\mathbf{K}$. Ele sunt independente dacă $P\left(\bigcap_{\beta \in J} A_\beta\right) = \prod_{\beta \in J} P(A_\beta)$ pentru orice oricare mulțime finită de indici $J \subset I$ și $A_\beta \in \mathbf{M}_\alpha$.

Propoziția 2. Dacă mulțimile $(\mathbf{M}_\alpha)_{\alpha \in I}$ sunt independente, atunci și U-sistemele generate vor fi independente. Dacă familiile $\mathbf{M}_\alpha$ sunt și stabile la intersecții finite, atunci $(\sigma(\mathbf{M}_\alpha))_{\alpha \in I}$ vor fi independente.

3. **Variabile aleatoare.** Variabilele aleatoare $(X_\alpha)_{\alpha \in I}$ sunt independente dacă σ -algebrele generate $(\sigma(X_\alpha))_{\alpha \in I}$ sunt independente.

4. **Proprietatea de asociativitate.** Dacă $(\mathbf{F}_\alpha)_{\alpha \in I}$ sunt σ -algebre independente și $\Pi = (\Delta_\beta)_{\beta \in J}$ este o partiție a mulțimii de indici I , atunci

σ -algebrele $\left(\sigma\left(\bigcup_{\alpha \in \Delta_\beta} \mathbf{F}_\alpha\right)\right)_{\beta \in J}$ vor fi de asemenea independente. Sau, în termeni de variabile aleatoare: Dacă $(X_\alpha)_{\alpha \in I}$ sunt variabile aleatoare independente, $\Pi = (\Delta_\beta)_{\beta \in J}$ este o partiție a mulțimii de indici I , $g_\beta : \mathbb{R}^{\Delta_\beta} \rightarrow \mathbb{R}$ sunt măsurabile, atunci și variabilele aleatoare $\left(g_\beta\left((X_\alpha)_{\alpha \in \Delta_\beta}\right)\right)_\beta$ vor fi de asemenea

independente

1.7.3 C. Șiruri de obiecte

Cum verificăm dacă un șir de variabile aleatoare sunt independente?

Suficient să verificăm dacă $P(X_1 \leq x_1, \dots, X_n \leq x_n) = P(X_1 \leq x_1)P(X_2 \leq x_2) \dots P(X_n \leq x_n)$ pentru orice n . Dacă unele din ele sunt discrete, e suficient să punem "=" în loc de " $\leq$ "

Probabilitatea produs. Teorema lui Kolmogorov.

Fie $(\Omega_n, K_n, P_n)_n$ un șir de spații probabilizate, $\Omega = \prod_{n \geq 1} \Omega_n, K = \otimes_{n \geq 1} K_n$.

Pe acest spațiu măsurabil există o unică probabilitate cu u proprietatea că $P(A_1 \times A_2 \times \dots) = \prod_{n \geq 1} P_n(A_n)$. Ea se numește peobabilitatea produs și se notează cu $P = \otimes_{n \geq 1} P_n$.

Fapt 1: variabilele aleatoare $(X_n)_{n \geq 1}$ sunt independente dacă $(X_1, \dots, X_n)$ sunt independente pentru orice $n \geq 2$

Dacă ele au aceeași repartiție, se numesc independente și identic repartizate și scriem "fie $(X_n)_{n \geq 1}$ " iid.

Fapt 2: Fie $(E_n, \mathbf{E}_n)_n$ spații măsurabile și $F_n : E_n \rightarrow [0, 1]$ un șir de repartiții. Atunci există un spațiu probabilizat (Ω, K, P) și un șir de variabile aleatoare $X_n : \Omega \rightarrow E_n$ care sunt independente și au exact repartițiile F_n .

Se ia $\Omega = \prod_{n \geq 1} E_n, K = \otimes_{n \geq 1} \mathbf{E}_n, P = \otimes_{n \geq 1} P_n, \mathbf{X}_n((x_k)_k) = x_n$.

Fapt 3. Dacă $(E_n, \mathbf{E}_n) = (\mathbb{R}, B(\mathbb{R}))$ atunci se poate lua mai concret $\Omega = [0, 1]^\infty, K = B([0, 1]^\infty), P = \lambda^\infty$, (unde λ este măsura Lebesgue pe $[0, 1]$) și $\mathbf{X}_n((x_k)_k) = F_n^{-1}(x_n)$, unde F_n^{-1} sunt cuantilele lui funcției de repartiție X_n .

Așadar enunțul "Fie $(X_n)_n$ un șir de variabile aletoare iid cu repartiția F are întotdeauna sens"

Exemplu. Fie $\Omega = (0, 1), K = B((0, 1)), p \geq 2$ un număr natural. Orice număr $\varpi \in \Omega$ se poate scrie în baza p sub forma

$\varpi = \sum_{n=1}^{\infty} X_n(\varpi) p^{-n}$. Atunci variabilele aleatoare $(X_n)_n$ sunt iid repartizate

$\text{Uniform}(\mathbb{Z}_p)$. În plus, variabilele aleatoare $\left\{ X_1, X_n, \dots, X_n, X_{n+1} = \left(\sum_{k=1}^n X_k \right) \pmod{p} \right\}$

sunt $n+1$ variabile aleatoare au proprietatea că NU sunt independente, deși oricare n din ele sunt independente.

Fapt 4. Dacă $(X_n)_n$ sunt variabile aleatoare independente din L^2 , *necorelate*,

atunci $\text{Var}\left(\sum_{k=1}^n X_k\right) = \sum_{k=1}^n \text{Var}(X_k)$. Deci cu atît mai mult egalitatea este vala-

bilă dacă ele sunt independente. Ca atare $\text{Var}\left(\frac{1}{n} \sum_{k=1}^n X_k\right) = \frac{1}{n} \sum_{k=1}^n \text{Var}(X_k)$. În

cazul particular cînd $(X_n)_n$ sunt i.i.d., atunci $\text{Var}\left(\frac{1}{n} \sum_{k=1}^n X_k\right) = \frac{\text{Var}(X_1)}{n} \xrightarrow{n \rightarrow \infty} 0$

Exerciții.

1. Dacă $X \perp Y$ atunci $P(X > x, Y > y) = P(X > x)P(Y > y)$. Interpretare dacă X, Y sunt timpi de viață.

2. Dacă $P(X > x, Y > y) \geq P(X > x)P(Y > y)$ pentru orice x, y variabilele X și Y se numesc pozitiv dependente, iar dacă este valabilă inegalitatea inversă, se numesc negativ dependente. Verificați că dacă $X \perp Y$ atunci $\min(X, Y)$ și $\max(X, Y)$ sunt pozitiv dependente.

3. Dacă (X, Y) are densitatea $p(x, y) = (ax + by) 1_{(0,1)^2(x,y)}$ cu $a, b \geq 0, a + b = 2$ atunci X și Y sunt negativ dependente

4. Verificați dacă $[X]$ și $\{X\}$ sunt independente dacă X este repartizată exponențial sau Uniform(a, b)

5. Verificați că dacă $X = (X_j)_{1 \leq j \leq n}$ este un vector cu toate componentele independente, atunci $m_X(t) = \prod_{j=1}^n m_{X_j}(t_j)$ și $\phi_X(t) = \prod_{j=1}^n \phi_{X_j}(t_j)$; dacă are valori din $\mathbb{N}^n$, atunci $g_X(x) = \prod_{j=1}^n g_{X_j}(x_j)$

6. Verificați că dacă $X = (X_j)_{1 \leq j \leq n}$ este un vector cu toate componentele independente și $S = \sum_{j=1}^n X_j$, atunci $m_S(t) = \prod_{j=1}^n m_{X_j}(t)$ și $\phi_X(t) = \prod_{j=1}^n \phi_{X_j}(t)$;

dacă are valori din $\mathbb{N}^n$, atunci $g_X(x) = \prod_{j=1}^n g_{X_j}(x)$. Ce rezultă în cazurile particulare când $X_j \sim N(\mu_j, \sigma_j^2)$, $X_j \sim \text{Binomial}(n_j, p)$, $X_j \sim \text{Poisson}(\lambda_j)$, $X_j \sim \text{Exponential}(\lambda)$?

7. Fie X, Y variabile aleatoare mărginite. Presupunem că $EX^m Y^n = EX^m EY^n$ pentru orice $m, n \geq 1$. Atunci $X \perp Y$

$$\text{Hint. } \phi_{X,Y}(s, t) = Ee^{i(sX+tY)} = \sum_n \frac{i^n}{n!} E(sX + tY)^n = \sum_n \frac{i^n}{n!} \sum_{k=0}^n C_n^k s^{n-k} t^k EX^{n-k} EY^k = \sum_n \frac{i^n}{n!} \sum_{k=0}^n C_n^k s^{n-k} t^k EX^{n-k} EY^k$$

$$\phi_X(s) \phi_Y(t) = Ee^{isX} Ee^{itY} = \sum_m \frac{i^m}{m!} s^m t^k EX^m \sum_k \frac{i^k}{k!} EY^k = \sum_{m,k} \frac{i^{m+k}}{(m+k)!} C_{m+k}^k s^m t^k EX^m EY^k$$

Cele două repartiții au aceeași funcție caracteristică, deci coincid (Teorema de unicitate)

De ce am pus condiția să fie mărginite? Ca să putem comuta media cu suma.

8. Vectorul $Z = (X, Y)$ este repartizat $\begin{pmatrix} (-1, 0) & (0, 1) & (1, 0) & (0, -1) \\ \frac{1}{4} & \frac{1}{4} & \frac{1}{4} & \frac{1}{4} \end{pmatrix}$.

Găsiți repartițiile marginale, media, covarianța, funcția de repartiție, funcția de supraviețuire $\underline{F}(x, y) = P(X > x, Y > y)$, $(Y|X)$, $(X|Y)$, $E(X^m Y^n) - E(X^m)E(Y^n)$ etc

1.8 Lecția 8. Convergența variabilelor aleatoare. Legea Numerelor Mari

1. În orice spațiu cu măsură $(E, \mathbf{E}, \mu)$ putem construi spațiile Banach $L^p(E, \mathbf{E}, \mu) = \{X : E \rightarrow \mathbb{R} : \int |X|^p d\mu \neq \infty\}$, $1 \leq p \leq \infty$.

Spațiile probabilitate nu fac excepție: Fie $(X_n)_n$, X variabile aleatoare din $L^p(\Omega, \mathbf{K}, P)$. Spunem că X_n converge la X în L^p (și scriem $X_n \xrightarrow{L^p} X$) dacă $\|X_n - X\|_p \rightarrow 0$

Ce este special la spațiile probabilizate este inegalitatea normelor. Ea arată că

Propoziție. Dacă $1 \leq p \leq q$ și $(X_n)_n, X$ sunt variabile aleatoare din L^q , și $X_n \xrightarrow{L^q} X$ atunci $X_n \xrightarrow{L^p} X$

2. De asemenea, în orice spațiu cu măsură $(E, \mathbf{E}, \mu)$ se introduce convergența în măsură:

Definiție. Spunem că X_n converge la X în măsură dacă $\mu(\{|X_n - X| > \varepsilon\}) \rightarrow 0$ pentru orice $\varepsilon > 0$ și scriem $X_n \xrightarrow{\mu} X$. În general nu este nici o legătură între aceste tipuri de convergență: de exemplu, pe $(\mathbb{R}, \mathbf{B}(\mathbb{R}), \lambda)$ șirul de funcții măsurabile $f_n(x) = e^{-nx} 1_{(0, \infty)}(x)$ converge la 0 în orice $L^p(\mathbb{R}, \mathbf{B}(\mathbb{R}), \lambda)$ cu $1 \leq p < \infty$ și totuși pentru orice $\varepsilon > 0$ este evident că $\lambda(\{x : |f_n(x)| > \varepsilon\}) = \infty$.

În spațiile probabilizate există o implicație

Propoziție. Fie $(X_n)_n, X$ variabile aleatoare din $L^p(\Omega, \mathbf{K}, P), 1 \leq p \leq \infty$. Atunci $X_n \xrightarrow{L^p} X \implies X_n \xrightarrow{P} X$

Într-adevăr, $P(|X_n - X| > \varepsilon) \leq \frac{\|X_n - X\|_p^p}{\varepsilon^p} \rightarrow 0$ dacă $n \rightarrow \infty$.

3. La fel, în orice spațiu cu măsură $(E, \mathbf{E}, \mu)$ se introduce și convergența aproape peste tot, notată a.p.t.:

spunem că X_n converge aproape peste tot dacă $\mu(\{\liminf X_n \neq \limsup X_n\}) = 0$. Aceași definiție este valabilă și în cazul spațiilor probabilizate, numai că aici notăm a.s. (= aproape sigur = almost surely) în loc de a.p.t.. Așadar

$$X_n \xrightarrow{a.s.} X \iff \mu(\{\liminf X_n = \limsup X_n = X\}) = 1$$

În general, pe un spațiu cu măsură oarecare, convergența a.p.t. NU garantează convergența în măsură (vezi exemplul de la 2). Totuși, în cazul spațiilor probabilizate avem

Propoziție. Dacă $X_n \xrightarrow{a.s.} X$ atunci $X_n \xrightarrow{P} X$

Demonstrație. Evident, înlocuind X_n cu $X_n - X$ putem presupune că $X = 0$.

Fie $A = \{X_n \xrightarrow{a.s.} 0\}$

$$\begin{aligned} \text{Așadar știm că } P(A^c) &= 0 \quad P(A^c) = P(\exists \varepsilon > 0, \forall n > 0, \exists n_1 > n \text{ ca } |X_n| > \varepsilon) = \\ &= P(\exists m > 0, \forall n > 0, \exists k > 0 \text{ ca } |X_{n+k}| > \frac{1}{m}) = P\left(\bigcup_{m=1}^{\infty} \bigcap_{n=1}^{\infty} \bigcup_{k=1}^{\infty} \{|X_{n+k}| > \frac{1}{m}\}\right) \end{aligned}$$

Cum șirul de mulțimi $\left(\bigcap_{n=1}^{\infty} \bigcup_{k=1}^{\infty} \{|X_{n+k}| > \frac{1}{m}\}\right)_m$ este crescător, aplicînd proprietatea de continuitate a probabilității găsim că $P(A^c) = \lim_m P\left(\bigcap_{n=1}^{\infty} \bigcup_{k=1}^{\infty} \{|X_{n+k}| > \frac{1}{m}\}\right) =$

0, așadar $P\left(\bigcap_{n=1}^{\infty} \bigcup_{k=1}^{\infty} \{|X_{n+k}| > \frac{1}{m}\}\right) = 0$ pentru orice $m \geq 1$. Dar șirul de

mulțimi $\left(\bigcup_{k=1}^{\infty} \{|X_{n+k}| > \frac{1}{m}\}\right)_n$ este descrescător, așadar $P\left(\bigcap_{n=1}^{\infty} \bigcup_{k=1}^{\infty} \{|X_{n+k}| > \frac{1}{m}\}\right) =$

$\lim_n P\left(\bigcup_{k=1}^{\infty} \{|X_{n+k}| > \frac{1}{m}\}\right) = 0$; deci cu atît mai mult $\lim_n P(\{|X_n| > \frac{1}{m}\}) = 0$,

adică $X_n \xrightarrow{P} 0$.

Reciproc nu este adevărat, după cum ne putem convinge cu exemplul urmă-

tor: orice număr natural n se poate scrie sub forma $n = 2^k + j$ unde $0 \leq j \leq 2^k - 1$. Luăm $\Omega = (0, 1)$, P = măsura Lebesgue, $A_n = \left(\frac{j}{2^k}, \frac{j+1}{2^k}\right)$, $X_n = 1_{A_n}$. De exemplu primele mulțimi A_n sunt $(0, 1)$, $(0, \frac{1}{2})$, $(\frac{1}{2}, 1)$, $(0, \frac{1}{4})$, $(\frac{1}{4}, \frac{2}{4})$, $(\frac{2}{4}, \frac{3}{4})$, $(\frac{3}{4}, 1)$,

Atunci $\limsup X_n = 1$ (a.s.), $\liminf X_n = 0$ (a.s.) și totuși $X_n \xrightarrow{P} 0$

4. **Legea slabă a numerelor mari.** Dacă $(X_n)_n \in L^2$ sunt necorelate atunci $\frac{X_1 + \dots + X_n}{n} \xrightarrow{P} \mu$, unde $\mu = EX_1$.

Evident: după ce centram variabilele X_n înlocuindu-le cu $Y_n = X_n - \mu$: $\left\| \frac{X_1 + \dots + X_n}{n} - \mu \right\|_2^2 = \text{Var}\left(\frac{Y_1 + \dots + Y_n}{n}\right) = \frac{\sigma^2}{n} \rightarrow 0$ unde am notat cu $\sigma^2 = \text{Var}(X_1)$.

De ce se numește legea slabă? Pentru că asigură DOAR convergența în probabilitate, care este mai slabă decât cea aproape sigură.

5. **Legea tare a numerelor mari.** Dacă $(X_n)_n \in L^1$ sunt i.i.d. atunci $\frac{X_1 + \dots + X_n}{n} \xrightarrow{a.s.} \mu$, unde $\mu = EX_1$. Mai mult, convergența are loc și în L^1 .

Sunt mai multe demonstrații clasice. Cea mai puternică se bazează pe

TEOREMA ERGODICA BIRKHOFF. Fie $(E, \mathbf{E}, \Pi)$ un spațiu probabilizat și $t: E \rightarrow E$ o funcție măsurabilă cu proprietățile:

a. $\Pi(t^{-1}(A)) = \Pi(A)$ pentru orice $A \in \mathbf{E}$.

b. Dacă $t^{-1}(A) = A$, atunci $\Pi(A) \in \{0, 1\}$

Fie, de asemenea, $f \in L^1(E, \mathbf{E}, \Pi)$.

Atunci $\frac{f + f(t) + f(t^2) + f(t^3) + \dots + f(t^{n-1})}{n}$ converge Π -aproape sigur și în L^1 la $\int f d\Pi$. Am notat $t^2 = t \circ t$, $f^3 = t \circ t \circ t$,

Observație. O funcție t cu proprietățile a. și b. se numește **ergodică**.

La noi vom lua $E = \mathbb{R}^\infty$, $\mathbf{E} = B(\mathbb{R})^\infty$, $\Pi = F^\infty$ unde $F = P \circ X_n^{-1}$ este repartiția comună a variabilelor i.i.d $(X_n)_n$, $t: E \rightarrow E$ va fi shiftul $t(x_1, x_2, x_3, \dots) = (x_2, x_3, x_4, \dots)$ care evident are proprietatea a.

Acceptăm că are proprietatea b. Apoi considerăm vectorul aleator $X: \Omega \rightarrow E$, $X = (X_n)_n$ și observăm că $P \circ X^{-1} = \Pi$. Așadar pentru orice funcție măsurabilă $f \in L^1(E, \mathbf{E}, \Pi)$ avem $\frac{f + f(t) + f(t^2) + f(t^3) + \dots + f(t^{n-1})}{n} \xrightarrow{a.s.} \int f d\Pi = \int f d(P \circ X^{-1}) = Ef(X)$. Deci $\frac{f + f(t) + f(t^2) + f(t^3) + \dots + f(t^{n-1})}{n}(X) \xrightarrow{a.s.} Ef(X)$.

Legea tare este un caz foarte particular în care se ia $f((x_n)_n) = x_1$: atunci $\frac{f + f(t) + f(t^2) + f(t^3) + \dots + f(t^{n-1})}{n}(X) = \frac{X_1 + \dots + X_n}{n}$.

Demonstrăm acum că shiftul t are proprietatea b.

LEMA. 5.1.

1. Fie $(E, \mathbf{E}, \Pi)$ un spațiu probabilizat, $t: E \rightarrow E$ o funcție măsurabilă cu proprietatea că $P(t^{-1}(A)) = P(A)$ pentru orice $A \in \mathbf{M}$ și $\mathbf{M} \subset \mathbf{E}$ o familie de submulțimi. Presupunem că $P(A \cap t^{-n}(B)) \rightarrow P(A)P(B)$ pentru orice $A, B \in \mathbf{M}$. Atunci $P(A \cap t^{-n}(B)) \rightarrow P(A)P(B)$ pentru orice $A, B \in u(\mathbf{M})$ unde $u(\mathbf{M})$ este u-sistemul generat.

2. Dacă $\mathbf{M}$ este stabil la intersecții finite, atunci afirmația este valabilă pentru orice $A, B \in \sigma(\mathbf{M})$

3. Dacă în plus $\sigma(\mathbf{M}) = \mathbf{E}$, atunci egalitatea $t^{-1}(A) = A$ implică $P(A) \in \{0, 1\}$, adică t este aplicație ergodică.

Demonstrație.

1. Fie $A \in \mathbf{M}$ fixat și $\mathbf{C}_A = \{B \in \mathbf{E} : P(A \cap t^{-n}(B)) \rightarrow P(A)P(B)\}$. Atunci $\mathbf{C}_A$ este un u-sistem care conține pe $\mathbf{M}$. (singurul lucru mai delicat este să arătăm că dacă $(B_k)_k$ este un șir de elemente disjuncte din $\mathbf{C}_A$, atunci și reuniunea $\bigcup B_k$ este tot în $\mathbf{C}_A$. Adică dacă $P(A \cap t^{-n}(B_k)) \rightarrow P(A)P(B_k)$, atunci și $\sum_k P(A \cap t^{-n}(B_k)) \rightarrow \sum_k P(A)P(B_k)$, lucru care rezultă din teorema Lebesgue cu dominarea $P(A \cap t^{-n}(B_k)) \leq P(t^{-n}(B_k)) = P(B_k)$)
În concluzie dacă $A \in \mathbf{M}$ și $B \in \sigma(\mathbf{M})$, atunci $P(A \cap t^{-n}(B)) \rightarrow P(A)P(B)$.
Fie $\mathbf{C} = \{A \in \mathbf{E} : P(A \cap t^{-n}(B)) \rightarrow P(A)P(B) \text{ pentru orice } B \in \mathbf{u}(\mathbf{M})\}$. Atunci $\mathbf{C}$ conține pe $\mathbf{M}$ și este de asemenea un u-sistem. (folosim acum dominarea $P(A_k \cap t^{-n}(B)) \leq P(A_k)$)
2. Evident
3. Dacă $t^{-1}(B) = B$, atunci $t^{-n}(B) = B$ deci convergența $P(A \cap t^{-n}(B)) \rightarrow P(A)P(B)$ devine $P(A \cap B) = P(A)P(B)$. Dacă luăm $A = B$ (e voie, căci $\sigma(\mathbf{M}) = \mathbf{E}$!) atunci avem $P(B) = P^2(B)$.

Observație. O funcție t cu proprietatea din Lemă se numește **funcție mixing**.

LEMA 5.2. Shiftul canonic $t : \mathbb{R}^\infty \rightarrow \mathbb{R}^\infty$ este mixing față de probabilitatea $\Pi = F^\infty$.

Demonstrație.

σ -algebra produs este generată de mulțimea $\mathbf{M} = \{A_1 \times A_2 \times \dots \times A_k \times \mathbb{R} \times \mathbb{R} \times \dots : k \geq 1, A_j \in B(\mathbb{R})\}$. Dacă $A, B \in \mathbf{M}$ și $B = B_1 \times B_2 \times \dots \times B_k \times \mathbb{R} \times \mathbb{R} \times \dots$, atunci $t^{-n}(B) = \mathbb{R} \times \mathbb{R} \times \dots \times \mathbb{R} \times B_1 \times B_2 \times \dots \times B_k \times \mathbb{R} \times \mathbb{R} \times \dots$, (pe primele n poziții este $\mathbb{R}$); deci pentru n destul de mare $A \cap t^{-n}(B) = A_1 \times A_2 \times \dots \times A_k \times \mathbb{R} \times \mathbb{R} \times \dots \times \mathbb{R} \times B_1 \times B_2 \times \dots \times B_k \times \mathbb{R} \times \mathbb{R} \times \dots$, așadar $P(A \cap t^{-n}(B))$ este chiar egal cu $P(A)P(B)$

Cu aceasta legea numerelor mari ca aplicație a teoremei lui Birkhof este complet demonstrată.

1.8.1 6. Consecințe ale Legii tari a numerelor mari.

6.1. Metoda Monte Carlo

Dacă vrem să calculăm o integrală de forma $\int f 1_C d\lambda^n$ unde $C \subset \mathbb{R}^n$ este o mulțime cu proprietatea că $\lambda^n(C) \in (0, \infty)$ putem observa că ea se scrie sub forma $\int f 1_C d\lambda^n = \lambda^n(C) E f(X)$ cu X un vector repartizat uniform pe C . Atunci avem $\int f 1_C d\lambda^n = \lambda^n(C) \left(a.s. - \lim_N \frac{f(X_1) + \dots + f(X_N)}{N} \right)$ unde $(X_n)_n$ este un șir de v.a. i.i.d cu repartiția Uniform(C)

Problema dificilă este cum se poate simula un asemenea șir. Uneori este simplu.

6.2. Teorema fundamentală a statisticii.

Fie $(X_n)_n$ un șir de variabile aleatoare i.i.d. Variabila aleatoare $F_n(x) = \frac{1_{(X_1 \leq x)} + 1_{(X_2 \leq x)} + \dots + 1_{(X_n \leq x)}}{n}$ se numește funcția de repartiție empirică după n observații. Legea tare a numerelor mari ne spune că $F_n(x) \xrightarrow{a.s.} F(x)$ unde $F(x) = E 1_{(X_1 \leq x)} = P(X_1 \leq x)$

Interpretare: *funcțiile de repartiție empirice converg a.s. la funcția de repartiție teoretică.*

Teorema lui Glivenco: $\sup_x |F_n(x) - F(x)| \xrightarrow{a.s.} 0$

Interpretare: *funcțiile de repartiție empirice converg UNIFORM a.s. la funcția de repartiție adevărată.*

Exemplu. Se aruncă două puncte la întâmplare într-un cerc de rază 1. Să se calculeze distanța medie dintre ele.

Soluție analitică. Fie $Z = (X, Y)$ și $Z' = (X', Y')$ doi vectori iid repartizați $\text{Uniform}(C)$ cu $C = \{(x, y) : x^2 + y^2 \leq 1\}$ și fie $D = \|Z - Z'\|$

Atunci avem, din formula de transport $E\|Z - Z'\| = E\sqrt{(X - X')^2 + (Y - Y')^2} =$
 $\frac{1}{\pi^2} \int \sqrt{(x - x')^2 + (y - y')^2} 1_C(x, y) 1_C(x', y') dx dx' dy dy'$

$$= \frac{1}{\pi^2} \int_{-1}^1 \int_{-1-\sqrt{1-x^2}}^{\sqrt{1-x^2}-\sqrt{1-x^2}} \sqrt{(x - x')^2 + (y - y')^2} dy dy' dx dx'$$

Este o integrală care nu se poate calcula

Simulăm un vector repartizat $\text{Uniform}(C)$ prin metoda următoare, numită

a respingerii:

- luăm X, Y independente repartizate $\text{Uniform}(-1, 1)$.

- verificăm dacă $X^2 + Y^2 \leq 1$.

Dacă DA, reținem $Z = (X, Y)$

Dacă NU, repetăm.

Algoritmul dă rezultate bune dacă putem încadra mulțimea C într-un dreptunghi de forma $I \times J$ cu $I, J \subset \mathbb{R}$ intervale mărginite în așa fel încât raportul $\frac{\lambda^2(C)}{\lambda(I)\lambda(J)}$ să nu fie prea mic.

Formal, se ia $U \sim \text{Uniform}((0, 1)^2)$ (e simplu) și se pune $Z = (U|U^{-1}(C))$

Dupa cum am vazut in lectia 6.2 Z este un vector aleator cu proprietatea ca

$$P(Z \in B) = P(U \in B | U \in C) = \frac{\lambda^2(U \cap C)}{\lambda^2(C)}$$

Un script R care simuleaza N asemenea vectori aleatori este

`n=10000`

`u=2*runif(n)-1;v=2*runif(n)-1;w=which(u^2+v^2<1);x=u[w];y=v[w]`

`up=2*runif(n)-1;vp=2*runif(n)-1;wp=which(up^2+vp^2<1);xp=up[wp];yp=vp[wp]`


`N=min(length(x),length(xp))`

`X=x[1:N];Y=y[1:N];Xp=xp[1:N];Yp=yp[1:N]`

`D=sqrt((X-Xp)^2+(Y-Yp)^2);summary(D)`

Explicație. n este numărul de vectori $(U_j, V_j) \sim \text{Uniform}((0, 1)^2)$ simulați; în urma testului $U_j^2 + V_j^2 \leq 1$ din ei se rețin vectorii (X_j, Y_j) ; se repetă cu vectorii (U'_j, V'_j) din care se rețin vectorii (X'_j, Y'_j) .

N este numărul de vectori aleatori care au trecut testul de apartenență în C . Cu ajutorul lor se calculează distanțele $D_j = \sqrt{(X_j - X'_j)^2 + (Y_j - Y'_j)^2}$ și li se face apoi sumarul.



Rezultate: $\text{Min} = \min D_j$ este minimul empiric: cu legea tare a numerelor mari tinde aproape sigur la $\text{ess inf } D = 0$

1st Qu. = $F_n^{-1}(\frac{1}{4})$, unde F_n este repartiția empirică a lui D după N probe;

tinde la $F^{-1}(\frac{1}{4})$ unde F este repartiția lui D

Median = mediana empirică a lui D , tinde la mediana teoretică

Mean = media empirică a lui D , tinde la ED

3rd Qu. = $F_n^{-1}(\frac{3}{4}) \xrightarrow{a.s.} F^{-1}(\frac{3}{4})$

Max = $\max(D_j) \xrightarrow{a.s.} \text{ess sup } D = 2$

Min.	1st Qu.	Median	Mean	3rd Qu.
Max.				
0.004957	0.575500	0.889100	0.906700	1.226000
0.01565	0.58110	0.89570	0.91090	1.22700
0.01315	0.57970	0.89000	0.90500	1.21900

0.002263	0.573700	0.888600	0.904800	1.221000
0.001696	0.575100	0.892900	0.906600	1.224000

Dar dacă am arunca punctele în pătratul unitate? Formal, am avea de

calculat $ED = \int_0^1 \int_0^1 \int_0^1 \int_0^1 \sqrt{(x-x')^2 + (y-y')^2} dy dy' dx dx'$ care pare mai simplă;

nu cred că se poate face.

Simularea este mult mai simplă

`x=runif(n);y=runif(n);xp=runif(n);yp=runif(n);d=sqrt((x-xp)^2+(y-yp)^2;summary(d)`

Vedeți ce iese.

1.9 Lecția 9. Convoluția, convergența repartițiilor și Teorema Limită Centrală

1.9.1 Convoluția

Fie X, Y două variabile aleatoare. Dacă se știe repartiția lor (notată cu F și G), atunci nu se poate spune nimic despre repartiția sumei $X + Y$, decât dacă știm repartiția comună a vectorului (X, Y) . În cazul cel mai simplu, dacă presupunem că X și Y sunt independente, atunci repartiția vectorului (X, Y) este $F \otimes G$. În acest caz repartiția sumei $S = X + Y$ se notează cu $F * G$ și se numește **convoluția** dintre F și G .

Formula de transport ne arată că dacă $f : \mathbb{R} \rightarrow \mathbb{R}$ este măsurabilă mărginită, atunci

$$Ef(X + Y) = \int f(x + y) dF \otimes G(x, y) = \int \int f(x + y) dF(x) dG(y) = \int \int f(x + y) dG(y) dF(x)$$

Așadar am descoperit formula

$$\int f dF * G = \int \int f(x + y) dF(x) dG(y) = \int \int f(x + y) dG(y) dF(x)$$

care poate fi luată ca o definiție a convoluției.

Proprietăți.

1. $(F * G)(B) = \int \int F(B - y) dG(y) = \int \int G(B - x) dF(x)$; deci funcție de repartiție se calculează după formula

$$(F * G)(t) = \int \int F(t - y) dG(y) = \int \int G(t - x) dF(x)$$

2. $F * \delta_0 = F, (F * \delta_a)(x) = F(x - a)$

3. $F * (aG + bH) = aF * G + bF * H$ (convoluția este distributivă față de adunare)

4. Spațiul măsurilor cu semn mărginite de pe dreapta reală echipat cu adunarea, înmulțirea cu scalari și convoluția $(M_b(\mathbb{R}, B(\mathbb{R})), +, *)$ este o algebră comutativă, cu elementul neutru δ_0 . În cadrul acestei algebre familia $\text{Prob}(\mathbb{R}, B(\mathbb{R}))$ a probabilităților este o mulțime convexă

$$5. \quad \delta_a * \delta_b = \delta_{a+b}, (p\delta_a + q\delta_b)^{*n} = \sum_{k=0}^n C_n^k p^{n-k} q^k \delta_{(n-k)a+kb}$$

6. **Proprietatea de netezire.** Dacă G este absolut continuă, atunci și $F * G$ este absolut continuă indiferent de F . Dacă G are densitatea g , atunci $F * G$ are densitatea $p_{F * G}(t) = \int g(t - x) dF(x)$

7. **Convoluția densităților.** Dacă F are densitatea p și G are densitatea q atunci $F * G$ are densitatea $p_{F * G}(t) = \int q(t - x) p(x) dx = \int p(t - y) q(y) dy$

8. Dacă $m_F(t) = \int e^{tx} dF(x)$, $m_G(t) = \int e^{tx} dG(x)$ sunt mgf-urile repartițiilor F și G atunci $m_{F * G} = m_F m_G$. Aceeași afirmație este valabilă pentru funcțiile caracteristice ϕ_F, ϕ_G sau pentru funcțiile generatoare (dacă F și G au suport pe mulțimea numerelor naturale) g_F, g_G

$$9. \quad \text{Bin}(m, p) * \text{Bin}(n, p) = \text{Bin}(m + n, p), \text{Poisson}(a) * \text{Poisson}(b) = \text{Poisson}(a + b),$$

$N(\mu_1, \sigma_1^2) * N(\mu_2, \sigma_2^2) = N(\mu_1 + \mu_2, \sqrt{\sigma_1^2 + \sigma_2^2})$, $\text{Gamma}(m, a) * \text{Gamma}(n, a) = \text{Gamma}(m + n, a)$
(prin definiție, dacă m este număr natural $\text{Gamma}(m, a) = \text{Exp}(a)^{*m}$).

$$10. \quad \text{Uniform}(a, b) * \text{Uniform}(c, d) = \text{Trapez}(a + c, a + d, b + c, b + d)$$

$$F_{\text{Uniform}(0,1)^{*n}}(x) = \frac{x^n - C_n^1(x-1)_+^n + C_n^2(x-2)_+^n - C_n^3(x-3)_+^n + \dots}{n!}$$

Demonstrațiile punctelor 1-8 sunt banale și lăsate ca exerciții.

9. La binomială și Poisson se face funcția generatoare, la Gamma nu avem nimic de demonstrat iar la normală folosim funcția caracteristică sau mgf-ul:

$$m_{N(\mu, \sigma^2)}(t) = e^{\mu t + \frac{\sigma^2 t^2}{2}}$$

$$10. \quad \text{Observăm că } \text{Uniform}(a, b) = \delta_a * \text{Uniform}(0, b - a), \text{Uniform}(c, d) = \delta_c * \text{Uniform}(0, d - c) \text{ deci}$$

$$\text{Uniform}(a, b) * \text{Uniform}(c, d) = \delta_{a+c} * \text{Uniform}(0, \alpha) * \text{Uniform}(0, \beta) \text{ cu } \alpha = b - a, \beta = d - c.$$

Fie X, Y independente, $X \sim \text{Uniform}(0, \alpha), Y \sim \text{Uniform}(0, \beta)$. Atunci $P(X + Y \leq t) = \frac{\lambda^2((0, \alpha) \times (0, \beta) \cap D_t)}{\alpha\beta}$ unde $D_t = \{(x, y) : x + y \leq t\}$. Calculînd aria aceasta (un triunghi triunghic isoscel din care se mai scad eventual alte două triunghiuri dreptunghice isoscele) rezultă $F_{X+Y}(x) = \frac{1}{2\alpha\beta} (x^2 - (x - \alpha)_+^2 - (x - \beta)_+^2 + (x - \alpha - \beta)_+^2)$

cu densitatea

$$p_{X+Y}(x) = \frac{1}{\alpha\beta} (x - (x - \alpha)_+ - (x - \beta)_+ + (x - \alpha - \beta)_+)$$

Graficul ei are forma unui trapez isoscel :de exemplu dacă $\alpha \leq \beta$ avem

$$p_{X+Y}(x) = \frac{1}{\alpha\beta} (x 1_{(\alpha, \beta)} + \alpha 1_{(\alpha, \beta)} + (\alpha + \beta - x) 1_{(\beta, \alpha + \beta)})$$

Analog,

$$F_{U(0, \alpha) * U(0, \beta) * U(0, \gamma)}(x) = \frac{1}{6\alpha\beta\gamma} (x^3 - (x - \alpha)_+^3 - (x - \beta)_+^3 - (x - \gamma)_+^3 + (x - \alpha - \beta)_+^3 + (x - \alpha - \gamma)_+^3 + (x - \beta - \gamma)_+^3 - (x - \alpha - \beta - \gamma)_+^3)$$

a carei densitate deja are formă de clopot.

Pentru a calcula convoluția $\text{Uniform}(0, 1)^{*n}$, calculăm $\lambda^n([0, 1]^n \cap D_t)$ unde

$$D_t = \left\{ (x_k)_{1 \leq k \leq n} \in \mathbb{R}_+^n : x_1 + x_2 + \dots + x_n \leq t \right\}$$

$$\text{Observăm că } [0, 1]^n \cap D_t = D_t - \bigcup_{k=1}^n \Delta_{t,j} \text{ unde } \Delta_{t,j} = \left\{ (x_k)_{1 \leq k \leq n} \in \mathbb{R}_+^n : x_1 + x_2 + \dots + x_n \leq t, x_j \geq 1 \right\}$$

Dacă scriem $x_j = 1 + y_j$, atunci vedem că putem scrie $\Delta_{t,j} = e_j + \{(x_1, \dots, x_{j-1}, y_j, x_{j+1}, \dots, x_n) \in \mathbb{R}_+^n : x_1 + \dots + x_n \leq t - 1\}$
 $e_j = (0, \dots, 0, 1, 0, \dots, 0)$ este versorul canonic de pe poziția j . Altfel scris, $\Delta_{t,j} = e_j + D_{t-1}$

Folosind principiul includerii și excluderii avem și observînd că $\Delta_{t,j} \cap \Delta_{t,i} = e_i + e_j + D_{t-2}$, $\Delta_{t,j} \cap \Delta_{t,i} \cap \Delta_{t,k} = e_i + e_j + e_k + D_{t-3}$ etc găsim că

$$\lambda^n([0, 1]^n \cap D_t) = \lambda^n \left(D_t - \bigcup_{k=1}^n \Delta_{t,j} \right) = \lambda^n(D_t) - \lambda^n \left(\bigcup_{k=1}^n \Delta_{t,j} \right)$$

$$= \lambda^n(D_t) - \left(\sum_i \lambda^n(\Delta_{t,i}) - \sum_{i,j:i \neq j} \lambda^n(\Delta_{t,i} \cap \Delta_{t,j}) + \sum_{i,j,k:i \neq j \neq k \neq i} \lambda^n(\Delta_{t,i} \cap \Delta_{t,j} \cap \Delta_{t,k}) - \dots \right)$$

găsim formula (10), deoarece se verifică imediat că $\lambda^n(D_t) = \frac{t^n}{n!}$

1.9.2 Convergența repartițiilor

Ce se întâmplă dacă facem mai multe convoluții de tipul $F, F^{*2}, F^{*3}, \dots$? Legea numerelor mari spune că în cazul i.i.d. media aritmetică $\bar{X}_n = \frac{X_1 + X_2 + \dots + X_n}{n}$ converge aproape sigur la media teoretică $\mu = EX_1 = \int x dF(x)$, unde F este repartiția lui X_1 . Cum se reflectă acest lucru în repartiția lui $\bar{X}_n$?

Oricum, dacă $X_n \xrightarrow{a.s.} X$ și $h: \mathbb{R} \rightarrow \mathbb{R}$ este o funcție continuă, atunci $h(X_n) \xrightarrow{a.s.} h(X)$.

Cum am putea traduce acest lucru în termeni de repartiții?

Dacă am putea comuta media cu limita, ar trebui să rezulte că $Eh(X_n) \rightarrow Eh(X)$.

Un caz în care acest lucru este absolut sigur este dacă h este continuă **și mărginită**.

Să notăm cu F_n repartițiile lui X_n și cu F repartiția lui X . Deci dacă h este continuă și mărginită avem

$$X_n \xrightarrow{a.s.} X \implies h(X_n) \xrightarrow{a.s.} h(X) \implies Eh(X_n) \rightarrow Eh(X) \iff \int h dF_n \rightarrow \int h dF.$$

Aceasta este definiția la care s-au oprit matematicienii.

Definiție. Fie $(F_n)_n$ un șir de repartiții. Spunem că F_n converge la F (**slab**) dacă

$$\int h dF_n \rightarrow \int h dF \text{ pentru orice } h: \mathbb{R} \rightarrow \mathbb{R} \text{ continuă mărginită}$$

Notăția acceptată este " $F_n \implies F$ "

Vom da fără demonstrație cele două teoreme mari privind convergența slabă

Teorema 1. (Portmanteau). $F_n \implies F$ dacă și numai dacă $F_n(x) \rightarrow F(x)$ în orice punct de continuitate al lui F , adică în toți acei x cu proprietatea că $F(x-0) = F(x)$

Comentariu. Trebuie pusă condiția neplăcută de continuitate deoarece este evident că $\delta_{\frac{1}{n}} \implies \delta_0$, dar nu este adevărat că funcțiile de repartiție converg peste tot: funcția de repartiție a lui $\delta_{\frac{1}{n}}$ este $1_{[\frac{1}{n}, \infty)}$ și ea converge la $1_{(0, \infty)}$ care, nefiind continuă la dreapta NU este o funcție de repartiție. De altfel se poate arăta că $F_n \implies F$ dacă și numai dacă $F_n(x) \rightarrow F(x)$ pe o mulțime $\Gamma \subset \mathbb{R}$ densă.

Teorema 2. (de convergență a funcțiilor caracteristice): $F_n \implies F$ dacă și numai dacă $\phi_{F_n} \rightarrow \phi_F$ adică $\int e^{itx} dF_n(x) \rightarrow \int e^{itx} dF(x)$ pentru orice $t \in \mathbb{R}$

Acum dăm un criteriu suficient pentru a asigura convergența slabă, folositor în cazurile didactice

Propoziția 3. (criteriul convergenței densităților)

Să presupunem că F_n au densitățile p_n față de o măsură σ -finită, μ . Să mai presupunem că p_n converge la o funcție p despre care **știm deja** că este densitate. Atunci $F_n \implies p \cdot \mu$

Demonstrație. $|F_n(x) - F(x)| = \left| \int_{-\infty}^x (p_n(z) - p(z)) d\mu(z) \right| \leq \int |p_n - p| d\mu$

Scriem $|p_n - p| = |p - p_n| = 2(p - p_n)_+ - (p - p_n)$ și avem în continuare

$$\int |p_n - p| d\mu = \int (2(p - p_n)_+ - (p - p_n)) d\mu = 2 \int (p - p_n)_+ d\mu - \int (p - p_n) d\mu = 2 \int (p - p_n)_+ d\mu - 1 + 1 = 2 \int (p - p_n)_+ d\mu$$

Dar $(p - p_n)_+$ converge la 0 și este dominat de p . Din teorema lui Lebesgue $\int (p - p_n)_+ d\mu$ va converge de asemenea la 0.

Cazuri particulare: măsura Lebesgue sau măsura cardinal pe o mulțime numărabilă.

Corolar. Teorema de aproximare Poisson. Dacă $F_n = Bin(n, p_n)$ și $np_n \rightarrow \lambda$, atunci $F_n \Rightarrow Poisson(\lambda)$

Într-adevăr, $C_n^k p^k (1-p)^{n-k}$ converge la $\frac{\lambda^k}{k!} e^{-\lambda}$.

Corolar al teoremei lui Glivenko. Repartițiile discrete sunt dense în familia tuturor repartițiilor de pe dreaptă.


Într-adevăr, repartițiile empirice sunt discrete și converg la repartiția teoretică.


Notăție. Să presupunem că variabilele X_n au repartițiile F_n și $F_n \Rightarrow F$. Atunci se mai folosește notația $X_n \xrightarrow{D} F$, care se citește " X_n converge în repartiție la F ". Sau, dacă X este o variabilă aleatoare cu repartiția F , atunci se mai poate citi " X_n converge în repartiție la X ". Evident că dacă X_n converge aproape sigur la X , atunci X_n converge în repartiție la X .

1.9.3 Teorema limită centrală

Convoluțiile tind să aibă o formă de clopot.

Iată, de exemplu densitățile lui F^{*n} dacă $F = Exp(1)$ pentru $n = 1, 2, 3, 4, 5$ (negru = densitatea lui F , maro = densitatea lui $F * F$, indigo = densitatea lui $F * F * F$, verde = densitatea lui F^{*4} , albastru = densitatea lui F^{*5})





sau densitatile repartițiilor $U(-1, 1)^{*n}$ pentru $n = 2, 3, 4, 5$ (Negru pentru $n = 2$, roșu pentru $n = 3$, verde pentru $n = 4$, albastru pentru $n = 5$)

Explicatia se află în

TEOREMA LIMITĂ CENTRALĂ

Fie $(X_n)_n$ un șir de variabile aleatoare i.i.d din L^2 cu media μ și varianța σ^2 .

Atunci $\frac{X_1 + X_2 + \dots + X_n - n\mu}{\sigma\sqrt{n}} \xrightarrow{D} N(0, 1)$

Sau, mai explicit

$P\left(\frac{X_1 + X_2 + \dots + X_n - n\mu}{\sigma\sqrt{n}} \leq x\right) \longrightarrow \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{y^2}{2}} dy$ pentru orice x număr real.

Demonstrație. Vom folosi teorema de convergență a funcțiilor caracteristice: va trebui să arătăm că $\phi_{s_n}(t) \longrightarrow \phi_{N(0,1)}(t)$ pentru orice t . Am notat cu s_n raportul $\frac{X_1 + X_2 + \dots + X_n - n\mu}{\sigma\sqrt{n}} = \frac{Y_1 + Y_2 + \dots + Y_n}{\sigma\sqrt{n}}$ unde $Y_n = X_n - \mu$ sunt variabilele centrate; evident $Y_n \in L^2$.

Fie $\phi(t) = Ee^{itY_n}$, $\phi: \mathbb{R} \rightarrow \mathbb{C}$. Funcția ϕ este derivabilă de două ori, $\phi(0) = 1$, $\phi'(0) = 0$, $\phi''(0) = i^2 E(X_n - \mu)^2 = -\sigma^2$.

Este important de reținut că putem scrie $\phi(t) = \phi(0) + t\phi'(0) + \frac{t^2}{2}\phi''(0) + o(t)t^2$ unde $o: \mathbb{R} \rightarrow \mathbb{C}$ este o funcție continuă și $o(0) = 0$. Într-adevăr, $o(t) = \frac{\phi(t) - \phi(0) - t\phi'(0) - \frac{t^2}{2}\phi''(0)}{t^2}$ este evident continuă; din regula L'Hospital $\lim_{t \rightarrow 0} o(t) = \frac{1}{2} \lim_{t \rightarrow 0} \left(\frac{\phi'(t) - \phi'(0)}{t} - \phi''(0) \right) = 0$ - căci am presupus că $\phi'(t)$ este derivabilă în 0.

Atunci $\phi_{s_n}(t) = Ee^{it\frac{Y_1 + Y_2 + \dots + Y_n}{\sigma\sqrt{n}}} = \left(Ee^{i\frac{t}{\sigma\sqrt{n}}Y_1}\right)^n$ (am presupus variabilele aleatoare i.i.d!)

$$\begin{aligned}
&= \phi^n \left(\frac{t}{\sigma\sqrt{n}} \right) = \left(\phi(0) + \frac{t}{\sigma\sqrt{n}} \phi'(0) + \frac{t^2}{2n\sigma^2} \phi''(0) + o\left(\frac{t}{\sigma\sqrt{n}}\right) \frac{t^2}{n\sigma} \right)^n = \\
&\left(1 - \frac{t^2}{2n} + o\left(\frac{t}{\sigma\sqrt{n}}\right) \frac{t^2}{n\sigma} \right)^n = (1 - \alpha_n)^n = \left((1 - \alpha_n)^{\frac{1}{\alpha_n}} \right)^{n\alpha_n} \quad (\text{cu } \alpha_n = \frac{t^2}{2n} - \\
&o\left(\frac{t}{\sigma\sqrt{n}}\right) \frac{t^2}{n\sigma}) \\
&\text{Deci } \lim \phi^n \left(\frac{t}{\sigma\sqrt{n}} \right) = \lim e^{-n\alpha_n} = \lim e^{-n\left(\frac{t^2}{2n} - o\left(\frac{t}{\sigma\sqrt{n}}\right) \frac{t^2}{n\sigma}\right)} = e^{-\frac{t^2}{2} - \lim o\left(\frac{t}{\sigma\sqrt{n}}\right) t^2} = \\
&e^{-\frac{t^2}{2}} = \phi_{N(0,1)}(t). \text{ QED.}
\end{aligned}$$

Convergența funcțiilor de repartiție nu implică și convergența densităților. Reciproca este evident adevărată, după cum am văzut mai sus.

Totuși, în anumite ipoteze se poate demonstra - mult mai greu și cu un aparat matematic foarte sofisticat - și

TEOREMA LIMITĂ LOCALĂ.

Presupunem că variabilele aleatoare de mai sus, X_n , sunt și absolut continue. Fie p_n densitatea sumelor centrate și normate $s_n = \frac{Y_1+Y_2+\dots+Y_n}{\sigma\sqrt{n}}$. Să presupunem că există un n_0 cu proprietatea că p_{n_0} este mărginită. Atunci $p_n(x) \longrightarrow \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{x^2}{2}}$: densitățile tind la densitatea normală. Aceasta ar fi explicația fenomenului arătat în cele două grafice de mai sus.

Aplicație în aproximarea unor repartiții.

Binomial(n, p) $\cong N(np, \sqrt{npq})$ dacă np și npq sunt "mari"

Gamma(n, λ) $\cong N\left(\frac{n}{\lambda}, \left(\frac{\sqrt{n}}{\lambda}\right)^2\right)$ dacă $\frac{n}{\lambda}$ și $\frac{\sqrt{n}}{\lambda}$ sunt "mari"

Poisson(λ) $\cong N(n\lambda, \sqrt{n\lambda})$ dacă $n\lambda$ este "mare"

etc

Aplicație în calculul primelor de asigurare.

Se dă un portofoliu omogen de n asigurați de tip F .

Traducere matematică: Fie $(X_k)_{1 \leq k \leq n}$ variabile aleatoare i.i.d. nenegative din L^2 . Ele e numesc daune.

Asiguratorul își asumă riscul de default ε . Ce primă de asigurare să ceară?

Traducere matematică. Care să fie cel mai mic număr Π cu proprietatea că $P(X_1 + X_2 + \dots + X_n \geq n\Pi) \leq \varepsilon$?

$$\text{Sriem } P(X_1 + X_2 + \dots + X_n \geq n\Pi) = P\left(\frac{X_1+X_2+\dots+X_n-n\mu}{\sigma\sqrt{n}} \geq \frac{n\Pi-n\mu}{\sigma\sqrt{n}}\right) = P\left(s_n \geq \frac{\sqrt{n}(\Pi-\mu)}{\sigma}\right)$$

Dacă n este destul de mare (ce înseamnă acest lucru este o altă discuție, de loc simplă!), atunci putem aproxima ultima probabilitate cu $N(0, 1) \left(\left(\frac{\sqrt{n}(\Pi-\mu)}{\sigma}, \infty \right) \right) =$

$\Phi\left(\frac{\sqrt{n}(\Pi-\mu)}{\sigma}\right)$, unde prin tradiție se notează $\Phi(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{y^2}{2}} dy$, adică

funcția de repartiție a normalei standard. Cum repartiția normală este simetrică față de origine, $\Phi(a) = \Phi(-a)$ pentru orice $a \in \mathbb{R}$. De aceea putem scrie

$$P(X_1 + X_2 + \dots + X_n \geq n\Pi) \cong \Phi\left(-\frac{\sqrt{n}(\Pi-\mu)}{\sigma}\right) \text{ și punem condiția ca } \Phi\left(-\frac{\sqrt{n}(\Pi-\mu)}{\sigma}\right) =$$

$$\varepsilon \iff -\frac{\sqrt{n}(\Pi-\mu)}{\sigma} = \Phi^{-1}(\varepsilon) \iff \frac{\sqrt{n}(\Pi-\mu)}{\sigma} = -\Phi^{-1}(\varepsilon) = \Phi^{-1}(1-\varepsilon) \text{ de unde}$$

$$\text{găsim } \frac{\Pi-\mu}{\sigma} = \frac{\Phi^{-1}(1-\varepsilon)}{\sqrt{n}} \text{ adică}$$

Principiul de calcul medie-abatere:

$$\Pi = \mu + \frac{\sigma}{\sqrt{n}} \Phi^{-1}(1 - \varepsilon)$$

Pe această bază putem, de exemplu aprecia că, pentru un portofoliu omogen

$$\text{de } 100 \text{ asigurați de tip Binomial}\left(100, \frac{1}{4}\right) \text{ prima va fi de tipul } \Pi = 25 + \frac{\sqrt{100 \cdot \frac{1}{4} \cdot \frac{3}{4}}}{\sqrt{100}} \Phi^{-1}(1 - \varepsilon) = 25 + 0.4331 \Phi^{-1}(1 - \varepsilon)$$

Concret, pentru un risc de 1% am avea $\Phi^{-1}(1 - \varepsilon) = \Phi^{-1}(0.99) = 2.326348$
deci $\Pi = 25 + 2.3263 = 27.326$

Putem compara cu probabilitatea exactă: $X_1 + \dots + X_{100}$ are repartiția
 $\text{Binomial}\left(100, \frac{1}{4}\right)^{*100} = \text{Binomial}\left(10000, \frac{1}{4}\right)$;

$$n\Pi = 2732.6$$

Probabilitatea de default este (în limbajul R) $\psi = 1 - \text{pbinom}(2732.6, 10000, 1/4) = 5.236055\text{e-}08$