

# CAPITOLUL 1

## PROBABILITATE, VARIABILE ALEATOARE ȘI PROCESE STOCHASTICE

### 1.1. SCURT ISTORIC AL TEORIEI PROBABILITĂȚII

Marele matematician american Claude Elwood Shannon (30.04.1916 – 24.02.2001), fondatorul teoriei moderne a informației, și-a formulat ideile cu ajutorul teoriei probabilității. Faptul că el și-a scris lucrările în limba engleză nu ne obligă să învățăm mai întâi această limbă pentru a le înțelege, căci o expunere a conținutului lor în românește este perfect posibilă și a fost deja făcută foarte bine; nimic, însă, nu ne dispensează de asimilarea prealabilă a bazei teoriei probabilității pentru a avea acces la teoria matematică a informației. De altfel, numeroase alte discipline de studiu se bazează pe teoria probabilității, de la fizica statistică până la sociologie și lingvistică, așa încât efortul nostru nu e unul foarte special, numeroși alți studenți făcându-l în cadrul educației lor.

Originile teoriei probabilității trebuie căutate în interesul purtat de unii nobili din Europa medievală jocurilor de noroc, o petrecere a timpului care le mobiliza de minune surplusul de inteligență, neconsumat în scopuri utilitariste, ca de exemplu născocirea unor mașinării și mecanisme, îndeletnicire lăsată pe seama minților mai prozaice ale burghezilor. Germenii teoriei probabilității au apărut pe la mijlocul secolului XVII în lucrările lui Pierre de Fermat (1601–1665), Blaise Pascal (1623–1662) și Christian Huygens (1629–1695). Deși cercetările lor erau inspirate de jocurile de noroc, importanța noilor concepte introduse –, cel de probabilitate a unui eveniment stochastic și cel de valoare medie sau așteptată a unei variabile aleatoare – pare-se că le era clară, după cum dă de înțeles Huygens în primul text despre probabilitate tipărit (1657) *Cu privire la calculele din jocurile de noroc*: „Cititorul va binevoi să

remarce că nu ne ocupăm numai cu jocurile de noroc, dar că se și pun aici fundamentele unei foarte interesante și profunde teorii.“ Menționăm că excentricul savant și mare amator de jocuri de noroc Girolamo Cardano (1501–1576) scrisese *Cartea jocurilor și a norocului* pe la 1520, dar ea n-a fost publicată decât în 1663. Ulterior, Jacob Bernoulli (1654–1705), Abraham de Moivre (1667–1754), reverendul Thomas Bayes (1702–1761), marchizul Pierre Simon Laplace (1729–1827), Johann Friedrich Carl Gauss (1777–1855) și Siméon Denis Poisson (1781–1840) au contribuit semnificativ la dezvoltarea teoriei probabilității. Școala rusă a dat mari matematicieni ca P. L. Cebîșev (1821–1894) și studenții săi A. Markov (1856–1922) și A. M. Liapunov (1857–1918) cu contribuții importante legate de legea numerelor mari. Germanul Richard von Mises, pe la începutul secolului XX, a introdus o teorie a probabilității bazată pe definiția probabilității ca frecvență relativă. Dar teoria deductivă bazată pe definiția axiomatică a probabilității, așa cum o studiem în zilele noastre, îi este atribuită în principal lui Andrei Nicolaevici Kolmogorov, care, în anii 1930, împreună cu Paul Lévy, a fundamentat o conexiune strânsă între teoria probabilității și teoria matematică a mulțimilor și a funcțiilor de o variabilă reală. Se cuvine menționat, totuși, că matematicianul francez Émile Borel (1871–1956) ajunsese la aceste idei anterior.

### 1.2. CE ÎNTELEGEM PRIN PROBABILITATE

O teorie se numește *deterministă* dacă stabilește relații matematice precise între diversele mărimi cu care operează. De exemplu, de la bazele electrotehnicii știm că, dacă legăm la bornele unei baterii de 9 V un rezistor având rezistența nominală de 1 k $\Omega$ , prin el va curge un curent de 9 mA, conform legii lui Ohm. Dacă vom măsura acest curent cu un miliampermetru analogic, acul va indica valoarea calculată, cea la care ne așteptăm, dar în ce privește precizia, aceasta depinde printre altele și de acuitatea noastră vizuală. Pentru o măsurătoare mai obiectivă, utilizăm un miliampermetru digital, care ne arată, să spunem, 9,08113 mA. Înlocuind rezistorul cu un altul de aceeași valoare nominală a rezistenței și repetând măsurătoarea, citim acum 8,97893 mA. Păstrând rezistorul, dar înlocuind bateria cu alta de aceeași tensiune nominală, măsurăm acum 9,11023 mA. Care este explicația? Să nu fie decât aproximativă legea lui Ohm? Desigur că nu. Dar rezistoarele produse industrial cu valoarea proiectată de 1 k $\Omega$ , ca și bateriile cu tensiunea nominală de 9 V, rezultă din procesul tehnologic cu o oarecare abatere de la valoarea nominală, suficient de mică însă pentru a fi

acceptabilă în practică. Adevărul este că trebuie să proiectăm circuitele noastre electronice astfel încât să funcționeze bine, deși componentele pe care le folosim au parametri doar aproximativ egali cu cei nominali. Observăm însă un fapt interesant: dacă măsurăm un număr mare de rezistoare de  $1\text{ k}\Omega$  și facem media aritmetică a măsurătorilor, aceasta este apropiată de  $1\text{ k}\Omega$ , iar cu cât numărul măsurătorilor este mai mare, cu atât este mai apropiată media aritmetică de cea nominală.

Vedem deci că, în anumite domenii, media tinde spre o valoare constantă pe măsură ce numărul observațiilor crește și că această valoare rămâne aceeași dacă media se efectuează pe orice subșir specificat mai înainte de realizarea experimentului. Teoria probabilității cu aceasta se ocupă, cu mediile unor fenomene de masă ce apar pe rând sau simultan: emisia electronilor, apelurile telefonice, defectările unor sisteme tehnice, rata natalității și cea a mortalității, zgomotul și multe altele.

Teoria are menirea de a prezice asemenea medii cu ajutorul probabilității evenimentelor. În vreme ce jocul de șah este absolut determinist –, făcând abstracție de caracterul conjunctural al condiției fizice și mentale a celor doi adversari, jocurile de noroc (de la riscă și barbut până la loteria de stat, trecând prin jocurile de cazino, ca ruleta și bacara) au un caracter probabilist prin excelență, încât, fără a le recomanda, le putem utiliza în scop ilustrativ.

Să catapultăm o monedă cu un bobârnac; după un zbor elegant prin aer, moneda va ateriza pe o suprafață plană cu una din cele două fețe în sus. În această carte, vom numi convențional cele două fețe „capul” și „banul”. Faptul că anumite monede au o stemă sau o pajură în loc de capul unei figuri istorice nu schimbă, desigur, datele experimentului nostru. Să presupunem că a căzut „capul”. Putem deduce din aceasta că, la o nouă aruncare a monedei, va cădea din nou capul? (Să renunțăm la ghilimele). Nicidecum, după cum bine știm din experiență. Să repetăm, totuși, experimentul de un număr  $n$  de ori, să spunem  $n = 10$ . De  $n_c$  ori va cădea capul, de  $n_b$  ori banul, astfel încât  $n_b + n_c = n$ . Pentru un număr  $n$  mic de încercări, se poate ca  $n_b \neq n_c$ . Observăm, însă, că, pe măsură ce  $n$  crește,  $n_b$  și  $n_c$  sunt tot mai apropiate. Pentru o monedă nemăsluită și un număr mare  $n$  de încercări,  $n_b$  și  $n_c$  trebuie să fie egale.

Să începem acum să ne familiarizăm cu terminologia specifică teoriei probabilității. Aruncarea monedei o singură dată este un exemplu de *experiment*. Efectuarea experimentului este o *încercare*. Faptul că moneda a căzut cu o față în sus este *rezultatul* experimentului. Spațiul de probabilitate, sau spațiul eșantioanelor  $S$  al unui experiment constă din mulțimea tuturor rezultatelor posibile. În cazul aruncării monedei,  $S = \{\text{capul}, \text{banul}\}$ , iar în cazul aruncării zarului,  $S = \{f_1, f_2, f_3, f_4, f_5, f_6\}$ , unde  $f_i$  este fațeta marcată cu  $i$  puncte. Cele două, respectiv șase rezultate posibile sunt *punctele eșantion*

## 4 PROBABILITATE, VARIABLE ALEATOARE ȘI PROCESE STOCHASTICE

ale experimentului. Un *eveniment* este o submulțime a lui  $S$  și poate consta din orice număr de puncte eșantion.

Fie  $S$  spațiul eșantioanelor pentru experimentul constând din aruncarea zarului. Un posibil eveniment este  $A = \{f_2, f_4\}$  care constă din rezultatele  $f_2$  și  $f_4$ . Complementul evenimentului  $A$ , notat  $\bar{A}$ , constă din toate punctele eșantion din  $S$  care nu sunt în  $A$ :  $\bar{A} = \{f_1, f_3, f_5, f_6\}$ . Două evenimente se spune că sunt mutual exclusive dacă n-au puncte eșantion în comun, adică, dacă apariția unui eveniment exclude apariția celuilalt. Cu consecvență, de acum înainte, în locul cuvântului *întâmplător*, vom utiliza termenul științific de *aleator*. (În limba latină, *aleator* înseamnă jucător de zaruri). Pentru ca un experiment să fie aleator, trebuie să fie satisfăcute trei cerințe:

1. Experimentul să fie repetabil în condiții identice.
2. La orice încercare a experimentului, rezultatul să fie imprevizibil.
3. Pentru un număr mare de încercări ale experimentului, rezultatele să prezinte *regularitate statistică*. Aceasta înseamnă că, dacă se repetă experimentul de un număr mare de ori, se observă că rezultatele au *medii* definite.

Să luăm acum un zar. Presupunem că oricine a văzut un zar, dar să îl descriem totuși ca pe un mic cub din os sau din plastic având marcate cele șase fațete cu un număr de puncte, de la 1 la 6. Dacă aruncăm un zar permițându-i să se rostogolească de mai multe ori, el se va opri în cele din urmă, pe o suprafață plată orizontală, cu o fațetă în sus. Care va fi ea? Nu știm cu anticipație decât că va fi una din cele șase. Apariția unei fațete este un eveniment. Un eveniment apare cu o anumită *probabilitate*. Știm cu toții, fără prea multă teorie, că probabilitatea unei fațete este egală cu  $1/6$ . Dar cum definim probabilitatea unui eveniment? Vom vedea aceasta în secțiunea următoare.

### 1.3. DEFINIȚIA PROBABILITĂȚII

Sunt trei definiții ale probabilității, după cum urmează.

#### Definiția clasică

Timp de secole, s-a utilizat definiția clasică, potrivit căreia probabilitatea  $P(A)$  a unui eveniment  $A$  se determină *a priori* fără a efectua vreun experiment. Ea este dată de raportul

$$P(A) = \frac{N_A}{N} \quad (1.1)$$

unde  $N$  este numărul rezultatelor *posibile* iar  $N_A$  este numărul rezultatelor care sunt *favorabile* evenimentului  $A$ .

În experimentul cu zarul, sunt șase rezultate posibile, astfel încât probabilitatea oricăruia dintre ele este egală cu  $1/6$ . Rezultatele favorabile evenimentului compus *par* (adică, oricare din fațetele  $f_2, f_4, f_6$ ) sunt în număr de trei astfel încât  $P(\text{par}) = 3/6$ .

În experimentul cu o monedă nemăsluită,  $N = 2$  și  $N_c = N_b = 1$ , astfel încât probabilitatea de a cădea *capul* este egală cu cea de a cădea *banul* și deci  $P(\text{cap}) = P(\text{ban}) = 1/2$ .

Nu rareori, însă, semnificația numerelor  $N$  și  $N_A$  nu este clară. Spre exemplu, care este probabilitatea  $p$  ca, aruncând două zaruri, suma numerelor marcate pe fațetele vizibile după oprire să fie 7? Pentru a rezolva această problemă utilizând definiția clasică (1.1), trebuie să determinăm numerele  $N$  și  $N_A$ .

a) Am putea considera drept rezultate posibile cele 11 sume 2, 3, ..., 12. Dintre acestea, numai una dintre ele, și anume 7, este favorabilă, astfel încât  $p = 1/11$ . Acest rezultat este greșit.

b) Am putea număra drept rezultate posibile toate perechile de numere fără a face deosebire între primul și al doilea zar. Avem acum 21 de rezultate dintre care favorabile sunt perechile (3, 4), (5, 2) și (6, 1). Deci  $N_A = 3$  și  $N = 21$ , de unde  $p = 3/21$ . Și acest rezultat este greșit.

c) Soluțiile precedente sunt greșite fiindcă rezultatele nu sunt egal probabile. Trebuie să socotim toate perechile de numere făcând deosebire între primul și al doilea zar. Numărul de rezultate posibile este acum 36, iar rezultatele favorabile sunt cele șase perechi (3, 4), (4, 3), (5, 2), (2, 5), (6, 1) și (1, 6). Prin urmare,  $p = 6/36$ .

### Definiția probabilității ca frecvență relativă

Probabilitatea  $P(A)$  a unui eveniment  $A$  este limita

$$P(A) = \lim_{n \rightarrow \infty} \frac{n_A}{n} \quad (1.2)$$

unde  $n_A$  este numărul de apariții ale lui  $A$  iar  $n$  este numărul de încercări.

În practică, vom aproxima infinitul printr-un număr mare de încercări. Spre exemplu, am putea calcula probabilitatea utilizând (1.2)

pentru câteva valori ale lui  $n$  din ce în ce mai mari, până când obținem aproximativ aceeași valoare pentru  $P(A)$ .

**Definiția axiomatică a probabilității**

Ne vom baza pe teoria mulțimilor, cu care suntem cu toții familiarizați. Să notăm cu  $f_i$  fațetele unui zar. Ele sunt elementele mulțimii  $S = \{f_1, f_2, f_3, f_4, f_5, f_6\}$ . Numim această mulțime *spațiu de probabilitate* și în același timp *evenimentul sigur*, căci la fiecare încercare, este sigur că va apărea unul din elementele sale. Elementele sale se numesc *rezultatele experimentale*. Submulțimile sale se numesc *evenimente*. În cazul aruncării zarului, sunt  $2^6 = 64$  de submulțimi:  $\{\emptyset\}, \{f_1\}, \dots, \{f_1, f_2\}, \dots, \{f_1, f_2, f_3\}, \dots, S$ . Mulțimea vidă  $\{\emptyset\}$  este *evenimentul imposibil*, iar evenimentul  $\{f_i\}$  constând dintr-un singur element  $f_i$  este un *eveniment elementar*.

Atribuim fiecărui eveniment  $A$  un număr  $P(A)$ , pe care-l numim *probabilitatea evenimentului  $A$* . Acest număr se alege astfel încât să fie satisfăcute următoarele trei condiții, care sunt axiomele teoriei probabilității:

**A1.**  $P(A) \geq 0$  (1.3)

**A2.**  $P(S) = 1$  (1.4)

**A3.** Dacă  $A \cap B = \{\emptyset\}$ ,  
 $P(A \cup B) = P(A) + P(B)$  (1.5)

Pe baza axiomelor, deducem următoarele proprietăți.

**P1.** Probabilitatea evenimentului imposibil este zero:

$$P\{\emptyset\} = 0 \tag{1.6}$$

Într-adevăr,  $A \cap \{\emptyset\} = \{\emptyset\}$  și  $A \cup \{\emptyset\} = A$ . De aceea, conform axiomei **A3**, avem:

$$P(A) = P(A \cup \emptyset) = P(A) + P\{\emptyset\}$$

**P2.** Pentru orice  $A$ ,

$$P(A) = 1 - P(\bar{A}) \leq 1 \tag{1.7}$$

din cauză că  $A \cup \bar{A} = S$  și  $A \cap \bar{A} = \{\emptyset\}$ , de unde

$$1 = P(S) = P(A \cup \bar{A}) = P(A) + P(\bar{A})$$

**P3.** Pentru orice  $A$  și  $B$ ,

$$P(A \cup B) = P(A) + P(B) - P(A \cap B) \leq P(A) + P(B) \quad (1.8)$$

Pentru a demonstra această proprietate, scriem evenimentele  $A \cup B$  și  $B$  ca reuniuni de două evenimente care se exclud reciproc:

$$\begin{aligned} A \cup B &= A \cup (\bar{A} \cap B) \\ B &= (A \cap B) \cup (\bar{A} \cap B) \end{aligned}$$

De aceea, aplicând axioma **A3**, putem scrie:

$$\begin{aligned} P(A \cup B) &= P(A) + P(\bar{A} \cap B) \\ P(B) &= P(A \cap B) + P(\bar{A} \cap B) \end{aligned}$$

Eliminând  $P(\bar{A} \cap B)$ , obținem (1.8).

**P4.** Dacă  $B \subset A$ , avem

$$P(A) = P(B) + P(A \cap \bar{B}) \geq P(B) \quad (1.9)$$

din cauză că  $A = B \cup (A \cap \bar{B})$  și  $B \cap (A \cap \bar{B}) = \{\emptyset\}$ .

## 1.4. CLASA F A EVENIMENTELOR

Evenimentele sunt submulțimi ale lui  $S$  cărora le-am atribuit probabilități. Pentru a elimina unele dificultăți matematice legate de mulțimi cu un număr infinit de rezultate, nu vom considera drept evenimente toate submulțimile lui  $S$ , ci doar o clasă  $F$  de submulțimi.

Un câmp  $F$  este o clasă nevidă de mulțimi astfel încât:

$$\mathbf{P1.} \quad \text{Dacă } A \in F, \text{ atunci } \bar{A} \in F \quad (1.10)$$

$$\mathbf{P2.} \quad \text{Dacă } A \in F \text{ și } B \in F, \text{ atunci } (A \cup B) \in F \quad (1.11)$$

Aceste două proprietăți sunt suficiente pentru ca  $F$  să fie un câmp. Din ele, rezultă proprietățile următoare:

$$\mathbf{P3.} \quad \text{Dacă } A \in F \text{ și } B \in F, \text{ atunci } (A \cap B) \in F \quad (1.12)$$

Într-adevăr, din (1.10) urmează că  $\bar{\bar{A}} \in F$  și  $\bar{\bar{B}} \in F$ . Aplicând **P1** și **P2** la mulțimile  $\bar{A}$  și  $\bar{B}$ , rezultă că  $\overline{\bar{A} \cap \bar{B}} \in F$  și  $\overline{\bar{A} \cup \bar{B}} \in F$ .

## 8 PROBABILITATE, VARIABLE ALEATOARE ȘI PROCESE STOCHASTICE

**P4.** Un câmp conține evenimentul sigur și evenimentul imposibil:

$$S \in F \text{ și } \{\emptyset\} \in F \quad (1.13)$$

Într-adevăr, fiindcă  $F$  nu este o mulțime vidă, conține cel puțin un element  $A$ , iar conform **P1**, va conține și  $\bar{A}$ . Prin urmare,  $A \cup \bar{A} = S \in F$  și  $A \cap \bar{A} = \{\emptyset\} \in F$ .

Din cele de mai sus, rezultă că toate mulțimile ce se pot scrie ca reuniuni sau intersecții ale unui număr finit de mulțimi din  $F$  sunt și ele în  $F$ . Aceasta, însă, nu este în mod necesar cazul și pentru un număr infinit de mulțimi. Suntem astfel nevoiți să introducem noțiunea de *câmp Borel*.

Dacă pentru orice șir infinit  $A_1, \dots, A_n, \dots$  de mulțimi din  $F$ , reuniunea și intersecția acestor mulțimi aparțin și ele lui  $F$ , atunci  $F$  se numește un câmp Borel.

Clasa tuturor submulțimilor unei mulțimi  $S$  este un câmp Borel. Să presupunem că o clasă  $C$  de submulțimi ale lui  $S$  nu este un câmp. Adăugându-i alte submulțimi ale lui  $S$ , toate submulțimile dacă este necesar, putem forma un câmp având  $C$  drept submulțime.

Pentru cazul unui număr infinit de mulțimi, trebuie să adăugăm la cele trei axiome ale probabilității o a patra, numită *axioma probabilității infinite*:

**A4.** Dacă evenimentele  $A_1, A_2, \dots$  sunt mutual exclusive, atunci

$$P(A_1 \cup A_2 \cup \dots) = P(A_1) + P(A_2) + \dots \quad (1.14)$$

### 1.5. DEFINIȚIA AXIOMATICĂ A UNUI EXPERIMENT

În teoria probabilității, specificăm un experiment cu ajutorul următoarelor concepte:

1. Mulțimea  $S$  a tuturor rezultatelor experimentale.
2. Câmpul Borel al tuturor evenimentelor din  $S$ .
3. Probabilitățile acestor evenimente.

Dacă spațiul  $S$  constă din  $N$  rezultate, unde  $N$  este un număr finit, iar evenimentul elementar  $\zeta_i$  are probabilitatea  $p_i$ , conform axiomelor probabilității, numerele  $p_i$  trebuie să fie pozitive iar suma lor trebuie să fie egală cu 1:



$$p_i \geq 0 \text{ și } p_1 + \dots + p_N = 1 \quad (1.15)$$

Probabilitatea oricărui eveniment  $A$  constând din  $r$  evenimente elementare se poate scrie ca suma probabilităților acestora.

## 1.6. DREAPTA REALĂ

Să presupunem că  $S$  este mulțimea numerelor reale. Submulțimile sale pot fi considerate drept mulțimi de puncte de pe dreapta numerelor reale. Se poate arăta că este imposibil să atribuim probabilități tuturor submulțimilor lui  $S$  astfel încât să satisfacă axiomele **A1**–**A4**. Pentru a construi un spațiu de probabilitate pe dreapta numerelor reale, vom considera drept evenimente intervalele  $x_1 \leq x \leq x_2$  precum și reuniunile și intersecțiile numărabile ale acestora. Aceste evenimente formează un câmp  $\mathcal{F}$  definit drept cel mai mic câmp Borel ce include toate semidreptele  $x \leq x_i$ , unde  $x_i$  este orice număr real. Acest câmp conține toate intervalele deschise și închise, toate punctele și, practic, toate mulțimile de puncte de pe dreapta numerelor reale ce prezintă interes în aplicații. Menționăm că există mulțimi de puncte de pe dreapta numerelor reale care nu sunt reuniuni și intersecții numărabile de intervale, dar ele nu prezintă interes în majoritatea aplicațiilor.

Presupunem că  $p(x) \geq 0$  este o funcție astfel încât

$$\int_{-\infty}^{\infty} p(x) dx = 1 \quad (1.16)$$

Definim probabilitatea evenimentului  $\{x \leq x_i\}$  prin integrala

$$P\{x \leq x_i\} = \int_{-\infty}^{x_i} p(x) dx \quad (1.17)$$

Probabilitatea evenimentului  $\{x_1 < x \leq x_2\}$  constând din toate punctele din intervalul  $(x_1, x_2]$  este dată de

$$P\{x_1 < x \leq x_2\} = \int_{x_1}^{x_2} p(x) dx \quad (1.18)$$

Într-adevăr, evenimentele  $\{x \leq x_1\}$  și  $\{x_1 < x \leq x_2\}$  sunt mutual exclusive iar reuniunea lor este egală cu  $\{x \leq x_2\}$ . Conform axiomei **A3**, avem

## 10 PROBABILITATE, VARIABLE ALEATOARE ȘI PROCESE STOCHASTICE

$$P\{x \leq x_1\} + P\{x_1 < x \leq x_2\} = P\{x \leq x_2\}$$

și (1.8) rezultă din (1.17).


Observăm că, dacă funcția  $p(x)$  este mărginită, integrala din (1.18) tinde spre 0 pentru  $x_1 \rightarrow x_2$ . Aceasta conduce la concluzia că probabilitatea evenimentului  $\{x_1\}$  constând din rezultatul  $x_1$  este 0 pentru orice  $x_1$ . Deci, probabilitatea tuturor evenimentelor elementare din  $S$  este egală cu 0, deși probabilitatea reuniunii lor este egală cu 1. Aceasta nu vine în conflict cu axioma **A4**, căci mulțimea elementelor lui  $S$  nu este numărabilă.

### Mase de probabilitate

Putem interpreta probabilitatea  $P(A)$  a unui eveniment  $A$  drept masa figurii corespunzătoare din reprezentarea prin diagrama Venn. Fie, de exemplu, identitatea

$$P(A \cup B) = P(A) + P(B) - P(A \cap B).$$

Membrul stâng este egal cu masa evenimentului  $A \cup B$ . În suma  $P(A) + P(B)$ , masa lui  $A \cap B$  este socotită de două ori. Pentru a obține din această sumă  $P(A \cup B)$ , trebuie deci să scădem din ea  $P(A \cap B)$ .



**Fig. 1.1.** Diagrama Venn a spațiului de probabilitate  $S$  arătând două mulțimi de evenimente  $A$  și  $B$  împreună cu reuniunea  $A \cup B$  și intersecția  $A \cap B$  lor.

## 1.7. EVENIMENTE COMUNE ȘI PROBABILITĂȚI COMUNE

Fie două experimente, primul constând din aruncarea unui zar nemăsluit

$$S_1 = \{f_1, \dots, f_6\} \text{ cu } P_1(f_i) = \frac{1}{6}$$

și al doilea constând din aruncarea unei monede nemăsluite

$$S_2 = \{c, b\} \text{ cu } P_2\{c\} = P_2\{b\} = \frac{1}{2}.$$

Să considerăm experimentul combinat constând din efectuarea ambelor experimente  $S_1$  și  $S_2$ . Produsul cartezian  $S_1 \times S_2$  este o mulțime  $S$  ale cărei elemente sunt toate perechile ordonate  $\zeta_1 \zeta_2$ , unde  $\zeta_1 \in S_1$  și  $\zeta_2 \in S_2$ .

$$S = S_1 \times S_2$$

Dacă  $A$  este o submulțime a lui  $S_1$  iar  $B$  este o submulțime a lui  $S_2$ , mulțimea  $C = A \times B$ , constând din toate perechile  $\zeta_1 \zeta_2$ , unde  $\zeta_1 \in A$  și  $\zeta_2 \in B$ , este o submulțime a lui  $S$ .

Produsul cartezian al experimentelor  $S_1$  și  $S_2$  este un nou experiment  $S = S_1 \times S_2$  ale cărui evenimente sunt toate produsele carteziene de forma  $A \times B$ , unde  $A$  este un eveniment din  $S_1$  iar  $B$  este un evenimente din  $S_2$ , precum și reuniunile și intersecțiile acestora.

În acest experiment, dacă  $P_1(A)$  este probabilitatea evenimentului  $A$  în experimentul  $S_1$  iar  $P_2(B)$  este probabilitatea evenimentului  $B$  în experimentul  $S_2$ , probabilitățile evenimentelor  $A \times S_2$  și  $S_1 \times B$  sunt

$$P(A \times S_2) = P_1(A) \tag{1.19}$$

$$P(S_1 \times B) = P_2(B) \tag{1.20}$$

### Experimente independente

Două evenimente  $A$  și  $B$  se spune că sunt independente dacă

$$P(A \cap B) = P(A)P(B) \tag{1.21}$$

În multe aplicații, evenimentele  $A \times S_2$  și  $S_1 \times B$  din experimentul combinat  $S$  sunt independente pentru orice  $A$  și  $B$ . Întrucât intersecția acestor evenimente este egală cu  $A \times B$ , din (1.19), (1.20) și (1.21) conchidem că

## 12 PROBABILITATE, VARIABLE ALEATOARE ȘI PROCESE STOCHASTICE

$$P(A \times B) = P(A \times S_2)P(S_1 \times B) = P_1(A)P_2(B) \quad (1.22)$$

Vom reformula conceptul de experiment combinat astfel: dacă un experiment are rezultatele posibile  $A_i, i = 1, 2, \dots, n$ , iar cel de al doilea experiment are rezultatele posibile  $B_j, j = 1, 2, \dots, m$ , experimentul combinat are rezultatele comune posibile  $(A_i, B_j), i = 1, 2, \dots, n, j = 1, 2, \dots, m$ . Probabilitatea comună  $P(A_i, B_j)$  asociată cu evenimentul comun  $(A_i, B_j)$  satisface condiția

$$0 \leq P(A_i, B_j) \leq 1$$

Presupunând că rezultatele  $B_j, j = 1, 2, \dots, m$  sunt mutual exclusive, urmează că

$$\sum_{j=1}^m P(A_i, B_j) = P(A_i) \quad (1.23)$$

Similar, dacă rezultatele  $A_i, i = 1, 2, \dots, n$  sunt mutual exclusive, avem

$$\sum_{i=1}^n P(A_i, B_j) = P(B_j) \quad (1.24)$$

$P(A_i)$  din (1.23) și  $P(B_j)$  din (1.24) se spune că sunt probabilități *marginale*. Dacă toate rezultatele celor două experimente sunt mutual exclusive, avem

$$\sum_{i=1}^n \sum_{j=1}^m P(A_i, B_j) = 1 \quad (1.25)$$

### 1.8. PROBABILITĂȚI CONDIȚIONATE

Să considerăm un experiment combinat în care un eveniment comun apare cu probabilitate  $P(A, B)$ . Presupunem că evenimentul  $B$  a apărut și vrem să determinăm probabilitatea de apariție a evenimentului  $A$ . Aceasta se numește probabilitatea evenimentului  $A$  condiționată de apariția evenimentului  $B$  și se definește prin relația

$$P(A|B) = \frac{P(A, B)}{P(B)} \quad (1.26)$$

pentru  $P(B) > 0$ . Similar, probabilitatea evenimentului  $B$  condiționată de apariția evenimentului  $A$  este

$$P(B|A) = \frac{P(A, B)}{P(A)} \quad (1.27)$$

pentru  $P(A) > 0$ . Combinând (1.26) și (1.27), obținem:

$$P(A, B) = P(A|B)P(B) = P(B|A)P(A) \quad (1.28)$$

Aceste relații se aplică și în cazul unui singur experiment în care  $A$  și  $B$  sunt două evenimente definite pe spațiul eșantioanelor  $S$  iar  $P(A, B)$  este interpretată drept probabilitatea lui  $A \cap B$ . Cu alte cuvinte,  $P(A, B)$  este probabilitatea apariției simultane a evenimentelor  $A$  și  $B$ . Dacă două evenimente  $A$  și  $B$  sunt mutual exclusive,  $A \cap B = \{\emptyset\}$  și deci  $P(A|B) = 0$ . Dacă  $A$  este o submulțime a lui  $B$ ,  $A \cap B = A$  și deci

$$P(A|B) = \frac{P(A)}{P(B)}.$$

Dacă însă  $B$  este o submulțime a lui  $A$ , avem  $A \cap B = B$  și deci

$$P(A|B) = \frac{P(B)}{P(B)} = 1.$$

### Teorema probabilității totale

O partiție  $U = [A_1, \dots, A_n]$  a lui  $S$  este prin definiție o colecție de  $n$  submulțimi  $A_1, \dots, A_n$  ale lui  $S$  disjuncte a căror reuniune este egală cu  $S$ . Fie  $B$  un eveniment arbitrar. Avem atunci

$$P(B) = P(B|A_1)P(A_1) + \dots + P(B|A_n)P(A_n) \quad (1.29)$$

#### Demonstrație

Este clar că

$$B = B \cap S = B \cap (A_1 \cup \dots \cup A_n) = (B \cap A_1) \cup \dots \cup (B \cap A_n).$$

Dar evenimentele  $B \cap A_i$  și  $B \cap A_j$  sunt mutual exclusive din cauză că evenimentele  $A_i$  și  $A_j$  sunt mutual exclusive. Prin urmare

$$P(B) = P(B \cap A_1) + \dots + P(B \cap A_n).$$

Conform (1.28), avem însă

$$P(B \cap A_i) = P(B|A_i)P(A_i)$$

Utilizând aceasta în expresia lui  $P(B)$ , rezultă (1.29).

### **Teorema lui Bayes**

Aplicând (1.28), putem scrie că

$$P(A_i | B) = P(B | A_i) \frac{P(A_i)}{P(B)} \quad (1.30)$$

Introducând (1.29) în (1.30), obținem teorema lui Bayes:

$$P(A_i | B) = \frac{P(B | A_i)P(A_i)}{P(B | A_1)P(A_1) + \dots + P(B | A_n)P(A_n)} \quad (1.31)$$

### **Independență statistică**

Să presupunem că apariția lui  $A$  nu depinde de apariția lui  $B$ , ceea ce înseamnă că

$$P(A | B) = P(A) \quad (1.32)$$

Înlocuind (1.32) în (1.26), obținem că

$$P(A, B) = P(A)P(B) \quad (1.33)$$

Dacă probabilitatea comună a evenimentelor  $A$  și  $B$  se descompune în produsul probabilităților marginale  $P(A)$  și  $P(B)$ , se spune că evenimentele sunt *independente statistic*.

Definiția independenței statistice se poate generaliza la un număr  $n$  de evenimente. Spre exemplu, trei evenimente independente statistic  $A_1$ ,  $A_2$  și  $A_3$  trebuie să satisfacă următoarele condiții:

$$\begin{aligned} P(A_1, A_2) &= P(A_1)P(A_2) \\ P(A_1, A_3) &= P(A_1)P(A_3) \\ P(A_2, A_3) &= P(A_2)P(A_3) \\ P(A_1, A_2, A_3) &= P(A_1)P(A_2)P(A_3) \end{aligned} \quad (1.34)$$

## 1.9. CONCEPTUL DE VARIABILĂ ALEATOARE

Se dă un experiment având un spațiu al eșantioanelor  $S$  și elemente  $s \in S$ . Fie o funcție  $X(s)$  al cărei domeniu de definiție este  $S$  și al cărei domeniu de existență este mulțimea numerelor reale, considerate drept coordonate ale punctelor de pe o dreaptă. Funcția  $X(s)$  se numește o *variabilă aleatoare*. Spre exemplu, în experimentul cu moneda, rezultatele posibile sunt capul ( $c$ ) și banul ( $b$ ), astfel încât  $S$  conține numai două puncte notate  $c$  și  $b$ . Putem defini o funcție  $X(s)$  astfel încât

$$X(s) = \begin{cases} 1 & (s = c) \\ -1 & (s = b) \end{cases} \quad (1.35)$$

În experimentul cu zarul,  $S = \{f_1, f_2, f_3, f_4, f_5, f_6\}$ . O variabilă aleatoare definită pe spațiul eșantioanelor este  $X(f_i) = i$ , în care caz rezultatele experimentului sunt aplicate în întregii 1, ..., 6.

Deși am dat exemple de experimente care au o mulțime finită de rezultate posibile, spațiul eșantioanelor poate fi la fel de bine un domeniu continuu, în care caz spunem că variabila aleatoare este *continuă*. Pentru simplitate, variabila aleatoare  $X(s)$  se scrie  $X$ . Adoptăm convenția de a nota variabila aleatoare cu literă mare, iar o valoare pe care o poate ea lua cu litera mică respectivă. Vom scrie concis că variabila aleatoare  $X$  are distribuția de probabilitate  $p(X)$  astfel:  $X \sim p(x)$ .

Se dă o variabilă aleatoare  $X$ . Să considerăm evenimentul  $\{X \leq x\}$  unde  $x$  este orice număr real din intervalul  $(-\infty, \infty)$ . Scriem probabilitatea acestui eveniment  $P(X \leq x)$  și o notăm cu  $F_X(x)$

$$F_X(x) = P(X \leq x), \quad -\infty < x < \infty \quad (1.36)$$

Indicele  $X$  din  $F_X(x)$  arată despre ce variabilă aleatoare este vorba și poate fi omis dacă nu există ambiguitate. Funcția  $F(x)$  se numește *funcția distribuție de probabilitate* a variabilei aleatoare  $X$ . Ea se mai numește și *funcția de distribuție cumulativă* (FDC). Fiindcă  $F(x)$  este o probabilitate, domeniul ei de existență este limitat la intervalul  $0 \leq F(x) \leq 1$ . Conform definiției (1.36), avem:

$$F(-\infty) = P(X \leq -\infty) = 0$$

$$F(+\infty) = P(X \leq \infty) = 1.$$

Variabila aleatoare generată de aruncarea unei monede nemăsluite și definită de ecuația (1.35) are FDC arătată în figura 1.2.




Fig. 1.2. Funcția de distribuție cumulativă a unei variabile aleatoare generate de aruncarea unei monede conform ecuației (1.35).




Fig. 1.3. Funcția de distribuție cumulativă a unei variabile aleatoare generate prin aruncarea zarului conform ecuației  $X(f_i) = i$ .



$F(x)$  are două discontinuități sau salturi, una la  $x = -1$  și alta la  $x = +1$ . Similar, variabila aleatoare  $X(s) = s$  generată de aruncarea unui zar are FDC arătată în figura 1.3. În acest caz,  $F(x)$  are șase salturi, câte unul la fiecare din punctele  $x = 1, \dots, 6$ .

Funcția de distribuție cumulativă a unei variabile aleatoare continue, așa cum se vede și din figura 1.4, este o funcție continuă, nedescrescătoare de  $x$ .




Fig. 1.4. Exemplu de funcție de distribuție cumulativă a unei variabile aleatoare continue.


În practică, putem întâlni și variabile aleatoare de tip *mixt*, așa cum se arată în figura 1.5. FDC a unei astfel de variabile aleatoare este o funcție continuă pe porțiuni, nedescrescătoare și conține salturi într-un număr de valori discrete ale lui  $x$ .

Derivata lui  $F(x)$ , notată  $p(x)$ , se numește *funcția densitate de probabilitate* (FDP) a variabilei aleatoare  $X$ . Deci, avem

$$p(x) = \frac{dF(x)}{dx} \quad -\infty < x < \infty \quad (1.37)$$

sau, echivalent,

$$F(x) = \int_{-\infty}^x p(u)du, \quad -\infty < x < \infty \quad (1.38)$$



**Fig. 1.5.** Exemplu de funcție de distribuție cumulativă a unei variabile aleatoare de tip mixt.

Fiindcă  $F(x)$  este o funcție nedescrescătoare, urmează că  $p(x) \geq 0$ . Dacă variabila aleatoare este discretă sau de tip mixt, FDP conține impulsuri în punctele de discontinuitate ale lui  $F(x)$ . În asemenea cazuri, partea discretă a lui  $p(x)$  poate fi exprimată astfel:

$$p(x) = \sum_{i=1}^n P(X = x_i) \delta(x - x_i) \quad (1.39)$$

unde  $x_i, i = 1, 2, \dots, n$  sunt valorile discrete posibile ale variabilei aleatoare,  $P(X = x_i), i = 1, 2, \dots, n$  sunt probabilitățile iar cu  $\delta(x)$  am notat un impuls Dirac în  $x = 0$ .

Să determinăm probabilitatea ca o variabilă aleatoare  $X$  să cadă într-un interval  $(x_1, x_2)$ , unde  $x_2 > x_1$ . Este evident că evenimentul  $\{X \leq x_2\}$  este reuniunea a două evenimente mutual exclusive  $\{X \leq x_1\}$  și  $\{x_1 < X \leq x_2\}$ . Conform axiomei **A3**, putem exprima probabilitatea evenimentului  $\{X \leq x_2\}$  drept suma probabilităților celor două evenimente mutual exclusive. Avem deci

$$\begin{aligned} P(X \leq x_2) &= P(X \leq x_1) + P(x_1 < X \leq x_2) \\ F(x_2) &= F(x_1) + P(x_1 < X \leq x_2) \end{aligned}$$

sau, echivalent,

$$P(x_1 < X \leq x_2) = F(x_2) - F(x_1) = \int_{x_1}^{x_2} p(x) dx \quad (1.40)$$

Cu alte cuvinte, probabilitatea evenimentului  $\{x_1 < X \leq x_2\}$  este aria suprafeței de sub curba FDP în intervalul  $x_1 < X \leq x_2$ .

Fie acum două variabile aleatoare  $X_1$  și  $X_2$ , fiecare din ele putând fi continuă, discretă sau mixtă. Prin definiție, FDC comună a celor două variabile aleatoare este

$$\begin{aligned} F(x_1, x_2) &= P(X_1 \leq x_1, X_2 \leq x_2) \\ &= \int_{-\infty}^{x_1} \int_{-\infty}^{x_2} p(u_1, u_2) du_1 du_2 \end{aligned} \quad (1.41)$$

unde  $p(x_1, x_2)$  este FDP comună. Putem exprima această FDP comună în forma

$$p(x_1, x_2) = \frac{\partial^2}{\partial x_1 \partial x_2} F(x_1, x_2) \quad (1.42)$$

Dacă integrăm  $p(x_1, x_2)$  pe una din variabile, obținem FDP a celeilalte variabile:

$$\int_{-\infty}^{\infty} p(x_1, x_2) dx_1 = p(x_2) \quad (1.43)$$

$$\int_{-\infty}^{\infty} p(x_1, x_2) dx_2 = p(x_1) \quad (1.44)$$

Aceste funcții densitate de probabilitate  $p(x_1)$  și  $p(x_2)$  obținute integrând pe una din variabile se numesc funcții densitate de probabilitate *marginale*. Integrând  $p(x_1, x_2)$  pe ambele variabile, obținem:

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} p(x_1, x_2) dx_1 dx_2 = F(\infty, \infty) = 1 \quad (1.45)$$

Se observă că  $F(-\infty, -\infty) = F(-\infty, x_2) = F(x_1, -\infty) = 0$ .

Vrem acum să determinăm probabilitatea ca variabila aleatoare  $X_1 \leq x_1$  condiționată de faptul că  $x_2 - \Delta x_2 < X_2 \leq x_2$  unde  $\Delta x_2$  este un

increment pozitiv. Cu alte cuvinte, dorim să determinăm probabilitatea evenimentului  $(X_1 \leq x_1 \mid x_2 - \Delta x_2 < X_2 \leq x_2)$ . Conform definiției probabilității condiționate a unui eveniment, putem exprima probabilitatea evenimentului  $(X_1 \leq x_1 \mid x_2 - \Delta x_2 < X_2 \leq x_2)$  drept probabilitatea evenimentului comun  $(X_1 \leq x_1, x_2 - \Delta x_2 < X_2 \leq x_2)$  împărțită la probabilitatea evenimentului  $(x_2 - \Delta x_2 < X_2 \leq x_2)$ . Deci

$$\begin{aligned} P(X_1 \leq x_1 \mid x_2 - \Delta x_2 < X_2 \leq x_2) &= \frac{\int_{-\infty}^{x_1} \int_{x_2 - \Delta x_2}^{x_2} p(u_1, u_2) du_1 du_2}{\int_{x_2 - \Delta x_2}^{x_2} p(u_2) du_2} \\ &= \frac{F(x_1, x_2) - F(x_1, x_2 - \Delta x_2)}{F(x_2) - F(x_2 - \Delta x_2)} \end{aligned} \quad (1.46)$$

În ipoteza că  $p(x_1, x_2)$  și  $p(x_2)$  sunt funcții continue pe intervalul  $(x_2 - \Delta x_2, x_2)$ , putem împărți atât numărătorul cât și numitorul din (1.46) cu  $\Delta x_2$  și trece la limită pentru  $\Delta x_2 \rightarrow 0$ . Obținem astfel

$$\begin{aligned} P(X_1 \leq x_1 \mid X_2 = x_2) &\equiv F(x_1 \mid x_2) = \frac{\partial F(x_1, x_2) / \partial x_2}{\partial F(x_2) / \partial x_2} \\ &= \frac{\partial \left[ \int_{-\infty}^{x_1} \int_{-\infty}^{x_2} p(u_1, u_2) du_1 du_2 \right] / \partial x_2}{\partial \left[ \int_{-\infty}^{x_2} p(u_2) du_2 \right] / \partial x_2} \\ &= \frac{\int_{-\infty}^{x_1} p(u_1, x_2) du_1}{p(x_2)} \end{aligned} \quad (1.47)$$

Aceasta este FDC a variabilei aleatoare  $X_1$  condiționată de variabila aleatoare  $X_2$ . Observăm că  $F(-\infty \mid x_2) = 0$  și  $F(\infty \mid x_2) = 1$ . Derivând ecuația (1.47) în raport cu  $x_1$ , obținem funcția densitate de probabilitate  $p(x_1 \mid x_2)$  în forma

$$p(x_1 \mid x_2) = \frac{p(x_1, x_2)}{p(x_2)} \quad (1.48)$$

Putem exprima FDP comună  $p(x_1, x_2)$  cu ajutorul funcțiilor densitate de probabilitate condiționate astfel:

$$p(x_1, x_2) = p(x_1 \mid x_2)p(x_2) = p(x_2 \mid x_1)p(x_1) \quad (1.49)$$

### 1.10. FUNCȚII DE O VARIABILĂ ALEATOARE

Fie  $X$  o variabilă aleatoare și  $g(x)$  o funcție de variabila reală  $x$ .  
Expresia

$$Y = g(X) \quad (1.50)$$

este o nouă variabilă aleatoare definită după cum urmează: pentru un eveniment  $\zeta$  dat,  $X(\zeta)$  este un număr iar  $g[X(\zeta)]$  este un alt număr specificat în funcție de  $X(\zeta)$  și de  $g(x)$ . Acest număr este valoarea  $Y(\zeta) = g[X(\zeta)]$  atribuită variabilei aleatoare  $Y$ . Deci, o funcție de o variabilă aleatoare  $X$  este o funcție compusă  $Y = g(X) = g[X(\zeta)]$  al cărei domeniu de definiție este mulțimea  $S$  a rezultatelor experimentale.

Funcția de distribuție  $F_Y(y)$  a variabilei aleatoare astfel formate este probabilitatea evenimentului  $\{Y \leq y\}$  constând din toate rezultatele  $\zeta$  astfel încât  $Y(\zeta) = g[X(\zeta)] \leq y$ . Deci

$$F_Y(y) = P\{Y \leq y\} = P\{g(X) \leq y\} \quad (1.51)$$

Pentru un  $y$  particular, valorile lui  $x$  astfel încât  $g(x) \leq y$  formează o mulțime de pe axa  $x$  notată cu  $R_y$ . În mod clar,  $g[X(\zeta)] \leq y$  dacă  $X(\zeta)$  este un număr din mulțimea  $R_y$ . Prin urmare

$$F_Y(y) = P\{X \in R_y\} \quad (1.52)$$

Conchidem că, pentru ca  $g(X)$  să fie o variabilă aleatoare, funcția  $g(x)$  trebuie să aibă următoarele proprietăți:

1. Domeniul ei de definiție trebuie să includă domeniul de existență al variabilei aleatoare  $X$ .
2. Trebuie să fie o funcție *Borel*, adică, pentru orice  $y$ , mulțimea  $R_y$  astfel încât  $g(x) \leq y$  trebuie să conste din reuniunea și intersecția unei mulțimi numărabile de intervale. Numai atunci  $\{Y \leq y\}$  este un eveniment.
3. Evenimentele  $\{g(X) = \pm\infty\}$  trebuie să aibe probabilitate zero.

**EXEMPLUL 1.1:** Fie variabila aleatoare  $Y$  definită prin

$$Y = aX + b \quad (1.53)$$

unde  $a$  și  $b$  sunt constante.

(a) Dacă  $a > 0$ , avem  $ax + b \leq y$  pentru  $x \leq \frac{y-b}{a}$ . Prin urmare,

$$\begin{aligned} F_Y(y) &= P(Y \leq y) = P(aX + b \leq y) = P\left(X \leq \frac{y-b}{a}\right) \\ &= F_X\left(\frac{y-b}{a}\right) = \int_{-\infty}^{(y-b)/a} p_X(x) dx \end{aligned} \quad (1.54)$$

Derivând ecuația (1.54) în raport cu  $y$ , obținem relația dintre funcțiile densitate de probabilitate respective:

$$p_Y(y) = \frac{1}{a} p_X\left(\frac{y-b}{a}\right) \quad (1.55)$$

(b) Dacă  $a < 0$ , avem  $ax + b \leq y$  pentru  $x > (y-b)/a$ . Prin urmare,

$$\begin{aligned} F_Y(y) &= P(Y \leq y) = P\left(X > \frac{y-b}{a}\right) = 1 - P\left(X \leq \frac{y-b}{a}\right) \\ &= 1 - F_X\left(\frac{y-b}{a}\right) \end{aligned} \quad (1.56)$$

**EXEMPLUL 1.2:** Fie variabila aleatoare  $Y$  definită prin

$$Y = aX^3 + b, a > 0 \quad (1.57)$$

Funcția  $y = ax^3 + b$  este bijectivă și, deci, inversabilă. Prin urmare,

$$\begin{aligned} F_Y(y) &= P(Y \leq y) = P(aX^3 + b \leq y) \\ &= P\left[X \leq \left(\frac{y-b}{a}\right)^{1/3}\right] = F_X\left[\left(\frac{y-b}{a}\right)^{1/3}\right] \end{aligned} \quad (1.58)$$

Derivând ecuația (1.58) în raport cu  $y$ , obținem relația dintre cele două FDP:

$$p_Y(y) = \frac{1}{3a[(y-b)/a]^{2/3}} p_X\left[\left(\frac{y-b}{a}\right)^{1/3}\right] \quad (1.59)$$

**EXEMPLUL 1.3:** Definim variabila aleatoare  $Y$  prin

$$Y = aX^2 + b, a > 0 \quad (1.60)$$

Spre deosebire de exemplele precedente, funcția  $y = g(x)$  nu este bijectivă. Pentru a determina FDC a lui  $Y$ , observăm că

$$F_Y(y) = P(Y \leq y) = P(aX^2 + b \leq y) = P\left(|X| \leq \sqrt{\frac{y-b}{a}}\right)$$

Prin urmare,

$$F_Y(y) = F_X\left(\sqrt{\frac{y-b}{a}}\right) - F_X\left(-\sqrt{\frac{y-b}{a}}\right) \quad (1.61)$$

Derivând ecuația (1.61) în raport cu  $y$ , obținem FDP a lui  $Y$  în funcție de FDP a lui  $X$  astfel:

$$p_Y(y) = \frac{p_X[\sqrt{(y-b)/a}]}{2a\sqrt{[(y-b)/a]}} + \frac{p_X[-\sqrt{(y-b)/a}]}{2a\sqrt{[(y-b)/a]}} \quad (1.62)$$

În Exemplul 1.3, observăm că ecuația

$$g(x) = ax^2 + b = y$$

are două rădăcini reale,

$$x_1 = \sqrt{\frac{y-b}{a}} \quad \text{și} \quad x_2 = -\sqrt{\frac{y-b}{a}}$$

și că  $p_Y(y)$  constă din doi termeni corespunzători acestor două soluții.

## 1.11. MEDII STATISTICE ALE VARIABILELOR ALEATOARE

Fie o variabilă aleatoare  $X$  de tip discret caracterizată prin distribuția de probabilitate  $P(x_i)$ ,  $i = 1, \dots, n$ . Prin definiție, *valoarea medie* sau *așteptată* a lui  $X$  este

$$E(X) \equiv m_x = \sum_{i=1}^n x_i P(x_i) \quad (1.63)$$

## 24 PROBABILITATE, VARIABLE ALEATOARE ȘI PROCESE STOCHASTICE

Fie o variabilă aleatoare  $X$  de tip continuu caracterizată prin FDP a ei  $p(x)$ . Prin definiție, *valoarea medie* sau *așteptată* a lui  $X$  este

$$E(X) \equiv m_x = \int_{-\infty}^{\infty} xp(x)dx \quad (1.64)$$

Operatorul  $E(\bullet)$  are o deosebită importanță în teoria probabilității. Notăția sa prin litera  $E$  se explică prin aceea că în engleză (*expectation*), în franceză (*espérance*) și în germană (*Erwartung*), această noțiune fundamentală se exprimă prin cuvinte cu inițiala  $e$ . În limba română există cuvântul „expectație” ca termen livresc pentru „așteptare, speranță”<sup>1</sup>. Ar fi indicat să-l utilizăm și noi în teoria probabilității și în teoria informației, fără a pierde din vedere că sensul său este de „lucru, valoare la care trebuie să ne așteptăm în medie”. Valoarea medie sau expectația, definită în (1.64), este și momentul de ordinul unu al variabilei aleatoare  $X$ . În general, momentul de ordinul  $n$  se definește prin

$$E(X^n) = \int_{-\infty}^{\infty} x^n p(x)dx \quad (1.65)$$

Fie acum o variabilă aleatoare  $Y = g(X)$ , unde  $g(X)$  este o funcție arbitrară de variabila aleatoare  $X$ . Media (expectația) lui  $Y$  este

$$E(Y) = E[g(X)] = \int_{-\infty}^{\infty} g(x)p(x)dx \quad (1.66)$$

În particular, dacă  $Y = (X - m_x)^n$  unde  $m_x$  este valoarea medie a lui  $X$ , definim *momentul central de ordinul  $n$*  al variabilei aleatoare  $X$  astfel:

$$E(Y) = E[(X - m_x)^n] = \int_{-\infty}^{\infty} (x - m_x)^n p(x)dx \quad (1.67)$$

Pentru  $n = 2$ , momentul central se numește *varianța* variabilei aleatoare și se notează  $\sigma_x^2$ :

$$\sigma_x^2 = \int_{-\infty}^{\infty} (x - m_x)^2 p(x)dx \quad (1.68)$$

Rădăcina pătrată a varianței,  $\sigma_x$ , se numește *deviația standard* a lui  $X$ .

Varianța este un parametru care ne dă o măsură a dispersiei variabilei aleatoare  $X$ . Să dezvoltăm termenul  $(x - m_x)^2$  din integrala ecuației (1.68):

---

<sup>1</sup> Vezi „Dicționarul explicativ al limbii române” (DEX) redactat de Institutul de lingvistică „Iorgu Iordan” și editat sub egida Academiei Române, p. 358.



$$(x - m_x)^2 = x^2 - 2m_x x + m_x^2$$

Întrucât valoarea medie a unei constante este egală cu constanta, obținem expresia care leagă varianța de momentele de ordinul unu și doi:

$$\sigma_x^2 = E(X^2) - [E(X)]^2 = E(X^2) - m_x^2 \quad (1.69)$$

Fie acum două variabile aleatoare  $X_1$  și  $X_2$  cu FDP comună  $p(x_1, x_2)$ . Definim *momentul comun* astfel:

$$E(X_1^k X_2^n) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x_1^k x_2^n p(x_1, x_2) dx_1 dx_2 \quad (1.70)$$

Să notăm mediile  $m_i = E(X_i)$  pentru  $i = 1, 2$ . Definim *momentul central comun* astfel:

$$E[(X_1 - m_1)^k (X_2 - m_2)^n] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x_1 - m_1)^k (x_2 - m_2)^n p(x_1, x_2) dx_1 dx_2 \quad (1.71)$$

De o importanță deosebită pentru noi sunt momentul comun și momentul central comun corespunzătoare lui  $k = n = 1$ .

Corelația dintre  $X_1$  și  $X_2$  este dată de momentul comun

$$E(X_1 X_2) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x_1 x_2 p(x_1, x_2) dx_1 dx_2 \quad (1.72)$$

Covarianța lui  $X_1$  și  $X_2$  este

$$\begin{aligned} \mu_{12} &\equiv E[(X_1 - m_1)(X_2 - m_2)] \\ &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x_1 - m_1)(x_2 - m_2) p(x_1, x_2) dx_1 dx_2 \\ &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x_1 x_2 p(x_1, x_2) dx_1 dx_2 - m_1 m_2 = E(X_1, X_2) - m_1 m_2 \end{aligned} \quad (1.73)$$

## 1.12. FUNȚII CARACTERISTICE

Prin definiție, *funcția caracteristică* a variabilei aleatoare  $X$  este media statistică

$$E(e^{jvX}) \equiv \psi(jv) = \int_{-\infty}^{\infty} e^{jvx} p(x) dx \quad (1.74)$$

unde variabila  $v$  este reală iar  $j = \sqrt{-1}$ .

## 26 PROBABILITATE, VARIABLE ALEATOARE ȘI PROCESE STOCHASTICE

Observăm că  $\psi(jv)$  seamănă cu transformata Fourier a lui  $p(x)$ , deosebirea constând în semnul exponentului. Prin analogie cu transformata Fourier inversă, putem scrie:

$$p(x) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \psi(jv) e^{-jvx} dv \quad (1.75)$$

Funcția caracteristică are o relație foarte utilă cu momentele variabilei aleatoare. Să derivăm ecuația (1.74) în raport cu  $v$ :

$$\frac{d\psi(jv)}{dv} = j \int_{-\infty}^{\infty} x e^{jvx} p(x) dx \quad (1.76)$$

Evaluând derivata în  $v = 0$ , obținem momentul de ordinul unu, sau media statistică

$$E(X) = m_x = -j \left. \frac{d\psi(jv)}{dv} \right|_{v=0} \quad (1.77)$$


Repetând procesul de derivare, găsim că derivata de ordinul  $n$  a lui  $\psi(jv)$  evaluată în  $v = 0$  ne dă momentul de ordinul  $n$ :

$$E(X^n) = (-j)^n \left. \frac{d^n \psi(jv)}{dv^n} \right|_{v=0} \quad (1.78)$$

### 1.13. DISTRIBUȚII DE PROBABILITATE

#### Distribuție binomială

Fie  $X$  o variabilă aleatoare discretă care are două valori posibile, să spunem  $X = 1$  și  $X = 0$  cu probabilități  $p$  și  $1 - p$ , respectiv. FDP a lui  $X$  este arătată în figura 1.6.

Fig.1.6. Funcția distribuție de probabilitate a lui  $X$ .

Formăm variabila aleatoare

$$Y = \sum_{i=1}^n X_i$$

unde  $X_i, i=1,2,\dots,n$  sunt variabile aleatoare distribuite identic și independente statistic cu FDP arătată în figura 1.6. Vrem să determinăm funcția distribuție de probabilitate a lui  $Y$ .

Observăm că domeniul de existență al lui  $Y$  este mulțimea întregilor de la 0 la  $n$ . Probabilitatea ca  $Y = 0$  nu este nimic altceva decât probabilitatea ca toate variabilele aleatoare  $X_i$  să fie egale cu zero. Fiindcă aceste  $X_i$  sunt independente statistic,

$$P(Y = 0) = (1 - p)^n \quad (1.79)$$

Probabilitatea ca  $Y = 1$  este probabilitatea ca una din variabilele aleatoare  $X_i = 1$ , toate celelalte fiind  $X_i = 0$ . Întrucât acest eveniment poate surveni în  $n$  moduri diferite,

$$P(Y = 1) = np(1 - p)^{n-1} \quad (1.80)$$

Probabilitatea ca  $Y = k$  este probabilitatea ca  $k$  din variabilele aleatoare  $X_i$  să fie egale cu unu, iar celelalte  $n - k$  să fie egale cu zero. Vom nota numărul combinațiilor de  $n$  obiecte luate câte  $k$  utilizând simbolul

$$\binom{n}{k} \equiv \frac{n!}{k!(n-k)!} \quad (1.81)$$

Reamintim de la cursul de algebră că  $\binom{n}{k}$  este și coeficientul binomial din dezvoltarea binomului lui Newton  $(x + y)^n$ . Deci

$$P(Y = k) = \binom{n}{k} p^k (1-p)^{n-k} \quad (1.82)$$

Funcția densitate de probabilitate a lui  $Y$  se poate exprima astfel:

$$p(y) = \sum_{k=0}^n P(Y = k) \delta(y - k) = \sum_{k=0}^n \binom{n}{k} p^k (1-p)^{n-k} \delta(y - k) \quad (1.83)$$

Funcția de distribuție cumulativă a lui  $Y$  este:

$$F(y) = P(Y \leq y) = \sum_{k=0}^{[y]} \binom{n}{k} p^k (1-p)^{n-k} \quad (1.84)$$

unde am notat cu  $[y]$  cel mai mare întreg  $m$  astfel încât  $m \leq y$ . FDC din ecuația (1.84) caracterizează o funcție aleatoare distribuită binomial.

Să calculăm media statistică (expectația) lui  $Y$ . Conform definiției (1.63),

$$\begin{aligned} E(Y) = m_y &= \int_{-\infty}^{\infty} y p(y) dy \\ &= \int_{-\infty}^{\infty} y \left[ \sum_{k=0}^n p^k (1-p)^{n-k} \delta(y - k) \right] dy \\ &= \int_{-\infty}^{\infty} \left[ \sum_{k=0}^n \binom{n}{k} p^k (1-p)^{n-k} y \delta(y - k) \right] dy \end{aligned} \quad (1.85)$$

Având în vedere că integrarea și însumarea sunt operații liniare, ordinea lor poate fi inversată:

$$m_y = \sum_{k=0}^n \int_{-\infty}^{\infty} \binom{n}{k} p^k (1-p)^{n-k} y \delta(y - k) dy \quad (1.86)$$

Aplicăm acum proprietatea de „filtrare“ a impulsului Dirac:

$$\int_{-\infty}^{\infty} f(x) \delta(x - x_0) dx = f(x_0) \quad (1.87)$$

Ecuația (1.86), aplicând (1.87), devine:

$$m_y = \sum_{k=0}^n \binom{n}{k} k p^k (1-p)^{n-k} = np \sum_{k=1}^n \binom{n-1}{k-1} p^{k-1} (1-p)^{n-k} \quad (1.88)$$

Fie  $m = k - 1$ . Suma din (1.88) se scrie:

$$\sum_{m=0}^{n-1} \binom{n-1}{m} p^m (1-p)^{n-1-m}.$$

Dar aceasta este dezvoltarea binomului lui Newton  $(p+1-p)^{n-1} = 1$ . Prin urmare,

$$m_y = np \quad (1.89)$$

Procedând similar, să calculăm și momentul de ordinul doi al lui  $Y$ . Conform definiției (1.65), avem

$$\begin{aligned} E(Y^2) &= \int_{-\infty}^{\infty} y^2 p(y) dy = \int_{-\infty}^{\infty} y^2 \left[ \sum_{k=0}^n \binom{n}{k} p^k (1-p)^{n-k} \delta(y-k) \right] dy \\ &= \sum_{k=0}^n \int_{-\infty}^{\infty} \binom{n}{k} p^k (1-p)^{n-k} y^2 \delta(y-k) dy = \sum_{k=1}^n \binom{n}{k} k^2 p^k (1-p)^{n-k} \\ &= \sum_{k=1}^n \frac{n!}{k!(n-k)!} k^2 p^k (1-p)^{n-k} = \sum_{k=1}^n \frac{n!}{(k-1)!(n-k)!} k p^k (1-p)^{n-k} \\ &= np \left[ \sum_{m=0}^{n-1} \frac{(n-1)!}{m!(n-m-1)!} (m+1) p^m (1-p)^{n-m-1} \right] \\ &= np \left[ \sum_{m=1}^{n-1} \frac{(n-1)!}{(m-1)!(n-m-1)!} p^m (1-p)^{n-m-1} + \right. \\ &\quad \left. + \sum_{m=0}^{n-1} \frac{(n-1)!}{m!(n-m-1)!} p^m (1-p)^{n-m-1} \right] \end{aligned} \quad (1.90)$$

Fie  $q = m - 1$ . Avem atunci

$$\begin{aligned} E(Y^2) &= np \left[ \sum_{q=0}^{n-2} \frac{(n-1)!}{q!(n-q-2)!} p^{q+1} (1-p)^{n-q-2} + \right. \\ &\quad \left. + \sum_{m=0}^{n-1} \frac{(n-1)!}{m!(n-m+1)!} p^m (1-p)^{n-m-1} \right] \\ &= np \left[ (n-1)p \sum_{q=0}^{n-2} \frac{(n-2)!}{q!(n-q-2)!} p^q (1-p)^{n-q-2} + \right. \\ &\quad \left. + \sum_{m=0}^{n-1} \frac{(n-1)!}{m!(n-m+1)!} p^m (1-p)^{n-m-1} \right] \\ &= np[(n-1)p+1] = n(n-1)p^2 + np = np(1-p) + n^2 p^2 \end{aligned} \quad (1-91)$$

### 30 PROBABILITATE, VARIABLE ALEATOARE ȘI PROCESE STOCHASTICE

Varianta  $\sigma^2$  rezultă imediat din (1.89) și (1.91) conform ecuației (1.69):

$$\sigma^2 = E(Y^2) - m_y^2 = np(1-p) + n^2 p^2 - n^2 p^2 = np(1-p) \quad (1.92)$$

Vom găsi acum funcția caracteristică a variabilei aleatoare  $Y$ . Conform ecuației de definiție (1-74), avem:

$$\begin{aligned} \psi(jv) &= \int_{-\infty}^{\infty} e^{jvy} p(y) dy = \int_{-\infty}^{\infty} e^{jvy} \left[ \sum_{k=0}^n \binom{n}{k} p^k (1-p)^{n-k} \delta(y-k) \right] dy \\ &= \sum_{k=0}^n \int_{-\infty}^{\infty} \binom{n}{k} p^k (1-p)^{n-k} e^{jvy} \delta(y-k) dy = \sum_{k=0}^n \binom{n}{k} p^k (1-p)^{n-k} e^{jkv} \quad (1.93) \\ &= \sum_{k=0}^n \binom{n}{k} (pe^{jv})^k (1-p)^{n-k} = (1-p + pe^{jv})^n \end{aligned}$$

#### Distribuție uniformă

FDP a unei variabile aleatoare distribuite uniform în intervalul  $[a, b]$  este:

$$p(x) = \begin{cases} 0, & x < a \\ \frac{1}{b-a}, & a \leq x \leq b \\ 0, & x > b \end{cases} \quad (1.94)$$

FDC corespunzătoare este:

$$F(x) = \begin{cases} 0, & x < a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ 1, & x > b \end{cases} \quad (1.95)$$

Media statistică (expectația) a lui  $X$  este:

$$E(X) = \int_a^b \frac{x}{b-a} dx = \frac{1}{b-a} \left. \frac{x^2}{2} \right|_a^b = \frac{b^2 - a^2}{2(b-a)} = \frac{1}{2}(a+b) \quad (1.96)$$

Momentul de ordinul doi este:

$$E(X^2) = \int_a^b \frac{x^2}{b-a} dx = \frac{1}{b-a} \left. \frac{x^3}{3} \right|_a^b = \frac{b^3 - a^3}{3(b-a)} = \frac{1}{3}(a^2 + ab + b^2) \quad (1.97)$$

Din (1.96) și (1.97), rezultă imediat:

$$\sigma^2 = \frac{1}{12}(a-b)^2 \quad (1.98)$$

Funcția caracteristică:

$$\Psi(j\nu) = \int_a^b e^{j\nu x} \frac{1}{b-a} dx = \frac{1}{b-a} \frac{e^{j\nu x}}{j\nu} \Big|_a^b = \frac{e^{j\nu b} - e^{j\nu a}}{j\nu(b-a)} \quad (1.99)$$

### Distribuție normală (Gaussiană)

FDP a unei variabile aleatoare distribuite normal (Gaussian) este

$$p(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-(x-m_x)^2/2\sigma^2} \quad (1.100)$$

unde  $m_x$  este media iar  $\sigma^2$  este varianța variabilei aleatoare. Din păcate, funcția  $p(x)$  din (1.100) nu are o primitivă. Pentru a exprima FDC, definim mai înainte o funcție deosebit de importantă în teoria informației și a sistemelor de comunicație, funcția *eroare*:

$$fer(x) = \frac{2}{\sqrt{\pi}} \int_0^x e^{-t^2} dt \quad (1.101)$$

Cu aceasta, FDC este

$$\begin{aligned} F(x) &= \int_{-\infty}^x p(u) du = \frac{1}{\sqrt{2\pi}\sigma} \int_{-\infty}^x e^{-(u-m_x)^2/2\sigma^2} du \\ &= \frac{1}{2} \frac{2}{\sqrt{\pi}} \int_{-\infty}^{(x-m_x)/\sqrt{2}\sigma} e^{-t^2} dt = \frac{1}{2} + \frac{1}{2} fer\left(\frac{x-m_x}{\sqrt{2}\sigma}\right) \end{aligned} \quad (1.102)$$

Definim și funcția *eroare complementară*:

$$ferc(x) = \frac{2}{\sqrt{\pi}} \int_x^{\infty} e^{-t^2} dt = 1 - fer(x) \quad (1.103)$$

Cu aceasta,  $F(x)$  se mai poate scrie și astfel:

$$F(x) = 1 - \frac{1}{2} ferc\left(\frac{x-m_x}{\sqrt{2}\sigma}\right) \quad (1.104)$$

Vom arăta acum că  $p(x)$  din (1.100) este normată corect în sensul că aria suprafeței de sub curba  $y = p(x)$  este egală cu 1. Pentru aceasta, să notăm cu  $I$  integrala lui  $p(x)$ :

$$I = \int_{-\infty}^{\infty} p(x) dx = \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}\sigma} e^{-(x-m_x)^2/2\sigma^2} dx \quad (1.105)$$

Facem schimbarea de variabilă  $u = (x - m_x)/\sigma$  și avem:

$$I = \frac{1}{\sqrt{2\pi}\sigma} \int_{-\infty}^{\infty} e^{-u^2/2} \sigma du = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{-u^2/2} du \quad (1.106)$$

Vom arăta că  $I^2$  este egală cu 1:

$$\begin{aligned} I^2 &= \left[ \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{-x^2/2} dx \right] \left[ \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{-y^2/2} dy \right] \\ &= \frac{1}{2\pi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} e^{-(x^2+y^2)/2} dx dy \end{aligned} \quad (1.107)$$

Trecem acum de la coordonate carteziene la coordonate polare. Fie  $r^2 = x^2 + y^2$  și  $\vartheta = \arctg(y/x)$ . Avem atunci

$$I^2 = \frac{1}{2\pi} \int_0^{2\pi} \left[ \int_0^{\infty} e^{-r^2/2} r dr \right] d\vartheta = \frac{1}{2\pi} \int_0^{2\pi} d\vartheta = 1. \quad (1.108)$$

Deci  $I^2 = 1$  și, prin urmare,  $I = 1$ .

Până acum, am presupus că parametrii  $m_x$  și  $\sigma^2$  din (1.100) sunt media și varianța distribuției. Pentru a arăta că este într-adevăr așa, să rescriem funcția lui Gauss utilizând parametrii arbitrari  $\alpha$  și  $\beta$ :

$$p(x) = \frac{1}{\sqrt{2\pi\beta}} e^{-(x-\alpha)^2/2\beta^2} \quad (1.109)$$

Această funcție este normată corect, după cum am demonstrat în (1.108). Vom arăta mai întâi că parametrul  $\alpha$  este media:

$$m_x = \int_{-\infty}^{\infty} xp(x)dx = \frac{1}{\sqrt{2\pi\beta}} \int_{-\infty}^{\infty} xe^{-(x-\alpha)^2/2\beta^2} dx \quad (1.110)$$

Facem schimbarea de variabilă  $y = (x - \alpha)/\beta$ , obținând:

$$\begin{aligned} m_x &= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} (\beta y + \alpha) e^{-y^2/2} dy \\ &= \frac{\beta}{\sqrt{2\pi}} \int_{-\infty}^{\infty} ye^{-y^2/2} dy + \alpha \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-y^2/2} dy \end{aligned} \quad (1.111)$$

Prima integrală din membrul drept al lui (1.111) este zero din cauză că integrandul este o funcție impară iar integrala este evaluată între limite simetrice. Cea de a doua integrală din membrul drept este integrala unei



funcții distribuție de probabilitate Gaussiene normate corect, astfel încât integrala are o valoare egală cu 1. Prin urmare, (1.111) devine:

$$m_x = \alpha \quad (1.112)$$

și am demonstrat că  $\alpha$  este valoarea medie.

Varianța este

$$\begin{aligned} \sigma^2 &= \int_{-\infty}^{\infty} (x - m_x)^2 p(x) dx \\ &= \frac{1}{\sqrt{2\pi}\beta} \int_{-\infty}^{\infty} (x - m_x)^2 e^{-(x - m_x)^2 / 2\beta^2} dx \end{aligned} \quad (1.113)$$

Trebuie să arătăm că  $\sigma^2 = \beta^2$ . Pentru aceasta, facem schimbarea de variabilă  $y = (x - m_x) / \beta$ , obținând:

$$\sigma^2 = \frac{\beta^2}{\sqrt{2\pi}} \int_{-\infty}^{\infty} y^2 e^{-y^2 / 2} dy \quad (1.114)$$

Fie acum  $J = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} y^2 e^{-y^2 / 2} dy$ . Vom calcula  $J^2$ :

$$\begin{aligned} J^2 &= \left[ \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} x^2 e^{-x^2 / 2} dx \right] \left[ \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} y^2 e^{-y^2 / 2} dy \right] \\ &= \frac{1}{2\pi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x^2 y^2 e^{-(x^2 + y^2) / 2} dx dy \end{aligned} \quad (1.115)$$

Trecând de la coordonate carteziene la coordonate polare, avem:

$$J^2 = \frac{1}{2\pi} \int_0^{2\pi} \int_0^{\infty} \cos^2 \theta \sin^2 \theta d\theta \int_0^{\infty} r^5 e^{-r^2 / 2} dr \quad (1.116)$$

Prima integrală se scrie succesiv:

$$\frac{1}{4} \int_0^{2\pi} \sin^2 2\theta d\theta = \frac{1}{8} \int_0^{2\pi} (1 - \cos 4\theta) d\theta = \frac{\pi}{4} \quad (1.117)$$

Notăm integrala a doua cu  $I_r$ . Cu schimbarea de variabilă  $r^2 / 2 = t$ , avem:

$$I_r = \int_0^{\infty} r^5 e^{-r^2 / 2} dr = 4 \int_0^{\infty} t^2 e^{-t} dt \quad (1.118)$$

### 34 PROBABILITATE, VARIABLE ALEATOARE ȘI PROCESE STOCHASTICE

Vom integra prin părți. Notând  $u = t^2$ ;  $v = -e^{-t}$ , avem:

$$\int_0^{\infty} t^2 e^{-t} dt = t^2 (-e^{-t}) \Big|_0^{\infty} - \int_0^{\infty} -e^{-t} (2t) dt = 2 \int_0^{\infty} t e^{-t} dt \quad (1.119)$$

Integrăm din nou prin părți:

$$\int_0^{\infty} t e^{-t} dt = -t e^{-t} \Big|_0^{\infty} - \int_0^{\infty} -e^{-t} dt = \int_0^{\infty} e^{-t} dt = 1. \quad (1.120)$$

Prin urmare,  $I_r = 4 \cdot 2 = 8$ . Rezultă că

$$J^2 = \frac{1}{2\pi} \cdot \frac{\pi}{4} \cdot 8 = 1. \quad (1.121)$$

Din (1.121), rezultă că  $J = 1$ . Cu această valoare, (1-114) devine  $\sigma^2 = \beta^2$ .

Funcția caracteristică a unei variabile aleatoare Gaussiene cu medie  $m_x$  și varianță  $\sigma_x^2$  este

$$\begin{aligned} \psi(jv) &= \int_{-\infty}^{\infty} e^{jvx} \left[ \frac{1}{\sqrt{2\pi}\sigma_x} e^{-(x-m_x)^2/2\sigma_x^2} \right] dx \\ &= \frac{1}{\sqrt{2\pi}\sigma_x} \int_{-\infty}^{\infty} e^{jvx-(x-m_x)^2/2\sigma_x^2} dx \\ &= \frac{1}{\sqrt{2\pi}\sigma_x} \int_{-\infty}^{\infty} e^{-[x-(m_x+jv\sigma_x^2)]^2/2\sigma_x^2 + jvm_x - (v\sigma_x)^2/2} dx \quad (1.122) \\ &= e^{jvm_x - (v^2\sigma_x^2)/2} \left\{ \frac{1}{\sqrt{2\pi}\sigma_x} \int_{-\infty}^{\infty} e^{-[x-(m_x+jv\sigma_x^2)]^2/2\sigma_x^2} dx \right\} \\ &= e^{jvm_x - (v^2\sigma_x^2)/2} \end{aligned}$$

deoarece termenul dintre acolade este egal cu 1, după cum am demonstrat mai sus (vezi (1.108)).

În cazul particular al unei variabile aleatoare normale cu medie zero și varianță egală cu 1, funcția caracteristică ia forma simplificată

$$\psi(jv) = e^{-v^2/2} \quad (1.123)$$

### Alte distribuții

Să reținem că în teoria sistemelor de comunicație se utilizează multe alte distribuții, între care:

- Chi pătrat
- Rayleigh
- Rice
- Nakagami- $m$
- Student- $t$
- Lognormală
- Gama
- Beta.

În economia acestui curs, ele nu își au locul, dar cunoștințele acumulate până acum sunt suficiente pentru a ne însuși aceste distribuții și altele prin studiu individual, dacă este cazul, recurgând la un manual de teoria probabilității.

## 1.14. INEGALITATEA LUI CEBÎȘEV

Dacă reprezentăm grafic funcția densitate de probabilitate  $p(x)$  a unei variabile aleatoare  $X$ , obținem o curbă ce sugerează un clopot sub care se concentrează „grosul“ probabilității, evenimentele mai puțin probabile formând două „cozi“ laterale (spre  $-\infty$  și spre  $\infty$ ). Prin *probabilitatea cozii* înțelegem aria suprafeței de sub curba  $p(x)$  corespunzătoare cozii. Este adeseori necesar să determinăm această mărime atunci când evaluăm performanța unui sistem de comunicație. Probabilitatea cozii de la dreapta lui  $x$  este dată de

$$1 - F_X(x) = \int_x^{\infty} p(u) du \quad (1.124)$$

Întrucât un calcul exact al integralei din (1.122) nu este întotdeauna posibil, ne interesează o margine superioară a probabilității cozii, care să aproximeze cât mai bine valoarea reală. Începem cu *inegalitatea lui Cebîșev*.

Presupunem că  $X$  este o variabilă aleatoare arbitrară cu medie finită  $m_x$  și varianță finită  $\sigma_x^2$ . Pentru orice număr pozitiv  $\delta$ , avem:

$$P(|X - m_x| \geq \delta) \leq \frac{\sigma_x^2}{\delta^2} \quad (1.125)$$

**Demonstrație:**

$$\begin{aligned} \sigma_x^2 &= \int_{-\infty}^{\infty} (x - m_x)^2 p(x) dx \geq \int_{|x - m_x| \geq \delta} (x - m_x)^2 p(x) dx & (1.126) \\ &\geq \delta^2 \int_{|x - m_x| \geq \delta} p(x) dx = \delta^2 P(|X - m_x| \geq \delta). \end{aligned}$$

Fie variabila aleatoare  $Y = X - m_x$  de medie zero și FDP  $p(y)$ . Inegalitatea lui Cebîșev este o margine superioară a ariei suprafeței de sub cozile lui  $p(y)$ , adică, aria lui  $p(y)$  în intervalele  $(-\infty, -\delta)$  și  $(\delta, \infty)$ . Putem deci scrie

$$\begin{aligned} P(|X - m_x| \geq \delta) &= P(|Y| \geq \delta) \\ &= P(Y \leq -\delta) + P(Y \geq \delta) & (1.127) \\ &= F_Y(-\delta) + 1 - F_Y(\delta) \end{aligned}$$

Putem deci exprima inegalitatea lui Cebîșev astfel:

$$1 - [F_Y(\delta) - F_Y(-\delta)] \leq \frac{\sigma_x^2}{\delta^2} \quad (1.128)$$

sau, echivalent, astfel:

$$1 - [F_X(m_x + \delta) - F_X(m_x - \delta)] \leq \frac{\sigma_x^2}{\delta^2} \quad (1.129)$$

Inegalitatea lui Cebîșev nu ne oferă o aproximație prea bună. Pentru a vedea de ce, să definim o funcție  $g(Y)$  astfel:

$$g(Y) = \begin{cases} 1 & \text{pentru } |Y| \geq \delta \\ 0 & \text{pentru } |Y| < \delta \end{cases} \quad (1.130)$$


Întrucât variabila aleatoare  $g(Y)$  este 0 cu probabilitate  $P(|Y| < \delta)$  și 1 cu probabilitate  $P(|Y| \geq \delta)$ , valoarea ei medie este

$$E[g(Y)] = P(|Y| \geq \delta) \quad (1.131)$$

Să încercăm să mărginim  $g(Y)$  prin forma pătratică  $(Y/\delta)^2$ :

$$g(Y) \leq \left(\frac{Y}{\delta}\right)^2 \quad (1.132)$$

Graficul lui  $g(Y)$  și marginea superioară se arată în figura 1.7.



**Fig.1.7.** Margine superioară pătratică a lui  $g(Y)$  utilizată pentru a obține probabilitatea cozii (marginea Cebîșev).

Din monotonia mediei, urmează că

$$E[g(Y)] \leq E\left(\frac{Y^2}{\delta^2}\right) = \frac{E(Y^2)}{\delta^2} = \frac{\sigma_y^2}{\delta^2} = \frac{\sigma_x^2}{\delta^2} \quad (1.133)$$

Întrucât  $E[g(Y)]$  este probabilitatea cozilor, am regăsit astfel inegalitatea lui Cebîșev.

### 1.15. MARGINEA CHERNOFF

Să presupunem că, pentru o aplicație dată, nu ne interesează decât aria suprafeței de sub una dintre cozi, fie în intervalul  $(-\infty, -\delta)$ , fie în intervalul  $(\delta, \infty)$ . Putem obține o aproximație foarte bună dacă mărginim

funcția  $g(Y)$  printr-o exponențială al cărei parametru poate fi optimizat. Fie probabilitatea cozii în intervalul  $(\delta, \infty)$ . Definem deci funcția  $g(Y)$  astfel:

$$g(Y) = \begin{cases} 1 & \text{pentru } Y \geq \delta \\ 0 & \text{pentru } Y < \delta \end{cases} \quad (1.134)$$

Fie  $v \geq 0$  parametrul ce urmează a fi optimizat pentru a obține o aproximație cât mai bună. Mărginim superior funcția  $g(Y)$  astfel:

$$g(Y) \leq e^{v(Y-\delta)} \quad (1.135)$$

Graficul lui  $g(Y)$  și exponențiala sunt arătate în figura 1.8.




Fig.1.8. Margine superioară exponențială a lui  $g(Y)$  utilizată pentru a obține probabilitatea cozii (marginea Chernoff).

Valoarea medie (expectația) lui  $g(Y)$  este

$$E[g(Y)] = P(Y \geq \delta) \leq E\left(e^{v(Y-\delta)}\right) \quad (1.136)$$

Această margine este valabilă pentru orice  $v \geq 0$ . Cea mai bună aproximație se obține minimizând  $E\left(e^{v(Y-\delta)}\right)$ . Pentru a avea un minim, o condiție necesară este ca

$$\frac{d}{dv} E\left(e^{v(Y-\delta)}\right) = 0 \quad (1.137)$$

Schimbând ordinea de efectuare a derivării și a integrării, avem succesiv

$$\begin{aligned}\frac{d}{dv}E(e^{v(Y-\delta)}) &= E\left(\frac{d}{dv}e^{v(Y-\delta)}\right) \\ &= E[(Y-\delta)e^{v(Y-\delta)}] = e^{-v\delta} [E(Ye^{vY}) - \delta E(e^{vY})] = 0\end{aligned}$$

Valoarea lui  $v$  care ne dă cea mai bună aproximație este, deci, soluția ecuației

$$E(Ye^{vY}) - \delta E(e^{vY}) = 0 \quad (1.138)$$

Fie  $\hat{v}$  soluția ecuației (1.138). Din (1.136), rezultă că marginea superioară a probabilității uneia dintre cozi este

$$P(Y \geq \delta) \leq e^{-\hat{v}\delta} E(e^{\hat{v}Y}) \quad (1.139)$$

Aceasta este marginea Chernoff pentru probabilitatea cozii din dreapta în cazul unei variabile aleatoare de tip discret sau continuu având medie zero.

Pentru  $v$  real,  $E(e^{vY})$  se numește *funcția generatoare de momente* a lui  $Y$ .

## 1.16. SUME DE VARIABILE ALEATOARE

Fie  $n$  variabile aleatoare distribuite identic și independente statistic  $X_i, i=1, 2, \dots, n$ , fiecare având o medie  $m_x$  finită și o varianță  $\sigma_x^2$  finită. Definim o nouă variabilă aleatoare  $Y$  drept sumă normată, denumită *medie a eșantioanelor*:

$$Y = \frac{1}{n} \sum_{i=1}^n X_i \quad (1.140)$$

Variabila aleatoare  $Y$  definită în (1-140) se întâlnește frecvent la estimarea mediei unei variabile aleatoare  $X$  dintr-un număr de observații  $X_i, i=1, 2, \dots, n$ .

Media lui  $Y$  este

$$E(Y) = m_y = \frac{1}{n} \sum_{i=1}^n E(X_i) = m_x \quad (1.141)$$

Varianța lui  $Y$  este

$$\begin{aligned} \sigma_y^2 &= E(Y^2) - m_y^2 = E(Y^2) - m_x^2 \\ &= \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n E(X_i X_j) - m_x^2 \\ &= \frac{1}{n^2} \sum_{i=1}^n E(X_i^2) + \frac{1}{n^2} \sum_{i=1}^n \sum_{\substack{j=1 \\ i \neq j}}^n E(X_i)E(X_j) - m_x^2 \\ &= \frac{1}{n} (\sigma_x^2 + m_x^2) + \frac{1}{n^2} n(n-1)m_x^2 - m_x^2 = \frac{\sigma_x^2}{n}. \end{aligned} \quad (1.142)$$

Dacă se consideră  $Y$  drept o estimăție pentru media  $m_x$ , observăm că expectația sa este egală cu  $m_x$  iar varianța sa descrește cu numărul de eșantioane  $n$ . Când  $n$  tinde spre infinit, varianța  $\sigma_y^2$  tinde spre zero.

O estimăție a unui parametru (în acest caz media  $m_x$ ) ce satisface condițiile ca expectația sa să convergă spre valoarea adevărată a parametrului iar varianța sa să convergă spre zero când  $n \rightarrow \infty$  se spune că este o *estimăție compatibilă*.

Să aplicăm inegalitatea lui Cebîșev la  $Y$ . Avem

$$\begin{aligned} P(|Y - m_y| \geq \delta) &\leq \frac{\sigma_y^2}{\delta^2} \\ P\left(\left|\frac{1}{n} \sum_{i=1}^n X_i - m_x\right| \geq \delta\right) &\leq \frac{\sigma_x^2}{n\delta^2} \end{aligned} \quad (1.143)$$

La limită când  $n \rightarrow \infty$  (1.143) devine:

$$\lim_{n \rightarrow \infty} P\left(\left|\frac{1}{n} \sum_{i=1}^n X_i - m_x\right| \geq \delta\right) = 0 \quad (1.144)$$

Rezultă că probabilitatea ca estimăția mediei să difere de adevărata medie  $m_x$  cu mai mult decât  $\delta$  ( $\delta > 0$ ) tinde către zero când  $n$  tinde la infinit. Aceasta este o formă a legii numerelor mari. Având în vedere că



marginea superioară converge la zero relativ lent (invers cu  $n$ ), expresia din (1.143) se numește *legea slabă a numerelor mari*.

Vom aplica acum marginea Chernoff care ne oferă o aproximație mai bună a probabilității unei cozi.

$$\begin{aligned} P(Y - m_y \geq \delta) &= P\left(\frac{1}{n} \sum_{i=1}^n X_i - m_x \geq \delta\right) \\ &= P\left(\sum_{i=1}^n X_i \geq n\delta_m\right) \leq E\left\{\exp\left[v\left(\sum_{i=1}^n X_i - n\delta_m\right)\right]\right\} \end{aligned} \quad (1.145)$$

unde  $\delta_m = m_x + \delta$  iar  $\delta > 0$ . Dar variabilele aleatoare  $X_i, i=1, 2, \dots, n$  sunt statistic independente și distribuite identic, așa că

$$\begin{aligned} E\left\{\exp\left[v\left(\sum_{i=1}^n X_i - n\delta_m\right)\right]\right\} &= e^{-vn\delta_m} E\left[\exp\left(v\sum_{i=1}^n X_i\right)\right] \\ &= e^{-vn\delta_m} \prod_{i=1}^n E(e^{vX_i}) = \left[e^{-v\delta_m} E(e^{vX})\right]^n \end{aligned} \quad (1.146)$$

unde  $X$  este oricare din  $X_i$ . Parametrul  $v$  care ne dă marginea superioară cea mai strânsă se obține derivând (1.146) și făcând derivata egală cu zero. Aceasta ne dă ecuația

$$E(Xe^{vX}) - \delta_m E(e^{vX}) = 0 \quad (1.147)$$

Notăm cu  $\hat{v}$  soluția ecuației (1.147). Marginea probabilității cozii din dreapta este atunci

$$P\left(\frac{1}{n} \sum_{i=1}^n X_i \geq \delta_m\right) \leq \left[e^{-\hat{v}\delta_m} E(e^{\hat{v}X})\right]^n, \quad \delta_m > m_x \quad (1.148)$$

**EXEMPLUL 1.4:** Fie  $X_i, i=1, 2, \dots, n$  o mulțime de variabile aleatoare independente statistic definite astfel

$$X_i = \begin{cases} 1 & \text{cu probabilitate } p < \frac{1}{2} \\ -1 & \text{cu probabilitate } 1-p \end{cases}$$

Vrem să determinăm o margine superioară strânsă a probabilității ca suma acestor  $X_i$  să fie mai mare decât zero. Întrucât  $p < \frac{1}{2}$ , observăm că suma va avea o valoare negativă drept medie; de aceea, ne interesează probabilitatea cozii din dreapta. Făcând  $\delta_m = 0$  în (1.148), avem

$$P\left(\sum_{i=1}^n X_i \geq 0\right) \leq [E(e^{\hat{v}X})]^n \quad (1.149)$$

unde  $\hat{v}$  este soluția ecuației

$$E(Xe^{\hat{v}X}) = 0 \quad (1.150)$$

Dar

$$E(Xe^{\hat{v}X}) = -(1-p)e^{-\hat{v}} + \hat{v}e^{\hat{v}} = 0 \quad (1.151)$$

De unde

$$\hat{v} = \ln\left(\sqrt{\frac{1-p}{p}}\right) \quad (1.152)$$

De asemenea,

$$E(e^{\hat{v}X}) = pe^{\hat{v}} + (1-p)e^{-\hat{v}} \quad (1.153)$$

Marginea Chernoff devine

$$\begin{aligned} P\left(\sum_{i=1}^n X_i \geq 0\right) &\leq [pe^{\hat{v}} + (1-p)e^{-\hat{v}}]^n \\ &\leq \left[p\sqrt{\frac{1-p}{p}} + (1-p)\sqrt{\frac{p}{1-p}}\right]^n \leq [4p(1-p)]^{n/2} \end{aligned} \quad (1.154)$$

Se observă că marginea superioară descrește exponențial cu  $n$ , așa cum și era de așteptat.

### 1.17. TEOREMA LIMITĂ CENTRALĂ

Fie  $n$  variabile aleatoare distribuite identic și independente statistic  $X_i$ ,  $i=1, 2, \dots, n$ , fiecare având o medie  $m_x$  finită și o varianță  $\sigma_x^2$  finită. Definim variabilele aleatoare normate:

$$U_i = \frac{X_i - m_x}{\sigma_x}, \quad i=1, 2, \dots, n \quad (1.155)$$

Se vede că  $U_i$  are medie zero și varianță egală cu unu. Fie

$$Y = \frac{1}{\sqrt{n}} \sum_{i=1}^n U_i \quad (1.156)$$

Funcția caracteristică a lui  $Y$  este

$$\begin{aligned} \psi_Y(jv) &= E(e^{jvY}) = E \left[ \exp \left( \frac{jv \sum_{i=1}^n U_i}{\sqrt{n}} \right) \right] \\ &= \prod_{i=1}^n \psi_{U_i} \left( \frac{jv}{\sqrt{n}} \right) = \left[ \psi_U \left( \frac{jv}{\sqrt{n}} \right) \right]^n \end{aligned} \quad (1.157)$$

unde  $U$  este oricare din variabilele aleatoare  $U_i$ , care sunt distribuite identic. Dezvoltăm funcția caracteristică în serie Taylor:

$$\psi_U \left( j \frac{v}{\sqrt{n}} \right) = 1 + j \frac{v}{\sqrt{n}} E(U) - \frac{v^2}{n 2!} E(U^2) + \frac{(jv)^3}{(\sqrt{n})^3 3!} E(U^3) - \dots \quad (1.158)$$

Întrucât  $E(U) = 0$  și  $E(U^2) = 1$ , (1.158) se simplifică devenind

$$\psi_U \left( \frac{jv}{\sqrt{n}} \right) = 1 - \frac{v^2}{2n} + \frac{1}{n} R(v, n) \quad (1.159)$$

unde  $R(v, n)/n$  este restul. Observăm că  $R(v, n)$  tinde la zero când  $n \rightarrow \infty$ . Înlocuind (1.159) în (1.157), obținem funcția caracteristică a lui  $Y$  în forma

$$\psi_Y(jv) = \left[ 1 - \frac{v^2}{2n} + \frac{R(v, n)}{n} \right]^n \quad (1.160)$$

Luând logaritmul natural în (1.160), obținem

$$\ln \psi_Y(jv) = n \ln \left[ 1 - \frac{v^2}{2n} + \frac{R(v, n)}{n} \right] \quad (1.161)$$

Pentru valori mici ale lui  $x$ ,  $\ln(1+x)$  se poate dezvolta în seria de puteri

$$\ln(1+x) = x - \frac{1}{2}x^2 + \frac{1}{3}x^3 - \dots \quad (1.162)$$

Aplicând această dezvoltare ecuației (1-161), avem

$$\ln \psi_Y(jv) = n \left[ -\frac{v^2}{2n} + \frac{R(v, n)}{n} - \frac{1}{2} \left( -\frac{v^2}{2n} + \frac{R(v, n)}{n} \right)^2 + \dots \right] \quad (1.163)$$

Trecem acum la limită când  $n \rightarrow \infty$ .

$$\lim_{n \rightarrow \infty} \ln \psi_Y(jv) = -\frac{1}{2}v^2 \quad (1.164)$$

Aceasta echivalează cu

$$\lim_{n \rightarrow \infty} \psi_Y(jv) = e^{-v^2/2} \quad (1.165)$$

Dar aceasta este chiar funcția caracteristică a unei variabile aleatoare normale (Gaussiene) cu medie zero și varianță egală cu unu (vezi(1.122)). Am obținut astfel un rezultat cunoscut drept *teorema limită centrală*: suma unor variabile aleatoare independente statistic și distribuite identic cu medie finită și varianță finită tinde către o funcție de distribuție cumulativă Gaussiană când  $n \rightarrow \infty$ .

## 1.18. PROCESE STOCHASTICE

Până acum, vorbind despre experimente repetate ca aruncarea zarului sau a monedei de  $n$  ori, nu am luat niciodată factorul timp expres în considerație. În realitate, numeroase fenomene aleatoare, atât naturale cât și artificiale, sunt funcții de timp. În particular, diversele mărimi aleatoare ce intervin în teoria transmisiunii informației sunt funcții de timp.

Stochastic este un adjectiv care își are etimologia într-un verb din greaca veche având sensul de „a ghici, a conjectura” și înseamnă aleator, adică întâmplător. În orice moment de timp dat, un proces stochastic este caracterizat printr-o variabilă aleatoare indexată cu parametrul  $t$ . Vom nota un proces stochastic cu  $X(t)$ . În general, parametrul  $t$  este continuu, dar  $X$  poate fi de tip continuu sau discret, în funcție de caracteristicile sursei care generează procesul stochastic.

Tensiunea de zgomot generată de un singur rezistor sau o singură sursă de informație reprezintă o singură realizare a procesului stochastic. De aceea, se numește o *funcție eșantion* a procesului stochastic. Mulțimea tuturor funcțiilor eșantion posibile, de exemplu mulțimea tuturor formelor de undă ale tensiunii de zgomot generate de rezistoarele dintr-un lot, constituie un *ansamblu* de funcții eșantion sau, echivalent, procesul stochastic  $X(t)$ . Numărul funcțiilor eșantion din ansamblu poate fi foarte mare, chiar și infinit.

Un exemplu de proces stochastic este zgomotul generat de rezistoarele, nominal identice, dintr-un lot de fabricație, ilustrat în figura 1.9.




Fig. 1.9. Proces stochastic reprezentat de tensiunile de zgomot generate de un lot de rezistoare.

### Procese stochastice staționare

Atunci când ne ocupăm cu procese aleatoare întâlnite în realitate, constatăm adeseori că proprietățile statistice ale unui proces sunt independente de momentul în care se începe observarea procesului. Cu alte cuvinte, dacă se împarte un astfel de proces într-un număr de intervale de timp, diversele secțiuni ale procesului prezintă aceleași proprietăți statistice.

## 46 PROBABILITATE, VARIABLE ALEATOARE ȘI PROCESE STOCHASTICE

Un astfel de proces se spune că este *staționar*. În caz contrar, se spune că este *nestaționar*.

Să exprimăm aceasta mai riguros. Variabilele aleatoare  $X_{t_i}$ ,  $i=1, 2, \dots, n$ , obținute de la un proces stochastic  $X(t)$  pentru orice mulțime de momente de timp  $t_1 > t_2 > t_3 > \dots > t_n$ , unde  $n$  este orice număr natural, sunt caracterizate statistic de FDP comună  $p(x_{t_1}, x_{t_2}, \dots, x_{t_n})$ . Să considerăm o altă mulțime de  $n$  variabile aleatoare  $X_{t_i+t} \equiv X(t_i + t)$ ,  $i=1, 2, \dots, n$ , unde  $t$  este o deplasare de timp arbitrară. Aceste variabile aleatoare sunt caracterizate de FDP comună  $p(x_{t_1+t}, x_{t_2+t}, \dots, x_{t_n+t})$ . Dacă

$$p(x_{t_1}, x_{t_2}, \dots, x_{t_n}) = p(x_{t_1+t}, x_{t_2+t}, \dots, x_{t_n+t}) \quad (1.166)$$

pentru orice  $t$  și orice  $n$ , procesul stochastic se spune că este *staționar în sens strict*.

### Media

Prin definiție, *media* procesului  $X(t)$  este expectația variabilei aleatoare obținute observând procesul la un timp  $t$ :

$$\mu_X(t) = E[X(t)] = \int_{-\infty}^{\infty} x p_{X(t)}(x) dx \quad (1.167)$$

unde  $p_{X(t)}(x)$  este funcția densitate de probabilitate de ordinul unu a procesului. Pentru un proces aleator strict staționar,  $p_{X(t)}(x)$  este independentă de timpul  $t$ . Drept urmare, media unui proces strict staționar este o constantă:

$$\mu_X(t) = \mu_X \text{ pentru orice } t \quad (1.168)$$

### Funcția de autocorelație

Funcția de autocorelație a procesului  $X(t)$  este expectația produsului dintre două variabile aleatoare  $X(t_1)$  și  $X(t_2)$  obținute observând procesul  $X(t)$  la timpurile  $t_1$  și  $t_2$ , respectiv:

$$\begin{aligned} R_X(t_1, t_2) &= E[X(t_1)X(t_2)] \\ &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x_1 x_2 p_{X(t_1), X(t_2)}(x_1, x_2) dx_1 dx_2 \end{aligned} \quad (1.169)$$

unde  $p_{X(t_1), X(t_2)}(x_1, x_2)$  este funcția densitate de probabilitate de ordinul doi a procesului. Pentru un proces aleator strict staționar,  $p_{X(t_1), X(t_2)}(x_1, x_2)$  depinde numai de diferența dintre timpii de observație  $t_1$  și  $t_2$ . Aceasta implică faptul că funcția de autocorelație a unui proces strict staționar depinde numai de diferența de timp  $t_2 - t_1$ :

$$R_X(t_1, t_2) = R_X(t_2 - t_1) \text{ pentru orice } t_1 \text{ și } t_2 \quad (1.170)$$

Să redefinim funcția de autocorelație a unui proces staționar  $X(t)$  astfel:

$$R_X(\tau) = E[X(t + \tau)X(t)] \text{ pentru orice } t \quad (1.171)$$

Această funcție de autocorelație are următoarele proprietăți importante:

1. Valoarea medie pătratică a procesului se obține din  $R_X(\tau)$  pentru  $\tau = 0$ :

$$R_X(0) = E[X^2(t)] \quad (1.172)$$

2. Funcția de autocorelație  $R_X(\tau)$  este o funcție pară de  $\tau$ :

$$R_X(\tau) = R_X(-\tau) \quad (1.173)$$

Această proprietate rezultă direct din ecuația de definiție (1.171). Aceasta înseamnă că am fi putut defini  $R_X(\tau)$  și astfel:

$$R_X(\tau) = E[X(t)X(t - \tau)]$$

3. Funcția de autocorelație  $R_X(\tau)$  este maximă pentru  $\tau = 0$ :

$$|R_X(\tau)| \leq R_X(0) \quad (1.174)$$

Pentru a demonstra această proprietate, să considerăm mărimea nenegativă

$$E[(X(t + \tau) \pm X(t))^2] \geq 0$$

Ridicând la pătrat și luând expectațiile termenilor, obținem

$$E[X^2(t + \tau)] \pm 2E[X(t + \tau)X(t)] + E[X^2(t)] \geq 0$$

Având în vedere (1.171) și (1.172), aceasta se reduce la relația

$$2R_X(0) \pm 2R_X(\tau) \geq 0$$

Echivalent, aceasta se poate scrie

$$-R_X(0) \leq R_X(\tau) \leq R_X(0)$$

din care rezultă (1.173).

**Funcția de autocovarianță**

Funcția de autocovarianță a unui proces strict staționar  $X(t)$  se scrie:

$$\begin{aligned} C_X(t_1, t_2) &= E[(X(t_1) - \mu_X)(X(t_2) - \mu_X)] \\ &= R_X(t_2 - t_1) - \mu_X^2 \end{aligned} \quad (1.175)$$

**1.19. PROCESE ERGODICE**

Există două feluri de a efectua medii ale unui proces stochastic  $X(t)$ . Primul este de a considera o „secțiune prin proces“. Spre exemplu, media unui proces stochastic  $X(t)$  la un timp  $t_k$  fixat este expectația variabilei aleatoare  $X(t_k)$  ce descrie *toate valorile posibile* ale funcțiilor eșantion ale procesului observate la timpul  $t = t_k$ . Al doilea este de a defini medii în timp "de-a lungul procesului". Întrucât medierea în timp reprezintă un mijloc practic care ne stă la dispoziție pentru estimarea medierilor pe ansamblu, ne interesează să facem o legătură între medierea pe ansamblu și medierea în timp. Când, însă, avem voie să înlocuim medierea pe ansamblu cu medierea în timp? Pentru a răspunde la această întrebare, să considerăm funcția eșantion  $x(t)$  a unui proces staționar  $X(t)$ . Definim intervalul de observație astfel:  $-T \leq t \leq T$ . Valoarea de curent continuu (c.c.) a lui  $x(t)$  este prin definiție media în timp

$$\mu_x(T) = \frac{1}{2T} \int_{-T}^T x(t) dt \quad (1.176)$$

Media în timp  $\mu_x(T)$  este o variabilă aleatoare, căci valoarea ei depinde de intervalul de observație și de funcția eșantion particulară a procesului stochastic  $X(t)$  ce se utilizează în ecuația (1.176). În ipoteza că procesul  $X(t)$  este staționar, media mediei în timp  $\mu_x(T)$ , după inversarea ordinii de efectuare a operațiilor de expectație și de integrare, este dată de

$$E[\mu_x(T)] = \frac{1}{2T} \int_{-T}^T E[x(t)] dt = \frac{1}{2T} \int_{-T}^T \mu_X dt = \mu_X \quad (1.177)$$



unde  $\mu_X$  este media procesului  $X(t)$ . În mod corespunzător,  $\mu_x(T)$  reprezintă o estimare nedepășită a mediei mediate pe ansamblu  $\mu_X$ . Spunem că procesul  $X(t)$  este *ergodic în medie* dacă sunt satisfăcute două condiții:

1. Media în timp  $\mu_x(T)$  tinde către media pe ansamblu  $\mu_X$  la limită pentru intervalul de observație tinzând la infinit:

$$\lim_{T \rightarrow \infty} \mu_x(T) = \mu_X$$

2. Variația lui  $\mu_x(T)$ , considerată drept variabilă aleatoare, tinde către zero la limită pentru intervalul de observație tinzând la infinit

$$\lim_{T \rightarrow \infty} \text{var}[\mu_x(T)] = 0$$

Definim funcția de *autocorelație mediată în timp* a unei funcții eșantion  $x(t)$  astfel:

$$R_x(\tau, T) = \frac{1}{2T} \int_{-T}^T x(t + \tau)x(t)dt \quad (1./178)$$

Considerăm  $R_x(\tau, T)$  drept o variabilă aleatoare, având medie și varianță. Spunem că procesul  $X(t)$  este ergodic în funcția de autocorelație dacă sunt îndeplinite următoarele două condiții:

$$\lim_{T \rightarrow \infty} R_x(\tau, T) = R_X(\tau)$$

$$\lim_{T \rightarrow \infty} \text{var}[R_x(\tau, T)] = 0$$

Cu aceste cunoștințe minime de teoria probabilității, vom aborda în capitolul următor obiectul nostru de studiu propriu-zis, care este teoria matematică a informației.