



## Table of contents

- 1 **Legile fundamentale**
  - Teorema limită centrală
  - Aproximarea normală a distribuției binomiale
- 2 **Simulare**
  - Simularea variabilelor aleatoare
  - Aplicații ale LNM și TLC
- 3 **Bibliography**

## Teorema limită centrală

## Theorem 1.1

(Teorema limită centrală, Lindeberg-Lévy) Fie  $(X_n)_{n \geq 1}$  un șir de variabile aleatoare independente și identic distribuite cu media  $\mu$  și dispersia  $\sigma^2$ . Atunci

$$\frac{\frac{1}{n} \sum_{i=1}^n X_i - \mu}{\frac{\sigma}{\sqrt{n}}} \rightarrow N(0, 1) \text{ sau}$$

$$\lim_{n \rightarrow \infty} P \left( \frac{\sum_{i=1}^n X_i - n\mu}{\sigma\sqrt{n}} \leq a \right) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^a \exp(-t^2/2) dt, \forall a \in \mathbb{R}.$$

## Teorema limită centrală

- Teorema limită centrală permite estimarea unor probabilități asociate sumelor de variabile (independente și identic distribuite).
- Pe de altă parte, teorema explică de ce atât de multe procese (din științele sociale, biologie, psihologie etc) urmează o lege normală.
- În esența ei teorema limită centrală spune că, pentru eșantioane suficient de mari ( $n \geq 30$ ), variabila

$$\frac{\sum_{i=1}^n X_i - n\mu}{\sigma\sqrt{n}}$$

urmează o lege normală standard,  $N(0, 1)$ .

- Teorema limită centrală are loc chiar și pentru variabile dependente, dacă au corelația foarte scăzută.

## Aproximarea normală a distribuției binomiale

- Fie  $X_n$  un șir de variabile Bernoulli( $p$ ) independente.
- $X = \sum_{i=1}^n X_i$  are o distribuție binomială,  $B(n, p)$ .
- Folosind teorema limită centrală obținem teorema de Moivre-Laplace care spune că, pentru  $n$  suficient de mare, variabila

$$Y = \frac{X - \mathbb{E}[X]}{\sqrt{\text{Var}[X]}} = \frac{X - np}{\sqrt{np(1-p)}}$$

este o variabilă normală standard ( $N(0, 1)$ ).

- Aproximarea este bună pentru  $np(1-p) \geq 10$ .

## Aproximarea normală a distribuției binomiale

- Un alt mod de a vedea acest rezultat este următorul: când  $k$  este aproape de  $np$

$$\binom{n}{k} p^k (1-p)^{n-k} \sim \frac{\exp\left(-\frac{(k-np)^2}{2np(1-p)}\right)}{\sqrt{2\pi np(1-p)}}$$

- Considerăm următorul exemplu: fie  $X$  numărul de apariții ale steimei în 40 de aruncări ale unei monede.
- Cât este  $P(X = 20)$ ?

$$\begin{aligned} P(X = 20) &= P(19.5 \leq X \leq 20.5) = \\ &= P\left(\frac{19.5 - 20}{\sqrt{10}} \leq \frac{X - 20}{\sqrt{10}} \leq \frac{20.5 - 20}{\sqrt{10}}\right) = P\left(-0.16 \leq \frac{X - 20}{\sqrt{10}} \leq 0.16\right) \\ &\sim \Phi(0.16) - \Phi(-0.16) = 0.1272, \end{aligned}$$

unde  $\Phi(\cdot)$  este funcția de repartiție a variabilei  $N(0, 1)$ .

## Corecția continuă

- Corecția continuă este o ajustare care se face ori de câte ori o distribuție discretă este aproximată printr-una continuă.
- $P(X = 10) = P(9.5 \leq X \leq 10.5)$ ,  $P(X > 15) = P(X \geq 15.5)$ ,  
 $P(X < 13) = P(X \leq 12.5)$ .

## Generarea de numere aleatoare uniform distribuite

- Când vorbim despre numere aleatoare ne gândim cel mai adesea la numere aleatoare uniform distribuite.
- Există două tipuri de variabile aleatoare uniforme: discretă și continuă.
- De exemplu, pentru a alege un număr întreg aleator uniform distribuit între 1 și  $n$  (câteodată între 0 și  $(n - 1)$ ) trebuie să generăm o valoare a unei variabile aleatoare discrete uniforme  $U_n$ .
- Pe de altă parte, dacă dorim să alegem un număr aleator uniform din intervalul  $[0, 1]$  trebuie să generăm o valoare a unei variabile continue uniforme  $U_{[0,1]}$ .
- În general, *a simula o anumită variabilă aleatoare înseamnă a genera valori care urmează acea distribuție.*

## Generarea de numere aleatoare

- Aproape orice limbaj de programare conține câte un generator de numere aleatoare uniforme (discrete și continue); noi vom utiliza generatoarele din R care acoperă și alte distribuții în afară de cele uniforme.
- Trecem în revistă comenzile R pentru distribuțiile discrete sau continue uzuale.
- Funcțiile care încep cu  $p$ ,  $q$ ,  $d$  și  $r$  returnează funcție de repartiție (sau CDF - cumulative distribution function), inversa CDF, funcție de densitate de probabilitate (PDF), respectiv o valoare a unei variabile aleatoare având distribuția specificată.
- Pentru a genera doar valori discrete uniforme se poate utiliza funcția `sample()`.

## Generarea de numere aleatoare

Distribuția	Comenzi			
Binomial	<code>pbinom()</code>	<code>qbinom()</code>	<code>dbinom()</code>	<code>rbinom()</code>
Geometric	<code>pgeom()</code>	<code>qgeom()</code>	<code>dgeom()</code>	<code>rgeom()</code>
Poisson	<code>ppois()</code>	<code>qpois()</code>	<code>dpois()</code>	<code>rpois()</code>
Uniform	<code>punif()</code>	<code>qunif()</code>	<code>dunif()</code>	<code>runif()</code>
Exponential	<code>pexp()</code>	<code>qexp()</code>	<code>dexp()</code>	<code>rexp()</code>
Normal	<code>pnorm()</code>	<code>qnorm()</code>	<code>dnorm()</code>	<code>rnorm()</code>
Student	<code>pt()</code>	<code>qt()</code>	<code>dt()</code>	<code>rt()</code>
Gamma	<code>pgamma()</code>	<code>qgamma()</code>	<code>dgamma()</code>	<code>rgamma()</code>

- Detalii se pot afla folosind `help(nume)` în R sau Rstudio.

## Generarea de numere aleatoare

- Pentru a simula o variabilă aleatoare discretă este nevoie de repartiția ei.

$$X : \begin{pmatrix} x_1 & x_2 & \dots & x_k & \dots \\ p_1 & p_2 & \dots & p_k & \dots \end{pmatrix}$$

- $X$  se poate simula astfel: generăm o valoare aleatoare uniformă (continuă)  $U$  și returnăm  $x_i$  dacă  $\sum_{j=1}^{i-1} p_j \leq U < \sum_{j=1}^i p_j$ .

## Aplicații ale LNM și TLC

*Exemplu 1. (LNM - Problema acului lui Buffon)* Problema (formulată în 1733 și rezolvată în 1777 de naturalistul și matematicianul francez Comte de Buffon) cere să se determine probabilitatea ca un ac de lungime  $l$  să intersecteze o dreaptă când este aruncat pe o suprafață plană pe care sunt desenate (o infinitate de) drepte paralele aflate la distanța  $2d$ .

*Soluție.* Vom presupune că lungimea acului este mai mică decât distanța dintre drepte (cea mai ușoară variantă de analizat); există două variabile care determină poziția relativă a acului față de cea mai apropiată dreaptă: unghiul,  $x$ , pe care îl face acul cu direcția liniilor și distanța de la mijlocul acului la această dreaptă,  $y$ . Acul va intersecta cea mai apropiată linie dacă și numai  $y \leq l/2 \sin x$ , oricare ar fi  $x \in [0, \pi]$ .

## Aplicații ale LNM și TLC

Toate situațiile posibile sunt complet descrise de perechile  $(x, y) \in [0, \pi] \times [0, d]$ , iar cazurile favorabile sunt perechile care dau puncte aflate sub graficul funcției  $f: [0, \pi] \rightarrow \mathbb{R}$ ,  $f(x) = l/2 \sin x$ .

Astfel, probabilitatea este

$$\frac{\int_0^{\pi} f(x) dx}{\pi \cdot d} = \frac{1}{\pi d} \int_0^{\pi} \frac{l}{2} \sin x dx = \frac{l}{2\pi d} [-\cos x]_0^{\pi} = \frac{l}{\pi d}.$$

Pentru  $l = d = 1$ , adică atunci când acul are lungimea egală cu jumătate din distanța dintre drepte, probabilitatea este  $1/\pi$ .

## Aplicații ale LNM și TLC

Introducem experiența aleatoare care constă în a arunca acul și notăm cu  $X$  variabila Bernoulli care are valoarea 1 dacă și numai dacă acul intersectează o dreaptă; probabilitatea de succes și media variabilei  $X$  au valoarea  $1/\pi$ .

Dacă repetăm în mod independent experimentul de  $n$  ori vom obține un eșantion de dimensiune  $n$ ,  $(X_i)_{i=1, \dots, n}$ . Datorită Legii Numerelor Mari  $\bar{x}_n \rightarrow 1/\pi$ , astfel, pentru valori mari ale lui  $n$ ,

$$\bar{x}_n = \frac{\text{numărul de succese}}{n} \approx \frac{1}{\pi}.$$

Acest tip de relație a fost utilizat pentru a obține aproximări experimentale ale lui  $\pi$ . Mai mulți "aruncători" de ace au efectuat deja acest experiment.

## Aplicații ale LNM și TLC

**Exemplul 2.** (*Verificarea LNM*) Considerăm o repartiție  $X$  cu media  $\mu$  și dispersia  $\sigma^2$  și un șir de  $n$  variabile aleatoare independente și identic distribuite cu  $X$ ,  $X_i$ ,  $i = \overline{1, n}$ . Legea numerelor mari spune că (într-un anumit sens, probabilistic) media de selecție converge la medie:

$$\bar{x}_n \rightarrow \mu \text{ as } n \rightarrow \infty$$

Verificăm această lege utilizând o distribuție Poisson cu diverși parametri  $\lambda$  (pentru o astfel de distribuție  $\mu = \lambda$ ).

$\lambda$	2	3	4	6	8	12	15
$\bar{x}_n$	1.955	2.977	4.003	6.027	8.018	12.093	14.925

Se observă că mediile de selecție obținute ( $n = 5000$ ) sunt foarte apropiate de mediile corespunzătoare. (Eșantioanele au fost obținute folosind  $rpois(n, \lambda)$ .)

## Aplicații ale LNM și TLC

Dacă repetăm testul anterior cu distribuția Gamma pentru diverse valori ale parametrilor  $(\alpha, \lambda)$  (media este  $\mu = \alpha/\lambda$ ) obținem

$\alpha$	2	2	3	4	6	6	6	12
$\lambda$	1.5	2	2	3	5	4	8	4
$\bar{x}_n$	1.361	1.009	1.489	1.345	1.204	1.501	0.752	2.973
$\mu$	1.333	1.000	1.500	1.333	1.200	1.500	0.750	3.000

Mediile de selecție obținute ( $n = 5000$ ) sunt foarte apropiate de mediile corespunzătoare. (Eșantioanele au fost obținute folosind  $rgamma(n, \alpha, \lambda)$ .)

## Aplicații ale LNM și TLC

**Exemplul 3.** (*TLC - de Moivre-Laplace*) Mărimea ideală a anului I la un colegiu particular este de 150 studenți. Conducerea colegiului, știind din experiență, că, în medie, doar 30% din elevii care trec examenul de admitere vor urma cursurile, aprobă 450 de locuri pentru admitere. Calculați probabilitatea ca cel puțin 151 de elevi admiși să rămână și să urmeze cursurile colegiului.

**Soluție.** Fie  $X$  numărul de elevi admiși care urmează cursurile colegiului; vom presupune că fiecare elev admis va urma independent cursurile colegiului. Atunci  $X : B(450, 0.3)$  și

$$\begin{aligned} P(X > 150) &= P(X \geq 150.5) = P\left(\frac{X - np}{\sqrt{np(1-p)}} \geq \frac{150.5 - np}{\sqrt{np(1-p)}}\right) = \\ &= P\left(\frac{X - 135}{\sqrt{81}} \geq \frac{15.5}{\sqrt{81}}\right) \approx P(Z \geq 1.722) \end{aligned}$$

unde  $Z : N(0, 1)$ . Astfel  $P(X \geq 150) \approx 1 - \text{pnorm}(1.722) = 0.0425$ .

## Aplicații ale LNM și TLC

**Exemplul 4.** (TLC) O populație de muncitori are media greutății 167 și deviația standard 27. Dacă se alege un eșantion de 36 muncitori, care este probabilitatea ca media de selecție să fie cuprinsă între 163 și 170?

**Soluție.** Fie  $\bar{x}_n$  media de selecție, din TLC,  $\frac{\bar{x}_n - \mu}{\sigma/\sqrt{n}}$  urmează cu aproximație o distribuție normală standard, astfel

$$\begin{aligned}
 P(163 \leq \bar{x}_n \leq 170) &= P\left(\frac{163 - 167}{4.5} \leq \frac{\bar{x}_n - 167}{4.5} \leq \frac{170 - 167}{4.5}\right) = \\
 &= P\left(-0.888 \leq \frac{\bar{x}_n - 167}{4.5} \leq 0.888\right) \approx P(-0.888 \leq Z \leq 0.888) = \\
 &= \text{pnorm}(0.888) - \text{pnorm}(-0.888) = 2 \cdot \text{pnorm}(0.888) - 1 = 0.625
 \end{aligned}$$

## Aplicații ale LNM și TLC

*Exemplul 5. (Verificarea TLC)* Considerăm o distribuție de probabilitate,  $X$ , cu media  $\mu$  și dispersia  $\sigma^2$  și un șir format din  $n$  variabile aleatoare independente și identic distribuite  $X_i$ ,  $i = 1, n$ . Conform TLC, pentru valori mari ale lui  $n$ , media de selecție,  $\bar{x}_n$ , are o distribuție normală,  $N(\mu, \sigma^2/n)$ .

Dorim să verificăm această afirmație și considerăm  $N$  astfel de medii de selecție și construim o histogramă. Exemplele de mai jos folosesc distribuția geometrică  $G(0.35)$  și distribuția exponențială  $Exp(5)$  ( $n = 50$ ,  $N = 10000$ ).

## Aplicații ale LNM și TLC

Probabilități și Statistică

Probabilități și Statistică

Probabilități și Statistică

Probă

stică

Probă

stică

Probă

stică

Probă

stică

Probă

stică

Probă

stică

Probă

stică

Probă

stică

Probă

stică

Probă

stică

Probă

Frequency

0  
500  
1500

1.0

1.5

2.0

2.5

3.0

3.5

Sample means for Geometric(0.35)

## Applications of LLN and CLT

Probabilități și Statistică

Probabilități și Statistică

Probabilități și Statistică

Probă

stică

Probă

stică

Probă

stică

Probă

stică

Probă

stică

Probă

stică

Probă

stică

Probă

stică

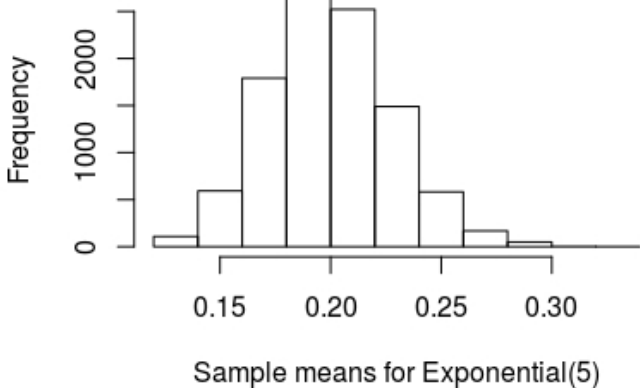
Probă

stică

Probă

stică

Probă



## Aplicații ale LNM și TLC

**Exemplul 6.** (*Verificarea TLC*) Considerăm o distribuție de probabilitate,  $X$ , cu media  $\mu$  și dispersia  $\sigma^2$  și un șir format din  $n$  variabile aleatoare independente și identic distribuite  $X_i$ ,  $i = \overline{1, n}$ . Acest șir poate fi văzut ca un eșantion aleator simplu; dacă  $\bar{x}_n$  este media de selecție, TLC spune că

$$\lim_{n \rightarrow \infty} P \left[ \frac{\bar{x}_n - \mu}{\sigma/\sqrt{n}} \leq z \right] = P(Z \leq z),$$

unde  $Z : N(0, 1)$ . De obicei, pentru valori mari ale lui  $n$  putem face următoarea aproximare

$$P_n(z) = P \left[ \frac{\bar{x}_n - \mu}{\sigma/\sqrt{n}} \leq z \right] \approx P(Z \leq z).$$

○ metoda pentru a verifica cât de precisă este această aproximare:

alegem independent  $N$  eșantioane (șiruri)  $(X_i^k)_{i=\overline{1, n}}^{k=\overline{1, N}}$  și calculăm

$$P^N = \frac{|\{k : \bar{x}_n^k \leq z\sigma/\sqrt{n} + \mu\}|}{N}.$$

## Aplicații ale LNM și TLC

Altfel spus,  $P^N$  este numărul de eșantioane (dintre cele  $N$ ) care satisfac inegalitatea  $\frac{\bar{x}_n - \mu}{\sigma/\sqrt{n}} \leq z$  supra numărul total de eșantioane. Această statistică ar trebui să aproximeze  $P[Z \leq z]$ . Pentru distribuția exponențială cu  $\lambda = 2$ ,  $n = 50$  și  $N = 2000$  rezultatele se găsesc mai jos (un singur eșantion de dimensiune  $n$  poate fi obținut cu  $rexp(n, \lambda)$ ).

$z$	-1.5	-1.0	-0.5	0	0.5	1.0	1.5
$P^N(z)$	0.055	0.154	0.313	0.509	0.723	0.831	0.931
<i>Rel. err</i>	16%	2.5%	1.6%	1.8%	4.6%	1.8%	0.2%
$pnorm(z)$	0.066	0.158	0.308	0.5	0.691	0.847	0.933

Eroarea relativă este egală cu  $\frac{|P(Z \leq z) - P^N(z)|}{P(Z \leq z)}$ .

## Aplicații ale LNM și TLC

Pentru a calcula  $P^N(z)$  am folosit următorul algoritm:

```
 $\mu \leftarrow 1/\lambda; // \text{why?}$ 
```

```
 $\sigma \leftarrow 1/\lambda; // \text{why?}$ 
```

```
 $c \leftarrow z * \sigma / \sqrt{n} + \mu;$ 
```

```
 $j \leftarrow 1;$ 
```

```
for( $i = 1, N$ )
```






```
    if( $mean(rexp(n, \lambda)) \leq c$ )
```

```
         $j++;$ 
```

```
return  $j/N;$ 
```



## Bibliography I

-  Baron, M., *Probability and Statistics for Computer Scientist*, Chapman & Hall/CRC Press, 2013 sau ediția electronică <https://ww2.ii.uj.edu.pl/~z1099839/naukowe/RP/rps-michael-byron.pdf>
-  Johnosn, J. L., *Probability and Statistics for Computer Science*, Wiley Interscience, 2008.
-  Lipschutz, S., *Theory and Problems of Probability*, Schaum's Outline Series, McGraw-Hill, 1965.
-  Ross, S. M., *A First Course in Probability*, Prentice Hall, 5th edition, 1998.
-  Shao, J., *Mathematical Statistics*, Springer Verlag, 1998.

## Bibliography II



Stone, C. J., *A Course in Probability and Statistics*, Duxbury Press, 1996.