

Ariadna Lucia Pletea

Liliana Popa

# TEORIA PROBABILITĂȚILOR

UNIVERSITATEA TEHNICĂ ” GH. ASACHI”,

IAȘI 1999



# Cuprins

<b>Introducere</b>	<b>5</b>
<b>1 Câmp de probabilitate</b>	<b>7</b>
1.1 Câmp finit de evenimente . . . . .	7
1.2 Câmp finit de probabilitate . . . . .	11
1.3 Metode de numărare . . . . .	16
1.4 Moduri de selectare a elementelor . . . . .	17
1.5 Definiția axiomatică a probabilității . . . . .	18
1.6 Formule probabilistice . . . . .	20
1.7 Scheme clasice de probabilitate . . . . .	26
1.8 Câmp infinit de probabilitate . . . . .	29
1.9 Probleme propuse . . . . .	36
<b>2 Variabile aleatoare discrete</b>	<b>43</b>
2.1 Definiția și clasificarea variabilelor aleatoare . . . . .	43
2.2 Variabile aleatoare discrete simple . . . . .	44
2.3 Exemple de variabile aleatoare discrete simple . . . . .	61
2.4 Variabile aleatoare discrete simple bidimensionale . . . . .	65
2.5 Variabile aleatoare cu un număr infinit numărabil de valori . . . . .	68
2.6 Funcția generatoare . . . . .	74
2.7 Probleme propuse . . . . .	75
<b>3 Variabile aleatoare continue</b>	<b>81</b>
3.1 Funcția de repartiție a unei variabile aleatoare unidimensionale . . . . .	81
3.2 Densitatea de probabilitate. Repartiția normală . . . . .	88
3.3 Funcția de repartiție multidimensională. Transformări . . . . .	95
3.4 Valori caracteristice ale unei variabile aleatoare . . . . .	108
3.5 Funcția caracteristică a unei variabile aleatoare . . . . .	117
3.6 Variabile aleatoare continue clasice și legăturile dintre ele . . . . .	126
3.7 Fiabilitate . . . . .	143
<b>4 Probleme la limită în teoria probabilităților</b>	<b>155</b>
4.1 Convergența în probabilitate . . . . .	155
4.2 Legea numerelor mari (forma slabă) . . . . .	156
4.3 Aproximări pentru repartiții discrete . . . . .	161

4.4	Convergența în repartiție. Teorema limită centrală . . . . .	164
4.5	Legătura dintre convergența șirurilor funcțiilor de repartiție și convergența șirurilor funcțiilor caracteristice . . . . .	177
4.6	Convergența aproape sigură . . . . .	181
4.7	Convergența în medie . . . . .	182
4.8	Probleme propuse . . . . .	184
<b>5</b>	<b>Procese stochastice</b>	<b>187</b>
5.1	Lanțuri Markov . . . . .	187
5.2	Procese Markov continue. Procese Poisson . . . . .	200
5.3	Procese stochastice staționare . . . . .	206

# Introducere

Numeroase probleme practice din variate domenii de activitate, ca: ingineria electrică, radio, transmisia de date, calculatoare, teoria informației, fiabilitatea sistemelor și altele, conduc la studiul unor fenomene și procese aleatoare. Evaluarea șanselor lor de producere constituie obiectul disciplinei teoria probabilităților.

Cursul de Teoria probabilităților are atât un caracter informativ, furnizând studenților noțiuni și rezultate fundamentale cu care vor opera în cadrul specialităților lor, cât și formativ, acomodându-i cu raționamente matematice, dintre care unele vor fi necesare prelucrării pe calculator a datelor.

Cursul este alcătuit din cinci capitole.

*Capitolul I*, intitulat ”*Câmp de probabilitate*” introduce noțiunea de câmp de probabilitate, cadru în care se definește axiomatic noțiunea de probabilitate. Sunt trecute în revistă formule și scheme clasice de probabilitate. Elementele de teorie sunt însoțite de exemple, dintre care unele cu referire la situații tehnice privind controlul de calitate, transmiterea informației etc.

Cuprinde paragrafele: 1.Câmp finit de evenimente; 2.Câmp finit de probabilitate; 3. Metode de numărare; 4.Moduri de selectare a elementelor; 5.Definiția axiomatică a probabilității; 6.Formule probabilistice; 7.Scheme clasice de probabilitate; 8.Câmp infinit de probabilitate.

*Capitolul II*, intitulat ”*Variabile aleatoare discrete*” cuprinde paragrafele 1.Definiția și clasificarea variabilelor aleatoare; 2.Variabile aleatoare discrete simple; 3.Exemple de variabile aleatoare discrete simple; 4.Variabile aleatoare discrete simple bidimensionale; 5.Variabile aleatoare cu un număr infinit numărabil de valori.

Este scos în evidență rolul distribuției Poisson, a evenimentelor rare în numeroase aplicații tehnice.

*Capitolul III*, intitulat ”*Variabile aleatoare continue*”, cuprinde paragrafele: 1.Funcția de repartiție a unei variabile aleatoare unidimensionale; 2.Densitatea de probabilitate.Repartiția normală;3.Funcția de repartiție multidimensională.Transformări; 4.Valori caracteristice ale unei variabile aleatoare. 5.Funcția caracteristică a unei variabile aleatoare; 6.Variabile aleatoare continue clasice și legăturile dintre ele; 7.Fiabilitate.

Este scos în evidență rolul legii lui Gauss în studiul erorilor accidentale de măsurare.

*Capitolul IV*, intitulat ”*Probleme la limită în teoria probabilităților*”, cuprinde paragrafele: 1.Convergența în probabilitate a șirurilor de variabile aleatoare; 2.Legea numerelor mari (forma slabă); 3.Aproximări pentru distribuții discrete; 4.Convergența în repartiție. Teorema limită centrală; 5.Legătura dintre convergența funcțiilor de repartiție

și convergența funcțiilor caracteristice; 6. Convergența aproape sigură; 7. Convergența în medie.

Scopul acestui capitol este de a pune în evidență justificări teoretice ale apropierii dintre anumite concepte din teoria probabilităților și din statistica matematică și de asemenea, legăturile dintre diferitele tipuri de convergență în teoria probabilităților.

*Capitolul V*, intitulat "*Procese stochastice*", cuprinde paragrafele: 1. Lanțuri Markov; 2. Procese Markov continue. Procese Poisson; 3. Procese stochastice staționare.

Pentru înțelegerea materialului din acest capitol, s-au dat numeroase exemple de importanță practică din teoria așteptării, teoria stocurilor și altele.

Capitolele I, II, IV au fost redactate de lector dr. Pletea Ariadna, iar Capitolele III și V de lector dr. Popa Liliana, care au colaborat pentru a obține o formă cât mai unitară și modernă a cursului.

Adresăm pe această cale vii mulțumiri comisiei de analiză a cursului, formată din prof. dr. Pavel Talpalaru, prof. dr. Stan Chiriță și lector Gheorghe Florea pentru observațiile constructive făcute, cât și, anticipat, tuturor cititorilor, care vor contribui prin sugestii la îmbunătățirea prezentului material.

Autoarele

# Capitolul 1

## Câmp de probabilitate

### 1.1 Câmp finit de evenimente

În teoria probabilităților noțiunile primare sunt: evenimentul și probabilitatea.

Teoria probabilităților studiază experiențele aleatoare, acele experiențe care reproduse de mai multe ori se desfășoară de fiecare dată în mod diferit, rezultatul neputând fi anticipat. Exemple de experiențe aleatoare: aruncarea unui zar, tragerile la țintă, durata de funcționare a unei mașini etc.

Rezultatele posibile ale unei experiențe aleatoare se numesc *probe* sau *cazuri posibile ale experienței*.

Experiențele se pot realiza printr-un număr finit sau un număr infinit de probe.

Mulțimea rezultatelor (cazurilor) posibile ale unei experiențe aleatoare formează *spațiul de selecție*.

Notăm simbolic spațiul de selecție cu  $E$ .

**Definiția 1.1.1** *Se numește eveniment o submulțime a spațiului de selecție.*

Orice element al lui  $E$ , notat  $e$ , este un punct de selecție sau un rezultat posibil al experienței.

În cele ce urmează vom presupune  $E$  finit.

**Exemplul 1.1.1** Considerăm experiența care constă în aruncarea unui zar. Aceasta este o experiență aleatoare. Mulțimea rezultatelor posibile ale experienței sunt 1, 2, 3, 4, 5, 6. Deci spațiul de selecție este  $E = \{1, 2, 3, 4, 5, 6\}$ . Presupunem că ne interesează evenimentul ca la o aruncare a zarului să obținem o față cu un număr par de puncte. Dacă aruncând zarul am obținut fața cu cinci puncte, aceasta este o probă a experienței noastre, dar evenimentul care ne interesa (o față cu un număr par de puncte) nu s-a realizat. Dacă proba experienței ar fi fața cu șase puncte, atunci evenimentul nostru s-a realizat.

Exemplul dat este al unei experiențe cu un număr finit de probe. Se pot da exemple și de experiențe cu o infinitate de probe. Astfel, experiența tragerii la țintă. Există o infinitate de probe care realizează evenimentul atingerii țintei.

Noțiunile de spațiu de selecție și de eveniment astfel introduse ne permit ca teoria mulțimilor să poată fi folosită în studiul evenimentelor aleatoare. Traducem în limbaj de evenimente noțiuni și simboluri caracteristice teoriei mulțimilor.

1. Drept submulțime a lui  $E$  se poate considera  $E$ . Cum indiferent de rezultatul  $e$  al experienței,  $e \in E$ , rezultă că odată cu  $e$  se realizează  $E$ . Evenimentul  $E$  se numește *eveniment cert* (sau *eveniment sigur*).

De exemplu, la aruncarea zarului apariția unei fețe cu un număr de puncte mai mic sau egal cu 6 este evenimentul sigur. Apariția unei fețe cu un număr mai mic sau egal cu 4 de puncte este un eveniment nesigur, dar posibil.

2. Drept submulțime a lui  $E$  putem considera mulțimea vidă  $\emptyset$  care nu se realizează la nici o efectuare a experienței, motiv pentru care se numește *eveniment imposibil*.
3. Fie evenimentul  $A$ , submulțime a lui  $E$ . Evenimentul complementar lui  $A$  în raport cu  $E$ , notat  $\bar{A}$ , se numește *eveniment contrar* evenimentului  $A$ . Acesta se realizează dacă și numai dacă nu se realizează evenimentul  $A$ .

În exemplul 1.1.1 evenimentul contrar evenimentului apariției unui număr par de puncte este evenimentul care constă în apariția unui număr impar de puncte. Astfel,  $A = \{2, 4, 6\}$  și  $\bar{A} = \{1, 3, 5\}$ .

4. Fie evenimentele  $A, B \subset E$ . Evenimentul  $A$  implică evenimentul  $B$  (scris  $A \subset B$ ) dacă  $B$  se realizează prin toate probele lui  $A$  (și prin alte probe), adică dacă  $(e \in A) \Rightarrow (e \in B)$ .
5. Fie  $A, B \subset E$  două evenimente. Evenimentul  $A \cup B$  este evenimentul a cărui realizare are loc dacă se realizează sau  $A$  sau  $B$ .
6. Fie  $A, B \subset E$ . Prin evenimentul  $A \cap B$  înțelegem evenimentul care se realizează dacă se realizează atât  $A$  cât și  $B$ .
7. Fie  $A, B \subset E$ . Prin  $A \setminus B$  înțelegem evenimentul care se realizează prin probe ale lui  $A$  și  $\bar{B}$ .

**Definiția 1.1.2** Fie  $A \subset E, A \neq \emptyset$ . Evenimentul  $A$  se numește eveniment elementar dacă este implicat numai de el însuși și de evenimentul imposibil. Celelalte evenimente se numesc evenimente compuse.

**Definiția 1.1.3** Fie  $A, B \subset E$ . Evenimentele  $A, B$  se numesc compatibile dacă se pot realiza simultan, adică există probe care realizează atât pe  $A$  cât și pe  $B$  ( $A \cap B \neq \emptyset$ ). În caz contrar evenimentele se numesc incompatibile ( $A \cap B = \emptyset$ ).

**Observația 1.1.1** Operațiile de reuniune și intersecție se extind pentru un număr finit de evenimente. Fie  $A_1, A_2, \dots, A_n \subset E$ . Avem

$$(\dots((A_1 \cup A_2) \cup A_3) \cup \dots \cup A_n) = \bigcup_{i=1}^n A_i,$$



adică evenimentul care se realizează dacă cel puțin un eveniment  $A_i$  se realizează și

$$(\dots((A_1 \cap A_2) \cap A_3) \cap \dots \cap A_n) = \bigcap_{i=1}^n A_i$$

este evenimentul care se realizează dacă toate evenimentele  $A_i, i = \overline{1, n}$  se realizează.

Menționăm câteva din proprietățile operațiilor introduse:

1. Dacă  $A \subset B$  atunci  $A \cup B = B$  și  $A \cap B = A$ .

2. Oricare ar fi evenimentul  $A$  au loc relațiile

$$A \cup A = A, A \cup \emptyset = A, A \cup E = E, E \cup \emptyset = E,$$

$$A \cap A = A, A \cap \emptyset = \emptyset, A \cap E = A, E \cap \emptyset = \emptyset.$$

3. Dacă  $A \subset C, B \subset C, A, B, C \subset E$  atunci  $A \cup B \subset C$  și  $A \cap B \subset C$ .

4. Dacă  $A, B, C \subset E$  atunci

$$A \cup B = B \cup A, A \cup (B \cup C) = (A \cup B) \cup C, A \cap (B \cup C) = (A \cap B) \cup (A \cap C),$$

$$A \cap B = B \cap A, A \cap (B \cap C) = (A \cap B) \cap C, A \cup (B \cap C) = (A \cup B) \cap (A \cup C).$$

Construcția sistematică a unui câmp finit de evenimente se poate face plecând de la două axiome, numite axiomele câmpului finit de evenimente.

Notăm cu  $\mathcal{P}(E)$  mulțimea părților lui  $E$ .

**Definiția 1.1.4** Perechea  $\{ E, K \}$ ,  $K \neq \emptyset$ ,  $K \subset \mathcal{P}(E)$ , se numește câmp finit de evenimente dacă:

$$a) \forall A \in K \Rightarrow \bar{A} \in K;$$

$$b) \forall A, B \in K \Rightarrow A \cup B \in K.$$

Consecințe ale definiției:

$$1. E \in K \text{ deoarece } (\forall A \in K \Rightarrow \bar{A} \in K) \Rightarrow (A \cup \bar{A} \in K) \Rightarrow (E \in K).$$

$$2. \emptyset \in K \text{ deoarece } (E \in K \Rightarrow \bar{E} \in K) \Rightarrow (\emptyset = \bar{E} \in K).$$

$$3. \text{ Dacă } A, B \in K \Rightarrow A \setminus B \in K \text{ deoarece } A \setminus B = A \cap \bar{B} = \overline{\bar{A} \cup B} \in K.$$

4. Următoarele proprietăți sunt echivalente:

$$(\forall A, B \in K \Rightarrow A \cup B \in K) \text{ și } (\forall A, B \in K \Rightarrow A \cap B \in K),$$

$$\text{deoarece } A \cap B = \overline{\bar{A} \cup \bar{B}}.$$

5. Din Definiția 1.1.4 rezultă, folosind metoda inducției matematice, că

$$\forall n \geq 2, A_j \in K, 1 \leq j \leq n \Rightarrow \bigcup_{j=1}^n A_j \in K.$$

6. Din Consecința 4 rezultă:

$$\forall n \geq 2, A_j \in K, 1 \leq j \leq n \Rightarrow \bigcap_{j=1}^n A_j \in K.$$

Într-un câmp finit de evenimente au loc următoarele proprietăți:

P1. Două evenimente elementare distincte sunt incompatibile.

Fie  $A_1$  și  $A_2$  două evenimente elementare. Să presupunem că  $A_1 \cap A_2 \neq \emptyset$ , adică  $A_1 \cap A_2 = B \neq \emptyset$ . Deci  $B \subset A_1, B \neq \emptyset$  și cum  $A_1$  și  $A_2$  sunt distincte,  $B \neq A_1$ , deci  $A_1$  nu este eveniment elementar, ceea ce este fals.

P2. Într-un câmp finit de evenimente există evenimente elementare.

Fie  $A_1$  un eveniment. Dacă  $A_1$  este elementar, afirmația este demonstrată. Dacă  $A_1$  este eveniment compus există  $A_2 \neq \emptyset, A_2 \neq A_1$  astfel încât  $A_2 \subset A_1$ . Dacă  $A_2$  este eveniment elementar, afirmația este demonstrată. Dacă  $A_2$  este eveniment compus se continuă raționamentul anterior. Câmpul fiind finit, rezultă că există un eveniment elementar  $A_n \neq \emptyset$  astfel încât

$$A_n \subset A_{n-1} \subset \dots \subset A_1.$$

P3. Fie  $\{ E, K \}$  un câmp finit de evenimente. Orice eveniment al acestui câmp se poate scrie ca reuniune finită de evenimente elementare.

Fie  $B$  un eveniment compus (dacă  $B$  este un eveniment elementar atunci afirmația este demonstrată). Există, conform proprietății P2, un eveniment elementar  $A_1 \in K$  și un eveniment  $B_1 \in K$  astfel încât  $B = A_1 \cup B_1, B_1 = B \setminus A_1$  cu  $A_1 \cap B_1 = \emptyset$ . Dacă  $B_1$  este eveniment elementar, afirmația este demonstrată. Dacă  $B_1$  nu este eveniment elementar, există evenimentul elementar  $A_2$  și un eveniment  $B_2 \in K$  astfel încât  $B_1 = A_2 \cup B_2$  și deci  $B = A_1 \cup A_2 \cup B_2$  și raționamentul se continuă. Deci

$$B = A_1 \cup A_2 \cup \dots \cup A_k,$$

unde  $A_i, i = \overline{1, k}$  sunt evenimente elementare.

P4. Reuniunea tuturor evenimentelor elementare ale lui  $K$  este  $E$ .

Într-adevăr, fie

$$E = A_1 \cup A_2 \cup \dots \cup A_s.$$

Presupunem că în câmpul finit de evenimente mai există un eveniment elementar  $A_n \neq A_j, j = \overline{1, s}$ . Atunci

$$A_n \cap E = A_n = A_n \cap (A_1 \cup \dots \cup A_s) = (A_n \cap A_1) \cup \dots \cup (A_n \cap A_s) = \emptyset$$

conform P1.

Nu de puține ori de un real folos ne va fi descompunerea unui eveniment într-o reuniune de evenimente incompatibile două câte două.

**Definiția 1.1.5** Fie  $\{ E, K \}$  un câmp finit de evenimente și  $A_1, A_2, \dots, A_n \in K$ . Spunem că familia de evenimente  $A_1, A_2, \dots, A_n$  formează un sistem complet de evenimente dacă:

- a)  $\forall A_i \neq \emptyset, i = \overline{1, n}$ ;
- b)  $A_i \cap A_j = \emptyset, \forall i \neq j, i, j = \overline{1, n}$ ;
- c)  $\bigcup_{i=1}^n A_i = E$ .

**Observația 1.1.2** Mulțimea tuturor evenimentelor elementare atașate unei experiențe formează un sistem complet de evenimente.

**Exemplul 1.1.2** Să se verifice care din următoarele submulțimi ale lui  $\mathcal{P}(E)$  ( $\mathcal{P}(E)$  mulțimea părților lui  $E$ ) sunt câmpuri finite de evenimente și, în caz afirmativ, să se precizeze evenimentele elementare:

1. Dacă  $E = \{1, 2, 3\}$  și  $K = \{\emptyset, \{1\}, \{2, 3\}, \{1, 2, 3\}\}$ , atunci  $\{ E, K \}$  este câmp finit de evenimente deoarece satisface cele două axiome ale Definiției 1.1.4. Evenimentele elementare sunt  $\{1\}$  și  $\{2, 3\}$ . Observăm că evenimentele elementare nu sunt submulțimi ale lui  $E$  formate dintr-un singur element nu este corectă. În exemplul prezentat un eveniment elementar este format dintr-un singur element, iar celălalt eveniment este format din două elemente.
2. Dacă  $E = \{1, 2, 3\}$  și  $K = \{\emptyset, \{1\}, \{2\}, \{3\}, \{1, 2\}, \{1, 3\}, \{2, 3\}, \{1, 2, 3\}\} = \mathcal{P}(E)$  atunci  $\{ E, K \}$  este un câmp finit de evenimente. Evenimentele elementare sunt  $\{1\}, \{2\}, \{3\}$ .
3. Dacă  $E = \{1, 2, 3\}$  și  $K = \{\{1\}, \{2\}, \{1, 3\}, \{1, 2, 3\}\}$  nu este un câmp finit de evenimente deoarece, de exemplu  $\{2\} = \{1, 3\} \notin K$  sau  $\{1\} \cup \{2\} = \{1, 2\} \notin K$ .

## 1.2 Câmp finit de probabilitate

Fie o experiență și un eveniment  $A$  legat de aceasta. Repetăm experiența de  $n$  ori în condiții identice. Notăm cu  $m$  numărul de realizări ale evenimentului  $A$ . Rezultă că  $n - m$  reprezintă numărul de nerealizări ale lui  $A$ .

**Definiția 1.2.1** Numărul

$$f_n = \frac{m}{n}$$

se numește frecvența relativă a evenimentului  $A$ .

**Observația 1.2.1** Frecvența relativă variază de la o experiență la alta, având un caracter experimental. Deoarece  $0 \leq m \leq n$  rezultă  $0 \leq f_n \leq 1, n \in \mathbb{N}$ .

**Observația 1.2.2** Frecvența relativă  $f_n$  depinde de  $n$ , numărul de repetări ale experimentului. Multe experiențe prezintă o stabilitate a frecvențelor relative în sensul că pe măsură ce numărul  $n$  ia valori mari, frecvența relativă oscilează în jurul unei anumite valori și se apropie din ce în ce mai mult de această valoare. Valoarea poate fi adesea intuită.

De exemplu, dacă într-o urnă sunt trei bile negre și una albă, la un număr mare de extracții ale unei bile din urnă, cu repunerea bilei extrase înapoi, șansele de extragere ale unei bile negre sunt de trei ori mai mari decât cele ale unei bile albe și deci, pentru valori mari ale lui  $n$ , în cazul celor două evenimente frecvențele relative se vor stabiliza în jurul valorilor  $3/4$  și respectiv  $1/4$ . Această stabilitate a frecvențelor relative, verificată prin observații și confirmată în practică, este una din legile cele mai importante ale experiențelor aleatoare. Legea a fost formulată pentru prima dată de Bernoulli în teorema care îi poartă numele și este forma slabă a legii numerelor mari (Capitolul 4, Teorema 4.2.2).

Definirea probabilității peste un câmp finit de evenimente se poate face în mod clasic și axiomatic.

Definiția clasică a probabilității se poate folosi în cazul în care experiența aleatoare are un număr finit de cazuri posibile și toate egal probabile, adică la un număr mare de efectuări ale experienței, fiecare caz are aceeași șansă de a se realiza.

Considerăm, de exemplu, experiența care constă în aruncarea unui zar pe o suprafață netedă. Dacă zarul este perfect cubic și omogen, atunci fiecare din fețe are aceeași șansă de a apare, frecvențele relative ale fiecăreia dintre ele variază în jurul lui  $1/6$ . În cazul în care zarul nu ar fi omogen, atunci una sau mai multe fețe ar fi favorizate.

**Definiția 1.2.2** *Fie o experiență și evenimentele legate de aceasta astfel încât toate evenimentele să fie egal posibile. Fie evenimentul  $A$  legat de această experiență. Numim probabilitatea evenimentului  $A$  numărul*

$$P(A) = \frac{m}{n}$$

*dat de raportul dintre numărul  $m$  al cazurilor favorabile realizării evenimentului  $A$  și numărul  $n$  al cazurilor egal posibile.*

Menționăm că orice probă care conduce la realizarea unui eveniment  $A$  reprezintă "un caz favorabil evenimentului  $A$ ".

**Observația 1.2.3** Definiția clasică a probabilității, formulată pentru prima dată de Laplace, este nesatisfăcătoare din punct de vedere logic deoarece reduce definiția probabilității la problema cazurilor egal posibile care nu a putut fi definită din punct de vedere matematic, ci numai ilustrată.

În cazul zarului neomogen, definiția clasică a probabilității nu poate fi aplicată. Riguros vorbind, zarul neomogen și nesimetric este singurul caz real deoarece construirea unui zar perfect este imposibilă.

Un alt inconvenient al definiției apare în cazul în care numărul cazurilor posibile este infinit deoarece în această situație probabilitatea, calculată după definiția clasică, este foarte mică sau egală cu zero.

În sfârșit, definiția clasică a probabilității nu poate fi admisă deoarece nu poate fi aplicată în studiul fenomenelor sociale, neputându-se determina numărul cazurilor posibile.

**Observația 1.2.4** Legătura existentă între frecvența relativă unui eveniment și probabilitatea sa este profundă. De fapt atunci când calculăm probabilitatea unui eveniment ne bazăm pe frecvențele relative.

**Exemplul 1.2.1** Se aruncă un zar de două ori. Mulțimea rezultatelor posibile ale experienței care constă în perechile de numere ce apar pe zar în cele două aruncări este  $E = \{11, 12, \dots, 16, 21, 22, \dots, 26, 31, \dots, 66\}$ ,  $|E| = 6^2 = 36$ , unde  $|E|$  notează numărul de elemente ale mulțimii  $E$ . Toate rezultatele posibile sunt echiprobabile, deci probabilitatea unui eveniment  $A$ ,  $P(A)$ , este egală cu numărul elementelor din mulțimea  $A$  împărțit la numărul elementelor din  $E$ . Presupunem că vom păstra fața zarului ce conține un punct albă, iar celelalte fețe le vom colora în negru. Notăm cu  $AN$  evenimentul ca la prima aruncare a zarului să obținem fața albă, iar la cea de-a doua aruncare o față neagră a zarului. Avem  $AN = \{12, 13, 14, 15, 16\}$ . Rezultă

$$P(AN) = \frac{5}{36}.$$

Analog, făcând notațiile în același fel, avem:

$$P(AA) = \frac{1}{36}, P(NA) = \frac{5}{36}, P(NN) = \frac{25}{36}.$$

Presupunem că au fost șterse numerele de pe fețele zarului și au rămas culorile. Mulțimea rezultatelor posibile, în acest caz, este  $E = \{AA, AN, NA, NN\}$  cu probabilitățile corespunzătoare. Observăm că în acest ultim caz, evenimentele  $AA, AN, NA, NN$  sunt elementare și formează un sistem complet de evenimente.

#### Proprietăți ale probabilității:

- P1.  $\forall A \in K : 0 \leq P(A) \leq 1$ ;
- P2.  $P(E) = 1$ ;
- P3.  $P(\emptyset) = 0$ ;
- P4.  $\forall A, B \in K, A \cap B = \emptyset : P(A \cup B) = P(A) + P(B)$ ;
- P5.  $\forall A, B \in K, B \subset A : P(A \setminus B) = P(A) - P(B)$ ;
- P6.  $\forall A \in K : P(A) + P(\bar{A}) = 1$ ;
- P7.  $\forall A, B \in K, B \subset A : P(B) \leq P(A)$ .

Primele trei proprietăți sunt evidente.

Demonstrăm proprietatea P4. Dacă din cele  $n$  cazuri posibile,  $m$  sunt favorabile lui  $A$  și  $p$  favorabile lui  $B$ , atunci

$$P(A) = \frac{m}{n}, \quad P(B) = \frac{p}{n}.$$

Dacă  $A \cap B = \emptyset$ , atunci numărul cazurilor favorabile lui  $A \cup B$  este  $m + p$ , deci rezultă proprietatea P4.

Această proprietate poate fi extinsă în sensul că dacă  $A_1, A_2, \dots, A_n \in K$ , evenimente incompatibile două câte două, adică  $A_i \cap A_j = \emptyset, \forall i \neq j$ , atunci

$$P\left(\bigcup_{i=1}^n A_i\right) = \sum_{i=1}^n P(A_i).$$

Demonstrația rezultă utilizând metoda inducției matematice.

Demonstrăm proprietatea P5. Scriem  $A = (A \setminus B) \cup B$  și atunci  $(A \setminus B) \cap B = \emptyset$ , deci, conform proprietății P4,

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

Mai general, avem:

$$\forall A, B \in K : P(A \setminus B) = P(A) - P(A \cap B). \quad (1.1)$$

Într-adevăr, scriem  $A = (A \setminus B) \cup (A \cap B)$ . Deoarece  $(A \setminus B) \cap (A \cap B) = \emptyset$  avem, conform proprietății P4,  $P(A) = P(A \setminus B) + P(A \cap B)$ . Rezultă formula (1.1).

Proprietatea P6 se obține din P4 punând  $B = \bar{A}$ , folosind P2.

Pentru a demonstra proprietatea P7 folosim P5. Dacă  $B \subset A$  atunci  $P(A \setminus B) = P(A) - P(B) \geq 0$  și deoarece, conform P1,  $P(A \setminus B) \geq 0$  rezultă proprietatea dorită.

**Definiția 1.2.3** *Un sistem finit de evenimente  $\{ E, K \}$  asociat unei experiențe aleatoare cu un număr finit de cazuri egal posibil împreună cu probabilitățile acestor evenimente formează un câmp finit de probabilitate notat  $\{ E, K, P \}$ .*

Odată introdusă noțiunea de probabilitate, putem defini două noțiuni importante în teoria probabilităților și anume noțiunea de probabilitate condiționată și de independență în probabilitate a evenimentelor.

Uneori trebuie să calculăm probabilitatea unui eveniment  $A$  legat de un eveniment  $B$ , în ipoteza că evenimentul  $B$  s-a realizat. Pentru aceasta restrângem mulțimea evenimentelor care realizează evenimentul  $A$  la cele care realizează și evenimentul  $B$ , deci restrângem  $E$  la  $B$ . Pentru ca această restricție să aibă sens este necesar ca evenimentul  $B$  să fie de probabilitate nenulă.

Fie  $\{ E, K, P \}$  un câmp finit de probabilitate și  $A, B \in K, P(B) \neq 0$ .

**Definiția 1.2.4** *Numim probabilitatea evenimentului  $A$  condiționată de evenimentul  $B$  (notat  $P_B(A)$  sau  $P(A|B)$ ) probabilitatea de realizare a evenimentului  $A$  în ipoteza că evenimentul  $B$  s-a realizat, probabilitate definită prin*

$$P(A|B) = \frac{P(A \cap B)}{P(B)}. \quad (1.2)$$

**Observația 1.2.5** Fie  $m$  numărul cazurilor favorabile lui  $B$ ,  $p$  numărul cazurilor favorabile lui  $A$  și  $q$  favorabile lui  $A \cap B$ . Din cele  $m$  cazuri favorabile lui  $B$ ,  $q$  sunt favorabile

și lui  $A$  sau, ceea ce este același lucru, din cele  $p$  cazuri favorabile lui  $A$ ,  $q$  sunt favorabile și lui  $B$ . Avem

$$P(B) = \frac{m}{n}, \quad P(A) = \frac{p}{n}, \quad P(A \cap B) = \frac{q}{n}.$$

În ipoteza că  $B$  s-a realizat, rămân  $m$  cazuri posibile, din care  $q$  favorabile lui  $A$ . Deci

$$P(A|B) = \frac{q}{m} = \frac{\frac{q}{n}}{\frac{m}{n}} = \frac{P(A \cap B)}{P(B)}.$$

Aceasta ar putea constitui o "justificare" a relației (1.2).

**Observația 1.2.6** Dacă presupunem că  $P(A) \neq 0$ , atunci

$$P(B|A) = \frac{P(A \cap B)}{P(A)}. \quad (1.3)$$

**Observația 1.2.7** Din relațiile (1.2) și (1.3) reținem

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

și

$$P(A \cap B) = P(A)P(B|A).$$

Fie  $\{E, K, P\}$  un câmp finit de probabilitate și  $A, B \in K$ .

**Definiția 1.2.5** *Evenimentele  $A$  și  $B$  sunt independente (în probabilitate) dacă probabilitatea ca unul să se realizeze nu depinde de faptul că celălalt s-a realizat sau nu, altfel spus*

$$P(A \cap B) = P(A)P(B). \quad (1.4)$$

**Teorema 1.2.1** *Evenimentele  $A$  și  $B$  cu  $P(A)P(B) \neq 0$  sunt independente dacă și numai dacă are loc una din relațiile:*

a)  $P(B|A) = P(B);$

b)  $P(A|B) = P(A);$

c)  $P(B|\bar{A}) = P(B);$

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

**Demonstrație.** Arătăm că cele patru relații sunt echivalente cu relația (1.4) din definiție. În acest fel se justifică și sensul Definiției 1.2.5. Presupunem că are loc a). Atunci, deoarece

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

rezultă  $P(A \cap B) = P(A)P(B)$ , adică (1.4).

Reciproc, dacă  $P(A \cap B) = P(A)P(B)$  și deoarece

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

rezultă a). Cum relația (1.4) este simetrică în  $A$  și  $B$ , rezultă că (1.4) este echivalentă cu b).

Demonstrăm că

$$P(\bar{A} \cap B) = P(\bar{A})P(B) \quad (1.5)$$

este echivalentă cu (1.4). Într-adevăr, dacă  $P(\bar{A} \cap B) = P(\bar{A})P(B)$  atunci deoarece  $\bar{A} \cap B = B \setminus A$  avem  $P(B \setminus A) = P(\bar{A})P(B)$  sau

$$P(B) - P(A \cap B) = (1 - P(A))P(B)$$

echivalent cu

$$P(B) - P(A \cap B) = P(B) - P(A)P(B),$$

deci (1.4). Invers, presupunem (1.4) și luăm în locul lui  $A$  pe  $\bar{A}$ . Vom avea  $P(\bar{A} \cap B) = P(\bar{A})P(B)$ , adică (1.5). Deci c) este echivalent cu (1.5) care este echivalent cu (1.4), rezultă că c) este echivalent cu (1.4). Echivalența lui d) cu (1.4) rezultă în mod analog. ■

**Definiția 1.2.6** *Date evenimentele  $A_1, A_2, \dots, A_n$ , vom spune că sunt independente dacă probabilitatea oricărei intersecții finite de evenimente este egală cu produsul probabilităților evenimentelor intersectate, adică dacă*

$$P(A_{i_1} \cap A_{i_2} \cap \dots \cap A_{i_k}) = P(A_{i_1})P(A_{i_2}) \dots P(A_{i_k})$$

oricare ar fi  $1 \leq i_1 \leq i_2 \leq \dots \leq i_k \leq n$ .

**Observația 1.2.8** Din definiție rezultă că dacă trei evenimente sunt independente două câte două nu rezultă că sunt independente în totalitatea lor. Exemplul lui S.N.Bernstein ne va ilustra acest lucru. Considerăm un tetraedru omogen cu fețele colorate astfel: una în alb, una în negru, una în roșu și a patra în toate cele trei culori. Aruncând tetraedrul pe o masă el se așază pe una din fețe; ne interesează probabilitatea apariției fiecărei culori și independența evenimentelor corespunzătoare. Notăm cu  $A_1$  evenimentul care constă în apariția culorii albe,  $A_2$  evenimentul care constă în apariția culorii negre și  $A_3$  evenimentul care constă în apariția culorii roșii. Avem:

$$P(A_1) = P(A_2) = P(A_3) = \frac{1}{2}$$

deoarece pentru fiecare culoare sunt patru cazuri posibile și două favorabile (fața cu culoarea respectivă și fața cu cele trei culori). Se constată că

$$P(A_1 \cap A_2) = P(A_1 \cap A_3) = P(A_2 \cap A_3) = \frac{1}{4},$$

dar

$$P(A_1 \cap A_2 \cap A_3) = \frac{1}{4} \neq P(A_1)P(A_2)P(A_3) = \frac{1}{8}.$$



### 1.3 Metode de numărare

Calculul probabilităților conduce adesea la numărarea diferitelor cazuri posibile. Capitolul din algebră referitor la permutări, aranjamente și combinări este foarte util în această situație.

**PRINCIPIUL MULTIPLICĂRII.** Presupunem că avem două situații  $A$  și  $B$ , situația  $A$  se poate realiza în  $m$  moduri, iar situația  $B$  în  $k$  moduri. Numărul de moduri în care se poate realiza  $A$  și  $B$  este  $m \times k$ .

Mai general, presupunem că avem  $r \geq 2$  situații. În prima situație putem face  $m_1$  alegeri, în a doua  $m_2, \dots$ , în a  $r$ -a situație  $m_r$  alegeri, deci în total  $m_1 \times m_2 \times \dots \times m_r$ .

**Exemplul 1.3.1** Care este numărul situațiilor care apar aruncând două zaruri? Pentru primul zar sunt 6 situații, pentru al doilea 6 situații, în total  $6 \times 6$  situații.

În continuare vom face distincție între o mulțime cu o ordine determinată de dispunere a elementelor sale, numită mulțime ordonată și o mulțime în care nu ne interesează ordinea elementelor.

**PERMUTĂRI:** Fie o mulțime  $A$  cu  $n$  elemente. Elementele acestei mulțimi se pot ordona în mai multe moduri. Fiecare mulțime ordonată care se formează cu cele  $n$  elemente ale mulțimii  $A$  se numește permutare a elementelor acelei mulțimi. Numărul permutărilor cu  $n$  elemente este  $n! = 1 \times 2 \times \dots \times n$ .

**ARANJAMENTE:** Fie o mulțime  $A$  cu  $n$  elemente. Submulțimile ordonate ale lui  $A$ , având fiecare câte  $k$  elemente,  $0 \leq k \leq n$ , se numesc aranjamente de  $n$  luate câte  $k$ . Numărul aranjamentelor de  $n$  luate câte  $k$  se notează

$$A_n^k = n(n-1) \dots (n-k+1).$$

**Exemplul 1.3.2** În câte moduri este posibil să facem un steag tricolor dacă avem la dispoziție pânză de steag de cinci culori diferite ?

Două steaguri tricolore care au aceleași culori se deosebesc dacă ordinea culorilor este diferită. Deci ne interesează câte submulțimi de câte trei elemente se pot forma cu elementele unei mulțimi de cinci elemente, în submulțimi interesându-ne ordinea elementelor. Deci sunt  $A_5^3 = 5 \times 4 \times 3 = 60$ .

**COMBINĂRI:** Fie o mulțime  $A$  cu  $n$  elemente. Submulțimile lui  $A$  având fiecare câte  $k$  elemente,  $0 \leq k \leq n$ , în care nu ne interesează ordinea elementelor, se numesc combinări de  $n$  luate câte  $k$ . Numărul combinărilor de  $n$  luate câte  $k$  se notează

$$C_n^k = \frac{A_n^k}{k!}.$$

**Exemplul 1.3.3** Pentru un joc, cinci fete și trei băieți trebuie să formeze două echipe de câte patru persoane. În câte moduri se pot forma echipele ?

În total sunt 8 copii cu ajutorul cărora trebuie făcute două grupe a câte patru copii. Studiem în câte moduri se poate forma o grupă de 4, cealaltă formându-se din copiii rămași. Nu interesează numărul de fete sau de băieți din grupă și nici ordinea lor, ci numai numărul de grupe care se pot forma. Acest număr este

$$C_5^4 + C_5^3 \times C_3^1 + C_5^2 \times C_3^2 + C_5^1 \times C_3^3 = C_8^4 = 70.$$

## 1.4 Moduri de selectare a elementelor

Presupunem că o urnă conține  $m$  bile, marcate de la 1 la  $m$ , din care se extrag  $n$  bile în anumite condiții. Vom număra, în fiecare situație, numărul cazurilor posibile. Evident  $n \leq m$ .

### 1. Selectare cu întoarcerea bilei extrase în urnă și ordonare.

Extragem  $n$  bile pe rând, fiecare bilă fiind pusă înapoi în urnă înainte de următoarea extragere, însemnând numărul bilelor în ordinea în care apar (interesează ordinea bilelor în  $n$ -uplul extras). Conform principiului multiplicării, în care  $m_1 = m_2 = \dots = m_n = m$ , numărul  $n$ -uplurilor este  $m^n$ .

### 2. Selectare fără întoarcerea bilei în urnă și cu ordonare.

Procedăm ca și în cazul întâi, dar după fiecare extragere bila obținută este pusă la o parte, această operație fiind echivalentă cu extragerea simultană din urnă a  $n$  bile. Obținem  $n$ -upluri  $(a_1, a_2, \dots, a_n)$ . Regula de multiplicare se aplică astfel: pentru  $a_1$  avem  $m$  posibilități, pentru  $a_2$  avem  $m - 1$  posibilități, ..., pentru  $a_n$  avem  $m - n + 1$  posibilități, în total

$$m \times (m - 1) \times \dots \times (m - n + 1) = A_m^n.$$

Caz particular: dacă  $m = n$ , atunci numărul cazurilor posibile este  $n!$ .

### 3. Selectare cu întoarcerea bilei în urnă și fără ordonare.

Extragem  $n$  bile, una după alta, fiecare fiind repusă în urnă înainte de a realiza următoarea extragere. Nu ținem seama de ordinea bilelor în mulțimea formată. Pot exista și repetiții. Numărul cazurilor posibile este  $C_{n+m-1}^n$ , deoarece ar fi ca și cum am extrage simultan dintr-o urnă care conține  $n + m - 1$  bile (numerotate de la 1 la  $m$ , unele din ele putându-se repeta)  $n$  bile, fără să ne intereseze ordinea. După ultima extragere secvențială în urnă vor rămâne  $m - 1$  bile.

### 4. Selectare fără întorcerea bilei și fără ordonare.

Bilele sunt extrase una după alta, fără a pune bila extrasă înapoi; este același lucru cu a spune că extragem  $n$  bile dintr-o dată și formăm submulțimi de  $n$  elemente, în total  $C_m^n$ .

Caz particular: determinarea numărului de permutări a  $m$  elemente care se disting prin grupuri de culori, adică avem  $m_1$  elemente de culoarea  $c_1$ ,  $m_2$  elemente de culoarea  $c_2$ , ...,  $m_r$  elemente de culoarea  $c_r$ . Culorile sunt distincte, dar bilele de aceeași culoare nu se disting între ele.

$$m_1 + m_2 + \dots + m_r = m.$$

Numărul cazurilor posibile:  $C_m^{m_1}$  moduri de alegere a pozițiilor bilelor de culoare  $c_1$ ,  $C_{m-m_1}^{m_2}$  moduri de alegere a pozițiilor bilelor de culoare  $c_2$ , ...,  $C_{m-m_1-\dots-m_{r-1}}^{m_r}$  moduri

de alegere a pozițiilor bilelor de culoarea  $c_m$  (de fapt  $m - m_1 - m_2 - \dots - m_{r-1} = m_r$  și avem, de fapt, o singură posibilitate), în total, ținând seama de regula multiplicării,

$$\begin{aligned} & C_m^{m_1} C_{m-m_1}^{m_2} \dots C_{m-m_1-\dots-m_{r-1}}^{m_r} = \\ &= \frac{m!}{m_1! (m-m_1)!} \cdot \frac{(m-m_1)!}{m_2! (m-m_1-m_2)!} \dots \frac{(m-m_1-\dots-m_r)!}{(m-m_1-\dots-m_r)! m_{r-1}!} = \\ &= \frac{m!}{m_1! m_2! \dots m_r!}. \end{aligned}$$

## 1.5 Definiția axiomatică a probabilității

Noțiunile de probabilitate și de câmp finit de probabilitate se pot prezenta și sub formă axiomatică.

**Definiția 1.5.1** Se numește probabilitate (măsură de probabilitate) o funcție definită pe un câmp finit de evenimente  $\{ E, K \}$  cu valori reale care satisface următoarele axiome:

- a)  $P(A) \geq 0, \quad \forall A \in K;$
- b)  $P(E) = 1;$
- c)  $P(A \cup B) = P(A) + P(B) \quad \forall A, B \in K, A \cap B = \emptyset.$

**Observația 1.5.1** Axioma c) din definiție se extinde prin recurență la orice număr finit de evenimente incompatibile două câte două, deci dacă  $A_i \cap A_j = \emptyset, i \neq j, i, j = \overline{1, n}$ , atunci

$$P\left(\bigcup_{i=1}^n A_i\right) = \sum_{i=1}^n P(A_i).$$

Definiția clasică a probabilității satisface toate axiomele definiției date și, de asemenea, oricare din proprietățile prezentate anterior pentru probabilitate poate fi obținută din definiția axiomatică. Într-adevăr,

P1.  $P(\emptyset) = 0.$

Deoarece  $E \cup \emptyset = E$  și  $E \cap \emptyset = \emptyset$  rezultă că  $P(E \cup \emptyset) = P(E) + P(\emptyset)$ , adică  $P(\emptyset) = 0.$

P2.  $P(A \setminus B) = P(A) - P(A \cap B).$

Deoarece  $(A \setminus B) \cup (A \cap B) = A$  și  $(A \setminus B) \cap (A \cap B) = \emptyset$  rezultă  $P(A \setminus B) + P(A \cap B) = P(A).$

P3. Pentru orice  $A, B \in K, A \subset B$  are loc relația  $P(A) \leq P(B).$

Într-adevăr, ținând seama de P2 și de faptul că  $A \subset B$  avem

$$0 \leq P(B \setminus A) = P(B) - P(B \cap A) = P(B) - P(A).$$

Deci  $P(B) - P(A) \geq 0$  sau  $P(B) \geq P(A).$

P4. Pentru orice  $A \in K$  are loc inegalitatea  $0 \leq P(A) \leq 1$ .

Într-adevăr,  $\emptyset \subset A \subset E$  și, folosind P3, avem  $P(\emptyset) \leq P(A) \leq P(E)$  sau  $0 \leq P(A) \leq 1$ .

**Definiția 1.5.2** Se numește câmp finit de probabilitate un câmp finit de evenimente  $\{E, K\}$  pe care am definit o probabilitate  $P$ . Se notează  $\{E, K, P\}$ .

**Observația 1.5.2** Definițiile probabilităților condiționate și a independenței evenimentelor rămân aceleași și atunci când construirea teoriei probabilităților se realizează folosind metoda axiomatică.

**Observația 1.5.3** Dacă  $E$  este reuniune finită de evenimente elementare, fie  $E = \{A_1, A_2, \dots, A_n\}$ , atunci orice eveniment  $A \in K, A \neq \emptyset$  poate fi scris ca o reuniune finită de evenimente elementare, conform P3 din Capitolul 1.1, adică

$$A = A_{i_1} \cup A_{i_2} \cup \dots \cup A_{i_k},$$

unde  $A_{i_j}$  este un eveniment elementar,  $j = \overline{1, k}$ . Atunci conform Observației 1.5.1 obținem

$$P(A) = P(A_{i_1}) + \dots + P(A_{i_k}).$$

Deci pentru a cunoaște probabilitatea unui eveniment oarecare din  $K$  este suficient să cunoaștem probabilitatea tuturor evenimentelor elementare care-l compun.

Probabilitatea unui astfel de eveniment  $A$  este suma probabilităților evenimentelor elementare ce-l compun. Evident, probabilitățile evenimentelor elementare satisfac condițiile

$$P(A_i) \geq 0, \quad i = \overline{1, n}, \quad (1.6)$$

$$P(A_1) + P(A_2) + \dots + P(A_n) = P(E) = 1. \quad (1.7)$$

Deci, fiind date toate evenimentele elementare care compun  $E$ , familia  $K$  este perfect determinată și deci câmpul de probabilitate mai depinde de alegerea a  $n$  numere (probabilitățile evenimentelor elementare) care satisfac condițiile (1.6) și (1.7). În cazul particular când evenimentele elementare sunt echiprobabile

$$P(A_1) = P(A_2) = \dots = P(A_n) = \frac{1}{n},$$

și dacă  $A = A_{i_1} \cup A_{i_2} \cup \dots \cup A_{i_n}$ , obținem  $P(A) = \frac{k}{n}$ , deci ajungem astfel la definiția clasică a probabilității.

**Observația 1.5.4** În definiția axiomatică a probabilității condiția pusă cazurilor posibile de a fi egal probabile este superfluă. Un exemplu celebru, dat de D'Alembert, ilustrează aceasta. Se aruncă două monede simultan. Există trei cazuri posibile care nu sunt echiprobabile:  $A$  evenimentul ca pe ambele monede să apară banul,  $B$  evenimentul ca pe ambele monede să nu apară banul,  $C$  evenimentul ca pe una din monede să apară banul, iar pe cealaltă nu. Probabilitățile evenimentelor  $A, B, C$  nu sunt  $1/3$ .

$$P(A) = \frac{1}{4}, \quad P(B) = \frac{1}{4}, \quad P(C) = \frac{1}{2},$$

deoarece evenimentul  $C$  este compus din două situații: pe una din monede să apară banul iar pe cealaltă nu, și invers. Cele două cazuri care compun evenimentul  $C$  ar fi evidente dacă monedele nu s-ar arunca simultan, ci una după alta. Cele două monede pot fi nedistincte din punct de vedere fizic și deci cele trei cazuri prezentate de D'Alembert sunt de fapt cele trei cazuri care se pot distinge.

## 1.6 Formule probabilistice

**Probabilitatea unei reuniuni de evenimente.** Dacă  $\{E, K, P\}$  un câmp finit de probabilitate atunci oricare ar fi  $A, B \in K$  are loc relația

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

Facem observația că vom demonstra formulele folosind definiția axiomatică a probabilității. Deoarece  $A \cup B = A \cup (B \setminus A)$  și  $A \cap (B \setminus A) = \emptyset$ , avem

$$P(A \cup B) = P(A \cup (B \setminus A)) = P(A) + P(B \setminus A)$$

dar, conform proprietății P2 din Capitolul 1.5,

$$P(B \setminus A) = P(B) - P(B \cap A)$$

și deci rezultă (1.8).

Relația se poate extinde și în cazul a  $n$  evenimente

$$P\left(\bigcup_{i=1}^n A_i\right) = \sum_{i=1}^n P(A_i) - \sum_{i,j=1, i<j}^n P(A_i \cap A_j) + \dots + (-1)^{n-1} P\left(\bigcap_{i=1}^n A_i\right). \quad (1.9)$$

Demonstrația se face prin inducție matematică după  $n$ . Pentru  $n = 2$  relația este demonstrată. Presupunem formula adevărată pentru  $n$  și o demonstrăm pentru  $n + 1$ .

$$\begin{aligned} P\left(\bigcup_{i=1}^{n+1} A_i\right) &= P\left(\left(\bigcup_{i=1}^n A_i\right) \cup A_{n+1}\right) = P\left(\bigcup_{i=1}^n A_i\right) + P(A_{n+1}) - P\left(\left(\bigcup_{i=1}^n A_i\right) \cap A_{n+1}\right) = \\ &= \sum_{i=1}^n P(A_i) - \sum_{i,j=1, i<j}^n P(A_i \cap A_j) + \dots + (-1)^{n-1} P\left(\bigcap_{i=1}^n A_i\right) - \sum_{i=1}^n P(A_i \cap A_{n+1}) + \\ &\quad + \sum_{i,j=1, i<j}^{n+1} P(A_i \cap A_j \cap A_{n+1}) + \dots + (-1)^n P\left(\bigcap_{i=1}^{n+1} A_i\right) = \sum_{i=1}^{n+1} P(A_i) - \\ &\quad \sum_{i,j=1, i<j}^{n+1} P(A_i \cap A_j) + \dots + \sum_{1 \leq i < j < k \leq n+1} P(A_i \cap A_j \cap A_k) + \dots + (-1)^{n+1} P\left(\bigcap_{i=1}^{n+1} A_i\right). \end{aligned}$$

**Probabilitatea unei intersecții.** Fie  $\{E, K, P\}$  un câmp finit de evenimente. Ori-care ar fi  $A, B \in K$  are loc relația

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

Relația de mai sus rezultă din (1.2). Ea poate fi folosită pentru a calcula probabilitatea unei intersecții:

$$P(A \cap B) = P(B)P(A|B).$$

Când folosim această formulă la rezolvarea unei probleme trebuie să considerăm evenimentele  $A$  și  $B$  într-o ordine convenabil aleasă, dat fiind că se poate utiliza, datorită echivalenței demonstrate, relația

$$P(A \cap B) = P(A)P(B|A).$$

Formula se poate extinde și în cazul a  $n$  evenimente  $A_1, A_2, \dots, A_n$ , cu  $P(\bigcap_{i=1}^k A_i) \neq 0$ ,  $k = \overline{2, n-1}$ , sub forma

$$P\left(\bigcap_{i=1}^n A_i\right) = P(A_1)P(A_2|A_1)P(A_3|(A_1 \cap A_2)) \dots P(A_n|(A_1 \cap A_2 \cap \dots \cap A_{n-1})). \quad (1.10)$$

Într-adevăr, folosind definiția probabilității condiționate, obținem

$$\begin{aligned} P(A_1) &= P(A_1), \\ P(A_2|A_1) &= \frac{P(A_2 \cap A_1)}{P(A_1)}, \\ P(A_3|(A_1 \cap A_2)) &= \frac{P(A_1 \cap A_2 \cap A_3)}{P(A_1 \cap A_2)}, \\ &\vdots \\ P(A_n|(A_1 \cap A_2 \cap \dots \cap A_{n-1})) &= \frac{P(A_1 \cap A_2 \cap \dots \cap A_n)}{P(A_1 \cap A_2 \cap \dots \cap A_{n-1})}. \end{aligned}$$

Înmulțind relațiile membru cu membru și făcând simplificările corespunzătoare, obținem (1.10).

**Observația 1.6.1** Dacă evenimentele  $A$  și  $B$  nu sunt independente, atunci din

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

$$0 \leq P(A \cup B) \leq 1,$$

rezultă

$$P(A \cap B) \geq P(A) + P(B) - 1$$

sau, notând  $p_1 = P(A), p_2 = P(B), p_{12} = P(A \cap B)$  atunci  $p_{12} \geq p_1 + p_2 - 1$ . Această inegalitate poartă numele de **inegalitatea lui Boole** și dă o margine inferioară pentru probabilitatea intersecției a două evenimente. Se poate demonstra, mai general,

$$p_{12\dots n} \geq p_1 + p_2 + \dots + p_n - (n - 1),$$

unde  $p_i = P(A_i), i = \overline{1, n}, p_{12\dots n} = P\left(\bigcap_{i=1}^n A_i\right)$ .

**Formula probabilității totale.** Fie  $\{E, K, P\}$  un câmp finit de evenimente,  $\{A_1, A_2, \dots, A_n\}, A_i \in K, i = \overline{1, n}$ , un sistem complet de evenimente și  $B$  un eveniment oarecare,  $B \in K$ . Atunci

$$P(B) = \sum_{i=1}^n P(A_i)P(B|A_i). \quad (1.11)$$

Într-adevăr, deoarece  $E = \bigcup_{i=1}^n A_i$  putem scrie

$$B = B \cap E = B \cap \left(\bigcup_{i=1}^n A_i\right) = \bigcup_{i=1}^n (B \cap A_i)$$

și cum pentru  $i \neq j, A_i \cap A_j = \emptyset$  atunci avem

$$P(B) = \sum_{i=1}^n P(B \cap A_i) = \sum_{i=1}^n P(A_i)P(B|A_i).$$

**Formula lui Bayes.** Fie  $\{E, K, P\}$  un câmp finit de evenimente și  $\{A_1, A_2, \dots, A_n\}, A_i \in K, i = \overline{1, n}$  un sistem complet de evenimente și  $B$  un eveniment oarecare. Atunci

$$P(A_i|B) = \frac{P(B|A_i)P(A_i)}{\sum_{j=1}^n P(A_j)P(B|A_j)}. \quad (1.12)$$

În condițiile date prin ipoteză are loc formula probabilității totale și ținând seama de (1.2) obținem

$$P(A_i|B) = \frac{P(B \cap A_i)}{P(B)} = \frac{P(B|A_i)P(A_i)}{\sum_{j=1}^n P(A_j)P(B|A_j)}$$

**Exemplul 1.6.1** *Controlul de calitate.* Presupunem că într-o cutie sunt 550 de piese, din care 2% sunt defecte. Care este probabilitatea ca alegând 25 de piese, acestea să conțină două piese defecte. Acesta este principiul testării produselor prin selecții aleatoare.

Problema poate fi rezolvată într-un caz general. Presupunem că avem  $k$  piese defecte din  $m$  piese,  $k \leq m$ . Care este probabilitatea ca alegând  $n$  piese, dintre acestea  $j$  să fie defecte?

Putem alege cele  $n$  piese dintre cele  $m$  ( $m \geq n$ ), fără să ne intereseze ordinea pieselor, în  $C_m^n$  moduri. Câte din acestea vor conține  $j$  piese defecte? Putem alege cele  $j$  piese defecte, din cele  $k$ , în  $C_k^j$  moduri, iar celelalte  $n - j$  care nu sunt defecte în  $C_{m-k}^{n-j}$  moduri. Probabilitatea căutată va fi

$$\frac{C_{m-k}^{n-j} C_k^j}{C_m^n}. \quad (1.13)$$

În cazul nostru,  $m = 550, k = 11, n = 25, j = 2$ , astfel încât probabilitatea căutată va fi

$$\frac{C_{11}^2 C_{550}^{23}}{C_{550}^{25}} = 0,12.$$

Dacă însumăm probabilitățile (1.13) după  $j, 0 \leq j \leq n$ , rezultatul va fi 1, deoarece au fost luate în considerare toate posibilitățile. Am demonstrat formula

$$\sum_{j=0}^k C_k^j C_{m-k}^{n-j} = C_m^n$$

cu argumente probabilistice.

**Exemplul 1.6.2** Dacă se amestecă un pachet de cărți, care este probabilitatea ca cei patru ași să apară unul după altul ?

Sunt 52 de cărți dintre care patru ași. Un rezultat posibil al experienței este o înșiruire de 52 de cărți, adică o permutare a celor 52 de cărți. Sunt  $52!$  cazuri posibile. În câte din aceste cazuri cei patru ași se găsesc unul după altul? Cei patru ași pot apare consecutiv în  $49 \times 4!$  moduri. Restul de 48 de cărți se pot aranja în  $48!$  moduri. Folosind principiul multiplicării, numărul cazurilor favorabile va fi  $4! \times 49 \times 48!$ . Probabilitatea căutată va fi

$$\frac{49! \times 4}{52!} = 0,00003.$$

**Exemplul 1.6.3** Urna  $U_1$  conține două bile roșii și patru albe, urna  $U_2$  conține o bilă roșie și două albe iar urna  $U_3$  conține cinci bile roșii și patru bile albe. Fie  $A_i$  evenimentul de a extrage o bilă dintr-o urnă oarecare  $U_i, i = \overline{1, 3}$ . Presupunem că probabilitatea de a extrage o bilă din urna  $U_i$  este  $P(A_1) = 1/3$ , din  $U_2$  este  $P(A_2) = 1/6$  și din  $U_3, P(A_3) = 1/2$ . Se cere probabilitatea de a extrage o bilă roșie.

Fie  $R$  evenimentul de a extrage o bilă roșie. Observăm că  $P(R)$  depinde în primul rând de urna din care s-a făcut extragerea și apoi de structura urnei din care am făcut extragerea, adică  $R$  este reuniunea evenimentelor disjuncte  $A_1 \cap R, A_2 \cap R, A_3 \cap R$ . Facem observația că  $A_1, A_2, A_3$  formează un sistem complet de evenimente. Astfel

$$P(R) = P\left(\bigcup_{i=1}^3 (A_i \cap R)\right) = \sum_{i=1}^3 P(A_i \cap R) = \sum_{i=1}^3 P(A_i)P(R|A_i) = \frac{4}{9}$$

Presupunem acum că rezultatul experienței este o bilă roșie, dar nu știm din ce urnă provine. Dorim să calculăm probabilitatea ca bila roșie să provină din urna  $U_1$ , adică  $P(A_1|R)$ . Conform formulei lui Bayes

$$P(A_1|R) = \frac{P(A_1)P(R|A_1)}{P(R)} = \frac{1}{4}.$$



La fel

$$P(A_2|R) = \frac{1}{8} \quad P(A_3|R) = \frac{5}{8}.$$

Observăm că probabilitățile condiționate  $P(A_1|R)$ ,  $P(A_2|R)$ ,  $P(A_3|R)$  s-au modificat față de probabilitățile inițiale  $P(A_1)$ ,  $P(A_2)$ ,  $P(A_3)$  într-un mod care confirmă intuiția, adică dacă s-a extras o bilă roșie, probabilitatea ca să aparțină urnei  $U_3$  este mai mare deoarece  $U_3$  are un procent mai ridicat de bile roșii și, de asemenea, probabilitatea de a selecta o bilă roșie din  $U_3$  este mai mare decât din  $U_2$  sau  $U_1$ . Adesea  $P(A_1)$ ,  $P(A_2)$ ,  $P(A_3)$  se numesc probabilități apriori, iar  $P(A_1|R)$ ,  $P(A_2|R)$ ,  $P(A_3|R)$  se numesc probabilități aposteriori.

**Exemplul 1.6.4** Un canal transmite semnale sub formă de șiruri formate din cifrele 0 și 1. În canal pot apare perturbări care produc erori, astfel încât în loc de 1 apare 0 sau invers. Să presupunem că prin  $B_1$  și  $B_2$  înțelegem evenimentele care constau în transmiterea cifrelor 1, respectiv 0, iar recepționarea cifrelor 1 și 0 le considerăm ca fiind evenimentele aleatoare  $A_1$  și respectiv  $A_2$ . Probabilitățile apriori pentru transmiterea lui 1 sau 0 sunt

$$P(B_1) = p \quad P(B_2) = 1 - p = q$$

iar probabilitatea de a recepționa 0, dacă s-a transmis 1, este egală cu  $q_{10}$ , pe când probabilitatea de a recepționa 1, dacă s-a transmis 0, este  $q_{01}$ . Să calculăm probabilitățile aposteriori  $P(B_j|A_k)$ ,  $j, k = 1, 2$ .

Conform formulei lui Bayes avem

$$P(B_j|A_k) = \frac{P(A_k|B_j)P(B_j)}{P(B_1)P(A_k|B_1) + P(B_2)P(A_k|B_2)}, \quad j, k = 1, 2.$$

Deoarece avem  $P(A_2|B_1) = q_{10}$ ,  $P(A_1|B_2) = q_{01}$  și notând  $p_{10} = 1 - q_{10}$ ,  $p_{01} = 1 - q_{01}$  se deduce

$$P(B_1|A_1) = \frac{pp_{10}}{pp_{10} + (1-p)(1-p_{01})}, \quad P(B_1|A_2) = \frac{p(1-p_{10})}{p(1-p_{10}) + (1-p)p_{01}},$$

$$P(B_2|A_1) = \frac{(1-p)(1-p_{10})}{pp_{10} + (1-p)(1-p_{01})}, \quad P(B_2|A_2) = \frac{(1-p)p_{01}}{p(1-p_{10}) + (1-p)p_{01}}.$$

Să observăm că

$$P(A_1) = P(B_1)P(A_1|B_1) + P(B_2)P(A_1|B_2) = pp_{10} + (1-p)(1-p_{01}),$$

iar

$$P(A_2) = P(B_1)P(A_2|B_1) + P(B_2)P(A_2|B_2) = p(1-p_{10}) + (1-p)p_{01} = 1 - P(A_1).$$

În particular, în ipoteza că este vorba de un canal simetric ( $q_{01} = q_{10}$  și deci  $p_{01} = p_{10}$ ), iar  $p = q = \frac{1}{2}$  se deduce

$$P(A_1) = pp_{10} + (1-p)(1-p_{10}) = \frac{1}{2}, \quad P(A_2) = p(1-p_{10}) + (1-p)p_{10} = \frac{1}{2}$$

$$P(B_1|A_2) = P(B_2|A_1) = 1 - p_{10}, \quad P(B_1|A_1) = P(B_2|A_2) = p_{10}.$$

ceea ce era previzibil.

**Exemplul 1.6.5** Demonstrăm că dacă  $A_i, i \in I, I$  o mulțime finită de indici,  $\{A_i\}_{i \in I}$  formează un sistem complet de evenimente, atunci

$$P\left(\bigcup_{i \in I} A_i \mid A\right) = \sum_{i \in I} P(A_i \mid A). \quad (1.14)$$

Pornind de la membrul întâi

$$P\left(\bigcup_{i \in I} A_i \mid A\right) = \frac{P\left(\left(\bigcup_{i \in I} A_i\right) \cap A\right)}{P(A)} = \frac{P\left(\bigcup_{i \in I} (A_i \cap A)\right)}{P(A)}$$

și ținând seama de

$$(A_i \cap A) \cap (A_j \cap A) = \emptyset, \quad \forall i, j \in I, i \neq j,$$

obținem

$$P\left(\bigcup_{i \in I} A_i \mid A\right) = \frac{\sum_{i \in I} P(A_i \cap A)}{P(A)} = \frac{\sum_{i \in I} P(A_i \mid A)P(A)}{P(A)} = \sum_{i \in I} P(A_i \mid A).$$

**Exemplul 1.6.6** Fie  $I$  o mulțime finită de indici,  $\{A_i\}_{i \in I}$  un sistem complet de evenimente și  $A, B$  două evenimente oarecare. Atunci

$$P\left(\bigcup_{i \in I} (A \cap A_i) \mid B\right) = \sum_{i \in I} P(A \mid (A_i \cap B))P(A_i \mid B) \quad (1.15)$$

Folosim formula (1.14) obținem

$$\begin{aligned} P\left(\bigcup_{i \in I} (A \cap A_i) \mid B\right) &= \sum_{i \in I} P((A \cap A_i) \mid B) = \frac{\sum_{i \in I} P(A \cap A_i \cap B)}{P(B)} = \\ &= \frac{\sum_{i \in I} P(A \mid (A_i \cap B))P(A_i \cap B)}{P(B)} = \frac{\sum_{i \in I} P(A \mid (A_i \cap B))P(A_i \mid B)P(B)}{P(B)} = \\ &= \sum_{i \in I} P(A \mid (A_i \cap B))P(A_i \mid B). \end{aligned}$$

## 1.7 Scheme clasice de probabilitate

**Schema lui Poisson.** Se dau  $n$  urne  $U_1, U_2, \dots, U_n$  care conțin bile albe și bile negre în proporții date, deci cunoaștem probabilitățile  $p_i, i = \overline{1, n}$ , cu care este extrasă o bilă albă din urna  $U_i$ . Se cere probabilitatea de a extrage  $k$  bile albe și  $n - k$  bile negre, atunci când din fiecare urnă se extrage câte o bilă.

Notăm cu  $A_i$  evenimentul extragerii unei bile albe din urna  $U_i$ . Notăm și  $B_k$  evenimentul care constă în extragerea a  $k$  bile albe și  $n - k$  bile negre, adică

$$B_k = (A_1 \cap \dots \cap A_k \cap \bar{A}_{k+1} \cap \bar{A}_n) \cup (A_1 \cap \dots \cap \bar{A}_k \cap A_{k+1} \cap \bar{A}_{k+2} \cap \dots \cap \bar{A}_n) \\ \cup (\bar{A}_1 \cap \dots \cap \bar{A}_{n-k} \cap A_{n-k+1} \cap \dots \cap A_n),$$

numărul parantezelor fiind  $C_n^k$ . Un eveniment

$$A_{i_1} \cap \dots \cap A_{i_k} \cap \bar{A}_{i_{k+1}} \cap \dots \cap \bar{A}_{i_n}$$

se realizează, ținând seama că evenimentele sunt independente, cu probabilitatea

$$p_{i_1} \dots p_{i_k} q_{i_{k+1}} \dots q_{i_n}$$

indicii  $i_1, i_2, \dots, i_n$  reprezentând o permutare a indicilor  $1, 2, \dots, n$ , iar litera  $p$  apare de  $k$  ori cu indici diferiți, iar  $q$  de  $n - k$  ori cu indici care nu apar în  $p$ . Se observă că după aceeași regulă se calculează coeficientul lui  $x^k$  din polinomul

$$P(x) = (p_1x + q_1)(p_2x + q_2) \dots (p_nx + q_n).$$

Schema lui Poisson permite rezolvarea problemelor în care se cere probabilitatea realizării de  $k$  ori a unor evenimente  $A_1, A_2, \dots, A_n$  atunci când se repetă de  $n$  ori aceste experiențe, presupuse independente, când cunoaștem  $P(A_i) = p_i$ ,  $i = \overline{1, n}$ .

**Exemplul 1.7.1** Într-un atelier sunt trei mașini. Prima dă 0,9 % rebut, a doua 1 % și a treia 1,3 %. Se ia la întâmplare câte o piesă de la fiecare mașină. Se cere probabilitatea ca două din piese să fie bune și una rebut.

$$p_1 = 0,991, \quad q_1 = 0,001, \quad p_2 = 0,99, \\ q_2 = 0,01, \quad p_3 = 0,987, \quad q_3 = 0,013,$$

$$P(x) = (0,991x + 0,009)(0,99x + 0,01)(0,987x + 0,013).$$

Coeficientul lui  $x^2$  este

$$0,991 \times 0,99 \times 0,013 + 0,99 \times 0,987 \times 0,987 \times 0,009 + 0,991 \times 0,987 \times 0,01 = 0,0313.$$

**Schema lui Bernoulli.** Presupunem că în schema lui Poisson urnele  $U_1, U_2, \dots, U_n$  sunt identice. Atunci putem lua

$$p_1 = p_2 = \dots = p_n = p, \quad q_1 = q_2 = \dots = q_n = q$$

Probabilitatea extragerii a  $k$  bile albe se va obține calculând coeficientul lui  $x^k$  din polinomul

$$P(x) = (px + q)^n,$$

adică va fi

$$C_n^k p^k q^{n-k}.$$

Recunoaștem în această expresie termenul general al ridicării la puterea  $n$  a binomului  $px + q$ . Pentru acest motiv schema se mai numește binomială. Deoarece urnele sunt identice,

putem considera că toate extragerile se fac dintr-o singură urnă, bila extrasă punându-se în urnă după fiecare extragere. Obținem astfel schema lui Bernoulli. Probabilitatea de a extrage  $k$  bile albe din  $n$  extrageri dintr-o urnă, punându-se de fiecare dată bila înapoi, este

$$P_{n,k} = C_n^k p^k q^{n-k},$$

unde  $p$  este probabilitatea oținerii unei bile albe dintr-o singură extragere și  $q = 1 - p$ . Schema lui Bernoulli se mai numește *shema bilei revenite (întoarse)*.

**Exemplul 1.7.2** Se aruncă un zar de 5 ori. Se cere probabilitatea ca fața cu un punct să apară exact de două ori.

Avem:

$$p = \frac{1}{6}, \quad q = \frac{5}{6}, \quad n = 5, \quad k = 2,$$

$$P_{5,2} = C_5^2 \left(\frac{1}{6}\right)^2 \left(\frac{5}{6}\right)^3 = 0,16.$$

**Schema lui Bernoulli cu mai multe stări.** Fie o urnă care conține bile de  $m$  culori  $c_1, c_2, \dots, c_m$  iar  $p_i$  probabilitatea ca la o extragere să obținem o bilă de culoarea  $c_i$ . Probabilitatea ca în  $n$  extrageri să obținem  $n_1$  bile de culoarea  $c_1$ ,  $n_2$  bile de culoarea  $c_2$ ,  $\dots$ ,  $n_m$  bile de culoarea  $c_m$  ( $n_1 + n_2 + \dots + n_m = n$ ) este

$$\frac{n!}{n_1! n_2! \dots n_m!} p_1^{n_1} p_2^{n_2} \dots p_m^{n_m}.$$

Această schemă rezolvă problemele în care se cere probabilitatea ca în  $n$  efectuări ale experienței evenimentul  $A_i$  să se realizeze de  $n_i$  ori,  $A_1, A_2, \dots, A_m$  fiind un sistem complet de evenimente și  $P(A_i) = p_i, i = \overline{1, m}$ . Presupunem că în cele  $n$  efectuări ale experienței s-au obținut succesiv

$$\underbrace{A_1 \dots A_1}_{n_1} \underbrace{A_2 \dots A_2}_{n_2} \dots \underbrace{A_m \dots A_m}_{n_m}.$$

Acest eveniment se produce cu probabilitatea

$$\underbrace{p_1 \dots p_1}_{n_1} \underbrace{p_2 \dots p_2}_{n_2} \dots \underbrace{p_m \dots p_m}_{n_m}.$$

Același rezultat îl obținem pentru orice altă ordine stabilită dinainte în care  $A_i$  apare de  $n_i$  ori. Rămâne să vedem în câte moduri putem scrie cele  $n$  simboluri, dintre care  $n_1$  egale cu  $A_1$ ,  $n_2$  cu  $A_2, \dots, n_m$  cu  $A_m$ .

$$\begin{aligned} & C_n^{n_1} C_{n-n_1}^{n_2} C_{n-n_1-n_2}^{n_3} \dots C_{n-n_1-n_2-\dots-n_{m-1}}^{n_m} = \\ &= \frac{n!}{n_1! (n-n_1)!} \frac{(n-n_1)!}{n_2! (n-n_1-n_2)!} \dots \frac{(n-n_1-\dots-n_{m-1})!}{n_m! (n-n_1-\dots-n_m)!} = \\ &= \frac{n!}{n_1! \dots n_m!}. \end{aligned}$$

**Exemplul 1.7.3** Se aruncă un zar de 5 ori. Care este probabilitatea ca exact de două ori să apară fața cu un punct și exact de 2 ori să apară fața cu două puncte?

Avem:

$$\begin{aligned} n &= 5, & n_1 &= 2, & n_2 &= 2, & n_3 &= 1, \\ p_1 &= \frac{1}{6}, & p_2 &= \frac{1}{6}, & p_3 &= \frac{2}{3}, \\ P_{4,2,2,1} &= \frac{5!}{2! \times 2! \times 1!} \times \left(\frac{1}{6}\right)^2 \left(\frac{1}{6}\right)^2 \left(\frac{2}{3}\right) = \frac{5}{324}. \end{aligned}$$

**Schema hipergeometrică.** O urnă conține  $a$  bile albe și  $b$  bile negre. Din această urnă se extrag  $n$  bile ( $n \leq a + b$ ) pe rând, fără a pune bila extrasă înapoi în urnă (ceea ce este echivalent cu a extrage  $n$  bile deodată). Se cere probabilitatea ca din cele  $n$  bile extrase,  $k$  să fie albe ( $k \leq a$ ) și  $n - k$  negre ( $n - k \leq b$ ). Pentru a calcula această probabilitate vom stabili numărul cazurilor posibile și numărul cazurilor favorabile.

Numărul cazurilor posibile este:  $C_{a+b}^n$ .

Numărul cazurilor favorabile: un grup de  $k$  bile albe dintr-un total de  $a$  bile albe poate fi luat în  $C_a^k$  moduri; un grup de  $n - k$  bile negre din totalul de  $b$  bile negre poate fi obținut în  $C_b^{n-k}$  moduri. Un grup de  $k$  bile albe și  $n - k$  bile negre poate fi obținut, conform principiului multiplicării, în  $C_a^k C_b^{n-k}$  moduri. Probabilitatea căutată este

$$\frac{C_a^k C_b^{n-k}}{C_{a+b}^n}.$$

**Exemplul 1.7.4** La o tombolă sunt 400 bilete dintre care 4 câștigătoare. O persoană cumpără 10 bilete. Care este probabilitatea să nu se găsească nici un bilet câștigător?

Avem

$$\begin{aligned} a &= 4, & b &= 396, \\ k &= 0, & n - k &= 10, & n &= 10, \\ p &= \frac{C_4^0 C_{396}^{10}}{C_{400}^{10}} = 0,903. \end{aligned}$$

În general, dacă urna conține  $a_i$  bile de culoarea  $c_i$ ,  $i = \overline{1, m}$ , probabilitatea de a obține  $n_1$  bile de culoarea  $c_1$ ,  $n_2$  bile de culoarea  $c_2$ ,  $\dots$ ,  $n_m$  bile de culoarea  $c_m$  când facem  $n = n_1 + n_2 + \dots + n_m$  extracții, este egală cu

$$\frac{C_{a_1}^{n_1} C_{a_2}^{n_2} \dots C_{a_m}^{n_m}}{C_{a_1+a_2+\dots+a_m}^n}.$$

**Exemplul 1.7.5** O urnă conține 7 bile albe, 7 bile negre și 6 verzi. Se extrag 9 bile. Care este probabilitatea să obținem câte 3 de fiecare culoare?

Avem

$$\begin{aligned} a_1 &= 7, & a_2 &= 7, & a_3 &= 6, \\ n_1 &= 3, & n_2 &= 3, & n_3 &= 3, \\ p &= \frac{C_7^3 C_7^3 C_6^3}{C_{20}^9} = 0,145. \end{aligned}$$

## 1.8 Câmp infinit de probabilitate

În numeroase cazuri practice nu este cu putință să evaluăm numărul cazurilor egal posibile și al celor favorabile pentru determinarea probabilității evenimentului care ne interesează. Asemenea situații apar în studiul fenomenelor economice și sociale, în efectuarea controlului statistic al producției etc. Deci definiția clasică a probabilității nu este satisfăcătoare când mulțimea evenimentelor elementare este infinită.

În acest caz definim câmpul infinit de evenimente astfel :

**Definiția 1.8.1** O mulțime de evenimente  $\{ E, K \}, K \neq \emptyset$ , se numește câmp infinit de evenimente dacă :

- a)  $\forall A \in K \Rightarrow \bar{A} \in K$ ;
- b)  $(A_n)_{n \in \mathbb{N}^*} \subset K \Rightarrow \bigcup_{n \in \mathbb{N}^*} A_n \in K$ .

Consecințe care rezultă din definiție :

C1.  $\emptyset \in K$  și  $E \in K$ .

Într-adevăr, deoarece  $K \neq \emptyset \Rightarrow \exists A \in K \Rightarrow \bar{A} \in K \rightarrow A \cup \bar{A} \in K \Rightarrow E \in K$   
 $E \in K \Rightarrow \bar{E} \in K \Rightarrow \emptyset \in K$ .

C2. Orice reuniune finită de evenimente din  $K$  este în  $K$ .

Într-adevăr, fie  $A_1, A_2, \dots, A_n \in K$  și luăm  $A_i = \emptyset$  pentru  $i > n$ . Conform b),  
 $\bigcup_{i=1}^{\infty} A_i = \bigcup_{i=1}^n A_i \in K$

C3. Orice intersecție (finită sau numărabilă) de elemente din  $K$  este de asemenea în  $K$ .

Fie  $I$  o mulțime de indici finită sau numărabilă

$$\overline{\bigcap_{i \in I} A_i} = \bigcup_{i \in I} \bar{A}_i \in K \Rightarrow \bigcap_{i \in I} A_i \in K$$

C4. Dacă  $A, B \in K$  atunci  $A \setminus B \in K$  (deoarece  $A \setminus B = A \cap \bar{B} \in K$ ).

C5. Dacă  $(A_n)_{n \in \mathbb{N}^*} \subset K$  atunci

$$\liminf_{n \rightarrow \infty} A_n \in K; \quad \limsup_{n \rightarrow \infty} A_n \in K.$$

Ținem seama de definiția limitei inferioare, respectiv superioare, de consecințele C2, C3 și obținem

$$\liminf_{n \rightarrow \infty} = \bigcup_{n=1}^{\infty} \left( \bigcap_{k=n}^{\infty} A_k \right) \in K; \quad \limsup_{n \rightarrow \infty} = \bigcap_{n=1}^{\infty} \left( \bigcup_{k=n}^{\infty} A_k \right) \in K.$$

C6. Dacă  $(A_n)_{n \in \mathbb{N}^*} \subset K$ , atunci  $\lim_{n \rightarrow \infty} A_n \in K$ , dacă această limită există. În acest caz

$$\lim_{n \rightarrow \infty} A_n = \liminf_{n \rightarrow \infty} A_n = \limsup_{n \rightarrow \infty} A_n \in K.$$

**Observația 1.8.1** Într-un câmp infinit de evenimente sunt permise operațiile clasice cu mulțimi.

Pentru a introduce noțiunea de probabilitate în asemenea cazuri, definim noțiunea de măsură a unui eveniment al unui câmp infinit de evenimente.

**Definiția 1.8.2** Se numește măsură a unui eveniment  $A$  al câmpului infinit de evenimente  $\{E, K\}$  o funcție

$$m : K \longrightarrow \mathbb{R}$$

care satisface următoarele axiome:

a)  $\forall A \in K : m(A) \geq 0;$

b)  $m(\emptyset) = 0;$

c)  $m\left(\bigcup_{i \in I} A_i\right) = \sum_{i \in I} m(A_i)$  pentru  $(A_i)_{i \in I} \subset K$  cu  $A_i \cap A_j = \emptyset$   $i \neq j$   $i, j \in I$ , iar  $I$  o mulțime cel mult numărabilă de indici.

**Observația 1.8.2** Axioma c) se numește axioma aditivității complete a măsurii  $m$ . În această axiomă intervine o reuniune numărabilă de evenimente, lucru despre care se poate vorbi numai în cazul în care câmpul de evenimente este infinit. Introducem  $\bigcup_{i=1}^{\infty} A_i$  ca fiind evenimentul care constă în realizarea a cel puțin unuia din evenimentele  $A_1, A_2, \dots, A_n, \dots$ . Analog, evenimentul  $\bigcap_{i=1}^{\infty} A_i$  constă în realizarea tuturor evenimentelor  $A_1, A_2, \dots, A_n, \dots$ . Acceptarea axiomei c) este justificată; ea reprezintă o extindere naturală a proprietății corespunzătoare din câmpurile finite de evenimente.

**Observația 1.8.3** Când  $A_{n+1} = A_{n+2} = \dots = \emptyset$  se obține aditivitatea finită a măsurii

$$m\left(\bigcup_{i=1}^n A_i\right) = \sum_{i=1}^n m(A_i).$$

**Observația 1.8.4** Din mulțimea funcțiilor de evenimente care satisfac axiomele a)-c) interesează numai acelea pentru care  $m(E) < \infty$ ,  $E$  fiind evenimentul cert.

**Propoziția 1.8.1** Dacă  $m(E) < \infty$  atunci pentru orice eveniment  $A$  avem  $m(A) < \infty$ .

**Demonstrație.** Deoarece  $A \cup \bar{A} = E$ ,  $A \cap \bar{A} = \emptyset \Rightarrow m(A \cup \bar{A}) = m(A) + m(\bar{A}) = m(E) < \infty$ . Dar  $m(\bar{A}) \geq 0 \Rightarrow m(A) \leq m(E) < \infty \Rightarrow m(A) < \infty$ . ■

**Definiția 1.8.3** Fie un câmp infinit de evenimente  $\{E, K\}$ . Se numește probabilitatea evenimentului  $A \in K$ , măsura  $m(A)$  pentru care  $m(E) = 1$

**Definiția 1.8.4** Se numește funcție de probabilitate acea măsură a evenimentelor definită pe câmpul infinit de evenimente  $\{E, K\}$  care satisface proprietatea  $m(E) = 1$ .

**Definiția 1.8.5** Se numește câmp borelian (infinit) de probabilitate un câmp infinit de evenimente  $\{E, K\}$  pe care s-a definit o funcție de probabilitate  $P$ . Un câmp infinit de probabilitate se notează  $\{E, K, P\}$ .

Problema cum trebuie determinată probabilitatea unui eveniment nu poate fi rezolvată în general deoarece ea depinde în mod esențial de natura fenomenului studiat.

**Exemplul 1.8.1** De exemplu, ne vom referi la probabilitățile geometrice. Fie  $E \subset \mathbb{R}^n$  un domeniu. Un punct  $M \in E$ , luat la întâmplare, se numește punct aleator. Fie o submulțime  $A \subset E$ . Prin măsura lui  $A$  putem înțelege lungimea, aria sau volumul lui  $A$ . Dacă admitem ipoteza că în cazul în care  $A, B \subset E$  și  $m(A) = m(B) \Rightarrow A = B$  sunt echivalente din punct de vedere al ariei, indiferent de forma domeniilor  $A$  și  $B$ , putem scrie

$$P(M \in A) = km(A)$$

unde  $k$  este un factor constant. Pentru întreg domeniul  $E$  avem evenimentul sigur, deci

$$P(M \in E) = 1 = km(E)$$

de unde

$$k = \frac{1}{m(E)}$$

și deci obținem probabilitatea

$$P(M \in A) = \frac{m(A)}{m(E)}.$$

În cazul considerat, dacă  $A$  nu are decât un număr finit de puncte,  $P(M \in A) = 0$ .

**Exemplul 1.8.2** Vom arăta cum se poate construi o funcție de probabilitate pentru orice mulțime numărabilă  $E = \{e_1, e_2, \dots, e_n, \dots\}$ . Fiecărui punct  $e_i$  îi atașăm un număr  $p_i$  satisfăcând condițiile

$$\forall i \in \mathbb{N}^* : p_i \geq 0, \quad \sum_{i=1}^{\infty} p_i = 1$$

Fie  $K = \mathcal{P}(E)$  și  $A$  o submulțime a lui  $E$ . Definim

$$P(A) = \sum_{e_i \in A} p_i = \sum_{e_i \in A} P(e_i)$$

Constatăm imediat că  $\{E, K, P\}$  este un câmp infinit de probabilitate.

Dăm un exemplu de câmp de probabilitate.



**Exemplul 1.8.3** Fie  $\mathcal{B}$  corpul borelian generat de mulțimea părților deschise de pe axa reală  $\mathbb{R}$  și o funcție  $f$  definită pe  $E \in \mathcal{B}$  cu valori în  $\mathbb{R}$ , integrabilă în raport cu măsura Lebesgue [vezi 22] și care îndeplinește condițiile

$$f(x) \geq 0, \quad \int_E f(x) dx = 1.$$

Se verifică imediat că  $\{E, K, P\}$  este un câmp borelian de probabilitate, unde

$$K = \{A \cap E, A \in \mathcal{B}\},$$

iar

$$P(A) = \int_E f(x) \chi_A(x) dx$$

pentru  $A \in K$ , unde

$$\chi_A(e) = \begin{cases} 1, & \text{dacă } e \in A, \\ 0, & \text{dacă } e \notin A, \end{cases}$$

În particular, dacă  $f$  este continuă, punem

$$P(A) = \int_A f(x) dx.$$

Se demonstrează că  $P$  satisface toate axiomele probabilității. Astfel de funcții se pot găsi. De exemplu

$$f(x) = \frac{1}{\pi(1+x^2)} \quad \text{sau} \quad f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}.$$

În câmpurile infinite de probabilitate se păstrează noțiunile și proprietățile din câmpurile finite de probabilitate.

1. Probabilitatea condiționată se definește plecând de la relația

$$P(A|B) = \frac{P(A \cap B)}{P(B)}, \quad \text{dacă } P(B) \neq 0.$$

Se poate demonstra că tripletul  $\{E, K, P_B\}$  este un câmp borelian de probabilitate. Într-adevăr,

- $P(A|B) \geq 0$  deoarece  $P(A \cap B) \geq 0$  și  $P(B) > 0$ .
- Dacă  $A = E$  atunci, deoarece  $E \cap B = B$ , rezultă

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

- Dacă  $(A_i)_{i \in I} \subset K$  este o familie cel mult numărabilă de evenimente incompatibile două câte două, atunci și evenimentele  $(A \cap A_i)_{i \in I}$  sunt incompatibile două câte două și

$$P\left(\bigcap_{i \in I} A_i | B\right) = \frac{P\left(B \cap \left(\bigcup_{i \in I} A_i\right)\right)}{P(B)} = \frac{P\left(\bigcup_{i \in I} (B \cap A_i)\right)}{P(B)} =$$

$$= \frac{\sum_{i \in I} P(B \cap A_i)}{P(B)} = \sum_{i \in I} P(A_i|B).$$

2. Formula probabilității totale și formula lui Bayes rămân valabile dacă considerăm sisteme complete de evenimente numărabile. Fie  $(A_i)_{i \in I} \subset K$  o familie cel mult numărabilă de evenimente incompatibile două câte două cu  $\bigcup_{i \in I} A_i = E$  și  $P(A_i) \neq 0, i \in I$ , atunci

$$P(A) = \sum_{i \in I} P(A_i)P(A|A_i)$$

și

$$P(A_i|A) = \frac{P(A_i)P(A|A_i)}{\sum_{j \in I} P(A_j)P(A|A_j)} \quad i \in I.$$

**Definiția 1.8.6** *Se spune că evenimentele  $(A_n)_{n \in \mathbb{N}} \subset K$  sunt independente dacă orice număr finit de evenimente din acest șir este independent.*

Există și proprietăți noi ale funcției de probabilitate  $P$  cum ar fi următoarele:

**Propoziția 1.8.2** *Fie  $(A_n)_{n \in \mathbb{N}^*} \subset K$  și  $P$  o funcție de probabilitate. Atunci*

$$P\left(\bigcup_{n \in \mathbb{N}^*} A_n\right) \leq \sum_{n \in \mathbb{N}^*} P(A_n).$$

**Demonstrație.** Introducem un șir de evenimente din  $K$  în felul următor:

$$\begin{aligned} A'_1 &= A_1 \\ A'_2 &= A_2 \setminus A_1 \\ A'_{n+1} &= A_{n+1} \setminus \left(\bigcup_{j=1}^n A_j\right). \end{aligned}$$

Evenimentele  $(A'_n)_{n \in \mathbb{N}^*}$  prin modul în care au fost construite sunt incompatibile două câte două; în plus  $A'_n \subseteq A_n, n \in \mathbb{N}^*$ . Demonstrăm că

$$\bigcup_{n \in \mathbb{N}^*} A'_n = \bigcup_{n \in \mathbb{N}^*} A_n.$$

Evident  $\bigcup_{n \in \mathbb{N}^*} A'_n \subset \bigcup_{n \in \mathbb{N}^*} A_n$ .

Demonstrăm incluziunea contrară. Fie  $e \in \bigcup_{n \in \mathbb{N}^*} A_n$  și  $n_0$  cel mai mic număr natural  $n$  pentru care  $e \in A_{n_0}$ ; rezultă deci

$$e \in A'_{n_0} \subset \bigcup_{n \in \mathbb{N}^*} A'_n,$$

$$\bigcup_{n \in \mathbb{N}^*} A_n \subset \bigcup_{n \in \mathbb{N}^*} A'_n$$

adică ceea ce trebuia de demonstrat. De aici rezultă că

$$P\left(\bigcup_{n \in \mathbb{N}^*} A_n\right) = P\left(\bigcup_{n \in \mathbb{N}^*} A'_n\right) = \sum_{n \in \mathbb{N}^*} P(A'_n) \leq \sum_{n \in \mathbb{N}^*} P(A_n)$$

datorită proprietăților de aditivitate și monotonie a probabilității. ■

**Propoziția 1.8.3** Inegalitatea lui Boole. *Dacă  $(A_i)_{i \in I} \subset K$  este o mulțime cel mult numărabilă de evenimente, atunci*

$$P\left(\bigcap_{i \in I} A_i\right) \geq 1 - \sum_{i \in I} P(\bar{A}_i).$$

*Demonstrație.* Din relațiile lui De Morgan avem

$$\bigcap_{i \in I} A_i = \overline{\left(\bigcup_{i \in I} \bar{A}_i\right)}$$

deci

$$P\left(\bigcap_{i \in I} A_i\right) = P\left(\overline{\bigcup_{i \in I} \bar{A}_i}\right) = 1 - P\left(\bigcup_{i \in I} \bar{A}_i\right)$$

dar

$$P\left(\bigcup_{i \in I} \bar{A}_i\right) \leq \sum_{i \in I} P(\bar{A}_i)$$

și obținem inegalitatea dorită. ■

**Definiția 1.8.7** *Un șir de evenimente  $(A_n)_{n \in \mathbb{N}^*}$  este ascendent (descendent) dacă  $A_j \subset (\supset) A_i$  pentru  $j < i$ ,  $i, j \in \mathbb{N}^*$ ,  $i \neq j$ .*

**Propoziția 1.8.4** *Fie  $(A_n)_{n \in \mathbb{N}^*}$  un șir descendent de evenimente din  $K$ . Dacă  $A = \bigcap_{n \in \mathbb{N}^*} A_n$ , atunci*

$$\lim_{n \rightarrow \infty} P(A_n) = P\left(\bigcap_{n \in \mathbb{N}^*} A_n\right) = P(A).$$

*Demonstrație.* a) Considerăm cazul în care  $A = \emptyset$ . Trebuie să arătăm că

$$\lim_{n \rightarrow \infty} P(A_n) = 0.$$

Deoarece  $(A_n)_{n \in \mathbb{N}^*}$  este un șir descendent, putem scrie

$$A_n = (A_n \setminus A_{n+1}) \cup (A_{n+1} \setminus A_{n+2}) \cup \dots$$

și deci  $A_n$  apare ca o reuniune de evenimente incompatibile, căci

$$(A_{n+k} \setminus A_{n+k+1}) \cap (A_{n+s} \setminus A_{n+s+1}) = \emptyset$$

dacă  $k \neq s$  și obținem

$$P(A_n) = \sum_{i=n}^{\infty} P(A_i \setminus A_{i+1}) = \sum_{i=n}^{\infty} (P(A_i) - P(A_{i+1})),$$

iar seria

$$\sum_{i=1}^{\infty} P(A_i \setminus A_{i+1}) = P(A_1)$$

este convergentă, deci restul seriei converge la zero când  $n \rightarrow \infty$ , deci  $\lim_{n \rightarrow \infty} P(A_n) = 0$ .

b) Considerăm cazul  $A \neq \emptyset$ . Vom introduce evenimentele  $C_n = A_n \setminus A$ ,  $n \in \mathbb{N}^*$ , care reduc acest caz la cazul precedent. Șirul  $(C_n)_{n \in \mathbb{N}^*}$  este un șir descendent și deoarece  $\bigcap_{n=1}^{\infty} C_n = \emptyset$ , rezultă, conform cazului a) că

$$\lim_{n \rightarrow \infty} P(C_n) = 0$$

Dar

$$P(C_n) = P(A_n \setminus A) = P(A_n) - P(A)$$

și deci

$$\lim_{n \rightarrow \infty} P(A_n) = P(A).$$

■

**Propoziția 1.8.5** Fie  $(A_n)_{n \in \mathbb{N}^*}$  un șir ascendent de evenimente din  $K$ . Dacă  $A = \bigcup_{n \in \mathbb{N}^*} A_n$ , atunci

$$\lim_{n \rightarrow \infty} P(A_n) = P\left(\bigcup_{n \in \mathbb{N}^*} A_n\right) = P(A).$$

**Demonstrație.** Trecem la evenimentele complementare; șirul  $(\bar{A}_n)_{n \in \mathbb{N}^*}$  este descendent,  $\cup$  se transformă în  $\cap$  și se aplică propoziția 1.8.4. ■

**Definiția 1.8.8** Fie  $(\pi)$  o proprietate descrisă de o propoziție formulată într-un câmp borelian de probabilitate  $\{E, K, P\}$ . Dacă toate evenimentele elementare care nu implică proprietatea  $(\pi)$  formează un eveniment de probabilitate nulă atunci vom spune că  $(\pi)$  este adevărată aproape sigur.

**Observația 1.8.5** În câmpuri infinite de probabilitate pot exista evenimente diferite de evenimentul imposibil și care să aibă probabilitatea nulă.

**Exemplul 1.8.4** Fie un ceas și presupunem că acele sale se opresc la întâmplare. Să se determine probabilitatea ca minutarul să se oprească în dreptul uneia din cele 12 cifre ale cadranului este nulă.

Aceasta rezultă din observația că probabilitatea ca minutarul să se oprească într-un segment al circumferinței cadranului este proporțională cu lungimea acestuia. Ori cele 12 cifre ale cadranului alcătuiesc o mulțime formată din 12 puncte ale circumferinței, fiecare din acestea fiind asimilat cu un segment de o lungime nulă. Evident, nu este exclus ca minutarul să se oprească în dreptul unei cifre. Proprietatea "minutarul nu se oprește în dreptul unei cifre a cadranului" este o proprietate aproape sigură.

## 1.9 Probleme propuse

**Problema 1.1** Se joacă un joc. Partida este considerată câștigată de primul dintre cei doi jucători care câștigă trei jocuri. Dacă jocul se întrerupe la scorul de 2-1, cum trebuie împărțită miza?

Soluție. La prima vedere s-ar părea că miza trebuie împărțită în trei părți egale și câștigătorul ia două părți. Corect este ca miza să fie împărțită proporțional cu probabilitatea pe care o are fiecare jucător de a câștiga partida, dacă acesta ar fi continuat.

Să presupunem că se mai joacă două jocuri (indiferent de rezultatul primului joc). Notăm cu 1 dacă jucătorul a câștigat partida și cu 0 dacă a pierdut-o. Prin notația (1, 0) înțelegem că primul jucător a câștigat prima partida iar al doilea nu a pierdut a doua partidă. Sunt următoarele posibilități: (1, 1), (1, 0), (0, 1) și (0, 0), din care rezultă că primul jucător, care conduce cu 2-1, are trei șanse și al doilea una singură. Miza trebuie împărțită în patru părți egale și primul jucător ia trei părți, iar al doilea o parte.

**Problema 1.2** Un student are de răspuns la  $n$  întrebări, cărora trebuie să le asocieze răspunsul corect dintre  $n$  răspunsuri indicate. Stabiliți probabilitatea ca studentul să răspundă la:

- prima întrebare;
- primele două întrebări;
- cel puțin o întrebare.

Indicație. a) numărul cazurilor posibile:  $n!$ , numărul cazurilor favorabile  $(n - 1)!$ , probabilitatea căutată:  $1/n$ ;

b)  $1/(n - 2)!$ ;

c) dacă notăm cu  $A_i$  evenimentul că studentul răspunde corect la întrebarea  $i$ , evenimentul căutat este  $A_1 \cup A_2 \cup \dots \cup A_n$ . Folosind formula (1.9) obținem:  $1 - 1/2! + 1/3! - \dots + (-1)^{n-1}1/n!$ .

**Problema 1.3** Evenimentul  $A$  constă în apariția cel puțin o dată a feței 5 aruncând un zar de 4 ori, iar evenimentul  $B$  constă în apariția feței 5 cel puțin de două ori, aruncând de 18 ori câte două zaruri. Care din cele două evenimente este cel mai probabil?

Indicație. Se poate interpreta apariția feței 5 a unui zar ca o urnă cu două stări, una "fața cu 5" cu probabilitatea  $q = 5/6$ .  $P(\bar{A}) = (\frac{5}{6})^4$ ,  $P(A) = 1 - (\frac{5}{6})^4$ . Deoarece aruncările sunt independente, în loc să aruncăm de 18 ori câte două zaruri, putem arunca 36 de zaruri o singură dată.

$$P(\bar{B}) = \left(\frac{5}{6}\right)^{36} + 36\frac{1}{6}\left(\frac{5}{6}\right)^{35}.$$

Avem

$$\frac{P(\bar{B})}{P(\bar{A})} = \frac{\left(\frac{5}{6}\right)^{35} \frac{41}{6}}{\left(\frac{5}{6}\right)^4} < 7\left(\frac{5}{6}\right)^{31} < 1.$$

**Problema 1.4** Un calculator este format din  $n$  componente. Probabilitatea ca o componentă  $i$  să se nu defecteze în perioada de timp  $T$  este  $p_i$ ,  $i = \overline{1, n}$ . Componentele se

defectează independent unele de celelalte. Să se calculeze probabilitatea ca în perioada de timp  $T$  calculatorul să se defecteze. (Defectarea unei componente conduce la oprirea calculatorului.)

Soluție. Calculăm probabilitatea evenimentului contrar, adică în perioada de timp  $T$  calculatorul să funcționeze. Aceasta înseamnă că toate componentele să nu se defecteze, iar probabilitatea acestui eveniment este  $\prod_{i=1}^n p_i$ . Probabilitatea căutată va fi  $1 - \prod_{i=1}^n p_i$ .

**Problema 1.5** Un circuit electric are patru rele a căror funcționare este egal probabilă (funcționează și se pot defecta independent unul de celălalt), montate după Figura 1.1. Calculați probabilitatea ca între punctele A și B să nu circule curentul.

Soluție. Ntoăm cu  $A_i$  evenimentul "releul  $R_i$  este defect". Curentul nu circulă atunci când se realizează evenimentul

$$((A_1 \cup A_2) \cap A_4) \cup A_3 = (A_1 \cap A_4) \cup (A_2 \cap A_4) \cup A_3.$$

Cum orice releu poate fi în două poziții, închis sau deschis, rezultă că numărul cazurilor posibile este  $2^4 = 16$ .

Probabilitatea căutată este  $2 \cdot 4/16 - 8/16 - 3 \cdot 2/16 + 1/16$ .

**Problema 1.6** Trei mesaje sunt transmise pe un canal de comunicare, pe fiecare dintre ele putând fi transmis cu o anumită exactitate. Transmiterea unui mesaj poate conduce la unul din următoarele evenimente:

- a)  $A_1 = \{ \text{mesajul este transmis într-o formă corectă} \}$ .
- b)  $A_2 = \{ \text{mesajul este parțial eronat} \}$ .
- c)  $A_3 = \{ \text{mesajul este complet eronat} \}$ .

Probabilitățile evenimentelor  $A_1, A_2, A_3$  sunt date și anume egale cu  $p_1, p_2$  și  $p_3$ , ( $p_1 + p_2 + p_3 = 1$ ). Considerând că transmiterea corectă sau eronată a unui mesaj nu este influențată de modul de transmitere a celorlalte (independența evenimentelor), să se găsească probabilitățile următoarelor evenimente:

- i)  $A = \{ \text{toate mesajele sunt transmise corect} \}$ .
- ii)  $B = \{ \text{cel puțin un mesaj să fie complet eronat} \}$ .
- iii)  $C = \{ \text{cel puțin două mesaje sunt parțial sau complet eronate} \}$ .

Soluție. Notăm următoarele evenimente astfel:

$$A_{11} = \{ \text{primul mesaj transmis este corect} \},$$

$$A_{12} = \{ \text{al doilea mesaj transmis este corect} \},$$

$$A_{13} = \{ \text{al treilea mesaj transmis este corect} \},$$

$$A_{21} = \{ \text{primul mesaj transmis este parțial eronat} \},$$

$$A_{22} = \{ \text{al doilea mesaj transmis este parțial eronat} \},$$

$$A_{23} = \{ \text{al treilea mesaj transmis este parțial eronat} \},$$

$$A_{31} = \{ \text{primul mesaj transmis este complet eronat} \},$$

$A_{32} = \{ \text{al doilea mesaj transmis este complet eronat} \},$

$A_{33} = \{ \text{al treilea mesaj transmis este complet eronat} \}.$

Avem  $P(A_{11}) = P(A_{12}) = P(A_{13}) = p_1$ ,  $P(A_{21}) = P(A_{22}) = P(A_{23}) = p_2$ ,  $P(A_{31}) = P(A_{32}) = P(A_{33}) = p_3$ . Evenimentul  $A$  înseamnă că primul mesaj transmis este corect și al doilea mesaj transmis este corect și al treilea mesaj transmis este corect, adică  $A = A_{11} \cap A_{12} \cap A_{13}$  și deoarece evenimentele sunt independente (conform presupunerii făcute) avem  $P(A) = p_1^3$ . Complementarul evenimentului  $B$  este: toate mesajele sunt sau corecte sau parțial eronate, deci  $B = (A_{11} \cup A_{12}) \cap (A_{21} \cap A_{22}) \cup (A_{31} \cap A_{32})$ . Probabilitatea acestui eveniment este  $(p_1 + p_2)^3$ , iar  $P(B) = 1 - (p_1 + p_2)^3$ . Evenimentul  $C$  este compus din reuniunea evenimentelor: (primul mesaj este corect și al doilea mesaj este parțial sau complet eronat și al treilea mesaj este parțial sau complet eronat) sau (primul mesaj este parțial sau complet eronat și al doilea mesaj este corect și al treilea mesaj este parțial sau complet eronat) sau (primul mesaj este parțial sau complet eronat și al doilea este parțial sau complet eronat și al treilea mesaj este corect) sau (toate cele trei mesaje sunt parțial sau complet eronate), adică  $C = (A_{11} \cap ((A_{22} \cup A_{32}) \cap (A_{23} \cup A_{33}))) \cap ((A_{21} \cup A_{31}) \cap A_{12} \cap (A_{23} \cup A_{33})) \cap ((A_{21} \cup A_{31}) \cap (A_{22} \cup A_{32}) \cap A_{31}) \cup ((A_{21} \cup A_{31}) \cap (A_{22} \cup A_{32}) \cap (A_{23} \cup A_{33}))$ . Probabilitatea acestui eveniment este  $P(C) = 3(p_2 + p_3)^2 p_1 + (p_2 + p_3)^3$ .

**Problema 1.7** Un mesaj important este transmis simultan pe  $n$  canale de comunicație și repetat pe fiecare canal de  $k$  ori pentru a ușura recepționarea sa corectă. Probabilitatea ca în timpul transmisiei unui mesaj acesta să fie eronat este  $p$  și nu depinde de transmiterea altor mesaje. Fiecare canal de comunicație poate fi "blocat" cu zgomote cu probabilitatea  $q$ ; un canal "blocat" nu poate transmite nici-un fel de mesaje. Să se calculeze probabilitatea evenimentului

$A = \{ \text{un mesaj este transmis sub formă corectă măcar odată} \}.$

Soluție. Introducem evenimentul:

$B = \{ \text{un mesaj este transmis pe un canal de comunicație fără nici o eroare măcar odată} \}.$

Pentru ca să aibă loc evenimentul  $B$  mai întâi canalul nu trebuie să fie "blocat" cu zgomote și apoi măcar unul din cele  $k$  mesaje transmise nu trebuie să fie eronat (contrar evenimentului că toate cele  $k$  mesaje transmise sunt eronate). Obținem  $P(B) = (1 - q)(1 - p^k)$ . Probabilitatea evenimentului  $A$ , eveniment care înseamnă că evenimentul  $B$  s-a produs măcar odată pe un canal, este  $P(A) = 1 - (1 - P(B))^n = 1 - (1 - (1 - q)(1 - p^k))^n$ .

**Problema 1.8** Un mesaj format din cifrele 0 și 1 este transmis. Fiecare simbol poate fi transmis eronat cu probabilitatea  $p$  (este schimbat în contrarul său cu probabilitatea  $q$ ). Pentru siguranță, mesajul este transmis de două ori; informația este considerată corectă dacă ambele mesaje coincid. Să se calculeze probabilitatea ca mesajul să nu fie corect, în ciuda faptului că cele două mesaje transmise sunt identice.

Soluție. Evenimentul ca mesajul să nu fie corect este contrar evenimentului că ambele mesaje sunt corecte. Probabilitatea ca un mesaj transmis să fie corect este  $(1 - p)^n$ , probabilitatea ca ambele mesaje să fie corecte este  $(1 - p)^{2n}$ , iar probabilitatea căutată este  $1 - (1 - p)^{2n}$ .

**Problema 1.9** Fie opt canale de transmitere a informației care funcționează independent. Presupunem că un canal este activ cu probabilitatea  $1/3$ . Să se calculeze probabilitatea ca la un moment dat să fie mai mult de șase canale active.

Soluție. Pentru  $i = 1, \dots, 8$  fie  $A_i$  evenimentul: "canalul  $i$  este activ". Numărul canalelor active este egal cu numărul de realizări ale evenimentelor  $A_i, i = 1, \dots, 8$ , în opt experiențe Bernoulli cu  $p = 1/3$ . Atunci probabilitatea ca mai mult de șase canale să fie active este

$$P(k = 7) + P(k = 8) = C_8^7(1/3)^7(2/3) + C_8^8(1/3)^8 = 0,0024 + 0,00015 = 0,00259$$

**Problema 1.10** Un bloc de 100 de biți este transmis pe un canal de comunicație binar cu probabilitatea de eroare pe bit  $10^{-3}$ . Să se găsească probabilitatea ca blocul să conțină trei sau mai mult de trei erori.

$$R: 1.5 \cdot 10^{-4}.$$

**Problema 1.11** Un asamblor de calculatoare folosește circuite din trei surse: A, B și C. Ele pot fi defecte cu probabilitățile de respectiv 0,001, 0,005 și 0,01. Dacă se ia un circuit la întâmplare și se constată că este defect, care este probabilitatea ca el să provină de la sursa A sau B.

Soluție. Fie  $A_1$  evenimentul ca circuitul să provină de la sursa A,  $A_2$  de la sursa B și  $A_3$  să provină de la sursa C. Fie  $D$  evenimentul ca circuitul folosit să fie defect, iar  $D|A_i, i = 1, 2, 3$  evenimentul ca circuitul folosit să fie defect știind că el provine de la sursa A, B și respectiv C. Avem

$$P(D|A_1) = 0,001, P(D|A_2) = 0,005, P(D|A_3) = 0,01$$

Folosind formula lui Bayes (1.12) obținem

$$P(A_1|D) = 1/16, P(A_2|D) = 10/16.$$

Deoarece evenimentele  $A_1|D$  și  $A_2|D$  sunt incompatibile, rezultă

$$P(A_1 \cup A_2|D) = P(A_1|D) + P(A_2|D) = 11/16 = 0,6875.$$

**Problema 1.12** Multe sisteme de comunicație pot fi modelate în felul următor: mai întâi utilizatorul introduce 0 sau 1 în sistem și semnalul corespunzător este transmis; în al doilea rând ia o decizie asupra a ceea ce s-a introdus în sistem pe baza semnalului recepționat. Presupunem că utilizatorul transmite 0 cu probabilitatea  $1 - p$  și 1 cu probabilitatea  $p$  și că cel ce recepționează ia o decizie eronată cu probabilitatea  $\varepsilon$ . Pentru  $i = 0, 1$  fie  $A_i$  evenimentul că la intrare s-a introdus  $i$  și  $B_i$  evenimentul că decizia celui ce recepționează a fost  $i$ . Să se calculeze probabilitățile  $P(A_i \cap B_j)$  pentru  $i = 0, 1$  și  $j = 0, 1$ .

Presupunem că probabilitățile ca la intrare să se transmită 0 sau 1 sunt egale cu  $1/2$ . Să se calculeze probabilitatea evenimentului  $B_1$ . Dar probabilitatea de a se fi transmis 0 știind că s-a recepționat 1? Dar probabilitatea de a se fi transmis 1 știind că s-a recepționat 1?

Soluție.



Se obțin probabilitățile

$$\begin{aligned} P(A_0 \cap B_0) &= (1-p)(1-\varepsilon) \\ P(A_0 \cap B_1) &= (1-p)\varepsilon \\ P(A_1 \cap B_0) &= p\varepsilon \\ P(A_1 \cap B_1) &= p(1-\varepsilon). \end{aligned}$$

Evenimentele  $A_1$  și  $A_2$  formează un sistem complet de evenimente pentru spațiul de selecție  $E = \{0, 1\}$ . Pentru a calcula probabilitatea evenimentului  $B_1$  aplicăm formula probabilității totale:

$$P(B_1) = P(A_0)P(B_1|A_0) + P(A_1)P(B_1|A_1) = 1/2\varepsilon + 1/2(1-\varepsilon) = 1/2.$$

Aplicând formula lui Bayes obținem probabilitățile (pe care le-am mai numit posteori);

$$\begin{aligned} P(A_0|B_1) &= \frac{P(B_1|A_0)P(A_0)}{P(B_1)} = \frac{\varepsilon/2}{1/2} = \varepsilon \\ P(A_1|B_1) &= \frac{P(B_1|A_1)P(A_1)}{P(B_1)} = \frac{(1-\varepsilon)/2}{1/2} = 1-\varepsilon. \end{aligned}$$

Dacă  $\varepsilon$  este mai mic decât  $1/2$  atunci este mai probabil ca la intrare să avem 1 decât 0 dacă la ieșire s-a primit semnalul 1.

**Problema 1.13** Un sistem constă dintr-o unitate centrală și trei unități periferice. Sistemul funcționează la capacitate optimă dacă unitatea centrală și două unități periferice funcționează. Să se calculeze probabilitatea ca sistemul să funcționeze la capacitate optimă presupunând că defectarea unităților se face independent una de cealalta.

Soluție. Definim următoarele evenimente:  $A$ -unitatea centrală funcționează;  $B_i$ -unitatea periferică  $i$  funcționează, unde  $i = 1, 2, 3$ . Evenimentul  $F$ -două sau mai multe unități periferice funcționează înseamnă că toate trei unitățile periferice funcționează sau exact două unități periferice funcționează. Astfel:

$$F = (B_1 \cap B_2 \cap \bar{B}_3) \cup (B_1 \cap \bar{B}_2 \cap B_3) \cup (\bar{B}_1 \cap B_2 \cap B_3) \cup (B_1 \cap B_2 \cap B_3).$$

Observăm că evenimentele de mai sus din paranteze sunt independente între ele și deci

$$\begin{aligned} P(F) &= P(B_1)P(B_2)P(\bar{B}_3) + P(B_1)P(\bar{B}_2)P(B_3) + \\ &+ P(\bar{B}_1)P(B_2)P(B_3) + P(B_1)P(B_2)P(B_3) = \\ &= 3(1-a)^2a + (1-a)^3 \end{aligned}$$

unde s-a presupus că fiecare periferic se defectează cu probabilitatea egală cu  $a$ , astfel încât  $P(B_i) = 1-a$  și  $P(\bar{B}_i) = a$ . Evenimentul "sistemul funcționează la capacitate optimă" este  $A \cap F$ . Dacă presupunem că unitatea centrală se defectează cu probabilitatea  $p$ , atunci:

$$P(A \cap F) = P(A)P(F) = (1-p)P(F) = (1-p)3(1-a)^2a + (1-a)^3.$$

Fie  $a = 10\%$ , atunci toate cele trei periferice sunt funcționale  $(1-a)^3 = 72,9\%$  din timp iar două sunt funcționale și una defectă  $3(1-a)^2a = 24,3\%$  din timp. Astfel două sau

mai multe, periferice funcționează 97,2% din timp. Presupunem că unitatea centrală nu este foarte bună, și anume  $p = 20\%$ , atunci sistemul funcționează la capacitate optimă numai 77,8% din timp, aceasta datorită faptului că unitatea centrală se defectează.

Presupunem că s-a introdus în sistem o a doua unitate centrală identică cu prima, adică  $p = 20\%$  și sistemul funcționează la capacitate optimă dacă măcar una din cele două unități centrale funcționează. Să calculăm cât la sută din timp funcționează sistemul în acest caz. Definim evenimentele  $A_i$ -unitatea centrală  $i = 1, 2$  funcționează. Evenimentul "sistemul funcționează la capacitate optimă" este, în acest caz,  $(A_1 \cap F) \cup (A_2 \cap F)$ . Atunci

$$\begin{aligned} P[(A_1 \cap F) \cup (A_2 \cap F)] &= P(A_1 \cap F) + P(A_2 \cap F) - \\ &- P[(A_1 \cap F) \cap (A_2 \cap F)] = P(A_1)P(F) + P(A_2)P(F) - P(A_1 \cap A_2 \cap F) = \\ &= P(A_1)P(F) + P(A_2)P(F) - P(A_1)P(A_2)P(F) = \\ &= 2(1-p)3(1-a)^2a + (1-a)^3 - (1-p)^23(1-a)^2a + (1-a)^3 = 93,3\% \end{aligned}$$

Aceasta a condus la o creștere de 15,5% a timpului de funcționare față de cazul în care sistemul funcționa cu o singură unitate centrală.

**Problema 1.14** Un sistem de comunicație transmite informație bimară pe un canal care introduce la transmiterea unui bit erori aleatoare cu probabilitatea  $\varepsilon = 10^{-3}$ . Fiecare bit este transmis de trei ori și în funcție de semnalul majoritar recepționat se decide informația ca fiind cea transmisă. Să se calculeze probabilitatea ca decizia luată să fie incorectă.

Soluție. Cel ce recepționează va lua o decizie eronată dacă canalul introduce două sau mai multe erori. Dacă privim fiecare transmitere ca o experiență Bernoulli în care realizarea evenimentului corespunde introducerii unei erori, atunci probabilitatea de a se produce două sau mai multe erori în trei experiențe Bernoulli este

$$P[k \geq 2] = C_3^2(0,001)^2(0,999) + C_3^3(0,001)^3 \approx 3 \times 10^{-6}$$

**Problema 1.15** O informație telegrafică constă din semnale "liniute" și "puncte". În medie se deformează  $2/5$  din semnalele cu "puncte" și "liniute". Este cunoscut că semnalele "puncte" și "liniute" se întâlnesc în raportul  $5/3$ .

Să se determine probabilitatea ca:

- primind un semnal consacrat, acesta să fie "punct" și
- probabilitatea ca el să fie "liniută".

Soluție. Notăm cu  $A$  evenimentul de primire a semnalului "punct", iar prin  $B$  evenimentul de primire a semnalului "liniută". Se pot considera următoarele ipoteze:  $H_1$  este transmis semnalul "punct",  $H_2$  este transmis semnalul "liniută". Avem

$$\frac{P(H_1)}{P(H_2)} = \frac{5}{3}, \quad P(H_1) + P(H_2) = 1.$$

deci

$$P(H_1) = \frac{5}{8}, \quad P(H_2) = \frac{3}{8}$$

și

$$P(A|H_1) = \frac{3}{5}, P(A|H_2) = \frac{1}{3}, P(B|H_1) = \frac{2}{5}, P(B|H_2) = \frac{2}{3}.$$

Folosind formula probabilității totale obținem:

$$P(A) = \frac{5}{8} \frac{3}{5} + \frac{3}{8} \frac{1}{3} = \frac{1}{2}, P(B) = \frac{5}{8} \frac{2}{5} + \frac{3}{8} \frac{2}{3} = \frac{1}{2}.$$

Avem cele două probabilități:

$$a) P(H_1|A) = \frac{P(H_1)P(A|H_1)}{P(A)} = \frac{3}{4},$$

$$b) P(H_2|B) = \frac{P(H_2)P(B|H_2)}{P(B)} = \frac{1}{2}.$$



# Capitolul 2

## Variabile aleatoare discrete

### 2.1 Definiția și clasificarea variabilelor aleatoare

Una din noțiunile fundamentale ale teoriei probabilităților este cea de variabilă aleatoare. Teoria clasică a probabilităților operează, în principal, cu evenimente, iar teoria modernă preferă, unde este posibil, să studieze variabile aleatoare.

Fie  $\{E, K, P\}$  un câmp borelian de probabilitate care a fost definit în Capitolul 1.8.

**Definiția 2.1.1** *Funcția*

$$X : E \rightarrow \mathbb{R}$$

se numește variabilă aleatoare dacă

$$\forall x \in \mathbb{R} \quad \{e \in E \mid X(e) < x\} \in K. \quad (2.1)$$

Pentru simplitate, vom nota  $\{e \in E \mid X(e) < x\} = \{X < x\}$ .

**Observația 2.1.1** Nu este obligatoriu  $X(E) = \mathbb{R}$ , deci  $X(E) \subseteq \mathbb{R}$ ;  $X(E)$  reprezintă mulțimea valorilor variabilei aleatoare.

După proprietățile mulțimii valorilor variabilei aleatoare, adică după proprietățile mulțimii  $X(E)$ , clasificăm variabile aleatoare astfel:

- variabile aleatoare de tip discret, dacă  $X(E)$  este cel mult numărabilă; dacă  $X(E)$  este finită, variabila aleatoare se numește discretă simplă, iar dacă  $X(E)$  este infinită, dar numărabilă, variabila aleatoare se numește discretă cu o infinitate de valori.
- variabile aleatoare de tip continuu, dacă  $X(E)$  este o mulțime infinită de numere reale.

Exemple de variabile aleatoare discrete:

- variabile aleatoare ale cărei valori reprezintă numărul de apeluri zilnice primite la o centrală telefonică,
- variabila aleatoare ale cărei valori reprezintă numărul de ruperi de fire la o mașină de cusut,

- variabila aleatoare ale cărei valori reprezintă numărul de puncte apărute pe o față a zarului, la aruncarea unui zar.

Exemple de variabile aleatoare de tip continuu:

- timpul de funcționare a unui aparat, până la prima defectare,
- mărimile erorilor comise la efectuarea măsurărilor,
- viteza unei particule, care se modifică în funcție de ciocnirile cu alte particule.

În fiecare din aceste exemple, unui fenomen, supus unor circumstanțe aleatoare, i se asociază un număr real, deci se stabilește o corespondență între spațiul de selecție  $E$  convenabil ales și  $\mathbb{R}$ . În practică, de multe ori este dificil să găsim valorile acestor corespondențe, dar e posibil să determinăm "cât de des" sunt luate ele. Astfel, în ultimul exemplu, putem aprecia cu ce probabilitate viteza  $X$  a particulei este mai mică decât 0,1, deci putem calcula  $P(\{e \in E \mid X(e) < 0,1\})$ .

**Definiția 2.1.2** *Funcția*

$$F : \mathbb{R} \rightarrow [0, 1]$$

*definită prin*

$$F(x) = P(\{e \in E \mid X(e) < x\}) \quad (2.2)$$

*se numește* funcție de repartiție.

Determinarea pentru orice  $x \in \mathbb{R}$  a probabilității cu care  $X$  ia valori mai mici ca  $x$ , înseamnă definirea funcției de repartiție.

## 2.2 Variabile aleatoare discrete simple

Condiția (2.1) din Definiția 2.1.2 are loc întotdeauna în cazul variabilelor aleatoare discrete, alegând eventual un câmp borelian convenabil. În acest caz putem spune că:

**Definiția 2.2.1** *Fie*  $\{E, K, P\}$  *un câmp de probabilitate cu*  $E$  *cel mult numărabilă. Se numește* variabilă aleatoare *orice aplicație*  $X$  *definită pe mulțimea evenimentelor elementare cu valori în mulțimea numerelor reale*  $\mathbb{R}$ .

Ilustrăm trecerea de la eveniment la variabilă aleatoare.

**Exemplul 2.2.1** Considerăm o experiență și un eveniment  $A$  legat de aceasta. În loc de evenimentul  $A$  putem considera funcția  $\chi_A$  care ia valoarea 1 dacă s-a realizat  $A$  și 0 dacă s-a realizat  $\bar{A}$ , adică dacă  $A \subset E, A \in K$ :

$$\chi_A : E \rightarrow \{0, 1\}$$

$$\chi_A(e) = \begin{cases} 1, & \text{dacă } e \in A \\ 0, & \text{dacă } e \notin A. \end{cases}$$

Funcția  $\chi_A$  se numește indicatorul evenimentului  $A$  (variabila aleatoare a evenimentului  $A$ ).

Această idee poate fi extinsă în sensul că putem considera o experiență și legat de aceasta un sistem complet de evenimente  $(A_i)_{1 \leq i \leq n}$ . Definim funcția  $X$  pe acest sistem complet de evenimente convenind să-i atribuim valoarea  $n - j$  în cazul în care s-a realizat evenimentul  $A_j, j = \overline{1, n}$ . Astfel, variabila aleatoare  $X$  s-a definit prin relația:

$$X(e) = \begin{cases} n - j, & \text{dacă } e \in A_j \\ 0, & \text{în rest} \end{cases}$$

pentru  $j = \overline{1, n}$ .

Fie tabelul

$$X : \begin{pmatrix} x_1 & x_2 & \dots & x_n \\ p_1 & p_2 & \dots & p_n \end{pmatrix} \quad (2.3)$$

cu  $p_i \geq 0, i = \overline{1, n}, \sum_{i=1}^n p_i = 1$ . Numerele  $x_i$  se numesc valorile variabilei aleatoare, iar  $p_i$  probabilitățile cu care variabila aleatoare ia aceste valori. Tabelul 2.3 se numește tabloul de repartiție al variabilei aleatoare  $X$ .

Facem convenția ca în tabloul de repartiție să se treacă valorile variabilei aleatoare distincte, iar valorile luate cu probabilitatea 0 să nu fie trecute.

**Observația 2.2.1** Fie  $x_k$  o valoare a variabilei aleatoare  $X$ . Valorii  $x_k$  îi corespunde, în general, o mulțime de evenimente elementare. Rezolvând ecuația  $x_k = X(e)$  în raport cu  $e$  obținem  $e = X^{-1}(x_k)$ , în general, o funcție multivocă, deci la un  $x_k$  pot corespunde mai multe valori ale lui  $e$ . Reuniunea acestora formează un eveniment  $A_k$  al câmpului ( $k \leq n$ ). Deoarece valorile  $x_k$  sunt diferite, evenimentele  $A_k$  sunt incompatibile două câte două și formează un sistem complet de evenimente. Observăm că

$$p_k = P(A_k) = P(\{e \in E \mid X(e) = x_k\})$$

și

$$\sum_{k=1}^n p_k = \sum_{k=1}^n P(A_k) = P\left(\bigcup_{k=1}^n A_k\right) = P(E) = 1.$$

Deci dată o variabilă aleatoare, putem să-i atașăm un sistem complet de evenimente. Reciproca afirmației este tocmai Exemplit 2.2.2.

**Exemplit 2.2.2** Considerăm experiența care constă în aruncarea unui zar omogen. Fie variabila aleatoare  $X$  care ia ca valori numărul de puncte apărute pe fața zarului. Să se scrie tabloul de repartiție al acestei variabile aleatoare.

Mulțimea evenimentelor elementare este  $\{1, 2, 3, 4, 5, 6\}$  și ea coincide, în acest caz, cu  $E$

$$X : \begin{pmatrix} 1 & 2 & 3 & 4 & 5 & 6 \\ \frac{1}{6} & \frac{1}{6} & \frac{1}{6} & \frac{1}{6} & \frac{1}{6} & \frac{1}{6} \end{pmatrix}.$$

Dacă considerăm evenimentele  $A$  și  $B$  legate de aceeași experiență și anume  $A$  evenimentul care constă în obținerea unui număr par de puncte, iar  $B$  evenimentul care constă în

obținerea un număr impar de puncte și definim variabila aleatoare  $Y$  care ia valoarea 0 dacă am obținut un număr par de puncte și 1 dacă am obținut un număr impar de puncte, atunci  $A$  și  $B$  formează un sistem complet de evenimente și putem defini variabila aleatoare  $Y$  astfel:

$$Y : \begin{pmatrix} 0 & 1 \\ \frac{1}{2} & \frac{1}{2} \end{pmatrix}.$$

**Exemplul 2.2.3** Considerăm o experiență care constă în extragerea a trei bile, câte una din fiecare din urnele  $U_1, U_2, U_3$  ce conțin respectiv 2 bile albe și 3 negre, 3 bile albe și 5 negre, 8 bile albe și 2 negre. Definim variabila aleatoare  $X$  care ia ca valori numărul de bile albe obținute la o extragere. Se cere tabloul de repartiție a lui  $X$ .

Notăm cu  $A_i$  și  $\bar{A}_i$  evenimentul de a extrage o bilă albă, respectiv neagră din urna  $U_i, i = \overline{1, 3}$ . Variabila aleatoare  $X$  poate lua valorile 0, 1, 2, 3 după cum s-au extras respectiv 0, 1, 2, 3 bile albe. Observăm că evenimentele  $A_i$  sunt independente și incompatibile două câte două. Atunci putem calcula

$$P(\{X = 0\}) = P\left(\bigcap_{i=1}^3 \bar{A}_i\right) = \prod_{i=1}^3 P(\bar{A}_i) = 0,075,$$

$$\begin{aligned} P(\{X = 1\}) &= P((A_1 \cap \bar{A}_2 \cap \bar{A}_3) \cup (\bar{A}_1 \cap A_2 \cap \bar{A}_3) \cup (\bar{A}_1 \cap \bar{A}_2 \cap A_3)) = \\ &= P(A_1)P(\bar{A}_2)P(\bar{A}_3) + P(\bar{A}_1)P(A_2)P(\bar{A}_3) + P(\bar{A}_1)P(\bar{A}_2)P(A_3) = \frac{79}{200} = 0,395, \end{aligned}$$

$$\begin{aligned} P(\{X = 2\}) &= P((A_1 \cap A_2 \cap \bar{A}_3) \cup (A_1 \cap \bar{A}_2 \cap A_3) \cup (\bar{A}_1 \cap A_2 \cap A_3)) = \\ &= P(A_1)P(A_2)P(\bar{A}_3) + P(A_1)P(\bar{A}_2)P(A_3) + P(\bar{A}_1)P(A_2)P(A_3) = \frac{41}{100} = 0,41, \end{aligned}$$

$$P(\{X = 3\}) = P(A_1 \cap A_2 \cap A_3) = P(A_1)P(A_2)P(A_3) = \frac{3}{25} = 0,12,$$

Tabloul de repartiție este

$$X : \begin{pmatrix} 0 & 1 & 2 & 3 \\ 0,075 & 0,395 & 0,41 & 0,12 \end{pmatrix}.$$

De cele mai multe ori în calcule este suficient să cunoaștem valorile pe care le ia o variabilă aleatoare și probabilitățile respective. Dar, în general, cunoașterea acestor date nu este suficientă pentru determinarea completă a variabilei aleatoare, așa cum se va vedea în exemplul următor.

**Exemplul 2.2.4** Considerăm experiența care constă în aruncarea unui zar. Legat de aceasta ne imaginăm un joc: celui care aruncă zarul i se acordă 1 punct dacă apare una din fețele cu 1 sau 2 puncte, 2 puncte dacă apare una din fețele cu 3 sau 4 puncte, 3 puncte dacă apare una din fețele cu 5 sau 6 puncte. Dacă notăm cu  $X$  variabila aleatoare



care ia ca valori numărul de puncte obținute de jucător la o aruncare a zarului, obținem o variabilă aleatoare având repartiția:

$$X : \begin{pmatrix} 1 & 2 & 3 \\ \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \end{pmatrix}.$$

Se consideră alt joc în care se acordă 1 punct dacă apare una din fețele cu 1 sau 6 puncte, 2 puncte dacă apare una din fețele cu 2 sau 5 puncte, 3 puncte dacă apare una din fețele cu 3 sau 4 puncte. Obținem analog o variabilă aleatoare  $Y$  cu repartiția

$$Y : \begin{pmatrix} 1 & 2 & 3 \\ \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \end{pmatrix}.$$

Variabilele aleatoare discrete simple  $X$  și  $Y$  definite în acest exemplu nu sunt egale, dar au același tablou de repartiție. Într-adevăr,  $X(6) = 3$  și  $Y(6) = 1$ . Experiența care constă în aruncarea zarului generează un câmp de probabilitate. Pe mulțimea evenimentelor elementare ale lui  $E$ ,  $X$  și  $Y$  sunt definite astfel:

$$X(1) = 1, X(2) = 1, X(3) = 2, X(4) = 2, X(5) = 3, X(6) = 3;$$

$$Y(1) = 1, Y(2) = 2, Y(3) = 3, Y(4) = 3, Y(5) = 2, Y(6) = 1.$$

Să determinăm sistemul complet de evenimente generat de fiecare din cele două variabile aleatoare discrete simple. Variabila aleatoare discretă simplă  $X$  determină

$$A_1 = \{1, 2\}, A_2 = \{3, 4\}, A_3 = \{5, 6\},$$

iar variabila aleatoare discretă simplă  $Y$  determină

$$B_1 = \{1, 6\}, B_2 = \{2, 5\}, B_3 = \{3, 4\}.$$

Rezultă că cele două sisteme complete de evenimente sunt diferite și deci numai aparent variabilele aleatoare discrete simple coincid.

Orice variabilă aleatoare simplă dată prin tabloul său de repartiție se poate reprezenta grafic prin poligonul său de repartiție: pe axa absciselor se trec valorile variabilei aleatoare, iar pe axa ordonatelor probabilitățile.

Pentru o variabilă aleatoare discretă simplă se poate introduce funcția de repartiție care este o funcție scară dată de relația:

$$F(x) = \begin{cases} 0, & \text{dacă } x \leq x_1, \\ p_1, & \text{dacă } x_1 < x \leq x_2, \\ p_1 + p_2, & \text{dacă } x_2 < x \leq x_3, \\ \dots & \\ p_1 + \dots + p_{n-1}, & \text{dacă } x_{n-1} < x \leq x_n, \\ 1, & \text{dacă } x_n < x. \end{cases}$$

În această definiție am presupus, pentru simplitate,  $x_1 < x_2 < \dots < x_n$ . Graficul acestei funcții este prezentat în Figura 2.1.

Vom insista mai mult asupra proprietăților funcției de repartiție în Capitolul 3. Să studiem  $F$  în unul din punctele de discontinuitate, fie  $x = x_2$ . Pentru  $\delta \in \mathbb{R}_+$  oricât de mic, avem

$$F(x_2 + \delta) = P(\{X < x_2 + \delta\}) = p_1 + p_2$$

astfel încât  $\lim_{x \searrow x_2} F(x) = p_1 + p_2$ . Mai mult

$$F(x_2) = P(\{X < x_2\}) = p_1$$

și

$$F(x_2 - \delta) = P(\{X < x_2 - \delta\}) = p_1.$$

Rezultă că funcția de repartiție este continuă la stânga. Funcția de repartiție poate fi scrisă restrâns cu ajutorul funcției unitate (*treapta unitate*)

$$u(x) = \begin{cases} 0, & \text{dacă } x \leq 0, \\ 1, & \text{dacă } x > 0, \end{cases}.$$

Funcția generalizată delta  $\delta(t)$  (*distribuția Dirac*) este definită cu ajutorul funcției unitate astfel:

$$u(x) = \int_{-\infty}^x \delta(t) dt$$

și deci

$$F(x) = p_1 u(x) + p_2 u(x - x_1) + \dots + p_n u(x - x_n) = \sum_{k=1}^n p_k u(x - x_k),$$

unde  $p_k = P(\{X < x_k\})$ . Putem introduce și în cazul discret (pentru cazul continuu se poate consulta Capitolul 3) funcția densitate de probabilitate ținând seama de legătura dintre funcția unitate și distribuția Dirac. Astfel, ținând seama de faptul că (vezi Capitolul 3.2, Formula (3.9)):

$$F(x) = \int_{-\infty}^x f(t) dt$$

obținem densitatea de probabilitate pentru variabile aleatoare discrete

$$f(x) = \sum_{k=1}^n p_k \delta(x - x_k).$$

Această densitate de probabilitate este o funcție generalizată (o distribuție).

### Operații cu variabile aleatoare discrete simple.

Deoarece variabila aleatoare discretă simplă este o funcție definită pe mulțimea evenimentelor elementare cu valori reale, putem vorbi de suma și produsul a două variabile aleatoare discrete simple ca și la funcții. Astfel, dacă  $e$  este un eveniment elementar și  $X$  și  $Y$  sunt definite pe aceeași mulțime de evenimente elementare, avem

$$(X + Y)(e) = X(e) + Y(e),$$

$$(XY)(e) = X(e)Y(e).$$

Dacă  $Y(e) \neq 0$  oricare ar fi evenimentul  $e$ , câtul  $\frac{X}{Y}$  este o nouă variabilă aleatoare definită prin relația

$$\left(\frac{X}{Y}\right)(e) = \frac{X(e)}{Y(e)}.$$

Produsul unei variabile aleatoare  $X$  cu o constantă reală  $c$  este o nouă variabilă aleatoare  $cX$  definită prin relația

$$(cX)(e) = cX(e).$$

Acest produs poate fi interpretat și ca produsul lui  $X$  cu variabila aleatoare constantă identic egală cu  $c$  ( $Y(e) = c, \forall e \in E$ ). Dacă  $X(e) \geq 0, \forall e \in E$ , iar  $\alpha \in \mathbb{R}$  fixat, definim  $X^\alpha$  ca o nouă variabilă aleatoare definită prin

$$(X^\alpha)(e) = (X(e))^\alpha.$$

În cazul în care  $\alpha \in \mathbb{N}$  se poate renunța la condiția  $X(e) \geq 0, \forall e \in E$ , variabila aleatoare poate fi interpretată ca produsul lui  $X$  cu el însuși. Fie variabilele aleatoare  $X$  și  $Y$  având tabelele de repartiție

$$X : \begin{pmatrix} x_1 & x_2 & \dots & x_m \\ p_1 & p_2 & \dots & p_m \end{pmatrix},$$

$$Y : \begin{pmatrix} y_1 & y_2 & \dots & y_n \\ q_1 & q_2 & \dots & q_n \end{pmatrix}.$$

Fie  $A_1, A_2, \dots, A_m$  respectiv  $B_1, B_2, \dots, B_n$  sistemul complet de evenimente generat de variabila aleatoare  $X$ , respectiv  $Y$ . Avem, evident

$$P(A_i) = p_i, i = \overline{1, m},$$

$$P(B_j) = q_j, j = \overline{1, n}.$$

Variabila aleatoare  $X + Y$  ia valoarea  $x_i + y_j$  pe submulțimea  $A_i \cap B_j$ , dacă această intersecție este nevidă. Dacă  $A_i \cap B_j = \emptyset$ , variabila aleatoare  $X + Y$  ia valoarea  $x_i + y_j$  cu probabilitatea zero și deci aceasta nu apare în tabel. Dacă notăm  $P(A_i \cap B_j) = p_{ij}, i = \overline{1, m}, j = \overline{1, n}$  atunci tabelul de repartiție al variabilei aleatoare  $X + Y$  va fi

$$X + Y : \begin{pmatrix} x_1 + y_1 & x_1 + y_2 & \dots & x_1 + y_n & \dots & x_m + y_n \\ p_{11} & p_{12} & \dots & p_{1n} & \dots & p_{mn} \end{pmatrix}.$$

Pentru produs vom avea

$$XY : \begin{pmatrix} x_1 y_1 & x_1 y_2 & \dots & x_1 y_n & \dots & x_m y_n \\ p_{11} & p_{12} & \dots & p_{1n} & \dots & p_{mn} \end{pmatrix}.$$

În ambele cazuri tabelul de repartiție are cel mult  $mn$  coloane.

**Observația 2.2.2** În cazul particular  $Y = a = \text{const.}$ , deoarece

$$p_{ij} = P(\{X = x_i, Y = a\}) = P(\{(X = x_i) \cap E\}) = P(\{X = x_i\}) = p_i$$

avem

$$a + X : \begin{pmatrix} a + x_1 & a + x_2 & \dots & a + x_m \\ p_1 & p_2 & \dots & p_m \end{pmatrix},$$

și la fel

$$aX : \begin{pmatrix} ax_1 & ax_2 & \dots & ax_m \\ p_1 & p_2 & \dots & p_m \end{pmatrix}.$$

**Observația 2.2.3** Definiția sumei de variabile aleatoare discrete simple se poate extinde la un număr finit de variabile aleatoare simple. De exemplu, dacă

$$X : \begin{pmatrix} x_i \\ p_i \end{pmatrix}, \quad i = \overline{1, m}, \quad Y : \begin{pmatrix} y_j \\ q_j \end{pmatrix}, \quad j = \overline{1, n}, \quad Z : \begin{pmatrix} z_k \\ r_k \end{pmatrix}, \quad k = \overline{1, l},$$

atunci

$$X + Y + Z : \begin{pmatrix} x_i + y_j + z_k \\ p_{ijk} \end{pmatrix}, \quad i = \overline{1, m}, \quad j = \overline{1, n}, \quad k = \overline{1, l}.$$

**Exemplul 2.2.5** Probabilitatea extragerii unei bile albe dintr-o urnă este  $p$ . Din această urnă se fac două extrageri, punându-se bila înapoi în urnă după extragere. Se consideră variabilele aleatoare  $X_1$  și  $X_2$ , prima reprezentând numărul de bile albe obținute la prima extragere și a doua numărul de bile albe de la a doua extragere. Să se scrie tabloul de repartiție al variabilelor aleatoare discrete simple  $X_1$ ,  $X_2$ ,  $X_1 + X_2$ ,  $X_1 X_2$ .

Dacă

$$X_1 : \begin{pmatrix} 0 & 1 \\ q & p \end{pmatrix}, \quad X_2 : \begin{pmatrix} 0 & 1 \\ q & p \end{pmatrix}, \quad q = 1 - p,$$

atunci

$$X_1 + X_2 : \begin{pmatrix} 0 & 1 & 2 \\ q^2 & 2pq & p^2 \end{pmatrix},$$

deoarece

$$P(\{X_1 + X_2 = 0\}) = P(\{X_1 = 0, X_2 = 0\}) = P(\{X_1 = 0\})P(\{X_2 = 0\}) = q^2,$$

$$P(\{X_1 + X_2 = 1\}) = P(\{X_1 = 1, X_2 = 0\} \cup \{X_1 = 0, X_2 = 1\}) = 2pq,$$

$$P(\{X_1 + X_2 = 2\}) = P(\{X_1 = 1, X_2 = 1\}) = P(\{X_1 = 1\})P(\{X_2 = 1\}) = p^2,$$

$$P(\{X_1 + X_2 = 0\}) = P(\{X_1 = 0, X_2 = 0\}) = q^2.$$

La fel,

$$X_1 X_2 : \begin{pmatrix} 0 & 1 \\ 2pq + q^2 & p^2 \end{pmatrix},$$

deoarece

$$P(\{X_1 X_2 = 0\}) = P(\{X_1 = 0, X_2 = 0\} \cup \{X_1 = 1, X_2 = 0\} \cup \{X_1 = 0, X_2 = 1\}) \\ = 2pq + q^2,$$

$$P(\{X_1 X_2 = 1\}) = P(\{X_1 = 1, X_2 = 1\}) = p^2.$$

**Propoziția 2.2.1** *Fiind date variabilele aleatoare*

$$X : \begin{pmatrix} x_i \\ p_i \end{pmatrix}, i = \overline{1, m}; \quad Y : \begin{pmatrix} y_j \\ q_j \end{pmatrix}, j = \overline{1, n},$$

iar  $p_{ij}$  probabilitățile definite de suma și produsul celor două variabile aleatoare. Au loc relațiile:

$$p_i = \sum_{j=1}^n p_{ij}, \quad q_j = \sum_{i=1}^m p_{ij}.$$

**Demonstrație.** Efectuând experiența căreia îi sunt asociate variabilele aleatoare,  $Y$  ia în mod sigur una din valorile  $y_1, y_2, \dots, y_n$ . Dacă  $X$  ia valoarea  $x_i$ , rezultă că evenimentul  $\{X = x_i\}$  se realizează împreună cu unul din evenimentele  $\{Y = y_1\}, \dots, \{Y = y_n\}$ . Deci

$$\begin{aligned} \{X = x_i\} &= \{X = x_i\} \cap (\{Y = y_1\} \cup \{Y = y_2\} \cup \dots \cup \{Y = y_n\}) = \\ &= (\{X = x_i\} \cap \{Y = y_1\}) \cup (\{X = x_i\} \cap \{Y = y_2\}) \cup \dots \cup (\{X = x_i\} \cap \{Y = y_n\}). \end{aligned}$$

De aici rezultă că

$$p_i = P(\{X = x_i\}) = \sum_{j=1}^n P(\{X = x_i, Y = y_j\}) = \sum_{j=1}^n p_{ij}.$$

La fel se demonstrează cea de-a doua relație. ■

**Observația 2.2.4** Dacă considerăm și variabila aleatoare discretă simplă

$$Z : \begin{pmatrix} z_k \\ r_k \end{pmatrix}, \quad k = \overline{1, l},$$

atunci pentru probabilitățile sumei (produsului) celor trei variabile aleatoare discrete simple au loc relațiile

$$\sum_{k=1}^l p_{ijk} = p_{ij}; \quad \sum_{i=1}^m p_{ijk} = p_{\cdot jk}; \quad \sum_{j=1}^n p_{ijk} = p_{i \cdot k};$$

**Independența variabilelor aleatoare discrete simple.**

**Definiția 2.2.2** *Două variabile aleatoare se numesc independente dacă probabilitatea ca una din variabile să ia o valoare nu depinde de valoarea luată de cea de a doua variabilă aleatoare.*

**Observația 2.2.5** Dacă  $X$  și  $Y$  sunt astfel de variabile aleatoare atunci două evenimente de forma  $\{X = x_i\}$  și  $\{Y = y_j\}$ ,  $i = \overline{1, m}$ ,  $j = \overline{1, n}$ , sunt independente.

În general, putem da definiția:

**Definiția 2.2.3** Variabilele aleatoare discrete simple  $X, Y, Z, \dots$  sunt independente dacă evenimentele  $\{X = x_i\}, \{Y = y_j\}, \{Z = z_k\}, \dots$   $i = \overline{1, m}, j = \overline{1, n}, k = \overline{1, l}$  sunt independente în totalitatea lor.

**Observația 2.2.6** Dacă variabilele aleatoare

$$X : \begin{pmatrix} x_i \\ p_i \end{pmatrix}, \quad i = \overline{1, m}, \quad Y : \begin{pmatrix} y_j \\ q_j \end{pmatrix}, \quad j = \overline{1, n},$$

sunt independente, atunci

$$p_{ij} = P(\{X = x_i, Y = y_j\}) = P(\{X = x_i\})P(\{Y = y_j\}) = p_i q_j.$$

La fel pentru trei variabile aleatoare discrete simple. În cazul acesta

$$X + Y : \begin{pmatrix} x_i + y_j \\ p_i q_j \end{pmatrix}, \quad i = \overline{1, m}, j = \overline{1, n};$$

$$XY : \begin{pmatrix} x_i y_j \\ p_i q_j \end{pmatrix}, \quad i = \overline{1, m}, j = \overline{1, n}.$$

**Exemplul 2.2.6** Suma a două variabile aleatoare discrete simple independente  $X, Y, Z = X + Y$ , poate fi obținută astfel:

$$\begin{aligned} P(\{Z = k\}) &= P(\{X + Y = k\}) = \\ &= \sum_i P(\{X = i, Y = k - i\}) = \sum_i P(\{X = i\})P(\{Y = k - i\}), \end{aligned}$$

sumarea referindu-se la toate valorile întregi ale lui  $X$ , mai mici decât  $k$ . Dacă notăm cu  $p(i) = P(\{X = i\}), q(j) = P(\{Y = j\}), r(k) = P(\{Z = k\})$ , obținem

$$r(k) = \sum_{i=0}^k p(i)q(k-i) = \sum_{j=0}^k p(k-j)q(j),$$

acestea reprezentând produsul de convoluție a lui  $p$  și  $q$ .

**Propoziția 2.2.2** Variabilele aleatoare simple  $X$  și  $Y$  sunt independente dacă și numai dacă evenimentele  $\{x' < X < x\}$  și  $\{y' < Y < y\}$  sunt independente, oricare ar fi  $x, x', y, y' \in \overline{\mathbb{R}}$ .

**Demonstrație.** Presupunem că  $X$  și  $Y$  sunt independente. Deoarece

$$\{x' < X < x, y' < Y < y\} = \bigcup_{x' < x_i < x, y' < y_j < y} \{X = x_i, Y = y_j\}$$

rezultă, datorită independenței,

$$P(\{x' < X < x, y' < y_j < y\}) = P\left(\bigcup_{x' < x_i < x, y' < y_j < y} \{X = x_i, Y = y_j\}\right) =$$

$$\begin{aligned}
&= \sum_{x' < x_i < x; y' < y_j < y} P(\{X = x_i, Y = y_j\}) = \sum_{x' < x_i < x} P(\{X = x_i\}) \sum_{y' < y_j < y} P(\{Y = y_j\}) = \\
&= P\left(\bigcup_{x' < x_i < x} \{X = x_i\}\right) P\left(\bigcup_{y' < y_j < y} \{Y = y_j\}\right) = P(\{x' < X < x\}) P(\{y' < Y < y\}).
\end{aligned}$$

Reciproc, presupunem că evenimentele  $\{x' < X < x\}$  și  $\{y' < Y < y\}$  sunt independente, oricare ar fi  $x, x', y, y' \in \overline{\mathbb{R}}$ . Atunci

$$\{X = x_i, Y = y_j\} = \{x_{i-1} < X < x_{i+1}, y_{j-1} < Y < y_{j+1}\}, \quad i = \overline{1, m}, \quad j = \overline{1, n},$$

unde  $x_0 = y_0 = -\infty, x_n = y_n = \infty$ . Rezultă că

$$\begin{aligned}
P(\{X = x_i, Y = y_j\}) &= P(\{x_{i-1} < X < x_{i+1}, y_{j-1} < Y < y_{j+1}\}) = \\
&= P(\{x_{i-1} < X < x_{i+1}\}) P(\{y_{j-1} < Y < y_{j+1}\}) = P(\{X = x_i\}) P(\{Y = y_j\}).
\end{aligned}$$

■

### Caracteristici numerice pentru variabile aleatoare discrete simple.

**Definiția 2.2.4** Fie variabila aleatoare discretă simplă

$$X : \begin{pmatrix} x_1 & x_2 & \dots & x_m \\ p_1 & p_2 & \dots & p_m \end{pmatrix}, \quad p_i \geq 0, \quad i = \overline{1, m}, \quad \sum_{i=1}^m p_i = 1. \quad (2.4)$$

Vom numi media variabilei aleatoare discrete simple  $X$  numărul

$$M[X] = x_1 p_1 + x_2 p_2 + \dots + x_m p_m = \sum_{i=1}^m x_i p_i.$$

Denumirea de medie este îndreptățită dacă ținem seama de sensul ei practic. Presupunem că am repetat de  $N$  ori o experiență care ne-a condus la variabila aleatoare  $X$ . Dacă valoarea  $x_1$  este luată de  $n_1$  ori, valoarea  $x_2$  de  $n_2$  ori, ..., valoarea  $x_m$  de  $n_m$  ori, unde  $n_1 + n_2 + \dots + n_m = N$ , atunci suma valorilor luate de variabila aleatoare  $X$  este  $n_1 x_1 + n_2 x_2 + \dots + n_m x_m$ , iar media aritmetică a valorilor luate de  $X$  va fi

$$\frac{n_1 x_1 + n_2 x_2 + \dots + n_m x_m}{N} = \frac{n_1}{N} x_1 + \frac{n_2}{N} x_2 + \dots + \frac{n_m}{N} x_m.$$

Dar  $\frac{n_1}{N}$  reprezintă raportul dintre numărul cazurilor în care s-a luat valoarea  $x_1$  și numărul total de experimentări, adică  $p_1$ . La fel  $\frac{n_2}{N} = p_2, \dots, \frac{n_m}{N} = p_m$ .

Media aritmetică a valorilor luate de  $X$  poate fi aproximată cu  $p_1 x_1 + p_2 x_2 + \dots + p_m x_m$ , adică media lui  $X$ . Media lui  $X$  ne arată la ce valoare putem să ne așteptăm pentru media aritmetică a unui mare număr de valori ale lui  $X$ , obținute în urma repetării experienței date.

**Exemplul 2.2.7** Variabilele aleatoare discrete simple din Exemplul 2.2.5,  $X_1$  și  $X_2$ , având repartițiile:

$$X_1, X_2 : \begin{pmatrix} 0 & 1 \\ q & p \end{pmatrix},$$

au valoarea medie

$$M[X_i] = 1p + 0q = p, \quad i = 1, 2,$$

iar

$$X_1 + X_2 : \begin{pmatrix} 0 & 1 & 2 \\ q^2 & 2pq & p^2 \end{pmatrix},$$

are media

$$M[X_1 + X_2] = 2pq + 2p^2 = 2p.$$

**Definiția 2.2.5** Se numește moment inițial de ordin  $k$ ,  $k \in \mathbb{N}$ , al variabilei aleatoare  $X$  media lui  $X^k$ . Notăm

$$v_k = M_k[X] = M[X^k].$$

**Observația 2.2.7** Momentul inițial de ordin 1 al variabilei aleatoare  $X$  este chiar media variabilei aleatoare.

### Proprietăți ale mediei.

1. Valoarea medie a unei constante este egală cu constanta,

$$X : \begin{pmatrix} c \\ 1 \end{pmatrix}, \quad M[X] = c.$$

2. Dacă  $X$  este o variabilă aleatoare simplă și  $a \in \mathbb{R}$  o constantă, atunci au loc relațiile:

$$M[a + X] = a + M[X], \quad M[aX] = aM[X],$$

Într-adevăr, deoarece

$$a + X : \begin{pmatrix} a + x_1 & a + x_2 & \dots & a + x_m \\ p_1 & p_2 & \dots & p_m \end{pmatrix},$$

$$M[a + X] = \sum_{i=1}^m (a + x_i)p_i = a \sum_{i=1}^m p_i + \sum_{i=1}^m x_i p_i = a + M[X];$$

$$aX : \begin{pmatrix} ax_1 & ax_2 & \dots & ax_m \\ p_1 & p_2 & \dots & p_m \end{pmatrix},$$

$$M[aX] = \sum_{i=1}^m (ax_i)p_i = a \sum_{i=1}^m x_i p_i = aM[X].$$



3. Valoarea medie a unei variabile aleatoare este cuprinsă între cea mai mică și cea mai mare dintre valorile posibile ale variabilei aleatoare. Fie  $a = \min_i x_i$  și  $A = \max_i x_i$ .

$$\left. \begin{aligned} M[X] &= \sum_{i=1}^m x_i p_i > a \sum_{i=1}^m p_i = a, \\ M[X] &= \sum_{i=1}^m x_i p_i < A \sum_{i=1}^m p_i = A, \end{aligned} \right\} \Leftrightarrow a < M[X] < A.$$

4. Valoarea medie a unei sume finite de variabile aleatoare este egală cu suma valorilor medii ale variabilelor aleatoare respective. Fie

$$X : \begin{pmatrix} x_1 & x_2 & \dots & x_m \\ p_1 & p_2 & \dots & p_m \end{pmatrix}, \quad Y : \begin{pmatrix} y_1 & y_2 & \dots & y_n \\ q_1 & q_2 & \dots & q_n \end{pmatrix},$$

$$X + Y : \begin{pmatrix} x_1 + y_1 & x_1 + y_2 & \dots & x_m + y_n \\ p_{11} & p_{12} & \dots & p_{mn} \end{pmatrix}.$$

Atunci

$$\begin{aligned} M[X + Y] &= \sum_{i=1}^m \sum_{j=1}^n (x_i + y_j) p_{ij} = \\ &= \sum_{i=1}^m x_i \left( \sum_{j=1}^n p_{ij} \right) + \sum_{j=1}^n y_j \left( \sum_{i=1}^m p_{ij} \right) = \sum_{i=1}^m x_i p_i + \sum_{j=1}^n y_j q_j = M[X] + M[Y]. \end{aligned}$$

Demonstrația pentru suma unui număr finit de variabile aleatoare se face prin inducție.

5. Valoarea medie a unui produs de variabile aleatoare independente este egală cu produsul mediilor variabilelor considerate.

$$X : \begin{pmatrix} x_1 & x_2 & \dots & x_m \\ p_1 & p_2 & \dots & p_m \end{pmatrix}, \quad Y : \begin{pmatrix} y_1 & y_2 & \dots & y_n \\ q_1 & q_2 & \dots & q_n \end{pmatrix},$$

$$XY : \begin{pmatrix} x_1 y_1 & x_1 y_2 & \dots & x_m y_n \\ p_{11} & p_{12} & \dots & p_{mn} \end{pmatrix},$$

$$M[XY] = \sum_{i=1}^m \sum_{j=1}^n x_i y_j p_{ij}.$$

Dacă variabilele sunt independente, se produc simplificări importante deoarece putem scrie

$$p_{ij} = p_i q_j$$

și atunci

$$\begin{aligned} M[XY] &= \sum_{j=1}^n x_1 y_j p_1 q_j + \sum_{j=1}^n x_2 y_j p_2 q_j + \dots + \sum_{j=1}^n x_m y_j p_m q_j = \\ &= \left( \sum_{i=1}^m x_i p_i \right) \left( \sum_{j=1}^n y_j q_j \right) = M[X] M[Y]. \end{aligned}$$

6. Oricare ar fi variabila aleatoare  $X$ , are loc relația

$$\sqrt{M[X^2]} \geq |M[X]|.$$

Considerăm variabila aleatoare  $X$  având tabloul (2.4) și fie  $Y = (X + a)^2$ ,  $a \in \mathbb{R}$ . Deoarece valorile lui  $Y$  sunt pozitive, rezultă că  $M[Y] \geq 0$  și deci

$$\begin{aligned} M[Y] &= \sum_{i=1}^m (x_i + a)^2 p_i = \sum_{i=1}^m x_i p_i + 2a \sum_{i=1}^m x_i p_i + a^2 = \\ &= M[X^2] + 2aM[X] + a^2 \geq 0 \quad \forall a \in \mathbb{R}. \end{aligned}$$

Rezultă  $\Delta \leq 0$  și cum

$$\Delta = (M[X])^2 - M[X^2] \leq 0$$

obținem inegalitatea dorită.

7. Inegalitatea lui Schwarz. Fie  $x$  și  $Y$  două variabile aleatoare discrete simple. Are loc inegalitatea

$$|M[XY]| \leq \sqrt{M[X^2]M[Y^2]}.$$

Demonstrația poate fi găsită în Capitolul 3.4, Formula (3.42).

**Definiția 2.2.6** Fie o variabilă aleatoare  $X$  și o constantă  $a \in \mathbb{R}$ . Numim abaterea de la constanta  $a$  a variabilei aleatoare  $X$  variabila  $X - a$ .

**Definiția 2.2.7** Se numește moment centrat de ordin  $k$  raportat la constanta  $a$  a variabilei aleatoare  $X$  media variabilei  $(X - a)^k$ .

**Observația 2.2.8** Pentru  $a = 0$  obținem momentul inițial de ordin  $k$ .

**Observația 2.2.9** Pentru  $a = M[X] = m$  obținem momentul centrat de ordin  $k$  al variabilei aleatoare  $X$ .

**Definiția 2.2.8** Variabila aleatoare  $X - M[X]$  se numește abaterea de la medie a variabilei aleatoare  $X$ .

**Propoziția 2.2.3** Valoarea medie a abaterii oricărei variabile aleatoare este nulă.

$$M[X - M[X]] = M[X] - M[M[X]] = M[X] - M[X] = 0.$$

De multe ori la o variabilă aleatoare ne interesează cât de mult se abat valorile variabilei de la valoarea medie. Trebuie să stabilim un indicator numeric al împrăștierii valorilor variabilei aleatoare în jurul valorii medii. Valoarea medie a abaterii de la medie nu poate caracteriza această împrăștiere deoarece este nulă pentru orice variabilă aleatoare. Abaterile diferitelor valori, având semne diferite, se compensează. Este firesc să caracterizăm împrăștierea variabilei aleatoare  $X$  prin valoarea medie a abaterilor absolute  $|X - M[X]|$  pe care o numim *abatere medie*. Dacă  $X$  are tabloul de repartiție

$$X : \begin{pmatrix} x_1 & x_2 & \dots & x_n \\ p_1 & p_2 & \dots & p_n \end{pmatrix},$$

atunci repartiția abaterii absolute este

$$\left( \begin{array}{cccc} |x_1 - m| & |x_2 - m| & \dots & |x_n - m| \\ p_1 & p_2 & \dots & p_n \end{array} \right),$$

unde  $m = M[X]$ , iar abaterea medie este

$$p_1 |x_1 - m| + p_2 |x_2 - m| + \dots + p_n |x_n - m|.$$

Se observă că semnul expresiilor  $x_i - m$  nu influențează valoarea abaterii medii. Folosirea abaterii medii este foarte incomodă în calcule. Foarte comodă este în schimb folosirea expresiei

$$M[(X - m)^2].$$

**Definiția 2.2.9** Se numește dispersie a variabilei aleatoare  $X$  momentul centrat de ordinul al doilea al variabilei, notat

$$\sigma^2 = D^2[X] = M[(X - m)^2], \quad m = M[X].$$

**Observația 2.2.10** Demonstrăm o formulă utilă în aplicații și anume că dispersia unei variabile aleatoare este egală cu media pătratului variabilei aleatoare minus pătratul mediei, adică

$$D^2[X] = M[X^2] - (M[X])^2.$$

Într-adevăr,

$$\begin{aligned} D^2[X] &= \sum_{i=1}^n p_i (x_i - m)^2 = \\ &= \sum_{i=1}^n p_i x_i^2 - 2m \sum_{i=1}^n p_i x_i + m^2 = M[X^2] - 2m^2 + m^2 = M[X^2] - (M[X])^2. \end{aligned}$$

Arătăm că dispersia unei variabile aleatoare  $X$  este, într-un anume sens, cea mai bună valoare care caracterizează împrăștierea valorilor  $x_1, x_2, \dots, x_n$  sau, cu alte cuvinte,  $M[X]$  este punctul cel mai potrivit față de care trebuie să măsurăm devierile acestor valori. Acest lucru rezultă din următoarea propoziție.

**Propoziția 2.2.4** Dacă  $X$  este o variabilă aleatoare care ia valorile  $x_1, x_2, \dots, x_n$  cu probabilitățile  $p_1, p_2, \dots, p_n$ , iar  $m$  este media, atunci

$$D^2[X] = \sum_{i=1}^n p_i (x_i - m)^2 \leq \sum_{i=1}^n p_i (x_i - x)^2, \quad \forall x \in \mathbb{R}.$$

**Demonstrație.** Putem scrie  $x_i - x = (x_i - m) + (m - x)$ ,  $i = \overline{1, n}$ .

$$\sum_{i=1}^n p_i (x_i - x)^2 = \sum_{i=1}^n p_i [(x_i - m) + (m - x)]^2 =$$

$$\begin{aligned}
&= \sum_{i=1}^n p_i(x_i - m)^2 + 2(m - x) \sum_{i=1}^n p_i(x_i - m) + (m - x)^2 = \\
&= \sum_{i=1}^n p_i(x_i - m)^2 + 2(m - x)(m - m) + (m - x)^2 = \\
&= D^2[X] + (m - x)^2 \leq D^2[X].
\end{aligned}$$

■

### Proprietăți ale dispersiei.

1. Dispersia unei constante este nulă deoarece, ținând seama de proprietățile mediei,

$$D^2[c] = M[c^2] - (M[c])^2 = 0.$$

2. Două variabile aleatoare care diferă printr-o constantă au dispersiile egale.

$$X : \begin{pmatrix} x_1 & x_2 & \dots & x_n \\ p_1 & p_2 & \dots & p_n \end{pmatrix},$$

$$Y = a + X : \begin{pmatrix} a + x_1 & a + x_2 & \dots & a + x_n \\ p_1 & p_2 & \dots & p_n \end{pmatrix},$$

$$M[Y] = M[X + a] = M[X] + a,$$

$$D^2[Y] = \sum_{i=1}^n (x_i + a - M[Y])^2 p_i =$$

$$= \sum_{i=1}^n p_i(x_i + a - M[X] - a)^2 = \sum_{i=1}^n p_i(x_i - M[X])^2 = D^2[X].$$

3.  $D^2[aX] = a^2 D^2[X]$  deoarece

$$D^2[aX] = \sum_{i=1}^n p_i(ax_i - am)^2 = \sum_{i=1}^n p_i a^2(x_i - m)^2 =$$

$$= a^2 \sum_{i=1}^n p_i(x_i - m)^2 = a^2 D^2[X].$$

4. Dacă variabilele aleatoare  $X_1, X_2, \dots, X_k$  sunt independente, atunci dispersia sumei este egală cu suma dispersiilor.

$$D^2[X_1 + X_2 + \dots + X_k] = D^2[X_1] + D^2[X_2] + \dots + D^2[X_k].$$

Într-adevăr, fie

$$Y = X_1 + X_2 + \dots + X_k$$

atunci

$$\begin{aligned} D^2[Y] &= M[Y^2] - (M[Y])^2 = M\left[\left(\sum_{i=1}^k X_i\right)^2\right] - \left(M\left[\sum_{i=1}^k X_i\right]\right)^2 = \\ &= M[X_1^2 + X_2^2 + \dots + X_k^2 + 2X_1X_2 + 2X_1X_3 + \dots + 2X_{k-1}X_k] - \\ &- (M[X_1] + M[X_2] + \dots + M[X_k])^2 = M[X_1^2] + M[X_2^2] + \dots + M[X_k^2] + \\ &+ 2M[X_1X_2] + 2M[X_1X_3] + \dots + 2M[X_{k-1}X_k] - (M[X_1])^2 - \\ &- (M[X_2])^2 - \dots - (M[X_k])^2 - 2M[X_1]M[X_2] - 2M[X_1]M[X_3] - \dots - \\ &- 2M[X_{k-1}]M[X_k] = M[X_1^2] - (M[X_1])^2 + M[X_2^2] - (M[X_2])^2 + \dots + \\ &+ M[X_k^2] - (M[X_k])^2 = D^2[X_1] + D^2[X_2] + \dots + D^2[X_k], \end{aligned}$$

folosind Proprietatea 5 a mediei.

**Observația 2.2.11** Proprietatea rămâne adevărată în condiții mai puțin restrictive. În cursul demonstrației s-a folosit faptul că variabilele aleatoare  $X_i, i = \overline{1, k}$  sunt independente două câte două și nu în totalitatea lor.

Mai general, combinând Proprietățile 3 și 4, avem

$$D^2\left[\sum_{i=1}^k a_i X_i\right] = \sum_{i=1}^k a_i^2 D^2[X_i]$$

În particular,

$$D^2[X - Y] = D^2[X] + D^2[Y].$$

De obicei, gradul de împrăștiere a valorilor unei variabile aleatoare  $X$  se exprimă nu prin dispersie, ci prin *abaterea medie pătratică*, notată  $D[X]$  și definită prin relația

$$\sigma = D[X] = \sqrt{D^2[X]}.$$

Aceasta are avantajul că se exprimă prin aceleași unități de măsură ca și valorile variabilei aleatoare  $X$ .

**Proprietăți ale abaterii medii pătratice.**

1.  $D[c] = 0$ , dacă  $c = \text{const.}$ ,  $c \in \mathbb{R}$ .
2.  $D[a + X] = D[X]$ .
3.  $D[aX] = |a| D[X]$ .

Proprietățile de mai sus rezultă din proprietățile dispersiei.

**Teorema 2.2.1** (Inegalitatea lui Cebâșev). *Fie  $X$  o variabilă aleatoare care admite medie și dispersie finite. Atunci, oricare ar fi  $\epsilon \geq 0$ , are loc inegalitatea*

$$P(\{|X - m| < \epsilon\}) \geq 1 - \frac{D^2[X]}{\epsilon^2}, \quad m = M[X]. \tag{2.5}$$

**Demonstrație.** Facem observația că această inegalitate dă o margine inferioară pentru probabilitatea ca abaterea absolută a unei variabile aleatoare cu dispersia cunoscută să fie mai mică decât un număr dat.

Pentru demonstrație considerăm repartiția variabilei aleatoare  $X$ ,

$$X : \begin{pmatrix} x_1 & x_2 & \dots & x_n \\ p_1 & p_2 & \dots & p_n \end{pmatrix},$$

în care presupunem că am scris valorile în ordine crescătoare, și deci așa vor fi scrise și valorile  $|x_i - m|, i = \overline{1, n}$ , adică

$$|x_1 - m| \leq |x_2 - m| \leq \dots \leq |x_n - m|.$$

Dacă luăm un  $\epsilon \geq 0$  oarecare, unele din valorile  $|x_i - m|, i = \overline{1, n}$ , vor fi mai mari sau egale cu  $\epsilon$ , altele mai mici. Există deci un  $l$  astfel încât

$$|x_1 - m| \leq |x_2 - m| \leq \dots \leq |x_l - m| < \epsilon \leq |x_{l+1} - m| \leq \dots \leq |x_n - m|.$$

Aceste inegalități se mai pot scrie

$$(x_1 - m)^2 \leq (x_2 - m)^2 \leq \dots \leq (x_l - m)^2 < \epsilon^2 \leq (x_{l+1} - m)^2 \leq \dots \leq (x_n - m)^2.$$

Variabila aleatoare  $|X - m|$  are repartiția

$$\begin{pmatrix} |x_1 - m| & |x_2 - m| & \dots & |x_l - m| & |x_{l+1} - m| & \dots & |x_n - m| \\ p_1 & p_2 & \dots & p_l & p_{l+1} & \dots & p_n \end{pmatrix}$$

și ia valoarea  $|x_i - m|$  atunci când  $X$  ia valoarea  $x_i$ . Inegalitatea  $|X - m| < \epsilon$  este verificată atunci când  $|X - m|$  ia una din valorile  $|x_1 - m|, |x_2 - m|, \dots, |x_l - m|$  adică atunci și numai atunci când  $X$  ia una din valorile  $x_1, x_2, \dots, x_l$ . Putem scrie deci evenimentul  $(|X - m| < \epsilon)$  ca o reuniune finită de evenimente incompatibile

$$\{|X - m| < \epsilon\} = \{X = x_1\} \cup \{X = x_2\} \cup \dots \cup \{X = x_l\}.$$

de unde

$$P(\{|X - m| < \epsilon\}) = \sum_{i=1}^l p_i = 1 - \sum_{i=l+1}^n p_i.$$

Scriem acum dispersia variabilei aleatoare  $X$

$$\sigma^2 = (x_1 - m)^2 p_1 + \dots + (x_l - m)^2 p_l + (x_{l+1} - m)^2 p_{l+1} + \dots + (x_n - m)^2 p_n.$$

Vom transforma această egalitate în inegalitate prin micșorarea membrului drept. Această minorare o realizăm astfel: valorile  $(x_i - m)^2$  care sunt mai mici ca  $\epsilon^2$  le înlocuim cu 0, iar cele care sunt mai mari sau egale cu  $\epsilon^2$  le înlocuim cu  $\epsilon^2$ . Atunci

$$\sigma^2 \geq 0p_1 + \dots + 0p_l + \epsilon^2 p_{l+1} + \dots + \epsilon^2 p_n = \epsilon^2 \sum_{i=l+1}^n p_i$$

și deci

$$\frac{\sigma^2}{\epsilon^2} \geq \sum_{i=l+1}^n p_i,$$

$$1 - \frac{\sigma^2}{\epsilon^2} \leq 1 - \sum_{i=l+1}^n p_i = P(\{|X - m| \geq \epsilon\}),$$

care este echivalentă cu Inegalitatea (2.5). ■

Dacă luăm  $\epsilon = k\sigma$  această inegalitate se scrie

$$P(\{|X - m| < k\sigma\}) \geq 1 - \frac{1}{k^2}$$

sau  $P(\{m - k\sigma < X < m + k\sigma\}) \geq 1 - \frac{1}{k^2}$ . De exemplu, pentru  $k = 3$  obținem

$$P(\{m - 3\sigma < X < m + 3\sigma\}) \geq 1 - \frac{1}{9} = \frac{8}{9}.$$

Deci, cu o probabilitate cuprinsă între  $\frac{8}{9}$  și 1, orice variabilă ia valori cuprinse în intervalul  $(m - 3\sigma, m + 3\sigma)$ .

**Exemplul 2.2.8** Fie

$$X : \begin{pmatrix} 0,2 & 0,3 & 0,4 & 0,5 \\ 0,1 & 0,2 & 0,3 & 0,4 \end{pmatrix}.$$

Să se estimeze probabilitatea  $P(\{|X - m| < 0,2\})$ .

Utilizăm inegalitatea lui Cebâșev cu

$$P(\{|X - m| < 0,2\}) \geq 1 - \frac{D^2[X]}{0,2^2}.$$

$M[X] = 0,4$ ,  $M[x^2] = 0$ ,  $D^2[X] = 0,01$ . Înlocuim mai sus și obținem:

$$P(\{|X - 0,4| < 0,2\}) \geq 0,75.$$

## 2.3 Exemple de variabile aleatoare discrete simple

### 1. Repartiția Poisson.

Fie  $X$  o variabilă aleatoare care ia ca valori numărul de bile albe extrase din  $n$  urne  $U_i$ ,  $i = \overline{1, n}$ , care conține fiecare, în proporții diferite, bile albe și negre. Probabilitatea de a extrage o bilă albă din urna  $U_i$  este  $p_i$ , iar o bilă neagră este  $q_i = 1 - p_i$ . Fie  $X_i, i = \overline{1, n}$ , variabilele aleatoare care iau valoarea 1 dacă din urna  $U_i$  se extrage o bilă albă și 0 dacă din aceeași urnă se extrage o bilă neagră.

$$X_i : \begin{pmatrix} 0 & 1 \\ q_i & p_i \end{pmatrix}, \quad i = \overline{1, n},$$

$$M[X_i] = p_i.$$

Cu notațiile introduse, putem scrie

$$X = X_1 + X_2 + \dots + X_n = \sum_{i=1}^n X_i,$$

$$M[X] = M\left[\sum_{i=1}^n X_i\right] = \sum_{i=1}^n M[X_i] = \sum_{i=1}^n p_i,$$

$$D^2[X] = D^2\left[\sum_{i=1}^n X_i\right] = \sum_{i=1}^n D^2[X_i],$$

deoarece variabilele aleatoare  $X_i, i = \overline{1, n}$ , sunt independente. Dar

$$D^2[X_i] = M[X_i^2] - (M[X_i])^2.$$

Deoarece

$$X_i^2 : \begin{pmatrix} 0 & 1 \\ q_i & p_i \end{pmatrix},$$

avem

$$M[X_i^2] = p_i,$$

deci

$$D^2[X_i] = p_i - p_i^2 = p_i q_i \text{ și } D^2[X] = \sum_{i=1}^n p_i q_i.$$

## 2. Repartiția Bernoulli.

Este de fapt repartiția Poisson în care structurile urnelor  $U_i, i = \overline{1, n}$ , sunt identice, adică  $p_1 = p_2 = \dots = p_n = p, q_1 = q_2 = \dots = q_n = q$ . Variabila aleatoare corespunzătoare este

$$X : \begin{pmatrix} 0 & 1 & 2 & \dots & k & \dots & n \\ C_n^0 p^0 q^n & C_n^1 p^1 q^{n-1} & C_n^2 p^2 q^{n-2} & \dots & C_n^k p^k q^{n-k} & \dots & C_n^n p^n q^0 \end{pmatrix}.$$

Scriem, în acest caz,  $X : Bi(n, p)$ . Particularizând schema lui Poisson, obținem

$$M[X] = np, \quad D^2[X] = npq.$$

De fapt variabila aleatoare binomială descrie o experiență în care un eveniment A se repetă independent de  $n$  ori și interesează de câte ori s-a realizat în decursul celor  $n$  repetări. Fie  $X$  numărul de realizări ale evenimentului A în cele  $n$  efectuări. Deci  $X$  va lua valorile  $1, 2, 3, \dots, n$  cu probabilitățile  $P(\{X = k\}) = C_n^k p^k q^{n-k}$ . Figura 2.2 și 2.3 sunt desenate densitățile de probabilitate generalizate pentru variabila aleatoare binomială, pentru  $n = 24$ , (a)  $p = 0, 2$  și respectiv (b)  $p = 0.5$ .

Remarcăm că  $P(\{X = k\})$  este maxim când  $k_{max} = [(n + 1)p]$ , unde  $[x]$  notează partea întreagă a lui  $x$ . Dacă  $(n + 1)p$  este întreg, atunci maximum este atins în  $k_{max}$  și  $k_{max} - 1$ .



Variabila aleatoare binomială apare în aplicații în care sunt două tipuri de situații: realizări/nerealizări, bit corect/eronat, aparat bun/defect etc.

### 3. Repartiția hipergeometrică.

Fie  $X$  variabila aleatoare care ia ca valori numărul de bile albe care se obțin extrăgând  $n$  bile dintr-o urnă care conține  $a$  bile albe și  $b$  bile negre ( $n \leq a + b$ ). Tabloul de repartiție al variabilei aleatoare  $X$  este

$$X : \left( \begin{array}{cccccc} 0 & 1 & 2 & \dots & k & \dots & \min\{n, a\} \\ \frac{C_a^0 C_b^n}{C_{a+b}^n} & \frac{C_a^1 C_b^{n-1}}{C_{a+b}^n} & \frac{C_a^2 C_b^{n-2}}{C_{a+b}^n} & \dots & \frac{C_a^k C_b^{n-k}}{C_{a+b}^n} & \dots & \frac{C_a^{\min\{n,a\}} C_b^{n-\min\{n,a\}}}{C_{a+b}^n} \end{array} \right).$$

Calculăm caracteristicile numerice ale variabilei aleatoare  $X$ . Avem

$$\begin{aligned} M[X] &= \sum_{k=1}^{\min\{a,n\}} k \frac{C_a^k C_b^{n-k}}{C_{a+b}^n} = \frac{1}{C_{a+b}^n} \sum_k k C_a^k C_b^{n-k} = \frac{1}{C_{a+b}^n} \sum_k a C_{a-1}^{k-1} C_b^{n-k} = \\ &= \frac{a}{C_{a+b}^n} C_{a+b-1}^{n-1} = a \frac{n!(a+b-n)!}{(a+b)!} \frac{(a+b-1)!}{(n-1)!(a+b-n)!} = \frac{an}{a+b}. \end{aligned}$$

Pentru calculul dispersiei utilizăm formula

$$D^2[X] = M[X^2] - (M[X])^2.$$

Calculăm mai întâi

$$\begin{aligned} M[X^2] &= \sum_k k^2 \frac{C_a^k C_b^{n-k}}{C_{a+b}^n} = \sum_k k(k-1) \frac{C_a^k C_b^{n-k}}{C_{a+b}^n} + \sum_k k \frac{C_a^k C_b^{n-k}}{C_{a+b}^n}; \\ \sum_k k(k-1) \frac{C_a^k C_b^{n-k}}{C_{a+b}^n} &= \frac{1}{C_{a+b}^n} \sum_k a(a-1) C_{a-2}^{k-2} C_b^{n-k} = \frac{a(a-1)}{C_{a+b}^n} C_{a+b-2}^{n-2} = \\ &= a(a-1) \frac{n!(a+b-n)!(a+b-2)!}{(a+b)!(n-2)!(a+b-n)!} = \frac{a(a-1)n(n-1)}{(a+b)(a+b-1)}. \end{aligned}$$

De aici rezultă că

$$\begin{aligned} M[X^2] &= \frac{a(a-1)n(n-1)}{(a+b)(a+b-1)} + \frac{an}{a+b} = \frac{an}{a+b} \left( \frac{(a-1)(n-1)}{a+b-1} + 1 \right), \\ D^2[X] &= \frac{an(an-n+b)}{(a+b)(a+b-1)} - \frac{a^2n^2}{(a+b)^2} = \frac{abn(a+b-n)}{(a+b)^2(a+b-1)}. \end{aligned}$$

și în cazul schemei bilei neîntoarse, variabila aleatoare hipergeometrică poate fi scrisă sub forma unei sume de variabile aleatoare. Să notăm cu  $X_1$  numărul de bile albe obținute la prima extragere, cu  $X_2$  numărul de bile albe obținute la a doua extragere etc. Tabloul de repartiție al variabilei  $X_1$  este

$$X_1 : \begin{pmatrix} 0 & 1 \\ q & p \end{pmatrix}.$$

Vom arăta că și celelalte variabile aleatoare  $X_i, i = \overline{2, n}$ , au aceeași repartiție. Pentru aceasta calculăm probabilitatea obținerii unei bile albe la extracția de ordin  $k$ , atunci când se fac extrageri fără întoarcerea bilei. Numărul cazurilor posibile  $A_{a+b}^k$ . Numărul cazurilor favorabile coincide cu numărul de moduri în care pot fi luate  $k$  bile astfel încât pe locul  $k$  să fie o bilă albă. O bilă albă poate fi luată în  $a$  moduri.

Celelalte  $k-1$  locuri pot fi ocupate în  $A_{a+b-1}^{k-1}$  moduri, în total  $aA_{a+b-1}^{k-1}$  cazuri favorabile. Probabilitatea cătată va fi deci

$$\frac{aA_{a+b-1}^{k-1}}{A_{a+b}^k} = \frac{a(a+b-1)(a+b-2)\dots(a+b-k+1)}{(a+b)(a+b-1)\dots(a+b-k+1)} = \frac{a}{a+b} = p.$$

Rezultă că  $X_k$  are repartiția

$$X_k : \begin{pmatrix} 0 & 1 \\ q & p \end{pmatrix}.$$

Din relațiile

$$X = X_1 + X_2 + \dots + X_n$$

și

$$M[X_1] = M[X_2] = \dots = M[X_n] = p,$$

rezultă

$$M[X] = np.$$

Ca și în cazul repartiției lui Bernoulli,  $X$  se scrie ca o sumă de variabile aleatoare având aceeași repartiție

$$\begin{pmatrix} 0 & 1 \\ q & p \end{pmatrix}.$$

Deosebirea este esențială: în cazul repartiției hipergeometrice, variabilele aleatoare nu sunt independente. Din această cauză nu putem calcula dispersia variabilei aleatoare  $X$  ca suma dispersiilor variabilelor aleatoare  $X_i$ .

**Teorema 2.3.1** *Dacă  $X$  este o variabilă aleatoare repartizată hipergeometric cu parametri  $a+b, a, n$ , pentru care*

$$P(\{X = k\}) = \frac{C_a^k C_b^{n-k}}{C_{a+b}^n},$$

atunci

$$\lim_{a+b \rightarrow \infty} \frac{C_a^k C_b^{n-k}}{C_{a+b}^n} = C_n^k p^k q^{n-k}, \quad (2.6)$$

unde  $p = \frac{a}{a+b}, q = 1 - p$  și deci pentru valori mari ale lui  $a+b$ , o variabilă aleatoare repartizată hipergeometric poate fi aproximată cu o variabilă repartizată binomială  $Bi(n, \frac{a}{a+b})$ .

**Demonstrație.**

$$\frac{C_a^k C_b^{n-k}}{C_{a+b}^n} = \frac{a(a-1)\dots(a-k+1)}{k!}.$$

$$\begin{aligned}
 & \cdot \frac{b(b-1)\dots(b-n+k-1)}{(n-k)!} \cdot \frac{n!}{(a+b)\dots(a+b-n+1)} = \\
 = & \frac{n!}{k!(n-k)!} \frac{a(a-1)\dots(a-k+1)b(b-1)\dots(b-n+k-1)}{(a+b)\dots(a+b-n+1)} = \\
 = & C_n^k \frac{a}{a+b} \frac{a-1}{a+b} \dots \frac{a-k+1}{a+b} \frac{b}{a+b} \frac{b-1}{a+b} \dots \frac{b-n+k-1}{a+b} \cdot \\
 & \cdot \frac{(a+b)^n}{(a+b)\dots(a+b-n+1)} = C_n^k p \left(p - \frac{1}{a+b}\right) \dots \left(p - \frac{k-1}{a+b}\right) \cdot \\
 & \cdot q \left(q - \frac{1}{a+b}\right) \dots \left(q - \frac{n-k+1}{a+b}\right) \frac{(a+b)^n}{(a+b)\dots(a+b-n+1)}.
 \end{aligned}$$

Trecând la limită obținem (2.6).

**Exemplul 2.3.1** Să se arate că dacă  $X, Y$  sunt două variabile aleatoare independente,  $X : Bi(n, p), Y : Bi(m, p)$  atunci  $X + Y : Bi(n + m, p)$ .

$$\begin{aligned}
 P(\{X + Y = k\}) &= \sum_{l=0}^k P(\{X = l, Y = k - l\}) = \sum_{l=0}^k C_n^l p^l q^{n-l} C_m^{k-l} p^{k-l} q^{m-k+l} = \\
 &= \left(\sum_{l=0}^k C_n^l C_m^{k-l}\right) p^k q^{n+m-k} = C_{m+n}^k p^k q^{n+m-k}.
 \end{aligned}$$

## 2.4 Variabile aleatoare discrete simple bidimensionale

În aplicațiile practice ale teoriei probabilităților se întâlnesc adesea probleme în care rezultatele nu pot fi descrise de o variabilă aleatoare, ci de două sau mai multe, ele formând un vector aleator.

De exemplu, într-un anumit experiment ne interesează să măsurăm atât viteza cât și direcția particulelor atomice emise de o suprafață. Acestea sunt date de perechile  $(v, \theta)$ , unde  $\theta$  este mărimea unghiului orientat în raport cu sistemul de referință și  $v$  viteza. Acestea pot fi studiate ca un vector aleator.

Orice variabilă aleatoare discretă simplă bidimensională  $(X, Y)$  se consideră ca un vector aleator de componente  $X$  și  $Y$ .

Dacă vectorul aleator  $(X, Y)$  ia un număr finit de valori, se poate obține următorul tablou numit *repartiția bidimensională* sau *tablou de repartiție bidimensională*.

$X \setminus Y$	$y_1$	$y_2$	$\dots$	$y_n$	
$x_1$	$p_{11}$	$p_{12}$	$\dots$	$p_{1n}$	$p_{1.}$
$x_2$	$p_{21}$	$p_{22}$	$\dots$	$p_{2n}$	$p_{2.}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$x_m$	$p_{m1}$	$p_{m2}$	$\dots$	$p_{mn}$	$p_{m.}$
	$p_{.1}$	$p_{.2}$	$\dots$	$p_{.n}$	1

Variabilele aleatoare :

$$X : \begin{pmatrix} x_i \\ p_{i.} \end{pmatrix}, i = \overline{1, m}, \quad Y : \begin{pmatrix} y_j \\ p_{.j} \end{pmatrix}, j = \overline{1, n},$$

se numesc *legi de probabilitate marginală* pentru vectorul bidimensional  $(X, Y)$ .

Din faptul că evenimentele  $\{e \in E \mid X(e) = x_i, Y(e) = y_j\}, i = \overline{1, m}, j = \overline{1, n}$ , formează un sistem complet de evenimente, rezultă că

$$\sum_{i=1}^m \sum_{j=1}^n p_{ij} = 1,$$

unde

$$p_{ij} = P(\{e \in E \mid X(e) = x_i, Y(e) = y_j\}).$$

Am notat

$$\sum_{k=1}^n p_{ik} = p_{i.}, \quad i = \overline{1, m}, \quad \sum_{k=1}^m p_{kj} = p_{.j}, \quad j = \overline{1, n},$$

cantități care se numesc *probabilități marginale*. Ca și în cazul variabilelor aleatoare unidimensionale, rezultă că

$$P(\{X = x_i\}) = \sum_{j=1}^n p_{ij} = p_{i.},$$

$$P(\{Y = y_j\}) = \sum_{i=1}^m p_{ij} = p_{.j}.$$

Notăm cu  $P(\{x_i|y_j\})$  *probabilitatea condiționată*:

$$P(\{x_i|y_j\}) = P(\{X = x_i\} \mid \{Y = y_j\}).$$

și atunci avem

$$P(\{x_i|y_j\}) = \frac{P(\{X = x_i\} \cap \{Y = y_j\})}{P(\{Y = y_j\})} = \frac{p_{ij}}{p_{.j}}. \quad (2.7)$$

Analog:

$$P(\{y_j|x_i\}) = \frac{p_{ij}}{p_{i.}}.$$

Dacă înmulțim relația (2.7) cu  $P(\{Y = y_j\})$  obținem

$$P(\{X = x_i\} \cap \{Y = y_j\}) = P(\{x_i|y_j\})P(\{Y = y_j\}),$$

adică am exprimat  $p_{ij}$  ca un produs dintre o probabilitate condiționată și o probabilitate marginală. Analog se obține

$$P(\{X = x_i\} \cap \{Y = y_j\}) = P(\{y_j|x_i\})P(\{X = x_i\}),$$

Presupunem că ne interesează ca  $Y$  să ia valori într-o regiune  $A$ ,

$$\begin{aligned} P\{Y \in A\} &= \sum_{x_i} \sum_{y_j \in A} P(\{X = x_i\} \cap \{Y = y_j\}) = \\ &= \sum_{x_i} \sum_{y_j \in A} P(\{y_j|x_i\})P\{X = x_i\} = \sum_{x_i} P\{X = x_i\} \sum_{y_j \in A} P(\{y_j|x_i\}) \end{aligned} \quad (2.8)$$

Dacă evenimentele  $\{X = x_i\}$  și  $\{Y = y_j\}$  sunt independente, deci variabilele aleatoare  $X$  și  $Y$  sunt independente, atunci  $p_{ij} = p_i \cdot p_j$  și reciproc.

Deoarece evenimentul

$$\begin{aligned} (\{Y = y_1\}|\{X = x_i\}) \cup (\{Y = y_2\}|\{X = x_i\}) \cup \dots (\{Y = y_n\}|\{X = x_i\}) = \\ = E|\{X = x_i\} \end{aligned}$$

rezultă că

$$\sum_{j=1}^n P(\{y_j|x_i\} = 1).$$

La fel

$$\sum_{i=1}^m P(\{x_i|y_j\} = 1).$$

**Observație.** Putem atașa vectorului aleator  $(X, Y)$  tabloul de repartiție dat de legile de probabilitate condiționată :

$$X|\{Y = y_j\} : \begin{pmatrix} x_1 & x_2 & \dots & x_i & \dots & x_m \\ \frac{p_{1j}}{p_{\cdot j}} & \frac{p_{2j}}{p_{\cdot j}} & \dots & \frac{p_{ij}}{p_{\cdot j}} & \dots & \frac{p_{mj}}{p_{\cdot j}} \\ p_{\cdot j} & p_{\cdot j} & \dots & p_{\cdot j} & \dots & p_{\cdot j} \end{pmatrix},$$

și respectiv

$$Y|\{X = x_i\} : \begin{pmatrix} y_1 & y_2 & \dots & y_i & \dots & y_m \\ \frac{p_{i1}}{p_{i\cdot}} & \frac{p_{i2}}{p_{i\cdot}} & \dots & \frac{p_{ij}}{p_{i\cdot}} & \dots & \frac{p_{im}}{p_{i\cdot}} \\ p_{i\cdot} & p_{i\cdot} & \dots & p_{i\cdot} & \dots & p_{i\cdot} \end{pmatrix}.$$

Deci avem  $n$  legi condiționate ale variabilei aleatoare  $X$  corespunzătoare celor  $n$  valori ale variabilei aleatoare  $Y$  și respectiv  $m$  legi de probabilitate ale variabilei aleatoare  $Y$  condiționate de cele  $m$  valori ale lui  $X$ .

**Exemplul 2.4.1** Numărul biților,  $N$ , dintr-un mesaj transmis corect este o variabilă aleatoare care urmează o repartiție geometrică cu parametrul  $p$ . Presupunem că mesajul este împărțit în pachete de maximum  $M$  biți lungime. Fie  $Q$  numărul pachetelor complete formate cu biții unui mesaj și  $R$  numărul biților rămași în ultimul pachet care poate fi incomplet. Să se calculeze probabilitatea ca mesajul transmis să conțină  $q$  pachete complete, iar ultimul pachet să conțină  $r$  biți. Notăm cu  $Y$  variabila aleatoare care ia ca valori numărul de pachete complete dintr-un mesaj și cu  $Z$  variabila aleatoare care ia ca valori numărul  $R$  de biți incompleți din ultimul pachet.

Dacă mesajul are  $N$  biți, atunci numărul pachetelor complete din mesaj este câtul  $Q$  a împărțirii lui  $N$  la  $M$ , iar restul este numărul  $R$  al biților din ultimul pachet,  $N = MQ + R$ . Variabila aleatoare  $Y$  ia valorile  $0, 1, 2, \dots$  iar variabila aleatoare  $Z$  ia valorile  $0, 1, 2, \dots, M-1$ . Asociat acestui eveniment considerăm variabila aleatoare bidimensională  $(Y, Z)$ . Probabilitatea ca mesajul corect să conțină  $q$  pachete complete și ultimul pachet să conțină  $r$  biți este dată de

$$P(\{Y = q, Z = r\}) = P(\{X = N\}) = p^{qM+r}(1-p),$$

unde  $N = qM + r$ . Probabilitatea ca mesajul transmis să conțină  $q$  pachete complete

$$\begin{aligned} P(\{Y = q\}) &= P(\{X \in \{qM, qM+1, \dots, qM+(M-1)\}\}) = \\ &= \sum_{k=0}^{M-1} p^{qM+k}(1-p) = (1-p)p^{qM} \frac{1-p^M}{1-p} = (1-p^M)(p^M)^q, \quad q = 0, 1, \dots \end{aligned}$$

Observăm că variabila aleatoare  $Y$  urmează o repartiție geometrică cu parametrul  $p^M$ . Probabilitatea ca ultimul pachet să conțină  $r$  biți este

$$\begin{aligned} P(\{Z = r\}) &= P(\{X \in \{r, M+r, 2M+r, \dots\}\}) = \sum_{q=0}^{\infty} (1-p)p^{qM+r} = \\ &= \frac{1-p}{1-p^M} p^r, \quad r = 0, 1, 2, \dots, M-1 \end{aligned}$$

Observăm că variabila aleatoare  $Z$  urmează o repartiție geometrică trunchiată.

Ne punem întrebarea dacă sunt variabilele aleatoare  $Y$  și  $Z$  independente. Avem:

$$\begin{aligned} P(\{Y = q\})P(\{Z = r\}) &= (1-p^M)(p^M)^q \frac{1-p}{1-p^M} p^r = \\ &= \frac{1-p}{1-p^M} p^r = P(\{Y = q\})P(\{Z = r\}), \quad \forall q = 0, 1, \dots, \quad r = 0, 1, \dots, M-1. \end{aligned}$$

Variabilele aleatoare  $Y$  și  $Z$  sunt independente.

## 2.5 Variabile aleatoare cu un număr infinit numărabil de valori

Dacă  $A_1, A_2, \dots, A_n, \dots$  constituie un sistem numărabil de evenimente care formează domeniul de definiție al unei astfel de variabile aleatoare cu  $P(A_n) = p_n, n \in \mathbb{N}$ , atunci tabloul de repartiție al variabilei aleatoare este

$$X : \begin{pmatrix} x_1 & x_2 & \dots & x_n & \dots \\ p_1 & p_2 & \dots & p_n & \dots \end{pmatrix},$$

$$A_i = \{e \in E, X(e) = x_i\}.$$

Un astfel de tabel trebuie să aibă proprietățile:

$$p_i \geq 0, \quad \forall i \in \mathbb{N}; \quad \sum_{i=1}^{\infty} p_i = 1.$$

Operațiile cu variabile cu un număr infinit numărabil de valori se definesc ca și în cazul variabilelor aleatoare discrete simple. La fel se pune problema și în cazul independenței variabilelor aleatoare cu un număr infinit numărabil de valori.

**Repartiția Poisson.**

Spunem că variabila aleatoare  $X$  este repartizată Poisson cu parametru  $\lambda, \lambda \in \mathbb{R}_+$ , dacă tabloul său de repartiție este

$$X : \begin{pmatrix} 0 & 1 & 2 & \dots & k & \dots \\ e^{-\lambda} & \frac{\lambda}{1!}e^{-\lambda} & \frac{\lambda^2}{2!}e^{-\lambda} & \dots & \frac{\lambda^k}{k!}e^{-\lambda} & \dots \end{pmatrix}.$$

Folosim notația

$$P(k; \lambda) = \frac{\lambda^k}{k!}e^{-\lambda}.$$

Evident  $P(k; \lambda) > 0$  și

$$\sum_{k=0}^{\infty} \frac{\lambda^k}{k!}e^{-\lambda} = e^{-\lambda} \sum_{k=0}^{\infty} \frac{\lambda^k}{k!} = e^{-\lambda}e^{\lambda} = 1.$$

În Figura 2.4 desenăm densitatea de probabilitate generalizată pentru valoarea lui  $\lambda = 9$ .  
Proprietăți ale repartiției Poisson.

P1. Media repartiției Poisson este aceeași cu dispersia repartiției și egală cu  $\lambda$ .

Într-adevăr,

$$M[X] = \sum_{k=0}^{\infty} k \frac{\lambda^k}{k!}e^{-\lambda} = \lambda \sum_{k=1}^{\infty} k \frac{\lambda^{k-1}}{(k-1)!}e^{-\lambda} = \lambda.$$

Pentru calculul dispersiei folosim formula  $D^2[x] = M[x^2] - (M[X])^2$ .

$$\begin{aligned} M[X^2] &= \sum_{k=1}^{\infty} k^2 \frac{\lambda^k}{k!}e^{-\lambda} = \sum_{k=2}^{\infty} (k^2 - k) \frac{\lambda^k}{k!}e^{-\lambda} + \sum_{k=1}^{\infty} k^2 \frac{\lambda^k}{k!}e^{-\lambda} = \\ &= \lambda^2 \sum_{k=2}^{\infty} k^2 \frac{\lambda^{k-2}}{(k-2)!}e^{-\lambda} + \lambda = \lambda^2 + \lambda \\ D^2[X] &= \lambda^2 + \lambda - \lambda = \lambda. \end{aligned}$$

P2. Suma a două variabile aleatoare independente repartizate Poisson de parametri  $\lambda_1$  și respectiv  $\lambda_2$  este o variabilă aleatoare repartizată Poisson de parametru  $\lambda_1 + \lambda_2$ .

Într-adevăr

$$\begin{aligned} \{X_1 + X_2 = k\} &= \\ &= \{X_1 = 0, X_2 = k\} \cup \{X_1 = 1, X_2 = k-1\} \cup \dots \cup \{X_1 = k, X_2 = 0\}, \end{aligned}$$

deci

$$\begin{aligned} P(\{X_1 + X_2 = k\}) &= \sum_{k_1=0}^k P(\{X_1 = k_1, X_2 = k - k_1\}) = \\ &= \sum_{k_1=0}^k P(\{X_1 = k_1\})P(\{X_2 = k - k_1\}) = \sum_{k_1}^k \frac{\lambda_1^{k_1}}{k_1!}e^{-\lambda_1} \frac{\lambda_2^{k-k_1}}{(k-k_1)!}e^{-\lambda_2} = \\ &= \frac{e^{-(\lambda_1+\lambda_2)}}{k!} \sum_{k_1=0}^k \frac{k!}{k_1!(k-k_1)!} \lambda_1^{k_1} \lambda_2^{k-k_1} = \frac{e^{-(\lambda_1+\lambda_2)}}{k!} (\lambda_1 + \lambda_2)^k. \end{aligned}$$



P3. Repartiția Poisson se obține ca un caz limită a repartiției binomiale când  $n \rightarrow \infty$  și  $p$  scade astfel încât  $np = \lambda = \text{const.}$  (în general,  $n > 30, p \in (0; 0, 1)$ ).

Repartiția Poisson a apărut odată cu studiul variabilelor aleatoare cu un număr foarte mare de valori. Exemple clasice de astfel de variabile aleatoare sunt cele legate de evenimentele care apar rar într-un interval de timp, ca de exemplu:

- numărul de particule emise de o suprafață radioactivă într-un interval de timp;
- numărul accidentelor dintr-o fabrică în decurs de o săptămână;
- numărul mașinilor care trec printr-un anumit loc într-un interval de timp;
- numărul cererilor de I/O la o rețea de calculatoare într-un interval de timp.

Toate aceste procese se numesc Poisson și ele vor fi studiate în Capitolul 5. În aceste cazuri  $\lambda$  este proporțională cu durata intervalului de timp (adică  $\lambda = tw$ ,  $w$  coeficient de proporționalitate). Parametrul  $w = \frac{\lambda}{t}$  se mai numește parametru de intensitate, reprezentând media numărului de evenimente care se produc în unitatea de timp.

P4. Deoarece repartiția Poisson se întâlnește în cazul evenimentelor care se întâmplă rar ( $n$  mare,  $np = \text{constant}$ , rezultă  $p$  mic), ea mai poartă denumirea de **legea evenimentelor rare**.

**Observația 2.5.1** Repartiția Poisson permite calculul probabilității ca un număr de particule să fie emise de o masă radioactivă într-un interval de timp. Presupunem că masa radioactivă conține  $n$  atomi. Într-o perioadă fixată de timp fiecare atom are o probabilitate  $p$  foarte mică de dezintegrare și emiteră a particulei radioactive. Dacă atomii se dezintegrează independent unii de alții, atunci numărul emisiilor într-un interval de timp poate fi privit ca efectuarea repetată de  $n$  ori a unui același eveniment. De exemplu, un microgram de raniu conține aproximativ  $n = 10^{16}$  atomi și probabilitatea ca un atom să se dezintegreze într-un interval de timp de o milisecundă este  $p = 10^{-15}$  (Rozanov, 1969). Astfel sunt îndeplinite condițiile din Proprietatea P3:  $n$  mare și  $p$  mic astfel încât numărul emisiilor urmează o variabilă aleatoare repartizată Poisson.

**Teorema 2.5.1** Dacă  $X$  urmează o repartiție binomială,

$$P(\{X = k\}) = C_n^k p^k q^{n-k},$$

atunci

$$\lim_{n \rightarrow \infty} C_n^k p^k q^{n-k} = \frac{\lambda^k}{k!} e^{-\lambda},$$

unde  $np = \lambda = \text{const.}$

**Demonstrație.**

$$\lim_{n \rightarrow \infty} C_n^k p^k q^{n-k} = \lim_{n \rightarrow \infty} \frac{n(n-1) \dots (n-k+1)}{k!} \left(\frac{\lambda}{n}\right)^k \left(1 - \frac{\lambda}{n}\right)^{n-k} =$$

$$= \frac{\lambda^k}{k!} \lim_{n \rightarrow \infty} \frac{n(n-1) \dots (n-k+1)}{n^k} \left(1 - \frac{\lambda}{n}\right)^{n-k} = \frac{\lambda^k}{k!} e^{-\lambda}.$$

■

Pentru calculul probabilităților  $P(k, \lambda)$  s-au întocmit tabele pentru  $\lambda$  cuprins între  $0, 1, \dots, 20$ . Aceste tabele dau probabilitățile ca evenimentele să se realizeze de cel puțin  $m$  ori.

$$P(\{X \geq m\}) = \sum_{k=m}^{\infty} \frac{\lambda^k}{k!} e^{-\lambda}.$$

Teorema 2.5.1 ne permite să aproximăm probabilitățile unei repartiții binomiale.

**Exemplul 2.5.1** Probabilitatea de eroare la transmiterea unui bit printr-o linie de comunicație este de  $10^{-3}$ . Să se calculeze probabilitatea ca la transmiterea unui bloc de 1000 de biti să avem cinci sau mai mult de cinci erori.

Transmiterea fiecărui bit reprezintă o experiență Bernoulli care se realizează dacă s-a produs o eroare la transmiterea bitului. Probabilitatea ca să se producă  $k$  erori în 1000 de transmisii este dată de probabilitatea calculată cu legea binomială cu  $n = 1000$  și  $p = 10^{-3}$ . Legea Poisson cu parametrul  $\lambda = np = 1000 \cdot 10^{-3} = 1$  aproximează legea binomială. Astfel

$$P[N \geq 5] = 1 - P[N < 5] = 1 - \sum_{k=0}^4 \frac{\lambda^k}{k!} e^{-\lambda} = 1 - e^{-1} \left\{ 1 + \frac{1}{1!} + \frac{1}{2!} + \frac{1}{3!} + \frac{1}{4!} \right\} = 0,00366$$

**Exemplul 2.5.2** O fabrică produce becuri și dă 2 % rebut. Să se aproximeze probabilitatea ca într-o cutie de 100 de becuri să obținem cel mult trei becuri defecte?

Presupunând independența, avem de-a face cu o variabilă aleatoare repartizată binomial cu  $p = 0,02$  și  $n = 100$ . Dacă dorim să calculăm probabilitatea cu ajutorul schemei binomiale, după calcule laborioase obținem

$$\sum_{k=0}^3 C_{100}^k (0,02)^k (0,98)^{100-k} = 0,859.$$

Dacă aproximăm  $X$  cu o variabilă aleatoare repartizată Poisson,  $\lambda = 100 \times 0,02 = 2$ ,

$$\sum_{k=0}^3 \frac{2^k e^{-2}}{k!} = 0,857.$$

Următorul exemplu justifică trecerea la limită și alegerea parametrului  $\lambda$ .

**Exemplul 2.5.3** Un generator de particule emite particule în unitatea de timp. Care este probabilitatea ca în intervalul  $t$  să apară  $k$  impulsuri ?

Pentru  $n$  suficient de mare împărțim  $[0, t]$  în intervale de lungime  $\frac{t}{n}$ , încât în fiecare interval să existe cel mult un impuls. Probabilitatea ca într-un interval de timp de lungime  $\frac{t}{n}$  să fie înregistrat un impuls este  $\approx w \frac{t}{n} = p$  (se observă că  $\frac{wt}{n} \rightarrow 0$ , pentru  $n \rightarrow \infty$ ,

ceea ce justifică încă o dată denumirea de eveniment rar). Probabilitatea ca în intervalul  $[0, t]$  să fie înregistrate  $k$  impulsuri este dată de schema lui Bernoulli

$$C_n^k \left(\frac{wt}{n}\right)^k \left(1 - \frac{wt}{n}\right)^{n-k} \longrightarrow \frac{(wt)^k}{k!} e^{-wt} \text{ pentru } n \rightarrow \infty \text{ cu } \lambda = wt.$$

**Repartiția geometrică.**

Spre deosebire de variabila aleatoare binomială care apare când fixăm un număr de repetări ale unei experiențe care poate consta în realizarea sau nerealizarea evenimentului  $A$  și numărăm numărul de realizări ale acestuia, în cazul variabilei geometrice numărăm numărul  $m$  de efectuări ale experienței (experiențe de tip Bernoulli, adică independente și repetate în aceleași condiții) până la prima realizare a evenimentului  $A$ . În acest caz variabila aleatoare  $X$  ia valorile  $X = k, k = 1, 2, \dots, m, \dots$  și avem

$$P(\{X = k\}) = pq^{k-1}, \quad q = 1 - p, \quad k = 1, 2, 3, \dots,$$

unde  $P(A) = p$  este probabilitatea de realizare a evenimentului  $A$ .

În acest caz

$$F(k) = P(\{X < k\}) = \sum_{j=1}^{k-1} pq^{j-1} = p \sum_{j'=0}^{k-2} pq^{j'} = p \frac{1 - q^{k-1}}{1 - q} = 1 - q^{k-1},$$

unde  $q = 1 - p$ .

Uneori ne interesează  $M' = M - 1$ , numărul de repetări ale experienței până la reușita ei:

$$P[M' = k] = P[M = k + 1] = (1 - p)^k p, \quad k = 0, 1, 2, \dots$$

Variabila aleatoare  $X$  va lua valoarea 1 dacă evenimentul se realizează în cadrul primei experiențe și deci  $P(\{X = 1\}) = p$ ;  $X$  va lua valoarea 2 dacă evenimentul  $A$  nu s-a realizat la prima experiență, dar se realizează la a doua experiență,  $P(\{X = 2\}) = P(\bar{A} \cap A) = P(\bar{A})P(A) = (1-p)p = qp$ . Analog,  $P(\{X = 3\}) = P(\bar{A} \cap \bar{A} \cap A) = P(\bar{A})P(\bar{A})P(A) = q^2p$  etc. Avem, evident

$$\sum_{k=1}^{\infty} P(\{X = k\}) = \sum_{k=1}^{\infty} pq^{k-1} = p \frac{1}{1 - q} = 1.$$

Calculăm media și dispersia variabilei aleatoare.

$$\begin{aligned} M[X] &= \sum_{k=1}^{\infty} k p q^{k-1} = p \sum_{k=1}^{\infty} k q^{k-1} = p \frac{d}{dq} \left( \sum_{k=1}^{\infty} q^k \right) = \\ &= p \frac{d}{dq} \left[ \frac{q}{1 - q} \right] = \frac{p}{(1 - q)^2} = \frac{1}{p}, \end{aligned}$$

ținând seama de proprietățile seriilor de puteri pentru  $|q| < 1$ .

$$D^2[X] = M[X^2] - (M[X])^2,$$

$$\begin{aligned} M[X^2] &= \sum_{k=1}^{\infty} k^2 p q^{k-1} = p \sum_{k=1}^{\infty} k^2 q^{k-1} = p \frac{d}{dq} \sum_{k=1}^{\infty} k q^k = \\ &= p \frac{d}{dq} \left[ \frac{q}{(1-q)^2} \right] = p \frac{2-p}{p^3} = \frac{2-p}{p^2}, \end{aligned}$$

și deci

$$D^2[X] = \frac{2-p}{p^2} - \frac{1}{p^2} = \frac{q}{p^2}.$$

În Figura 2.5 a) și b) desenăm densitatea de probabilitate generalizată pentru diferite valori ale lui  $p$ .

**Exemplul 2.5.4** Calculatorul  $A$  transmite un mesaj calculatorului  $B$  printr-o linie telefonică. Mesajul este codat astfel încât  $B$  detectează când se produc erori în cursul transmiterii mesajului. Dacă  $B$  detectează o eroare cere calculatorului  $A$  retransmiterea mesajului. Dacă probabilitatea ca transmiterea mesajului să fie eronată este  $q = 0, 1$ , care este probabilitatea ca mesajul să necesite mai mult de două transmisii.

Fiecare transmitere a mesajului urmează o repartiție binomială cu probabilitatea ca mesajul să fie corect  $p = 1 - q$ . Experiențele se repetă până când prima transmisie este corectă. Probabilitatea ca mesajul să necesite mai mult de două transmisii este

$$P(\{X > 2\}) = q^2 = 10^{-2}.$$

**Exemplul 2.5.5** Fie  $N$  numărul de apeluri pe care le face un calculator spre un terminal până când terminalul are un mesaj gata de a fi transmis. Dacă presupunem că terminalul produce mesaje care formează un șir de experiențe care urmează legea binomială, atunci  $N$  are o repartiție geometrică. Aflați media variabilei aleatoare care ia ca valori numărul de apeluri. Presupunem  $p = 0, 4$ .

$$M[X = N] = \sum_{k=1}^{\infty} k p q^{k-1} = \frac{1}{p} = 2, 5$$

Aceasta nu este o valoare pe care o poate lua  $N$ . Afirmatia ” $N$  este egală cu 2.5 în medie” nu are sens. Sensul afirmației este că media aritmetică a unui număr mare de experiențe va fi aproape de 2.5.

### Repartiția binomială cu exponent negativ.

Se spune că variabila aleatoare  $X$  are repartiție binomială cu exponent negativ, cu parametrii  $m$  și  $p$ , ( $m = 1, 2, \dots, 0 < p < 1$ ), dacă  $X$  poate lua valorile  $m, m+1, m+2, \dots$  iar

$$P(\{X = k\}) = C_{k-1}^{m-1} p^m q^{k-m}, \quad q = 1 - p.$$

Această repartiție apare în modele de tipul următor: să presupunem că s-a efectuat un număr de observații independente, în cursul fiecărei observații evenimentul  $A$  (de exemplu nefuncționarea unui subansamblu al unui aparat) poate să se producă cu probabilitatea  $p$ . Observațiile continuă până când evenimentul se produce de  $m$  ori și se caută probabilitatea pentru ca aceasta să se producă exact în decursul a  $k$  observații ( $k \geq m$ ).

Evenimentul  $\{X = k\}$  se scrie ca intersecție a două evenimente: în primele  $k - 1$  observații evenimentul  $A$  se produce de  $m - 1$  ori și în observația  $k$  se produce evenimentul  $A$ . Din schema lui Bernoulli se deduce că probabilitatea primului eveniment este  $C_{k-1}^{m-1} p^m q^{k-m}$  iar probabilitatea celui de-al doilea eveniment este egală cu  $p$ . Deci

$$P(\{X = k\}) = p C_{k-1}^{m-1} p^{m-1} q^{k-m} = C_{k-1}^{m-1} p^m q^{k-m}.$$

Numele acestei repartiții provine din faptul că probabilitatea căutată este coeficient în dezvoltarea în serie a lui

$$\left(\frac{1}{p} - \frac{q}{p}\right)^{-m} = p^m (1 - q)^{-m} = p^m \sum_{k=m}^{\infty} C_{k-1}^{m-1} q^{k-m} = \sum_{k=m}^{\infty} C_{k-1}^{m-1} p^m q^{k-m}.$$

Observăm că definiția acestei variabile aleatoare este corectă deoarece  $P(\{X = k\}) > 0$  și  $\sum_{k=m}^{\infty} C_{k-1}^{m-1} p^m q^{k-m} = 1$ .

Pentru a calcula media ținem seama că  $(1 - x)^{-m} = \sum_{k=m}^{\infty} C_{k-1}^{m-1} x^{k-m}$  și deci

$$\frac{x^m}{(1 - x)^m} = \sum_{k=m}^{\infty} C_{k-1}^{m-1} x^k \quad \text{dacă } |x| < 1, \quad (2.9)$$

$$\sum_{k=m}^{\infty} C_{k-1}^{m-1} x^{k-1} = \frac{d}{dx} \left( \frac{x^m}{(1 - x)^m} \right) = \frac{mx^{m-1}}{(1 - x)^{m+1}} \quad \text{dacă } |x| < 1,$$

adică

$$M[X] = \sum_{k=m}^{\infty} k C_{k-1}^{m-1} p^m q^{k-m} = p^m q^{-m+1} \sum_{k=m}^{\infty} k C_{k-1}^{m-1} q^{k-1} = p^m q^{-m+1} \frac{mq^{m-1}}{p^{m+1}} = \frac{m}{p},$$

$$M[X] = \frac{m}{p}.$$

Pentru calculul dispersiei folosim

$$M[X^2] = \sum_{k=m}^{\infty} k^2 C_{k-1}^{m-1} p^m q^{k-m} = p^m q^{-m+1} \sum_{k=m}^{\infty} k^2 q^{k-1}.$$

Pentru a calcula ultima sumă înmulțim (2.9) cu  $x$  și derivăm

$$\sum_{k=m}^{\infty} k^2 C_{k-1}^{m-1} x^{k-1} = \frac{d}{dx} \left[ \frac{mx^m}{(1 - x)^{m+1}} \right] = \frac{mx^{m-1}(m + x)}{(1 - x)^{m+2}},$$

deci

$$M[X^2] = \frac{m(m + q)}{p^2},$$

iar

$$D^2[X] = \frac{mq}{p^2}.$$

## 2.6 Funcția generatoare

În problemele în care apar variabile aleatoare nenegative se utilizează funcția generatoare a variabilei aleatoare  $X$ ,  $G_X(z)$  care se definește prin relația

$$G_X(z) = \sum_{k=0}^{\infty} p_k z^k, \quad (2.10)$$

unde  $P(\{X = k\}) = p_k, k = 0, 1, 2, \dots$ . Deci cunoscând probabilitățile  $p_k$  putem determina funcția generatoare. Deoarece  $\sum_{k=0}^{\infty} p_k = 1$ , seria de puteri (2.10) converge pentru  $|z| \leq 1$ . Pentru  $|z| < 1$  seria de puteri se poate deriva termen cu termen și obținem:

$$G_X^{(j)}(z) = \sum_{k=j}^{\infty} n(n-1)\dots(n-j+1)p_j z^{(n-k)} = \sum_{k=j}^{\infty} C_n^j j! p_j z^{(n-k)}.$$

Dacă în relația de mai sus facem  $z = 0$  obținem

$$G_X^{(j)}(0) = j! p_j \text{ sau } p_j = \frac{1}{j!} G_X^{(j)}(0).$$

Aceasta ne arată că putem determina toate probabilitățile  $p_k$  cu ajutorul funcției generatoare. Din această cauză  $G_X^{(j)}$  se numește funcție generatoare. În particular, punând  $z = 1$  în  $G'_X$  și în  $G''_X$  obținem:

$$M[X] = G'_X(1), \quad M[X^2] = G'_X(1) + G''_X(1).$$

**Exemplul 2.6.1** Funcția generatoare pentru variabila aleatoare Poisson cu parametru  $\lambda$  este dată de

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

Primele două derivate ale lui  $G_X(z)$  sunt date de

$$G'_X(z) = \lambda e^{\lambda(z-1)}; \quad G''_X(z) = \lambda^2 e^{\lambda(z-1)}.$$

De aici rezultă media și dispersia variabilei aleatoare Poisson

$$\begin{aligned} M[X] &= \lambda \\ D^2[X] &= \lambda^2 + \lambda - \lambda^2 = \lambda. \end{aligned}$$

## 2.7 Probleme propuse

**Problema 2.1** Se definește variabila aleatoare

$$X : \begin{pmatrix} -1 & 0 & 1 \\ 1/3 & 1/3 & 1/3 \end{pmatrix}.$$

Să se scrie tabloul de repartiție al variabilelor aleatoare  $X^2$ ,  $X + X^2$ ,  $X + X^3$ .

Indicație.  $P(\{X^2 = 0\}) = P(\{X = 0\}) = 1/3$ ,  $P(\{X^2 = 1\}) = P(\{X = 1\} \cup \{X = -1\}) = 1/3 + 1/3 = 2/3$ .

$$X^2 : \begin{pmatrix} 0 & 1 \\ 1/3 & 2/3 \end{pmatrix}.$$

$$X + X^2 : \begin{pmatrix} -1 & 0 & 1 & 2 \\ 0 & 1/3 & 0 & 2/3 \end{pmatrix}.$$

$$X + X^3 : \begin{pmatrix} -2 & -1 & 0 & 1 & 2 \\ 1/3 & 0 & 1/3 & 0 & 1/3 \end{pmatrix}.$$

**Problema 2.2** Fie

$$X : \begin{pmatrix} 0 & 1 & 2 & 3 & 4 \\ 0,15 & 0,45 & 0,20 & 0,15 & 0,05 \end{pmatrix}.$$

Să se calculeze:

- valoarea medie a variabilei aleatoare  $X$  și momentul inițial de ordin 2;
- dispersia;
- momentul centrat de ordin 3.

Indicație.

$$\text{a) } M[X] = \sum_1^5 x_i p_i = 1,5, \quad M[X^2] = \sum_1^5 x_i^2 p_i = 3,4.$$

$$\text{b) Notăm } m = M[X] = 1,5, \quad D^2[X] = M[(X - m)^2].$$

$$X - m : \begin{pmatrix} -1,5 & -0,5 & 0,5 & 1,5 & 2,5 \\ 0,15 & 0,45 & 0,20 & 0,15 & 0,05 \end{pmatrix}.$$

$$X - m : \begin{pmatrix} 0,25 & 2,25 & 6,25 \\ 0,65 & 0,30 & 0,05 \end{pmatrix}.$$

$$D^2[X] = M[(X - m)^2] = 1,15 \text{ sau } D^2[X] = M[X^2] - (M(X))^2.$$

$$\text{b) } M[(X - m)^3] = \sum_1^5 (x_i - m)^3 p_i,$$

$$(X - m)^3 : \begin{pmatrix} (-1,5)^3 & (-0,5)^3 & (0,5)^3 & (1,5)^3 & (2,5)^3 \\ 0,15 & 0,45 & 0,20 & 0,15 & 0,05 \end{pmatrix}.$$

astfel încât  $M[(X - m)^3] = 0,75$ .

**Problema 2.3** Fie  $X$  o variabilă aleatoare repartizată binomial.

a. Să se atate că

$$\frac{p_k}{p_{k-1}} = \frac{(n-k+1)p}{kq} = 1 + \frac{(n+1)p-k}{kq}$$

b. Să se atate că a. implică: (1)  $P(\{X = k\})$  este maximă pentru  $k_{max} = [(n+1)p]$ , unde  $[x]$  este partea întreagă a lui  $x$ ; (2) dacă  $(n+1)p$  este un întreg, atunci maximum este atins în  $k_{max}$  și  $k_{max} - 1$ .

Indicație. b. Impunem condițiile  $p_k/p_{k-1} > 1$ ,  $p_{k+1}/p_k < 1$ .

**Problema 2.4** Fie  $X$  o variabilă aleatoare repartizată geometric. Să se calculeze  $P(\{X > k\})$  și  $P(\{X \text{ este un număr par}\})$ .

Indicație.  $P(\{X > k\}) = 1 - P(\{X < k\}) - P(\{X = k\}) = 1 - (1 - q^{k-1})pq^{k-1} = q^k$ ;  
 $P(\sum_{k=1}^{\infty} \{X = 2k\}) = \sum_{k=1}^{\infty} P(\{X = 2k\}) = \sum_{k=1}^{\infty} pq^{2k-1} = \frac{p}{1-q^2} = \frac{1}{1+q}$ .

**Problema 2.5** Să se arate că variabila aleatoare geometrică are proprietatea de pierdere a memoriei

$$P(\{X \geq k+j | X > j\}) = P(\{X \geq k\}), \quad \forall j, k > 0$$

În ce sens are loc pierderea memoriei?

Indicație.  $P(\{X \geq k+j | X \geq j\}) = \frac{P(\{(X \geq k+j) \cap (X \geq j)\})}{P(\{X > j\})} = q^k$ . Pierderea memoriei are loc în sensul că probabilitatea realizării unui eveniment, legat de o experiență Bernoulli, după  $k+j-1$  nerealizări, știind că nu s-a realizat după  $j$  efectuări ale experienței, depinde numai de  $k$ .

**Problema 2.6** Fie  $X$  o variabilă aleatoare repartizată geometric. Să se calculeze  $P(\{X = k | X \leq m\})$ .

Indicație.  $q^{k-1}p/(1-q^m)$ ,  $1 \leq k \leq m$ .

**Problema 2.7** Fie  $X$  o variabilă aleatoare repartizată binomial.

a. Să se atate că

$$\frac{p_k}{p_{k-1}} = \frac{(n-k+1)p}{kq} = 1 + \frac{(n+1)p-k}{kq}$$

b. Să se atate că a. implică: (1)  $P(\{X = k\})$  este maximă pentru  $k_{max} = [(n+1)p]$ , unde  $[x]$  este partea întreagă a lui  $x$ ; (2) dacă  $(n+1)p$  este un întreg, atunci maximum este atins în  $k_{max}$  și  $k_{max} - 1$ .

Indicație. b. Impunem condițiile  $p_k/p_{k-1} > 1$ ,  $p_{k+1}/p_k < 1$ .

**Problema 2.4** Fie  $X$  o variabilă aleatoare repartizată geometric. Să se calculeze  $P(\{X > k\})$  și  $P(\{X \text{ este un număr par}\})$ .

Indicație.  $P(\{X > k\}) = 1 - P(\{X < k\}) - P(\{X = k\}) = 1 - (1 - q^{k-1})pq^{k-1} = q^k$ ;  
 $P(\sum_{k=1}^{\infty} \{X = 2k\}) = \sum_{k=1}^{\infty} P(\{X = 2k\}) = \sum_{k=1}^{\infty} pq^{2k-1} = \frac{p}{1-q^2} = \frac{1}{1+q}$ .



**Problema 2.8** Comparați aproximația obținută cu variabila Poisson cu probabilitatea binomială pentru  $k = 0, 1, 2, 3$  și  $n = 19, p = 0, 1$ ;  $n = 20, p = 0, 05$ ;  $n = 100, p = 0, 01$ .

**Problema 2.9** Fie  $X$  o variabilă aleatoare repartizată Poisson. Să se arate că pentru  $\lambda < 1$ ,  $P(\{X = k\})$  este maxim în  $k = 0$ ; pentru  $\lambda > 1$ ,  $P(\{X = k\})$  este maximum pentru  $[\lambda]$ ; dacă  $\lambda$  este întreg pozitiv,  $P(\{X = k\})$  este maximum pentru  $\lambda = k$  și  $k = \lambda - 1$ .

**Problema 2.10** Calculați media și dispersia unei variabile aleatoare discrete care ia valorile  $\{1, 2, \dots, n\}$  cu aceeași probabilitate.

Indicație.  $P(\{X = k\}) = \frac{1}{n}$ ,  $k = 1, 2, \dots, n$ .

**Problema 2.11** Să se calculeze probabilitățile marginale pentru următorii vectori aleatori bidimensionali:

$X \setminus Y$	-1	0	1
-1	1/6	0	1/6
0	0	1/3	0
1	1/6	0	1/6

$X \setminus Y$	-1	0	1
-1	1/9	1/9	1/9
0	1/9	1/9	1/9
1	1/9	1/9	1/9

$X \setminus Y$	-1	0	1
-1	0	0	1/3
0	0	1/3	0
1	1/3	0	0

Să se calculeze probabilitățile evenimentelor  $A = \{X \leq 0\}$ ,  $B = \{x \leq Y\}$  și  $C = \{X = -Y\}$ .

Indicație. În toate cazurile  $P(\{X = -1\}) = P(\{X = 0\}) = P(\{X = 1\}) = 1/3$ ,  $P(\{Y = -1\}) = P(\{Y = 0\}) = P(\{Y = 1\}) = 1/3$ .

**Problema 2.12** Un mesaj necesită  $X$  unități de timp pentru a fi transmis, unde  $X$  este o variabilă aleatoare repartizată geometric cu  $p_j = (1 - \alpha)\alpha^{j-1}$ ,  $j = 1, 2, \dots$ . Un singur nou mesaj este transmis într-o unitate de timp cu probabilitatea  $p$  și nici un mesaj cu probabilitatea  $1 - p$ . Fie  $K$  numărul de mesaje noi care apar de-a lungul transmiterii unui singur mesaj. Să se calculeze probabilitatea  $P(\{X = k\})$ . Să se calculeze  $M[X]$  și  $D^2[X]$ .

Indicație.  $P(\{X = k\}) = \frac{(1 - \alpha)}{\alpha(1 - \alpha(1 - p))} \left(\frac{p\alpha}{1 - \alpha(1 - p)}\right)^k$ .

**Problema 2.13** Numărul total de defecte care apar la un circuit urmează o distribuție Poisson cu parametrul  $\lambda$ . Presupunem că fiecare defect apare într-o anumită regiune  $R$  cu probabilitatea  $p$  și că apariția unui defect este independentă de apariția altor defecte. Să se determine probabilitatea ca numărul de defecte  $Y$  care apar în regiunea  $R$  să fie  $j$ .

Indicație. Folosind ecuația (2.8) avem

$$P(\{Y = j\}) = \sum_{k=0}^{\infty} P(\{Y = j/X = k\})P(\{X = k\}).$$

Defectele care apar în fiecare moment pot fi considerate ca experiențe Bernoulli care se realizează cu succes dacă defectul este în regiunea  $R$ . Dacă numărul total de defecte este  $X = k$ , atunci numărul de defecte care apar în regiunea  $R$  urmează o repartiție Bernoulli de parametrii  $k$  și  $p$ :

$$P(\{Y = j|X = k\}) = C_k^j p^j (1-p)^{k-j}, \quad 0 \leq j \leq k.$$

Atunci

$$\begin{aligned} P(\{Y = j\}) &= \sum_{k=j}^{\infty} \frac{k!}{j!(k-j)!} p^j (1-p)^{k-j} \frac{\lambda^k}{k!} e^{-\lambda} = \\ &= \frac{(\lambda p)^j e^{-\lambda}}{j!} \sum_{k=j}^{\infty} \frac{((1-p)\lambda)^{k-j}}{(k-j)!} = \frac{(\lambda p)^j e^{-\lambda}}{j!} e^{(1-p)\lambda} = \frac{(\lambda p)^j}{j!} e^{-\lambda p}. \end{aligned}$$

Astfel  $Y$  este o variabilă aleatoare repartizată Poisson cu media  $\lambda p$ .

# Capitolul 3

## Variabile aleatoare continue

### 3.1 Funcția de repartiție a unei variabile aleatoare unidimensionale

În cele ce urmează  $\{E, K, P\}$  este un câmp borelian de probabilitate, noțiune care a fost definită în Capitolul 1.8.

**Definiția 3.1.1** Funcția  $X : E \rightarrow \mathbb{R}$  se numește variabilă aleatoare dacă

$$\forall x \in \mathbb{R}, \quad \{e \in E | X(e) < x\} \in K. \quad (3.1)$$

Pentru simplificare vom nota  $\{X < x\} = \{e \in E | X(e) < x\}$ . Această condiție are loc totdeauna în cazul unei variabile aleatoare discrete (alegând eventual un câmp borelian convenabil). Din definiție și din proprietățile lui  $K$  (de a fi închis la complementară, reuniuni și intersecții numărabile), fiecare din mulțimile

$$\begin{aligned} &\{X \leq x\}, \quad \{X > x\}, \quad \{X \geq x\}, \quad \{a \leq X < b\}, \\ &\{a < X \leq b\}, \quad \{a < X < b\}, \quad \{a \leq X \leq b\}, \quad \forall x, a, b \in \mathbb{R}, \end{aligned} \quad (3.2)$$

aparține lui  $K$ , dacă (3.1) are loc și reciproc, apartenența la  $K$  a oricărei mulțimi (3.2) implică (3.1). Pentru exemplificare, să demonstrăm că pentru orice  $x \in \mathbb{R}$ , următoarele două afirmații sunt echivalente:

*i.*  $\{X < x\} \in K$ ;

*ii.*  $\{X \leq x\} \in K$ .

Să demonstrăm  $(i) \Rightarrow (ii)$ . Putem scrie

$$\{X \leq x\} = \bigcap_{n=1}^{\infty} \{X < x + 1/n\}.$$

Din (i) avem  $\{X < x + 1/n\} \in K$  și din faptul că familia  $K$  este închisă la intersecții numărabile, rezultă că  $\{X \leq x\} \in K$ .

Pentru implicația  $(ii) \Rightarrow (i)$ , observăm că

$$\{X < x\} = \bigcup_{n=1}^{\infty} \{X \leq x - 1/n\},$$

iar  $\{X \leq x - 1/n\} \in K$ . Echivalența  $\{X < x\} \in K \Leftrightarrow \{X > x\} \in K$ ,  $\forall x \in \mathbb{R}$ , rezultă din faptul că  $\{X \leq x\} = \{X > x\}$  și axioma a) din definiția câmpului borelian.

**Exemplul 3.1.1** Dacă  $E = \mathbb{R}$ , iar  $K$  este cel mai mic corp borelian ce conține toate intervalele  $(a, b)$ ,  $\forall a, b \in \mathbb{R}$ , elementele lui  $K$  se numesc *mulțimi boreliene*. Orice funcție  $f : \mathbb{R} \rightarrow \mathbb{R}$  continuă este o variabilă aleatoare, deoarece contraimagea unei mulțimi deschise este o mulțime deschisă. Se poate demonstra că acest rezultat se păstrează și în cazul mulțimilor boreliene (contraimagea unei mulțimi boreliene este boreliană).

Următoarele propoziții ne arată că operațiile uzuale cu funcții, aplicate variabilelor aleatoare, au ca rezultat tot variabile aleatoare.

**Propoziția 3.1.1** Fie  $X$  o variabilă aleatoare și  $c \in \mathbb{R}$ , atunci următoarele funcții:

1.  $X + c$ ;
2.  $cX$ ;
3.  $|X|$ ;
4.  $X^2$ ;
5.  $1/X$ ;

sunt variabile aleatoare.

**Demonstrație.** Vom transforma convenabil relația (3.1) în fiecare caz și vom folosi faptul că  $X$  este variabilă aleatoare.

$$1. \{X + c < x\} = \{X < x - c\} \in K, \quad \forall x \in \mathbb{R}.$$

$$2. \{cX < x\} = \begin{cases} \{X > x/c\}, & \text{dacă } c < 0 \\ \{X < x/c\}, & \text{dacă } c > 0 \end{cases} \in K.$$

Dacă  $c = 0$ , afirmația este imediată.

$$3. \{|X| < x\} = \{X < x\} \cap \{X > -x\} \in K.$$

$$4. \{X^2 < x\} = \{|X| < \sqrt{x}\} \in K, \quad \forall x > 0.$$

$$5. \left\{ \frac{1}{X} < x \right\} = \begin{cases} \{X < 0\} \cap \{X > 1/x\}, & \text{dacă } x < 0 \\ \{X < 0\}, & \text{dacă } x = 0 \\ \{X < 0\} \cup \{X > 1/x\}, & \text{dacă } x > 0 \end{cases} \in K. \quad \blacksquare$$

**Propoziția 3.1.2** Dacă  $X$  și  $Y$  sunt variabile aleatoare, atunci:

1.  $X - Y$ ;
2.  $X + Y$ ;
3.  $XY$ ;
4.  $X/Y$ ;
5.  $\max(X, Y)$ ;

6.  $\min(X, Y)$ ;

sunt variabile aleatoare.

**Demonstrație.** Toate afirmațiile 2-6, decurg din prima. Să demonstrăm 1. Folosind numărabilitatea mulțimii  $\mathbf{Q}$  și faptul că între două numere reale există cel puțin un număr rațional putem scrie:

$$\{X - Y < x\} = \{X < Y + x\} = \left( \bigcup_{n=1}^{\infty} (\{X < r_n\} \cap \{r_n - x < Y\}) \right) \in K,$$

unde  $r_n \in \mathbf{Q}$ .

Pentru 2, observăm că  $X + Y = X - (-Y)$ , iar pentru  $XY$ , afirmația rezultă din identitatea  $XY = \frac{1}{4}[(X + Y)^2 - (X - Y)^2]$ .

4 este o consecință a afirmației precedente și a Propoziției 3.1.1.

Ultimele două afirmații rezultă din egalitățile:

$$\max(X, Y) = \frac{1}{2}(X + Y + |X - Y|),$$

$$\min(X, Y) = \frac{1}{2}(X + Y - |X - Y|).$$

■

**Definiția 3.1.2**  $\{X_i\}$ ,  $i \in I$  este o familie de variabile aleatoare independente, dacă pentru orice  $J \subset I$ ,  $J$  finită și orice familie  $\{B_j\}$ ,  $j \in J$  de mulțimi boreliene (vezi Exemplul 3.1.1) are loc:

$$P(\{\bigcap_{j \in J} X_j^{-1}(B_j)\}) = \prod_{j \in J} P(\{X_j^{-1}(B_j)\}).$$

**Propoziția 3.1.3** Fie  $\{X_i\}$ ,  $i \in I$  o familie de variabile aleatoare independente și  $f_i : \mathbb{R} \rightarrow \mathbb{R}$  o familie de funcții continue. Atunci familia  $\{f_i \circ X_i\}$  constituie o familie de variabile aleatoare independente.

**Demonstrație.** Pentru orice  $J \subset I$  finită, are loc:

$$P(\{\bigcap_{j \in J} (f_j \circ X_j)^{-1}(B_j)\}) = P(\{\bigcap_{j \in J} X_j^{-1} \circ f_j^{-1}(B_j)\}) = \prod_{j \in J} P(\{X_j^{-1}(f_j^{-1}(B_j))\}).$$

Deoarece  $f_j$  este o funcție continuă, contraimaginea unei mulțimi boreliene este de asemenea boreliană, iar afirmația rezultă din faptul că  $X_j$  este variabilă aleatoare. ■

**Definiția 3.1.3** Funcția  $F : \mathbb{R} \rightarrow [0, 1]$ , definită prin

$$F(x) = P(\{X < x\}) \tag{3.3}$$

se numește funcția de repartiție a variabilei aleatoare  $X$ .

Dacă se particularizează definiția în cazul unei variabile aleatoare discrete, se obține funcția în scară dată în Capitolul 2.2.

**Propoziția 3.1.4** *Următoarele afirmații sunt adevărate:*

1. Dacă  $x_1 < x_2$ , atunci  $F(x_1) \leq F(x_2)$ ,  $\forall x_1, x_2 \in \mathbb{R}$ ;
2.  $F(x-0) = F(x)$ ,  $\forall x \in \mathbb{R}$  ( $F$  este continuă la stânga);
3.  $\lim_{x \rightarrow -\infty} F(x) = 0$ ;
4.  $\lim_{x \rightarrow +\infty} F(x) = 1$ ;

**Demonstrație.**

1. Observăm că  $\{X < x_2\} = \{X < x_1\} \cup \{x_1 \leq X < x_2\}$ , iar cele două evenimente sunt incompatibile. Aplicând probabilitatea peste ultima relație, găsim

$$F(x_2) = P(\{X < x_2\}) = F(x_1) + P(\{x_1 \leq X < x_2\}) \geq F(x_1),$$

deoarece din definiție,  $P(\{x_1 \leq X < x_2\}) \geq 0$ .

2. Fie  $x_n$  un șir crescător la  $x$ . Avem:

$$\{X < x\} = \{X < x_1\} \cup \left( \bigcup_{n=1}^{\infty} \{x_n \leq X < x_{n+1}\} \right).$$

Aplicând probabilitatea, găsim

$$F(x) = F(x_1) + \sum_{n=1}^{\infty} (F(x_{n+1}) - F(x_n))$$

deci seria precedentă este convergentă și are ca sumă limită șirului de sume parțiale.

$$\begin{aligned} F(x) &= F(x_1) + \lim_{n \rightarrow \infty} (F(x_2) - F(x_1) + F(x_3) - F(x_2) + \dots + F(x_{n+1}) - F(x_n)) = \\ &= \lim_{n \rightarrow \infty} F(x_{n+1}) = F(x-0). \end{aligned}$$

3. Dacă  $x_n$  este un șir descrescător la  $-\infty$ , atunci

$$\{X < x\} = \{x_1 \leq X < x\} \cup \left( \bigcup_{n=1}^{\infty} \{X_{n+1} \leq X < x_n\} \right).$$

Aplicând probabilitatea, rezultă

$$F(x) = F(x) - F(x_1) + \sum_{n=1}^{\infty} (F(x_n) - F(x_{n+1})),$$

de unde  $\lim_{n \rightarrow \infty} F(x_{n+1}) = 0$ .

4. Se constată că

$$\{X \leq \infty\} = \{X < x_1\} \cup \left( \bigcup_{n=1}^{\infty} \{x_n \leq X < x_{n+1}\} \right),$$

unde  $x_n$  este un șir crescător la  $+\infty$ . Procedând ca mai sus, găsim  $1 = \lim_{n \rightarrow \infty} F(x_n)$ . ■

**Observație.** Dacă  $x_1 < x_2$ , atunci

$$P(\{x_1 \leq X < x_2\}) = F(x_2) - F(x_1).$$

Afirmația rezultă folosind demonstrația punctului 1.

Folosind relația dintre probabilitatea unui eveniment și cea a evenimentului contrar, mai rezultă

$$P(\{X \geq x\}) = 1 - F(x).$$

**Observație.** Se poate demonstra că, reciproc, orice funcție  $F : \mathbb{R} \rightarrow \mathbb{R}$  având proprietățile 1-4, este funcția de repartiție a unei variabile aleatoare, pe un anumit câmp de probabilitate, de aceea vom spune că aceste proprietăți reprezintă o caracterizare a funcției de repartiție. De exemplu putem lua  $E = (0, 1)$  și  $K$  corpul borelian generat de intervalele deschise ale lui  $E$ , iar  $P$  măsura Lebesgue [ 22 ] pentru care vom schița modul de construcție. Notăm cu

$$\mathcal{D} = \left\{ \bigcup_{i \in I} (a_i, b_i) \mid (a_i, b_i) \cap (a_j, b_j) = \emptyset, I \subseteq \mathbb{N} \right\}, \quad \forall a_i, b_i \in (0, 1).$$

Elementele lui  $\mathcal{D}$  se numesc *mulțimi deschise*. Definim aplicația

$$P_0 : \mathcal{D} \rightarrow [0, 1],$$

$$P_0\left(\bigcup_{i \in I} (a_i, b_i)\right) = \sum_{i \in I} (b_i - a_i), \quad \forall a_i, b_i \in (0, 1).$$

Se observă că dacă  $I$  are un singur element, condiția de mai sus devine:

$$P_0(a, b) = b - a, \quad \forall a, b \in (0, 1)$$

formulă care dă lungimea intervalului  $(a, b)$ ; deci măsura Lebesgue a unei reuniuni numărabile de intervale disjuncte este suma lungimilor lor. Seria din membrul al doilea are șirul sumelor parțiale  $s_n$  mărginit. Într-adevăr, ordonând intervalele din șirul sumelor parțiale, putem presupune  $0 \leq a_1 < a_2 < \dots < a_n$  și  $b_n \leq 1$ . Atunci

$$s_n = \sum_{i=1}^n (b_i - a_i) \leq \sum_{i=1}^n (b_i - a_i) + \sum_{i=1}^{n-1} (a_{i+1} - b_i) = b_n - a_1 \leq 1 - 0 = 1.$$

Fie  $K$  cel mai mic corp borelian (se poate arăta că există), care conține  $\mathcal{D}$ , pe care îl notăm  $K$ ; aplicația  $P_0$  poate fi prelungită la o probabilitate pe  $K$ , astfel încât să aibă loc  $\forall D \in \mathcal{D}, P(D) = P_0(D)$ .

Fie  $F$  o funcție care satisface condițiile propoziției precedente; pentru simplificare să presupunem că  $F$  este strict monotonă și continuă (deci este inversabilă) și notăm  $X = F^{-1}$ . Atunci  $F$  este funcția de repartiție a variabilei aleatoare  $X$ . Într-adevăr,

$$\begin{aligned} P(\{y \in (0, 1) | X(y) < x\}) &= P(\{y \in (0, 1) | F^{-1}(y) < x\}) = \\ &= P_0(\{y \in (0, 1) | y < F(x)\}) = F(x) - 0 = F(x), \end{aligned}$$

unde  $P$  este măsura Lebesgue introdusă anterior.

**Propoziția 3.1.5** Pentru orice variabilă aleatoare  $X$ , are loc

$$P(\{X = x\}) = F(x+0) - F(x).$$

**Demonstrație.** Fie  $x_1 > x_2 > \dots > x_n > x_{n+1} > \dots$  un șir convergent la  $x$ . Atunci are loc

$$\{X \geq x\} = \{X = x\} \cup \{X \geq x_1\} \cup \left( \bigcup_{n=1}^{\infty} \{x_{n+1} \leq X < x_n\} \right).$$

Aplicând probabilitatea, găsim

$$\begin{aligned} 1 - F(x) &= P(\{X = x\}) + 1 - F(x_1) + \lim_{n \rightarrow \infty} (F(x_1) - F(x_2) + \dots + F(x_n) - F(x_{n+1})) = \\ &= P(\{X = x\}) + 1 - \lim_{n \rightarrow \infty} F(x_n) = P(\{X = x\}) + 1 - F(x+0). \end{aligned}$$

Deci afirmația este adevărată. ■

Din propoziția precedentă deducem că următoarele afirmații sunt echivalente:

- i.  $P(\{X = x\}) = 0$ ;
- ii.  $F$  este continuă în  $x$ .

**Propoziția 3.1.6** O funcție de repartiție are o mulțime cel mult numărabilă de puncte de discontinuitate de prima speță.

**Demonstrație.** Fiind monotonă, funcția de repartiție  $F$  nu poate avea decât discontinuități de prima speță (deci în orice punct  $x \in R$ , există  $F(x-0) = F(x)$  și  $F(x+0)$  finite). Deoarece  $0 \leq F(x) \leq 1$ ,  $F$  nu poate avea un salt mai mare ca  $1/2$ , cel mult trei salturi cuprinse între  $1/4$  și  $1/2$ , iar în general cel mult  $2^n - 1$  salturi cuprinse între  $\frac{1}{2^n}$  și  $\frac{1}{2^{n-1}}$ . Renumerotând, obținem mulțimea salturilor cel mult numărabilă. ■

O variabilă aleatoare cu funcție de repartiție continuă va fi numită *variabilă aleatoare continuă*. Dacă  $X$  este o variabilă aleatoare continuă, iar  $A$  este o mulțime cel mult numărabilă, atunci probabilitatea ca  $X$  să ia valori în  $A$  este nulă, adică

$$P(\{e \in E | X(e) \in A\}) = P(\{X^{-1}(A)\}) = 0.$$

**Definiția 3.1.4** Fie  $X$  o variabilă aleatoare cu funcția de repartiție  $F$  și  $q \in \mathbb{N}^*$ ; numerele  $c_i, i = 1, \dots, q-1$  definite prin

$$F(c_i) \leq \frac{i}{q}, \quad F(c_i + 0) \geq \frac{i}{q}$$

se numesc  $q$ -cvantile.



q-cvartilele sunt unic determinate dacă  $F$  este continuă și strict crescătoare ca soluții ale ecuației

$$F(c_i) = \frac{i}{q}, \quad i = 1 \dots q - 1.$$

Pentru  $q = 2$  se obține *mediana*, pe care o vom nota  $m_e$  și care se caracterizează prin

$$F(m_e) \leq \frac{1}{2}, \quad F(m_e + 0) \geq \frac{1}{2}, \quad (3.4)$$

iar în cazul continuității lui  $F$ ,

$$F(m_e) = \frac{1}{2}.$$

Pentru  $q = 4$  se obțin *cvartilele*, pentru  $q = 10$ , *decilele* etc.

### Funcția de repartiție condiționată.

În câmpul de probabilitate  $\{E, K, P\}$  considerăm  $A \in K$ , cu proprietatea  $P(A) \neq 0$ . Reamintim că în Capitolul 1.2 s-a definit noțiunea de probabilitate condiționată prin formula

$$P(B|A) = P_A(B) = \frac{P(A \cap B)}{P(A)}, \quad \forall B \in K.$$

**Definiția 3.1.5** *Dată o variabilă aleatoare  $X$ , numim funcție de repartiție condiționată de evenimentul  $A$ , funcția dată de*

$$F(x|A) = P(\{X < x\}|A) = \frac{P(\{X < x\} \cap A)}{P(A)}.$$

Toate proprietățile funcției de repartiție se păstrează; menționăm

$$F(+\infty|A) = 1; \quad F(-\infty|A) = 0.$$

Să demonstrăm următoarea formulă

$$P(\{a \leq X < b\}|A) = F(b|A) - F(a|A). \quad (3.5)$$

Într-adevăr, dacă  $a < b$  avem  $\{X < a\} \subset \{X < b\}$  și

$$\begin{aligned} P(\{a \leq X < b\}|A) &= \frac{P(\{a \leq X < b\} \cap A)}{P(A)} = \frac{P((\{X < b\} \cap A) \setminus (\{X < a\} \cap A))}{P(A)} = \\ &= \frac{P(\{X < b\} \cap A) - P(\{X < a\} \cap A)}{P(A)} = F(b|A) - F(a|A). \end{aligned}$$

Ne interesează în continuare, pentru numeroasele aplicații practice, unele cazuri particulare ale evenimentului  $A$ .

1. Dacă  $A = \{X < a\}$  și  $F(a) = P(\{X < a\}) \neq 0$ , atunci

$$F(x|A) = \frac{P(\{X < x\} \cap \{X < a\})}{P(\{X < a\})} = \begin{cases} \frac{F(x)}{F(a)}, & \text{dacă } x \leq a \\ 1, & \text{dacă } x > a. \end{cases}$$

Deci obținem

$$F(x|\{X < a\}) = \begin{cases} \frac{F(x)}{F(a)}, & \text{dacă } x \leq a \\ 1, & \text{dacă } x > a. \end{cases} \quad (3.6)$$

În Figura 3.1 sunt ilustrate cele două funcții.

2. Fie  $A = \{a \leq X < b\}$  astfel ca  $P(A) = F(b) - F(a) \neq 0$ . Deducem imediat că

$$F(x|\{a \leq X < b\}) = \begin{cases} 0, & \text{dacă } x \leq a, \\ \frac{F(x) - F(a)}{F(b) - F(a)}, & \text{dacă } a < x \leq b, \\ 1, & \text{dacă } x > b. \end{cases} \quad (3.7)$$

Demonstrăm următoarea formulă, care se dovedește utilă în aplicații. În ipotezele precedente are loc

$$P(A|\{a \leq X < b\}) = \frac{(F(b|A) - F(a|A))P(A)}{F(b) - F(a)}. \quad (3.8)$$

Aceasta rezultă imediat

$$\begin{aligned} P(A|\{a \leq X < b\}) &= \frac{P(A \cap \{a \leq X < b\})}{P(\{a \leq X < b\})} = \\ &= \frac{P(\{a \leq X < b\}|A)P(A)}{F(b) - F(a)} = \frac{(F(b|A) - F(a|A))P(A)}{F(b) - F(a)}. \end{aligned}$$

În ultima relație s-a folosit (3.5).

## 3.2 Densitatea de probabilitate. Repartiția normală

Fie  $\{E, K, P\}$  un câmp borelian de probabilitate. Considerăm o clasă de variabile aleatoare  $X$  pentru care există o funcție  $f : \mathbb{R} \rightarrow \mathbb{R}_+$  cu un număr finit de puncte de discontinuitate de prima speță, ce satisface relația

$$F(x) = \int_{-\infty}^x f(t)dt, \quad (3.9)$$

unde  $F(x)$  este funcția de repartiție a variabilei  $X$ .

Funcția  $f$  se numește *densitate de probabilitate*.

Dacă  $f$  este continuă în  $x \in \mathbb{R}$ , atunci  $F$  este derivabilă în  $x$  și

$$F'(x) = f(x).$$

Acest lucru rezultă imediat dacă se aplică teorema de medie în integrala Riemann și continuitatea lui  $f$ . Într-adevăr,

$$\lim_{\Delta x \rightarrow 0} \frac{F(x + \Delta x) - F(x)}{\Delta x} = \lim_{\Delta x \rightarrow 0} \frac{\int_x^{x+\Delta x} f(t)dt}{\Delta x} = f(x).$$

Dacă  $a, b \in \mathbb{R}$  și  $F$  este continuă, atunci

$$P(\{a \leq X < b\}) = \int_a^b f(x)dx.$$

Dacă în relația (3.9) trecem la limită pentru  $x$  tinzând la  $\infty$  și folosim faptul că  $\lim_{x \rightarrow \infty} F(x) = 1$ , deducem

$$\int_{-\infty}^{+\infty} f(t)dt = 1. \quad (3.10)$$

Reciproc, dacă o funcție  $f : \mathbb{R} \rightarrow \mathbb{R}_+$ , cu un număr finit de puncte de discontinuitate de prima speță, satisface (3.10), atunci ea este integrabilă pe orice interval de forma  $(-\infty, x)$ ,  $\forall x \in \mathbb{R}$ , deoarece

$$\int_{-\infty}^x f(x)dt \leq \int_{-\infty}^{+\infty} f(t)dt = 1$$

și funcția  $F : \mathbb{R} \rightarrow \mathbb{R}$ , definită prin

$$F(x) = \int_{-\infty}^x f(t)dt,$$

satisface condițiile propoziției (3.1.4), deci este o funcție de repartiție, dacă ținem cont de observația făcută după această propoziție.

**Repartiția uniformă.** Vom nota cu  $X : U(a, b)$  o variabilă aleatoare uniform repartizată pe intervalul  $(a, b)$ ,  $\forall a, b \in \mathbb{R}$ , dacă densitatea de probabilitate este dată de

$$f(x) = \begin{cases} \frac{1}{b-a}, & \text{dacă } a \leq x \leq b \\ 0, & \text{în rest.} \end{cases}$$

Se constată imediat că este îndeplinită condiția (3.10). Funcția de repartiție este dată de

$$F(x) = \int_{-\infty}^x f(t)dt = \begin{cases} 0, & \text{dacă } x \leq a, \\ \frac{x-a}{b-a}, & \text{dacă } a < x \leq b, \\ 1, & \text{dacă } x > b. \end{cases}$$

Graficele celor două funcții sunt reprezentate în figurile 3.2 și 3.3.

**Exemplul 3.2.1** Dacă efectuăm măsurători de precizie, iar rezultatul este cuprins între  $k$  și  $k+1$  unități, convenind să-l aproximăm cu  $k+1/2$ , comitem o eroare care poate fi presupusă uniform repartizată pe intervalul  $(-1/2, 1/2)$ , deci are densitatea

$$f(x) = \begin{cases} 1, & \text{dacă } x \in [-1/2, 1/2], \\ 0, & \text{în rest.} \end{cases}$$

**Repartiția normală.** Variabila aleatoare  $X$  este distribuită normal cu parametrii  $m \in \mathbb{R}$ ,  $\sigma > 0$  și vom nota  $X : N(m, \sigma^2)$ , dacă are densitatea de probabilitate

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-m)^2}{2\sigma^2}}, \quad \forall x \in \mathbb{R}. \quad (3.11)$$

Observăm că  $f(x) \geq 0$ . Pentru calculul integralei din condiția (3.10) facem schimbarea de variabilă  $y = \frac{x-m}{\sigma}$  și obținem

$$\int_{-\infty}^{\infty} f(x) dx = \frac{1}{\sqrt{2\pi}\sigma} \int_{-\infty}^{\infty} e^{-\frac{(x-m)^2}{2\sigma^2}} dx = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{-\frac{y^2}{2}} dy = 1.$$

Pentru calculul ultimei integrale vezi Anexa 3.

Dacă  $m = 0$  și  $\sigma = 1$ , repartiția se mai numește *normată* și are densitatea

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}. \quad (3.12)$$

Graficul este cunoscut sub numele de "clopotul lui Gauss". Se constată că acesta este simetric față de dreapta  $x = m$ , pentru  $x = m$  funcția  $f$  are maxim egal cu  $f(m) = \frac{1}{\sqrt{2\pi}\sigma}$ , iar punctele  $m \pm \sigma$  sunt puncte de inflexiune. Pentru  $\sigma$  constant și  $m$  variabil, graficul se translează corespunzător. Dacă  $m$  este constant, iar  $\sigma$  variabil se constată că punctul de maxim variază invers proporțional în raport cu  $\sigma$ . În Figura 3.4 se poate constata cum variază densitatea în funcție de  $\sigma$ . Funcția de repartiție  $F$  are graficul dat de Figura 3.5

și se poate determina numeric, dacă se cunosc valorile **funcției lui Laplace**, care se definește prin

$$\Phi(z) = \frac{1}{\sqrt{2\pi}} \int_0^z e^{-\frac{x^2}{2}} dx, \quad \forall z \in \mathbb{R}.$$

Se verifică ușor că  $\Phi(-z) = -\Phi(z)$ , ceea ce permite tabelarea funcției doar pentru valori pozitive. Mai observăm că are loc relația

$$\lim_{z \rightarrow \infty} \frac{1}{\sqrt{2\pi}} \int_0^z e^{-\frac{x^2}{2}} dx = \frac{1}{2}. \quad (3.13)$$

Să exprimăm funcția de repartiție cu ajutorul funcției lui Laplace. În integrala  $F(x) = \int_{-\infty}^x f(t) dt$  facem schimbarea de variabilă  $\frac{t-m}{\sigma} = u$  și obținem

$$\begin{aligned} F(x) &= \frac{1}{\sqrt{2\pi}\sigma} \int_{-\infty}^{\frac{x-m}{\sigma}} e^{-\frac{u^2}{2}} \sigma du = \\ &= \frac{1}{\sqrt{2\pi}} \left( \int_{-\infty}^0 e^{-\frac{u^2}{2}} du + \int_0^{\frac{x-m}{\sigma}} e^{-\frac{u^2}{2}} du \right) = \frac{1}{2} + \Phi\left(\frac{x-m}{\sigma}\right). \end{aligned}$$

În ultima egalitate s-a folosit relația (3.13). Se obține astfel formula

$$F(x) = \frac{1}{2} + \Phi\left(\frac{x-m}{\sigma}\right). \quad (3.14)$$

Din (3.14), folosind faptul că  $P(\{a \leq X < b\}) = F(b) - F(a)$ , deducem

$$P(\{a \leq X < b\}) = \Phi\left(\frac{b-m}{\sigma}\right) - \Phi\left(\frac{a-m}{\sigma}\right).$$

Probabilitatea ca abaterea față de  $m$ , notată  $|X - m|$  să nu depășească  $\epsilon > 0$ , este dată de

$$P(\{|X - m| < \epsilon\}) = 2\Phi\left(\frac{\epsilon}{\sigma}\right).$$

**Regula celor  $3\sigma$ .** O variabilă normal repartizată  $X : N(m, \sigma^2)$  ia valori semnificative în intervalul  $(m - 3\sigma, m + 3\sigma)$ . Într-adevăr,  $P(\{|X - m| \geq 3\sigma\}) = 1 - P(\{|X - m| < 3\sigma\}) = 1 - 2\Phi(3) = 0,0027$ , valoare care în unele situații poate fi neglijată.

**Exemplul 3.2.2** Durata de funcționare a unei baterii este o variabilă aleatoare, notată  $X$ , repartizată normal  $N(m, \sigma^2)$ , unde  $m = 120$  zile reprezintă timpul mediu de funcționare, iar  $\sigma = 10$  zile reprezintă abaterea față de medie (aceste noțiuni vor fi introduse și studiate și în cazul continuu în Capitolul 3.4). Determinați

- a. probabilitatea ca bateria să funcționeze cel puțin 100 de zile;
- b. probabilitatea ca bateria să funcționeze între 100 și 150 de zile;
- c. intervalul de timp în care se poate presupune că bateria funcționează aproape sigur.

a.  $P(\{X \geq 100\}) = 1 - P(\{X < 100\}) = 1 - F(100) = 1 - \left(\frac{1}{2} + \Phi\left(\frac{100-120}{10}\right)\right) = \frac{1}{2} + \Phi(2) = 0,97725$ ;

b.  $P(\{100 \leq X \leq 150\}) = \Phi\left(\frac{150-120}{10}\right) - \Phi\left(\frac{100-120}{10}\right) = \Phi(3) + \Phi(2) = 0,9759$ ;

c. Aplicând regula celor  $3\sigma$ , găsim intervalul căutat de forma  $|X - m| < 3\sigma$ , deci bateria funcționează aproape sigur între 90 și 150 zile.

**Exemplul 3.2.3** Repartiția erorilor accidentale de măsurare. Alte tipuri de erori decât cele datorate aproximărilor (în cazul măsurătorilor de precizie) sunt cele accidentale. Notăm cu  $X$  eroarea comisă la efectuarea unei măsurători, care este o variabilă aleatoare. Dacă valoarea exactă a mărimii este  $r$ , prin efectuarea a  $n$  măsurători obținem valorile  $r_1, r_2, \dots, r_n$  aproximative și erorilor  $e_k = r - r_k, k = 1, \dots, n$ . Să determinăm o funcție derivabilă,  $f$ , care să fie densitatea de probabilitate a variabilei  $X$ . Probabilitatea ca eroarea să fie cuprinsă în intervalul  $[e_k, e_k + h_k], k = 1, \dots, n$ , cu  $h_k$  suficient de mic poate fi aproximată cu  $f(e_k)h_k$ , iar în cele  $n$  măsurători independente este produsul

$$p(r) = h_1 f(e_1) h_2 f(e_2) \dots h_n f(e_n) = h_1 h_2 \dots h_n f(r - r_1) \dots f(r - r_n).$$

*Legea numerelor mari* (care va fi studiată amănunțit în Capitolul 4) ne permite să luăm ca valoare cea mai probabilă media aritmetică, notată

$$\bar{r} = \frac{1}{n}(r_1 + \dots + r_n).$$

Deci  $\bar{r}$  este un punct de maxim pentru  $p(r)$ . Notăm cu  $g(r) = f(r - r_1) \dots f(r - r_n)$ . Din condiția  $p'(\bar{r}) = 0$ , rezultă  $g'(\bar{r}) = 0$ . Are loc

$$\frac{g'(r)}{g(r)} = \frac{\sum_{i=1}^n f(r - r_1) \dots f(r - r_{i-1}) f'(r - r_i) f(r - r_{i+1}) \dots f(r - r_n)}{f(r - r_1) \dots f(r - r_n)} =$$

$$= \sum_{i=1}^n \frac{f'(r - r_i)}{f(r - r_i)}.$$

Din definiția mediei, rezultă  $(\bar{r} - r_1) + \dots + (\bar{r} - r_n) = 0$ , deci  $\sum_{k=1}^n (\bar{r} - r_k) = 0$ . Putem atunci scrie

$$0 = \frac{g'(\bar{r})}{g(\bar{r})} = \sum_{k=1}^n \frac{f'(\bar{r} - r_k)}{f(\bar{r} - r_k)} - c \sum_{k=1}^n (\bar{r} - r_k) = \sum_{k=1}^n \left( \frac{f'(\bar{r} - r_k)}{f(\bar{r} - r_k)} - c(\bar{r} - r_k) \right).$$

Punem condiția ca termenul general al sumei să se anuleze. Aceasta conduce la ecuația diferențială

$$\frac{f'(x)}{f(x)} = cx$$

cu soluția  $f(x) = ke^{\frac{cx^2}{2}}$ . Să determinăm constantele  $k$  și  $c$ , astfel ca  $f(x)$  să fie o densitate de probabilitate. Punând condiția (3.10), găsim  $c < 0, k > 0$ . Dacă notăm  $\sigma^2 = -\frac{1}{c}$ , găsim  $k = \frac{1}{\sqrt{2\pi}\sigma}$  și

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{x^2}{2\sigma^2}}.$$

Deci erorile accidentale de măsurare se repartizează după legea  $N(0, \sigma^2)$ . Constanta  $h = \frac{1}{\sqrt{2\pi}\sigma}$  se numește *precizia măsurătorii*.

**Exemplul 3.2.4** O variabilă aleatoare  $X$  este repartizată normal  $N(0, \sigma^2)$ . Dat un interval  $(\alpha, \beta)$ , cu  $\alpha < 0, \beta > 0$ , să determinăm valoarea  $\sigma$ , astfel ca probabilitatea  $P(\{X \in (\alpha, \beta)\})$  să fie maximă. Are loc evident

$$P(\{\alpha < X < \beta\}) = \Phi\left(\frac{\beta}{\sigma}\right) - \Phi\left(\frac{\alpha}{\sigma}\right) = \frac{1}{\sqrt{2\pi}} \left( \int_0^{\frac{\beta}{\sigma}} e^{-\frac{t^2}{2}} dt - \int_0^{\frac{\alpha}{\sigma}} e^{-\frac{t^2}{2}} dt \right).$$

Anulăm derivata în raport cu  $\sigma$  a integralei cu parametru și găsim

$$\frac{1}{\sqrt{2\pi}} \left( e^{-\frac{\beta^2}{2\sigma^2}} \left(-\frac{\beta^2}{\sigma^2}\right) - e^{-\frac{\alpha^2}{2\sigma^2}} \left(-\frac{\alpha^2}{2\sigma^2}\right) \right) = 0.$$

Deducem

$$\sigma = \sqrt{\frac{\beta^2 - \alpha^2}{2(\ln \beta - \ln |\alpha|)}}.$$

În practică apar des situații în care o variabilă aleatoare continuă este suma dintre o variabilă aleatoare discretă și o variabilă aleatoare continuă. Ca aplicație a formulei probabilității totale se poate deduce densitatea de probabilitate.

**Exemplul 3.2.5** Fie  $X$  o variabilă aleatoare discretă care are repartiția:

$$X : \begin{pmatrix} x_i \\ p_i \end{pmatrix}, \quad i = 1, \dots, n$$

și  $Y$  o variabilă aleatoare continuă care are densitatea de probabilitate  $f(x)$ . Să determinăm densitatea de probabilitate a variabilei aleatoare  $Z = X + Y$ , dacă  $X$  și  $Y$  sunt independente. Considerăm sistemul complet de evenimente  $A_i = \{X = x_i\}$ ,  $i = 1, \dots, n$  și să exprimăm funcția de repartiție a variabilei aleatoare  $Z$ .

$$\begin{aligned} F_Z(x) &= P(\{X + Y < x\}) = P\left(\bigcup_{i=1}^n (\{X + Y < x\} \cap A_i)\right) = \\ &= \sum_{i=1}^n P(\{Y + x_i < x\})P(A_i) = \sum_{i=1}^n p_i P(\{Y < x - x_i\}). \end{aligned}$$

Prin derivare găsim

$$f_Z(x) = \sum_{i=1}^n p_i f_Y(x - x_i).$$

**Exemplul 3.2.6** O variabilă aleatoare continuă are densitatea de probabilitate  $f_1(x)$  cu probabilitatea  $p_1$  și densitatea de probabilitate  $f_2(x)$  cu probabilitatea  $p_2$ , cu  $p_1 + p_2 = 1$ . Găsiți expresia densității de probabilitate și a funcției de repartiție a variabilei  $X$ . Considerăm sistemul complet de evenimente  $A_i$ ,  $i = 1, 2$ , unde evenimentul  $A_i$  reprezintă faptul că  $X$  are densitatea de probabilitate  $f_i$ . Atunci funcția de repartiție este dată de

$$\begin{aligned} F(x) &= P(\{X < x\}) = P(A_1)P(\{X < x\}|A_1) + P(A_2)P(\{X < x\}|A_2) = \\ &= p_1 F_1(x) + p_2 F_2(x). \end{aligned}$$

Funcția de densitate este atunci

$$f(x) = p_1 f_1(x) + p_2 f_2(x).$$

**Densități de probabilitate condiționate.** Fie  $X$  o variabilă aleatoare continuă și  $A \in K$ , cu probabilitatea  $P(A) \neq 0$ . Presupunem că  $X$  are densitatea de probabilitate  $f$ , atunci *densitatea de probabilitate a lui  $X$ , condiționată de  $A$*  este dată în punctele ei de continuitate de derivata funcției de repartiție condiționată

$$f(x|A) = F'(x|A).$$

1. Dacă  $A = \{X < a\}$ , prin derivarea formulei (3.6) se obține

$$f(x|A) = \begin{cases} \frac{f(x)}{F(a)}, & \text{dacă } x \leq a, \\ 0, & \text{dacă } x > a. \end{cases} \quad (3.15)$$

2. Dacă  $A = \{a \leq X < b\}$  prin derivarea relației (3.7) găsim

$$f(x|\{a \leq X < b\}) = \begin{cases} \frac{f(x)}{F(b) - F(a)}, & \text{dacă } a < x \leq b, \\ 0, & \text{în rest.} \end{cases} \quad (3.16)$$

**Exemplul 3.2.7** Fie  $X : N(m, \sigma^2)$ . Să determinăm  $f(x|\{|X - m| \leq k\sigma\})$ . Observăm că  $P(\{|X - m| \leq k\sigma\}) = 2\Phi(k)$  și înlocuim în (3.16). Deci

$$f(x|\{|X - m| \leq k\sigma\}) = \begin{cases} \frac{1}{\sqrt{2\pi}\sigma 2\Phi(k)} e^{-\frac{(x-m)^2}{2\sigma^2}}, & \text{dacă } |x - m| \leq k\sigma \\ 0, & \text{în rest} \end{cases}.$$

**Exemplul 3.2.8** Fie  $T$  variabila aleatoare care dă timpul de funcționare până la prima defectare. Să determinăm  $F(x|\{T \geq t\})$  și  $f(x|\{T \geq t\})$ . Observăm că  $P(\{T \geq t\}) = 1 - F(t)$ , probabilitate care va fi definită ca funcție de fiabilitate în Capitolul 3.7. Găsim

$$F(x|\{T \geq t\}) = \begin{cases} \frac{F(x) - F(t)}{1 - F(t)}, & \text{dacă } x \geq t, \\ 0, & \text{dacă } x < t. \end{cases}$$

$$f(x|\{T \geq t\}) = \frac{f(x)}{1 - F(t)} = \frac{f(x)}{\int_t^{+\infty} f(x)dx}, \quad x \geq t.$$

#### Formula probabilității totale. Formula lui Bayes.

Vom da versiunea continuă a formulelor prezentate în Capitolul 1.6. Considerăm evenimentul  $\{X = x\}$  unde  $X$  este o variabilă aleatoare continuă, deci admite funcție de repartiție continuă. Atunci avem  $P(\{X = x\}) = 0$ . În unele situații putem totuși defini  $P(A|\{X = x\})$ , în sensul existenței următoarei limite

$$\begin{aligned} P(A|\{X = x\}) &= \lim_{\Delta x \rightarrow 0} P(A|\{x \leq X < x + \Delta x\}) = \\ &= \lim_{\Delta x \rightarrow 0} \frac{(F(x + \Delta x|A) - F(x|A))P(A)}{F(x + \Delta x) - F(x)} = \frac{f(x|A)P(A)}{f(x)}. \end{aligned}$$

În șirul de egalități s-a folosit formula (3.8). Dacă integrăm pe  $\mathbb{R}$  relația

$$P(A|\{X = x\})f(x) = f(x|A)P(A)$$

obținem

$$\begin{aligned} \int_{-\infty}^{+\infty} P(A|\{X = x\})f(x)dx &= \int_{-\infty}^{+\infty} f(x|A)P(A)dx = \\ &= P(A)(F(+\infty|A) - F(-\infty|A)) = P(A). \end{aligned}$$

Relația obținută se numește *formula probabilității totale* în cazul continuu și este

$$P(A) = \int_{-\infty}^{+\infty} P(A|\{X = x\})f(x)dx. \quad (3.17)$$

Formula lui Bayes în cazul continuu este

$$f(x|A) = \frac{P(A|\{X = x\})f(x)}{\int_{-\infty}^{+\infty} P(A|\{X = x\})f(x)dx}.$$



**Exemplul 3.2.9** Densitatea de probabilitate a defectării unei valve radio în momentul deschiderii este  $q(v)$ . Voltajul  $V$  este aleator și are repartiție  $N(m, \sigma^2)$ . Să găsim probabilitatea evenimentului  $A$ , care semnifică faptul că la momentul deschiderii valva s-a defectat. Vom folosi formula (3.17)

$$P(A) = \int_{-\infty}^{+\infty} q(v)f(v)dv = \frac{1}{\sqrt{2\pi\sigma}} \int_{-\infty}^{+\infty} q(v)e^{-\frac{(v-m)^2}{2\sigma^2}} dv.$$

### 3.3 Funcția de repartiție multidimensională. Transformări

Fie  $\{E, K, P\}$  un câmp borelian de probabilitate și  $X_1, \dots, X_n$ , variabile aleatoare.

**Definiția 3.3.1** Funcția notată  $(X_1, \dots, X_n) : E \rightarrow \mathbb{R}^n$ , definită prin

$$(X_1, \dots, X_n)(e) = (X_1(e), \dots, X_n(e)),$$

se numește variabilă aleatoare  $n$ -dimensională.

Pentru  $(x_1, \dots, x_n) \in \mathbb{R}^n$ , notăm

$$\{X_1 < x_1, X_2 < x_2, \dots, X_n < x_n\} = \bigcap_{i=1}^n \{X_i < x_i\}$$

și observăm că acesta este un element al lui  $K$ .

**Definiția 3.3.2** Funcția  $F : \mathbb{R}^n \rightarrow \mathbb{R}$ , definită prin

$$F(x_1, x_2, \dots, x_n) = P(\{X_1 < x_1, \dots, X_n < x_n\}),$$

se numește funcție de repartiție  $n$  dimensională.

Fără a intra în detalii de demonstrație, amintim că pentru funcția de repartiție  $n$ -dimensională au loc proprietățile:

1.  $F$  este nedescrescătoare în fiecare argument;
2.  $F$  este continuă la stânga în fiecare argument;
3.  $F(+\infty, \dots, +\infty) = 1$ ;
4. Pentru orice  $k = 1, \dots, n$ , are loc

$$\lim_{x_k \rightarrow -\infty} F(x_1, \dots, x_k, \dots, x_n) = 0, \quad \forall x_1, \dots, x_{k-1}, x_{k+1}, \dots, x_n \in \mathbb{R}.$$

Numai satisfacerea acestor proprietăți, nu implică faptul că  $F$  este funcție de repartiție, pentru o variabilă aleatoare  $n$ -dimensională. Pentru  $a_i, b_i$   $i = 1, \dots, n$  se poate arăta că

$$P(\{a_1 \leq X_1 < b_1, \dots, a_n \leq X_n < b_n\}) =$$

$$= F(b_1, \dots, b_n) - \sum_{i=1}^n p_i + \sum_{i<j}^n p_{ij} - \sum_{i<j<k}^n p_{ijk} + \dots + (-1)^n F(a_1, \dots, a_n), \quad (3.18)$$

unde  $p_{ij\dots k} = F(c_1, c_2, \dots, c_n)$ ,  $c_i = a_i, c_j = a_j, \dots, c_k = a_k$ , restul valorilor fiind  $c_s = b_s$ . Să exemplificăm în cazul  $n = 2$ . Pentru aceasta evaluăm

$$\begin{aligned} P(\{a_1 \leq X_1 < b_1, a_2 \leq X_2 < b_2\}) &= P(\{X_1 < b_1, X_2 < b_2\}) - \\ &- P(\{X_1 < a_1, X_2 < b_2\}) - P(\{X_1 < b_1, X_2 < a_2\}) + P(\{X_1 < a_1, X_2 < a_2\}) = \\ &= F(b_1, b_2) - F(a_1, b_2) - F(b_1, a_2) + F(a_1, a_2), \end{aligned}$$

a căror justificare este ușor de constatat în Figura 3.6.

Vom da un exemplu de funcție  $F$  care satisface proprietățile 1-4, dar nu este funcție de repartiție.

**Exemplul 3.3.1** Să definim

$$F(x_1, x_2) = \begin{cases} 0, & \text{dacă } x_1 \leq 0 \text{ sau } x_1 + x_2 \leq 1 \text{ sau } x_2 \leq 0, \\ 1, & \text{în rest.} \end{cases}$$

Aceasta va satisface condițiile 1-4, dar dacă în formula precedentă luăm  $a_1 = a_2 = \frac{1}{2}, b_1 = b_2 = 1$ , găsim  $F(1, 1) - F(1, \frac{1}{2}) - F(\frac{1}{2}, 1) + F(\frac{1}{2}, \frac{1}{2}) < 0$ , care nu poate fi probabilitatea unui eveniment.

Pentru ca  $F$ , o funcție ce satisface condițiile 1-4, să fie funcție de repartiție mai trebuie îndeplinită condiția  $\forall a_i, b_i \in \mathbb{R}, i = 1, \dots, n$ , membrul al doilea al formulei (3.18) este pozitiv.

La fel ca în cazul unidimensional, vom considera o clasă de variabile aleatoare pentru care există o funcție pozitivă și continuă cu excepția unui număr finit de puncte  $f(x_1, \dots, x_n)$ , astfel ca

$$F(x_1, \dots, x_n) = \int_{-\infty}^{x_1} \dots \int_{-\infty}^{x_n} f(y_1, \dots, y_n) dy_1 \dots dy_n.$$

Vom numi această funcție *densitate de probabilitate  $n$ -dimensională*. Dacă funcția de repartiție este continuă, variabila aleatoare va fi numită *continuă*. Densitatea de probabilitate se caracterizează prin

$$\int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f(y_1, \dots, y_n) dy_1 \dots dy_n = 1. \quad (3.19)$$

Mai observăm că în punctele de continuitate ale funcției  $f$  are loc

$$f(x_1, \dots, x_n) = \frac{\partial^n F(x_1, \dots, x_n)}{\partial x_1 \dots \partial x_n}.$$

Dacă variabila aleatoare  $n$ -dimensională are densitate de probabilitate, probabilitatea din formula (3.18) poate fi calculată astfel:

$$P(\{a_1 \leq X_1 < b_1, \dots, a_n \leq X_n < b_n\}) = \int_{a_1}^{b_1} dx_1 \dots \int_{a_n}^{b_n} f(x_1, \dots, x_n) dx_n.$$

În general, dacă  $D \subset \mathbb{R}^n$  este un domeniu arbitrar, probabilitatea ca variabila aleatoare  $n$ -dimensională să ia valori în  $D$  este dată de formula

$$P(\{(x_1, \dots, x_n) \in D\}) = \int \dots \int_D f(x_1, \dots, x_n) dx_1 \dots dx_n.$$

**Definiția 3.3.3** *Funcțiile definite de formulele*

$$F_{X_i}(x_i) = \int_{-\infty}^{x_i} du \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f(x_1, \dots, x_{i-1}, u, x_{i+1}, \dots, x_n) dx_1 \dots dx_n$$

se numesc funcții marginale de repartiție, iar derivatele lor, date de formulele

$$\begin{aligned} f_{X_i}(x_i) &= F'_{X_i}(x_i) = \\ &= \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f(x_1, \dots, x_{i-1}, x_i, x_{i+1}, \dots, x_n) dx_1 \dots dx_{i-1} dx_{i+1} \dots dx_n \end{aligned}$$

se numesc densități marginale de probabilitate.

În particular pentru  $n = 2$ , alegând notații mai convenabile, densitățile marginale și funcțiile marginale de repartiție, sunt date de formulele:

$$\begin{aligned} F_X(x) &= \int_{-\infty}^x du \int_{-\infty}^{\infty} f(u, v) dv, & F_Y(y) &= \int_{-\infty}^y dv \int_{-\infty}^{\infty} f(u, v) du, \\ f_X(x) &= \int_{-\infty}^{\infty} f(x, v) dv, & f_Y(y) &= \int_{-\infty}^{\infty} f(u, y) du. \end{aligned}$$

Fie  $(X_1, \dots, X_n)$  o variabilă aleatoare continuă. Variabilele aleatoare  $X_i$  sunt *independente* dacă și numai dacă  $\forall x_{i_1}, \dots, x_{i_k} \in \mathbb{R}, k = 1, \dots, n$ , are loc

$$P(\{X_{i_1} < x_{i_1}, \dots, X_{i_k} < x_{i_k}\}) = P(\{X_{i_1} < x_{i_1}\}) \dots P(\{X_{i_k} < x_{i_k}\}).$$

Această afirmație se deduce imediat din Propoziția 3.1.3. În particular pentru  $n = 2$ , condiția revine la

$$F(x, y) = F_X(x)F_Y(y).$$

Dacă variabilele considerate au densități de probabilitate, condiția de mai sus este echivalentă cu

$$f(x, y) = f_X(x)f_Y(y). \tag{3.20}$$

**Exemplul 3.3.2** Repartiția uniformă  $n$ -dimensională are densitatea de probabilitate dată de

$$f(x_1, \dots, x_n) = \begin{cases} k, & \text{dacă } (x_1, \dots, x_n) \in D \\ 0, & \text{în rest} \end{cases},$$

unde  $D$  este un domeniu din  $\mathbb{R}^n$ , mărginit, iar  $k$  este astfel ales încât să aibă loc (3.19), deci

$$k = \frac{1}{\int \dots \int_D dx_1 \dots dx_n}.$$

În particular pentru  $n = 2$  și  $D = [a, b] \times [c, d]$ , avem

$$f(x, y) = \begin{cases} \frac{1}{(b-a)(d-c)}, & \text{dacă } (x, y) \in D, \\ 0, & \text{în rest.} \end{cases}$$

Să determinăm densitățile marginale.

$$f_X(x) = \int_{-\infty}^{\infty} f(x, v) dv = \int_c^d \frac{1}{(b-a)(d-c)} dv = \begin{cases} \frac{1}{b-a}, & \forall x \in [a, b] \\ 0, & \text{în rest} \end{cases}$$

și analog,

$$f_Y(y) = \begin{cases} \frac{1}{d-c}, & \forall x \in [c, d], \\ 0, & \text{în rest} \end{cases}$$

Deci variabilele aleatoare marginale  $X$  și  $Y$  cu densitățile marginale  $f_X$ , respectiv  $f_Y$  sunt independente, deoarece este satisfăcută (3.20).

### Transformări de variabile aleatoare.

Fie  $(X_1, \dots, X_n)$  o variabilă aleatoare pe câmpul borelian  $\{E, K, P\}$ . Considerăm o transformare inversabilă între două domenii  $\Delta, D \subset \mathbb{R}^n$ , deci o funcție vectorială de mai multe variabile

$$\begin{cases} x_1 = \phi_1(y_1, \dots, y_n) \\ \vdots \\ x_n = \phi_n(y_1, \dots, y_n) \end{cases} \quad (x_1, \dots, x_n) \in D, \quad (y_1, \dots, y_n) \in \Delta$$

și care satisface condițiile:

1.  $\phi_1, \dots, \phi_n$  sunt funcții reale de clasă  $C^1(\Delta)$ ;

$$2. \quad J(y_1, \dots, y_n) = \frac{D(\phi_1, \dots, \phi_n)}{D(y_1, \dots, y_n)} = \begin{vmatrix} \frac{\partial \phi_1}{\partial y_1} & \cdots & \frac{\partial \phi_1}{\partial y_n} \\ \vdots & \cdots & \vdots \\ \frac{\partial \phi_n}{\partial y_1} & \cdots & \frac{\partial \phi_n}{\partial y_n} \end{vmatrix} \neq 0 \text{ pe } \Delta.$$

În aceste condiții, compunerea dintre  $(X_1, \dots, X_n)$  și inversa transformării este tot o variabilă aleatoare, pe care o notăm  $(Y_1, \dots, Y_n)$ . Presupunem că ambele variabile aleatoare au densități de probabilitate, pe care le notăm  $f_{X_1 \dots X_n}$  și  $f_{Y_1 \dots Y_n}$ . Folosind schimbarea de variabile în integrala multiplă, obținem

$$\begin{aligned} & \int \cdots \int_D f_{X_1 \dots X_n}(x_1, \dots, x_n) dx_1 \cdots dx_n = \\ & = \int \cdots \int_{\Delta} f_{X_1 \dots X_n}(\phi_1(y_1, \dots, y_n), \dots, \phi_n(y_1, \dots, y_n)) |J(y_1, \dots, y_n)| dy_1 \cdots dy_n, \end{aligned} \quad (3.21)$$

care se interpretează astfel: probabilitatea ca variabila aleatoare  $(X_1, \dots, X_n)$  să ia valori în domeniul  $D$ , coincide cu probabilitatea ca  $(Y_1, \dots, Y_n)$  să ia valori în domeniul  $\Delta$ . Atunci densitatea de probabilitate pentru variabila aleatoare  $(Y_1, \dots, Y_n)$  este dată de

$$\begin{aligned} f_{Y_1 \dots Y_n}(y_1, \dots, y_n) &= \\ &= f_{X_1 \dots X_n}(\phi_1(y_1, \dots, y_n), \dots, \phi_n(y_1, \dots, y_n)) |J(y_1, \dots, y_n)|. \end{aligned} \quad (3.22)$$

**Caz particular.** Pentru  $n = 1$ , considerăm transformarea  $x = \phi(y)$  unde  $\phi$  este de clasă  $C^1(D)$ ,  $D \subset \mathbb{R}$ , inversabilă. Formula precedentă devine

$$f_Y(y) = f_X(\phi(y)) \left| \frac{d\phi}{dy} \right|. \quad (3.23)$$

**Exemplul 3.3.3** Dacă  $X$  este o variabilă aleatoare și facem transformarea  $Y = aX + b$ , unde  $a, b \in \mathbb{R}$ ,  $a \neq 0$ , atunci folosind relația (3.23) găsim

$$f_Y(y) = f_X\left(\frac{y-b}{a}\right) \frac{1}{|a|}.$$

În particular, dacă  $X : N(m, \sigma^2)$ , să determinăm densitatea de probabilitate a variabilei aleatoare  $Y = aX + b$ ,  $a \neq 0$ , înlocuind mai sus

$$\begin{aligned} f_Y(y) &= \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(\frac{y-b}{a}-m)^2}{2\sigma^2}} \frac{1}{|a|} = \\ &= \frac{1}{\sqrt{2\pi}|a|\sigma} e^{-\frac{(y-(am+b))^2}{2a^2\sigma^2}}. \end{aligned}$$

deci  $Y$  este o variabilă repartizată  $N(am + b, a^2\sigma^2)$ . Deci prin transformarea liniară a unei variabile aleatoare normale se obține tot o variabilă normală. De aici se deduce imediat că, dacă  $X : N(m, \sigma^2)$

$$\frac{X - m}{\sigma} : N(0, 1).$$

Uneori este comod să găsim densitatea de probabilitate calculând funcția de repartiție a variabilei aleatoare obținute prin transformare, ca în următorul exemplu.

**Exemplul 3.3.4** Dacă  $X : N(m, \sigma^2)$  să determinăm densitatea variabilei aleatoare  $e^X$ . Notăm  $Y = e^X$ . Pentru  $y > 0$ , să calculăm

$$F_Y = P(\{Y < y\}) = P(\{e^X < y\}) = P(\{X < \ln y\}).$$

Prin derivare găsim

$$f_Y(y) = F'_Y(y) = F'_X(\ln y) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(\ln y - m)^2}{2\sigma^2}}.$$

Această repartiție se numește **lognormală**.

**Exemplul 3.3.5** Erorile de măsurare pentru două mărimi sunt  $X, Y$  independente și repartizate uniform pe  $(0, 1)$ . Să determinăm densitățile marginale ale sumei și diferenței erorilor. Vom particulariza cazul general (făcând o schimbare convenabilă de notații suma și diferența erorilor sunt variabile aleatoare definite prin

$$U = X + Y$$

$$V = X - Y.$$

Inversa transformării este

$$x = \phi_1(u, v) = \frac{1}{2}(u + v)$$

$$y = \phi_2(u, v) = \frac{1}{2}(u - v)$$

iar iacobianul  $J(u, v) = -\frac{1}{2}$ ; reprezentăm în Figurile 3.7 și 3.8 domeniile  $D$  și  $\Delta$ . Din ipoteza de independență rezultă

$$f_{XY}(x, y) = f_X(x)f_Y(y).$$

Deci  $f_{UV}(u, v) = 1 - 1/2|$ , dacă  $(u, v) \in \Delta$  și 0 în rest. Densitatea marginală este dată de

$$f_U(u) = \int_{-\infty}^{\infty} f_{UV}(u, v)dv.$$

Pentru calculul ei distingem cazurile

$$1. 0 \leq u \leq 1, f_U(u) = \int_{-u}^u \frac{dv}{2} = u;$$

$$2. 1 \leq u \leq 2, f_U(u) = \int_{u-2}^{2-u} \frac{dv}{2} = 2 - u.$$

Deci

$$f_U(u) = \begin{cases} u, & \text{dacă } 0 \leq u \leq 1, \\ 2 - u, & \text{dacă } 1 \leq u \leq 2, \\ 0, & \text{în rest.} \end{cases}$$

și analog

$$f_V(v) = \begin{cases} \frac{v+1}{2}, & \text{dacă } -1 \leq v \leq 0, \\ \frac{-v+1}{2}, & \text{dacă } 0 \leq v \leq 1, \\ 0, & \text{în rest.} \end{cases}$$

**Exemplul 3.3.6** Un dispozitiv are două componente ale căror durate de viață sunt variabile aleatoare independente, notate  $X$  și  $Y$ , cu densitățile

$$f_X(x) = \begin{cases} \frac{1}{x^2}, & \text{dacă } x \geq 1, \\ 0, & \text{în rest} \end{cases}, \quad f_Y(y) = \begin{cases} \frac{1}{y^2}, & \text{dacă } y \geq 1, \\ 0, & \text{în rest.} \end{cases}$$

O măsură pentru calitatea funcționării dispozitivului este  $U = \sqrt{XY}$ . Să determinăm densitatea de probabilitate a lui  $U$ . Facem schimbarea de variabile

$$\begin{cases} U = \sqrt{XY} \\ V = X \end{cases}$$

definită pe domeniul  $D$  cu inversa

$$\begin{cases} x = v \\ y = \frac{u^2}{v} \end{cases}$$

definită pe domeniul  $\Delta$  și având iacobianul  $J(u, v) = -\frac{2u}{v}$ . Din condiția de independență

$$f_{XY}(x, y) = \begin{cases} \frac{1}{x^2y^2}, & \text{dacă } x, y \geq 1, \\ 0, & \text{în rest,} \end{cases}$$

iar

$$f_{UV}(u, v) = \frac{2}{u^3v}.$$

Reprezentăm grafic cele două domenii.

Densitatea marginală este

$$f_U(u) = \int_{-\infty}^{\infty} f_{UV}(u, v)dv = \int_1^{u^2} \frac{2}{u^3v}dv = 4\frac{\ln u}{u^3}, \quad \forall u \geq 1.$$

**Exemplul 3.3.7** (Limitatorul). Fie funcția

$$g(x) = \begin{cases} -b, & \text{dacă } x \leq -b, \\ x, & \text{dacă } -b < x \leq b, \\ b, & \text{dacă } x > b. \end{cases}$$

Să determinăm funcția de repartiție a variabilei aleatoare  $Y = g(X)$ , unde  $X$  este o variabilă aleatoare cu funcția de repartiție  $F_X$ .

Dacă  $y \leq -b$  evenimentul  $g(X) < y$  nu se realizează pentru nici un  $x$ , deci  $F_Y(y) = 0$ .

Dacă  $-b < y \leq b$ ,  $F_Y(y) = F_X(y)$ .

Dacă  $b < y$ ,  $F_Y(y) = 1$ .

**Exemplul 3.3.8** Repartiția normală n-dimensională. Considerăm funcția definită de

$$f(x_1, \dots, x_n) = \frac{\sqrt{\det A}}{(2\pi)^{n/2}} e^{-1/2(X-M)^t A(X-M)}, \tag{3.24}$$

unde  $A = (a_{ij})_{i,j=1\dots n}$  este o matrice simetrică, deci  $A = A^t$  și care are proprietatea că forma pătratică

$$(X - M)^t A(X - M) = \sum_i \sum_j a_{ij}(x_i - m_i)(x_j - m_j)$$

este pozitiv definită.  $X$  și  $M$  reprezintă:

$$X = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}, \quad M = \begin{pmatrix} m_1 \\ \vdots \\ m_n \end{pmatrix}.$$

Presupunem pentru început că  $m_1 = \dots = m_n = 0$ . Reamintim că în acest caz există o matrice ortogonală  $H$  (cu proprietatea  $HH^t = I_n$ , unde  $I_n$  este matricea unitate), pentru care forma pătratică are forma canonică

$$X^t A X = \sum_{i=1}^n \lambda_i y_i^2,$$

unde  $\lambda_i$  sunt valorile proprii ale lui  $A$ , care în cazul nostru sunt strict pozitive. După cum știm  $\det A = \lambda_1 \dots \lambda_n$ . Să verificăm satisfacerea condiției (3.19). Facem schimbarea de variabile  $X = HY$  și observăm că determinantul funcțional

$$\left| \frac{D(x_1, \dots, x_n)}{D(y_1, \dots, y_n)} \right| = \det H = 1$$

deoarece  $H$  este o matrice ortogonală. Avem atunci

$$\begin{aligned} & \int \dots \int_{\mathbb{R}^n} e^{-\frac{1}{2} \sum_{i=1}^n a_{ij} x_i x_j} dx_1 \dots dx_n = \\ & = \int \dots \int_{\mathbb{R}^n} e^{-\frac{1}{2} \sum_{i=1}^n \lambda_i y_i^2} \det H dy_1 \dots dy_n = \prod_{i=1}^n \int_{-\infty}^{\infty} e^{-\frac{1}{2} \lambda_i y_i^2} dy_i. \end{aligned}$$

Facem în ultima integrală substituția  $y_i = \frac{z_i}{\sqrt{\lambda_i}}$  și găsim

$$\int_{-\infty}^{\infty} e^{-\frac{1}{2} \lambda_i y_i^2} dy_i = \frac{1}{\sqrt{\lambda_i}} \int_{-\infty}^{\infty} e^{-\frac{z_i^2}{2}} dz_i = \frac{\sqrt{2\pi}}{\sqrt{\lambda_i}}.$$

Efectuând calculele obținem

$$\prod_{i=1}^n \sqrt{\frac{2\pi}{\lambda_i}} = \frac{(2\pi)^{\frac{n}{2}}}{\sqrt{\lambda_1 \dots \lambda_n}} = \frac{(2\pi)^{\frac{n}{2}}}{\sqrt{\det A}}.$$

Dacă revenim la cazul general, prin substituția  $X - M = Y$ , situația se reduce la satisfacerea condiției  $m_1 = \dots = m_n = 0$ .

Semnificația coeficienților matricei  $A$  și unele proprietăți vor fi studiate în Capitolul 3.5. Vom da cazuri particulare ale legii normale.

### Variabila aleatoare normală bidimensională.



Dacă variabilele marginale  $X, Y$  sunt independente, atunci densitatea de probabilitate bidimensională are o formă foarte simplă

$$f(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} e^{-\frac{1}{2}\left(\frac{(x-m_x)^2}{\sigma_x^2} + \frac{(y-m_y)^2}{\sigma_y^2}\right)}. \quad (3.25)$$

Dacă  $D = [a, b] \times [c, d] \subset \mathbb{R}^2$ , atunci

$$P(\{(X, Y) \in D\}) = \left(\Phi\left(\frac{b-m_x}{\sigma_x}\right) - \Phi\left(\frac{a-m_x}{\sigma_x}\right)\right) \left(\Phi\left(\frac{d-m_y}{\sigma_y}\right) - \Phi\left(\frac{c-m_y}{\sigma_y}\right)\right).$$

Să considerăm un domeniu  $D_k$  delimitat de *elipsa de egală probabilitate*, adică elipsa în ale cărei puncte densitatea de probabilitate este constanta  $k > 0$ . Elipsa are ecuația  $\frac{(x-m_x)^2}{\sigma_x^2} + \frac{(y-m_y)^2}{\sigma_y^2} = k^2$ . Observăm că semiaxele elipsei sunt  $a = k\sigma_x$ ,  $b = k\sigma_y$ . Atunci are loc

$$P(\{(X, Y) \in D_k\}) = 1 - e^{-\frac{k^2}{2}} \quad (3.26)$$

Aceasta rezultă imediat dacă facem în integrala dublă schimbarea de variabile de forma

$$\begin{cases} x - m_x = \rho\sigma_x \cos \theta \\ y - m_y = \rho\sigma_y \sin \theta \end{cases} \quad 0 < \rho \leq k, \theta \in [0, 2\pi).$$

După efectuarea calculelor obținem

$$\int \int_{D_k} f(x, y) dx dy = \frac{\sigma_x\sigma_y}{2\pi\sigma_x\sigma_y} \int_0^{2\pi} d\theta \int_0^k e^{-\frac{\rho^2}{2}} \rho d\rho,$$

de unde (3.26).

**Exemplul 3.3.9** Repartiția Rayleigh Dacă  $\sigma_x = \sigma_y = \sigma$  și  $m_x = m_y = 0$ , distanța  $R$  a unui "punct aleator"  $(X, Y)$  la origine are repartiția Rayleigh. Înlocuind în (3.25), densitatea de probabilitate are forma

$$f(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{1}{2}\frac{x^2+y^2}{\sigma^2}}.$$

Facem schimbarea de variabile

$$\begin{cases} x = r \cos \theta \\ y = r \sin \theta \end{cases} \quad r > 0 \quad \theta \in [0, 2\pi)$$

și densitatea de probabilitate a variabilei  $(R, \Theta)$  este

$$f_{R\Theta}(r, \theta) = \frac{r}{2\pi\sigma^2} e^{-\frac{r^2}{2\sigma^2}},$$

iar densitatea marginală a variabilei  $R$  este

$$f(r) = \frac{r}{\sigma^2} e^{-\frac{r^2}{2\sigma^2}}.$$

### Variabila aleatoare normală tridimensională.

Dacă variabilele marginale  $X, Y, Z$  sunt independente, densitatea de probabilitate este

$$f(x, y, z) = \frac{1}{(2\pi)^{\frac{3}{2}}\sigma_x\sigma_y\sigma_z} e^{-\frac{1}{2}\left(\frac{(x-m_x)^2}{\sigma_x^2} + \frac{(y-m_y)^2}{\sigma_y^2} + \frac{(z-m_z)^2}{\sigma_z^2}\right)}.$$

La fel ca în cazul bidimensional probabilitatea ca variabila  $(X, Y, Z)$  să ia valori într-un elipsoid  $D_k$ , pe a cărui suprafață densitatea ia valori constante, *elipsoid de egală probabilitate*, este

$$P(\{(X, Y, Z) \in D_K\}) = 2\Phi(k) - \sqrt{\frac{2}{\pi}}ke^{-\frac{k^2}{2}}.$$

Elipsoidul are semiaxele  $a = k\sigma_x$ ,  $b = k\sigma_y$ ,  $c = k\sigma_z$ .

### Operații cu variabile aleatoare continue.

Vom deduce formule de calcul pentru densitățile de probabilitate ale sumei, diferenței, produsului și câtului de variabile aleatoare continue. Vom alege de fiecare dată transformări convenabile și vom utiliza formula (3.22).

#### Suma de variabile aleatoare continue.

Fie  $(X, Y)$  o variabilă aleatoare continuă cu densitatea de probabilitate  $f_{XY}$ . Considerăm transformarea:

$$\begin{cases} u = x + y \\ v = x \end{cases},$$

care admite inversa

$$\begin{cases} x = v \\ y = u - v \end{cases}$$

și iacobianul  $J(u, v) = -1$ . Din (3.22) deducem că densitatea de probabilitate a variabilei aleatoare  $(U, V)$  este  $f_{UV}(u, v) = f_{XY}(v, u - v)|-1|$ . Luând densitatea marginală, găsim

$$f_U(u) = \int_{-\infty}^{\infty} f_{XY}(v, u - v)dv. \quad (3.27)$$

Dacă  $X$  și  $Y$  sunt independente  $f_{XY}(v, u - v) = f_X(v)f_Y(u - v)$  și densitatea sumei este produsul de convoluție al densităților  $f_X, f_Y$ , adică

$$f_U(u) = \int_{-\infty}^{\infty} f_X(v)f_Y(u - v)dv. \quad (3.28)$$

**Exemplul 3.3.10** Să determinăm suma de variabile aleatoare independente repartizate uniform pe intervalul  $(a, b)$ . Densitatea de probabilitate are valoarea  $\frac{1}{b-a}$  pe intervalul  $[a, b]$  și 0 în rest. Vom folosi (3.28).

$$f_{X+Y}(x) = \int_{-\infty}^{+\infty} f(y)f(x - y)dy = \frac{1}{b-a} \int_{x-a}^{x-b} f(x - y)dy.$$

În ultima integrală facem schimbarea de variabilă  $x - y = t$ , și obținem

$$f_{X+Y}(x) = \frac{1}{b-a} \int_{x-b}^{x-a} f(t) dt.$$

Comparând  $x - a$  și  $x - b$  cu  $a$  și  $b$  obținem

$$f_{X+Y} = \begin{cases} 0, & x < 2a \\ \frac{x-2a}{(b-a)^2}, & 2a \geq x < a+b \\ \frac{2b-x}{(b-a)^2}, & a+b \leq x < 2b \\ 0, & x \geq 2b \end{cases} .$$

Graficul densității de probabilitate este dat de Figura 3.11.

**Diferență de variabile aleatoare continue.**

Considerăm transformarea

$$\begin{cases} u = x - y \\ v = x \end{cases}$$

cu inversa

$$\begin{cases} x = v \\ y = v - u \end{cases} ,$$

iar  $f_{UV}(u, v) = f_{XY}(v, v - u)$ . Densitatea marginală a diferenței este

$$f_U(u) = \int_{-\infty}^{\infty} f_{XY}(v, v - u) dv,$$

iar în caz de independență

$$f_U(u) = \int_{-\infty}^{\infty} f_X(v) f_Y(v - u) dv. \tag{3.29}$$

**Produs de variabile aleatoare.**

Considerăm transformarea

$$\begin{cases} u = xy \\ v = x \end{cases} ,$$

cu inversa

$$\begin{cases} x = v \\ y = \frac{u}{v} \end{cases}$$

și iacobianul  $J(u, v) = \frac{1}{v}$ . Densitatea de probabilitate este

$$f_{UV}(u, v) = f_{XY}\left(v, \frac{u}{v}\right) \frac{1}{|v|}.$$

Deducem

$$f_U(u) = \int_{-\infty}^{\infty} f_{XY}\left(v, \frac{u}{v}\right) \frac{dv}{|v|},$$

iar în caz de independență

$$f_U(u) = \int_{-\infty}^{\infty} f_X(v) f_V\left(\frac{u}{v}\right) \frac{dv}{|v|}. \quad (3.30)$$

### Câțul a două variabile aleatoare continue.

Considerăm transformarea

$$\begin{cases} u = \frac{x}{y} \\ v = y \end{cases}$$

cu inversa

$$\begin{cases} x = uv \\ y = v \end{cases}$$

și iacobianul  $J(u, v) = v$ . Se obține densitatea de probabilitate

$$f_U(u) = \int_{-\infty}^{\infty} f_{XY}(uv, v) |v| dv,$$

care în caz de independență devine

$$f_U(u) = \int_{-\infty}^{\infty} f_X(uv) f_Y(v) |v| dv. \quad (3.31)$$

### Probabilități și funcții de repartiție condiționate.

Dacă  $X, Y$  sunt variabile aleatoare discrete, noțiunile de probabilități condiționate au fost definite prin în Capitolul 2.4. Fie  $X$  este o variabilă aleatoare discretă, iar  $Y$  o variabilă aleatoare continuă; definim funcția de repartiție a lui  $Y$  condiționată de  $X$  prin

$$F_Y(y|x_k) = \frac{P(\{Y < y, X = x_k\})}{P(\{X = x_k\})}$$

dacă  $P(\{X = x_k\}) > 0$ . Dacă funcția de repartiție condiționată este derivabilă, definim densitatea de probabilitate prin formula

$$f_Y(y|x_k) = \frac{d}{dy} F_Y(y|x_k).$$

Pentru  $A \in K$ , are loc

$$P(\{Y \in A | X = x_k\}) = \int_A f_Y(y|x_k) dy.$$

În cazul în care  $X, Y$  sunt independente, se obțin imediat

$$F_Y(y|x) = F_Y(y); \quad f_Y(y|x) = f_Y(y).$$

**Exemplul 3.3.11** Într-un canal de comunicație intrarea este o variabilă  $X$ , care poate lua valorile  $+1$  volt,  $-1$  volt cu aceeași probabilitate. Ieșirea  $Y = X + N$  unde  $N$  este "zgomotul" ce poate fi considerat o variabilă aleatoare repartizată uniform pe intervalul  $(-2, 2)$ . Să determinăm probabilitatea  $P(\{X = 1, Y < 0\})$ .

Folosind formula probabilităților condiționate, avem

$$P(\{X = 1, Y < y\}) = P(\{Y < y\}|\{X = 1\})P(\{X = 1\}) = F_Y(y|1)P(\{X = 1\}).$$

Funcția de repartiție a lui  $Y$  condiționată de  $\{X = 1\}$  este

$$F_Y(y|1) = P(\{N + 1 < y\}) = P(\{N < y - 1\}) = F_N(y - 1),$$

unde  $F_N$  este funcția de repartiție a variabilei uniforme, care are expresia

$$F_N(x) = \begin{cases} 0, & x \leq -2, \\ \frac{x+2}{4}, & -2 \leq x \leq 2, \\ 1, & 2 < x. \end{cases}$$

Deci  $F_Y(y|1) = P(\{Y < y|X = 1\}) = \frac{y+1}{4}$ ,  $-1 \leq y \leq 3$ , iar probabilitatea căutată este astfel  $P(\{X = 1\}|\{Y < 0\}) = \frac{1}{4} \cdot \frac{1}{2} = \frac{1}{8}$ .

Fie  $(X, Y)$  o variabilă aleatoare bidimensională continuă cu densitatea de probabilitate  $f_{XY}$  continuă și  $f_X \neq 0$  densitatea marginală continuă. Definim funcția de repartiție a variabilei  $Y$  condiționată de  $\{X = x\}$  prin limita următoare, dacă există

$$F_Y(y|x) = \lim_{h \rightarrow 0} \frac{P(\{Y < y, x \leq X < x + h\})}{P(\{x \leq X < x + h\})} = \frac{\int_{-\infty}^y \int_x^{x+h} f_{XY}(x', y') dx' dy'}{\int_x^{x+h} f_X(x') dx'}.$$

Folosind teoreme de medie pentru cele două integrale, găsim

$$F_Y(y|x) = \frac{\int_{-\infty}^y f_{XY}(x, y') dy'}{f_X(x)}.$$

Prin derivare obținem densitatea de probabilitate

$$f_Y(y|x) = \frac{f_{XY}(x, y)}{f_X(x)}. \quad (3.32)$$

Dacă  $X, Y$  sunt independente, au loc

$$f_Y(y|x) = f_Y(y), \quad F_Y(y|x) = F_Y(y).$$

Analog se deduce

$$F_X(x|y) = \frac{\int_{-\infty}^x f_{XY}(x', y) dx'}{f_Y(y)}.$$

Prin derivare obținem densitatea de probabilitate condiționată

$$f_X(x|y) = \frac{f_{XY}(x, y)}{f_Y(y)}.$$

**Exemplul 3.3.12** Fie variabila aleatoare  $(X, Y)$  cu densitatea

$$f_{XY}(x, y) = \begin{cases} 2e^{-x}e^{-y}, & 0 \leq y \leq x < +\infty, \\ 0, & \text{în rest.} \end{cases}$$

Să determinăm densitățile de probabilitate condiționată. Pentru început aflăm densitățile marginale

$$f_X(x) = \int_0^x 2e^{-x}e^{-y}dy = 2e^{-x}(1 - e^{-x}), \quad 0 \leq x < +\infty$$

și

$$f_Y(y) = \int_y^{+\infty} 2e^{-x}e^{-y}dx = 2e^{-2y}, \quad 0 \leq y < +\infty.$$

Folosind formulele precedente, avem

$$f_X(x|y) = \frac{2e^{-x}e^{-y}}{2e^{-2y}} = e^{-(x-y)}, \quad y \leq x$$

și

$$f_Y(y|x) = \frac{2e^{-x}e^{-y}}{2e^{-x}(1 - e^{-x})} = \frac{e^{-y}}{1 - e^{-x}}, \quad 0 \leq y \leq x.$$

Formula probabilității totale și formula lui Bayes se pot generaliza și în acest caz. Relația (3.32) poate fi scrisă sub forma

$$f_{XY}(x, y) = f_Y(y|x)f_X(x)$$

și aplicând definiția probabilității marginale, obținem **formula probabilității totale**:

$$f_Y(y) = \int_{-\infty}^{+\infty} f_Y(y|x)f_X(x)dx$$

și **formula lui Bayes**

$$f_Y(y|x) = \frac{f_X(x|y)f_Y(y)}{f_X(x)}.$$

În practică intervin și alte tipuri de probabilități condiționate. Lăsăm ca exerciții, stabilirea următoarelor formule. Dacă evenimentul ce condiționează este  $\{X < x\}$  și  $F_X(x) \neq 0$  avem

$$F_Y(y|\{X < x\}) = \frac{F_{XY}(x, y)}{F_X(x)},$$

$$f_Y(y|\{X < x\}) = \frac{\int_{-\infty}^x f_{XY}(x', y)dx'}{\int_{-\infty}^{+\infty} \int_{-\infty}^x f_{XY}(x', y')dx'dy'}.$$

Dacă evenimentul care condiționează este  $\{x_1 \leq X < x_2\}$  și  $F_X(x_1) \neq F_X(x_2)$  avem

$$F_Y(y|\{x_1 \leq X < x_2\}) = \frac{F_{XY}(x_2, y) - F_{XY}(x_1, y)}{F_X(x_2) - F_X(x_1)},$$

$$f_Y(y|\{x_1 \leq X < x_2\}) = \frac{\int_{x_1}^{x_2} f_{XY}(x, y)dx}{F_X(x_2) - F_X(x_1)}.$$

### 3.4 Valori caracteristice ale unei variabile aleatoare

**Medii și momente.**

**Definiția 3.4.1** Dacă  $X$  este o variabilă aleatoare având funcția de repartiție  $F(x)$ , numim medie, numărul dat de

$$M[X] = \int_{-\infty}^{\infty} x dF(x). \quad (3.33)$$

Integrala din (3.33) este de tip Riemann-Stieltjes (vezi Anexa 1). Dacă  $X$  are densitate de probabilitate continuă  $f(x)$ , atunci integrala din definiție se reduce la o integrală Riemann și avem

$$M[X] = \int_{-\infty}^{\infty} x f(x) dx \quad (3.34)$$

Să observăm că integrala improprie din definiție s-ar putea să nu fie convergentă. De exemplu, variabila aleatoare repartizată Cauchy, cu densitatea de probabilitate

$$f(x) = \frac{1}{\pi(1+x^2)}, \quad x \in \mathbb{R}$$

nu are medie, deoarece integrala (3.34) este divergentă. Reamintim că o variabilă aleatoare este continuă, dacă are funcția de repartiție continuă. Mai general, dacă  $F$  are  $c_1, \dots, c_n$  puncte de discontinuitate (evident de prima speță), media se obține exprimând integrala Stieltjes (vezi Anexa 1) ca o sumă dintre o integrală Riemann și o sumă de salturi.

$$\begin{aligned} M[X] &= \int_{-\infty}^{\infty} f(x) dF(x) = \\ &= \int_{-\infty}^{\infty} x f(x) dx + \sum_{k=1}^n c_k (F(c_k + 0) - F(c_k - 0)). \end{aligned}$$

**Exemplul 3.4.1** Să determinăm media variabilei aleatoare repartizate normal  $N(m, \sigma^2)$ . Facem în integrală schimbarea de variabilă  $y = \frac{x-m}{\sqrt{2}\sigma}$  și obținem

$$\begin{aligned} M[X] &= \int_{-\infty}^{\infty} x f(x) dx = \frac{1}{\sqrt{2\pi}\sigma} \int_{-\infty}^{\infty} (m + \sqrt{2}\sigma y) e^{-y^2} \sqrt{2}\sigma dy = \\ &= \frac{m}{\sqrt{\pi}} \int_{-\infty}^{\infty} e^{-y^2} dy + \sqrt{\frac{2}{\pi}} \sigma \int_{-\infty}^{\infty} \left(-\frac{1}{2} e^{-y^2}\right)' dy = m, \end{aligned}$$

deoarece ultima integrală este 0.

Dacă  $X$  are media  $m$  și admite densitate de probabilitate nesimetrică, cele două arii determinate de  $x = m$  pot fi neegale. Astfel dacă  $X$  reprezintă o caracteristică numerică studiată într-o colectivitate statistică, are înțeles afirmația că majoritatea indivizilor au caracteristica  $X$  mai mică decât media.

Regăsim și în cazul continuu aceleași proprietăți pentru medie, pe care le-am întâlnit în cazul discret.

**Propoziția 3.4.1** *Dacă  $X$  și  $Y$  sunt variabile aleatoare ce au medii, atunci  $X + Y$  are medie și*

$$M[X + Y] = M[X] + M[Y]. \quad (3.35)$$

*Demonstrație.* Vom demonstra această propoziție în cazul particular în care  $X$  și  $Y$  au densități de probabilitate  $f_X$ , respectiv  $f_Y$ . Folosind densitatea de probabilitate a sumei, (3.27), avem

$$M[X + Y] = \int_{-\infty}^{\infty} x dx \int_{-\infty}^{\infty} f_{XY}(y, x - y) dy = \int_{-\infty}^{\infty} dy \int_{-\infty}^{\infty} x f_{XY}(y, x - y) dx.$$

Ultima egalitate se datorează posibilității de a schimba ordinea de integrare. În ultima integrală facem schimbarea de variabilă  $x - y = z$  și obținem

$$\begin{aligned} M[X + Y] &= \int_{-\infty}^{\infty} dy \int_{-\infty}^{\infty} (y + z) f_{XY}(y, z) dz = \int_{-\infty}^{\infty} y dy \int_{-\infty}^{\infty} f_{XY}(y, z) dz + \\ &+ \int_{-\infty}^{\infty} z dz \int_{-\infty}^{\infty} f_{XY}(y, z) dy = \int_{-\infty}^{\infty} y f_Y(y) dy + \int_{-\infty}^{\infty} z f_X(z) dz = M[X] + M[Y]. \end{aligned}$$

Proprietatea se poate extinde pentru un număr finit de variabile aleatoare.

**Propoziția 3.4.2** *Dacă  $X$  și  $Y$  sunt variabile aleatoare independente ce admit medii, atunci produsul  $XY$  are medie și*

$$M[XY] = M[X]M[Y]. \quad (3.36)$$

*Demonstrație.* Vom folosi formula care definește densitatea produsului de variabile aleatoare (3.30), presupunând că  $X$  și  $Y$  au densități de probabilitate  $f_X$ ,  $f_Y$ .

$$M[XY] = \int_{-\infty}^{\infty} x dx \int_{-\infty}^{\infty} f_X(y) f_Y\left(\frac{x}{y}\right) \frac{dy}{|y|}.$$

În ultima integrală facem schimbarea  $x = yz$  și inversăm ordinea de integrare. Găsim

$$\begin{aligned} M[XY] &= \int_{-\infty}^{\infty} dy \int_{-\infty}^{\infty} x f_X(y) f_Y\left(\frac{x}{y}\right) \frac{dx}{|y|} = \int_{-\infty}^{\infty} dy \int_{-\infty}^{\infty} yz f_X(y) f_Y(z) dz = \\ &= M[X]M[Y]. \end{aligned}$$

■

Dacă o variabilă aleatoare nu are medie, alte caracteristici numerice care studiază "tendința centrală" sunt *modul* și *mediana*. Mediana a fost definită de (3.4) și ea există pentru orice variabilă aleatoare. De exemplu, în cazul repartiției Cauchy, datorită simetriei față de axa  $Oy$ , mediana este  $m_e = 0$ , iar în cazul repartiției normale este  $m$ .

**Definiția 3.4.2**  $m_o$  se numește modul pentru variabila aleatoare  $X$  cu densitatea de probabilitate  $f(x)$ , dacă este un punct de maxim pentru  $f(x)$ .



O variabilă aleatoare poate fi *unimodală*, *bimodală* etc, după cum densitatea de probabilitate are unul sau mai multe puncte de maxim local.

**Media unei transformări de variabilă aleatoare.**

Dacă  $X$  este o variabilă aleatoare, iar  $y = \Psi(x)$  este o transformare de clasă  $C^1$ , inversabilă, media variabilei  $Y = \Psi(X)$  dacă există, este dată de formula

$$M[Y] = \int_{-\infty}^{+\infty} \Psi(x) f_X(x) dx. \tag{3.37}$$

Aceasta rezultă dacă facem în integrala care definește media

$$M[Y] = \int_{-\infty}^{+\infty} y f_Y(y) dy$$

schimbarea de variabilă și aplicăm relația (3.23), unde  $\Phi$  este transformarea inversă.

**Exemplul 3.4.2** Dacă  $X : U(0, 2\pi)$ , să determinăm media variabilei  $Y = \cos X$ . Aplicând formula (3.37), avem

$$M[Y] = \int_0^{2\pi} \cos x \frac{1}{2\pi} dx = 0.$$

Reamintim că dacă  $X$  este o variabilă aleatoare, numărul  $\nu_k = M[X^k], k \in \mathbb{N}$  (dacă există), se numește *moment inițial de ordin  $k$* . Momentul inițial de ordin  $k$  se calculează după formula

$$\nu_k = \int_{-\infty}^{\infty} x^k f(x) dx, \tag{3.38}$$

dacă variabila aleatoare  $X$  are densitatea de probabilitate  $f$ . Această formulă rezultă dacă aplicăm (3.37) variabilei  $\Psi(x) = X^k$ . Observăm că  $\nu_1 = M[X]$ .

*Momentul centrat de ordin  $k$*  se definește prin  $\mu_k = M[(X - M[X])^k]$ . Dacă  $X$  are densitatea de probabilitate  $f$ , atunci folosind din nou (3.37), momentul centrat are expresia

$$\mu_k = \int_{-\infty}^{\infty} (x - \nu_1)^k f(x) dx.$$

Între momentele inițiale și cele centrate au loc relațiile următoare, care se demonstrează fără dificultate:

$$\mu_k = \sum_{i=0}^k (-1)^i C_k^i \nu_{k-i} \nu_1^i; \quad \nu_k = \sum_{i=0}^k C_k^i \mu_{k-i} \nu_1^i. \tag{3.39}$$

Reamintim că  $\mu_2$  se numește *dispersie* sau *varianță* și se notează  $D^2[X]$ , iar  $D[X]$  se numește *abaterea medie pătratică*. Aceste caracteristici au aceleași proprietăți ca în cazul discret, demonstrația lor nefiind dificilă.

**Exemplul 3.4.3** Să calculăm momentele centrate ale repartiției normale  $N(m, \sigma^2)$ . Avem

$$\mu_k = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^{\infty} (x-m)^k e^{-\frac{(x-m)^2}{2\sigma^2}} dx,$$

în care facem schimbarea de variabilă  $x-m = \sqrt{2}\sigma y$ , deci

$$\mu_k = \frac{(\sigma\sqrt{2})^k}{\sqrt{\pi}} \int_{-\infty}^{\infty} y^k e^{-y^2} dy.$$

Dacă integrăm prin părți obținem

$$\begin{aligned} \mu_k &= \frac{(\sigma\sqrt{2})^k}{\sqrt{\pi}} \left( -\frac{1}{2} e^{-y^2} y^{k-1} \Big|_{-\infty}^{+\infty} + \frac{k-1}{2} \int_{-\infty}^{\infty} y^{k-2} e^{-y^2} dy \right) = \\ &= \frac{(k-1)(\sigma\sqrt{2})^k}{2\sqrt{\pi}} \int_{-\infty}^{\infty} y^{k-2} e^{-y^2} dy = (k-1)\sigma^2 \mu_{k-2}, \end{aligned}$$

deoarece prima expresie se anulează la limită. Deducem din relația de recurență precedentă

$$\begin{cases} \mu_{2k+1} = 0 \\ \mu_{2k} = (k-1)!!\sigma^{2k} \end{cases} .$$

În particular, pentru  $k=2$ , obținem  $D^2[X] = \sigma^2$ . Regăsim, și în cazul variabilelor aleatoare continue, inegalitatea lui Cebășev, cu ajutorul căreia putem aprecia gradul de împrăștiere a valorilor variabilei; inegalitatea va constitui un important instrument de lucru în cazul *Legii numerelor mari* (Capitolul 4).

**Propoziția 3.4.3** (Inegalitatea lui Cebășev) *Dacă variabila aleatoare  $X$  este continuă cu media  $m$  și dispersia  $\sigma^2$ , atunci are loc*

$$P(\{|X-m| < \epsilon\}) \geq 1 - \frac{\sigma^2}{\epsilon^2}, \quad \forall \epsilon > 0, \quad (3.40)$$

sau echivalent

$$P(\{|X-m| \geq \epsilon\}) < \frac{\sigma^2}{\epsilon^2} \quad \forall \epsilon > 0.$$

**Demonstrație.** Dispersia este dată de

$$\begin{aligned} \sigma^2 &= \int_{-\infty}^{\infty} (x-m)^2 f(x) dx = \int_{-\infty}^{m-\epsilon} (x-m)^2 f(x) dx + \int_{m-\epsilon}^{m+\epsilon} (x-m)^2 f(x) dx + \\ &\quad + \int_{m+\epsilon}^{+\infty} (x-m)^2 f(x) dx. \end{aligned}$$

Din faptul că  $x \notin (m-\epsilon, m+\epsilon)$ , rezultă  $(x-m)^2 \geq \epsilon^2$  și dispersia poate fi minorată prin

$$\sigma^2 \geq \epsilon^2 \left( \int_{-\infty}^{m-\epsilon} f(x) dx + \int_{m+\epsilon}^{\infty} f(x) dx \right) =$$

$$= \epsilon^2 \left( 1 - \int_{m-\epsilon}^{m+\epsilon} f(x) dx \right),$$

deoarece  $\int_{-\infty}^{\infty} f(x) dx = 1$ . Ultima paranteză se poate scrie

$$\sigma^2 \geq \epsilon^2 (1 - P(\{|X - m| < \epsilon\})),$$

care este echivalentă cu relația (3.40). ■

**Exemplul 3.4.4** Timpul mediu de răspuns al unui calculator este de 15 secunde pentru o anumită operație, cu abaterea medie pătratică 3 secunde. Estimați probabilitatea ca timpul de răspuns să se abată cu mai puțin de 5 secunde față de medie. Vom folosi inegalitatea lui Cebâșev. Avem

$$P(\{|X - 15| \geq 5\}) \leq \frac{9}{25} = 0,36.$$

Reamintim că *momentul absolut* de ordin  $k$  pentru o variabilă aleatoare se definește prin formula  $\beta_k = M[|X|^k]$ . Dacă  $X$  are densitatea de probabilitate  $f$ , atunci momentul absolut este dat de formula

$$\beta_k = \int_{-\infty}^{\infty} |x|^k f_X(x) dx.$$

Observăm că existența momentelor absolute de ordin  $k$ , antrenează existența momentelor inițiale de ordin  $k$ , deoarece

$$\left| \int_{-\infty}^{\infty} x^k f(x) dx \right| \leq \int_{-\infty}^{\infty} |x|^k f(x) dx < \infty,$$

iar din presupunerea făcută, a doua integrală este convergentă. De asemenea, dacă există moment absolut de ordin  $k$ , există momente absolute de orice ordin  $l \leq k$ . Într-adevăr,

$$\begin{aligned} \int_{-\infty}^{\infty} |x|^l f(x) dx &= \int_{|x| \leq 1} |x|^l f(x) dx + \int_{|x| > 1} |x|^l f(x) dx \leq \\ &\leq \int_{|x| \leq 1} |x|^l f(x) dx + \int_{|x| > 1} |x|^k f(x) dx. \end{aligned}$$

Prima integrală este finită datorită domeniului de integrare, iar a doua din presupunerea făcută.

Inegalitatea lui Cebâșev poate fi generalizată pentru momente absolute de orice ordin  $k \in \mathbb{N}$ , în sensul următor: dacă variabila aleatoare  $X$  are moment absolut de ordin  $k$ , atunci

$$P(\{|X - m| < \epsilon\}) \geq 1 - \frac{M[|X - m|^k]}{\epsilon^k}, \forall \epsilon > 0, \tag{3.41}$$

sau echivalent

$$P(\{|X - m| \geq \epsilon\}) < \frac{M[|X - m|^k]}{\epsilon^k}.$$

**Propoziția 3.4.4** (Inegalitatea lui Schwarz) *Dacă variabilele aleatoare  $X$  și  $Y$  au momente absolute de ordin 2, atunci  $XY$  are moment absolut de ordin 2 și*

$$\beta_2(XY) \leq \sqrt{\beta_2(x)\beta_2(y)}. \quad (3.42)$$

**Demonstrație.** Pentru orice  $\lambda \in \mathbb{R}$ , inegalitatea  $M[(|X| + \lambda|Y|)^2] \geq 0$  este evidentă. Efectuând calculele avem

$$M[(X + \lambda Y)^2] = \lambda^2 M[X^2] + 2\lambda M[|XY|] + M[Y^2] \geq 0,$$

și folosind semnul funcției de gradul al doilea, inegalitatea precedentă este adevărată dacă discriminantul  $\Delta \leq 0$ , ceea ce revine la

$$M[|XY|^2] \leq M[X^2]M[Y^2].$$

De unde, după extragerea radicalului găsim (3.42). ■

Observăm că, în aceleași ipoteze, rezultă și

$$|M[XY]| \leq \sqrt{M[X^2]M[Y^2]}.$$

**Definiția 3.4.3** *Fie  $X$  și  $Y$  două variabile aleatoare pentru care există momentele absolute de ordinul al doilea. Numărul definit de*

$$Cov[X, Y] = M[(X - M[X])(Y - M[Y])]$$

*se numește covarianța variabilelor  $X$  și  $Y$ , iar numărul dat de formula*

$$\rho[X, Y] = \frac{Cov[X, Y]}{D[X]D[Y]}, \quad (3.43)$$

*dacă  $D[X] \neq 0$ ,  $D[Y] \neq 0$ , se numește coeficient de corelație. Variabilele aleatoare  $X$  și  $Y$  se numesc necorelate dacă*

$$M[XY] = M[X]M[Y].$$

Observăm că dacă  $X$  și  $Y$  sunt independente, din Propoziția 3.4.2 rezultă că sunt necorelate. Se pot da exemple care să ilustreze că reciproca afirmației precedente nu este adevărată, adică pot exista variabile aleatoare necorelate fără ca ele să fie independente. Dacă  $X$  și  $Y$  sunt variabile aleatoare continue care admit momente absolute de ordinul al doilea, dispersia sumei se calculează după formula

$$D^2(X + Y) = D^2(X) + D^2(Y) + 2Cov[X, Y].$$

Această formulă se generalizează ușor în cazul a  $n$  variabile. Din formula (3.43) rezultă imediat că

$$\rho[X, X] = 1,$$

iar

$$\rho[X, Y] = 0 \text{ dacă și numai dacă } X \text{ și } Y \text{ sunt necorelate.}$$

**Propoziția 3.4.5** Pentru oricare două variabile  $X$  și  $Y$ , care admit coeficient de corelație, este satisfăcută inegalitatea

$$|\rho[X, Y]| \leq 1. \tag{3.44}$$

**Demonstrație.** Considerăm variabilele aleatoare  $X' = \frac{X - M[X]}{D[X]}, Y' = \frac{Y - M[Y]}{D[Y]}$  și le aplicăm inegalitatea lui Schwarz. Rezultă

$$|M[X'Y']| \leq \sqrt{M[X'^2]M[Y'^2]}.$$

Rămâne să observăm că

$$\rho[X, Y] = M[X', Y'] = \frac{M[(X - M(X))(Y - M(Y))]}{D[X]D[Y]}$$

și că  $M[X'^2] = \frac{D^2[X]}{D^2[X]} = 1$ . După efectuarea înlocuirilor, se obține formula(3.44). ■

**Propoziția 3.4.6** Pentru oricare două variabile aleatoare, ce admit coeficient de corelație, următoarele afirmații sunt echivalente:

1.  $|\rho[X, Y]| = 1$ ;
2. există  $a, b \in \mathbb{R}$ , nesimultan nule și  $c \in \mathbb{R}$ , astfel încât relația  $aX + bY + c = 0$  are loc aproape sigur (adică  $P(\{aX + bY + c = 0\}) = 1$ ).

Vom schița demonstrația. Într-un sens afirmația este imediată; anume dacă are loc  $aX + bY + c = 0$  aproape sigur și presupunem  $b \neq 0$ , găsim  $m, n \in \mathbb{R}$  astfel ca  $Y = mX + n$ . Observăm imediat că

$$\rho[X, Y] = \begin{cases} 1, & \text{dacă } m > 0 \\ -1, & \text{dacă } m < 0. \end{cases}$$

Reciproc, dacă  $X' = \frac{X - M[X]}{D[X]}, Y' = \frac{Y - M[Y]}{D[Y]}$ , atunci sunt evidente următoarele relații  $\rho[X, Y] = M[X'Y'] = 1$  și  $M[(X' \pm Y')^2] = 0$ . Într-un cadru mai general decât cel prezentat în acest curs (vezi [22]), se poate arăta că din ultima egalitate rezultă că  $X' \pm Y' = 0$  aproape sigur, deci:

$$\frac{X - M[X]}{D[X]} = \pm \frac{Y - M[Y]}{D[Y]}.$$

Schimbând eventual notațiile, din ultima egalitate deducem 2.

Noțiunea de moment poate fi extinsă la variabile aleatoare multidimensionale.

**Definiția 3.4.4** Dacă  $(X_1, \dots, X_n)$  este o variabilă aleatoare  $n$ -dimensională cu densitatea de probabilitate  $f_{X_1 \dots X_n}$ , numim moment inițial de ordinul  $(k_1 \dots k_n)$  numărul

$$\nu_{k_1 \dots k_n} = M[X_1^{k_1}, \dots, X_n^{k_n}] = \int \dots \int_{\mathbb{R}^n} x_1^{k_1} \dots x_n^{k_n} f_{X_1 \dots X_n}(x_1, \dots, x_n) dx_1 \dots dx_n.$$

**Definiția 3.4.5** Dacă  $X$  și  $Y$  sunt două variabile aleatoare  $n$ -dimensionale, matricea de elemente

$$Cov[X_i Y_j], i = 1, \dots, n, j = 1, \dots, n.$$

se numește matricea de covarianță.

**Medii condiționate.**

Dacă  $X$  este o variabilă aleatoare cu densitatea de probabilitate  $f$  și  $A \in K$ , definim media lui  $X$  condiționată de  $A$

$$M[x|A] = \int_{-\infty}^{+\infty} xf(x|A)dx \quad (3.45)$$

unde  $f(x|A)$  este densitatea de probabilitate a lui  $X$  condiționată de  $A$ .

**Exemplul 3.4.5** Fie  $T$  variabila aleatoare care dă timpul de funcționare până la prima defectare. Să determinăm media lui  $T$ , condiționată de faptul că sistemul a funcționat până la momentul  $t$ . Folosind un raționament asemănător cu cel pentru deducerea formulei (3.15), deducem

$$f(x|\{T \leq t\}) = \frac{f(x)}{\int_t^{+\infty} f(x)dx}, \quad x \leq t.$$

Atunci cu ajutorul relației (3.45), obținem

$$M[T|\{T \leq t\}] = \frac{\int_t^{+\infty} xf(x)dx}{\int_t^{+\infty} f(x)dx}.$$

Dacă  $X$  și  $Y$  sunt două variabile aleatoare cu densitățile de probabilitate  $f_X$ ,  $f_Y$  definim *mediile condiționate* prin formulele

$$M[Y|x] = \int_{-\infty}^{+\infty} yf_Y(y|x)dy$$

$$M[X|y] = \int_{-\infty}^{+\infty} xf_X(x|y)dx,$$

dacă există. Se poate arata că mediile condiționate sunt de fapt variabile aleatoare, care admit la rândul lor medie, ce se exprimă prin **formulele integrale ale mediei totale**.

$$M[Y] = \int_{-\infty}^{+\infty} M[Y|x]f_X(x)dx$$

$$M[X] = \int_{-\infty}^{+\infty} M[X|y]f_Y(y)dy.$$

Să deducem prima egalitate.

$$\begin{aligned} \int_{-\infty}^{+\infty} M[Y|x]f_X(x)dx &= \int_{-\infty}^{+\infty} f_X(x)dx \int_{-\infty}^{+\infty} yf_Y(y|x)dy = \\ &= \int_{-\infty}^{+\infty} ydy \int_{-\infty}^{+\infty} f_Y(y|x)f_X(x)dx. \end{aligned}$$

Dacă folosim (3.32) și densitatea de probabilitate marginală, deducem că ultima formulă reprezintă chiar  $M[Y]$ .

**Exemplul 3.4.6** Numărul de "clienți" care ajunge la "o stație de deservire" într-un interval de timp  $t$  este o variabilă aleatoare Poisson cu parametrul  $\beta t$ . Timpul necesar deservirii fiecăruia este o variabilă exponențială,  $T$ , cu parametrul  $\alpha$ , deci are densitatea de probabilitate

$$f(t) = \begin{cases} \alpha e^{-\alpha t}, & \text{dacă } t \geq 0 \\ 0, & \text{dacă } t < 0 \end{cases} \quad (\alpha > 0).$$

Să determinăm repartiția variabilei  $N$ , care dă numărul de clienți ce ajung în timpul  $T$  al deservirii unui client, media și dispersia, în ipoteza că sosirile clienților sunt independente de timpul de deservire. Aplicăm formula probabilității totale

$$\begin{aligned} P(\{N = k\}) &= \int_{-\infty}^{+\infty} P(\{N = k\} | \{T = t\}) f_T(t) dt = \int_0^{+\infty} \frac{(\beta t)^k}{k!} e^{-\beta t} \alpha e^{-\alpha t} dt = \\ &= \frac{\alpha \beta^k}{k!} \int_0^{+\infty} t^k e^{-(\alpha + \beta)t} dt. \end{aligned}$$

Făcând schimbarea de variabile  $r = (\alpha + \beta)t$  șirul de egalități poate fi continuat,

$$\frac{\alpha \beta^k}{k! (\alpha + \beta)^{k+1}} \int_0^{+\infty} r^k e^{-r} dr = \frac{\alpha \beta^k}{(\alpha + \beta)^{k+1}} = \frac{\alpha}{\alpha + \beta} \left( \frac{\beta}{\alpha + \beta} \right)^k.$$

Deci  $N$  este o variabilă aleatoare geometrică. Dacă se produce  $\{T = t\}$ , variabila condiționată este Poisson, cu parametrul  $\beta t$ . Rezultă că media și dispersia au aceeași valoare și anume  $\beta t$ . Pentru calculul mediei lui  $N$  putem folosi formula mediei totale

$$M[N] = \int_0^{+\infty} M[N|t] f_T(t) dt = \int_0^{+\infty} \beta t f_T(t) dt = \beta M[T].$$

$$M[N^2] = \int_0^{+\infty} M[N^2|t] f_T(t) dt = \int_0^{+\infty} (\beta t + \beta^2 t^2) f_T(t) dt = \beta M[T] + \beta^2 M[T^2].$$

Să mai observăm că  $T$  fiind variabilă exponențială  $M[T] = \frac{1}{\alpha}$ ,  $D^2[T] = \frac{1}{\alpha^2}$ . Deci  $M[N] = \frac{\beta}{\alpha}$ ,  $D^2[N] = \frac{\beta^2}{\alpha^2} + \frac{\beta}{\alpha}$ .

### 3.5 Funcția caracteristică a unei variabile aleatoare

În acest capitol am văzut că densitatea de probabilitate a sumei de variabile aleatoare independente este produsul de convoluție al densităților de probabilitate, dar analitic este uneori dificil de aplicat acest rezultat. Un instrument mai comod este funcția caracteristică, pe care o vom utiliza și la determinarea momentelor unei variabile aleatoare.

Fie  $X$  o variabilă aleatoare continuă având densitatea de probabilitate  $f_X$ .

**Definiția 3.5.1** Numim funcție caracteristică asociată variabilei aleatoare  $X$ , funcția  $\varphi : \mathbb{R} \rightarrow \mathbb{C}$ , definită prin

$$\varphi(t) = M[e^{itX}] = \int_{-\infty}^{\infty} e^{itx} f_X(x) dx.$$

Tinând cont că  $e^{iy} = \cos y + i \sin y$  cu  $y \in \mathbb{R}$ ,  $e^{itX}$  reprezintă o variabilă aleatoare bidimensională cu componentele  $(\cos tX, \sin tX)$ . Deoarece  $|e^{itx}| = 1$ , funcția caracteristică există pentru orice variabilă aleatoare ce admite densitate de probabilitate. Vom mai nota  $\varphi_X(t)$ , pentru a pune în evidență cărei variabile aleatoare i se asociază funcția caracteristică. Definiția funcției caracteristice reprezintă transformata Fourier aplicată funcției absolut integrabile  $f_X$ ; o formulă de inversare va fi formulată în prezența condiției suplimentare de absolută integrabilitate a funcției caracteristice, în Teorema 5.3 din acest capitol.

**Propoziția 3.5.1** Următoarele afirmații sunt adevărate :

1.  $\varphi(0) = 1$ ;
2.  $|\varphi(t)| \leq 1$ ;
3.  $\varphi(-t) = \overline{\varphi(t)}$ ;
4.  $\varphi(t)$  este uniform continuă pe  $\mathbb{R}$ .

**Demonstrație.**

1. și 2. sunt evidente.
3. Să calculăm

$$\varphi(-t) = \int_{-\infty}^{\infty} e^{-itx} \varphi(x) dx = \int_{-\infty}^{\infty} \overline{e^{itx}} f(x) dx = \overline{\int_{-\infty}^{\infty} e^{itx} f(x) dx} = \overline{\varphi(t)}.$$

4. Pentru a arăta că  $\varphi$  este uniform continuă, să calculăm:

$$|\varphi(t+h) - \varphi(t)| = \left| \int_{-\infty}^{\infty} e^{itx} (e^{ihx} - 1) f(x) dx \right| \leq \int_{-\infty}^{\infty} |e^{ihx} - 1| f(x) dx.$$

Deoarece  $\int_{-\infty}^{\infty} f(x) dx = 1$ , pentru orice  $\epsilon > 0$ , există  $A$  suficient de mare astfel încât

$$\int_{|x| \geq A} f(x) dx < \epsilon/4,$$

iar din continuitatea exponențialei există  $h$  suficient de mic încât  $|e^{ihx} - 1| < \epsilon/2$ . Atunci putem scrie

$$|\varphi(t+h) - \varphi(t)| \leq \int_{-A}^A |e^{ihx} - 1| f(x) dx + \int_{|x| \geq A} f(x) dx < \epsilon.$$

■

**Observație.** Următoarele afirmații sunt echivalente : o funcție caracteristică este reală;  $f(-x) = f(x)$ ;  $F(x) = 1 - F(-x)$ , unde  $F$  și  $f$  sunt funcțiile de repartiție, respectiv de densitate de probabilitate. Egalitățile dintre funcțiile precedente au loc în



cazul cel mai general cu excepția unei mulțimi de probabilitate nulă (deci aproape sigur). Demonstrăm afirmația în cazul în care  $f$  este continuă. Arătăm, mai întâi, că ultimele două afirmații sunt echivalente. Avem

$$F'(x) = (1 - F(-x))' \Rightarrow f(x) = f(-x).$$

Reciproc, dacă  $f(x) = f(-x)$

$$\begin{aligned} F(x) &= \int_{-\infty}^x f(t)dt = 1 - \int_x^{\infty} f(t)dt = 1 + \int_{-x}^{-\infty} f(-u)du = \\ &= 1 - \int_{-\infty}^{-x} f(u)du = 1 - F(-x). \end{aligned}$$

În ce privește echivalența primelor două relații se observă imediat că

$$f(x) = f(-x) \implies \varphi(t) = \int_{-\infty}^{\infty} e^{itx} f(x)dx = \int_{-\infty}^{\infty} e^{-itx} f(x)dx = \varphi(-t) = \overline{\varphi(t)}.$$

Se poate arăta, în prezența unor rezultate suplimentare și care nu sunt cuprinse în acest curs, că din faptul că  $\varphi$  este reală, rezultă  $f(x) = f(-x)$ .

**Propoziția 3.5.2** 1. Dacă  $Y = aX + b$ , cu  $a, b \in \mathbb{R}$ , atunci  $\varphi_Y(t) = e^{itb}\varphi_X(at)$ ;  
 2. Dacă  $X$  și  $Y$  sunt independente, atunci  $\varphi_{X+Y} = \varphi_X\varphi_Y$ .

**Demonstrație.**

1.  $\varphi_Y(t) = M[e^{ity}] = M[e^{it(aX+b)}] = e^{itb}M[e^{itaX}] = e^{itb}\varphi_X(at)$ .
2.  $\varphi_{X+Y}(t) = M(e^{it(X+Y)}) = M(e^{itX}e^{itY}) = \varphi_X(t)\varphi_Y(t)$ . ■

Cunoașterea funcției caracteristice permite calculul momentelor inițiale, după cum rezultă din următoarea teoremă.

**Teorema 3.5.1** Dacă o variabilă aleatoare admite moment absolut de ordin  $n$ ,  $n \in \mathbb{N}$ , atunci funcția caracteristică este de  $n$  ori derivabilă și are loc :

$$\nu_k = \frac{\varphi^{(k)}(0)}{i^k}, k = 1, \dots, n.$$

**Demonstrație.** Derivăm formal de  $k$  ori sub integrala cu parametru din definiția funcției caracteristice. Găsim după majorări

$$\varphi^{(k)}(t) = i^k \int_{-\infty}^{\infty} x^k e^{itx} f(x)dx,$$

iar

$$\left| \int_{-\infty}^{\infty} x^k e^{itx} f(x)dx \right| \leq \beta_k \leq \beta_n, \forall k = 1, \dots, n,$$

deci derivatele există. Dacă în formula de derivare luăm  $t = 0$ , găsim

$$\varphi^{(k)}(0) = i^k \nu_k.$$

■

**Teorema 3.5.2** *Dacă  $X$  este o variabilă aleatoare continuă care admite momente absolute de orice ordin, atunci funcția caracteristică admite dezvoltare în serie de puteri de forma*

$$\varphi(t) = \sum_{k=0}^{\infty} \frac{(it)^k}{k!} \nu_k.$$

**Demonstrație.** Înlocuim în definiția funcției caracteristice dezvoltarea în serie a exponențialei și găsim

$$\begin{aligned} \varphi(t) &= \int_{-\infty}^{\infty} e^{itx} \varphi(x) dx = \\ &= \int_{-\infty}^{\infty} \left( 1 + \frac{itx}{1!} + \dots + \frac{(itx)^{n-1}}{(n-1)!} + \frac{(itx)^n}{n!} e^{ix\theta} \right) f(x) dx = \\ &= \nu_0 + \frac{it}{1!} \nu_1 + \dots + \frac{(it)^{n-1}}{(n-1)!} \nu_{n-1} + R_n. \end{aligned}$$

Majorând restul obținem

$$|R_n| = \left| \frac{(it)^n}{n!} \int_{-\infty}^{\infty} x^n e^{it\theta} f(x) dx \right| \leq \frac{|t|^n}{n!} \int_{-\infty}^{\infty} |x|^n f(x) dx < \infty.$$

Se observă că  $\lim_{n \rightarrow \infty} R_n = 0$ , deci afirmația este adevărată. ■

**Teorema 3.5.3 (Formula de inversiune)** *Fie  $X$  o variabilă aleatoare având  $\varphi$  și  $F$ , respectiv, funcția caracteristică și funcția de repartiție. Dacă  $x_1, x_2$ , cu  $x_1 < x_2$  sunt puncte de continuitate ale lui  $F$ , atunci are loc*

$$F(x_2) - F(x_1) = \lim_{c \rightarrow \infty} \frac{1}{2\pi} \int_{-c}^c \frac{e^{-itx_1} - e^{-itx_2}}{it} \varphi(t) dt. \quad (3.46)$$

**Demonstrație.** Observăm că pentru  $c \in \mathbb{R}$ , funcția de sub integrală este continuă, dacă o definim în  $t = 0$  prin

$$\lim_{t \rightarrow 0} \frac{e^{-itx_1} - e^{-itx_2}}{it} = (x_2 - x_1) \varphi(0).$$

De asemenea, funcția are un majorant integrabil, deci integrala

$$I_c = \frac{1}{2\pi} \int_{-c}^c \frac{e^{-itx_1} - e^{-itx_2}}{it} \varphi(t) dt$$

este convergentă. Considerăm cazul particular în care  $X$  are densitate de probabilitate  $f$  și înlocuim în integrala precedentă pe  $\varphi$

$$I_c = \frac{1}{2\pi} \int_{-c}^c \int_{-\infty}^{\infty} \frac{e^{-itx_1} - e^{-itx_2}}{it} e^{itz} f(z) dz dt.$$

Prin schimbarea ordinii de integrare (posibilă deoarece în raport cu  $z$  avem absolută convergență, iar în raport cu  $t$  integrarea se face pe interval finit), găsim

$$I_c = \frac{1}{2\pi} \int_{-\infty}^{\infty} \left( \int_{-c}^c \frac{e^{it(z-x_1)} - e^{it(z-x_2)}}{it} dt \right) f(z) dz =$$

$$= \frac{1}{2\pi} \int_{-\infty}^{\infty} \left( \int_{-c}^0 \frac{e^{it(z-x_1)} - e^{it(z-x_2)}}{it} dt + \int_0^c \frac{e^{it(z-x_1)} - e^{it(z-x_2)}}{it} dt \right) f(z) dz.$$

În prima integrală făcând schimbarea  $t \rightarrow -t$ , obținem

$$\begin{aligned} I_c &= \frac{1}{2\pi} \int_{-\infty}^{\infty} \left( \int_0^c \frac{-e^{-it(z-x_1)} + e^{-it(z-x_2)} + e^{it(z-x_1)} - e^{it(z-x_2)}}{it} dt \right) f(z) dz = \\ &= \frac{1}{\pi} \int_{-\infty}^{\infty} \int_0^c \left( \frac{\sin t(z-x_1)}{t} - \frac{\sin t(z-x_2)}{t} \right) dt f(z) dz \end{aligned}$$

Alegem un  $\delta > 0$  astfel încât  $x_1 + \delta < x_2 - \delta$  și descompunem integrala pe domeniile :

$$(-\infty, x_1 - \delta), (x_1 - \delta, x_1 + \delta), (x_1 + \delta, x_2 - \delta), (x_2 - \delta, x_2 + \delta), (x_2 + \delta, \infty).$$

Reamintim formula lui Dirichlet [10] :

$$\lim_{c \rightarrow \infty} \frac{1}{\pi} \int_0^c \frac{\sin \alpha t}{t} dt = \begin{cases} 1/2, & \text{dacă } \alpha > 0 \\ -1/2, & \text{dacă } \alpha < 0 \end{cases}$$

unde limita este uniformă în raport cu  $\alpha$ . Pe intervalul  $(-\infty, x_1 - \delta)$ , avem  $z - x_2 < z - x_1 < -\delta < 0$ , deci

$$\frac{1}{\pi} \int_0^c \left( \frac{\sin t(z-x_1)}{t} - \frac{\sin t(z-x_2)}{t} \right) dt \rightarrow 0, \text{ dacă } c \rightarrow \infty$$

și cum integrala este uniform mărginită în raport cu  $c$ , putem comuta integrala cu limita și obținem

$$\int_{-\infty}^{x_1-\delta} \frac{1}{\pi} \int_0^c \left( \frac{\sin t(z-x_1)}{t} - \frac{\sin t(z-x_2)}{t} \right) dt f(z) dz \rightarrow 0, \text{ dacă } c \rightarrow \infty \quad (3.47)$$

și analog

$$\int_{x_2+\delta}^{\infty} \frac{1}{\pi} \int_0^c \left( \frac{\sin t(z-x_1)}{t} - \frac{\sin t(z-x_2)}{t} \right) dt f(z) dz \rightarrow 0, \text{ pentru } c \rightarrow \infty. \quad (3.48)$$

Pe intervalul  $(x_1 + \delta, x_2 - \delta)$  folosind formula lui Dirichlet și convergența uniformă în raport cu  $\alpha$ , deducem

$$\begin{aligned} &\lim_{c \rightarrow \infty} \int_{x_1+\delta}^{x_2-\delta} \frac{1}{\pi} \int_0^c \left( \frac{\sin t(z-x_1)}{t} - \frac{\sin t(z-x_2)}{t} \right) dt f(z) dz = \\ &= \int_{x_1+\delta}^{x_2-\delta} \left( \frac{\sin t(z-x_1)}{t} - \frac{\sin t(z-x_2)}{t} \right) dt f(z) dz = F(x_2 - \delta) - F(x_1 + \delta). \end{aligned} \quad (3.49)$$

Pe intervalele  $(x_1 - \delta, x_1 + \delta)$  și  $(x_2 - \delta, x_2 + \delta)$ , integralele pot fi majorate respectiv, dacă folosim din nou formula lui Dirichlet, cu

$$\begin{aligned} &2(F(x_1 + \delta) - F(x_1 - \delta)), \\ &2(F(x_2 + \delta) - F(x_2 - \delta)). \end{aligned} \quad (3.50)$$

Pentru orice  $\epsilon > 0$ , din (3.47) și (3.48) există  $c_\epsilon$  astfel încât  $\forall c > c_\epsilon$  are loc

$$\begin{aligned} & \left| \frac{1}{\pi} \int_{-\infty}^{\infty} \left( \int_0^c \left( \frac{\sin t(z-x_1)}{t} - \frac{\sin t(z-x_2)}{t} \right) \right) f(z) dz \right| \leq \\ & \leq \epsilon/3 + \epsilon/3 + F(x_2 - \delta) - F(x_1 + \delta)/3 + 2(F(x_1 + \delta) - \\ & \quad - F(x_1 - \delta) + F(x_2 + \delta) - F(x_2 - \delta)). \end{aligned}$$

În inegalitatea de mai sus au intervenit și relațiile (3.49) și (3.50). Deoarece  $x_1$  și  $x_2$  sunt puncte de continuitate pentru  $F$

$$\lim_{\delta \rightarrow 0} (F(x_1 + \delta) - F(x_1 - \delta)) = \lim_{\delta \rightarrow 0} (F(x_2 + \delta) - F(x_2 - \delta)) = 0.$$

Trecând apoi la limită pentru  $c \rightarrow \infty$ , găsim formula (3.46). ■

Această teoremă ne permite să stabilim o corespondență biunivocă între funcțiile de repartiție și cele caracteristice, după cum rezultă din următoarea teoremă.

**Teorema 3.5.4** (Teorema de unicitate) *Funcția de repartiție este unic determinată de funcția sa caracteristică.*

**Demonstrație.** În teorema precedentă facem pe  $x_1$  să tindă la  $\infty$ ,  $x_1$  rămânând punct de continuitate. Deoarece  $\lim_{x_1 \rightarrow -\infty} F(x_1) = 0$ , găsim

$$F(x_2) = \lim_{x_1 \rightarrow -\infty} \lim_{c \rightarrow \infty} \int_{-c}^c \frac{e^{-itx_1} - e^{-itx_2}}{it} \varphi(t) dt$$

$\forall x_1, x_2$  puncte de continuitate ale lui  $F$ . ■

**Teorema 3.5.5** *Dacă funcția caracteristică este absolut integrabilă pe  $\mathbb{R}$ , adică*

$$\int_{-\infty}^{\infty} |\varphi(t)| dt < \infty,$$

*atunci  $F$  are derivată simetrică pe  $\mathbb{R}$ , deci  $\forall x \in \mathbb{R}$ , există*

$$\lim_{h \rightarrow 0} \frac{F(x+h) - F(x-h)}{2h} = F'_s(x),$$

*și*

$$F'_s(x) = f(x)$$

*în orice punct de continuitate a lui  $f$ .*

**Demonstrație.** Pentru orice două puncte de continuitate ale lui  $F$ , are loc din formula de inversiune

$$F(x_2) - F(x_1) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \frac{e^{-itx_1} - e^{-itx_2}}{it} \varphi(t) dt,$$

deoarece folosind ipoteza, funcția din membrul al doilea este integrabilă. Presupunând că  $x_1 = x - h, x_2 = x + h$ , atunci :

$$F(x + h) - F(x - h) = 2h \frac{1}{2\pi} \int_{-\infty}^{\infty} \frac{\sin th}{th} e^{-itx} \varphi(t) dt.$$

Deoarece

$$\left| \frac{\sin th}{th} \right| \leq 1,$$

avem

$$\left| e^{-itx} \frac{\sin th}{th} \varphi(t) \right| \leq |\varphi(t)|, \quad \forall h \in \mathbb{R},$$

și

$$\lim_{h \rightarrow 0} e^{-itx} \frac{\sin th}{th} = e^{-itx}.$$

Într-un cadru mult mai general decât cel prezent, se poate demonstra un criteriu de convergență dominată a lui Lebesgue [22], în baza căruia putem trece la limită sub integrală și găsim

$$F'_s = \lim_{h \rightarrow 0} \frac{F(x + h) - F(x - h)}{2h} = \frac{1}{2\pi} \int_{-\infty}^{\infty} e^{-itx} \varphi(t) dt. \quad (3.51)$$

Să demonstrăm că  $F'_s$  este continuă; într-adevăr

$$\begin{aligned} |F'_s(x + h) - F'_s(x)| &\leq \frac{1}{2\pi} \int_{-\infty}^{\infty} 2 \left| \sin \frac{th}{2} \right| |\varphi(t)| dt = \\ &= \frac{1}{\pi} \int_{|t| \leq A} \left| \sin \frac{th}{2} \right| |\varphi(t)| dt + \frac{1}{\pi} \int_{|t| > A} \left| \sin \frac{th}{2} \right| |\varphi(t)| dt. \end{aligned}$$

Pentru  $\epsilon > 0$  putem alege  $A$  suficient de mare încât

$$\frac{1}{\pi} \int_{|t| > A} |\varphi(t)| dt < \epsilon/2.$$

Prima integrală poate fi făcută  $< \epsilon/2$ , dacă alegem  $h$  suficient de mic, deci

$$|F'_s(x + h) - F'_s(x)| < \epsilon,$$

de unde rezultă continuitatea. Reamintim că în orice punct de continuitate pentru  $f$ , are loc  $F'(x) = f(x)$ , de unde afirmația teoremei, deoarece derivata simetrică coincide cu derivata. ■

Relația (3.51) constituie formula de inversare, care exprimă densitatea de probabilitate cu ajutorul funcției caracteristice. Vom demonstra în continuare teorema lui Bochner, care dă o descriere completă a funcțiilor caracteristice, acest rezultat fiindu-ne necesar la studiul proceselor stochastice staționare.

**Definiția 3.5.2** Funcția  $\varphi : \mathbb{R} \rightarrow \mathbb{R}$ , continuă, se numește pozitiv definită pe  $\mathbb{R}$ , dacă  $\forall t_1, \dots, t_n \in \mathbb{R}$  și  $z_1, \dots, z_n \in \mathbb{C}$ ,  $\forall n \in \mathbb{N}$ , are loc

$$\sum_{k=1}^n \sum_{j=1}^n \varphi(t_j - t_k) z_j \bar{z}_k \geq 0.$$

Câteva proprietăți decurg imediat din definiție.

1.  $\varphi(0) \geq 0$ .

Într-adevăr pentru  $n = 1, t_1 = 0, z_1 = 1$ , afirmația este evidentă.

2.  $\varphi(-t) = \overline{\varphi(t)}$ ,  $\forall t \in \mathbb{R}$ .

Aceasta rezultă dacă luăm  $n = 2, t_1 = 0, t_2 = t, z_1, z_2 \in \mathbb{C}$ .

$$\begin{aligned} 0 &\leq \sum_{k=1}^2 \sum_{j=1}^2 \varphi(t_k - t_j) z_k \bar{z}_j = \varphi(0 - 0) z_1 \bar{z}_1 + \varphi(0 - t) z_1 \bar{z}_2 + \varphi(t - 0) z_2 \bar{z}_1 + \varphi(t - t) z_2 \bar{z}_2 = \\ &= \varphi(0)(|z_1|^2 + |z_2|^2) + \varphi(-t) z_1 \bar{z}_2 + \varphi(t) \bar{z}_1 z_2, \end{aligned}$$

și deci  $\varphi(-t) z_1 \bar{z}_2 + \varphi(t) \bar{z}_1 z_2 \in \mathbb{R}$ . Dacă luăm

$$\begin{aligned} \varphi(-t) &= \alpha_1 + i\beta_1, & \varphi(t) &= \alpha_2 + i\beta_2, \\ z_1 \bar{z}_2 &= \gamma + i\delta, & \bar{z}_1 z_2 &= \gamma - i\delta, \end{aligned}$$

rezultă  $\alpha_1 \delta + \beta_1 \gamma - \alpha_2 \delta + \beta_2 \gamma = 0, \forall \gamma, \delta$ , deci obținem  $\alpha_1 = \alpha_2$  și  $\beta_1 + \beta_2 = 0$ .

3.  $|\varphi(t)| \leq \varphi(0)$ .

În inegalitatea de la punctul precedent, fie  $z_1 = \varphi(t), z_2 = -|\varphi(t)|$ , atunci deducem

$$2\varphi(0)|\varphi(t)|^2 - |\varphi(t)|^2|\varphi(t)| - |\varphi(t)|^2|\varphi(t)| \geq 0,$$

De unde, dacă  $|\varphi(t)| \neq 0$  rezultă  $\varphi(0) \geq |\varphi(t)|$ , iar dacă  $|\varphi(t)| = 0$ , din prima proprietate deducem din nou afirmația.

**Teorema 3.5.6** (Bochner-Hincin) O funcție  $\varphi(t)$  continuă, cu condiția  $\varphi(0) = 1$  este o funcție caracteristică, dacă și numai dacă este pozitiv definită.

**Demonstrație.** Dacă  $\varphi$  este funcție caracteristică pentru o variabilă aleatoare cu densitatea de probabilitate  $f$ , are loc

$$\varphi(t) = \int_{-\infty}^{\infty} e^{itx} f(x) dx.$$

Să demonstrăm că este pozitiv definită. Avem

$$\begin{aligned} \sum_{k=1}^n \sum_{j=1}^n \varphi(t_j - t_k) z_j \bar{z}_k &= \sum_{k=1}^n \sum_{j=1}^n \left( \int_{-\infty}^{\infty} e^{ix(t_k - t_j)} f(x) dx z_k \bar{z}_j \right) = \\ &= \int_{-\infty}^{\infty} \sum_{k=1}^n \sum_{j=1}^n e^{ix(t_k - t_j)} f(x) z_k \bar{z}_j dx = \int_{-\infty}^{\infty} \left( \sum_{k=1}^n e^{it_k x} z_k \right) \left( \sum_{j=1}^n e^{-it_j x} \bar{z}_j \right) f(x) dx = \end{aligned}$$

$$= \int_{-\infty}^{\infty} \left| \sum_{k=1}^n e^{it_k x} z_k \right|^2 f(x) dx \geq 0.$$

Reciproc. Pentru  $Z > 0$ , considerăm funcția

$$p_Z(x) = \frac{1}{2\pi Z} \int_0^Z \int_0^Z \varphi(u-v) e^{-iux} e^{ivx} dudv.$$

Dacă scriem integrala dublă ca limită a sumelor Riemann corespunzătoare și folosim pozitivă definire a lui  $\varphi$ , rezultă că  $p_Z \geq 0$ . Facem în integrala dublă schimbarea de variabile

$$\begin{cases} t = u - v \\ z = u \end{cases}$$

cu inversa

$$\begin{cases} u = z \\ v = z - t. \end{cases}$$

Domeniul  $[0, Z] \times [0, Z]$  din Figura 3.12 este dus în domeniul reprezentat în figură 3.13. Se obține imediat

$$p_Z(x) = \frac{1}{2\pi} \int_{-Z}^Z \left(1 - \frac{|t|}{Z}\right) \varphi(t) e^{-itx} dt.$$

Să demonstrăm că  $p_Z(x)$  este integrabilă pe  $R$ . Vom reface în acest scop o demonstrație datorată lui Yu Linnik, pe acest caz particular. Notăm

$$G(x) = \int_{-x}^x p_Z(z) dz$$

și înlocuim  $p_Z$ , după care schimbăm ordinea de integrare. Obținem

$$G(x) = \frac{1}{2\pi} \int_{-x}^x \int_{-Z}^Z \left(1 - \frac{|t|}{Z}\right) \varphi(t) e^{-itz} dt dz.$$

Întroducând funcția

$$p(t) = \begin{cases} \left(1 - \frac{|t|}{Z}\right) \varphi(t), & |t| \leq Z \\ 0, & |t| > Z \end{cases},$$

deducem

$$G(x) = \frac{1}{2\pi} \int_{-Z}^Z p(t) \int_{-x}^x e^{-itx} dz dt = \frac{1}{\pi} \int_{-Z}^Z p(t) \frac{\sin tx}{t} dt.$$

Datorită faptului că  $p_Z \geq 0$ , rezultă că  $G$  este nedescrescătoare. Pentru asigurarea integrabilității este suficient să arătăm că  $G$  este mărginită. Întroducem funcția auxiliară

$$G_1(u) = \frac{1}{u} \int_u^{2u} G(x) dx$$

și observăm că

$$G_1(u) \geq \frac{G(u)}{u} \int_u^{2u} dx = G(u).$$

Deoarece  $G_1$  majorează  $G$ , pentru mărginirea lui  $G$  este suficient să arătăm mărginirea lui  $G_1$ . Să calculăm

$$\begin{aligned} G_1(u) &= \frac{1}{\pi u} \int_u^{2u} \int_{-Z}^Z p(t) \frac{\sin tx}{t} dt dx = \frac{1}{\pi u} \int_{-Z}^Z p(t) \frac{-\cos tx}{t^2} \Big|_u^{2u} dt = \\ &= \frac{1}{\pi u} \int_{-Z}^Z p(t) \frac{1}{t^2} (\cos ut - \cos 2ut) dt = \\ &= \frac{2}{\pi u} \int_{-Z}^Z p(t) \frac{(\sin ut)^2}{t^2} dt - \frac{2}{\pi u} \int_{-Z}^Z p(t) \frac{(\sin \frac{ut}{2})^2}{t^2} dt. \end{aligned}$$

Fie  $M = \sup |p(t)|$ . Atunci

$$\frac{2}{\pi u} \int_{-Z}^Z p(t) \frac{(\sin ut)^2}{t^2} dt \leq 2M \int_{-\infty}^{\infty} \frac{(\sin ut)^2}{u^2 t^2} u dt,$$

iar

$$\frac{2}{u} \int_{-Z}^Z p(t) \frac{(\sin \frac{ut}{2})^2}{t^2} dt \leq \frac{M}{\pi} \int_{-\infty}^{\infty} \frac{(\sin v)^2}{v^2} dv.$$

Întegrările din membrul al doilea sunt convergente. Deci mărginirea este asigurată. Se constată că

$$p_Z(x) = \frac{1}{2\pi} \int_{-\infty}^{\infty} p(t) e^{-itx} dt$$

adică  $\frac{1}{2\pi} p_Z$  este transformata Fourier a funcției  $p$ . Folosind formula de inversiune pentru funcția  $p$  continuă (vezi [10]), rezultă că

$$\frac{1}{2\pi} \left(1 - \frac{|t|}{Z}\right) \varphi(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} p_Z(x) e^{itx} dx, \forall |t| \leq Z.$$

În particular, pentru  $t = 0$ ,

$$\int_{-\infty}^{\infty} p_Z(x) dx = \varphi(0) = 1,$$

iar funcția  $p_Z$  fiind continuă și integrabilă pe  $\mathbb{R}$ , constituie o densitate de probabilitate pentru o variabilă aleatoare, care are funcția caracteristică asociată  $p$ . Observăm că pentru  $Z \rightarrow \infty$ , funcția  $p(t)$  converge uniform la  $\varphi$ , pe fiecare interval mărginit. De aici, folosind convergența în repartiție Capitolul 4, rezultă că  $\varphi$  este o funcție caracteristică. ■

### 3.6 Variabile aleatoare continue clasice și legăturile dintre ele

Vom enumera principalele repartiții continue și vom studia proprietățile lor. Un instrument important pentru aceasta este funcția caracteristică, ce a fost studiată anterior. Pentru început vom calcula funcția caracteristică a repartiției normale  $N(m, \sigma^2)$ , dată de (3.11).



**Propoziția 3.6.1** *Funcția caracteristică a repartiției normale este*

$$\varphi(t) = e^{imt - \frac{t^2\sigma^2}{2}}. \quad (3.52)$$

*Demonstrație.* Reamintim că densitatea de probabilitate a repartiției normale este

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-m)^2}{2\sigma^2}}$$

pe care o înlocuim în expresia funcției caracteristice. Facem schimbarea de variabilă  $x - m = \sqrt{2}\sigma y$  și obținem

$$\begin{aligned} \varphi(t) &= \frac{1}{\sqrt{2\pi}\sigma} \int_{-\infty}^{\infty} e^{itx} e^{-\frac{(x-m)^2}{2\sigma^2}} dx = \frac{1}{\sqrt{\pi}} \int_{-\infty}^{\infty} e^{itm-y^2+ity\sqrt{2}\sigma} dy = \\ &= \frac{e^{itm-\frac{t^2\sigma^2}{2}}}{\sqrt{\pi}} \int_{-\infty}^{\infty} e^{-(y-\frac{t\sigma}{2}i)^2} dy = e^{imt - \frac{t^2\sigma^2}{2}}. \end{aligned}$$

■

În particular, dacă  $X$  este o variabilă repartizată  $N(0, 1)$ , funcția sa caracteristică este

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

Folosind Propoziția 3.5.2 determinăm comod repartiția sumei de variabile aleatoare normale.

**Teorema 3.6.1** *Dacă  $X_k : N(m_k, \sigma_k^2), k = 1, \dots, n$ , sunt variabile aleatoare independente, atunci variabila aleatoare  $X_1 + \dots + X_n$  este repartizată  $N(\sum_{k=1}^n m_k, \sum_{k=1}^n \sigma_k^2)$ .*

*Demonstrație.* Funcția caracteristică a sumei este produsul funcțiilor caracteristice

$$\begin{aligned} \varphi_{X_1+\dots+X_n}(t) &= \prod_{k=1}^n e^{im_k t - \frac{t^2\sigma_k^2}{2}} = \\ &= e^{it \sum_{k=1}^n \left( m_k - \frac{t^2 \sum_{k=1}^n \sigma_k^2}{2} \right)}, \end{aligned}$$

care corespunde în mod unic variabilei repartizate  $N(\sum_{k=1}^n m_k, \sum_{k=1}^n \sigma_k^2)$ .

■

**Propoziția 3.6.2** Dacă  $X_k, k = 1, \dots, n$ , sunt variabile aleatoare independente repartizate normal  $N(m, \sigma^2)$ , atunci media lor aritmetică

$$\frac{1}{n} \sum_{k=1}^n X_k$$

este repartizată  $N(m, \frac{\sigma^2}{n})$ .

**Demonstrație.** Din Teorema 3.6.1 suma este repartizată  $N(nm, n\sigma^2)$ . Să calculăm funcția de repartiție a variabilei aleatoare notată

$$\bar{X} = \frac{1}{n} \sum_{k=1}^n X_k.$$

Avem

$$F_{\bar{X}} = P(\{\bar{X} < x\}) = P(\{\sum_{k=1}^n X_k < nx\}).$$

Prin derivare găsim densitatea de probabilitate

$$f_{\bar{X}}(x) = \frac{1}{\sqrt{2\pi n\sigma}} e^{-\frac{(nx-nm)^2}{2n\sigma^2}} n = \frac{1}{\sqrt{2\pi} \frac{\sigma}{\sqrt{n}}} e^{-\frac{(x-m)^2}{2\frac{\sigma^2}{n}}},$$

de unde afirmația propoziției. ■

Să definim funcția caracteristică în cazul multidimensional. Dacă variabila aleatoare  $n$ -dimensională are densitatea de probabilitate  $f_{X_1 \dots X_n}$ , atunci funcția caracteristică este

$$\varphi(t_1, \dots, t_n) = \int \dots \int_{\mathbb{R}^n} e^{-i \sum_{k=1}^n t_k x_k} f(x_1, \dots, x_n) dx_1 \dots dx_n.$$

Relația poate fi pusă sub forma

$$\varphi(t_1, \dots, t_n) = \int \dots \int_{\mathbb{R}^n} e^{-iT^t X} f(x_1, \dots, x_n) dx_1 \dots dx_n,$$

unde  $X = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}$  și  $T = \begin{pmatrix} t_1 \\ \vdots \\ t_n \end{pmatrix}$ . Să determinăm funcția caracteristică pentru

variabila aleatoare normală  $n$ -dimensională, mai întâi pentru cazul  $m_1 = \dots = m_n = 0$ . Reamintim că densitatea de probabilitate este dată de (3.24)

$$f(x) = \frac{\sqrt{\det A}}{(2\pi)^{\frac{n}{2}}} e^{-\frac{1}{2} X^t A X}.$$

Dacă înlocuim în expresia funcției caracteristice, obținem

$$\varphi(t_1, \dots, t_n) = \frac{\sqrt{\det A}}{(2\pi)^{\frac{n}{2}}} \int \dots \int_{\mathbb{R}^n} e^{iT^t X - \frac{1}{2} X^t A X} dx_1 \dots dx_n.$$

Facem transformarea ortogonală  $X = HY$ , pentru care forma pătratică de la exponent are forma canonică  $\sum_{j=1}^n l_j y_j^2$ , cu  $l_j > 0$  (aceste transformări au fost explicate în detaliu la repartiția normală  $n$ -dimensională în 3.3 ). Notăm  $U = H^{-1}T = H^t T$ . Atunci, se observă că

$$T^t X = (HU)^t HY = U^t H^t HY = U^t Y.$$

Cu aceasta funcția caracteristică devine

$$\begin{aligned} \varphi(t_1, \dots, t_n) &= \frac{\sqrt{\det A}}{(2\pi)^{\frac{n}{2}}} \int \int_{\mathbb{R}^n} e^{iU^t Y - \frac{1}{2} \sum_{j=1}^n l_j y_j^2} dy_1 \dots y_n = \\ &= \frac{\sqrt{\det A}}{(2\pi)^{\frac{n}{2}}} \prod_{j=1}^n \int_{-\infty}^{\infty} e^{iu_j y_j - \frac{1}{2} l_j y_j^2} dy_j. \end{aligned}$$

Ultima integrală înmulțită cu  $\frac{|l_j|}{\sqrt{2\pi}}$  reprezintă funcția caracteristică pentru o variabilă aleatoare repartizată  $N(0, \frac{1}{l_j})$ , deci folosind (3.52), avem

$$\varphi(t_1, \dots, t_n) = e^{-\frac{1}{2} \sum_{j=1}^n \frac{u_j^2}{l_j}}.$$

Reamintim că matricea formei pătratice se modifică după legea

$$H^t A H = \begin{pmatrix} l_1 & 0 & \dots & 0 \\ 0 & l_2 & \dots & 0 \\ 0 & 0 & \dots & l_n \end{pmatrix},$$

unde  $l_j > 0$ , sunt valorile proprii ale matricei  $A$ . Prin inversare găsim

$$H^{-1} A^{-1} H = \begin{pmatrix} \frac{1}{l_1} & 0 & \dots & 0 \\ 0 & \frac{1}{l_2} & \dots & 0 \\ 0 & 0 & \dots & \frac{1}{l_n} \end{pmatrix},$$

deci în ultima integrală recunoaștem că exponentul este următorul produs de matrice

$$\begin{aligned} \sum_{j=1}^n \frac{u_j^2}{l_j} &= U^t (H^{-1} A^{-1} H) U = \\ &= T^t H (H^{-1} A^{-1} H) H^{-1} T = T^t A^{-1} T \end{aligned}$$

(s-a folosit faptul că  $U = H^t T$ ). Găsim forma finală

$$\varphi(t_1, \dots, t_n) = e^{-\frac{1}{2} T^t A^{-1} T}.$$

Se demonstrează că dacă vectorul  $M \neq 0$ , atunci printr-o schimbare de variabile, funcția caracteristică devine

$$\varphi(t_1, \dots, t_n) = e^{iT^t M - \frac{1}{2}T^t A^{-1}T}.$$

Generalizând la cazul  $n$ -dimensional Teorema 3.5.1, se poate demonstra că derivatele parțiale ale lui  $\varphi$  în raport cu  $t_i$  generează momentele variabilelor aleatoare marginale. Astfel

$$M[X_h] = \frac{1}{i} \left( \frac{\partial \varphi}{\partial t_h} \right) (0, \dots, 0),$$

$$M[X_h X_k] = \frac{1}{i^2} \left( \frac{\partial^2 \varphi}{\partial t_h \partial t_k} \right) (0, \dots, 0).$$

Să determinăm momentele variabilei aleatoare normale  $n$ -dimensionale, mai întâi în cazul  $m_1 = \dots = m_n = 0$ .

$$M[X_h] = \frac{1}{i} \left( \frac{\partial \varphi}{\partial t_h} \right) (0, \dots, 0) = \left( i e^{-\frac{1}{2}T^t A^{-1}T} \sum_{k=1}^n a_{hk}^{-1} t_k \right) (0, \dots, 0) = 0,$$

$$M[X_h X_k] = \frac{1}{i^2} \left( \frac{\partial^2 \varphi}{\partial t_h \partial t_k} \right) (0, \dots, 0) =$$

$$= \left( i^2 e^{-\frac{1}{2}T^t A^{-1}T} \sum_{h=1}^n a_{hk}^{-1} t_h \sum_{k=1}^n a_{hk}^{-1} t_k + a_{hk}^{-1} e^{-\frac{1}{2}T^t A^{-1}T} \right) (0, \dots, 0) = a_{hk}^{-1}.$$

Dacă  $(m_1, \dots, m_n) \neq (0, \dots, 0)$ ,

$$M[X_h] = \frac{1}{i} \left( \frac{\partial \varphi}{\partial t_h} \right) (0, \dots, 0) = \left( m_h + i \sum_{k=1}^n a_{hk}^{-1} t_k \right) \varphi(t_1, \dots, t_n) (0, \dots, 0) = m_h,$$

$$M[X_h X_k] = \frac{1}{i^2} \left( \frac{\partial^2 \varphi}{\partial t_h \partial t_k} \right) (0, \dots, 0) =$$

$$= \left( (m_h + i \sum_{k=1}^n a_{hk}^{-1} t_k) (m_k + i \sum_{h=1}^n a_{hk}^{-1} t_k) \right) \varphi(t_1, \dots, t_n) +$$

$$+ a_{hk}^{-1} \varphi(t_1, \dots, t_n) (0, \dots, 0) = m_h m_k + a_{hk}^{-1}.$$

Se obțin imediat egalitățile

$$M[(X_h - m_h)] = 0,$$

$$M[(X_h - m_h)^2] = M[(X_h^2)] - m_h^2 = a_{hh}^{-1},$$

$$Cov[X_h, X_k] = M[(X_h - m_h)(X_k - m_k)] = M[X_h X_k] - m_h m_k = a_{hk}^{-1}.$$

Deci  $A^{-1}$  este matricea de covarianță a variabilei normale  $n$ -dimensionale. Pe baza acestei observații în cazul 2-dimensional, repartiția normală poate fi scrisă sub o formă mai comodă. Notăm:

$$M[X_1] = m_1, \quad M[X_2] = m_2$$

$$D^2(X_1) = \sigma_1^2, \quad D^2(X_2) = \sigma_2^2$$

$$\text{Cov}[X_1, X_2] = \rho\sigma_1\sigma_2$$

și găsim

$$A^{-1} = \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix}$$

de unde, prin inversare, găsim

$$A = \frac{1}{(1 - \rho^2)\sigma_1^2\sigma_2^2} \begin{pmatrix} \sigma_2^2 & -\rho\sigma_1\sigma_2 \\ -\rho\sigma_1\sigma_2 & \sigma_1^2 \end{pmatrix}$$

De aceea densitatea de probabilitate se poate scrie:

$$f(x_1, x_2) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1 - \rho^2}} e^{-\frac{1}{2(1-\rho^2)} \left( \frac{(x_1-m_1)^2}{\sigma_1^2} - \frac{2\rho(x_1-m_1)(x_2-m_2)}{\sigma_1\sigma_2} + \frac{(x_2-m_2)^2}{\sigma_2^2} \right)}. \quad (3.53)$$

**Exemplul 3.6.1** Variabila aleatoare  $(X, Y, Z)$  este normal repartizată și are matricea de covarianță

$$\begin{pmatrix} 1 & 0,2 & 0,3 \\ 0,2 & 1 & 0,4 \\ 0,3 & 0,4 & 1 \end{pmatrix}.$$

Să determinăm densitatea de probabilitate a variabilei aleatoare marginale  $(X, Z)$ . Observăm pentru aceasta că matricea de covarianță este

$$\begin{pmatrix} 1 & 0,3 \\ 0,3 & 1 \end{pmatrix}.$$

Deci  $m_X = m_Z = 0, \rho = 0,3, \sigma_1 = \sigma_2 = 1$  și înlocuind în (3.53), obținem densitatea de probabilitate căutată.

Vom enunța un rezultat care stabilește legătura dintre convergența funcțiilor caracteristice și cele de repartiție, de mare utilitate practică. Demonstrația acestui rezultat se găsește de exemplu în [10] și este făcută într-un cadru mai general.

**Teorema 3.6.2** *Dacă șirul de funcții caracteristice  $\varphi_n$  converge pentru orice  $t$  la  $\varphi(t) = e^{-\frac{t^2}{2}}$ , atunci șirul funcțiilor de repartiție corespunzătoare  $F_n$  satisface:*

$$\lim_{n \rightarrow \infty} F_n(x) = \frac{1}{2\pi} \int_{-\infty}^x e^{-\frac{u^2}{2}} = \frac{1}{2} + \Phi(x).$$

Reamintim că  $\frac{1}{2} + \Phi(x)$  este funcția de repartiție a variabilei aleatoare normale normate.

**Repartiția  $\chi^2$  ("hi pătrat").** Funcția  $f : \mathbb{R} \rightarrow \mathbb{R}$ , definită prin

$$f(x) = \frac{1}{2^{\frac{n}{2}}\sigma^n\Gamma(\frac{n}{2})} x^{\frac{n}{2}-1} e^{-\frac{x}{2\sigma^2}}, \quad 0 \leq x < \infty, \quad n \in \mathbb{N}, \quad \sigma > 0$$

este o densitate de probabilitate. Prin substituția  $y = \frac{x}{2\sigma^2}$  integrala  $\int_0^\infty f(x)dx$  se reduce la  $2^{\frac{n}{2}}\sigma^n\Gamma(\frac{n}{2})$ . Pentru funcția  $\Gamma$  și proprietățile ei, vezi Anexa 3. Această repartiție a fost descoperită de Helmert și pusă în valoare de Pearson.  $n$  se numește *număr de grade de libertate*. Vom nota  $X : H(n, \sigma)$ . Funcția caracteristică este dată de

$$\varphi(t) = (1 - 2\sigma^2 ti)^{-\frac{n}{2}}.$$

Într-adevăr, calculăm integrala  $\varphi(t) = \int_{-\infty}^\infty f(x)e^{itx}dx$  și obținem

$$\begin{aligned}\varphi(t) &= \frac{1}{2^{\frac{n}{2}}\sigma^n\Gamma(\frac{n}{2})} \int_0^\infty e^{itx - \frac{x}{2\sigma^2}} x^{\frac{n}{2}-1} dx = \\ &= \frac{1}{2^{\frac{n}{2}}\sigma^n\Gamma(\frac{n}{2})} \int_0^\infty x^{\frac{n}{2}-1} e^{-\frac{x}{2\sigma^2}(1-2\sigma^2 ti)} dx.\end{aligned}$$

În ultima integrală facem schimbarea  $\frac{x}{2\sigma^2}(1 - 2\sigma^2 ti) = y$ ; atunci integrala precedentă devine

$$\left(\frac{2\sigma^2}{1 - 2\sigma^2 ti}\right)^{\frac{n}{2}} \int_0^\infty y^{\frac{n}{2}-1} e^{-y} dy = \frac{2^{\frac{n}{2}}\sigma^n}{(1 - 2\sigma^2 ti)^{\frac{n}{2}}} \Gamma\left(\frac{n}{2}\right),$$

de unde se obține imediat afirmația. Pentru calculul momentelor, vom deriva funcția caracteristică. Avem

$$\begin{aligned}\varphi'(t) &= in\sigma^2(1 - 2\sigma^2 ti)^{-\frac{n}{2}-1}, \\ \varphi''(t) &= i^2 n(n+2)\sigma^4(1 - 2\sigma^2 ti)^{-\frac{n}{2}-2}, \\ &\vdots \\ \varphi^{(k)}(t) &= i^k n(n+2) \dots (n+2k-2)\sigma^{2k}(1 - 2\sigma^2 ti)^{-\frac{n}{2}-k}.\end{aligned}$$

Folosind apoi Teorema 3.5.1, găsim

$$\begin{aligned}\nu_1 &= \frac{1}{i}\varphi'(0) = n\sigma^2, \\ \nu_2 &= \frac{1}{i^2}\varphi''(0) = n(n+2)\sigma^4, \\ &\vdots \\ \nu_k &= \frac{1}{i^k}\varphi^{(k)}(0) = n(n+2) \dots (n+2k-2)\sigma^{2k}.\end{aligned}$$

Următoarea teoremă este un important instrument de lucru în statistica matematică.

**Teorema 3.6.3** *Dacă  $X_1, \dots, X_n$  sunt variabile aleatoare independente, repartizate  $N(0, \sigma^2)$ , atunci variabila aleatoare*

$$\sum_{k=1}^n X_k^2$$

*este repartizată  $H(n, \sigma)$ .*

**Demonstrație .** Să determinăm pentru început funcția caracteristică a variabilei aleatoare  $X_k^2$ ,  $k = 1 \dots n$ . Pentru aceasta să-i determinăm mai întâi densitatea de probabilitate. Avem

$$F_{X_k^2}(x) = P(\{X_k^2 < x\}) = P(\{-\sqrt{x} < X_k < \sqrt{x}\}) = \frac{2}{\sqrt{2\pi}\sigma} \int_0^{\sqrt{x}} e^{-\frac{y^2}{2\sigma^2}} dy, \quad x \geq 0.$$

Prin derivare, găsim

$$f_{X_k^2}(x) = \frac{1}{\sqrt{2\pi}\sigma\sqrt{x}} e^{-\frac{x}{2\sigma^2}}, \quad x \geq 0,$$

care se constată a fi o densitate de probabilitate pentru o variabilă aleatoare  $H(1, \sigma)$ , deci are funcția caracteristică dată de

$$\varphi_k(t) = (1 - 2\sigma^2 ti)^{-\frac{1}{2}}.$$

Folosind acum faptul că funcția caracteristică a sumei este produsul funcțiilor caracteristice, obținem

$$\varphi(t) = \prod_{k=1}^n (1 - 2\sigma^2 ti)^{-\frac{1}{2}} = (1 - 2\sigma^2 ti)^{-\frac{n}{2}},$$

care este funcția caracteristică a unei variabile aleatoare  $H(n, \sigma)$ . ■

Folosind din nou funcția caracteristică a sumei, se poate demonstra următoarea teoremă.

**Teorema 3.6.4** *Dacă  $X_i : H(n_i, \sigma)$ ,  $i = 1, 2$ , atunci*

$$X_1 + X_2 : H(n_1 + n_2, \sigma).$$

În practică interesează determinarea unor probabilități de forma  $P(\{X \geq \delta\})$ , unde  $X : H(n, 1)$ , deoarece se verifică imediat că dacă  $X : H(n, \sigma)$ , atunci variabila aleatoare

$$\frac{X}{\sigma^2} : H(n, 1).$$

Există tabele întocmite pentru diferite valori ale lui  $\delta$  și ale numărului de grade de libertate  $n$ , care au ca rezultate ariile din Figura 3.14.

Când numărul de grade de libertate este foarte mare, se folosește comportarea la limită a șirului de variabile aleatoare repartizate  $\chi^2$ .

**Teorema 3.6.5** *Dacă  $X : H(n, \sigma)$ , atunci variabila aleatoare*

$$\frac{X - n\sigma^2}{\sqrt{2n\sigma^2}}$$

*este asimptotic normală  $N(0, 1)$ , pentru  $n \rightarrow \infty$ .*

**Demonstrație .** Șirul funcțiilor caracteristice este

$$\varphi_n(t) = e^{-it\sqrt{\frac{n}{2}}}\left(1 - 2\sigma^2 i \frac{t}{\sqrt{2\pi\sigma^2}}\right)^{-\frac{n}{2}} = e^{-it\sqrt{\frac{n}{2}}}\left(1 - \sqrt{\frac{2}{n}}it\right)^{-\frac{n}{2}}.$$

Calculăm limita lui  $|\varphi_n(t)| = \left(1 + \frac{2t^2}{n}\right)^{-\frac{n}{2}}$ , pentru  $n \rightarrow \infty$  și găsim  $e^{-\frac{t^2}{2}}$ . Funcția  $\varphi_n(t)$  poate fi scrisă sub forma  $(\cos t\sqrt{\frac{n}{2}} - i \sin t\sqrt{\frac{n}{2}})(\cos \frac{n}{2}\theta_n - i \sin \frac{n}{2}\theta_n)\rho_n$ , unde  $(\cos \theta_n + i \sin \theta_n)\rho_n = 1 - \sqrt{\frac{2}{n}}it$ . Pentru  $n$  suficient de mare,

$$\theta_n = -\arctan \sqrt{\frac{2}{n}}t.$$

Deci argumentul numărului complex  $\varphi_n(t)$  poate fi luat de forma

$$y_n = -t\frac{\sqrt{n}}{2} + \frac{n}{2} \arctan t\sqrt{\frac{2}{n}}.$$

Notând  $x = \sqrt{\frac{2}{n}}$ , avem de calculat

$$\lim_{x \rightarrow 0} \frac{\arctan tx - tx}{x^2}$$

care este 0. Deci  $\lim_{n \rightarrow \infty} \varphi_n(t) = e^{-\frac{t^2}{2}}$ . ■

Această teoremă permite ca la un număr mare de grade de libertate să se folosească tabelele funcției lui Laplace. În teoria selecției, ne interesează să determinăm repartiția dispersiei (privită ca variabilă aleatoare) a unei selecții provenind dintr-o colectivitate guvernată de variabila aleatoare normală. În acest scop sunt necesare următoarele rezultate.

**Teorema 3.6.6** *Fie  $X_k, k = 1, \dots, n$ , variabile aleatoare independente repartizate  $N(0,1)$ , iar*

$$l_j(X_1, \dots, X_n) = \sum_{k=1}^n a_{jk}X_k, \quad a_{jk} \in \mathbb{R}, j = 1, \dots, s, \quad s \in \mathbb{N}, \quad s < n,$$

*variabile aleatoare independente de tip  $N(0,1)$ . Atunci variabila aleatoare*

$$Q = \sum_{k=1}^n X_k^2 - \sum_{j=1}^s l_j^2, \quad s < n,$$

*este repartizată  $H(n-s, 1)$ .*

**Demonstrație.** Variabilele aleatoare  $l_i$  și  $l_j$  cu  $i \neq j$ , sunt independente, deci

$$M[l_i l_j] = M[l_i]M[l_j] = M\left[\sum_{k=1}^n a_{ik}X_k\right]M\left[\sum_{k=1}^n a_{jk}X_k\right] = 0,$$



deoarece media este aditivă și  $M[X_k] = 0$ . Pe de altă parte

$$\begin{aligned} M[l_i l_j] &= M\left[\sum_{k=1}^n a_{ik} a_{jk} X_k^2 + \sum_{l,m=1}^n a_{il} a_{jm} X_m X_l\right] = \\ &= \sum_{k=1}^n a_{ik} a_{jk} M[X_k^2] = \sum_{k=1}^n a_{ik} a_{jk}, \end{aligned}$$

deoarece  $M[X_m X_l] = M[X_m]M[X_l] = 0$ . Analog,  $M[l_i^2] = \sum_{k=1}^n a_{ik}^2 = 1, \quad \forall i = 1, \dots, s$ .

Sistemul celor  $s$  vectori  $(a_{11}, \dots, a_{n1}), \dots, (a_{s1}, \dots, a_{sn})$  este ortogonal și poate fi deci completat la o bază ortonormată. Notăm matricea corespunzătoare cu  $A = (a_{ij}) \quad i, j = 1, \dots, s$ , care este deci ortogonală și au loc prin urmare

$$\sum_{k=1}^n a_{jk}^2 = 1, \quad \sum_{k=1}^n a_{ik} a_{jk} = 0, \quad \forall i, j = 1, \dots, n.$$

Introducem notațiile

$$l_r(x_1, \dots, x_n) = \sum_{k=1}^n a_{rk} x_k, \quad r = s+1, \dots, n,$$

și fie  $L$  matricea coloană cu componentele  $l_i, \quad i = 1, \dots, n$ . Atunci are loc

$$L = AX,$$

unde  $X$  este vectorul  $n$ -dimensional cu componentele  $x_i$ . Un simplu calcul ne arată că

$$\sum_{k=1}^n l_k^2(x_1, \dots, x_n) = \sum_{k=1}^n X_k^2.$$

Deci

$$Q = \sum_{k=1}^n X_k^2 - \sum_{j=1}^s l_j^2 = \sum_{k=s+1}^n l_k^2(x_1, \dots, x_n).$$

Mai observăm că variabila aleatoare  $n$ -dimensională  $L$  obținută printr-o transformare ortogonală asupra lui  $X$ , variabila aleatoare cu componentele  $X_i, i = 1 \dots n$ , independente, are componentele independente; rezultă că variabilele  $l_{s+1}, \dots, l_n$  sunt independente, repartizate  $N(0, 1)$ . Afirmatia rezultă din Teorema 3.6.3. ■

**Teorema 3.6.7 (Cochran)** *Dacă  $Q_i(x_1, \dots, x_n), i = 1, \dots, s$ , sunt forme pătratice respectiv de rangurile  $r_1, \dots, r_s$ , și  $X_1, \dots, X_n$  sunt variabile aleatoare independente, repartizate  $N(0, 1)$ , astfel încât*

$$\sum_{i=1}^s Q_i(X_1, \dots, X_n) = \sum_{j=1}^n X_j^2,$$

atunci condiția necesară și suficientă ca  $Q_i$  să fie variabile aleatoare independente este ca

$$r_1 + \dots + r_s = n.$$

**Demonstrație.** Pentru început să presupunem că  $Q_i$  sunt independente. Dacă  $Q_i$  este o formă pătratică de rang  $r_i$ , atunci poate fi scrisă ca sumă de  $r_i$  pătrate de variabile aleatoare normale normate, deci din Teorema 3.6.3 fiecare  $Q_i$  este repartizată  $H(r_i, 1)$ , iar suma lor este repartizată  $H(\sum_{i=1}^s r_i, 1)$ , deoarece din ipoteză  $Q_i$  sunt independente. Pe de altă parte,  $\sum_{j=1}^n X_j^2 : H(n, 1)$ . Rămâne să observăm că funcția de repartiție este unică,

$$\text{deci } \sum_{j=1}^s r_j = n.$$

Reciproc. Dacă  $Q_i(X_1, \dots, X_n)$  sunt forme pătratice și  $r_1 + \dots + r_n = n$  există o matrice ortogonală  $A$  astfel încât

$$\sum_{i=1}^s Q_i(x_1, \dots, x_n) = \sum_{k=1}^n l_k^2,$$

unde  $L = \begin{pmatrix} l_1 \\ \vdots \\ l_n \end{pmatrix} = AX$ . Fiecare formă pătratică  $Q_i$  este sumă de  $r_i$  pătrate  $l_i$ , repartizate  $N(0, 1)$  (obținute printr-o transformare ortogonală de variabile normal repartizate), deci  $Q_i$  sunt repartizate  $H(r_i, 1)$ . Se verifică ușor că sunt și independente. ■

**Repartiția Student.** Spunem că variabila aleatoare  $X$  este repartizată Student cu  $n$  grade de libertate, dacă are densitatea de probabilitate

$$f(x) = \frac{\Gamma(\frac{n+1}{2})}{\sqrt{\pi n} \Gamma(\frac{n}{2})} \left(1 + \frac{x^2}{n}\right)^{-\frac{n+1}{2}}, \quad \forall x \in \mathbb{R}$$

Vom nota  $X : S(n)$ . Să verificăm mai întâi că  $f$  este o densitate de probabilitate. Observăm că din paritatea funcției

$$\int_{-\infty}^{\infty} f(x) dx = 2 \int_0^{\infty} f(x) dx.$$

Facem schimbarea de variabilă  $x = \sqrt{ny}$ , după care găsim

$$\int_0^{\infty} \left(1 + \frac{x^2}{n}\right)^{-\frac{n+1}{2}} dx = \sqrt{n} \int_0^{\infty} (1 + y^2)^{-\frac{n+1}{2}} dy.$$

În ultima integrală substituția  $\frac{y^2}{1+y^2} = t$ , ne duce la funcția Beta vezi Anexa 3. Într-adevăr,  $dy = \frac{1}{2} t^{-\frac{1}{2}} (1-t)^{-\frac{3}{2}} dt$ , și

$$\begin{aligned} \int_{-\infty}^{\infty} f(x) dx &= \frac{2\Gamma(\frac{n+1}{2})}{\sqrt{\pi n} \Gamma(\frac{n}{2})} \sqrt{n} \int_0^1 (1-t)^{\frac{n+1}{2}} \frac{1}{2} t^{-\frac{1}{2}} (1-t)^{-\frac{3}{2}} dt = \\ &= \frac{\Gamma(\frac{n+1}{2})}{\Gamma(\frac{1}{2}) \Gamma(\frac{n}{2})} B\left(\frac{n}{2}, 1\right) = 1. \end{aligned}$$

**Momentele repartiției Student.** Funcția  $f$  fiind pară, media este 0, deci momentele inițiale coincid cu cele centrate, iar toate cele de ordin impar sunt nule.

$$\mu_{2k} = \nu_{2k} = \int_{-\infty}^{\infty} x^{2k} f(x) dx = \frac{\Gamma(\frac{n+1}{2})}{\sqrt{\pi n} \Gamma(\frac{n}{2})} \int_{-\infty}^{\infty} x^{2k} \left(1 + \frac{x^2}{n}\right)^{-\frac{n+1}{2}} dx.$$

Folosind substituția  $x = \sqrt{ny}$ , reducem, ca mai înainte, la o integrală Beta și obținem

$$\mu_{2k} = \frac{n^k}{\sqrt{\pi}} \frac{\Gamma(k + \frac{1}{2}) \Gamma(\frac{n}{2} - k)}{\Gamma(\frac{n}{2})}, \text{ dacă } \frac{n}{2} - k > 0.$$

Folosind proprietățile funcției  $\Gamma$

$$\Gamma(\frac{n}{2}) = (\frac{n}{2} - 1) \dots (\frac{n}{2} - k) \Gamma(\frac{n}{2} - k),$$

$$\Gamma(k + \frac{1}{2}) = (k - \frac{1}{2}) \dots \frac{1}{2} \Gamma(\frac{1}{2}),$$

Găsim

$$\mu_{2k} = \frac{n^k 1.3 \dots (2k + 1)}{(n - 2)(n - 4) \dots (n - 2k)}.$$

Un caz particular îl constituie  $n = 1$ , când regăsim repartiția Cauchy. Următorul rezultat de comportare la limită a unui șir de variabile aleatoare repartizate Student este utilizat mult în statistică.

**Teorema 3.6.8** *Dacă  $f$  este densitatea de probabilitate a variabilei aleatoare repartizate Student, atunci*

$$\lim_{n \rightarrow \infty} f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}.$$

**Demonstrație.** Vom folosi formula lui Legendre (vezi [10]). Pentru orice  $a > 0$  are loc

$$\Gamma(a) \Gamma(a + \frac{1}{2}) = \frac{\sqrt{\pi}}{2^{2a-1}} \Gamma(2a).$$

Pentru a arăta că

$$\lim_{n \rightarrow \infty} \frac{\Gamma(\frac{n+1}{2})}{\sqrt{n} \Gamma(\frac{n}{2})} = \frac{1}{\sqrt{2}},$$

vom analiza separat cazurile  $n$  par și  $n$  impar. Reamintim formula lui Wallis

$$\pi = \lim_{n \rightarrow \infty} \frac{2^{2n} (n!)^4}{n((2n)!)^2}.$$

Dacă  $n = 2k$ , luăm în formula lui Legendre  $a = k$  și obținem

$$\frac{\Gamma(k + \frac{1}{2})}{\sqrt{2k} \Gamma(k)} = \frac{\sqrt{\pi} \Gamma(2k)}{2^{2k+1} \Gamma^2(k) \sqrt{2k}} = \frac{\sqrt{\pi} (2k - 1)!}{2^{2k-1} \sqrt{2k} ((k - 1)!)^2} =$$

$$= \frac{\sqrt{\pi}(2k)!k^2}{2^{2k-1}\sqrt{2k}(k!)^2 2k}.$$

Din formula lui Wallis, ultimul șir are aceeași comportare la limită cu șirul

$$\frac{\sqrt{\pi}2^{2k}k^2}{2^{2k-1}\sqrt{2k}\sqrt{\pi k}2k}$$

care, pentru  $k \rightarrow \infty$ , tinde evident la  $\frac{1}{\sqrt{2}}$ . Dacă  $n = 2k + 1$ , folosind din nou formula lui Wallis, obținem

$$\begin{aligned} \frac{\Gamma(k+1)}{\sqrt{2k+1}\Gamma(k+\frac{1}{2})} &= \frac{k!2^{2k-1}(k-1)!}{\sqrt{(2k+1)\pi}\Gamma(2k)} = \\ &= \frac{2^{2k-1}2k(k!)^2}{\sqrt{(2k+1)\pi}(2k)!} \rightarrow \frac{1}{\sqrt{2}}, \text{ pentru } k \rightarrow \infty. \end{aligned}$$

■

Deci pentru un număr mare de grade de libertate, se utilizează tabelele legii normale.

Pentru repartiția Student există tabele care determină, pentru  $n = 1, \dots, 30$ , valorile  $P(\{|X| > \delta\}) = \alpha$ , adică ariile hașurate din figură 3.15. De asemenea există tabele pentru calculul funcției de repartiție

$$F(x) = \int_{-\infty}^x f(t)dt,$$

adică de determinare a ariilor din Figura 3.16, pentru  $x > 0$ . Pentru  $x < 0$ , se folosesc aceleași tabele, dar ținem seama de

$$F(-x) = \int_{-\infty}^{-x} f(t)dt = - \int_{-\infty}^x f(-t)dt = \int_x^{\infty} f(t)dt = 1 - F(x).$$

**Teorema 3.6.9** Fie  $X$  și  $Y$  variabile aleatoare independente repartizate  $N(0, \sigma^2)$  și  $H(n, \sigma)$  respectiv; atunci variabila aleatoare

$$\frac{X}{\sqrt{\frac{Y}{n}}}$$

este repartizată  $S(n)$ .

**Demonstrație.** Variabila aleatoare bidimensională  $(X, Y)$  are densitatea

$$f(x, y) = \frac{1}{\sqrt{\pi}2^{\frac{n+1}{2}}\sigma^{n+1}\Gamma(\frac{n}{2})} y^{\frac{n}{2}-1} e^{-\frac{x^2+y}{2\sigma^2}} \quad -\infty < x < \infty, \quad 0 \leq y < \infty.$$

Facem schimbarea

$$\begin{cases} u(x, y) = \frac{x}{\sqrt{\frac{y}{n}}} \\ v(x, y) = y \end{cases}.$$

Atunci densitatea de probabilitate a variabilei  $(U, V)$  devine

$$g(u, v) = \frac{1}{\sqrt{\pi n} 2^{\frac{n+1}{2}} \sigma^{n+1} \Gamma(\frac{n}{2})} v^{\frac{n-1}{2}} e^{-\frac{(\frac{u^2}{n} + 1)v}{2\sigma^2}}.$$

Densitatea marginală a lui  $U$  este

$$\int_0^\infty g(u, v) dv = \frac{1}{\sqrt{\pi n} 2^{\frac{n+1}{2}} \sigma^{n+1} \Gamma(\frac{n}{2})} \int_0^\infty v^{\frac{n-1}{2}} e^{-\frac{(\frac{u^2}{n} + 1)v}{2\sigma^2}} dv =$$

$$\frac{1}{\sqrt{\pi n} 2^{\frac{n+1}{2}} \sigma^{n+1} \Gamma(\frac{n}{2})} \frac{\Gamma(\frac{n+1}{2})}{\frac{n+1}{2}} = \frac{\Gamma(\frac{n+1}{2})}{\sqrt{\pi n} \Gamma(\frac{n}{2})} \left(1 + \frac{u^2}{n}\right)^{-\frac{n+1}{2}},$$

aceasta datorită schimbării de variabilă  $\frac{(\frac{u^2}{n} + 1)v}{2\sigma^2} = t$ . ■

**Consecință.** Dacă variabilele aleatoare independente  $X_1, \dots, X_{n+1}$  sunt repartizate  $N(0, \sigma^2)$ , atunci variabila aleatoare

$$\frac{X_{n+1}}{\sqrt{\frac{X_1^2 + \dots + X_n^2}{n}}} : S(n).$$

Demonstrația este imediată, dacă se folosește faptul că  $X_1^2 + \dots + X_n^2$  este repartizată  $H(n, \sigma)$ .

**Teorema 3.6.10** *Fie  $X_1, \dots, X_n$  variabile aleatoare independente repartizate  $N(0, \sigma)$  și  $\bar{X} = \frac{X_1 + \dots + X_n}{n}$ . Atunci variabila aleatoare*

$$y = \sqrt{n(n+1)} \frac{\bar{X}}{\sqrt{\sum_{j=1}^n (X_j - \bar{X})^2}}$$

este repartizată  $S(n-1)$ .

**Demonstrație.** Alegem  $a_{ij} \in \mathbb{R}$  astfel încât matricea

$$A = \begin{pmatrix} a_{11} & \dots & a_{1n} \\ a_{21} & \dots & a_{2n} \\ \dots & & \\ a_{(n-1)1} & \dots & a_{(n-1)n} \\ \frac{1}{\sqrt{n}} & \dots & \frac{1}{\sqrt{n}} \end{pmatrix}$$

să fie ortogonală și considerăm transformarea

$$\begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} = A \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix}.$$

După cum am văzut mai înainte, variabilele aleatoare  $Y_j, j = 1, \dots, n$ , sunt independente și repartizate  $N(0, \sigma)$ . Avem de asemenea

$$Y_1^2 + \dots + Y_n^2 = X_1^2 + \dots + X_n^2$$

și dacă înmulțim ultima linie a matricei  $A$  cu  $X$

$$\bar{X} = \frac{y_n}{\sqrt{n}}.$$

Deci

$$Y_1^2 + \dots + Y_{n-1}^2 = \sum_{j=1}^n X_j^2 - n\bar{X}^2 = \sum_{j=1}^n (X_j - \bar{X})^2.$$

Atunci variabila aleatoare căutată poate fi scrisă sub forma

$$Y = \sqrt{n(n-1)} \frac{\bar{X}}{\sum_{j=1}^n (X_j - \bar{X})^2} = \frac{Y_n}{\sqrt{\frac{Y_1^2 + \dots + Y_{n-1}^2}{n-1}}},$$

iar din consecința precedentă aceasta este repartizată  $S(n-1)$ . ■

Se poate arăta că variabila aleatoare

$$\frac{X_n}{\sqrt{\frac{X_1^2 + \dots + X_n^2}{n}}}$$

este de asemenea repartizată  $S(n-1)$ .

**Repartiția Snedecor.** Are densitatea de probabilitate dată de

$$f(x) = \left(\frac{n_1}{n_2}\right)^{\frac{n_1}{2}} \frac{\Gamma\left(\frac{n_1+n_2}{2}\right)}{\Gamma\left(\frac{n_1}{2}\right)\Gamma\left(\frac{n_2}{2}\right)} x^{\frac{n_1}{2}-1} \left(1 + \frac{n_1}{n_2}x\right)^{-\frac{n_1+n_2}{2}}, \quad 0 \leq x < \infty,$$

unde  $n_1, n_2 \in \mathbb{N}$  se numesc *grade de libertate*. Vom nota o variabilă aleatoare repartizată Snedecor prin  $S(n_1, n_2)$ . Prin schimbarea de variabilă

$$\frac{\frac{n_1}{n_2}x}{1 + \frac{n_1}{n_2}x} = y,$$

integrala  $\int_{-\infty}^{\infty} f(x)dx$  este redusă la o integrală Beta și folosind proprietățile funcției Beta (Anexa 3) deducem imediat că funcția de mai sus este o densitate de probabilitate. Momentele inițiale ale repartiției Snedecor se obțin prin calcul direct

$$\begin{aligned} \nu_k &= \left(\frac{n_1}{n_2}\right)^{\frac{n_1}{2}} \frac{\Gamma\left(\frac{n_1+n_2}{2}\right)}{\Gamma\left(\frac{n_1}{2}\right)\Gamma\left(\frac{n_2}{2}\right)} \int_0^{\infty} x^k x^{\frac{n_1}{2}-1} \left(1 + \frac{n_1}{n_2}x\right)^{-\frac{n_1+n_2}{2}} dx = \\ &= \left(\frac{n_2}{n_1}\right)^k \frac{\Gamma\left(k + \frac{n_1}{2}\right)\Gamma\left(\frac{n_2}{2} - k\right)}{\Gamma\left(\frac{n_1}{2}\right)\Gamma\left(\frac{n_2}{2}\right)}, \end{aligned}$$

dacă facem aceeași schimbare de variabilă ca mai sus. Ținând cont de proprietățile funcției Gama, găsim

$$\nu_k = \left(\frac{n_2}{n_1}\right)^k \frac{n_1(n_1 + 2) \dots (n_1 + 2k - 2)}{(n_2 - 2)(n_2 - 4) \dots (n_2 - 2k)}, \quad k < \frac{n_2}{2}.$$

În particular găsim

$$\begin{aligned} \nu_1 &= \frac{n_2}{n_2 - 2} \\ \nu_2 &= \frac{n_2^2}{n_1} \frac{n_1 + 2}{(n_2 - 2)(n_2 - 4)} \\ \nu_3 &= \frac{n_2^3}{n_1^2} \frac{(n_1 + 2)(n_1 + 4)}{(n_2 - 2)(n_2 - 4)(n_2 - 6)}. \end{aligned} \tag{3.54}$$

**Teorema 3.6.11** *Fie  $X_1, X_2$  două variabile aleatoare independente, care sunt repartizate  $S(n_1, n_2)$ . Atunci variabila aleatoare*

$$\frac{n_2 X_1}{n_1 X_2} : S(n_1, n_2).$$

*Demonstrație.* Notăm cu  $U$  variabila din enunț și determinăm funcția de repartiție

$$F_U(x) = P(\{U < x\}) = P\left\{\frac{X_1}{X_2} < \frac{n_1}{n_2}x\right\},$$

iar prin derivare găsim

$$f_U(x) = \frac{n_1}{n_2} f_U\left(\frac{n_1}{n_2}x\right).$$

Mai departe vom folosi formula care dă densitatea cântului de variabile aleatoare (3.31)

$$f_U(x) = \frac{1}{2^{\frac{n_1+n_2}{2}} \Gamma\left(\frac{n_1}{2}\right)\Gamma\left(\frac{n_2}{2}\right)} \int_0^{\infty} e^{-\frac{z}{2}} z^{\frac{n_2}{2}-1} e^{-\frac{xz}{2}} (xz)^{\frac{n_1}{2}-1} z dz,$$

care prin substituția  $\frac{z(1+x)}{2} = t$ , devine

$$f_U(x) = \frac{1}{2^{\frac{n_1+n_2}{2}} \Gamma\left(\frac{n_1}{2}\right)\Gamma\left(\frac{n_2}{2}\right)} x^{\frac{n_1}{2}-1} \int_0^{\infty} e^{-t} \left(\frac{2t}{1+x}\right)^{\frac{n_1+n_2}{2}-1} \frac{2}{1+x} dt =$$

$$= \frac{\Gamma\left(\frac{n_1 + n_2}{2}\right)}{\Gamma\left(\frac{n_1}{2}\right)\Gamma\left(\frac{n_2}{2}\right)} x^{\frac{n_1}{2} - 1} (1+x)^{-\frac{n_1 + n_2}{2}}.$$

Dacă facem schimbarea de variabilă  $x = \frac{n_1}{n_2}y$ , se obține densitatea de probabilitate Snedecor. ■

**Consecință.** Dacă variabilele aleatoare independente  $X_j, j = \overline{1, n_1}, Y_k, k = \overline{1, n_2}$ , sunt repartizate  $N(0, \sigma)$ , atunci variabile aleatoare

$$\frac{n_2 X_1^2 + \dots + X_{n_1}^2}{n_1 Y_1^2 + \dots + Y_{n_2}^2}$$

este repartizată  $S(n_1, n_2)$ . Dacă variabila aleatoare  $X$  este repartizată  $S(n_1, n_2)$ , variabila aleatoare  $\frac{1}{2} \ln X$  are densitatea de probabilitate

$$f(x) = 2 \left(\frac{n_1}{n_2}\right)^{\frac{n_1}{2}} \frac{\Gamma\left(\frac{n_1 + n_2}{2}\right)}{\Gamma\left(\frac{n_1}{2}\right)\Gamma\left(\frac{n_2}{2}\right)} e^{n_1 x} \left(1 + \frac{n_1}{n_2} e^{2x}\right)^{-\frac{n_1 + n_2}{2}}. \quad (3.55)$$

O variabilă aleatoare având această densitate se numește **Fisher**.

**Repartiția Gama.** Se verifică imediat că funcția

$$f(x) = \frac{1}{\Gamma(m)} e^{-x} x^{m-1}, \quad x \geq 0, \quad m > 0,$$

este o densitate de probabilitate. Momentele inițiale de ordin  $k$  sunt

$$\nu_k = \frac{1}{\Gamma(m)} \int_0^\infty e^{-x} x^{m-1+k} dx = \frac{\Gamma(m+k)}{\Gamma(m)} = m(m+1) \dots (m+k-1).$$

Momentele centrate, după particularizarea formulelor (3.39), sunt

$$\mu_2 = \nu_2 - \nu_1^2 = m(m+1) - m^2 = m,$$

$$\mu_3 = \nu_3 - 3\nu_2\nu_1 + 2\nu_1^3 = 2m.$$

Funcția caracteristică este dată de

$$\varphi(t) = (1 - it)^{-m},$$

care se obține din

$$\varphi(t) = \frac{1}{\Gamma(m)} \int_0^\infty e^{itx} e^{-x} x^{m-1} dx = \frac{1}{\Gamma(m)} \int_0^\infty e^{(it-1)x} x^{m-1} dx,$$

prin substituția  $(it - 1)x = y$ .

Folosind produsul funcțiilor caracteristice se deduce ușor că dacă  $X_i$  este repartizată Gama cu parametrul  $m_i, i = 1, 2$ , atunci suma este repartizată Gama cu parametrul  $m_1 + m_2$ .



**Exemplul 3.6.2** Repartiția Erlang Să determinăm repartiția sumei de  $n$  variabile aleatoare independente, repartizate exponențial, cu parametrul  $\lambda$ . Funcția caracteristică a repartiției exponențiale este

$$\varphi(t) = \frac{\lambda}{\lambda - it}.$$

Sumei de variabile exponențiale îi corespunde funcția caracteristică

$$\varphi_n(t) = \left( \frac{\lambda}{\lambda - it} \right)^n,$$

iar aceasta corespunde variabilei aleatoare cu densitatea de probabilitate

$$f(x) = \frac{\lambda e^{-\lambda x} (\lambda x)^{n-1}}{(n-1)!}, \quad x > 0.$$

Să determinăm funcția de repartiție a variabilei Erlang.

$$F(x) = \frac{\lambda^{n-1}}{(n-1)!} \int_0^x y^{n-1} \lambda e^{-\lambda y} dy.$$

Integrăm prin părți și avem

$$\begin{aligned} F(x) &= \frac{\lambda^{n-1}}{(n-1)!} \left( -y^{n-1} e^{\lambda y} \Big|_0^x + \int_0^x (n-1) y^{n-2} e^{-\lambda y} dy \right) = \\ &= -\frac{(\lambda x)^{n-1}}{(n-1)!} e^{-\lambda x} + \frac{\lambda^{n-2}}{(n-2)!} \int_0^x y^{n-2} \lambda e^{-\lambda y} dy. \end{aligned}$$

Repetînd integrarea prin părți, găsim

$$F(x) = 1 - \sum_{k=0}^{n-1} \frac{(\lambda x)^k}{k!} e^{-\lambda x}.$$

Recunoaștem în suma precedentă primii  $n$  termeni ai unei repartiții Poisson. Legătura dintre aceste două repartiții va fi evidențiată la procese Poisson.

**Repartiția Beta.** Este definită prin densitatea de probabilitate

$$f(x) = \frac{x^{m-1} (1-x)^{n-1}}{B(m, n)}, \quad 0 \leq x \leq 1, \quad m > 0, n > 0.$$

Momentele sunt date de

$$\nu_k = \frac{m(m+1) \dots (m+k-1)}{(m+n)(m+n+1) \dots (m+n+k-1)}.$$

În particular avem

$$\begin{aligned} \nu_1 &= \frac{m}{m+n}, \quad \nu_2 = \frac{m(m+1)}{(m+n)(m+n+1)}, \\ \mu_2 &= \nu_2 - \nu_1^2 = \frac{mn}{(m+n)^2(m+n+1)}. \end{aligned}$$

### 3.7 Fiabilitate

În sensul cel mai larg, fiabilitatea reprezintă proprietatea unui dispozitiv de a-și îndeplini funcția specifică în condiții de exploatare date. O analiză completă a fiabilității ne pune în evidență:

-fiabilitatea precalculată, care se evaluează pornind de la concepția dispozitivului și a componentelor sale;

-fiabilitate tehnică (nominală) determinată în urma încercărilor în condiții de fabrică;

-fiabilitate de exploatare, determinată de condițiile reale de exploatare, cu luarea în considerare a acțiunii complexe a tuturor factorilor ce influențează funcționarea.

Fiabilitatea poate fi exprimată cantitativ prin parametri de fiabilitate. Determinarea lor se face în practică în urma prelucrării statistice a datelor. Cel mai frecvent utilizată este probabilitatea funcționării fără defecțiune într-un interval de timp. Intervalul de timp în care sistemul funcționează fără defecțiuni este o variabilă aleatoare pe care o notăm cu  $T$ .

**Definiția 3.7.1** Numim funcție de fiabilitate sau reliabilitate funcția  $R : \mathbb{R}_+ \rightarrow [0, 1]$  definită prin

$$R(t) = P(\{T \geq t\}).$$

Observăm că  $1 - R(t)$  este funcția de repartiție, care în sensul fiabilității măsoară probabilitatea ca până la momentul  $t$  să apară o defecțiune. Funcția  $F(t) = 1 - R(t)$  se mai numește *funcție de nesiguranță*. În strânsă legătură cu proprietățile funcției  $F(t)$ , putem enunța pe cele ale lui  $R$ .

1.  $R(0) = 1$ ;
2.  $\lim_{t \rightarrow \infty} R(t) = 0$ ;
3.  $t_1 < t_2 \implies R(t_1) \geq R(t_2)$ ;
4. Dacă  $f$  este densitatea de probabilitate pentru variabila  $T$ ,

$$f(t) = -R'(t).$$

În Figura 3.17 sunt reprezentate cele două funcții.

Observăm că la momentul inițial funcția de fiabilitate este maximă, iar nesiguranța minimă și dacă  $t \rightarrow \infty$  se produce fenomenul invers. Vom presupune că se poate preciza o funcție, numită *rată de defectare* și notată  $r$ , cu proprietatea că  $r(t)\Delta t$  este probabilitatea ca în intervalul  $(t, t + \Delta t)$  să apară o defecțiune, dacă până la momentul  $t$ , dispozitivul a funcționat. Condiția din definiție este o probabilitate condiționată :

$$\begin{aligned} r(t)\Delta t &= P(\{t \leq T < t + \Delta t \mid \{T \geq t\}\}) = \frac{P(\{t \leq T < t + \Delta t\})}{P(\{T \geq t\})} = \\ &= \frac{F(t + \Delta t) - F(t)}{R(t)} = -\frac{R(t + \Delta t) - R(t)}{R(t)}. \end{aligned}$$

În ultima relație împărțim prin  $\Delta t$  și trecem la limită pentru  $\Delta t \rightarrow 0$ . Dacă această limită există, găsim ecuația diferențială

$$-\frac{R'(t)}{R(t)} = r(t),$$

cu condiția inițială

$$R(0) = 1,$$

care are ca soluție

$$R(t) = e^{-\int_0^t r(s)ds}. \quad (3.56)$$

**Exemplul 3.7.1** Rata de defectare a unui utilaj este  $r(t) = 0,1$ . Cu ce probabilitate dispozitivul funcționează cel puțin 10 ore? Înlocuim în (3.56)  $r(t) = 0,1$  și observăm că dispozitivul funcționează cel puțin 10 ore este evenimentul  $\{T \geq 10\}$ , deci

$$R(10) = e^{-\int_0^{10} 0,1 ds} = e^{-1} = 0,368$$

În practică sunt utilizate o parte din repartițiile continue prezentate anterior, dar și altele specifice.

**Repartiția exponențială.** are densitatea de probabilitate

$$f(t) = \begin{cases} \mu e^{-\mu t}, & \text{dacă } t \geq 0, \\ 0, & \text{dacă } t < 0, \end{cases} \quad (\mu > 0).$$

Se verifică imediat că  $f$  este o densitate de probabilitate. Funcția de fiabilitate este

$$R(t) = \int_t^{\infty} f(s)ds = e^{-\mu t},$$

iar rata de defectare

$$r(t) = -\frac{R'(t)}{R(t)} = \mu$$

este deci constantă. Această repartiție este utilizată pentru dispozitive care "nu îmbătrânesc".

**Repartiția Weibull.** Are densitatea de probabilitate

$$f(t) = \begin{cases} \lambda \alpha t^{\alpha-1} e^{-\lambda t^\alpha}, & \text{dacă } t \geq 0, \\ 0, & \text{dacă } t < 0 \end{cases} \quad (\lambda, \alpha \in R_+).$$

Funcția de fiabilitate este

$$R(t) = e^{-\lambda t^\alpha},$$

iar rata de defectare

$$r(t) = \lambda \alpha t^{\alpha-1}.$$

Pentru  $\alpha = 1$  se regăsește repartiția exponențială, iar pentru  $\alpha = 2$  se obține repartiția **Rayleigh**. Faptul că rata este o funcție polinomială, face să modeleze mai bine diferitele situații practice; de aceea repartiția Weibull este des utilizată.

Pentru diferite valori ale lui  $\alpha$ , în Figura 3.18 sunt reprezentări grafice ale densității de probabilitate, iar în Figura 3.19 și 3.20 ale ratelor și funcțiilor de fiabilitate.

În general variația defecțiunilor unui dispozitiv se poate împărți în trei perioade.

1. perioada inițială în care apar defecțiuni datorate erorilor de fabricație și se face rodajul (copilăria);

2. perioada de funcționare care începe după rodaj, când numărul defecțiunilor scade, rămânând practic constant (maturitatea), pentru care se poate utiliza distribuția exponențială;

3. perioada în care intensitatea de defectare crește continuu, datorită uzurii (bătrânețea).

Componentele unui dispozitiv pot fi legate "în serie", sau "în paralel". Vom analiza modul de determinare a fiabilității pentru fiecare situație în parte.

**Legare în serie.** Spunem că un dispozitiv are  $n$  componente legate în serie, dacă defectarea uneia, atrage nefuncționarea întregului sistem. Convenim să vizualizăm prin schema de la Figura 3.21.

Presupunem că fiecare componentă  $C_i, i = 1, \dots, n$ , se poate defecta indiferent de celelalte, cu rata de defectare  $r_i$  și funcția de fiabilitate  $R_i$ . Dacă  $T$ , respectiv  $T_i, i = 1, \dots, n$  semnifică timpul de funcționare până la prima defectare a sistemului, respectiv a componentei  $C_i$ , atunci evident

$$\{T \geq t\} = \bigcap_{i=1}^n \{T_i \geq t\}$$

și aplicând probabilitatea pentru evenimente independente găsim

$$\begin{aligned} R(t) &= \prod_{i=1}^n R_i(t) = \prod_{i=1}^n e^{-\int_0^t \sum_{i=1}^n r_i(s) ds} = \\ &= e^{-\int_0^t \sum_{i=1}^n r_i(s) ds} . \end{aligned}$$

Deci rata de defectare este

$$r(t) = \sum_{i=1}^n r_i(t).$$

Observăm că  $T = \min\{T_1, \dots, T_n\}$ .

**Legare în paralel.** Un dispozitiv are  $n$  componente legate în paralel, dacă acesta poate funcționa, chiar dacă una din componente se defectează.

Sistemul nu funcționează dacă fiecare din componente nu funcționează; presupunem că acestea se pot defecta independent una de alta. Atunci obținem

$$\{T < t\} = \bigcup_{i=1}^n \{T_i < t\}$$

și dacă aplicăm probabilitatea

$$1 - R(t) = \prod_{i=1}^n (1 - R_i(t)).$$

Observăm că  $T = \max\{T_1, \dots, T_n\}$ . În acest caz nu putem găsi o expresie simplă a ratei de defectare a sistemului. În practică aceste moduri de alcătuire apar combinat.

Reprezentăm acest lucru în Figura 3.22.

**Exemplul 3.7.2** În schema alăturată componentele  $C_i$  funcționează independent, cu aceeași funcție de fiabilitate.

Să determinăm funcția de fiabilitate a sistemului. Dispozitivul funcționează la momentul  $t$ , dacă

$$\begin{aligned} \{T > t\} &= (\{T_1 > t\} \cap \{T_3 > t\}) \cup (\{T_1 > t\} \cap \{T_4 > t\}) \cup \\ &\cup (\{T_2 > t\} \cap \{T_4 > t\}). \end{aligned}$$

Calculăm acum probabilitatea acestei reuniuni, folosind independența

$$\begin{aligned} R(t) &= R_1(t)R_3(t) + R_1R_4(t) + R_2(t)R_4(t) - R_1(t)R_3(t)R_4(t) - \\ &- R_1(t)R_2(t)R_4(t) - R_1(t)R_2(t)R_3(t)R_4(t) + R_1(t)R_2(t)R_3(t)R_4(t) = \\ &= 3R_1^2(t) - 2R_1^3(t). \end{aligned}$$

### PROBLEME PROPUSE

**Problema 3.1** O variabilă aleatoare  $X$  are repartiția dată de "legea triunghiului dreptunghic" pe intervalul  $(0, a)$ ,  $a > 0$  (vezi Figura 3.24). Găsiți :

- densitatea de probabilitate;
- funcția de repartiție;
- probabilitatea ca variabila aleatoare  $X$  să ia valori în intervalul  $(a/2, a)$ ;
- media și dispersia.

Soluție a. Scriem dreapta cu tăieturile  $(a, 0)$  și  $(a/2, 0)$  și găsim

$$f(x) = \begin{cases} \frac{2}{a}(1 - \frac{x}{a}), & x \in (0, a), \\ 0, & x \notin (0, a); \end{cases}$$

$$b. F(x) = \begin{cases} 0, & x \leq 0, \\ \frac{x}{a}(2 - \frac{x}{a}), & 0 < x \leq a, \\ 1, & x > 0. \end{cases}$$

$$c. P(\{X \in (\frac{a}{2}, a)\}) = F(a) - F(\frac{a}{2}) = \frac{1}{4};$$

$$d. M[X] = \frac{a}{3}, D^2[X] = \frac{a^2}{18}.$$

**Problema 3.2** Determinați funcția de repartiție a variabilei aleatoare  $X$ , repartizată Cauchy, deci cu densitatea de probabilitate  $f(x) = \frac{1}{\pi(1+x^2)}$ ,  $x \in \mathbb{R}$ .

$$R: F(x) = \frac{1}{\pi} \arctan x + \frac{1}{2}.$$

**Problema 3.3** O variabilă aleatoare  $X$  are repartiția Simpson sau "legea triunghiului isoscel" pe un interval  $(-a, a)$ ,  $a > 0$ .

Găsiți

- densitatea de probabilitate;
- funcția de repartiție.

R: Graficul este dat de Figura 3.25

$$a. f(x) = \begin{cases} \frac{1}{a}(1 - \frac{x}{a}), & 0 < x < a, \\ \frac{1}{a}(1 + \frac{x}{a}), & -a < x < 0, \\ 0, & |x| \geq a. \end{cases};$$

$$b. F(x) = \begin{cases} 0, & x \leq 0, \\ \frac{1}{a}(x+a) + \frac{1}{2a^2}(x^2 - a^2), & -a < x \leq 0, \\ \frac{1}{2} + \frac{1}{a}(x - \frac{x^2}{2a}), & 0 \leq x < a \\ 1, & x > a. \end{cases}$$

**Problema 3.4** Determinați media și dispersia variabilei aleatoare exponențiale, având densitatea de probabilitate

$$f(x) = \begin{cases} \lambda e^{-\lambda x}, & x \geq 0, \\ 0, & x < 0. \end{cases}$$

R:  $M[X] = \frac{1}{\lambda}, D^2[X] = \frac{1}{\lambda^2}.$

**Problema 3.5** Determinați media și dispersia repartiției Laplace, cu densitatea de probabilitate  $f(x) = \frac{\lambda}{2}e^{-\lambda|x|}, \lambda > 0, \forall x \in \mathbb{R}.$

R:  $M[X] = 0, D^2[X] = \frac{2}{\lambda^2}.$

**Problema 3.6** Determinați media și dispersia variabilei aleatoare repartizată uniform pe intervalul  $(a, b).$

R:  $M[X] = \frac{a+b}{2}, D^2[X] = \frac{(a-b)^2}{12}.$

**Problema 3.7** O variabilă aleatoare este repartizată normal  $N(m, \sigma^2).$  Să aproximăm  $X$  pe un interval  $(\alpha, \beta)$  cu legea uniformă, dacă  $m, \sigma$  rămân constanți.

Soluție. Folosim problema precedentă și egalăm mediile și abaterile medii pătratice

$$\frac{\alpha + \beta}{2} = m, \quad \frac{\beta - \alpha}{2\sqrt{3}} = \sigma$$

de unde  $\alpha = m - \sigma\sqrt{3}, \beta = m + \sigma\sqrt{3}.$

**Problema 3.8** O variabilă aleatoare  $X : N(m, \sigma^2)$  poate avea parametrii  $m = 2, \sigma = 2$  cu probabilitatea 0,4 sau  $m = 2, \sigma = 1$  cu probabilitatea 0,6 determinați densitatea de probabilitate.

Soluție . Folosim generalizarea formulei probabilității totale, din 3.2. Avem

$$f(x) = \frac{0,4}{2\sqrt{2\pi}}e^{-\frac{(x-2)^2}{8}} + \frac{0,6}{\sqrt{2\pi}}e^{-\frac{(x-2)^2}{2}}.$$

**Problema 3.9** Într-o secție se produc articole care corespund calitativ, dacă satisfac o anumită proprietate măsurabilă printr-o caracteristică numerică. Se observă unele deviații

de la normele impuse, care sunt repartizate normal, cu media  $m = 0$  și abaterea  $\sigma$ . La controlul de calitate se elimină acele produse ale căror deviații depășesc mărimea  $\Delta$ . Determinați probabilitatea evenimentului  $A$  "un articol este respins".

$$R: P(A) = P(\{|X| > \Delta\}) = 1 - 2\Phi\left(\frac{\Delta}{\sigma}\right).$$

**Problema 3.10** Fie  $\alpha, a > 0$  și  $n \in \mathbb{N}$ . Determinați  $a$  și  $\alpha$  astfel ca funcția

$$f_n(x) = ax^n e^{-\alpha^2 x^2}, \quad x > 0$$

să fie o densitate de probabilitate pentru o variabilă aleatoare cu media  $m$ .

Soluție. Punem condițiile

$$\int_0^{+\infty} ax^n e^{-\alpha^2 x^2} dx = 1, \quad \int_0^{+\infty} ax^{n+1} e^{-\alpha^2 x^2} dx = m$$

și găsim

$$a = \frac{2\alpha^{n+1}}{\Gamma\left(\frac{n+1}{2}\right)}, \quad \alpha = \frac{1}{m} \frac{\Gamma\left(\frac{n+2}{2}\right)}{\Gamma\left(\frac{n+1}{2}\right)}.$$

**Problema 3.11** Un mesaj este așteptat printr-un canal de comunicație. Momentul  $T$  la care mesajul este primit este aleator și are funcția de densitate  $f(t)$ . La un moment dat  $\tau$ , se observă că mesajul nu a ajuns încă. Determinați densitatea de probabilitate  $\phi$  a timpului care rămâne până la recepționarea mesajului,  $\Theta$ .

Soluție. Fie  $A$  evenimentul "mesajul nu a fost recepționat până la momentul  $\tau$ ". Folosind formula lui Bayes, găsim

$$f_A(t) = \frac{f(t)}{P(A)} = \begin{cases} \frac{f(t)}{1 - \int_0^\tau f(t) dt}, & t > \tau, \\ 0, & t < \tau. \end{cases}$$

Deoarece  $\Theta = T - \tau$ , rezultă

$$\phi(t) = \begin{cases} \frac{f(t)}{1 - \int_0^\tau f(t) dt}, & t > 0, \\ 0, & t < 0. \end{cases}$$

**Problema 3.12** Un sistem de comunicație acceptă un voltaj pozitiv  $V$  la intrare, iar la ieșire un voltaj  $Y = \alpha V + N$ , unde  $\alpha = 10^{-2}$ , iar  $N$  este o variabilă aleatoare normală cu  $m = 0, \sigma = 2$ . Ce valoare trebuie să ia  $V$ , astfel ca la ieșire voltajul să fie pozitiv cu siguranța  $1 - \epsilon$ ,  $\epsilon = 10^{-6}$ .

Soluție. Punem condiția ca  $P(\{Y < 0\}) = 10^{-6}$  și găsim

$$P(\{Y < 0\}) = P(\{\alpha V + N < 0\}) = P(\{N < -\alpha V\}) = \frac{1}{2} - \Phi\left(\frac{\alpha V}{\sigma}\right).$$



De aici găsim că  $V = 950,6$ .

**Problema 3.13** Legea evenimentelor rare în plan. Un semnal luminos se poate produce aleator cu densitatea  $\lambda$ , pe cadranul unui osciloscop. Găsiți repartiția  $R$ , care dă distanța de la semnal, la cel mai apropiat "vecin", media și dispersia.

Soluție. Evenimentul  $\{R < r\}$  înseamnă că cel puțin un semnal se produce în interiorul discului de rază  $r$ . Numărul mediu de apariții în acest disc este  $\pi r^2 \lambda$ , deci  $P(\{R < r\}) = 1 - P(\{R \geq r\}) = 1 - e^{-\pi r^2 \lambda}$ ,  $r > 0$ , dacă generalizăm raționamentul de la legea Poisson. Densitatea de probabilitate, este  $f(r) = 2\pi \lambda r e^{-\pi r^2 \lambda}$ ,  $r > 0$ . Această repartiție este repartiția Rayleigh.

$$M[R] = \frac{1}{2\sqrt{\lambda}}, \quad D^2[R] = \frac{(4 - \pi)}{4\pi\lambda}.$$

Analog se poate deduce repartiția evenimentelor rare în spațiu, care are densitatea de probabilitate  $f(r) = 4\pi r^2 \lambda e^{-\lambda \frac{4}{3}\pi r^3}$ ,  $r > 0$ , unde  $r$  este raza unei sfere alese convenabil.

**Problema 3.14** În timpul funcționării unui calculator, defecțiunile pot apărea la momente aleatoare. Timpul  $T$  în care acesta funcționează fără defecțiuni, urmează o lege exponențială cu parametru  $\nu$ , adică  $\phi(t) = \nu e^{-\nu t}$ ,  $\nu > 0$ . Dacă o defecțiune apare este imediat îndepărtată într-un interval de timp  $t_0$ , după care calculatorul funcționează din nou. Notăm cu  $Z$  intervalul de timp între două defecțiuni. Aflați  $P(\{Z > 2t_0\})$ .

Soluție. Avem  $Z = T + t_0$  și funcția de repartiție este

$$F(t) = P(\{Z < t\}) = P(\{T < t - t_0\}) = F_T(t - t_0).$$

Prin derivare

$$F'(t) = f_T(t - t_0) = \begin{cases} \nu e^{-\nu(t-t_0)}, & t > t_0 \\ 0, & t < 0 \end{cases}.$$

Atunci  $P(\{Z > 2t_0\}) = e^{-\nu t_0}$ .

**Problema 3.15** Timpul  $T$  între două defecțiuni ale unui calculator, urmează o lege exponențială cu parametru  $\lambda$ . Rezolvarea unei anumite probleme necesită funcționarea fără defecțiuni a componentelor pentru un timp  $\tau$ ; dacă o defecțiune apare în timpul rezolvării, problema poate fi reluată. Fie  $\Theta$  variabila aleatoare care reprezintă intervalul de timp în care problema va fi rezolvată. Să determinăm repartiția și media variabilei aleatoare  $\Theta$ .

Soluție. Dacă problema a fost rezolvată în intervalul  $\tau$ , înseamnă că  $T > \tau$  și  $R(\tau) = P(\{T > \tau\}) = e^{-\tau\lambda}$ , pe care o notăm  $p$ . Evenimentul contrar se produce cu probabilitatea  $1 - p$ . Dacă problema a fost rezolvată în intervalul  $((n - 1)\tau, n\tau)$ , aceasta înseamnă că au survenit defecțiuni ale calculatorului în intervalele  $(0, \tau)$ ,  $(\tau, 2\tau)$ ,  $\dots$ ,  $((n - 2)\tau, (n - 1)\tau)$  și aceasta se întâmplă cu probabilitatea  $p(1 - p)^{n-1}$ . Variabila căutată este

$$\Theta : \left( \begin{matrix} n\tau \\ p(1 - p)^{n-1} \end{matrix} \right)$$

care are media  $\frac{\tau}{p}$ .

**Problema 3.16** Durata vieții unui circuit integrat normal este dată de o lege exponențială cu rata  $\alpha$ , iar a unui circuit rebut  $1000\alpha$ . Probabilitatea de a extrage un

circuit integrat normal dintr-un lot este  $p$ . Găsiți probabilitatea ca alegînd un circuit la întîmplare, acesta să funcționeze după  $t$  secunde. Presupunem că fiecare este testat  $t$  secunde. Pentru ce valoare a lui  $t$ , 99% dintre circuite sunt bune.

Soluție. Fie  $B$  evenimentul de a "alege un circuit normal",  $R$  de a "alege un circuit rebut", iar  $C$  de a "alege un circuit care să funcționeze după  $t$  secunde". Are loc, dacă folosim formula probabilității totale

$$P(C) = pe^{-\alpha t} + (1-p)e^{-1000\alpha t}.$$

Calculăm  $P_C(B)$  cu formula lui Bayes și din condiția  $P_C(B) = 0,99$ , avem  $t = \frac{1}{999\alpha} \ln \frac{(1-p)99}{p}$ .

**Problema 3.17** Variabila aleatoare  $(X, Y)$  are densitatea de probabilitate  $f(x, y)$ . Exprimați probabilitățile următoarelor evenimente: 1.  $\{X > Y\}$ , 2.  $\{X > |Y|\}$  3.  $\{|X| > Y\}$  4.  $\{Y - X > 1\}$ .

Soluție 1.  $P(\{X > Y\}) = \int_{-\infty}^{+\infty} dy \int_y^{+\infty} f(x, y) dx;$

2.  $P(\{X > |Y|\}) = \int_0^{+\infty} dx \int_{-x}^x f(x, y) dy;$

3.  $P(\{|X| > Y\}) = \int_{-\infty}^0 dx \int_{-\infty}^{-x} f(x, y) dy + \int_0^{+\infty} dx \int_{-\infty}^x f(x, y) dy;$

4.  $P(\{Y - X > 1\}) = \int_{-\infty}^{+\infty} dx \int_{x+1}^{+\infty} f(x, y) dx dy.$

Domeniile de integrare sunt reprezentate mai jos.

**Problema 3.18** Variabila aleatoare  $X$  are repartiția exponențială cu densitatea  $f(x) = \lambda e^{-\lambda x}$ ,  $x > 0$ . Să determinăm condițiile în care variabila aleatoare  $Y = e^X$  are medie și dispersie.

Soluție.  $M[Y] = \int_0^{+\infty} e^x \lambda e^{-\lambda x} dx = \lambda \int_0^{+\infty} e^{-(\lambda-1)x} dx$ . Pentru  $\lambda > 1$ , există media egală cu  $\frac{\lambda}{\lambda-1}$ . Pentru  $\lambda \leq 1$ , integrala din definiția mediei este divergentă. Pentru  $\lambda > 2$ ,  $M[Y^2] = \frac{\lambda}{\lambda-2}$  și deci există dispersie, iar dacă  $\lambda \leq 2$  aceasta nu există.

**Problema 3.19** Variabila aleatoare  $X$  are densitatea de probabilitate

$$f(x) = \frac{1}{2} \cos x, \quad x \in \left(-\frac{\pi}{2}, \frac{\pi}{2}\right);$$

calculați media și dispersia variabilelor aleatoare  $X$  și  $Y = |\sin X|$ .

Soluție.  $M[X] = 0$ ,  $D^2[X] = \frac{\pi^2}{4} - 2$ ,  $M[Y] = \frac{1}{2} \int_{-\frac{\pi}{2}}^{\frac{\pi}{2}} |\sin x| \cos x dx = \frac{1}{2}$ ,  $D^2[Y] = \frac{1}{12}$ .

**Problema 3.20** Variabilele aleatoare  $X$  și  $Y$  au repartiții exponențiale

$$f_1(x) = \lambda e^{-\lambda x}, \quad x > 0; \quad f_2(x) = \mu e^{-\mu y}, \quad y > 0.$$

Determinați densitatea de probabilitate  $f(x, y)$  și funcția de repartiție  $F(x, y)$  pentru variabila aleatoare bidimensională  $(X, Y)$ , dacă  $X, Y$  sunt independente.

Soluție.

$$f(x, y) = \begin{cases} 0 & x \leq 0 \text{ sau } y \leq 0, \\ \lambda\mu e^{-(\lambda x + \mu y)}, & x > 0 \text{ și } y > 0; \end{cases}$$

$$F(x, y) = \begin{cases} 0, & x \leq 0 \text{ sau } y \leq 0, \\ (1 - e^{-\lambda x})(1 - e^{-\mu y}), & x > 0 \text{ și } y > 0. \end{cases}$$

**Problema 3.21** Variabila aleatoare  $(X, Y)$  este repartizată constant în pătratul de latură  $a$ , pe care îl notăm  $D$  și nulă în afară. Determinați  $f(x, y)$  și  $F(x, y)$ , funcțiile de densitate marginale  $f_1(x)$ ,  $f_2(y)$ . Stabiliți dacă  $X$  și  $Y$  sunt independente.

Soluție.

$$f(x, y) = \begin{cases} \frac{1}{a^2}, & (x, y) \in D, \\ 0, & (x, y) \notin D; \end{cases}$$

$$F(x, y) = \begin{cases} 0, & x \leq 0 \text{ sau } y \leq 0, \\ \frac{xy}{a^2}, & 0 \leq x \leq a, \text{ și } 0 \leq y \leq a, \\ \frac{y}{a}, & x > a \text{ și } 0 < y \leq a, \\ \frac{x}{a}, & 0 < x \leq a \text{ și } y > a, \\ 1, & x > 0 \text{ și } y > a; \end{cases}$$

$$f_X(x) = \begin{cases} \frac{1}{a}, & x \in (0, a), \\ 0, & x \notin (0, a); \end{cases} \quad f_Y(y) = \begin{cases} \frac{1}{a}, & y \in (0, a) \\ 0, & y \notin (0, a). \end{cases}$$

**Problema 3.22** Funcția  $f(x, y)$  este constantă în interiorul unui cerc de rază  $r$  și nulă în afară. Determinați raza  $r$  astfel ca  $f(x, y)$  să fie o densitate de probabilitate pentru o variabilă aleatoare bidimensională  $(X, Y)$ ,  $f_X(x)$ ,  $f_Y(y)$ ,  $f_X(x|y)$ ,  $f_Y(y|x)$ . Calculați  $Cov[X, Y]$ .

Soluție. Căutăm densitatea de probabilitate de forma

$$f(x, y) = \begin{cases} h, & x^2 + y^2 < r^2, \\ 0, & x^2 + y^2 \geq r^2. \end{cases}$$

Punem condiția ca  $1 = \int \int f(x, y) dx dy = h\pi r^2$ . Deci  $r = \sqrt{\frac{1}{\pi h}}$ .

$$f_X(x) = \begin{cases} 2h\sqrt{r^2 - x^2}, & |x| < r, \\ 0, & |x| > r; \end{cases} \quad f_Y(y) = \begin{cases} 2h\sqrt{r^2 - y^2}, & |y| < r, \\ 0, & |y| \geq r; \end{cases}$$

$$f_X(x|y) = \frac{f(x, y)}{f_Y(y)} = \begin{cases} \frac{1}{2\sqrt{r^2 - y^2}}, & |x| < \sqrt{r^2 - y^2}, \\ 0, & |x| > \sqrt{r^2 - y^2}; \end{cases}$$

$$f_Y(y|x) = \frac{f(x, y)}{f_X(x)} = \begin{cases} \frac{1}{2\sqrt{r^2 - x^2}}, & |y| < \sqrt{r^2 - x^2}, \\ 0, & |y| > \sqrt{r^2 - x^2}. \end{cases}$$

Avem imediat  $M[X] = M[Y] = 0$ ,  $D[X] = D[Y] = \frac{r^2}{2}$ .  $M[XY] = \int \int xyf(x, y) dx dy = 0$ . Deci  $Cov[X, Y] = 0$ .

**Problema 3.23** O variabilă aleatoare are densitatea de probabilitate constantă în pătratul  $D$  din Figura 3.30.

Găsiți  $f(x, y)$ ,  $f_X(x)$ ,  $f_Y(y)$ ,  $f_X(x|y)$ ,  $f_Y(y|x)$  și stabiliți dacă sunt independente; dar corelate ?

Soluție.

$$f(x, y) = \begin{cases} \frac{1}{2}, & (x, y) \in D, \\ 0, & (x, y) \notin D; \end{cases} \quad f_X(x) = \begin{cases} 1 - |x|, & |x| < 1, \\ 0, & |x| > 1. \end{cases}$$

Analog

$$f_Y(y) = \begin{cases} 1 - |y|, & |y| < 1, \\ 0, & |y| > 1, \end{cases}$$

care sunt repartizate Simpson.

$$f_X(x|y) = \frac{f(x, y)}{f_Y(y)} = \begin{cases} \frac{1}{2(1 - |y|)}, & |x| < 1 - |y| \\ 0, & |x| > 1 - |y|; \end{cases}$$

$$f_Y(y|x) = \frac{f(x, y)}{f_X(x)} = \begin{cases} \frac{1}{2(1 - |x|)}, & |y| < 1 - |x| \\ 0, & |y| > 1 - |x|. \end{cases}$$

$X$  și  $Y$  nu sunt independente, dar nici corelate.  $M[X] = M[Y] = 0$ , iar  $M[XY] = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} xyf(x, y) dx dy = 0$ .  $Cov[X, Y] = 0$ .

**Problema 3.24** Variabila aleatoare  $(X, Y)$  este uniform repartizată în interiorul unui cerc de rază  $r = 1$  cu interiorul  $D$ . Găsiți media și dispersia variabilei  $Z = XY$ .

Soluție.  $M[XY] = \frac{1}{\pi} \int \int_D xy dx dy = 0$ ;  $D^2[XY] = \frac{1}{\pi} \int \int_D x^2 y^2 dx dy = \frac{1}{8}$ .

**Problema 3.25** O variabilă aleatoare  $(X, Y)$  este uniform repartizată într-un pătrat de latură 1. Găsiți media și dispersia variabilei  $XY$ .

Soluție. Pentru că  $X$  și  $Y$  sunt independente  $M[XY] = M(X)M(Y) = \frac{1}{4}$ ;  $D^2[XY] = \frac{1}{144}$ .

**Problema 3.26** Variabilele  $X$  și  $Y$  sunt legate prin  $Y = 2 - 3X$  și  $m_x = -1, D_X^2 = 4$ . Găsiți  $m_y, D_Y^2, Cov[X, Y], \rho[X, Y]$ .

R:  $M[Y] = M[2 - 3X] = 2 - 3(-1) = 5; D^2[Y] = (-3)^2 4 = 36$ . Din  $M[X^2] = D^2[X] + M^2[X]$ , deducem  $M[X^2] = 5$   $Cov[X, Y] = M[X(2 - 3X)] + 1 \times 5 = -12$   
 $\rho[X, Y] = \frac{-12}{D[X]D[Y]} = -1$ .

**Problema 3.27** Variabilele aleatoare  $X, Y, Z$  au mediile  $m_x, m_y, m_z$  și matricea de covarianță

$$\begin{pmatrix} D[X] & Cov[X, Y] & Cov[X, Z] \\ Cov[X, Y] & D[Y] & Cov[Y, Z] \\ Cov[X, Z] & Cov[Y, Z] & D[Z] \end{pmatrix}.$$

Găsiți media și dispersia variabilei  $U = aX - bY + cZ - d, a, b, c, d \in \mathbb{R}$ .

R:  $M[U] = a m_x - b m_y + c m_z - d, D^2[U] = a^2 D[X] + b^2 D[Y] + c^2 D[Z] - 2 a b Cov[X, Y] + 2 a c Cov[X, Z] - 2 b c Cov[Y, Z]$ .

**Problema 3.28**  $X, Y$  sunt variabile aleatoare independente  $X : N(1, 4), Y : U(0, 2)$ . Găsiți  $M[X + Y], M[XY], M[X^2], M[X - Y^2], D^2[X + Y], D^2[X - Y]$ .

R:  $M[X + Y] = 2, M[XY] = M[X]M[Y] = 1, M[X^2] = 5, M[X - Y^2] = -\frac{1}{3}, D^2[(X + Y)] = D^2[(X - Y)] = \frac{13}{3}$ .

**Problema 3.29** Densitatea de probabilitate a unei variabile aleatoare bidimensionale normale este

$$f(x, y) = \frac{1}{1,6\pi} e^{-\frac{1}{1,28}((x-2)^2 - 1,2(x-2)(y+3) + (y+3)^2)}.$$

Calculați covarianța variabilelor marginale.

R:  $Cov[X, Y] = 0,6$ .

**Problema 3.30** Un voltmetru înregistrează cea mai mare dintre două tensiuni  $V_1, V_2$ . Variabilele  $V_1, V_2$  sunt independente și au aceeași densitate  $f(v)$ . Găsiți media variabilei  $V = \max\{V_1, V_2\}$ .

Soluție.  $m = \int_{-\infty}^{+\infty} x_1 dv_1 \int_{-\infty}^{v_1} f(v_2) dv_2 + \int_{-\infty}^{+\infty} v_2 f(v_2) dv_2 \int_{-\infty}^{v_2} f(v_1) dx_1$ .



# Capitolul 4

## Probleme la limită în teoria probabilităților

Baza teoretică a statisticii matematice, care conferă garanții asupra valabilității studiului statistic al fenomenelor aleatoare, se sprijină pe proprietățile de convergență ale șirurilor de variabile aleatoare. Prezentăm principalele tipuri de convergență și unele proprietăți ale șirurilor de variabile aleatoare referitoare la acestea.

### 4.1 Convergența în probabilitate

Fie  $\{E, K, P\}$  un câmp de probabilitate,  $\{X_n\}_{n \in \mathbb{N}}$  un șir de variabile aleatoare,  $X$  o variabilă aleatoare, toate definite pe  $\{E, K, P\}$ .

**Definiția 4.1.1** Șirul  $\{X_n\}_{n \in \mathbb{N}}$  converge în probabilitate către  $X$  (vom folosi notația  $\{X_n\} \xrightarrow{prob} X$ ) dacă

$$\forall \varepsilon > 0 : \lim_{n \rightarrow \infty} P(\{e \in E \mid |X_n(e) - X(e)| > \varepsilon\}) = 0 \quad (4.1)$$

sau, echivalent,

$$\forall \varepsilon > 0 : \lim_{n \rightarrow \infty} P(\{e \in E \mid |X_n(e) - X(e)| \leq \varepsilon\}) = 1. \quad (4.2)$$

**Observația 4.1.1** Se poate defini și convergența în probabilitate a șirului de variabile aleatoare  $\{X_n\}_{n \in \mathbb{N}}$  către constanta  $c$  deoarece orice constantă este un caz particular de variabilă aleatoare.

#### Proprietăți ale convergenței în probabilitate.

**Propoziția 4.1.1** Limita unui șir de variabile aleatoare convergent în probabilitate este unică aproape sigur.

**Demonstrație.** Arătăm că dacă există două variabile aleatoare  $X$  și  $Y$  astfel încât  $\{X_n\} \xrightarrow{prob} X$ ,  $\{X_n\} \xrightarrow{prob} Y$  atunci  $P(\{X \neq Y\}) = 0$ . Fie

$$\varepsilon < |X - Y| = |X - X_n + X_n - Y| \leq |X - X_n| + |X_n - Y|$$

de aici rezultă

$$\{|X - Y| > \varepsilon\} \subseteq \{|X - X_n| > \frac{\varepsilon}{2}\} \cup \{|X_n - Y| > \frac{\varepsilon}{2}\},$$

deci

$$P(\{|X - Y| > \varepsilon\}) \leq P(\{|X - X_n| > \frac{\varepsilon}{2}\}) + P(\{|X_n - Y| > \frac{\varepsilon}{2}\}).$$

Deoarece  $\{X_n\} \xrightarrow{prob} X$  și  $\{X_n\} \xrightarrow{prob} Y$  rezultă, trecând la limită,

$$0 \leq P(\{|X - Y| > \varepsilon\}) \leq \lim_{n \rightarrow \infty} P(\{|X - X_n| > \frac{\varepsilon}{2}\}) + \lim_{n \rightarrow \infty} P(\{|X_n - Y| > \frac{\varepsilon}{2}\}) = 0$$

deci  $P(\{|X - Y| > \varepsilon\}) = 0$ . ■

**Propoziția 4.1.2** Dacă  $\{X_n\} \xrightarrow{prob} X$ ,  $\{Y_n\} \xrightarrow{prob} Y$  și  $a, b \in \mathbb{R}$  atunci  $\{aX_n + bY_n\} \xrightarrow{prob} aX + bY$ .

**Demonstrație.** Fie  $\varepsilon > 0$ . Urmând un raționament analog cu cel folosit în proprietatea precedentă, putem scrie

$$P(\{|(aX_n + bY_n) - (aX + bY)| > \varepsilon\}) = P(\{|a(X_n - X) + b(Y_n - Y)| > \varepsilon\}) \leq P(\{|a||X_n - X| > \frac{\varepsilon}{2}\}) + P(\{|b||Y_n - Y| > \frac{\varepsilon}{2}\}).$$

Ținând seama că  $\{X_n\} \xrightarrow{prob} X$  și  $\{Y_n\} \xrightarrow{prob} Y$  și trecând la limită obținem

$$\lim_{n \rightarrow \infty} P(\{|(aX_n + bY_n) - (aX + bY)| > \varepsilon\}) = 0$$

adică  $\{aX_n + bY_n\} \xrightarrow{prob} aX + bY$ . ■

## 4.2 Legea numerelor mari (forma slabă)

Un tip de probleme la limită, bazat pe noțiunea de convergență în probabilitate, cu semnificație de maximă importanță asupra legăturii dintre conceptele de bază ale teoriei probabilității și noțiunile empirice, este cel cunoscut sub denumirea de legea numerelor mari. Aceasta este un ansamblu de rezultate privind convergența către 1 a probabilităților unui șir de evenimente depinzând de un număr crescând de factori aleatori.



**Teorema 4.2.1** Fie  $(Y_n)_{n \in \mathbb{N}}$  un șir de variabile aleatoare admitând valori medii și dispersii finite și fie

$$M[Y_n] = M_n < \infty, \quad D^2[Y_n] = \sigma_n^2 < \infty.$$

Dacă există o constantă  $M$  astfel încât

$$\lim_{n \rightarrow \infty} M_n = M \text{ și } \lim_{n \rightarrow \infty} \sigma_n^2 = 0, \quad (4.3)$$

atunci

$$\{Y_n\} \xrightarrow{\text{prob}} M.$$

**Demonstrație.** Observăm că pentru orice  $\varepsilon > 0$

$$\{|Y_n - M| > \varepsilon\} \subseteq \{|Y_n - M_n| > \frac{\varepsilon}{2}\} \cup \{|M_n - M| > \frac{\varepsilon}{2}\}.$$

Putem scrie

$$P(\{|Y_n - M| > \varepsilon\}) \leq P(\{|Y_n - M_n| > \frac{\varepsilon}{2}\}) + P(\{|M_n - M| > \frac{\varepsilon}{2}\}). \quad (4.4)$$

Aplicând inegalitatea lui Cebâșev variabilei aleatoare  $Y_n$  obținem

$$P(\{|Y_n - M_n| > \varepsilon\}) \leq \frac{D^2[Y_n]}{\varepsilon^2} = \frac{\sigma_n^2}{\varepsilon^2}. \quad (4.5)$$

Deoarece  $\lim_{n \rightarrow \infty} M_n = M$  rezultă că  $\forall \varepsilon > 0, \exists N(\varepsilon) \in \mathbb{N}$  astfel încât  $\forall n \geq N(\varepsilon)$  inegalitatea  $|M_n - M| > \frac{\varepsilon}{2}$  devine imposibilă, adică

$$\forall n \geq N(\varepsilon) : P(\{|M_n - M| > \varepsilon\}) = 0.$$

Trecând la limită în (4.4), ținând seama de (4.5) și de ipotezele (4.3) rezultă

$$\lim_{n \rightarrow \infty} P(\{|Y_n - M| > \varepsilon\}) = 0.$$

■

**Teorema 4.2.2** (forma slabă a teoremei lui Jacob Bernoulli)

**Prima formulare:** Dacă  $A$  un eveniment caracterizat prin  $P(A) = p \neq 0$  și  $\frac{S_n}{n}$  frecvența relativă de realizare a evenimentului  $A$  în primele  $n$  probe ale unui șir infinit de probe independente, atunci

$$\forall \varepsilon > 0 : \lim_{n \rightarrow \infty} P(\{|\frac{S_n}{n} - p| > \varepsilon\}) = 0$$

sau, echivalent,

$$\forall \varepsilon > 0 : \lim_{n \rightarrow \infty} P(\{|\frac{S_n}{n} - p| \leq \varepsilon\}) = 1.$$

**A doua formulare:** Dacă  $\{X_n\}_{n \in \mathbb{N}}$  un șir de variabile aleatoare independente astfel încât  $X_n : Bi(n, p), n \in \mathbb{N}$ , atunci șirul de variabile aleatoare  $\{\frac{1}{n} \sum_{k=1}^n X_k\}_{n \in \mathbb{N}}$  converge în

probabilitate către  $p$ , adică  $\{\frac{1}{n} \sum_{k=1}^n X_k\} \xrightarrow{\text{prob}} p$ .

Demonstrație. Demonstrăm teorema lui Bernoulli sub cea de-a doua formă. Notăm

$$Y_n = \frac{1}{n} \sum_{k=1}^n X_k$$

și ținem seama că

$$M[Y_n] = \frac{1}{n} \sum_{k=1}^n M[X_k] = \frac{1}{n} np = p, \quad D^2[Y_n] = \frac{1}{n^2} \sum_{k=1}^n D^2[X_k] = \frac{npq}{n^2} = \frac{pq}{n},$$

deci  $\lim_{n \rightarrow \infty} M[Y_n] = p$  și  $\lim_{n \rightarrow \infty} D^2[Y_n] = 0$ , ceea ce arată că ipotezele Teoremei 4.2.1 sunt satisfăcute, deci  $\left\{ \frac{1}{n} \sum_{k=1}^n X_k \right\} \xrightarrow{prob} p$ . ■

### Observații.

1. Prima formulare a teoremei lui Bernoulli constituie justificarea teoretică a apropierii făcute între conceptele de frecvență relativă și probabilitate a unui eveniment. Ea exprimă faptul că pentru șiruri foarte mari de probe orice diferență sensibilă între frecvența relativă a unui eveniment și probabilitatea sa devine foarte improbabilă. Deci convergența frecvențelor relative către probabilitatea evenimentului nu trebuie înțeleasă ca o convergență numerică obișnuită; nu rezultă din teorema de mai sus și nici nu este intuitiv acceptabilă ideea că odată cu creșterea numărului de probe valorile frecvențelor relative sunt, obligatoriu, mai apropiate de probabilitate.

2. Cele două formulări decurg una din cealaltă dacă ținem seama că frecvența absolută de realizare a lui  $A$  în  $n$  probe. Fie  $X_n$  o variabilă aleatoare repartizată  $Bi(n, p)$ .

Dacă notăm  $S_n = \sum_{k=1}^n X_k$ , atunci  $\frac{S_n}{n} = \frac{1}{n} \sum_{k=1}^n X_k$  și deci

$$\lim_{n \rightarrow \infty} P(\left\{ \left| \frac{S_n}{n} - p \right| > \varepsilon \right\}) = 0$$

ceea ce nu înseamnă altceva decât că

$$\left\{ \frac{1}{n} \sum_{k=1}^n X_k \right\} \xrightarrow{prob} p.$$

3. Rezultatul teoremei constituie justificarea teoretică a definiției noțiunii de estimare a unui parametru al unei repartiții, noțiune de mare importanță în statistica matematică.

**Teorema 4.2.3 (Cebâșev)** *Dacă  $(X_n)_{n \in \mathbb{N}}$  este un șir de variabile aleatoare independente două câte două, având dispersiile mărginite de o aceeași constantă*

$$D^2[X_n] \leq c^2, \quad n \in \mathbb{N},$$

atunci

$$\forall \varepsilon > 0 : \lim_{n \rightarrow \infty} P(\{|\frac{1}{n} \sum_{k=1}^n X_k - \frac{1}{n} \sum_{k=1}^n M[X_k]| > \varepsilon\}) = 0$$

sau, echivalent,

$$\forall \varepsilon > 0 : \lim_{n \rightarrow \infty} P(\{|\frac{1}{n} \sum_{k=1}^n X_k - \frac{1}{n} \sum_{k=1}^n M[X_k]| \leq \varepsilon\}) = 1,$$

adică are loc convergența în probabilitate a șirul de variabile aleatoare,

$$\{\frac{1}{n} \sum_{k=1}^n (X_k - M[X_k])\} \xrightarrow{prob} 0.$$

**Demonstrație.** Dacă  $Y_n = \frac{1}{n} \sum_{k=1}^n (X_k - M[X_k])$  atunci

$$M[Y_n] = M[\frac{1}{n} \sum_{k=1}^n (X_k - M[X_k])] = \frac{1}{n} \sum_{k=1}^n M[X_k] - \frac{1}{n} \sum_{k=1}^n M[X_k] = 0$$

și deoarece variabilele aleatoare  $X_n$  sunt independente două câte două, rezultă  $(X_k - M[X_k])$  sunt independente două câte două și deci

$$D^2[Y_n] = D^2[\frac{1}{n} \sum_{k=1}^n (X_k - M[X_k])] = \frac{1}{n^2} \sum_{k=1}^n D^2[X_k - M[X_k]] = \frac{1}{n} \sum_{k=1}^n D^2[X_k].$$

Aplicând inegalitatea lui Cebâșev variabilei aleatoare  $Y_n$  și ținând seama de ipotezele problemei, putem scrie

$$P(\{|\frac{1}{n} \sum_{k=1}^n X_k - \frac{1}{n} \sum_{k=1}^n M[X_k]| > \varepsilon\}) \leq \frac{1}{n^2 \varepsilon^2} \sum_{k=1}^n D^2[X_k] < \frac{nc^2}{n^2 \varepsilon^2} = \frac{c^2}{n \varepsilon^2}$$

și deci

$$\lim_{n \rightarrow \infty} P(\{|\frac{1}{n} \sum_{k=1}^n X_k - \frac{1}{n} \sum_{k=1}^n M[X_k]| > \varepsilon\}) \leq \lim_{n \rightarrow \infty} \frac{c^2}{n \varepsilon^2} = 0.$$

■

**Teorema 4.2.4 (Markov)** Dacă variabilele aleatoare  $X_1, X_2, \dots, X_n, \dots$  au proprietatea că:

$$\frac{D^2[\sum_{i=1}^n X_i]}{n^2} \rightarrow 0, n \rightarrow \infty,$$

atunci are loc legea numerelor mari.

**Demonstrație.** Trebuie demonstrat că șirul  $\{X_n\}_{n \in \mathbb{N}}$  verifică relația:

$$\forall \varepsilon > 0 : \lim_{n \rightarrow \infty} P(\{|\frac{1}{n} \sum_{k=1}^n X_k - \frac{1}{n} \sum_{k=1}^n M[X_k]| \leq \varepsilon\}) = 1.$$

Aplicăm inegalitatea lui Cebâșev pentru variabilele aleatoare:

$$Y = \sum_{i=1}^n X_i/n, D^2[Y] = D^2[\sum_{i=1}^n X_i/n] = \frac{1}{n^2} D^2[\sum_{i=1}^n X_i] \rightarrow 0, n \rightarrow \infty.$$

Deci  $D^2[Y] < \infty$  și atunci are loc inegalitatea lui Cebâșev:

$$P(|Y - M[Y]| \leq \varepsilon) \geq 1 - \frac{1}{\varepsilon^2} \frac{1}{n^2} D^2[\sum_{i=1}^n X_i].$$

Dar  $\frac{1}{n^2} D^2[\sum_{i=1}^n X_i] \rightarrow 0$ , dacă  $n \rightarrow \infty$ . Trecând la limită în inegalitatea precedentă, obținem afirmația teoremei. ■

**Observația 4.2.1** În cazul particular când variabilele aleatoare sunt independente, condiția din enunț se scrie:

$$\frac{\sum_{i=1}^n D^2[X_i]}{n} \rightarrow 0, n \rightarrow \infty.$$

**Teorema 4.2.5 (Hincin)** Dacă  $\{X_n\}_{n \in \mathbb{N}}$  este un șir de variabile aleatoare independente două câte două urmând aceeași repartiție și având dispersii finite, atunci

$$\lim_{n \rightarrow \infty} P(\{|\frac{1}{n} \sum_{k=1}^n X_k - M| > \varepsilon\}) = 0.$$

unde  $M = M[X_n], n \in \mathbb{N}$ .

**Demonstrație.** Dacă variabila aleatoare  $\{X_n\}_{n \in \mathbb{N}}$  urmează aceeași repartiție, rezultă  $D^2[X_n] = \sigma^2, n \in \mathbb{N}$ , ceea ce implică satisfacerea ipotezelor Teoremei lui Cebâșev. ■

**Observație.** Acest rezultat fundamentează teoretic procesul uzual de aproximare a mediei caracteristicii studiate a unei populații statistice prin media aritmetică a valorilor observate. Într-adevăr, dacă  $X_1, X_2, \dots, X_n, \dots$  sunt privite ca valori potențiale ale unei variabile aleatoare  $X$  obținute printr-un șir de probe independente, atunci teorema arată că media aritmetică a acestora converge către  $M = M[X]$ .

Ca un caz particular al teoremei lui Cebâșev se obține teorema lui Poisson.

**Teorema 4.2.6 (Poisson)** Fie  $A$  un eveniment a cărui probabilitate de realizare variază pe parcursul unui șir de probe independente, astfel încât la proba de rang  $k$ ,  $P(A) = p_k, k = 1, 2, \dots$  și fie  $\frac{S_n}{n}$  frecvența de realizare a evenimentului  $A$  în primele  $n$  probe. Atunci

$$\lim_{n \rightarrow \infty} P(\{|\frac{S_n}{n} - \frac{p_1 + p_2 + \dots + p_n}{n}| > \varepsilon\}) = 0.$$

**Demonstrație.** Definim, pentru fiecare  $k = 1, 2, \dots, n, \dots$  variabila aleatoare  $X_k$  ce ia valorile 1 sau 0 după cum  $A$  se realizează sau nu în proba de rang  $k$ . În consecință,  $X_k$  este definită

$$X_k : \begin{pmatrix} 0 & 1 \\ 1 - p_k & p_k \end{pmatrix}.$$

Notând cu  $S_n$  numărul de realizări ale lui  $A$  în primele  $n$  probe, se constată

$$f_n(A) = \frac{S_n}{n} = \frac{1}{n} \sum_{k=1}^n X_k.$$

Deoarece  $X_1, X_2, \dots, X_n, \dots$  sunt variabile aleatoare independente și deoarece

$$M[X_k] = p_k, \quad D^2[X_k] = M[X_k^2] - M[X_k]^2 = p_k - p_k^2 = p_k(1 - p_k) \leq \frac{1}{4},$$

rezultă că șirul  $\{X_n\}_{n \in \mathbb{N}}$  verifică ipotezele Teoremei lui Cebâșev și deci

$$\begin{aligned} & \lim_{n \rightarrow \infty} P(\{ \left| \frac{S_n}{n} - \frac{p_1 + p_2 + \dots + p_n}{n} \right| > \varepsilon \}) = \\ & = \lim_{n \rightarrow \infty} P(\{ \left| \frac{1}{n} \sum_{k=1}^n X_k - \frac{1}{n} \sum_{k=1}^n M[X_k] \right| > \varepsilon \}) = 0. \end{aligned}$$

■

### 4.3 Aproximări pentru repartiții discrete

Reamintim că o variabilă aleatoare binomială care ia  $n$  valori poate fi scrisă ca o sumă de  $n$  variabile aleatoare  $X_1, X_2, \dots, X_n$ ,

$$X_k : \begin{pmatrix} 0 & 1 \\ 1 - p & p \end{pmatrix}, \quad k = \overline{1, n}.$$

Atunci  $Y = \sum_{k=1}^n X_k$  este o variabilă aleatoare repartizată binomial,  $Bi(n; p)$ . Am văzut că o variabilă aleatoare binomială,  $Bi(n; p)$ , pentru valori mari ale lui  $n$  poate fi aproximată cu o variabilă aleatoare Poisson, dacă  $p$  este suficient de mic astfel încât  $np = \lambda = \text{constant}$ . Vom arăta că o variabilă aleatoare binomială,  $Bi(n; p)$  poate fi aproximată cu o variabilă aleatoare repartizată normal pentru orice valoare fixată a lui  $p$  și pentru  $n$  suficient de mare.

De exemplu, aruncăm un ban de 100 de ori. Ne interesează probabilitatea ca să obținem fața care conține banul de 50 de ori. Răspunsul

$$p = C_{100}^{50} \frac{1}{2^{100}} = \frac{100!}{50!50!} \frac{1}{2^{100}}$$

este nesatisfăcător deoarece nu ne dă nici o idee asupra mărimii probabilității. Nu putem stabili dacă această probabilitate este în jurul lui  $1/2$  sau  $1/10$  sau  $1/50$ . Dificultatea apare în calculul lui  $n!$  pentru  $n$  suficient de mare.

Problema care se pune este de a găsi o altă funcție  $h(n)$  care să constituie o bună aproximare în pentru  $n!$  (o bună aproximare în sensul că  $n!$  și  $h(n)$  să crească aproape la fel de repede odată cu  $n$ , sau  $|n! - h(n)|$  să fie mic când  $n$  crește sau  $\lim_{n \rightarrow \infty} \frac{n!}{h(n)} = 1$ ).

**Definiția 4.3.1** Fie  $f, g : \mathbb{R} \rightarrow \mathbb{R}$ . Spunem că  $f$  și  $g$  sunt asimptotic egale și notăm  $f \sim g$  dacă

$$\lim_{n \rightarrow \infty} \frac{f(n)}{g(n)} = 1.$$

Relația ” $f$  și  $g$  sunt asimptotic egale” este o relație de echivalență pe mulțimea funcțiilor neidentice. Proprietățile de reflexivitate, simetrie și tranzitivitate rezultă imediat.

De exemplu, un polinom în variabila  $n$  este asimptotic egal cu termenul său dominant. În cele ce urmează vom încerca să găsim o funcție  $h(n)$  astfel încât

$$\lim_{n \rightarrow \infty} \frac{n!}{h(n)} = 1.$$

Expresia unei astfel de funcții este sugerată de formula lui Stirling (vezi Anexa 2)

$$h(n) = \left(\frac{n}{e}\right)^n \sqrt{n} \sqrt{2\pi}.$$

Pare mai neplăcut să calculăm  $h(n)$  decât  $n!$ , dar este mult mai ușor deoarece puterile sunt mai lesne de calculat. Să aplicăm în cazul exemplului dat

$$\begin{aligned} p &= C_{100}^{50} \frac{1}{200} = \frac{100!}{50!50!} \frac{1}{2^{100}}, \\ p &\sim \frac{\left(\frac{100}{e}\right)^{100} \sqrt{100} \sqrt{2\pi}}{\left(\frac{50}{e}\right)^{100} 50 \cdot 2\pi} \frac{1}{2^{100}} = \left(\frac{100}{50}\right)^{100} \frac{10}{50\sqrt{2\pi}} \frac{1}{2^{100}} = \frac{2^{100}}{5\sqrt{2\pi}} \frac{1}{2^{100}} = \\ &= \frac{1}{5\sqrt{2\pi}} = 0,0797884 \approx 0,08. \end{aligned}$$

**Teorema 4.3.1** (teorema locală Moivre-Laplace).

Presupunem  $0 < p < 1$  și  $q = 1 - p$  iar

$$x_{n,k} = \frac{k - np}{\sqrt{npq}}, \quad 0 \leq k \leq n. \quad (4.6)$$

Dacă  $M$  o constantă pozitivă arbitrară fixată, atunci pentru acei  $k$  pentru care

$$|x_{n,k}| \leq M$$

avem

$$C_n^k p^k q^{n-k} \sim \frac{1}{\sqrt{2\pi npq}} e^{-\frac{x_{n,k}^2}{2}}. \quad (4.7)$$

(Convergența este în raport cu  $n$  și este uniformă relativ la  $k$ .)

Demonstrație. Din

$$x_{n,k} = \frac{k - np}{\sqrt{npq}}$$

rezultă  $k = np + \sqrt{npq} x_{n,k}$ , adică  $n - k = nq - \sqrt{npq} x_{n,k}$ . Deoarece  $|x_{n,k}| \leq M$  avem

$$\begin{cases} \frac{k}{np} = 1 + \frac{\sqrt{npq}}{np} x_{n,k} \rightarrow 1 \text{ și deci } k \sim np, \\ \frac{n-k}{nq} = 1 - \frac{\sqrt{npq}}{nq} x_{n,k} \rightarrow 1 \text{ și deci } n-k \sim nq. \end{cases} \quad (4.8)$$

Folosind formula lui Stirling putem scrie

$$C_n^k p^k q^{n-k} \sim \frac{\left(\frac{n}{e}\right)^n \sqrt{n} \sqrt{2\pi}}{\left(\frac{k}{e}\right)^k \sqrt{k} \sqrt{2\pi} \left(\frac{n-k}{e}\right)^{n-k} \sqrt{n-k} \sqrt{2\pi}} p^k q^{n-k} \sim \sqrt{\frac{n}{k(n-k)}} \frac{1}{\sqrt{2\pi}} \varphi(n, k),$$

unde

$$\varphi(n, k) = \frac{n^n}{k^n (n-k)^{n-k}} p^k q^{n-k} = \left(\frac{np}{k}\right)^k \left(\frac{nq}{n-k}\right)^{n-k}.$$

Deoarece  $k \sim np$  și  $n-k \sim nq$  rezultă că

$$C_n^k p^k q^{n-k} \sim \frac{1}{\sqrt{2\pi npq}} \varphi(n, k).$$

Demonstrăm în continuare că

$$\varphi(n, k) \sim e^{-\frac{x_{n,k}^2}{2}}.$$

Folosim dezvoltarea în serie Taylor a lui  $\ln(1+x)$

$$\ln(1+x) = x - \frac{x^2}{2} + \dots + (-1)^{n-1} \frac{x^n}{n} + \dots \quad \text{pentru } |x| < 1$$

și obținem

$$\begin{aligned} \ln\left(\frac{np}{k}\right)^k &= k \ln\left(\frac{np}{k}\right) \sim k \ln\left(\frac{k - \sqrt{npq} x_{n,k}}{k}\right) = k \ln\left(1 - \frac{\sqrt{npq} x_{n,k}}{k}\right) = \\ &= k\left(-\frac{\sqrt{npq}}{k} x_{n,k} - \frac{npq}{2k^2} x_{n,k}^2 - \dots\right), \\ \ln\left(\frac{nq}{n-k}\right)^{n-k} &= (n-k) \ln\left(\frac{nq}{n-k}\right) \sim (n-k) \ln\left(\frac{n-k + \sqrt{npq} x_{n,k}}{n-k}\right) = \\ &= (n-k) \ln\left(1 + \frac{\sqrt{npq} x_{n,k}}{n-k}\right) = (n-k) \left(\frac{\sqrt{npq}}{n-k} x_{n,k} - \frac{npq}{2(n-k)^2} x_{n,k}^2 + \dots\right), \end{aligned}$$

deoarece

$$\left|\frac{\sqrt{npq}}{k} x_{n,k}\right| < 1 \text{ și } \left|\frac{\sqrt{npq}}{n-k} x_{n,k}\right| < 1 \quad (4.9)$$

sunt satisfăcute pentru  $n$  suficient de mare pentru care  $|x_{n,k}| < M$ . Deci

$$\ln \varphi(n, k) = \ln\left(\frac{np}{k}\right)^k + \ln\left(\frac{nq}{n-k}\right)^{n-k} \sim k\left(-\frac{\sqrt{npq}}{k} x_{n,k} - \frac{npq}{2k^2} x_{n,k}^2 - \dots\right) +$$

$$\begin{aligned}
& +(n-k)\left(\frac{\sqrt{npq}}{n-k}x_{n,k} - \frac{npq}{2(n-k)^2}x_{n,k}^2 + \dots\right) = \\
& = \left(-\sqrt{npq}x_{n,k} - \frac{npq}{2k}x_{n,k}^2 - \dots\right) + \left(\sqrt{npq}x_{n,k} - \frac{npq}{2(n-k)}x_{n,k}^2 + \dots\right) = \\
& = \frac{npq}{2}x_{n,k}^2\left(-\frac{1}{k} - \frac{1}{n-k}\right) + \dots = -\frac{n^2pq}{2k(n-k)}x_{n,k}^2 + \dots
\end{aligned}$$

Justificăm de ce neglijăm termenii din dezvoltare de grad mai mare decât doi pentru  $n \rightarrow \infty$ . Când  $n$  este suficient de mare, cele două cantități din (4.9) sunt mai mici decât  $2/3$  și prin urmare Lema A2.1 din Anexa 2 este aplicabilă și contribuția acestora la cele două serii este mărginită de

$$k\left|\frac{\sqrt{npq}}{k}x_{n,k}\right|^3 = (n-k)\left|\frac{\sqrt{npq}}{(n-k)}x_{n,k}\right|^3.$$

Deoarece  $pq < 1$  și  $|x_k| \leq M$  aceasta nu depășește

$$\frac{n^{\frac{2}{3}}}{k^2}M^3 + \frac{n^{\frac{3}{2}}}{(n-k)^2}M^3,$$

care în mod evident tinde la zero când  $n \rightarrow \infty$  datorită relațiilor (4.8). Astfel, folosind aceste relații, rezultă

$$\ln \varphi(n, k) \sim \frac{n^2pq}{2npnq}x_{n,k} = -\frac{x_{n,k}^2}{2}.$$

Aceasta este echivalentă cu

$$\varphi(n, k) \sim e^{-\frac{x_{n,k}^2}{2}}$$

și de aici rezultă (4.7). ■

**Observația 4.3.1** Aproximarea este utilizată dacă  $n$  este suficient de mare astfel încât  $np \geq 5$  și  $n(1-p) \geq 5$ .

## 4.4 Convergența în repartiție. Teorema limită centrală

Unele probleme în teoria probabilităților impun studierea unor sume cu un număr foarte mare de variabile aleatoare. Teorema limită centrală stabilește condițiile în care repartiția limită a sumelor considerate este normală.

**Teorema 4.4.1 (Moivre-Laplace)** Fie  $A$  un eveniment care are probabilitatea de realizare  $p = P(A)$  într-un șir de probe independente. Dacă  $S_n$  este numărul de realizări ale lui  $A$  în  $n$  probe, atunci oricare ar fi  $a$  și  $b$ ,  $a < b$ ,

$$\lim_{n \rightarrow \infty} P\left(\left\{a \leq \frac{S_n - np}{\sqrt{npq}} \leq b\right\}\right) = \frac{1}{\sqrt{2\pi}} \int_a^b e^{-\frac{x^2}{2}} dx. \quad (4.10)$$



Demonstrație. Fie  $k$  o valoare posibilă a lui  $S_n$  astfel încât  $S_n = k$  înseamnă

$$\frac{S_n - np}{\sqrt{npq}} = x_{n,k}$$

conform relației (4.6). Atunci probabilitatea evenimentului din dreapta formulei (4.10) este

$$\sum_{a < x_{n,k} < b} P(\{S_n = k\}) = \sum_{a < x_{n,k} < b} C_n^k p^k q^{n-k}.$$

Ținând seama de faptul că

$$x_{n,k+1} - x_{n,k} = \frac{k+1 - np}{\sqrt{npq}} - \frac{k - np}{\sqrt{npq}} = \frac{1}{\sqrt{npq}},$$

obținem

$$\sum_{a < x_{n,k} < b} P(\{S_n = k\}) \sim \frac{1}{\mathcal{K}} \sum_{a < x_{n,k} < b} e^{-\frac{x^2}{2}} (x_{n,k+1} - x_{n,k}). \quad (4.11)$$

Corespondența dintre  $k$  și  $x_{n,k}$  este bijectivă și atunci când  $k$  variază de la 0 la  $n$ ,  $x_{n,k}$  variază în intervalul  $[-\sqrt{\frac{np}{q}}, \sqrt{\frac{nq}{p}}]$ , nu continuu, cu pasul  $x_{n,k+1} - x_{n,k} = \frac{1}{\sqrt{npq}}$ . Pentru  $n$  suficient de mare intervalul va conține  $[a, b]$  iar punctele  $x_{n,k}$  vor fi în interiorul lui  $[a, b]$ , împărțindu-l în intervale echidistante de lungime  $\frac{1}{\sqrt{npq}}$ . Presupunem că cea mai mică și cea mai mare valoare a lui  $k$  ce satisfac condițiile  $a \leq x_{n,k} < b$  sunt, respectiv,  $j$  și  $l$  și deci vom avea

$$x_{j-1} < a < x_j < x_{j+1} < \dots < x_{l-1} < x_l < b < x_{l+1},$$

și suma din (4.11) se poate scrie

$$\sum_{k=j}^l \varphi(x_{n,k})(x_{n,k+1} - x_{n,k}),$$

unde

$$\varphi(x) = \frac{1}{\mathcal{K}} e^{-\frac{x^2}{2}}$$

Aceasta este suma Riemann pentru integrala definită  $\int_a^b \varphi(x) dx$ . Făcând  $n \rightarrow \infty$ , divizarea devine din ce în ce mai fină și suma converge la integrala dată. Rămâne de determinat constanta  $\mathcal{K}$ . În formula

$$\lim_{n \rightarrow \infty} P(\{a \leq \frac{S_n - np}{\sqrt{npq}} \leq b\}) = \frac{1}{\sqrt{2\pi}} \int_a^b e^{-\frac{x^2}{2}} dx \quad (4.12)$$

facem  $a = -b$  și atunci

$$\lim_{n \rightarrow \infty} P(-b < \frac{S_n - np}{\sqrt{npq}} \leq b) = \frac{1}{\mathcal{K}} \int_{-b}^b e^{-\frac{x^2}{2}} dx. \quad (4.13)$$

Dacă notăm

$$X = \frac{S_n - np}{\sqrt{npq}},$$

atunci

$$M[X] = 0, \quad D^2[X] = 1$$

și obținem

$$P\left(\left|\frac{S_n - np}{\sqrt{npq}}\right| \leq b\right) \geq 1 - \frac{1}{b^2}. \quad (4.14)$$

Combinând relațiile (4.13) și (4.14) obținem relația

$$1 - \frac{1}{b^2} \leq \frac{1}{\mathcal{K}} \int_{-b}^b e^{-\frac{x^2}{2}} \leq 1$$

și făcând  $b \rightarrow \infty$  obținem

$$\mathcal{K} = \int_{-\infty}^{\infty} e^{-\frac{x^2}{2}} dx = \sqrt{2\pi},$$

deci constanta  $\mathcal{K}$  din formula lui Stirling este  $\sqrt{2\pi}$ . ■

Înainte de a da o nouă formulare teoremei Moivre-Laplace, introducem noțiunea de convergență în repartiție.

**Definiția 4.4.1** Fie  $\{X_n\}_{n \in \mathbb{N}}$  un șir de variabile aleatoare și  $\{F_n\}_{n \in \mathbb{N}}$  șirul funcțiilor de repartiție corespunzătoare. Dacă șirul funcțiilor de repartiție  $\{F_n\}_{n \in \mathbb{N}}$  converge către o funcție de repartiție  $F$  în fiecare punct de continuitate  $x_0$  al funcției de repartiție  $F$  corespunzătoare variabilei aleatoare  $X$ , adică dacă

$$\lim_{n \rightarrow \infty} F_n(x_0) = F(x_0)$$

atunci spunem că șirul  $\{X_n\}_{n \in \mathbb{N}}$  converge în repartiție către  $X$  și se notează  $\{X_n\} \xrightarrow{rep} X$ .

**Observatii.**

1. Deoarece pot exista mai multe variabile aleatoare care au aceeași funcție de repartiție, rezultă din definiție că limita unui șir de variabile aleatoare convergent în repartiție nu este unică.
2. Un exemplu de astfel de convergență este următorul: dacă  $\{X_n\}_{n \in \mathbb{N}}$  este un șir de variabile aleatoare repartizată  $Bi(n, \frac{\lambda}{n})$ , atunci  $\{X_n\}_{n \in \mathbb{N}}$  converge în repartiție către variabila aleatoare  $X$  repartizată Poisson de parametru  $\lambda$ . (Legătura între repartiția binomială și repartiția Poisson).

Următoarele rezultate stabilesc legătura între cele două moduri de convergență.

**Teorema 4.4.2** Dacă  $\{X_n\} \xrightarrow{prob} X$ , atunci  $\{X_n\} \xrightarrow{rep} X$ .

**Demonstrație.** Din definiția convergenței în probabilitate,  $\{X_n\} \xrightarrow{prob} X$ , rezultă că

$$\forall \varepsilon > 0 : \lim_{n \rightarrow \infty} P(\{|X_n - X| \geq \varepsilon\}) = 0.$$

Fie  $F_n$  funcția de repartiție a variabilei aleatoare  $X_n$ ,  $F$  funcția de repartiție a lui  $X$  și  $x_0$  un punct de continuitate a lui  $F$ . Atunci

$$\forall \varepsilon > 0 \exists \delta > 0 : |F(x_0 + \delta) - F(x_0 - \delta)| \leq \varepsilon.$$

Din

$$\begin{aligned} F(x_0 - \delta) &= P(\{X < x_0 - \delta\}) = P(\{X < x_0 - \delta\} \cap (\{X_n < x_0\} \cup \{X_n \geq x_0\})) = \\ &= P(\{X < x_0 - \delta\} \cap \{X_n < x_0\}) + P(\{X < x_0 - \delta\} \cap \{X_n \geq x_0\}) \leq \\ &\leq P(\{X_n < x_0\}) + P(\{|X_n - X| > \delta\}) = F_n(x_0) + P(\{|X_n - X| > \delta\}) = 0, \end{aligned}$$

și ținând seama că  $\{X_n\} \xrightarrow{prob} X$ , adică

$$\lim_{n \rightarrow \infty} P(\{|X_n - X| \geq \delta\}) = 0,$$

rezultă

$$F(x_0 - \delta) \leq \lim_{n \rightarrow \infty} F_n(x_0).$$

Analog

$$F(x_0 + \delta) \geq \lim_{n \rightarrow \infty} F_n(x_0).$$

Rezultă

$$\lim_{n \rightarrow \infty} F_n(x_0) = F(x_0).$$

■

**Observație.** Reciproca acestei teoreme nu este adevărată. Ilustrăm aceasta printr-un exemplu. Fie variabila aleatoare

$$X : \begin{pmatrix} 0 & 1 \\ \frac{1}{2} & \frac{1}{2} \end{pmatrix}$$

și variabila aleatoare  $Y = 1 - X$ . Variabilele aleatoare  $X$  și  $Y$  au aceeași funcție de repartiție. într-adevăr,

$$Y : \begin{pmatrix} 0 & 1 \\ \frac{1}{2} & \frac{1}{2} \end{pmatrix}$$

$$F_X(x) = F_Y(x) = \begin{cases} 0 & \text{dacă } x \leq 0 \\ \frac{1}{2} & \text{dacă } 0 < x \leq 1 \\ 1 & \text{dacă } x > 1 \end{cases}$$

și  $|Y - X| = |1 - 2X| = 1$  indiferent de valoarea variabilei aleatoare  $X$ . Definim șirul de variabile aleatoare  $\{X_n\}_{n \in \mathbb{N}}$  unde  $X_n = Y$ . Rezultă că  $\{X_n\}_{n \in \mathbb{N}}$  converge în repartiție către  $X$ . Deoarece  $|X_n - X| = 1$  rezultă că  $\{X_n\}_{n \in \mathbb{N}}$  nu converge în probabilitate către  $X$ . Există totuși un caz particular în care se poate stabili și legătura inversă.

**Teorema 4.4.3** Dacă  $C$  este o constantă reală și dacă  $\{X_n\} \xrightarrow{rep} C$ , atunci  $\{X_n\} \xrightarrow{prob} C$ .

*Demonstrație.* Punând  $X = C$  am definit o variabilă aleatoare a cărei repartiție este

$$C : \begin{pmatrix} c \\ 1 \end{pmatrix}.$$

Deci funcția de repartiție a variabilei aleatoare  $X$  este

$$F(x) = \begin{cases} 0, & \text{dacă } x \leq c, \\ 1, & \text{dacă } x > c. \end{cases}$$

Fie  $\varepsilon > 0$ . Atunci

$$\begin{aligned} P(\{|X_n - c| \geq \varepsilon\}) &= 1 - P(\{c - \varepsilon < X_n < c + \varepsilon\}) = \\ &= 1 - P(\{X_n < c + \varepsilon\}) + P(\{X_n < c - \varepsilon + 0\}) \leq 1 - F_n(c + \varepsilon) + F_n(c - \varepsilon + 0) \end{aligned}$$

Punctul  $x = c$  este punct de discontinuitate pentru  $F$  și

$$F(c + \alpha) - F(c - \alpha) = 1,$$

deci

$$P(\{|X_n - c| \geq \varepsilon\}) \leq F(c + \alpha) - F(c - \alpha) - F_n(c + \varepsilon) + F_n(c - \varepsilon + 0).$$

Dar  $c + \varepsilon$  și  $c - \varepsilon + 0$  sunt puncte de continuitate ale lui  $F$  și, prin ipoteză,  $\lim_{n \rightarrow \infty} F_n(x) = F(x)$  pentru orice punct de continuitate  $x$  a lui  $F$ , deci

$$\lim_{n \rightarrow \infty} F_n(c + \varepsilon) = F(c + \varepsilon),$$

$$\lim_{n \rightarrow \infty} F_n(c - \varepsilon + 0) = F(c - \varepsilon + 0) = F(c - \varepsilon),$$

și deci

$$\lim_{n \rightarrow \infty} P(\{|X_n - C| \geq \varepsilon\}) = 0$$

ceea ce exprimă convergența în probabilitate a lui  $X_n$  către  $C$ . ■

Vom da acum o formulare mai generală a teoremei Moivre-Laplace. Notăm cu

$$S_n = X_1 + X_2 + \dots + X_n, \quad n \geq 1,$$

unde  $X_j, j = \overline{1, n}$ , sunt variabile aleatoare independente Bernoulli. Știm că

$$M[X_j] = p, \quad D^2[S_n] = npq, \quad j = \overline{1, n},$$

și pentru orice  $n$ ,

$$M[S_n] = np, \quad D^2[S_n] = npq.$$

Notăm

$$X_j^* = \frac{X_j - M[X_j]}{D[X_j]}, \quad S_n^* = \frac{S_n - M[S_n]}{D[S_n]} = \frac{1}{\sqrt{n}} \sum_{j=1}^n X_j^*. \quad (4.15)$$

$S_n^*$  este o variabilă aleatoare și se numește variabilă aleatoare normalizată. Avem pentru fiecare  $j$  și  $n$

$$M[X_j^*] = 0, \quad D^2[X_j^*] = 1.$$

$$M[S_n^*] = 0, \quad D^2[S_n^*] = 1.$$

Transformarea liniară care duce  $X_j$  în  $X_j^*$  sau  $S_n$  în  $S_n^*$  are ca scop aducerea lor la o variabilă aleatoare cu media 0 și dispersia 1. Fiecare  $S_n^*$  este o variabilă aleatoare care ia ca valori

$$x_{n,k} = \frac{k - np}{\sqrt{npq}}.$$

Aceasta este tocmai  $x_{n,k}$  din Teorema Moivre-Laplace și

$$P(\{S_n^* = x_{n,k}\}) = C_n^k p^k q^{n-k}, \quad 0 \leq k \leq n.$$

Dacă utilizăm funcția de repartiție corespunzătoare

$$P(\{S_n^* < x\}) = F_n(x),$$

iar dacă  $F$  este funcția de repartiție normală standard, atunci teorema Moivre-Laplace se poate scrie sub o formă mai elegantă și anume

$$\lim_{n \rightarrow \infty} F_n(x) = F(x).$$

■

**Observație.** Teorema poate fi extinsă în următorul sens: fie  $\{X_n\}_{n \in \mathbb{N}}$  un șir de variabile aleatoare independente având aceeași repartiție care nu trebuie să fie specificată. Trebuie, în schimb, ca  $M[X_j] = m < \infty$  și  $D^2[X_j] = \sigma^2 < \infty$ . Teorema lui Laplace are loc și în aceste condiții.

**Teorema 4.4.4** Pentru sumele  $S_n$  în condițiile generalizate de mai sus și pentru  $a < b$  are loc

$$\lim_{n \rightarrow \infty} P\left(\left\{a < \frac{S_n - nm}{\sigma\sqrt{n}} \leq b\right\}\right) = \frac{1}{\sqrt{2\pi}} \int_a^b e^{-\frac{x^2}{2}} dx. \quad (4.16)$$

Există însă o situație în care teorema limită centrală are o demonstrație banală. Este cazul în care variabilele aleatoare  $\{X_n\}_{n \in \mathbb{N}}$  sunt normale și independente. Atunci  $S_n = X_1 + X_2 + \dots + X_n$  este tot o variabilă aleatoare normală cu media  $nm$  și dispersia  $n\sigma^2$  conform Teoremei 3.6.2.

**Exemplul 4.4.1** Determinarea volumului unei selecții bernoulliene care să permită aplicarea legii numerelor mari.

Legea numerelor mari (Teorema 4.2.2) afirmă că

$$\lim_{n \rightarrow \infty} P(\{|f_n(A) - p| > \varepsilon\}) = 0,$$

unde  $f_n(A)$  este frecvența relativă de realizare a evenimentului  $A$  în primele  $n$  probe independente.

$$f_n(A) = \frac{k}{n} = \frac{S_n}{n} \quad \text{unde } S_n = X_1 + X_2 + \dots + X_n, \quad X_i : Bi(n, p), \quad i = \overline{1, n},$$

$$M\left[\frac{S_n}{n}\right] = p, \quad D^2\left[\frac{S_n}{n}\right] = \frac{pq}{n},$$

$$P\left(\left\{\left|\frac{S_n}{n} - p\right|\right\}\right) \geq 1 - \frac{D^2\left[\frac{S_n}{n}\right]}{\varepsilon^2} = 1 - \frac{pq}{n\varepsilon^2},$$

$$P\left(\left\{\left|\frac{S_n}{n} - p\right| > \varepsilon\right\}\right) < \frac{pq}{n\varepsilon^2} < \delta,$$

$\delta$  fiind dat, relația ne permite să determinăm o margine inferioară pentru volumul selecției  $n$ , deoarece

$$\frac{pq}{n\varepsilon^2} < \delta \text{ implică } n > \frac{pq}{\delta\varepsilon^2} \text{ și } \max_p \frac{pq}{\delta\varepsilon^2} = \frac{1}{4\delta\varepsilon^2},$$

adică

$$n > \frac{1}{4\delta\varepsilon^2}.$$

Această margine inferioară este mai mult decât este necesar pentru a putea aplica Teorema Moivre-Laplace.

$$\begin{aligned} P\left(\left\{\left|\frac{S_n}{n} - p\right| > \varepsilon\right\}\right) &= P\left(\left\{\left|\frac{S_n - np}{n}\right| > \varepsilon\right\}\right) = \\ &= P\left(\left\{\left|\frac{S_n - np}{\sqrt{npq}}\right| > \varepsilon\sqrt{\frac{n}{pq}}\right\}\right) = 1 - P\left(\left\{\left|\frac{S_n - np}{\sqrt{npq}}\right| \leq \varepsilon\sqrt{\frac{n}{pq}}\right\}\right) = \\ &= 1 - [F(\varepsilon\sqrt{\frac{n}{pq}}) - F(-\varepsilon\sqrt{\frac{n}{pq}})] = 1 - 0,5 - \Phi(\varepsilon\sqrt{\frac{n}{pq}}) + 0,5 - \Phi(\varepsilon\sqrt{\frac{n}{pq}}) \\ &= 1 - 2\Phi(\varepsilon\sqrt{\frac{n}{pq}}) < \delta \end{aligned}$$

Notăm  $z = \varepsilon\sqrt{\frac{n}{pq}}$ ; problema este să se determine  $z$  astfel încât  $1 - 2\Phi(z) < \delta$  adică  $\Phi(z) = \frac{1 - \delta}{2}$ . Determinăm  $z_0$  din relația  $\Phi(z_0) = \frac{1 - \delta}{2}$  și  $n$  astfel încât  $\varepsilon\sqrt{\frac{n}{pq}} = z$ .

Rezultă  $n = \frac{z^2 pq}{\varepsilon^2}$  și deci  $\max \frac{z^2 pq}{\varepsilon^2} = \frac{z^2}{4\varepsilon^2}$ , adică

$$n \geq \frac{z^2}{4\varepsilon^2}.$$

Într-adevăr, dacă luăm  $\varepsilon = 0,02$  și  $\delta = 0,05$  obținem, conform Legii numerelor mari

$$n > \frac{1}{4 \times 0,05 \times (0,02)^2} = 125000.$$

Folosind Teorema lui Moivre-Laplace,  $\Phi(z) = \frac{1 - 0,05}{2} = 0,475$ , adică  $z \geq 1,96$  și deci

$$n > \frac{(1,96)^2}{4(0,02)^2} = 2401.$$

**Exemplul 4.4.2** O tensiune constantă, dar necunoscută, trebuie să fie măsurată. Fiecare măsurătoare  $X_j$  se face cu o eroare  $N_j$  față de valoarea exactă  $v$ . Eroarea  $N_j$  are media egală cu zero și dispersia egală cu 1 microvolt.

$$X_j = v + N_j$$

Presupunem că eroarea este o variabilă aleatoare independentă. Câte măsurători sunt necesare ca media măsurătorilor să fie cu cel mult  $\varepsilon = 1$  mai mare decât valoarea exactă cu o probabilitate de 0,99?

Fiecare măsurătoare  $X_j$  are  $v$  și dispersia 1, astfel încât folosind legea numerelor mari obținem:

$$1 - \frac{1}{n\varepsilon^2} = 1 - \frac{1}{n} = 0,99.$$

Aceasta implică  $n = 100$ . Astfel dacă repetăm măsurătorarea de 100 de ori și calculăm media în mod normal în 99% din situații media obținută va diferi cu cel mult 1 microvolt de valoarea exactă.

**Exemplul 4.4.3** Pentru a estima probabilitatea unui eveniment  $A$ , se efectuează un șir de experiențe Bernoulli și se observă frecvența relativă a evenimentului  $A$ . De câte ori trebuie repetat evenimentul  $A$  astfel încât cu o probabilitate de 0,95 frecvența relativă să difere de  $p = P(A)$  cu 0,01?

Fiind experiențe Bernoulli, media  $m = p$  și dispersia  $D^2[X] = p(1 - p)$ . Evident că  $p(1 - p) \leq 1/4$  pentru  $0 \leq p \leq 1$ . Atunci rezultă

$$P(|f_n(A) - p| \geq \varepsilon) \leq \frac{D^2[X]}{n\varepsilon^2} \leq \frac{1}{4n\varepsilon^2}.$$

Pentru  $\varepsilon = 0,01$  obținem

$$1 - 0,95 = \frac{1}{4n\varepsilon^2}$$

Rezolvăm și obținem  $n = 50000$ . Această evaluare s-a obținut utilizând inegalitatea lui Cebâșev care dă niște evaluări destul de grosiere. Vom obține o altă evaluare utilizând Teorema Moivre-Laplace. Deoarece  $f_n(A) = \frac{S_n}{n}$  obținem:

$$P\left(\left|\frac{S_n}{n} - p\right| < \varepsilon\right) = P\left(\left|\frac{S_n - np}{n}\right| < \varepsilon\right) = 1 - 2\Phi\left(\varepsilon\sqrt{\frac{n}{p(1-p)}}\right)$$

Această probabilitate nu poate fi calculată deoarece  $p$  este necunoscut. Mai mult, deoarece  $p(1 - p) \leq 1/4$  pentru  $0 \leq p \leq 1$ , avem  $\sqrt{p(1 - p)} \leq 1/2$ , deci  $\Phi(x)$  descrește când argumentul crește.

$$P(|f_n(A) - p| \geq \varepsilon) < 1 - 2\Phi(2\varepsilon\sqrt{n})$$

Vrem ca probabilitatea de mai sus să fie egală cu 0,95. Aceasta implică  $\Phi(2\varepsilon\sqrt{n}) = (1 - 0,95)/2 = 0,25$ . Din tabele obținem  $2\varepsilon\sqrt{n} = 1,95$ . Rezolvând, obținem  $n = (0,98)^2/\varepsilon^2 = 9506$ .

**Exemplul 4.4.4** Să se determine numărul minim de aruncări ale unei monede care să asigure cel puțin cu o probabilitate de 0,9 ca diferența dintre frecvența relativă obținută și probabilitatea de apariție a unei fețe să fie mai mică în valoare absolută decât 0,2.

Folosind Teorema 4.2.2 obținem,

$$P(\{|f_n(A) - \frac{1}{2}| < 0,2\}) > 0,9. \quad (4.17)$$

Conform Exemplului 4.4.4 avem  $\varepsilon = 0,2$ ,  $\delta = 1 - 0,9 = 0,1$  și deci

$$n > \frac{1}{4\delta\varepsilon^2} = \frac{1}{4 \times 0,1 \times (0,2)^2} = 62,5, \quad n > 63.$$

Cel puțin 63 de aruncări asigură

$$P(\{|\frac{S_{63}}{63} - \frac{1}{2}| < 0,2\}) > 0,9.$$

Putem determina intervalul în care variază frecvența relativă astfel încât (4.17) să fie satisfăcută și deci frecvența absolută pentru un anumit  $n \leq 63$ ,

$$|\frac{k}{n} - \frac{1}{2}| < 0,2 \iff 0,3 < \frac{k}{n} < 0,7 \iff n \times 0,3 < k < n \times 0,7.$$

Dacă  $n = 63$  rezultă  $18 < k < 44$ . Deci din 63 aruncări, numărul aruncărilor reușite este cuprins între 18 și 44, atunci (4.17) este satisfăcută, adică am determinat intervalul în care se situează numărul cazurilor favorabile apariției unei aceleiași fețe, aceasta având loc cu probabilitatea de cel puțin 0,9.

**Exemplul 4.4.5** Un zar se aruncă de 1200 de ori. Să se determine probabilitatea minimă ca numărul de apariții ale feței cu  $i$  puncte,  $i$  fixat, să fie cuprins între 150 și 250. Dar între 100 și 250 ?

Constatăm că  $p = \frac{1}{6}$  și  $n = 1200$ . Deci

$$|\frac{k}{1200} - \frac{1}{6}| < \varepsilon \iff \frac{1}{6} - \varepsilon < \frac{k}{1200} < \frac{1}{6} + \varepsilon$$

echivalent cu

$$200 - 1200 \times \varepsilon < k < 200 + 1200 \times \varepsilon.$$

Să cercetăm dacă această situație este compatibilă cu datele problemei, adică dacă sistemul

$$\begin{cases} 200 - 1200\varepsilon = 150, \\ 200 + 1200\varepsilon = 250, \end{cases}$$

are soluție. Se obține  $\varepsilon = \frac{50}{1200} = \frac{1}{24}$ . În al doilea caz, sistemul devine

$$\begin{cases} 200 - 1200\varepsilon = 100, \\ 200 + 1200\varepsilon = 250, \end{cases}$$



și este incompatibil, obținând, din fiecare ecuație,  $\varepsilon_1 = \frac{1}{12}$  și  $\varepsilon_2 = \frac{1}{24}$ . Pentru  $\varepsilon_1 = \frac{1}{12}$  obținem intervalul (100, 300), iar pentru  $\varepsilon_2 = \frac{1}{24}$  obținem intervalul (150, 250). Cum

$$P(\{100 < \frac{S_n}{1200} < 250\}) > P(\{150 < \frac{S_n}{1200} < 250\}) > 1 - \frac{1}{24},$$

alegem  $\varepsilon = \frac{1}{24}$  și deci

$$\delta = \frac{1}{4\varepsilon^2 n} = \frac{1}{4 \cdot \frac{1}{24^2} \cdot 1200} = 0.12.$$

Deci, cu probabilitatea de cel puțin 0,88, numărul de apariții ale unei fețe a zarului cu  $i$  puncte este în intervalul (150, 250) dacă aruncăm zarul de 1200 ori. Pe de altă parte, ținând seama de regula celor  $3\sigma$  de la repartiția normală,

$$P(\{-3 < \frac{S_n - np}{\sqrt{npq}} \leq 3\}) = 0,9973,$$

ceea ce înseamnă că probabilitatea ca numărul de apariții ale unei fețe a zarului să fie în intervalul (161, 239) este de 0.9973. Se poate calcula exact probabilitatea ca numărul de apariții ale unei fețe să fie cuprins între 100 și 250. Deoarece  $np = 200$  și  $\sqrt{npq} = 12,91$  obținem

$$\begin{aligned} P(\{100 < S_n < 250\}) &= P(\{-100 < S_n - np < 50\}) = \\ &= P(\{-\frac{100}{12,91} < \frac{S_n - np}{\sqrt{npq}} < \frac{50}{12,91}\}) = \\ &= P(\{-7,75 < \frac{S_n - np}{\sqrt{npq}} < 3,873\}) = F(3,873) - F(-7,75) \end{aligned}$$

și ținând seama de Relația (3.14) din Capitolul 3,

$$\begin{aligned} P(\{100 < S_n < 250\}) &= \Phi(3,873) + \Phi(7,75) = \\ &= 0,499946 + 0,499997 = 0,999943, \end{aligned}$$

rezultat în concordanță cu cel anterior.

**Exemplul 4.4.6** Să se calculeze probabilitatea opririi simultane a trei mașini din zece care lucrează independent într-o fabrică în cazul în care probabilitatea defectării unei mașini este  $p = 0,2$ .

Numărul de mașini defecte este o variabilă aleatoare cu repartiție binomială:

$$X : \left( C_n^k(0,2)^k(0,8)^{10-k} \right), \quad k = \overline{1,10}$$

Se cere probabilitatea

$$P_{10,3} = C_{10}^3(0,2)^3(0,8)^7 = 0,2.$$

Folosind Teorema 4.3.1 putem aproxima

$$x_{10,3} = \frac{3 - \frac{10}{3}}{\sqrt{10 \frac{1}{2} \frac{1}{2}}} = -0,21$$

și obținem

$$C_{10}^3(0,2)^3(0,8)^7 \sim \frac{1}{\sqrt{2\pi \frac{1}{2} \frac{1}{2} 10}} e^{-\frac{(0,21)^2}{2}} \approx 0,246.$$

Diferența  $0,246 - 0,2 = 0,046$  este considerată ca o aproximație cu eroare mare. (Am văzut că aplicăm formula dacă  $np \geq 5$  și  $nq \geq 5$ , dar în cazul acesta  $np = 10 \times 0,2 = 2 < 5$ .)

Dacă am avea 25 de mașini și calculam probabilitatea opririi simultane a opt mașini (observăm că  $np = 25 \times 0,2 = 5$  și  $nq = 25 \times 0,8 = 20 > 5$ ), atunci

$$P_{25,8} = C_{25}^8(0,2)^8(0,8)^{17} = 0,06234.$$

Conform Teoremei 4.3.1

$$x_{25,8} = \frac{8 - 25 \times 0,2}{\sqrt{25 \times 0,2 \times 0,8}} = 1,5,$$

$$C_{25}^8(0,2)^8(0,8)^{17} \sim \frac{1}{\sqrt{2\pi \times 0,2 \times 0,8}} e^{-\frac{(1,5)^2}{2}} = 0,06475.$$

Diferența

$$0,06475 - 0,06234 = 0,00241$$

de ordinul miimilor este considerată satisfăcătoare din punct de vedere practic.

**Exemplul 4.4.7** O centrală electrică trebuie să deservească o rețea de 10000 de becuri medii. Probabilitatea aprinderii unui bec într-o noapte de iarnă, care constituie perioada de vârf a consumului de energie electrică, este de 0,7. Să se facă analiza economică necesară proiectării centralei.

Pentru a determina capacitatea centralei pot fi adoptate criteriile diferite:

- să construim centrala astfel încât în orice moment cele 10000 de becuri să funcționeze;
- să se determine capacitatea centralei astfel încât cu o probabilitate suficient de mare, consumul obișnuit să fie asigurat cu energia necesară bunei funcționări.

Fie  $X$  o variabilă aleatoare care ia ca valori numărul de becuri care pot fi aprinse într-o noapte. Această variabilă aleatoare are o repartiție binomială cu

$$n = 10000, \quad p = 0,7, \quad M[X] = np = 7000,$$

$$D^2[X] = npq = 2100, \quad D[X] = 45,83 \approx 46,$$

$$P(\{|X - M[X]| \leq k \times 46\}) \geq 1 - \frac{2100}{k^2 2100} = 1 - \frac{1}{k^2} = \frac{k^2 - 1}{k^2}.$$

Pentru  $k = 2$  obținem

$$P(\{|X - 700| \leq\}) \geq \frac{3}{4} = 0,75.$$

Dacă centrala se construiește pentru o capacitate de 7092 becuri atunci, cu o probabilitate de cel puțin 0,75, funcționarea ei este normală. Rezultatul nu este convenabil. La fel,

$$k = 3, \quad P(\{|X - 7000| \leq 138\}) \geq \frac{8}{9} = 0,89;$$

$$k = 4, \quad P(\{|X - 7000| \leq 184\}) \geq \frac{15}{16} = 0,94.$$

Dacă construim centrala pentru o capacitate de 7184 becuri medii atunci, cu probabilitatea de cel puțin 0,94, funcționarea va fi normală.

Să determinăm capacitatea centralei astfel încât cu o probabilitate de 0,99 funcționarea să fie normală. Folosim Teorema Moivre-Laplace cu  $a = -\infty$ .

$$P\left(\left\{\frac{S_n - np}{\sqrt{npq}} \leq b\right\}\right) = 0,999 = F(b) = 0,5 + \Phi(b)$$

$$0,5 + \Phi(b) = 0,999 \iff \Phi(b) = 0,499 \iff b = 3,09$$

$$\frac{S_n - 10000 \times 0,7}{\sqrt{10000 \times 0,7 \times 0,3}} \leq 3,09$$

$S_n = 7142$  se numește coeficient de *simultaneitate* și este indicat să se facă construcția centralei pentru el. Dacă centrala se construiește pentru 10000 de becuri medii, cu o probabilitate de 0.99, un număr de  $10000 - 7142 = 2858$  becuri rămân nefolosite.

**Exemplul 4.4.8** O fabrică are în stoc 1660 tone dintr-o materie primă. știind că zilnic se consumă în medie 13,33 t cu abaterea 1,2 t, cu ce probabilitate această cantitate ajunge pentru 4 luni.

Notăm cu  $X_i$  variabila aleatoare care ia ca valori consumul zilei  $i, i = \overline{1, 120}$ . Avem

$$M[X_i] = 13,33, \quad D[X_i] = 1,2.$$

În 120 de zile se consumă  $X = \sum_{i=1}^{120} X_i$ . Ne aflăm în cazul general în care nu se cunoaște repartiția variabilei aleatoare  $X_i$ . Să determinăm  $P(\{X < 1660\})$ .

$$M[X] = nm = 120 \times 13,33 = 1599,6, \quad D[X] = \sqrt{n\sigma^2} = \sqrt{n}\sigma = 13,1,$$

$$P(\{X < 1660\}) = P\left(\left\{\frac{X - 1599,6}{13,1} < \frac{1660 - 1599,6}{13,1}\right\}\right) = 0,5 + \Phi(4,6) = 0,999.$$

Se poate deci presupune că aproape sigur cantitatea de materie primă este suficientă.

**Exemplul 4.4.9** O sursă radioactivă este modelată după o lege Poisson și emite 30 particule/oră. Care este probabilitatea ca în 10 minute să fie emise cel mult 10 particule ?

Notăm  $X = \sum_{i=1}^{10} X_i$ , unde  $X_i$  sunt variabile aleatoare repartizate Poisson și independente. Din condițiile

$$\lambda = M[X] = \sum_{i=1}^{10} M[X_i] = nM[X_i]$$

și deci  $M[X_i] = \frac{\lambda}{n}$  și

$$\lambda = D^2[X] = \sum_{i=1}^{10} D^2[X_i] = nD^2[X_i],$$

adică  $D^2[X_i] = \frac{\lambda}{n}$ , unde  $\lambda$  este parametrul repartiției Poisson ce trebuie determinat din condiția  $\lambda = 30 \frac{1}{6} = 5$  particule/10 minute. După (4.16)

$$P(\{X \leq 10\}) = P\left(\left\{\frac{X - n\frac{\lambda}{n}}{\sqrt{n}\sqrt{\frac{\lambda}{n}}} \leq \frac{10 - \lambda}{\sqrt{\lambda}}\right\}\right) = 0,5 + \Phi\left(\frac{10 - 5}{\sqrt{5}}\right) = 0,98713.$$

**Exemplul 4.4.10** Fie  $\{X_n\}_{n \in \mathbb{N}}$  un șir de variabile aleatoare independente

$$X_n : \begin{pmatrix} -\sqrt{n} & 0 & \sqrt{n} \\ \frac{1}{n} & 1 - \frac{2}{n} & \frac{1}{n} \end{pmatrix}, \quad P(\{X_1 = 0\}) = 1, \quad n = 2, 3, \dots$$

Să se arate că  $\{X_n\}_{n \in \mathbb{N}}$  se supune Legii numerelor mari.

Verificăm condițiile Teoremei 4.2.1.

$$M[X_n] = 0, \quad D^2[X_n] = M[X_n^2] - (M[X_n])^2,$$

$$X_n^2 : \begin{pmatrix} 0 & \frac{1}{n} \\ 1 - \frac{2}{n} & \frac{2}{n} \end{pmatrix}, \quad M[X_n^2] = 2, \quad D^2[X_n] = 2$$

Conform Teoremei 4.2.1,  $\{X_n\} \xrightarrow{prob} 0$ . Dacă notăm

$$Y_n = \frac{1}{n} \sum_{k=1}^n X_k,$$

atunci

$$M[Y_n] = 0, \quad D^2[Y_n] = \frac{1}{n^2} \sum_{k=1}^n D^2[X_k] = \frac{2(n-1)}{n^2} + \frac{1}{n^2} = \frac{2n-1}{n^2} \rightarrow 0$$

deci

$$\lim_{n \rightarrow \infty} P(\{|Y_n - M[Y_n]| < \varepsilon\}) = 1 \iff \{Y_n\} \xrightarrow{prob} 0.$$

## 4.5 Legătura dintre convergența șirurilor funcțiilor de repartiție și convergența șirurilor funcțiilor caracteristice

**Teorema 4.5.1** *Fie  $F_n$  un șir de funcții de repartiție și  $F$  o funcție de repartiție. Dacă  $F_n \rightarrow F$  în orice punct de continuitate a lui  $F$ , rezultă că pentru orice  $f : \mathbb{R} \rightarrow \mathbb{R}$  continuă și mărginită are loc*

$$\lim_{n \rightarrow \infty} \int_{\mathbb{R}} f(x) dF_n(x) = \int_{\mathbb{R}} f(x) dF(x)$$

*Demonstrație.* Fie  $M = \sup_{x \in \mathbb{R}} |f(x)|$  și fie  $a, b$  puncte de continuitate ale lui  $F$  încât

$$F(a) \leq \varepsilon \text{ și } 1 - F(b) \leq \varepsilon.$$

Deoarece pe un interval închis  $[a, b]$  orice funcție continuă este și uniform continuă, alegem punctele de continuitate ale lui  $F$ ,  $x_k$  cu  $0 \leq k \leq s$  astfel încât

$$a = x_0 < x_1 < \dots < x_s = b$$

și

$$|f(x) - f(x_k)| \leq \varepsilon, \quad \forall x \in [x_k, x_{k+1}], \quad 0 \leq k \leq s-1.$$

Introducem funcția auxiliară de salturi  $f_\varepsilon$  definită astfel:

$$f_\varepsilon(x) = \begin{cases} f(x_k), & \text{dacă } x_k \leq x < x_{k+1}, \\ 0, & \text{dacă } x < x_0, x \geq x_s, \end{cases} \quad 0 \leq k \leq s-1.$$

Are loc, evident,

$$|f(x) - f_\varepsilon(x)| < \varepsilon, \quad \forall x \in [a, b].$$

Pentru orice funcție de repartiție  $G$  are loc

$$\int_{\mathbb{R}} f_\varepsilon(x) dg(x) = \sum_{k=0}^{s-1} f(x_k)(G(x_{k+1}) - G(x_k)).$$

Deoarece în  $x = x_k, 0 \leq k \leq s$ ,  $F$  este continuă,  $\lim_{n \rightarrow \infty} F_n(x) = F(x)$  și deci

$$\begin{aligned} \lim_{n \rightarrow \infty} \int_{\mathbb{R}} f_\varepsilon(x) dF_n(x) &= \lim_{n \rightarrow \infty} \sum_{k=0}^{s-1} f(x_k)(F_n(x_{k+1}) - F_n(x_k)) = \\ &= \sum_{k=0}^{s-1} f(x_k)(F(x_{k+1}) - F(x_k)) = \int_{\mathbb{R}} f_\varepsilon(x) dF(x), \end{aligned}$$

deci

$$\lim_{n \rightarrow \infty} \int_{\mathbb{R}} f_\varepsilon(x) dF_n(x) = \int_{\mathbb{R}} f_\varepsilon dF(x). \tag{4.18}$$

De asemenea avem

$$\begin{aligned}
 \int_{\mathbb{R}} |f(x) - f_{\varepsilon}(x)| dF(x) &= \int_{-\infty}^a |f(x) - f_{\varepsilon}(x)| dF(x) + \\
 &+ \int_a^b |f(x) - f_{\varepsilon}(x)| dF(x) + \int_b^{\infty} |f(x) - f_{\varepsilon}(x)| dF(x) \leq \\
 &\leq \int_{-\infty}^a |f(x)| dF(x) + \int_a^b |f(x) - f_{\varepsilon}(x)| dF(x) + \int_b^{\infty} |f(x)| dF(x) \leq \\
 &\leq M \int_{-\infty}^a dF(x) + \int_a^b |f(x) - f_{\varepsilon}(x)| dF(x) + M \int_b^{\infty} dF(x) = \\
 &= MF(a) + \varepsilon(F(b) - F(a)) + M(1 - F(b)).
 \end{aligned}$$

Dacă ținem seama de (4.18), găsim

$$\int_{\mathbb{R}} |f(x) - f_{\varepsilon}(x)| dF(x) \leq (2M + 1)\varepsilon. \quad (4.19)$$

Din convergența în repartiție, pentru  $n$  suficient de mare, avem

$$|F_n(a) - F(a)| < \frac{\varepsilon}{2M} \quad \text{și} \quad |F_n(b) - F(b)| < \frac{\varepsilon}{2M}.$$

Făcând același raționament ca mai sus găsim evaluarea

$$\int_{\mathbb{R}} |f(x) - f_{\varepsilon}(x)| dF_n(x) \leq (2M + 1)\varepsilon. \quad (4.20)$$

Din (4.18), (4.19) și (4.20) avem

$$\begin{aligned}
 \left| \int_{\mathbb{R}} f(x) dF_n(x) - \int_{\mathbb{R}} f(x) dF(x) \right| &\leq \int_{\mathbb{R}} |f(x) - f_{\varepsilon}(x)| dF_n(x) + \int_{\mathbb{R}} |f(x) - \\
 &- f_{\varepsilon}(x)| dF(x) + \left| \int_{\mathbb{R}} f_{\varepsilon}(x) dF_n(x) - \int_{\mathbb{R}} f_{\varepsilon}(x) dF(x) \right| \leq (4M + 3)\varepsilon.
 \end{aligned}$$

Deoarece  $\varepsilon$  este arbitrar, rezultă teorema. ■

Menționăm că și implicația inversă este adevărată.

**Teorema 4.5.2** *Dacă  $F_n$  este un șir de funcții de repartiție, atunci există un subșir  $F_{n_k}$  convergent la o funcție nedescrescătoare în punctele sale de continuitate.*

**Demonstrație.** Fie  $(x_n)_{n \in \mathbb{N}^*}$  o mulțime numărabilă arbitrară de numere reale, densă în  $\mathbb{R}$ , de exemplu mulțimea numerelor raționale. Deoarece șirul  $\{F_n(x_1)\}_{n \in \mathbb{N}^*} \in [0, 1]$  (fiind mărginit), din teorema lui Bolzano-Weierstrass există un subșir convergent  $\{F_n^1(x_1)\}_{n \in \mathbb{N}^*}$ . Analog, din șirul mărginit  $\{F_n^2(x_2)\}$  extragem un subșir convergent  $\{F_n^2(x_2)\}_{n \in \mathbb{N}^*}$  etc.

Rezultă că șirul diagonal  $\{F_n^n\}_{n \in \mathbb{N}}$  (cu excepția eventual a unui număr finit de termeni) este conținut în toate subșirurile  $\{F_n^k\}_{n \in \mathbb{N}^*, k \in \mathbb{N}^*}$  și deci converge, oricare ar fi  $x \in \mathbb{Q}$ . Introducem

$$F(x) \stackrel{def}{=} \lim_{k \rightarrow \infty} F_{n_k}(x).$$

$F$  este, evident, nedescrescătoare și mărginită pe  $\mathbf{Q}$  și poate fi extinsă la  $\mathbb{R}$  cu păstrarea proprietăților

$$F(x) = \sup_{y < x, y \in \mathbf{Q}} F(y).$$

Să demonstrăm că  $\{F_{n_k}\} \rightarrow F$  în punctele sale de continuitate. Fie  $x_0$  un punct de continuitate a lui  $F$  și să alegem  $\eta > 0$  încât pentru  $|x - x_0| < \eta$  să avem

$$|F(x) - F(x_0)| < \varepsilon.$$

Introducem funcțiile auxiliare

$$f_1(x) = \begin{cases} 1, & \text{dacă } x \leq x_0 - \eta, \\ \frac{x_0 - x}{\eta}, & \text{dacă } x_0 - \eta \leq x \leq x_0, \\ 0, & \text{dacă } x \geq x_0, \end{cases}$$

$$f_2(x) = \begin{cases} 1, & \text{dacă } x \leq x_0, \\ 1 - \frac{x_0 - x}{\eta}, & \text{dacă } x_0 \leq x \leq x_0 + \eta, \\ 0, & \text{dacă } x \geq x_0 + \eta. \end{cases}$$

Avem, evident,

$$\int_{\mathbb{R}} f_1(x) dF(x) \geq \int_{-\infty}^{x_0 - \eta} dF(x) = F(x_0 - \eta) \geq F(x_0) - \varepsilon,$$

$$\int_{\mathbb{R}} f_2(x) dF(x) \leq \int_{-\infty}^{x_0 + \eta} dF(x) = F(x_0 + \eta) \leq F(x_0) + \varepsilon,$$

și analog pentru  $F_{n_k}$

$$\int_{\mathbb{R}} f_1(x) dF_{n_k}(x) \leq \int_{-\infty}^x dF_{n_k}(x) = F_{n_k}(x_0),$$

$$\int_{\mathbb{R}} f_2(x) dF_{n_k}(x) \geq \int_{-\infty}^x dF_{n_k}(x) = F_{n_k}(x_0).$$

Pentru  $n$  suficient de mare, conform teoremei 4.4.1,

$$\left| \int_{\mathbb{R}} f_1(x) dF_{n_k}(x) - \int_{\mathbb{R}} f_1(x) dF(x) \right| < \varepsilon,$$

$$\left| \int_{\mathbb{R}} f_2(x) dF_{n_k}(x) - \int_{\mathbb{R}} f_2(x) dF(x) \right| < \varepsilon.$$

Din ultimele șase relații deducem

$$F(x_0) - 2\varepsilon \leq F_{n_k}(x_0) \leq F(x_0) + 2\varepsilon.$$

Deoarece  $\varepsilon > 0$  este arbitrară rezultă

$$\lim_{n \rightarrow \infty} F_n(x_0) = F(x_0).$$

■

**Teorema 4.5.3** *Dacă șirul  $\{F_n\}$  de funcții de repartiție converge în repartiție către funcția  $F$  în toate punctele de continuitate ale lui  $F$ , atunci șirul  $\{\varphi_n\}$  al funcțiilor caracteristice corespunzătoare converge (uniform pe orice interval mărginit) la funcția caracteristică  $\varphi$  corespunzătoare lui  $F$ .*

*Demonstrație.* Deoarece

$$\varphi_n(t) = \int_{\mathbb{R}} e^{itx} dF_n(x) \quad \text{și} \quad \varphi(t) = \int_{\mathbb{R}} e^{itx} dF(x)$$

și funcția  $e^{itx}$  este continuă și mărginită pe  $\mathbb{R}$ . Conform Teoremei 4.5.2 rezultă

$$\lim_{n \rightarrow \infty} \varphi_n(t) = \varphi(t)$$

(se poate demonstra și convergența uniformă). ■

**Teorema 4.5.4** *Dacă șirul  $\{\varphi_n\}_{n \in \mathbb{N}^*}$  de funcții caracteristice converge pentru orice  $t \in \mathbb{R}$  la  $\varphi$  continuă pe  $\mathbb{R}$ , atunci șirul  $\{F_n\}_{n \in \mathbb{N}^*}$  de funcții de repartiție corespunzătoare converge către o funcție de repartiție  $F$ ; în plus,  $\varphi$  este funcția caracteristică corespunzătoare lui  $F$ .*

*Demonstrație.* Din Teorema 4.5.1 există un subșir  $\{F_{n_k}\}_{k \in \mathbb{N}^*}$  care converge la o funcție  $F$  nedescrescătoare, continuă la stânga în toate punctele de continuitate ale lui  $F$ . Să demonstrăm că  $F$  este o funcție de repartiție. Presupunem, prin absurd, că

$$F(-\infty) > 0 \quad F(+\infty) < 1$$

și

$$\delta = F(+\infty) - F(-\infty) < 1.$$

Fie  $\varepsilon > 0$  ales arbitrar astfel încât  $\varepsilon < 1 - \delta$ . Deoarece  $\varphi_n \rightarrow \varphi$  și  $\varphi_n(0) = 1$ , rezultă că  $\varphi(0) = 1$  și deoarece  $\varphi$  este continuă pe  $\mathbb{R}$  putem lua  $\tau > 0$  suficient de mic încât

$$\frac{1}{2\tau} \left| \int_{-\tau}^{\tau} \varphi(t) dt \right| > 1 - \frac{\varepsilon}{2} > \delta + \frac{\varepsilon}{2}. \quad (4.21)$$

De asemenea putem alege  $x_0 > \frac{4}{\tau\varepsilon}$  dacă  $K > 0$  suficient de mare, încât

$$\delta_k = F_{n_k}(x_0) - F_{n_k}(-x_0) = \int_{|x| < x_0} dF_{n_k}(x) < \delta + \frac{\varepsilon}{4}, \quad \text{dacă } k > K$$

ceea ce este posibil deoarece  $F_{n_k}$  este o funcție de repartiție. Deoarece  $\varphi_{n_k}$  este o funcție caracteristică,

$$\int_{-\tau}^{\tau} \varphi_{n_k}(t) dt = \int_{\mathbb{R}} \left[ \int_{-\tau}^{\tau} e^{itx} dt \right] dF_{n_k}(x).$$

Dar  $\left| \int_{-\tau}^{\tau} e^{itx} dt \right| \leq 2\tau$  deoarece  $|e^{itx}| = 1$ , iar pe de altă parte, calculând efectiv această integrală,

$$\int_{-\tau}^{\tau} e^{itx} dt = \frac{1}{ix} e^{itx} \Big|_{-\tau}^{\tau} = \frac{1}{ix} [e^{i\tau x} - e^{-i\tau x}] = \frac{2}{x} \sin(\tau x).$$



Deci, pentru  $|x| > x_0$ , ținând seama de faptul că  $|\sin(\tau x)| \leq 1$  avem  $\int_{-\tau}^{\tau} e^{itx} dt < \frac{2}{x_0}$ .

Deci

$$\begin{aligned} \left| \int_{-\tau}^{\tau} \varphi_{n_k}(t) dt \right| &\leq \left| \int_{|x| \leq x_0} \left[ \int_{-\tau}^{\tau} e^{itx} dt \right] dF_{n_k}(x) \right| + \\ &+ \left| \int_{x > x_0} \left[ \int_{-\tau}^{\tau} e^{itx} dt \right] dF_{n_k}(x) \right| < 2\tau\delta_k + \frac{2}{x_0}. \end{aligned}$$

Împărțind prin  $2\tau$

$$\frac{1}{2\tau} \left| \int_{-\tau}^{\tau} \varphi_{n_k}(t) dt \right| < \delta_k + \frac{1}{\tau x_0} < \delta + \frac{\varepsilon}{4} + \frac{1}{\tau} \frac{\tau\varepsilon}{4} < \delta + \frac{\varepsilon}{2},$$

ceea ce contrazice (4.21). Din teorema 4.5.3,

$$\lim_{k \rightarrow \infty} \int_{\mathbb{R}} e^{itx} dF_{n_k}(x) = \int_{\mathbb{R}} e^{itx} dF(x) = \varphi(t).$$

Rămâne să demonstrăm că  $\{F_n\}$  converge în repartiție către  $F$ . Să presupunem contrariul; atunci există un subsir  $\{F_{n_k}\}$  care converge în repartiție către  $F^* \neq F$ , dar  $F^*$  este o funcție de repartiție cu aceeași funcție caracteristică, deci din Teorema de unicitate Cap.III, Teorema 3.5.4 rezultă  $F^* \equiv F$ . ■

## 4.6 Convergența aproape sigură

Deoarece variabilele aleatoare sunt funcții definite pe spațiul de selecție (cu proprietăți suplimentare) putem vorbi de convergența punctuală a unui șir de variabile aleatoare  $\{X_n\}_{n \in \mathbb{N}}$  către variabila aleatoare  $X$ , înțelegând prin aceasta că șirul numeric de variabile aleatoare  $\{X_n(e)\}_{n \in \mathbb{N}}$ ,  $e \in E$  converge către  $X(e)$ .

**Definiția 4.6.1** Șirul de variabile aleatoare  $\{X_n\}_{n \in \mathbb{N}}$  converge aproape sigur către variabila aleatoare  $X$  (notat  $\{X_n\}_{n \in \mathbb{N}} \xrightarrow{a.s.} X$ ) dacă mulțimea evenimentelor în care  $\{X_n\}_{n \in \mathbb{N}}$  converge punctual la  $X$  formează un eveniment de probabilitate 1,

$$P(\{X_n \rightarrow X\}) = 1, \tag{4.22}$$

echivalent cu

$$P(\{X_n \not\rightarrow X\}) = 0.$$

**Observația 4.6.1** Convergența aproape sigură se mai numește convergență tare.

**Teorema 4.6.1** Dacă pentru orice  $r \in \mathbb{N}^*$  are loc

$$\sum_{n=1}^{\infty} P(\{|X_n - X| \geq \frac{1}{r}\}) < \infty \tag{4.23}$$

atunci  $\{X_n\}_{n \in \mathbb{N}} \xrightarrow{a.s.} X$ .

**Demonstrație.** Fie  $A_n^r = \{e \in E, |X_n - X| \geq \frac{1}{r}\}$  și  $B_n^r = \bigcup_{k=1}^{\infty} A_{n+k}^r$ . Din faptul că

$$P(B_n^r) \leq \sum_{k=1}^{\infty} P(A_{n+k}^r) = \sum_{l=n+1}^{\infty} P(\{|X_l - X| \geq \frac{1}{r}\})$$

și cum seria din (4.23) este convergentă, rezultă că restul seriei converge la zero și deci

$$\lim_{n \rightarrow \infty} P(B_n^r) = 0. \quad (4.24)$$

Fie  $B^r = B^1 \cup B^2 \cup B^3 \cup \dots$  și cum  $P(B) \leq \sum_{r=1}^{\infty} P(B^r)$  rezultă, conform (4.24) că  $P(B) = 0$ , unde de fapt  $B$  este mulțimea evenimentelor pentru care  $X_n$  nu converge la  $X$ . ■

Se poate demonstra că dacă  $\{X_n\}_{n \in \mathbb{N}} \xrightarrow{a.s.} X$  atunci  $\{X_n\}_{n \in \mathbb{N}} \xrightarrow{prob} X$  și deci  $\{X_n\}_{n \in \mathbb{N}} \xrightarrow{rep} X$ .

Un alt rezultat, datorat lui E. Borel, face parte din legea numerelor mari (forma tare) și reformulează, într-o manieră întărită, afirmația conținută în teorema lui Bernoulli.

**Teorema 4.6.2 (Borel)** *Fie  $A$  un eveniment care are probabilitatea de realizare  $p = P(A)$  într-un șir de probe independente și fie  $\frac{S_n}{n}$  frecvența relativă de realizare a evenimentului  $A$  din  $n$  probe. Atunci are loc convergența aproape sigură a șirului frecvențelor relative  $\frac{S_n}{n}$  către  $p$ .*

$$\frac{S_n}{n} \xrightarrow{a.s.} p.$$

**Demonstrație.** Conform Teoremei 4.5.1 este suficient să arătăm că seria

$$\sum_{n=1}^{\infty} P(\{|\frac{S_n}{n} - p| \geq \frac{1}{r}\}) \quad (4.25)$$

este convergentă, oricare ar fi  $r \in \mathbb{N}^*$ . Pentru aceasta vom observa, ca și la inegalitatea lui Cebășev, că putem stabili următoarea inegalitate pentru orice variabilă aleatoare  $X$  pentru care există  $M[(X - M[X])^4]$

$$P(\{|X - M[X]| \geq \varepsilon\}) \leq \frac{1}{\varepsilon^4} M[(X - M[X])^4].$$

## 4.7 Convergența în medie

**Definiția 4.7.1** *Șirul de variabile aleatoare  $\{X_n\}_{n \in \mathbb{N}}$  converge în medie de ordinul  $r$  către variabila aleatoare  $X$  dacă există momente absolute  $M[|X_n|^r], n \in \mathbb{N}$  și  $M[|X|^r]$  și dacă*

$$\lim_{n \rightarrow \infty} M[|X_n - X|^r] = 0,$$

și scriem  $\{X_n\}_{n \in \mathbb{N}} \xrightarrow{r} X$

**Teorema 4.7.1** *Dacă șirul de variabile aleatoare  $\{X_n\}_{n \in \mathbb{N}}$  converge în medie de ordinul  $r$  către variabila aleatoare  $X$  atunci converge în probabilitate către  $X$ .*

**Demonstrație.** Folosim inegalitatea analogă inegalității lui Cebâșev, dar pentru momentul centrat de ordin  $r$ , Relația (3.41):

$$P(\{|X_n - X| \geq \varepsilon\}) \leq \frac{M[|X_n - X|^r]}{\varepsilon^r}$$

rezultă că deoarece are loc (4.22) atunci

$$\lim_{n \rightarrow \infty} P(\{|X_n - X| \geq \varepsilon\}) = 0.$$

**Observație.** Dacă  $r = 2$  convergența în medie de ordinul doi se numește *convergență în medie pătratică*.

**Concluzie.**

$$\begin{array}{l} \{X_n\}_{n \in \mathbb{N}} \xrightarrow{a.s.} X \\ \{X_n\}_{n \in \mathbb{N}} \xrightarrow{r} X \end{array} \implies \{X_n\}_{n \in \mathbb{N}} \xrightarrow{prob} X \implies \{X_n\}_{n \in \mathbb{N}} \xrightarrow{rep} X .$$

## 4.8 Probleme propuse

**Problema 4.1** Se dau variabilele aleatoare independente  $X_1, X_2, \dots, X_n, \dots$ , unde  $X_n$  ia valorile  $-na, 0, na$ ,  $a \in \mathbb{R}_+$  cu probabilitățile:

a)  $p_1 = 1/2n^2$ ,  $p_2 = 1 - 1/n^2$ ,  $p_3 = 1/2n^2$ ,

b)  $p_1 = 1/2^n$ ,  $p_2 = 1 - 1/2^{n-1}$ ,  $p_3 = 1/2^n$ .

Satisfac aceste șiruri  $\{X_n\}_{n \in \mathbb{N}}$  legea numerelor mari?

Soluție. a)

$$X_n : \begin{pmatrix} -na & 0 & na \\ 1/2n^2 & 1 - 1/n^2 & 1/2n^2 \end{pmatrix}, n = 1, 2, \dots,$$

$$M[X_n] = 0, M[X^2] = a^2, D^2[X] = M[X^2] = a^2 < \infty.$$

Șirul  $\{X_n\}_{n \in \mathbb{N}}$  satisface legea numerelor mari, folosind Teorema lui Cebășev.

b)

$$X_n : \begin{pmatrix} -na & 0 & na \\ 1/2^n & 1 - 1/2^{n-1} & 1/2^n \end{pmatrix}, n = 1, 2, \dots,$$

$$M[X_n] = 0, M[X^2] = n^2 a^2 / 2^{n-1}, D^2[X] = M[X^2] - (M[X])^2 = n^2 a^2 / 2^{n-1} < \infty.$$

Întrucât  $D^2[X_n]$  nu este constantă nu se poate aplica Teorema lui Cebășev. Se aplică Teorema lui Hincin.

**Problema 4.2** Fie șirul de variabile aleatoare independente  $\{X_n\}_{n \in \mathbb{N}}$ .  $X_n$  ia valorile:  $-n, -(n-1), \dots, -1, 0, 1, \dots, n-1, n$  cu probabilitățile:

$$P(|X_n| = k) = \frac{1}{3k^3}, k = \overline{1, n}, P(X_n = 0) = 1 - \frac{2}{3} \left( 1 + \frac{1}{2^3} + \frac{1}{3^3} + \dots + \frac{1}{n^3} \right).$$

Se aplică șirului  $\{X_n\}_{n \in \mathbb{N}}$  legea numerelor mari?

Soluție. Tabloul de repartiție al variabilei aleatoare  $X_n$  este:

$$X_n : \begin{pmatrix} -n & \dots & -1 & 0 & 1 & 2 & \dots & n \\ \frac{1}{3n^3} & \dots & \frac{1}{3} & 1 - \frac{2}{3} \left( 1 + \frac{1}{2^3} + \frac{1}{3^3} + \dots + \frac{1}{n^3} \right) & \frac{1}{3} & \frac{2}{3^3} & \dots & \frac{1}{3n^3} \end{pmatrix}$$

$$M[X_n] = 0, n = \overline{1, n}$$

$$D^2[X_n] = M[X_n^2] = \sum_{k=1}^n k^2 \frac{1}{3k^3} = \frac{2}{3} \sum_{k=1}^n \frac{1}{k} < \frac{2}{3} (1 + \ln n).$$

Pentru majorare am utilizat egalitatea:

$$1 + \frac{1}{2} + \frac{1}{3} + \dots + \frac{1}{n} = \ln n + C + \varepsilon_n, \lim_{n \rightarrow \infty} \varepsilon_n = 0$$

iar  $C$  este constanta lui Euler cu  $C \approx 0.577$ . Vom aplica Teorema lui Markov:

$$\frac{1}{n^2} D^2 \left[ \sum_{i=1}^n X_i \right] = \frac{\sum_{i=1}^n D^2[X_i]}{n^2} < \frac{1}{n^2} \frac{2n}{3} (1 + \ln n),$$

$$\frac{1}{n^2} D^2 \left[ \sum_{i=1}^n X_i \right] < \frac{2}{3n} (1 + lnn) \rightarrow 0, n \rightarrow \infty.$$

Deci șirului  $\{X_n\}_{n \in \mathbb{N}}$  i se poate aplica legea numerelor mari.

**Problema 4.3** Se dă șirul de variabile aleatoare independente  $\{X_n\}_{n \in \mathbb{N}}$  cu  $M[X] = 0$ ,  $D^2[X] = n^a$ ,  $a = \text{const.}$ ,  $a < 1$ . Se aplică șirului dat legea numerelor mari?

Indicație. Se aplică Teorema lui Markov.

**Problema 4.4** Se dă șirul de variabile aleatoare  $\{X_n\}_{n \in \mathbb{N}^*}$  independente:  $X_n$  ia valorile  $-\sqrt{n}$ ,  $0$ ,  $\sqrt{n}$  cu probabilitățile  $1/n$ ,  $1 - 2/n$ ,  $1/n$  respectiv. Se aplică acestui șir legea numerelor mari?

Indicație. Da, întrucât se poate aplica teorema lui Cebâșev. Trebuie verificată condiția  $D^2[X_n] < c$ .

**Problema 4.5** Probabilitatea ca o diodă să se defecteze înainte de 1000 ore de funcționare este de 0,45. Dacă 1000 de diode sunt testate, care este probabilitatea ca să se defecteze un număr de diode cuprins între 4450 și 4515 înainte de a funcționa 1000 de ore?

Indicație.  $p = 0,45$ ,  $q = 0,55$ ,  $n = 10^4$ ,  $np = 4500$ ,  $\sigma^2 = npq = 2475$ ,  $a = -0,4020$ ,  $b = 0,3015$ . Utilizând (4.12) și legătura cu funcția lui Laplace, obținem

$$P(\{-0,4020 \leq \frac{S_n - 4500}{\sqrt{2475}} \leq 0,3015\}) = \Phi(0,3015) + \Phi(0,4020) = 0,275.$$

**Problema 4.6** Probabilitatea ca un rezistor să nu fie la limita de toleranță este 0,1. S-au cumpărat 1000 de rezistoare. Care este probabilitatea ca mai mult de 100 rezistoare să nu fie la limita de toleranță?

Indicație.  $P(\{1,0541 \leq \frac{S_n - 100}{\sqrt{90}} \leq 94,9\}) = 0,0778$

**Problema 4.7** În cazul unui semnal luminos dirijat spre un detector fotoelectric, numărul  $k$  de electroni emisi urmează o repartiție Poisson cu media  $\lambda = 150$ . Un semnal este detectat dacă emite mai mult de 140 de electroni. Care este probabilitatea ca semnalul să fie pierdut?

Indicație. Această probabilitate este  $p = \sum_{k=0}^{140} \frac{(150)^k e^{-k}}{k!}$ . Fie  $X$  variabila aleatoare care ia ca valori numărul de electroni emisi. Calculăm

$$P(\{X \leq 140\}) = P(\{\frac{X - 150}{\sqrt{150}} \leq \frac{140 - 150}{\sqrt{150}}\}) = 0,5 - \Phi(0,8165) = 0,209.$$

**Problema 4.8** Presupunem că numărul particulelor emise de o masă în  $t$  secunde este o variabilă aleatoare Poisson cu media  $\lambda t$ . Folosind inegalitatea lui Cebâșev să se obțină o margine pentru probabilitatea ca  $|N(t)/t - \lambda|$  să nu depășească  $\varepsilon$ .

Indicație.  $P(|N(t)/t - \lambda| \geq \varepsilon) \leq \frac{\lambda}{\varepsilon^2 t}$

**Problema 4.9** Numărul mesajelor care sosesc la un canal de comunicație este o variabilă aleatoare Poisson cu media de 10 mesaje/secundă. Folosind teorema limită centrală să se estimeze probabilitatea ca mai mult de 650 de mesaje să ajungă într-un minut.

Indicație. Se utilizează Exercițiul 4.4.9.

# Capitolul 5

## Procese stochastice

În studiul unor probleme fizice sau tehnologice apar fenomene care se desfășoară în timp și care se numesc *procese*. Să dăm câteva exemple.

1. În modelul atomului de hidrogen, datorat lui Bohr, electronul se poate plasa pe una din orbitele admisibile; la un moment dat  $t$ , definim variabila aleatoare  $X(t)$ , care ia valoarea  $i$ , dacă electronul se găsește pe orbita  $i$ .

2. Numărul de impulsuri care se produc în intervalul  $(0, t)$  la o centrală telefonică este o variabilă aleatoare pe care o notăm  $X(t)$ .

3. Dacă mișcarea unei particule depinde de circumstanțe întâmplătoare, de exemplu de ciocnirea cu alte particule, atunci în fiecare moment  $t$ , viteza  $V(t)$  sau poziția  $X(t)$  sunt variabile aleatoare.

4. Un semnal aleator este o undă electrică, sonoră etc. ce traversează un anumit mediu la un moment dat și pe care îl notăm cu  $X(t)$ . Un semnal poate fi condițional determinist dacă se cunoaște expresia analitică a undei; de exemplu  $X(t) = \sin(\omega t + \phi)$ , unde  $\phi$  este o variabilă aleatoare.

În fiecare din exemplele precedente se pune în evidență o familie de variabile aleatoare  $\{X(t)\}$ , cu  $t \in T$ ,  $T \subset \mathbb{R}$ , care definește un proces stochastic.

### 5.1 Lanțuri Markov

Fie  $\{E, K, P\}$  un câmp borelian de probabilitate.

**Definiția 5.1.1** Familia de variabile aleatoare  $X(t) : E \rightarrow \mathbb{R}$ , unde  $t \in T \subset \mathbb{R}$ , se numește proces stochastic. Dacă  $T = \mathbb{N}$  procesul se numește lanț.

Ne ocupăm în detaliu de lanțuri cu un număr finit de valori. Fie  $S$  o mulțime finită, ale cărei elemente le numim *stări*, numerotate într-un mod bine-definit și care reprezintă mulțimea tuturor valorilor pe care le pot lua variabilele aleatoare  $X(n)$ . Vom nota  $X(n) = X_n$ .

Presupunem cunoscute probabilitățile

$$p_i = P(\{X_0 = i\}), \quad \forall i \in S,$$

pe care le vom numi *probabilități inițiale* ale lanțului. Evident

$$\sum_{i \in S} p_i = 1.$$

**Definiția 5.1.2** Lanțul  $\{X_n\}, n \in \mathbb{N}$  se numește lanț Markov dacă are loc

$$P(\{X_{n+1} = i_{n+1}\} | \{X_n = i_n, \dots, X_0 = i_0\}) = P(\{X_{n+1} = i_{n+1}\} | \{X_n = i_n\}). \quad (5.1)$$

Egalitatea (5.1) este cunoscută sub numele de proprietatea Markov și se interpretează intuitiv prin aceea că lanțul păstrează asupra trecutului amintirea cea mai recentă, deci trecutul este în întregime rezumat în starea din ultimul moment cunoscut.

Se poate demonstra echivalența dintre condiția (5.1) și relația :

$$\forall t_0 < t_1 < \dots < t_n < t_{n+1} \in \mathbb{R},$$

$$P(\{X_{t_{n+1}} = i_{n+1}\} | \{X_{t_n} = i_n, \dots, X_{t_0} = i_0\}) = P(\{X_{t_{n+1}} = i_{n+1}\} | \{X_{t_n} = i_n\}). \quad (5.2)$$

Relația (5.2) corespunde situației în care schimbarea stărilor nu se face la momente echidistante de timp.

**Propoziția 5.1.1** Dacă  $\{X_n\}, n \in \mathbb{N}$  este un lanț Markov, are loc următoarea formulă de calcul:

$$P(\{X_n = i_n, \dots, X_0 = i_0\}) = p_{i_0} \prod_{t=1}^n P(\{X_t = i_t\} | \{X_{t-1} = i_{t-1}\}). \quad (5.3)$$

**Demonstrație.** Vom folosi probabilitatea unei intersecții.

$$\begin{aligned} P(\{X_n = i_n, \dots, X_0 = i_0\}) &= P(\{X_0 = i_0\} \cap \{X_1 = i_1\} \cap \dots \cap \{X_n = i_n\}) = \\ &= P(\{X_0 = i_0\})P(\{X_1 = i_1\} | \{X_0 = i_0\})P(\{X_2 = i_2\} | \{X_1 = i_1, X_0 = i_0\}) \dots \\ &\quad P(\{X_n = i_n\} | \{X_{n-1} = i_{n-1}, \dots, X_0 = i_0\}) = \\ &= P(\{X_0 = i_0\})P(\{X_1 = i_1\} | \{X_0 = i_0\})P(\{X_2 = i_2\} | \{X_1 = i_1\}) \dots \\ &\quad \dots P(\{X_n = i_n\} | \{X_{n-1} = i_{n-1}\}). \end{aligned}$$

Ultima relație s-a obținut folosind proprietatea Markov; scrisă condensat este de fapt relația (5.3). ■

**Definiția 5.1.3** Probabilitățile date de formula

$$p(t, i_{t-1}, i_t) = P(\{X_t = i_t\} | \{X_{t-1} = i_{t-1}\}), \quad t = 1, \dots, n,$$

se numesc probabilități de trecere.

**Definiția 5.1.4** Un lanț Markov se numește omogen dacă  $p(t, i_{t-1}, i_t)$  nu depinde explicit de  $t$ , deci are loc

$$p(t, i_{t-1}, i_t) = p(i_{t-1}, i_t)$$

În caz contrar, procesul se numește neomogen.



Vom nota aceste probabilități cu  $p_{i_{t-1}, i_t}$ . Pentru un lanț Markov omogen, relația (5.3) devine

$$P(\{X_t = i_t, \dots, X_0 = i_0\}) = p_{i_0} \prod_{t=1}^n p_{i_{t-1}, i_t}. \quad (5.4)$$

In cazul unui lanț Markov omogen, vom introduce notația

$$p_{ij} = P(\{X_{t+1} = j\} | \{X_t = i\}), \quad i, j \in S. \quad (5.5)$$

Matricea  $P = (p_{i,j})$  se numește *matrice de trecere*.

**Propoziția 5.1.2** *Matricea de trecere a unui lanț Markov omogen satisface relațiile :*

$$\begin{cases} p_{ij} \geq 0, & \forall i, j \in S \\ \sum_{j \in S} p_{ij} = 1, & \forall i \in S \end{cases} .$$

**Demonstrație.** Prima afirmație este evidentă. Pentru a doua să observăm că evenimentul sigur  $E = \bigcup_{j \in S} \{X_{t+1} = j\}$  și că

$$1 = P\left(\left(\bigcup_{j \in S} \{X_{t+1} = j\}\right) | \{X_t = i\}\right) = \sum_{j \in S} P(\{X_{t+1} = j\} | \{X_t = i\}) = \sum_{j \in S} p_{ij}.$$

■

O matrice ce satisface aceste două proprietăți se numește *stochastică*. Se poate ușor demonstra că produsul a două matrice stochastice este o matrice stochastică. Un lanț Markov este caracterizat de probabilitățile inițiale și de trecere. Am văzut că dacă se cunosc probabilitățile inițiale și de trecere se pot determina pentru orice  $n$ , probabilitățile care caracterizează un lanț stochastic, adică

$$P(\{X_t = i_t, X_{t-1} = i_{t-1}, \dots, X_0 = i_0\}), \quad t = 0, 1, \dots, n.$$

Reciproc, se poate demonstra că dacă  $p_i, i \in S$ , este un șir cu proprietățile

$$p_i \geq 0, \quad \sum_{i \in S} p_i = 1$$

și  $(p_{ij}), i, j \in S$ , este o matrice cu proprietățile :

$$p_{ij} \geq 0, \quad \sum_{j \in S} p_{ij} = 1,$$

atunci există un corp borelian și un lanț Markov omogen, cu mulțimea stărilor  $S$ , cu  $p_i$  probabilități inițiale și  $p_{ij}$  probabilități de trecere.

**Exemplul 5.1.1** Două urne au următoarea componență :

$U_a$  are 4 bile albe și 6 bile negre

$U_n$  are 5 bile albe și 5 bile negre

Alegem la întâmplare o urnă și din ea o bilă, pe care o punem înapoi în urnă; dacă bila este albă extragem următoarea bilă din  $U_a$ , iar dacă e neagră din  $U_n$  și continuăm procedeul. Este un exemplu de lanț Markov omogen, cu probabilitățile inițiale  $p_1 = p_2 = \frac{1}{2}$ , deoarece alegerea urnelor este egal probabilă; definim stările

$S_1$  se extrage o bilă din urna  $U_a$

$S_2$  se extrage o bilă din urna  $U_n$

și ilustrăm prin următoarea diagramă:

Matricea de trecere este

$$P = \begin{pmatrix} 0,4 & 0,6 \\ 0,5 & 0,5 \end{pmatrix}.$$

**Exemplul 5.1.2** Intr-o urnă sunt  $a$  bile albe și  $b$  bile negre. Se efectuează un șir infinit de extrageri astfel încât după fiecare extragere se pun înapoi două bile de aceeași culoare cu cea extrasă. Fie  $X_k$  numărul de bile la momentul  $k$ . Definim probabilitățile de trecere

$$P(\{X_{k+1} = j\}|\{X_k = i\}) = \begin{cases} 1 - \frac{i}{a+b+k}, & \text{dacă } j = i, \\ \frac{i}{a+b+k}, & \text{dacă } j = i+1, \\ 0, & \text{dacă } j \neq i, i+1. \end{cases}$$

Numărul de bile din urnă la momentul  $k+1$  depinde numai de numărul de bile din urnă aflate la momentul  $k$ , nefiind necesar întreg istoricul. Probabilitățile de trecere depind efectiv de momentul în care s-a desfășurat extracția, deci e un lanț Markov neomogen.

Dat un lanț Markov omogen, ne propunem să determinăm probabilitățile

$$P(\{X_{n+m} = j\}|\{X_m = i\}), \quad n \in \mathbb{N},$$

pe care le numim *probabilități de trecere după  $n$  pași*. Definim prin recurență  $p_{ij}^{(n)}$ , după formulele

$$\begin{cases} p_{ij}^{(1)} & = p_{ij} \\ p_{ij}^{(n+1)} & = \sum_{k \in S} p_{ik}^{(n)} p_{kj}^{(1)} \quad n \in \mathbb{N}^*. \end{cases} \quad (5.6)$$

Sub formă matriceală, relațiile (5.6) devin:

$$P^{(n)} = P \times \dots \times P = P^n.$$

**Propoziția 5.1.3** Pentru orice  $n \in \mathbb{N}$  are loc

$$p_{ij}^{(n)} = P(\{X_{n+m} = j\}|\{X_m = i\}), \quad m \in \mathbb{N}. \quad (5.7)$$

**Demonstrație.** Vom demonstra prin inducție. Observăm că pentru  $n = 1$ , găsim definiția probabilităților de trecere date de (5.5). Presupunem că (5.7) are loc pentru  $n \in \mathbb{N}$  și să determinăm

$$P(\{X_{n+1+m} = j\}|\{X_m = i\}) = \sum_{k \in S} P(\{X_{n+m+1} = j, X_{n+m} = k\}|\{X_m = i\}),$$

aceasta deoarece  $\{X_{n+m} = k\}$ ,  $k \in S$ , formează un sistem complet de evenimente și are loc formula probabilității totale (vezi Exemplul 6.6, Capitolul 1). Aplicând în continuare formula probabilității condiționate și proprietatea Markov, ultimul membru este

$$\begin{aligned} & \sum_{k \in S} P(\{X_{n+1+m} = j, X_{n+m} = k\}|\{X_m = i\}) = \\ &= \sum_{k \in S} \frac{P(\{X_{n+m+1} = j\} \cap \{X_{n+m} = k\} \cap \{X_m = i\})}{P(\{X_m = i\})} = \\ &= \sum_{k \in S} \frac{P(\{X_{n+m+1} = j\} \cap \{X_{n+m} = k\} \cap \{X_m = i\})}{P(\{X_{n+m} = k\} \cap \{X_m = i\})} \cdot \\ & \quad \frac{P(\{X_{n+m} = k\} \cap \{X_m = i\})}{P(\{X_m = i\})} = \\ &= \sum_{k \in S} P(\{X_{n+m+1} = j\}|\{X_{n+m} = k, X_m = i\})P(\{X_{n+m} = k\}|\{X_m = i\}) \\ &= \sum_{k \in S} P(\{X_{n+m+1} = j\}|\{X_{n+m} = k\})P(\{X_{n+m} = k\}|\{X_m = i\}) = \\ & \quad = \sum_{k \in S} p_{kj}^1 P(\{X_{n+m} = k\}|\{X_m = i\}). \end{aligned}$$

Folosind ipoteza inductivă ultimul membru este

$$\sum_{k \in S} p_{ik}^{(n)} p_{kj}^{(1)} = p_{ij}^{(n+1)}.$$

Deci afirmația este dovedită. ■

Dacă într-un lanț Markov omogen se cunosc probabilitățile inițiale și matricea de trecere, atunci probabilitatea ca la momentul  $n \in \mathbb{N}$  sistemul să se afle în starea  $i$ ,  $i \in S$ , probabilitate pe care o vom nota  $p_i(n)$ , este dată de formula

$$p_i(n) = \sum_{j \in S} p_j(n-1)p_{ji}. \quad (5.8)$$

Într-adevăr, la momentul  $n$

$$\begin{aligned} p_i(n) &= P(\{X_n = i\}) = P\left(\{X_n = i\} \cap \left(\bigcup_{j \in S} \{X_{n-1} = j\}\right)\right) = \\ &= P\left(\bigcup_{j \in S} (\{X_n = i\} \cap \{X_{n-1} = j\})\right) = \sum_{j \in S} P(\{X_{n-1} = j\})P(\{X_n = i\}|\{X_{n-1} = j\}) \\ &= \sum_{j \in S} p_j(n-1)p_{ji}. \end{aligned}$$

**Exemplul 5.1.3** Un calculator poate fi privit ca un sistem  $S$  care se poate afla într-una din următoarele stări:

$S_1$  calculatorul funcționează normal;

$S_2$  calculatorul prezintă unele dereglări, dar poate executa programe;

$S_3$  calculatorul prezintă unele dereglări și rezolvă un număr limitat de probleme;

$S_4$  calculatorul nu funcționează.

La momentul inițial calculatorul funcționează, deci se află în starea  $S_1$  cu probabilitatea 1 și se poate presupune că el trece în celelalte stări cu probabilitățile indicate de următoarea schemă

Deci matricea de trecere este

$$P = \begin{pmatrix} 0,3 & 0,4 & 0,1 & 0,2 \\ 0 & 0,2 & 0,5 & 0,3 \\ 0 & 0 & 0,4 & 0,6 \\ 0 & 0 & 0 & 1 \end{pmatrix}.$$

Să determinăm probabilitățile stărilor la momentul  $n = 2$ . Deoarece la momentul inițial calculatorul funcționează, probabilitățile inițiale sunt

$$p_1 = 1, \quad p_2 = p_3 = p_4 = 0.$$

Folosind (5.8) găsim

$$p_1(1) = 0,3; \quad p_2(1) = 0,4; \quad p_3(1) = 0,1; \quad p_4(1) = 0,2$$

și

$$p_1(2) = 0,09; \quad p_2(2) = 0,2; \quad p_3(2) = 0,27; \quad p_4(2) = 0,44.$$

**Propoziția 5.1.4** Pentru orice  $m, n \in \mathbb{N}$  are loc

$$p_{ij}^{(m+n)} = \sum_{k \in S} p_{ik}^{(n)} p_{kj}^{(m)}. \quad (5.9)$$

**Demonstrație.** Demonstrăm prin inducție după  $m$ . Pentru  $m = 1$  regăsim (5.7). Înlocuind  $m$  cu  $m + 1$ , să evaluăm

$$\begin{aligned} p_{ij}^{(n+m+1)} &= \sum_{k \in S} p_{ik}^{(n+m)} p_{kj}^{(1)} = \sum_{k \in S} \left( \sum_{l \in S} p_{il}^{(n)} p_{lk}^{(m)} \right) p_{kj}^{(1)} = \\ &= \sum_{l \in S} p_{il}^{(n)} \sum_{k \in S} p_{lk}^{(m)} p_{kj}^{(1)} = \sum_{l \in S} p_{il}^{(n)} p_{lj}^{(m+1)}. \end{aligned}$$

Relația (5.9) se numește relația **Chapman-Kolmogorov**. Matriceal ea se scrie

$$P^{(m+n)} = P^{(m)} P^{(n)}.$$

■

Cu ajutorul matricei de trecere putem exprima probabilitatea apariției unor stări la momente nesuccesive.

**Exemplul 5.1.4** Dacă avem un lanț Markov omogen cu matricea de trecere  $P$ , să determinăm

$$P(\{X_{10} = l, X_8 = k, X_5 = j\} | \{X_1 = i\}).$$

Folosind formula probabilității unei intersecții și proprietatea Markov, avem

$$\begin{aligned} &\frac{P(\{X_{10} = l, X_8 = k, X_5 = j, X_1 = i\})}{P(\{X_1 = i\})} = \\ &= \frac{P(\{X_1 = i\})P(\{X_5 = j\} | \{X_1 = i\})P(\{X_8 = k\} | \{X_5 = j\})P(\{X_{10} = l\} | \{X_8 = k\})}{P(\{X_1 = i\})} = \\ &= p_{ij}^{(4)} p_{jk}^{(3)} p_{kl}^{(2)}. \end{aligned}$$

### Exemple de lanțuri Markov omogene.

**Exemplul 5.1.5** Mers la întâmplare pe segmentul  $[0, l]$  [11].

a. cu bariere absorbante; o particulă se deplasează pe o axă orientată ocupând doar punctele de abscisă  $0, 1, \dots, l$ . La fiecare moment particula rămâne imobilă dacă se află într-unul din punctele  $0$  sau  $l$  și face un pas la dreapta cu probabilitatea  $p$  sau la stânga cu probabilitatea  $q$ . Matricea de trecere este

$$P = \begin{pmatrix} 1 & 0 & 0 & \dots & 0 & 0 & 0 \\ q & 0 & p & \dots & 0 & 0 & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \dots & q & 0 & p \\ 0 & 0 & 0 & \dots & 0 & 0 & 1 \end{pmatrix}.$$

b. cu bariere reflectante; dacă particula ajunge în  $0$  sau  $l$ , este "reflectată" în  $1$ , respectiv  $l - 1$ . Matricea de trecere este

$$P = \begin{pmatrix} 0 & 1 & 0 & \dots & 0 & 0 & 0 \\ q & 0 & p & \dots & 0 & 0 & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \dots & q & 0 & p \\ 0 & 0 & 0 & \dots & 0 & 1 & 0 \end{pmatrix}.$$

**Exemplul 5.1.6** Un model din teoria așteptării [11].

O "stație" de deservire poate servi clienții la momentele  $0, 1, 2, \dots$ . Numărul de clienți care sosesc în intervalul  $(n, n + 1)$  este o variabilă aleatoare notată  $X_n$ . Presupunem că  $X_n$  sunt variabile aleatoare independente și identic repartizate

$$X_n : \binom{k}{p_k}_{k=0}^{+\infty}, \quad \sum_{k=0}^{\infty} p_k = 1$$

și că există un loc de așteptare pentru cel mult  $m$  clienți, număr în care se include și clientul care este servit. Clienții care ajung în stație și găsesc  $m$  clienți, pleacă fără a fi serviți.

Fie  $Y_n$  numărul de clienți prezenți la momentul  $n$ , în care se include și clientul care este servit.  $Y_n$  este un lanț Markov cu stările  $0, 1, \dots, m$ .  $Y_{n+1}$  este egal cu numărul clienților la momentul  $n$ , mai puțin cel servit la momentul  $n$  (dacă există) plus numărul clienților care sosesc în intervalul  $(n, n + 1)$ , dacă rezultatul nu depășește  $m$  și este egal cu  $m$  în caz contrar. Deci

$$Y_{n+1} = \begin{cases} Y_n - 1 + X_n, & \text{dacă } 1 \leq Y_n \leq m, \quad 0 \leq X_n \leq m + 1 - Y_n, \\ X_n, & \text{dacă } Y_n = 0, \quad 0 \leq X_n \leq m - 1, \\ m, & \text{în rest.} \end{cases}$$

Deoarece  $Y_{n+1}$  depinde doar de  $Y_n$ , iar variabilele aleatoare  $X_n$  și  $Y_n$  sunt independente, rezultă că  $Y_n$  este un lanț Markov. Să determinăm matricea de trecere. Notăm cu  $\overline{p_m} = p_m + p_{m-1} + \dots$

$$\begin{aligned}
 p_{0j} &= P(\{Y_{n+1} = j\} | \{Y_n = 0\}) \\
 &= \begin{cases} P(\{X_n = j\}) = p_j, & \text{dacă } 0 \leq j \leq m-1, \\ P(\{X_n \geq m\}) = \overline{p_m}, & \text{dacă } j = m; \end{cases} \\
 p_{ij} &= P(\{Y_{n+1} = j\} | \{Y_n = i\}) = \\
 &= \begin{cases} P(\{X_n = j+1-i\}) = p_{j-i+1}, & \text{dacă } i-1 \leq j \leq m-1, \\ P(\{X_n \geq m+1-i\}) = \overline{p_{m+1-i}}, & \text{dacă } j = m, \\ 0, & \text{în rest.} \end{cases}
 \end{aligned}$$

Rezultă matricea

$$\begin{pmatrix}
 p_0 & p_1 & p_2 & \dots & p_{m-1} & \overline{p_m} \\
 p_0 & p_1 & p_2 & \dots & p_{m-1} & \overline{p_m} \\
 0 & p_0 & p_1 & \dots & p_{m-2} & \overline{p_{m-1}} \\
 \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\
 0 & 0 & 0 & \dots & p_1 & \overline{p_2} \\
 0 & 0 & 0 & \dots & p_0 & \overline{p_1}
 \end{pmatrix}.$$

**Exemplul 5.1.7** Un model din teoria stocurilor. [11]

O marfă este stocată pentru a putea satisface cererile întâmplătoare. Completarea eventuală a stocului se face la momentele  $0, 1, 2, \dots$ , iar cererea în intervalul  $(n, n+1)$  este o variabilă aleatoare  $X_n$ , cu repartiția

$$X_n : \binom{k}{p_k}_{k=0}^{\infty}, \quad \sum_{k=0}^{\infty} p_k = 1.$$

Presupunem că  $X_n$  sunt independente. Dacă la un moment oarecare  $n \geq 0$  cantitatea de marfă stocată nu este mai mare decât  $m$  unități, atunci se procură instantaneu o cantitate de marfă care ridică stocul la  $M$  unități,  $M \in \mathbb{N}$ . Dacă însă cantitatea de marfă depășește  $m$  unități, atunci nu se întreprinde nimic. Fie  $Y_n$  stocul imediat înainte de reîmprospătarea eventuală de la momentul  $n$ . Observăm că

$$Y_{n+1} = \begin{cases} \max\{Y_n - X_n, 0\}, & \text{dacă } m < Y_n \leq M, \\ \max\{M - X_n, 0\}, & \text{dacă } Y_n \leq m. \end{cases}$$

Se arată că  $Y_n$  este un lanț Markov cu matricea de trecere

$$\begin{pmatrix}
 \overline{p_M} & p_{M-1} & \dots & p_{M-m} & p_{M-m-1} & p_{M-m-2} & \dots & p_0 \\
 \overline{p_M} & p_{M-1} & \dots & p_{M-m} & p_{M-m-1} & p_{M-m-2} & \dots & p_0 \\
 \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\
 \overline{p_M} & p_{M-1} & \dots & p_{M-m} & p_{M-m-1} & p_{M-m-2} & \dots & p_0 \\
 \overline{p_{m+1}} & p_m & \dots & p_1 & p_0 & 0 & \dots & 0 \\
 \overline{p_{m+2}} & p_{m+1} & \dots & p_2 & p_1 & p_0 & \dots & 0 \\
 \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\
 \overline{p_M} & p_{M-1} & \dots & p_{M-m} & p_{M-m-1} & p_{M-m-2} & \dots & p_0
 \end{pmatrix}.$$

(Matricea are primele  $m$  linii identice). S-a folosit notația  $\bar{p}_l = p_l + p_{l+1} + \dots$ , dacă  $m < l \leq M$ .

Dat un lanț Markov omogen ne interesează comportarea la limită a probabilităților de trecere peste  $n$  pași  $p_{ij}^{(n)}$ .

**Definiția 5.1.5** Dacă pentru orice  $i, j \in S$  șirul  $p_{ij}^{(n)}$   $n \in \mathbb{N}$  este convergent independent de  $i$ , lanțul  $X_n$  se numește ergodic.

**Teorema 5.1.1** (Teoremă de ergodicitate). Fie  $(X_n)$ ,  $n \in \mathbb{N}$ , un lanț Markov cu matricea de trecere  $P = (p_{ij})$ ,  $i, j \in S$ . Următoarele afirmații sunt echivalente:

1. există  $s \in \mathbb{N}^*$  și o stare  $j_0 \in S$  astfel încât  $p_{ij_0}^{(s)} > 0 \quad \forall i \in S$ ;
2. există  $\lim_{n \rightarrow \infty} p_{ij}^{(n)} = p_j^\infty$ ,  $j \in S$ ,  $\forall i \in S$ .

**Demonstrație.**

2.  $\implies$  1. Afirmația este imediată; observăm că

$$\sum_{j \in S} p_j^\infty = \lim_{n \rightarrow \infty} \sum_{j \in S} p_{ij}^{(n)} = 1.$$

Există deci  $j_0 \in S$  astfel încât  $p_{j_0}^\infty > 0$ , deci de la un rang  $s$  termenii șirului

$$p_{ij_0}^{(s)} > 0, \quad \forall i \in S.$$

1.  $\implies$  2. Pentru orice  $j \in S$  să considerăm șirurile

$$\bar{p}_j^{(n)} = \max_{i \in S} p_{ij}^{(n)}, \quad \underline{p}_j^{(n)} = \min_{i \in S} p_{ij}^{(n)}. \quad (5.10)$$

Arătăm că  $\bar{p}_j^{(n)}$  este necrescător; într-adevăr folosind (5.6)

$$p_{ij}^{(n+1)} = \sum_{l \in S} p_{il}^{(1)} p_{lj}^{(n)} \leq \bar{p}_j^{(n)} \sum_{l \in S} p_{il}^{(1)} = \bar{p}_j^{(n)}, \quad \forall i \in S,$$

deci

$$\bar{p}_j^{(n+1)} \leq \bar{p}_j^{(n)}.$$

Analog rezultă că  $\underline{p}_j^{(n)}$  este nedescrescător, deci

$$\underline{p}_j^{(n+1)} \geq \underline{p}_j^{(n)}.$$

Deoarece cele două șiruri sunt și mărginite ( $1 \geq \bar{p}_j^{(n)} \geq \underline{p}_j^{(n)} \geq 0$ ) ele sunt convergente; să notăm

$$\bar{p}_j^\infty = \lim_{n \rightarrow \infty} \bar{p}_j^{(n)}, \quad \underline{p}_j^\infty = \lim_{n \rightarrow \infty} \underline{p}_j^{(n)}.$$



Rămâne să mai arătăm că  $\underline{p}_j^\infty = \bar{p}_j^\infty$ . Pentru aceasta să demonstrăm că

$$\lim_{n \rightarrow \infty} \max_{i, l \in S} |p_{ij}^{(n)} - p_{lj}^{(n)}| = 0.$$

Folosind relația (5.6), pentru  $n > s$ , cu  $s$  dat din ipoteza 1

$$p_{ij}^{(n)} = \sum_{r \in S} p_{ir}^{(s)} p_{rj}^{(n-s)},$$

rezultă

$$p_{ij}^{(n)} - p_{lj}^{(n)} = \sum_{r \in S} (p_{ir}^{(s)} - p_{lr}^{(s)}) p_{rj}^{(n-s)} = \sum_{r \in S} u_{il}(r) p_{rj}^{(n-s)},$$

unde am introdus notația  $u_{il} = p_{ir}^{(s)} - p_{lr}^{(s)}$ . Să notăm cu  $S^+$  mulțimea acelor stări din  $S$  pentru care  $u_{il}(r) > 0$  și cu  $S^-$  mulțimea acelor stări din  $S$  pentru care  $u_{il}(r) < 0$ . Avem evident  $S = S^+ \cup S^-$ . Deoarece

$$\sum_{r \in S} p_{ir}^{(s)} = \sum_{r \in S} p_{lr}^{(s)} = 1,$$

rezultă că

$$\sum_{r \in S} u_{il}(r) = \sum_{r \in S^+} u_{il}(r) + \sum_{r \in S^-} u_{il}(r) = 0,$$

deci

$$\sum_{r \in S^+} u_{il} = \sum_{r \in S^-} |u_{il}(r)|.$$

Să demonstrăm că are loc

$$\sum_{r \in S^+} u_{il}(r) < 1. \tag{5.11}$$

Presupunem că starea  $j_0$  din ipoteza 1 aparține lui  $S^+$ ; atunci

$$\begin{aligned} \sum_{r \in S^+} u_{il}(r) &= \sum_{r \in S^+} (p_{ir}^{(s)} - p_{lr}^{(s)}) = \sum_{r \in S^+} p_{ir}^{(s)} - \sum_{r \in S^+} p_{lr}^{(s)} \leq \\ &\leq 1 - \sum_{r \in S^+} p_{lr}^{(s)} \leq 1 - p_{lj_0}^{(s)} < 1 \end{aligned}$$

deoarece  $0 < p_{lj_0}^{(s)} \leq \sum_{r \in S^+} p_{lr}^{(s)}$ . Aceeași evaluare se obține după un raționament analog în cazul în care  $j_0 \in S^-$ . Deoarece (5.11) are loc pentru orice  $i, l \in S$ , rezultă

$$u = \sup_{i, l \in S} \sum_{r \in S^+} u_{il}(r) < 1.$$

Revenim la suma ce trebuia majorată și folosim (5.10)

$$p_{ij}^{(n)} - p_{lj}^{(n)} = \sum_{r \in S^+} u_{il}(r) p_{rj}^{(n-s)} - \sum_{r \in S^-} |u_{il}(r)| p_{rj}^{(n-s)} \leq$$

$$\leq \sum_{r \in S^+} u_{il}(r) \bar{p}_j^{(n-s)} - \sum_{r \in S^-} u_{il}(r) \underline{p}_j^{(n-s)} \leq u(\bar{p}_j^{(n-s)} - \underline{p}_j^{(n-s)}).$$

Cum inegalitatea are loc pentru orice  $i, l \in S$ , rezultă că

$$\bar{p}_j^{(n)} - \underline{p}_j^{(n)} \leq u(\bar{p}_j^{(n-s)} - \underline{p}_j^{(n-s)}).$$

Aplicând această inegalitate de  $[\frac{n}{s}]$  ori, unde  $[\ ]$ , semnifică partea întreagă a numărului  $\frac{n}{s}$ , deducem că

$$\sup_{i, l \in S} |p_{ij}^{(n)} - p_{lj}^{(n)}| = |\bar{p}_j - \underline{p}_j| \leq u^{[\frac{n}{s}]}$$

iar

$$\lim_{n \rightarrow \infty} u^{[\frac{n}{s}]} = 0.$$

De aici rezultă că

$$\bar{p}_j = \underline{p}_j = \lim_{n \rightarrow \infty} p_{ij}^{(n)}$$

și această limită o notăm  $p_j^\infty$ . ■

Importanța acestei teoreme este însemnată, deoarece pe baza ei putem analiza stabilitatea în timp a unor procese aleatoare.

**Exemplul 5.1.8** Considerăm următorul proces Markov: mulțimea stărilor are 3 elemente și dacă la un moment dat este luată o anumită stare, la momentul următor se trece în oricare din celelalte două cu aceeași probabilitate. Matricea de trecere este evident

$$P = \begin{pmatrix} 0 & \frac{1}{2} & \frac{1}{2} \\ \frac{1}{2} & 0 & \frac{1}{2} \\ \frac{1}{2} & \frac{1}{2} & 0 \end{pmatrix}.$$

Observăm că

$$P^2 = \begin{pmatrix} \frac{1}{2} & \frac{1}{4} & \frac{1}{4} \\ \frac{1}{4} & \frac{1}{2} & \frac{1}{4} \\ \frac{1}{4} & \frac{1}{4} & \frac{1}{2} \end{pmatrix}$$

satisface condiția 1 din teorema precedentă, pe care o vom numi condiție de ergodicitate. Fiind matrice simetrică ea admite valorile proprii reale  $\lambda_1 = 1$ ,  $\lambda_{2,3} = -\frac{1}{2}$  și forma diagonală

$$D = \begin{pmatrix} 1 & 0 & 0 \\ 0 & -\frac{1}{2} & 0 \\ 0 & 0 & -\frac{1}{2} \end{pmatrix}.$$

Fie  $S$  matricea ortogonală de schimbare de bază, care are forma

$$S = \begin{pmatrix} \frac{1}{\sqrt{3}} & \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{6}} \\ \frac{1}{\sqrt{3}} & -\frac{1}{\sqrt{2}} & \frac{1}{\sqrt{6}} \\ \frac{1}{\sqrt{3}} & 0 & \frac{2}{\sqrt{6}} \end{pmatrix}.$$

Ridicând la puterea  $n$  matricea  $P = SDS^t$ , rezultă

$$\lim_{n \rightarrow \infty} P^n = \begin{pmatrix} \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \\ \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \\ \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \end{pmatrix}.$$

Mai sus s-a folosit faptul că  $D^n$  are pe diagonală puterea a  $n$ -a a elementelor de pe diagonală lui  $D$ . Deci după un număr foarte mare de pași se poate presupune că fiecare stare este luată cu aceleași șanse.

**Exemplul 5.1.9** Fie un lanț Markov cu două stări și diagrama asociată în Figura 5.3.

Obsevăm că matricea de tranziție este de forma

$$\begin{pmatrix} 1 - \alpha & \alpha \\ \beta & 1 - \beta \end{pmatrix}.$$

Să studiem comportarea la limită a matricei de tranziție. Putem scrie

$$P = \frac{1}{\alpha + \beta} \begin{pmatrix} \beta & \alpha \\ \beta & \alpha \end{pmatrix} + \frac{1 - \alpha - \beta}{\alpha + \beta} \begin{pmatrix} \alpha & -\alpha \\ -\beta & \beta \end{pmatrix}.$$

Se constată ușor că

$$P^n = \frac{1}{\alpha + \beta} \begin{pmatrix} \beta & \alpha \\ \beta & \alpha \end{pmatrix} + \frac{(1 - \alpha - \beta)^n}{\alpha + \beta} \begin{pmatrix} \alpha & -\alpha \\ -\beta & \beta \end{pmatrix}.$$

Matricea de tranziție după  $n$  pași tinde pentru  $n \rightarrow +\infty$  la

$$\frac{1}{\alpha + \beta} \begin{pmatrix} \beta & \alpha \\ \beta & \alpha \end{pmatrix}.$$

Dacă cele două stări sunt luate inițial cu probabilitățile  $p_0, 1 - p_0$ , se constată că pentru  $n \rightarrow +\infty$  probabilitățile de stare sunt  $\frac{\beta}{\alpha + \beta}, \frac{\alpha}{\alpha + \beta}$ . Deci după un număr foarte mare de pași probabilitățile nu depind de starea inițială.

Dacă analizăm mersul la întâmplare cu bariere absorbante, pentru  $l = 2$ , găsim

$$P = \begin{pmatrix} 1 & 0 & 0 \\ q & 0 & p \\ 0 & 0 & 1 \end{pmatrix}$$

iar  $P^n = P, \forall n \in \mathbb{N}$ . Observăm că nu este în deplină condiția de ergodicitate; se poate totuși aprecia că la un număr foarte mare de pași particula rămâne imobilă, fiind absorbită de bariere.

## 5.2 Procese Markov continue. Procese Poisson

### Procese Poisson.

În unele situații practice, făcând observații asupra unui eveniment aleator ne poate interesa de câte ori s-a produs acesta într-un interval de timp ; de exemplu numărul de impulsuri care apar la o centrală telefonică într-un interval de timp, numărul de "clienți" care solicită un produs într-o "stație de deservire", numărul de vehicule care traversează un pod, etc. Pentru orice  $t \in \mathbb{R}$ , notăm cu  $X(t)$  numărul de produceri ale evenimentului în intervalul  $(0, t)$ ; evident variabila aleatoare  $X(t)$  ia valori în  $\mathbb{N}$ . Facem următoarele presupuneri:

1. observațiile încep la momentul inițial  $t = 0$ , deci  $X(0) = 0$ ;
2. pentru orice momente de timp  $0 < t_1 < t_2 < t_3 < t_4$ , variabilele aleatoare  $X(t_2) - X(t_1)$  și  $X(t_4) - X(t_3)$  sunt independente (proces cu *creșteri independente*);
3. repartiția variabilei aleatoare  $X(t + s) - X(t)$ ,  $t > 0$ ,  $s > 0$ , depinde doar de  $s$ , lungimea intervalului și nu de  $t$ ;
4. probabilitatea ca un singur eveniment să se producă în intervalul  $(t, t + \Delta t)$ , pentru  $\Delta t$  suficient de mic este aproximativ proporțională cu lungimea intervalului, deci de forma  $\lambda \Delta t + o(\Delta t)$ . Probabilitatea ca mai mult de un eveniment să se producă în intervalul  $(t, t + \Delta t)$  este  $o(\Delta t)$ . (Prin  $o(\Delta t)$  s-a notat o cantitate ce depinde doar de  $\Delta t$  ce satisface  $\lim_{\Delta t \rightarrow 0} \frac{o(\Delta t)}{\Delta t} = 0$ .) Notăm  $p_k(t) = P(\{X(t) = k\})$ . Fie  $\Delta t$  suficient de mic; la momentul  $t + \Delta t$ ,  $X(t)$  ia valoarea  $k$  în următoarele două moduri:

- a.  $X(t) = k$  și nici un eveniment nu se produce în intervalul  $(t, t + \Delta t)$ ;
- b.  $X(t) = k - 1$  și un eveniment se produce în  $(t, t + \Delta t)$ .

Deoarece din ipoteza 2, variabilele aleatoare  $X(t + \Delta t) - X(t)$  și  $X(t)$  sunt independente, probabilitatea evenimentului dat de a este  $p_k(t)(1 - \lambda \Delta t)$ , iar cea a evenimentului dat de b este  $p_{k-1}(t)\lambda \Delta t$  și cum evenimentele de la a și b sunt independente

$$p_k(t + \Delta t) = p_k(t)(1 - \lambda \Delta t) + p_{k-1}(t)\lambda \Delta t.$$

Relația se scrie sub forma echivalentă

$$\frac{p_k(t + \Delta t) - p_k(t)}{\Delta t} = -\lambda p_k(t) + \lambda p_{k-1}(t) \quad k = 1, 2, 3, \dots$$

Când  $\Delta t \rightarrow 0$ , găsim ecuația diferențială

$$p'_k(t) = -\lambda p_k(t) + \lambda p_{k-1}(t). \quad (5.12)$$

Pentru  $k = 0$ ,  $p_{-1}(t) = 0$  și ecuația (5.12) devine

$$p'_0(t) = -\lambda p_0(t)$$

cu soluția evidentă  $p_0(t) = Ae^{-\lambda t}$ . Din ipoteza 1 avem condiția inițială  $X(0) = 0$ , care determină în mod unic soluția

$$p_0(t) = e^{-\lambda t}.$$

Pentru  $k = 1$ , ecuația (5.12) devine

$$p_1'(t) = -\lambda p_1(t) + \lambda e^{-\lambda t},$$

care este o ecuație liniară cu soluția

$$p_1(t) = \lambda t e^{-\lambda t}.$$

Procedând recursiv în acest mod, găsim

$$p_k(t) = \frac{(\lambda t)^k}{k!} e^{-\lambda t}, \quad k = 0, 1, 2, \dots$$

Constatăm că pentru fiecare  $t \in \mathbb{R}$ ,  $X(t)$  este o variabilă aleatoare repartizată Poisson cu parametru  $\lambda t$ .

**Matricea de tranziție cu un pas.**

$$p_{ij}(t) = P(\{j - i \text{ evenimente au loc în } t \text{ secunde}\}) = \frac{(\lambda t)^{j-i}}{(j-i)!} e^{-\lambda t}, \quad j \geq i.$$

Matricea  $P$  este

$$P(t) = \begin{pmatrix} e^{-\lambda t} & \lambda t e^{-\lambda t} & \frac{(\lambda t)^2 e^{-\lambda t}}{2!} & \dots \\ 0 & e^{-\lambda t} & \lambda t e^{-\lambda t} & \dots \\ \dots & \dots & \dots & \dots \end{pmatrix}.$$

**Intervalul aleator dintre două evenimente succesive într-un proces Poisson.**

Dacă în cadrul unui proces Poisson un eveniment se produce la momentul  $t$ , iar următorul la momentul  $t + \tau$ ,  $\tau$  este o variabilă aleatoare. Să-i determinăm densitatea de probabilitate. Pentru aceasta determinăm mai întâi funcția de repartiție. Avem

$$P(\{\tau \geq x\}) = e^{-\lambda x}.$$

$\{\tau \geq x\}$  exprimă faptul că nici un eveniment nu are loc în intervalul  $(t, t+x)$ . Deci funcția de repartiție este  $1 - \lambda e^{-\lambda x}$ ,  $x \geq 0$ , iar prin derivare găsim  $f(x) = \lambda e^{-\lambda x}$ ,  $x \geq 0$ , care este repartiția exponențială. Această densitate caracterizează intervalul aleator de timp dintre două produceri succesive de evenimente ale unui proces Poisson. Să observăm că

$$\begin{aligned} P(\{\tau \geq t + t_0\} | \{\tau \geq t_0\}) &= \frac{P(\{\tau \geq t_0 + t\})}{P(\{\tau \geq t_0\})} = \\ &= \frac{\lambda \int_{t_0+t}^{\infty} e^{-\lambda s} ds}{\lambda \int_{t_0}^{\infty} e^{-\lambda s} ds} = e^{-\lambda t} = P(\{\tau \geq t\}), \end{aligned}$$

ceea ce semnifică faptul că procesul Poisson este un proces Markov. Observăm că probabilitatea ca în intervalul  $(0, t)$  să se producă exact un eveniment este  $\lambda t e^{-\lambda t}$ , deoarece este urmată o lege Poisson cu parametrul  $\lambda t$ .

**Exemplul 5.2.1** Impulsurile care se recepționează la o stație se primesc cu rata de 15 pe minut. Să determinăm probabilitatea ca într-un minut să se recepționeze 5 impulsuri astfel: 3 impulsuri să ajungă în primele 10 secunde și 2 impulsuri în ultimile 15 secunde. Obținem  $\lambda = \frac{15}{60} = \frac{1}{4}$  și

$$\begin{aligned} P(\{X(10) = 3, X(60) - X(45) = 2\}) &= P(\{X(10) = 3\})P(\{X(60) - X(45) = 2\}) = \\ &= P(\{X(10) = 3\})P(\{X(60 - 45) = 2\}) = \frac{10^3}{3!} e^{-\frac{10}{4}} \frac{15^2}{2!} e^{-\frac{15}{4}}. \end{aligned}$$

### Momentul de producere al unui eveniment într-un proces Poisson.

Ne interesează, pe de altă parte, următorul eveniment: știind că în intervalul  $(0, t)$  s-a produs exact un eveniment, ce densitate de probabilitate are momentul de producere, pe care îl notăm cu  $s$ ,  $0 \leq s \leq t$ .  $s$  este o variabilă aleatoare continuă a cărei densitate de probabilitate o notăm cu  $g$ . Să determinăm funcția de repartiție.

$$\begin{aligned} F(s) &= P(\{X(s) = 1\} | \{X(t) = 1\}) = \frac{P(\{X(s) = 1, X(t) = 1\})}{P(\{X(t) = 1\})} = \\ \frac{P(\{X(s) = 1, X(t) - X(s) = 0\})}{P(\{X(t) = 1\})} &= \frac{P(\{X(s) = 1, X(t-s) = 0\})}{P\{X(t) = 1\}} = \frac{e^{-\lambda s} \lambda s e^{-\lambda(t-s)}}{e^{-\lambda t} (\lambda t)} = \frac{s}{t}. \end{aligned}$$

Densitatea de probabilitate este atunci

$$g(s) = \frac{1}{t}, \quad 0 \leq s \leq t,$$

care este densitatea de probabilitate a repartiției uniforme; deci producerea în intervalul  $(0, t)$  a unui singur eveniment se face după legea uniformă.

**Exemplul 5.2.2** Doi clienți ajung la o stație într-o perioadă de două minute. Să determinăm probabilitatea ca ambii să ajungă în primul minut. Timpii fiind repartizați uniform și independent, rezultă că probabilitatea este  $\frac{1}{4}$ .

### Timpul la care s-a produs evenimentul $n$ într-un proces Poisson.

Apariția unui "client" la o "stație de deservire" este supus legii Poisson cu parametrul  $\lambda$ . Dacă stația se închide după apariția clientului  $n$  să determinăm densitatea de probabilitate pentru timpul  $T$  în care stația rămâne deschisă. Fie  $T_i$  timpul dintre sosirea clientului  $i - 1$  și a clientului  $i$  ( $T_1$  este timpul de la deschidere până la sosirea primului client). Avem deci

$$T = T_1 + \dots + T_n,$$

unde  $\{T < t\}$  semnifică faptul că stația s-a închis până la momentul  $t$ , deci au apărut cel puțin  $n$  clienți, iar probabilitatea este dată de legea Poisson cu parametrul  $\lambda t$

$$P(\{T < t\}) = \sum_{k=n}^{\infty} \frac{(\lambda t)^k}{k!} e^{-\lambda t}.$$

Prin derivare găsim

$$f_T(t) = \sum_{k=n}^{\infty} \left( \lambda k \frac{(\lambda t)^{k-1}}{k!} - \frac{\lambda(\lambda t)^k}{k!} \right) e^{-\lambda t} = \frac{\lambda(\lambda t)^{n-1}}{(n-1)!} e^{-\lambda t}$$

care este o densitate de probabilitate pentru variabila numită **repartiția Erlang**.

**Exemplul 5.2.3** Numărul de semnale emise de un radar este un proces Poisson cu parametrul  $\lambda$ . Dacă  $n$  semnale au fost observate în intervalul  $(0, t)$  să determinăm probabilitatea evenimentului  $\{k$  particule au fost emise în  $(0, \tau)\}$  cu  $\tau < t$ .

$$\begin{aligned} & P(\{k \text{ semnale emise în } (0, \tau) \mid n \text{ semnale emise în } (0, t)\}) = \\ &= \frac{P(\{k \text{ semnale emise în } (0, \tau) \text{ și } n - k \text{ semnale emise în } (\tau, t)\})}{P(\{n \text{ semnale emise în } (0, t)\})} = \\ &= \frac{\frac{e^{-\lambda\tau}(\lambda\tau)^k}{k!} \frac{e^{-\lambda(t-\tau)}(\lambda(t-\tau))^{n-k}}{(n-k)!}}{e^{-\lambda t} \frac{(\lambda t)^n}{n!}} = C_n^k \left(\frac{\tau}{t}\right)^k \left(1 - \frac{\tau}{t}\right)^{n-k}. \end{aligned}$$

**Exemplul 5.2.4** Semnalul telegrafic aleator.

Fie  $T(t)$  un proces care ia stările  $\pm 1$  cu aceeași probabilitate la momentul inițial.  $T(t)$  își schimbă polaritatea odată cu sosirea unui semnal dintr-un proces Poisson cu parametrul  $\alpha$ . Reprezentăm o traiectorie în Figura 5.4.

Să calculăm probabilitățile evenimentelor  $\{T(t) = \pm 1\}$ .

Ne ocupăm pentru început de evenimentul  $\{T(t) = 1\}$ . Folosind formula probabilității totale avem

$$\begin{aligned} P(\{T(t) = 1\}) &= P(\{T(t) = 1\} \mid \{T(0) = 1\})P(\{T(0) = 1\}) + \\ &+ P(\{T(t) = 1\} \mid \{T(0) = -1\})P(\{T(0) = -1\}). \end{aligned}$$

Calculăm probabilitățile condiționate. Notăm cu  $A = \{$  în intervalul  $(0, t)$  se produce un număr par de schimbări  $\}$  și cu  $B = \{$  în intervalul  $(0, t)$  se produce un număr impar de schimbări  $\}$

$$\begin{aligned} P(\{T(t) = 1\} \mid \{T(0) = 1\}) &= P(A) = \sum_{j=0}^{+\infty} \frac{(\lambda t)^{2j}}{(2j)!} e^{-\lambda t} = \frac{e^{-\lambda t}}{2} (e^{\lambda t} + e^{-\lambda t}) = \\ &= \frac{1}{2} (1 + e^{-2\lambda t}). \end{aligned}$$

$$P(\{T(t) = 1\} \mid \{T(0) = -1\}) = P(B) = \frac{1}{2} (1 - e^{-2\lambda t}).$$

Deoarece  $P(\{T(0) = 1\}) = P(\{T(0) = -1\}) = \frac{1}{2}$ , rezultă după înlocuiri că evenimentele  $\{T(t) = \pm 1\}$  au probabilitatea  $\frac{1}{2}$ .

### Procese de naștere-moarte.

Vom modela în continuare următoarea situație practică ce apare în teoria așteptării. Considerăm un sistem format dintr-un "fir de așteptare" formată din  $n$  "clienți" și o persoană care servește. Spunem că sistemul se află în starea  $S_n$  dacă sunt  $n$  "clienți" la coadă, inclusiv cel servit (dacă există). Din starea  $S_n$  sunt posibile doar două tranziții:

- la starea  $S_{n-1}$  dacă un client a fost servit și părăsește coada;
- la starea  $S_{n+1}$  dacă un client este încă servit în timp ce un nou client se așează la coadă.

Considerăm un proces care descrie comportarea cozii în timp. La momentul  $t$ , dacă sistemul precedent se află în starea  $S_n$ , vom nota  $X(t) = n$ . Se obține astfel un proces Markov. Facem următoarele ipoteze:

1. Dacă sistemul este în starea  $S_n$ , poate realiza tranziții la  $S_{n-1}$  sau la  $S_{n+1}$ ,  $n \geq 1$  (de la  $S_0$  este posibilă doar  $S_1$ ).
2. Probabilitatea unei tranziții  $S_n \rightarrow S_{n+1}$  într-un interval scurt  $\Delta t$  este  $\alpha_n \Delta t$  parametrul  $\alpha_n$  se numește parametru de "naștere" și facem ipoteza că depinde de starea  $S_n$ .
3. Probabilitatea unei tranziții  $S_n \rightarrow S_{n-1}$  într-un interval de lungime  $\Delta t$  este  $\beta_n \Delta t$  parametru  $\beta_n$  se numește parametru de "moarte".

Probabilitatea ca în intervalul  $(t, t + \Delta t)$  să aibă loc mai mult de o tranziție este 0. Sistemul se află în starea  $S_n$  la momentul  $t + \Delta t$  în următoarele situații:

- a. La momentul  $t$  se află în starea  $S_n$  și nici o tranziție nu are loc în intervalul  $(t, t + \Delta t)$  cu probabilitatea  $(1 - \alpha_n \Delta t)(1 - \beta_n \Delta t)$ , care poate fi aproximată cu  $1 - \alpha_n \Delta t - \beta_n \Delta t$ .
- b. Fiind în starea  $S_{n-1}$  la momentul  $t$  are loc o tranziție la starea  $S_n$  în intervalul  $(t, t + \Delta t)$  cu probabilitatea  $\alpha_{n-1} \Delta t$ .
- c. La momentul  $t$  sistemul se află în starea  $S_{n+1}$  și o tranziție la starea  $S_n$  are loc în  $(t, t + \Delta t)$  cu probabilitatea  $\beta_{n+1} \Delta t$ .

Notăm  $P_n(t) = P(\{ X(t) \text{ se află în starea } S_n \})$  și facem ipoteza că  $P_n(t)$  este o funcție derivabilă cu derivată continuă. Atunci

$$P_n(t + \Delta t) = P_n(t)(1 - \alpha_n \Delta t - \beta_n \Delta t) + \alpha_{n-1} \Delta t P_{n-1}(t) + \beta_{n+1} \Delta t P_{n+1}(t), \quad n \geq 1,$$

$$P_0(t + \Delta t) = P_0(t)(1 - \alpha_0 \Delta t) + \beta_1 \Delta t P_1(t).$$

Impărțind prin  $\Delta t$

$$\frac{P_n(t + \Delta t) - P_n(t)}{\Delta t} = -(\alpha_n + \beta_n)P_n(t) + \alpha_{n-1}P_{n-1}(t) + \beta_{n+1}P_{n+1}(t), \quad n \geq 1,$$

$$\frac{P_0(t + \Delta t) - P_0(t)}{\Delta t} \Delta t = -\alpha_0 P_0(t) + \beta_1 P_1(t).$$

Dacă  $\Delta t \rightarrow 0$ , obținem

$$P'_n(t) = -(\alpha_n + \beta_n)P_n(t) + \alpha_{n-1}P_{n-1}(t) + \beta_{n+1}P_{n+1}(t), \quad n \geq 1,$$

$$P'_0(t) = -\alpha_0 P_0(t) + \beta_1 P_1(t).$$



Vom da soluții pentru aceste ecuații diferențiale în cazul în care  $P_n(t)$  nu depinde de  $t$ ; în acest caz sistemul precedent devine

$$\begin{cases} (\alpha_n + \beta_n)P_n = \alpha_{n-1}P_{n-1} + \beta_{n+1}P_{n+1}, & n \geq 1, \\ \alpha_0 P_0 = \beta_1 P_1, \end{cases}$$

și se rezolvă prin recurență. Se obține soluția

$$\begin{aligned} P_1 &= \frac{\alpha_0}{\beta_1} P_0 \\ P_2 &= \frac{\alpha_0 \alpha_1}{\beta_1 \beta_2} P_0 \\ &\vdots \\ P_n &= \frac{\alpha_0 \alpha_1 \dots \alpha_{n-1}}{\beta_1 \beta_2 \dots \beta_n} P_0 \end{aligned}$$

Deoarece sistemul trebuie să se afle într-o stare, suma probabilităților precedente trebuie să fie 1, deci

$$P_0 \left( 1 + \frac{\alpha_0}{\beta_1} + \frac{\alpha_0 \alpha_1}{\beta_1 \beta_2} + \dots \right) = 1.$$

**Exemplul 5.2.5** Intr-o "stație" sosesc "clienți" după legea Poisson cu parametrul  $\lambda$ , iar timpul de servire este o lege exponențială cu parametrul pozitiv  $\mu$ ,  $0 < \lambda < \mu$ . Dacă este aglomerație se formează o coadă, iar starea sistemului la momentul  $X(t)$  este un proces de naștere -moarte cu parametrii  $\alpha_n = \lambda$  și  $\beta_n = \mu$ . Particularizând ecuațiile precedente și notând  $\rho = \frac{\lambda}{\mu}$  găsim

$$\begin{aligned} P_1 &= \frac{\lambda}{\mu} P_0 \\ P_2 &= \left( \frac{\lambda}{\mu} \right)^2 P_0 = \rho^2 P_0 \\ &\vdots \\ P_n &= \left( \frac{\lambda}{\mu} \right)^n P_0 = \rho^n P_0 \end{aligned}$$

Punem condiția

$$P_0(1 + \rho + \rho^2 + \dots) = P_0 \frac{1}{1 - \rho} = 1, \quad \rho < 1.$$

De aici rezultă  $P_0 = 1 - \rho$ . Deducem  $P_n = (1 - \rho)\rho^n$ , pentru  $n = 0, 1, \dots$ , care este repartiția geometrică. Să particularizăm această situație. Pentru a evita aglomerația dintr-o stație de deservire, clienții așezați la coadă ar trebui să nu depășească numărul 5, cu probabilitatea 0,99. Sosirile au loc după o lege Poisson cu parametrul  $\lambda = 1,5$  clienți pe minut. Dacă deservirea se face după o lege exponențială, cât de repede trebuie să fie servii? Să determinăm deci  $\mu$ .

Probabilitatea ca cel puțin 5 clienți să fie la coadă este

$$p = \sum_{n=5}^{\infty} (1 - \rho)\rho^n = \rho^5; \quad \rho = \frac{\lambda}{\mu}.$$

Pentru ca această probabilitate să fie  $1-0,99 = 0,01$ , punem condiția

$$\rho^5 \leq 0,1$$

de unde găsim  $\mu > 9,12$ . Deci ar trebui serviți cel puțin 10 clienți în medie pe minut pentru a evita aglomerația.

### 5.3 Procese stochastice staționare

În unele situații stările precedente ale unui sistem exercită un puternic efect asupra stărilor viitoare. În general dacă procesele au fost considerate fără postacțiune (proces Markov), se pot face unele corectări în alegerea stărilor. De exemplu, dacă considerăm o schimbare în poziția unei particule în procesul de difuzie, considerat ca proces fără postacțiune, aceasta înseamnă că se neglijează inerția particulei. Situația se poate corecta introducând în conceptul de stare și viteza particulei, alături de coordonatele poziției. În cazul cel mai general Hincin a izolat o clasă importantă de procese stochastice cu *postacțiune*, numite *proces staționare*. Acestea se întâlnesc în fenomenele acustice, teoria semnalelor etc.

Fie  $\{X(t)\}$ ,  $t \geq 0$ , un proces stohastic.

**Definiția 5.3.1** Numim funcție de repartiție  $n$ -dimensională *funcția dată prin formula*

$$F(x_1, \dots, x_n, t_1, \dots, t_n) = P(\{X(t_1) < x_1, \dots, X(t_n) < x_n\})$$

pentru orice  $t_1, \dots, t_n$ ,  $n \in \mathbb{N}$ .

Presupunem că funcția de repartiție  $n$ -dimensională satisface următoarele două condiții:  
-condiția de simetrie

$$F(x_{i_1}, \dots, x_{i_n}, t_{i_1}, \dots, t_{i_n}) = F(x_1, \dots, x_n, t_1, \dots, t_n), \quad (5.13)$$

pentru orice permutare  $i_1, \dots, i_n$  a mulțimii  $1, \dots, n$ ,

-condiția de compatibilitate; dacă  $m < n$

$$\begin{aligned} F(x_1, \dots, x_m, t_1, t_2, \dots, t_m) &= \\ &= F(x_1, \dots, x_m, \infty, \dots, \infty, t_1, \dots, t_m, t_{m+1}, \dots, t_n), m+1 \leq j \leq n. \end{aligned} \quad (5.14)$$

Kolmogorov a demonstrat că aceste funcții de repartiție caracterizează complet un proces stohastic, în sensul că dată o familie de funcții ce verifică condițiile 1-4, din Capitolul 3.3 și satisface (5.13), (5.14), există un câmp borelian de probabilitate și un proces stohastic care admite aceste funcții, ca funcții de repartiție  $n$ -dimensionale (vezi [9]). Prin analogie cu cazul variabilelor aleatoare  $n$ -dimensionale, se poate introduce noțiunea de densitate de probabilitate, care se va nota  $f(x_1, \dots, x_m, t_1, t_2, \dots, t_m)$ . Dacă procesul este cu valori discrete, analogul îl constituie

$$p(x_1, \dots, x_m, t_1, t_2, \dots, t_m) = P(\{X_1(t_1) = x_1, X_2(t_2) = x_2, \dots, X_n(t_n) = x_n\})$$

**Exemplul 5.3.1** Fie  $X_n$  un lanț de variabile aleatoare identice, independente repartizate, cu  $p = \frac{1}{2}$ , atunci

$$P(\{X_1(t_1) = x_1, X_2(t_2) = x_2, \dots, X_n(t_n) = x_n\}) = 2^{-n}.$$

**Valori caracteristice ale unui proces.**

Fie  $X(t)$  un proces aleator. *Media*  $m_X(t)$  este definită prin

$$m_X(t) = M[X(t)] = \int_{-\infty}^{+\infty} x f(x, t) dx,$$

unde  $f(x, t)$  este densitatea de probabilitate a variabilei  $X(t)$ . *Autocorelația*  $R_X(t_1, t_2)$  este definită prin

$$R_X(t_1, t_2) = M[X(t_1)X(t_2)] = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} xy f(x, y, t_1, t_2) dx dy,$$

unde  $f(x, y, t_1, t_2)$  este densitatea de probabilitate de dimensiune doi a procesului. *Autocovarianța*  $Cov_X(t_1, t_2)$  este definită drept covarianța variabilelor  $X(t_1)$  și  $X(t_2)$ ,

$$Cov_X(t_1, t_2) = M[(X(t_1) - m_X(t_1))(X(t_2) - m_X(t_2))].$$

Legătura dintre cele două funcții este imediată și constă în

$$Cov_X(t_1, t_2) = R_X(t_1, t_2) - m_X(t_1)m_X(t_2).$$

*Dispersia (varianța)* lui  $X(t)$  este dată de formula

$$D^2[X(t)] = M[(X(t) - m_X(t))^2] = Cov_X(t, t).$$

*Coeфициentul de corelație* este definit de

$$\rho_X(t_1, t_2) = \frac{Cov_X(t_1, t_2)}{\sqrt{Cov_X(t_1, t_1)}\sqrt{Cov_X(t_2, t_2)}}.$$

**Exemplul 5.3.2** Fie  $X(t) = A \cos 2\pi t$ , unde  $A$  este o variabilă aleatoare. Să determinăm valorile caracteristice.

$$m_X(t) = M[A \cos 2\pi t] = M[A] \cos 2\pi t;$$

$$R_X(t_1, t_2) = M[A \cos 2\pi t_1 A \cos 2\pi t_2] = M[A^2] \cos 2\pi t_1 \cos 2\pi t_2;$$

$$\begin{aligned} Cov_X(t_1, t_2) &= R_X(t_1, t_2) - m_X(t_1)m_X(t_2) = (M[A^2] - M^2[A]) \cos 2\pi t_1 \cos 2\pi t_2 = \\ &= D^2[A] \cos 2\pi t_1 \cos 2\pi t_2. \end{aligned}$$

**Procese multiple.**

Două procese  $X(t)$ ,  $Y(t)$  se numesc *independente* dacă  $\forall k, j$  și orice alegere  $t_1, \dots, t_k$  și  $t'_1, \dots, t'_j$ , variabilele aleatoare multidimensionale  $(X(t_1), \dots, X(t_k))$  și  $(Y(t'_1), \dots, Y(t'_j))$  sunt independente. *Corelația încrucișată*  $R_{XY}(t_1, t_2)$  este definită prin

$$R_{XY}(t_1, t_2) = M[X(t_1)Y(t_2)].$$

Procesele  $X(t)$  și  $Y(t)$  se numesc *ortogonale* dacă

$$R_{XY}(t_1, t_2) = 0, \quad \forall t_1, t_2.$$

*Covarianța încrucișată*  $Cov_{XY}(t_1, t_2)$  este definită prin

$$Cov_{XY}(t_1, t_2) = M[(X(t_1) - m_X(t_1))(Y(t_2) - m_Y(t_2))] = R_{XY}(t_1, t_2) - m_X(t_1)m_Y(t_2).$$

Procesele se numesc *necorelate* dacă

$$Cov_{XY}(t_1, t_2) = 0, \quad \forall t_1, t_2.$$

**Exemplul 5.3.3** Fie  $X(t) = \cos(\omega t + \Theta)$  și  $Y(t) = \sin(\omega t + \Theta)$  unde  $\Theta$  este o variabilă aleatoare repartizată uniform pe  $[-\pi, +\pi]$ . Să determinăm covarianța încrucișată. Arătăm că media procesului  $X(t)$  este 0.

$$m_X(t) = M[\cos(\omega t + \theta)] = \frac{1}{2\pi} \int_{-\pi}^{\pi} \cos(\omega t + x) dx = 0.$$

Analog rezultă că media procesului  $Y(t)$  este 0.

$$\begin{aligned} R_{XY}(t_1, t_2) &= M[\cos(\omega t_1 + \Theta) \sin(\omega t_2 + \Theta)] = \\ &= M\left[-\frac{1}{2} \sin(\omega(t_1 - t_2)) + \frac{1}{2} \sin(\omega(t_1 + t_2) + 2\Theta)\right] = -\frac{1}{2} \sin(\omega(t_1 - t_2)) \end{aligned}$$

deoarece  $M[\sin(\omega(t_1 + t_2) + 2\Theta)] = 0$ .

**Definiția 5.3.2** *Procesul*  $X(t)$  *se numește staționar în sens restrâns* dacă  $\forall t_1, \dots, t_n \in \mathbb{R}_+$ ,  $n \in \mathbb{N}$ ,  $u \in \mathbb{R}_+$  are loc

$$F(x_1, \dots, x_n, t_1 + u, \dots, t_n + u) = F(x_1, \dots, x_n, t_1, \dots, t_n). \quad (5.15)$$

Relația (5.15) se interpretează astfel: funcțiile de repartiție  $n$ -dimensionale nu depind de creșterea timpului. Dacă în (5.15) dăm lui  $n$  valoarea 2, găsim că funcțiile de repartiție bidimensionale depind numai de diferența  $t_2 - t_1$ . Deoarece în practică lucrul cu funcțiile de repartiție este dificil se pune problema înlocuirii lor cu alte caracteristici și anume cu momentele. Dacă  $X(t)$  are dispersie finită și  $X(t)$  este staționar în sens restrâns găsim:

1.  $M[X(t+u)] = M[X(t)] = M[X(0+u)] = M[X(0)] = m$ ;
2.  $D^2[X(t+u)] = D^2[X(t)] = D^2[X(0)] = \sigma^2$ ;
3.  $M[(X(t+u)X(t))] = M[(X(u)X(0))]$ .

Ca o primă consecință a acestor proprietăți, observăm că în cazul proceselor staționare putem presupune  $m = 0$  și  $\sigma = 1$ , ceea ce revine la considerarea procesului normalizat,

adică  $\frac{X(t) - m}{\sigma}$ .

**Definiția 5.3.3** *Procesul  $X(t)$  este staționar în sens larg dacă au loc condițiile 1-3.*

**Definiția 5.3.4** *Numim funcție de corelație a unui proces staționar în sens larg coeficientul de corelație al variabilelor aleatoare  $X(t)$  și  $X(t + u)$ .*

Deci funcția de corelație are expresia

$$R(u) = \frac{M[X(t + u) - M[X(t + u)]]M[X(t) - M[X(t)]]}{\sqrt{D^2[X(t)]D^2[X(t + u)]}}.$$

Dacă facem ipoteza  $m = 0$  și  $\sigma = 1$  din condiția de a fi staționar rezultă că funcția de corelație depinde doar de  $u$  și are expresia

$$R(u) = M[(X(u)X(0))].$$

**Definiția 5.3.5** *Un proces staționar se numește continuu dacă are loc*

$$M(X(t + u) - X(t))^2 \rightarrow 0, \text{ pentru } u \rightarrow 0.$$

**Propoziția 5.3.1** *Dacă  $X(t)$  este un proces continuu, atunci au loc:*

1.  $P(\{|X(t + u) - X(t)| \geq \varepsilon\}) \rightarrow 0$ , dacă  $u \rightarrow 0$ ;
2.  $\lim_{u \rightarrow 0} R(u) = 1$ ;
3.  $R(u)$  este continuă.

**Demonstrație.**

1. Din inegalitatea lui Cebâșev, rezultă

$$\begin{aligned} P(\{|X(t + u) - X(t)| \geq \varepsilon\}) &= P(\{|X(t + u) - X(t) - M[(X(t + u) - X(t))]| \geq \varepsilon\}) \leq \\ &\leq \frac{D^2[(X(t + u) - X(t))]}{\varepsilon}, \end{aligned}$$

care din definiția continuității tinde la 0, dacă  $u \rightarrow 0$ .

2. Se observă imediat că

$$M(X(t + u) - X(t))^2 = 2(1 - R(u)) \rightarrow 0, \text{ dacă } u \rightarrow 0,$$

de unde afirmația 2.

3. Folosind inegalitatea lui Cauchy are loc

$$\begin{aligned} |R(u + \Delta u) - R(u)| &= |M[(X(u + \Delta u)X(0))] - M[(X(u)X(0))]| = \\ &= |M[(X(0)(X(u + \Delta u) - X(u)))]| \leq \sqrt{M[X^2(0)]M[(X(u + \Delta u) - X(u))^2]} \rightarrow 0, \end{aligned}$$

dacă  $\Delta u \rightarrow 0$ . ■

**Teorema 5.3.1** (Teorema lui Hincin) *Funcția reală  $R(u)$  este o funcție de corelație pentru un proces staționar continuu dacă și numai dacă există o funcție de repartiție  $F(x)$  astfel încât*

$$R(u) = \int_{-\infty}^{\infty} \cos ux \, dF(x).$$

**Demonstrație.** Să presupunem mai întâi că  $R(u)$  este o funcție de corelație pentru un proces staționar continuu. Din proprietatea precedentă  $R(u)$  rezultă continuă și mărginită. Să arătăm că este și pozitiv definită. Pentru orice numere reale  $u_1, u_2, \dots, u_n$  din  $\mathbb{R}$  și  $\eta_1, \dots, \eta_n \in \mathbb{C}$  unde  $n \in \mathbb{N}$ , are loc

$$\begin{aligned} 0 &\leq M \left| \sum_{k=1}^n \eta_k X^2(u_k) \right| = M \left( \sum_{i=1}^n \sum_{j=1}^n \eta_i \bar{\eta}_j X(u_i) X(u_j) \right) = \\ &= \sum_{i=1}^n \sum_{j=1}^n R(u_i - u_j) \eta_i \bar{\eta}_j. \end{aligned}$$

Deoarece  $R(0) = 1$  din teorema Bochner-Hincin are loc reprezentarea

$$R(u) = \int_{-\infty}^{\infty} e^{iux} dF(x),$$

unde  $F$  este o funcție de repartiție. Deoarece  $R$  este o funcție reală, rezultă afirmația.

Reciproc, să arătăm că dacă

$$R(u) = \int_{-\infty}^{\infty} \cos ux dF(x),$$

există un proces staționar  $X(t)$  cu funcția de corelație  $R(u)$ . Fie  $n \in \mathbb{N}$ ,  $t_1, t_2, \dots, t_n$  și variabila aleatoare  $n$ -dimensională normal repartizată  $X(t_1), \dots, X(t_n)$  cu

$$M[X(t_1)] = \dots = M[X(t_n)] = 0,$$

$$D^2[(X(t_1))] = \dots = D^2[(X(t_n))] = 1,$$

având funcțiile de corelație

$$R(t_i - t_j) = M[X(t_i)X(t_j)].$$

Deoarece forma pătratică

$$\sum_{i=1}^n \sum_{j=1}^n R(t_i - t_j) u_i u_j$$

este pozitiv definită, se pot defini funcțiile de densitate

$$f_n(u_1, \dots, u_n, t_1, \dots, t_n) = A_n e^{-\sum_{i=1}^n \sum_{j=1}^n R(t_i - t_j) u_i u_j}, \quad A_n \in \mathbb{R}.$$

Se verifică ușor că funcțiile de repartiție asociate satisfac condițiile de simetrie și compatibilitate, deci definesc un proces stochastic, care rezultă staționar. ■

**Exemplul 5.3.4** Considerăm procesul de forma

$$Z(t) = X(t) \cos \lambda t + Y(t) \sin \lambda t, \quad \lambda \in \mathbb{R},$$

unde  $X(t), Y(t)$  sunt procese necorelate, deci  $M[XY] = M[X]M[Y]$  ce satisfac

$$M[X] = M[Y] = 0, \quad D^2[X] = D^2[Y] = 1.$$

Să arătăm că  $Z(t)$  este un proces staționar. Pentru aceasta să calculăm funcția de corelație

$$\begin{aligned} R(u) &= M[X(t+u)X(t)] = \\ &= M[X \cos \lambda(t+u) + Y \sin \lambda(t+u)](X \cos \lambda t + Y \sin \lambda t) = \\ &= M[(X^2 \cos \lambda t \cos \lambda(t+u) + XY(\sin \lambda(t+u) \cos \lambda t + \cos \lambda(t+u) \sin \lambda t) + \\ &\quad + Y^2 \sin \lambda t \sin \lambda(t+u))] = \cos \lambda(t+u) \cos \lambda t + \sin \lambda t \sin \lambda(t+u) = \cos \lambda u. \end{aligned}$$

Alegem

$$f(x) = \begin{cases} 0, & x \leq -\lambda \\ \frac{1}{2}, & -\lambda < x \leq \lambda \\ 1, & x > \lambda \end{cases}.$$

Avem atunci

$$\cos \lambda u = \int_{-\infty}^{\infty} \cos ux dF(x) = \int_{-\lambda}^{\lambda} \cos ux dF(x),$$

de unde în virtutea teoremei rezultă că procesul este staționar.

**Exemplul 5.3.5** Considerăm procesul

$$X(t) = \sum_{k=1}^n b_k Z_k(t),$$

unde  $\sum_{k=1}^n b_k^2 = 1$ , iar  $Z_k(t) = X_k(t) \cos \lambda_k t + Y_k \sin \lambda_k t$ ,  $\lambda_k \in \mathbb{R}$ .  $X_k(t), Y_k(t)$  sunt preprocesse ce satisfac

$$\begin{aligned} M[X_k] &= M[Y_k] = 0, \quad D^2[X_k] = D^2[Y_k] = 1, \quad k = \overline{1, n} \\ M[X_i X_j] &= M[Y_i Y_j] = 0, \quad i \neq j, \quad M[X_i Y_j] = 0, \quad i, j = \overline{1, n}. \end{aligned}$$

Calculând funcția de corelație, găsim

$$R(u) = \sum_{k=1}^n b_k^2 \cos \lambda_k u,$$

de unde rezultă că procesul este staționar, asociat funcției de repartiție  $F$  care are salturi de mărimea  $\frac{1}{2}b_k^2$  în punctele  $\pm \lambda_k$ .

În literatura de specialitate  $F$  se numește *spectru*; dacă  $F$  este funcție de salturi, procesul se numește *cu spectru discret*. Slutsky a demonstrat că orice proces cu spectru discret este reprezentabil sub forma celui din exemplul precedent.

### PROBLEME PROPUSE

**Problema 4.1** Fie  $I_n$  procesul Bernoulli identic și independent repartizat. Calculați  $P(\{I_1 = 1, I_2 = 0, I_3 = 0, I_4 = 1\})$ .

R:  $p^2(1-p)^2$ .

**Problema 4.2** Fie  $D_n = 2I_n - 1$  unde  $I_n$  este procesul din problema precedentă. Calculați media și dispersia.

Soluție  $m_X(n) = M[2I_n - 1] = 2M[I_n] - 1 = 2p - 1$   $D^2[D_n] = D^2[2I_n - 1] = 2^2 D^2[I_n] = 4p(1-p)$ . Procesul reprezintă de fapt schimbarea poziției unei particule care se mișcă în linie dreaptă făcând salturi de  $\pm 1$  la fiecare unitate de timp.

**Problema 4.3** Fie  $X$  un număr ales la întâmplare din  $[0, 1]$  și fie dezvoltarea lui în baza 2,  $x = \sum_{n=1}^{+\infty} b_n 2^{-n}$ ,  $b_n \in \{0, 1\}$ . Definim  $X_n = b_n$ ,  $n \in \mathbb{N}$ . Calculați  $P(\{X_1 = 0\})$  și  $P(\{X_1 = 0, X_2 = 1\})$ .

Soluție.  $X_1 = 0$ , dacă  $0 \leq X \leq \frac{1}{2}$ , deci cu probabilitatea  $\frac{1}{2}$ . Iar  $P(\{X_1 = 0, X_2 = 1\})$  este  $\frac{1}{4}$ , deoarece  $\frac{1}{4} \leq X \leq \frac{1}{2}$ .

**Problema 4.4** Un calculator este inspectat la momentele  $t_1, t_2, t_3$  și se poate afla în una din următoarele stări:

- $s_1$  funcționează normal;
- $s_2$  are un număr neglijabil de erori, care nu împiedică calculatorul să funcționeze;
- $s_3$  are erori considerabile, dar rezolvă limitat probleme;
- $s_4$  nu funcționează.

La momentul inițial calculatorul este în starea  $s_1$  iar matricea de tranziție este

$$P = \begin{pmatrix} 0,5 & 0,3 & 0,2 & 0 \\ 0 & 0,4 & 0,4 & 0,2 \\ 0 & 0 & 0,3 & 0,7 \\ 0 & 0 & 0 & 1 \end{pmatrix}.$$

Asociați diagrama și aflați probabilitățile de stare după fiecare din cele trei inspecții.

Soluție. Probabilitățile de stare inițială sunt  $(1, 0, 0, 0)$ , deoarece inițial calculatorul funcționează. Apoi

$$p_1(1) = 0,5, \quad p_2(1) = 0,3, \quad p_3(1) = 0,2, \quad p_4(1) = 0$$

$$p_1(2) = 0,25, \quad p_2(2) = 0,27, \quad p_3(2) = 0,28, \quad p_4(2) = 0,2$$

$$p_1(3) = 0,125, \quad p_2(3) = 0,183, \quad p_3(3) = 0,242, \quad p_4(3) = 0,450.$$



Diagrama este următoare

**Problema 4.5** O particulă se deplasează aleator, sărind câte o unitate la dreapta sau stânga, după diagrama de mai jos. Găsiți probabilitatea ca după patru pași particula să nu fie mai depărtată cu o unitate față de origine. Inițial particula se află în origine.

R: Însușim probabilitățile, ca la momentul 4, particula să se afle în stările  $S_{-1}, S_0$ , sau  $S_1$  și găsim 0,693.

**Problema 4.6** Fie  $X(t) = \cos(\omega t + \Theta)$  unde  $\Theta$  este repartizată uniform pe  $(-\pi, +\pi)$ . Să determinăm media, autocorelația și autocovarianța.

Soluție  $m_X(t) = M[\cos(\omega t + \Theta)] = \frac{1}{2\pi} \int_{-\pi}^{+\pi} \cos(\omega t + x) dx = 0;$   
 $Cov_X(t_1, t_2) = R_X(t_1, t_2) = M[\cos(\omega t_1 + \theta) \cos(\omega t_2 + \theta)] =$   
 $\frac{1}{2\pi} \int_{-\pi}^{+\pi} \frac{1}{2} (\cos(\omega(t_1 - t_2)) + \cos(\omega(t_1 + t_2) + 2x)) dx = \frac{1}{2} \cos(\omega(t_1 - t_2)).$

**Problema 4.7** Fie  $X_n$  un lanț de variabile normale independente, identic repartizate, cu media  $m$  și dispersia  $\sigma^2$ . Determinați matricea de covarianță la momentele  $t_1, \dots, t_k$  și densitatea de probabilitate.

Soluție  $C_X(t_i, t_j) = \sigma^2 \delta_{ij}$  unde  $\delta_{ij} = \begin{cases} 1 & i = j \\ 0 & i \neq j \end{cases}$

$$f(x_1, \dots, x_k, X_1, \dots, X_k) = f_X(x_1) f_X(x_2) \dots f_X(x_k) =$$

$$= \frac{1}{(2\pi\sigma^2)^{k/2}} e^{-\frac{\sum_{i=1}^k (x_i - m)^2}{2\sigma^2}}.$$

**Problema 4.8** Un proces  $Y(t)$  constă dintr-un semnal dorit  $X(t)$  la care se adaugă zgomotul  $N(t)$ , deci  $Y(t) = X(t) + N(t)$ . Găsiți corelația încrucișată dintre cele două procese, presupunînd că  $X(t), N(t)$  sunt independente.

Soluție Folosind independența variabilelor  $X(t)$  și  $N(t)$ , găsim

$$R_{XY}(t_1, t_2) = M[X(t_1)Y(t_2)] = M[X(t_1)(X(t_2) + N(t_2))] =$$

$$= M[X(t_1)X(t_2)] + M[X(t_1)N(t_2)] =$$

$$= R_{XY}(t_1, t_2) + M[X(t_1)]M[N(t_2)] = R_{XY}(t_1, t_2) + m_X(t_1)m_N(t_2).$$

**Problema 4.9** În ziua 0 există 2 becuri noi de rezervă. Probabilitatea de a schimba un bec este  $p$ , iar probabilitatea de a nu schimba este  $q = 1 - p$ . Fie  $Y_n$  numărul de becuri necesar la sfârșitul zilei  $n$ . Determinați matricea de tranziție după un pas și după  $n$  pași, probabilitățile de stare la momentul  $n$  și comportarea lor la limită.

Soluție Stările procesului sunt 2,1,0, iar diagrama corespunzătoare este Matricea de tranziție cu un pas este

$$P = \begin{pmatrix} 1 & 0 & 0 \\ p & 1-p & 0 \\ 0 & p & 1-p \end{pmatrix}$$

iar probabilitățile de stare la momentul inițial sunt 0, 0, 1. După  $n$  pași

$p_{22}(n) = P(\{\text{nici un bec nou nu e necesar în } n \text{ zile}\}) = q^n;$   
 $p_{21}(n) = P(\{\text{un bec nou este necesar în } n \text{ zile}\}) = C_n^1 p q^{n-1};$   
 $p_{20}(n) = 1 - p_{22}(n) - p_{21}(n);$   
 Matricea de tranziție după  $n$  pași este

$$P^n = \begin{pmatrix} 1 & 0 & 0 \\ 1 - q^n & q^n & 0 \\ 1 - q^n - npq^{n-1} & npq^{n-1} & q^n \end{pmatrix}.$$

Trecînd la limită pe fiecare element al matricei găsim matricea

$$\begin{pmatrix} 1 & 0 & 0 \\ 1 & 0 & 0 \\ 1 & 0 & 0 \end{pmatrix}.$$

Probabilitățile de stare la momentul  $n$  sunt date de produsul

$$(0 \ 0 \ 1) \begin{pmatrix} 1 & 0 & 0 \\ 1 - q^n & q^n & 0 \\ 1 - q^n - npq^{n-1} & npq^{n-1} & q^n \end{pmatrix}$$

iar la limită se obține  $(1 \ 0 \ 0)$ . Interpretarea evidentă este că după un număr foarte mare de pași procesul devine "staționar" și rămân 0 becuri de rezervă.

## Index

# Index

- matricea de covarianță, 121
- repartiția Fisher , 148
  
- coeficient de corelație, 119
- corelația variabilelor, 119
  
- densitate de probabilitate, 91
- densitate de probabilitate  $n$ -dimensională, 100
- densitate marginală de probabilitate, 101
- densitatea de probabilitate condiționată, 97
  
- formula de inversiune, 125
- formula lui Bayes, 98, 113
- formula probabilității totale, 113
- formula probabilității totale, 98
- formulele integrale ale mediei totale, 121
- funcția caracteristică a repartiției Gama, 149
- funcția caracteristică a repartiției normale , 132
- funcția de repartiție, 85
- funcție caracteristică, 123
- funcție de fiabilitate, 150
- funcție de repartiție  $n$  dimensională, 99
- funcție de repartiție condiționată, 89
- funcție marginală de repartiție, 101
- funcție pozitiv definită, 129
- funcției lui Laplace, 94
  
- legare în paralel, 154
- legare în serie, 153
  
- media, 114
- media condiționată, 121
- mediana, 89
- medii condiționate, 121
- modul, 115
- moment centrat de ordin  $k$ , 116
- moment pentru variabilă aleatoare multidimensională, 120
  
- momentele inițiale, 147
- momentele inițiale ale repartiției Gama, 149
- momentele repartiției Beta, 150
- momentele repartiției Student, 142
- momentele variabilei aleatoare normale  $n$ -dimensionale, 135
  
- normală normată, 93
  
- q-cvantine, 88
  
- Repartiția Beta, 150
- repartiția Erlang, 149
- repartiția exponențială, 152
- repartiția lognormală, 104
- repartiția normală, 93
- repartiția normală  $n$ -dimensională, 106
- repartiția Rayleigh, 108
- repartiția Snedecor, 147
- repartiția Student , 142
- repartiția uniformă, 92
- repartiția uniformă  $n$ -dimensională, 102
- repartiția Weibull, 152
  
- teorema Bochner-Hincin, 129
- teorema lui Bochner, 128
- teorema lui Cochran, 141
  
- variabilă aleatoare, 83
- variabilă aleatoare  $n$ -dimensională, 99
- variabilă aleatoare continuă, 88
- variabile aleatoare independente, 85
- variabile necorelate, 119