

Bazele teoriei riscului

Mircea Crâșmăreanu

Contents

1	Mulțimi și funcții	3
2	Probabilități: abordare clasică	5
3	Probabilități: abordare modernă	11
4	Funcția de repartiție a unei variabile aleatoare	19
5	Valori medii. Momente, dispersie, corelație	25
6	Teoria deciziilor	31
7	Invarianță în teoria deciziilor	41
8	Utilitate și pierdere	45
9	Teoria credibilității	47
10	Variabile fuzzy pe spații de credibilitate	51
11	Entropia, energia și corelația surselor de informație	53
	Index	57

MOTTO

Fie acțiunea "a" având consecințele c_i cu $i = 1, \dots, n$ pentru care considerăm:

- 1) p_i probabilitatea de producere a lui c_i
- 2) $Pierd(c_i)$ "pierderea" cauzată de c_i .

Atunci riscul acțiunii "a" este:

$$R(a) = \sum_{i=1}^n p_i \cdot Pierd(c_i).$$

Cursul conține 30 de desene repartizate astfel:

Curs	Desene
I	0
II	5
III	8
IV	5
V	0
VI	12
VII	0
VIII	0
IX	0
X	0
XI	0
XII	0
Examen	mai multe

Chapter 1

Mulțimi și funcții

Noțiunea de *mulțime* este una din noțiunile fundamentale al matematicii. Încercarea de a o defini într-un sens precis este sortită eșecului deoarece încadrarea acestei noțiuni ca un acaz particular al unei alte noțiuni mai generale este imposibilă, noțiunea de mulțime fiind, în fapt, cea mai generală noțiune matematică.

Fondatorul teoriei (moderne a) mulțimilor, matematicianul german Georg Cantor (1845-1918), spunea că prin mulțime se înțelege, la modul intuitiv, totalitatea unor obiecte distincte, bine determinate individual.

Vom utiliza o serie de simboluri grafice pentru ușurința exprimării:

-semnul \forall va desemna expresia *pentru orice* sau *oricare ar fi*,

-semnul \exists va desemna cuvântul *există*,

-semnul \Rightarrow va desemna o implicație, adică va fi echivalentul cuvintelor *rezultă că* sau *deci* sau *atunci*.

Obiectele ce compun o mulțime le vom numi *elemente* iar acestea, de regulă, le vom nota cu litere mici iar mulțimile cu litere mari. Astfel, $a \in A$ va desemna *apartența* elementului a la mulțimea A ; avem negația $a \notin A$.

Există două metode de a indica (sau da) o mulțime A :

I) prin înșiruirea completă a elementelor sale, metodă preferabilă atunci când A are un număr finit de elemente; spunem că A este *mulțime finită*. Deci notăm $A = \{a, b, c, \dots\}$.

II) prin indicarea unei proprietăți caracteristice P ; scriem $A = \{x; x \text{ satisface } P\}$.

Mulțimile numerice utilizate în acest Curs sunt cele clasice:

i) mulțimea numerelor *naturale*: $\mathbb{N} = \{0, 1, 2, \dots, n, \dots\}$; avem submulțimea $\mathbb{N}^* = \{1, \dots, n, \dots\}$.

ii) mulțimea numerelor *întregi*: $\mathbb{Z} = \mathbb{N}_- \cup \mathbb{N} = \{\dots, -n, \dots, -2, -1, 0, 1, 2, \dots, n, \dots\}$.

iii) mulțimea numerelor *raționale*: $\mathbb{Q} = \{\frac{m}{n}; m, n \in \mathbb{Z}, n \neq 0\}$.

iv) mulțimea numerelor *iraționale* este mulțimea \mathbb{I} a numerelor ce nu se pot exprima ca fracții; spre exemplu $\sqrt{2}$, $\sqrt[3]{2}$, π , ...

v) mulțimea numerelor *reale*: $\mathbb{R} = \mathbb{Q} \cup \mathbb{I} = (-\infty, +\infty)$. Submulțimi remarcabile sunt: $\mathbb{R}_+ = [0, +\infty)$ =numerele reale nenegative, $\mathbb{R}_+^* = (0, +\infty)$ =numerele reale pozitive, $\mathbb{R}_- = (-\infty, 0]$ =numerele reale nepozitive, $\mathbb{R}_-^* = (-\infty, 0)$ =numerele reale negative.

Semnul \cup reprezintă *reuniunea* a două mulțimi; astfel date mulțimile A și B avem că $A \cup B$ cuprinde toate elementele din A și B (evident, luate o singură dată):

$$A \cup B = \{x; x \in A \text{ sau } x \in B\}. \quad (1.1)$$

Simbolul \cap reprezintă *intersecția*; astfel $A \cap B$ conține elementele comune lui A și B :

$$A \cap B = \{x; x \in A \text{ și } x \in B\}. \quad (1.2)$$

Dacă B este submulțime în A notăm $B \subset A$ și definim *complementara lui B în A* prin:

$$C_A B = cB = \bar{B} = \{x \in A; x \notin B\}. \quad (1.3)$$

Submulțimii $B \subset A$ îi asociem *funcția caracteristică* $1_B : A \rightarrow \{0, 1\}$:

$$1_B(x) = \begin{cases} 1, & x \in B \\ 0, & x \notin B. \end{cases} \quad (1.4)$$

Reciproc, orice funcție caracteristică definește în mod unic submulțimea B și deci există o corespondență biunivocă între mulțimea $\{\Gamma : A \rightarrow \{0, 1\}\}$ și mulțimea $\mathcal{P}(A)$ a tuturor submulțimilor lui A .

Definiția 1.1 Fixăm două mulțimi. Numim *relație de la X la Y* un triplet $r = (X, Y, G)$ cu G submulțime în produsul cartezian $X \times Y$. *Domeniul de definiție* al lui r este $E_r = \{x \in X; \exists y \in Y(x, y) \in G\}$ iar *mulțimea valorilor* lui r este $F_r = \{y \in Y; \exists x \in X(x, y) \in G\}$. Dacă $(x, y) \in G$ mai notăm xry . Dacă $X = Y$ spunem că avem o relație *pe X* .

Definiția 1.2 O relație $f = (X, Y, G)$ se numește *funcție* dacă îndeplinește următoarele două condiții:

Fc1) X este domeniul de definiție al lui f i.e. $X = E_f$;

Fc2) dacă $(x, y_1) \in G$ și $(x, y_2) \in G$ atunci $y_1 = y_2$.

Notăm $f : X \rightarrow Y$.

Definiția 1.3 Relația r pe X se numește *de ordine* dacă este:

O1) *reflexivă*: avem xrx pentru orice $x \in X$.

O2) *antisimetrică*: dacă avem xry și yrx atunci $x = y$.

O3) *tranzitivă*: dacă avem xry și yrz atunci xrz .

Dacă păstrăm O1 și O3 și înlocuim antisimetria cu:

E) *simetrică*: dacă xry atunci yrx

obținem noțiunea de *relație de echivalență*. Dacă r este o relație de echivalență atunci pentru $x \in X$ fixat, mulțimea $[x] = \{y \in X; xry\}$ se numește *clasa de echivalență* a lui X

Mulțimea tuturor claselor de echivalență se numește *mulțimea factor* sau *mulțimea cât* a lui X în raport cu r . Deoarece două clase de echivalență sau coincid sau sunt disjuncte, obținem prin factorizare o *partiție* a lui X în clase de echivalență.

Chapter 2

Probabilități: abordare clasică

Fixăm în acest Curs mulțimea nevidă și finită $\Omega = \{\omega_1, \dots, \omega_n\}$; deci Ω are *cardinalul* $n \in \mathbb{N}^* = \{1, 2, \dots\}$ și notăm acest fapt prin $\text{card}\Omega = n$ sau $|\Omega| = n$.

Definiția 2.1 i) Ω se numește *spațiul evenimentelor (probelor)* iar $\omega_i \in \Omega$ îl numim *eveniment elementar*.

ii) Mulțimea $\mathcal{P}(\Omega)$ o numim *câmpul evenimentelor* iar $A \in \mathcal{P}(\Omega)$ o numim *eveniment*.

Exemplul 2.2 Aruncăm o monedă: avem două evenimente elementare 0=a căzut stema, 1=a căzut moneda (banul). Deci $n = 2$ și $\Omega = \{0, 1\}$.

Exemplul 2.3 Aruncăm un zar. Avem șase evenimente elementare i =a căzut fața i , $i = 1, \dots, 6$. Deci $\Omega = \{1, \dots, 6\}$ și un eveniment compus este, spre exemplu, "a căzut o față pară/impară", eveniment modelat de $A = \{2, 4, 6\}$ respectiv $B = \{1, 3, 5\}$.

Definiția 2.4 i) $\Omega \in \mathcal{P}(\Omega)$ îl numim *evenimentul sigur* iar *mulțimea vidă* $\emptyset \in \mathcal{P}(\Omega)$ se numește *evenimentul imposibil*.

ii) Fie A și B din $\mathcal{P}(\Omega)$. Dacă $A \cap B = \emptyset$ atunci spunem că evenimentele A și B sunt *incompatibile* iar dacă $B \subset A$ atunci spunem că evenimentul B *implică* evenimentul A .

Exemplul 2.5 La aruncarea zarului evenimentul B =a căzut fața 4 implică evenimentul A =a căzut o față pară, care este independent de evenimentul C =a căzut o față impară.

Noțiunea principală a acestui Curs este dată de:

Definiția 2.6 Se numește *probabilitate* pe Ω o funcție $p : \mathcal{P}(\Omega) \rightarrow \mathbb{R}$ satisfăcând axiomele:

p1) $p(A) \geq 0$ pentru orice $A \in \mathcal{P}(\Omega)$

p2) $p(\Omega) = 1$

p3) dacă A și B sunt evenimente incompatibile atunci:

$$p(A \cup B) = p(A) + p(B). \quad (2.1)$$

Perechea (Ω, p) o numim *câmp de probabilitate*.

Propoziția 2.7 (Regula de adunare a probabilităților) Fie A_1, \dots, A_r evenimente incompatibile două câte două i.e. $A_i \cap A_j = \emptyset$ pentru $i \neq j$ în mulțimea $\{1, \dots, r\}$. Atunci:

$$p(A_1 \cup \dots \cup A_r) = p(A_1) + \dots + p(A_r) (= \sum_{i=1}^r p(A_i)). \quad (2.2)$$

Demonstrație Vom arăta prin inducție după $r \geq 2$. Pentru $r = 2$ avem formula (1.5). Presupunem adevărată relația (1.6) pentru $(r - 1)$ și s-o demonstrăm pentru r . Evenimentele $A = A_1 \cup \dots \cup A_{r-1}$ și $B = A_r$ sunt evident incompatibile și aplicăm (1.5):

$$p((A_1 \cup \dots \cup A_{r-1}) \cup A_r) = p(A_1 \cup \dots \cup A_{r-1}) + p(A_r)$$

ceea ce dă concluzia în baza ipotezei inductive. \square

Fie $A = \{\omega_{i_1}, \dots, \omega_{i_r}\}$ oarecare din $\mathcal{P}(\Omega)$. Evident evenimentele elementare ω_{i_j} , $j = 1, \dots, r$ sunt incompatibile și deci $p(A) = \sum_{j=1}^r p(\{\omega_{i_j}\})$. În concluzie a da/ști probabilitatea p pe $\mathcal{P}(\Omega)$ este echivalent cu a da/ști $p = (p_i)$ cu $i \in \{1, \dots, n\}$. Rezultă că funcția p apare ca un vector n -dimensional $\bar{p} = (p_1, \dots, p_n) \in \mathbb{R}^n$ iar proprietățile din Definiția 1.6 se traduc în: p1) $\bar{p} \in \mathbb{R}_+^n$ i.e. $p_i \geq 0$ pentru $1 \leq i \leq n$
p2) $\sum_{i=1}^n p_i = 1$.
Rezultă că $p_i \in [0, 1]$ pentru toți $i \in \{1, \dots, n\}$.

Exemplul 2.8 i) Evenimentele *echiprobabile* sunt caracterizate de vectorul $\bar{p}_n = (\frac{1}{n}, \dots, \frac{1}{n})$ ceea ce corespunde la funcția probabilitate clasică:

$$p(A) = \frac{\text{card}A}{\text{card}\Omega} \quad (2.3)$$

care dă definiția clasică (sau tradițională) a probabilității unui eveniment E :

$$p(E) = \frac{\text{numărul cazurilor favorabile producerii lui } E}{\text{numărul total de cazuri posibile}}. \quad (2.4)$$

ii) În particular, moneda este dată de \bar{p}_2 iar zarul de \bar{p}_6 .

Propoziția 2.9 Date evenimentele $A, B \in \mathcal{P}(\Omega)$ avem:

$$p(B \cap \bar{A}) = p(B) - p(A \cap B). \quad (2.5)$$

Demonstrație Evenimentele $X = B \cap \bar{A}$ și $Y = B \cap A$ sunt evident incompatibile datorită prezenței lui A și \bar{A} . Aplicăm (1.5) pentru X și Y și folosim faptul că:

$$(B \cap A) \cup (B \cap \bar{A}) = B \quad (2.6)$$

care se dovedește imediat. \square

Corolarul 2.10 Pentru orice $A, B \in \mathcal{P}(\Omega)$ avem:

$$p(\bar{A}) = 1 - p(A) \quad (2.7)$$

$$p(A \cup B) = p(A) + p(B) - p(A \cap B) \quad (2.8)$$

$$A \subset B \Rightarrow p(A) \leq p(B). \quad (2.9)$$

Din (1.10) avem în particular că $p(\emptyset) = 0$.

Demonstrație Pentru (2.7) punem $B = \Omega$ în (2.5). Pentru (2.8) să observăm că: - evenimentele A și $B \cap \bar{A}$ sunt incompatibile, -avem $A \cup (B \cap \bar{A}) = (A \cup B) \cap (A \cup \bar{A}) = (A \cup B) \cap \Omega = A \cup B$,

și utilizăm (2.6) Pentru ultima relație, din $A \subset B$ avem $A \cap B = A$ și din (2.5) rezultă $0 \leq p(B \cap \bar{A}) = p(B) - p(A)$ ceea ce dă concluzia. \square

Seminar 2

Cardinalul lui $\mathcal{P}(\Omega)$ este 2^n . Acest cardinal crește foarte repede odată cu n mai precis *exponențial*.

S2.1 Să se calculeze cu MATLAB puterea 2^n pentru $n = 0, \dots, 10$.

Soluție

```
>> for n=1:10; x(n)=2^n; end;
```

```
>> x (+ Enter)
```

Ans:

```
x=2 4 8 16 32 64 128 256 512 1024
```

Observație: MATLAB nu știe de convenția $x^0 = 1$ într-un șir. \square

O altă funcție ce crește foarte rapid este *factorialul*: $n! = 1 \cdot \dots \cdot n$ cu convenția $0! = 1$.

S2.2 Se cere $n!$ pentru $n \in \{1, \dots, 8\}$.

Soluție $1! = 1$, $2! = 2$, $3! = 6$, $4! = 24$, $5! = 120$, $6! = 720$, $8! = ???$.

În MATLAB folosim următoarele simboluri pentru operații numerice:

- 1) + pentru adunare; - pentru scădere
- 2) * pentru înmulțire
- 3) / pentru împărțire
- 4) ^ pentru ridicarea la putere.

Deci pentru $8!$ tastăm:

```
>> 2*3*4*5*6*7*8 (+Enter)
```

Ans:

```
40320
```

Avem în Matlab funcția *factorial* cu sintaxa:

```
>> factorial(n)
```

pentru $n \leq 21$! O altă variantă este *prod(1 : n)*.

Pe Wikipedia (engleză) avem un tabel foarte amplu:

<http://en.wikipedia.org/wiki/Factorial>

Atenție: în MATLAB avem funcția *factor* care factorizează un număr natural în produs de numere prime. Exemplu:

```
>> factor(2009)
```

are ca rezultat 7 7 41 deoarece $2009 = 7^2 \cdot 41$. Analog:

```
>> factor(2010)
```

dă rezultatul 2 3 5 67. Cele două funcții nu trebuie confundate! \square

O funcție importantă în calculul unor scheme probabilistice este *combinări de n obiecte luate câte k* , $0 \leq k \leq n$:

$$C_n^k = \frac{n!}{k!(n-k)!}. \quad (2.10)$$

De altfel, numărul submulțimilor cu k elemente ale lui Ω este C_n^k și deci:

$$\sum_{k=0}^n C_n^k = 2^n. \quad (2.11)$$

O altă proprietate importantă combinărilor este *complementaritatea*:

$$C_n^k = C_n^{n-k}. \quad (2.12)$$

A se vedea http://en.wikipedia.org/wiki/Binomial_coefficient.

În Matlab avem comanda: $C = nchoosek(n, k)$ eficientă pentru $n \leq 15$.

S2.3 Să se figureze în MATLAB vectorii de probabilitate doi dimensionali.

Cu programul:

```
>> x=linspace(0, 1, 1000);
>> plot(x, 1-x) (+Enter)
```

avem graficul următor:

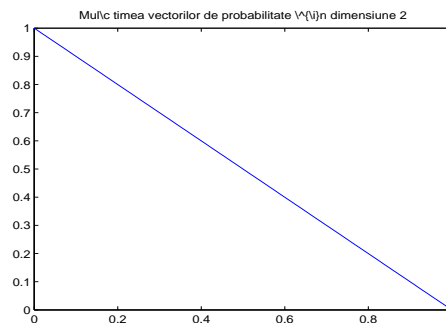


Figura 2.1: Distribuția în plan a vectorilor de probabilitate

Cu programul:

```
>> x=linspace(0, 1, 1000);
>> plot(x, 1-x, 1/2, 1/2, 'o') (+Enter)
```

avem graficul următor ce poziționează vectorul \bar{p}_2 al monedei:

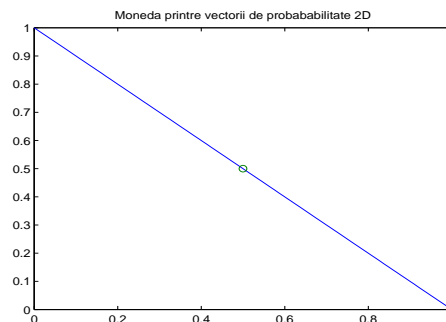


Figura 2.2: Distribuția monedei printre vectorii de probabilitate 2D

Cu programul:

```
>> x=linspace(0, 1, 1000);
>> plot(x, 1-x); grid on (+Enter)
```

avem graficul următor:

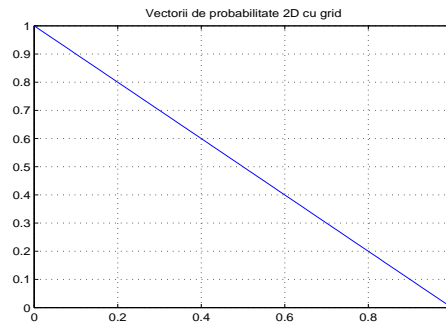


Figura 2.3: Distribuția în plan a vectorilor de probabilitate cu grid

Cu:

```
>> x=linspace(0, 1, 1000);
>> plot(x, 1-x); axis equal (+Enter)
```

obținem:




Figura 2.4: Distribuția în plan a vectorilor de probabilitate cu "axis equal"

S2.4 Să se figureze în MATLAB vectorii de probabilitate trei dimensionali.

Următorul program a fost sugerat de colegul Marian Ioan Munteanu și îi mulțumim pe această cale:

```
>>u=0:pi/25:pi/2;
>>v=0:pi/25:pi/2;
>>for i=1:length(u); for j=1:length(v); x(i, j)=(cos(u(i)))^2*(cos(v(j)))^2;
  y(i, j)=(cos(u(i)))^2*(sin(v(j)))^2; z(i, j)=(sin(u(i)))^2; end; end; %un singur rand !
>>mesh(x, y, z)
```

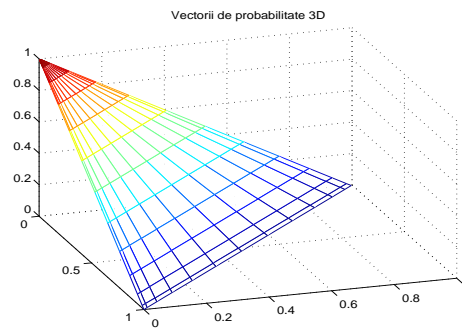


Figura 2.5: Distribuția în spațiu a vectorilor de probabilitate

Această parametrizare a fost aleasă pentru $p = (x, y, z) \in \mathbb{R}^3$ cu:

$$\begin{cases} x \in [0, 1], y \in [0, 1], z \in [0, 1] \\ x + y + z = 1. \end{cases}$$

Chapter 3

Probabilități: abordare modernă

În cursul precedent am introdus probabilitatea pe o mulțime finită Ω . Evident, există situații, foarte importante pentru practică, când suntem nevoiți să lucrăm cu o mulțime infinită. Din acest motiv introducem în acest Curs o altă abordare a noțiunii de probabilitate.

Fixăm o mulțime nevidă Ω de cardinal finit sau infinit; dacă Ω este în bijecție cu \mathbb{N} atunci spunem că este (*infinit*) *numărabilă*. Un element $\omega \in \Omega$ va fi numit, ca și anterior, *eveniment elementar*. Nu toate evenimentele din Ω , considerate ca submulțimi, sunt interesante pentru experimentul avut în vedere și de aceea vom selecta o clasă specială de astfel de evenimente:

Definiția 3.1 Familia \mathcal{F} de elemente din $\mathcal{P}(\Omega)$ o numim σ -algebră dacă:

a1) $\emptyset \in \mathcal{F}$

a2) dacă $A \in \mathcal{F}$ atunci și $\bar{A} = \Omega \setminus A \in \mathcal{F}$

a3) dacă $A_i \in \mathcal{F}$ cu $i \in \mathbb{N}$ atunci $\cup_{i \in \mathbb{N}} A_i \in \mathcal{F}$.

Perechea (Ω, \mathcal{F}) o numim *spațiu măsurabil* iar $A \in \mathcal{F}$ o numim \mathcal{F} -măsurabilă sau pe scurt *măsurabilă* atunci când \mathcal{F} este specificată.

Observații 3.2 i) Dacă \mathcal{C} este o familie oarecare de submulțimi în Ω atunci există o cea mai mică (în sensul incluziunii) σ -algebră ce conține pe \mathcal{C} . Aceasta se notează $\sigma(\mathcal{C})$ și se numește σ -algebra generată de \mathcal{C} .

ii) Din a1) și a2) rezultă că $\Omega \in \mathcal{F}$ pentru orice σ -algebră \mathcal{F} .

Definiția 3.3 Fie $n \in \mathbb{N}^*$ și spațiul \mathbb{R}^n al vectorilor n -dimensionali notați $\bar{x} = (x^1, \dots, x^n)$. Pe acest spațiu introducem:

PS) *produsul scalar Euclidian* $\langle, \rangle: \mathbb{R}^n \times \mathbb{R}^n \rightarrow \mathbb{R}$ dat de:

$$\langle \bar{x}, \bar{y} \rangle = x^1 y^1 + \dots + x^n y^n = \sum_{i=1}^n x^i y^i. \quad (3.1)$$

N) *norma Euclidiană* $\|, \|: \mathbb{R}^n \rightarrow \mathbb{R}_+$ dată de:

$$\|\bar{x}\| = \sqrt{\langle \bar{x}, \bar{x} \rangle}. \quad (3.2)$$

D) *distanța Euclidiană* $d: \mathbb{R}^n \times \mathbb{R}^n \rightarrow \mathbb{R}_+$:

$$d(\bar{x}, \bar{y}) = \|\bar{x} - \bar{y}\|. \quad (3.3)$$

Perechea $(\mathbb{R}^n, \langle, \rangle)$ o numim *spațiul Euclidian n -dimensional*.

Definiția 3.4 Fie $A \subset \mathbb{R}^n$. Spunem că A este *deschisă* dacă pentru orice $\bar{x} \in A$ există $r > 0$ așa încât orice $\bar{y} \in \mathbb{R}^n$ cu $d(\bar{x}, \bar{y}) < r$ este element din A . Deoarece mulțimea $B(\bar{x}, r) = \{\bar{y} \in \mathbb{R}^n; d(\bar{x}, \bar{y}) < r\}$ se numește *bila deschisă de centru \bar{x} și rază r* avem că A este deschisă dacă orice punct din A este centrul unei bile deschise conținute în A .

Definiția 3.5 Fie $\mathcal{D}(n)$ familia mulțimilor deschise din \mathbb{R}^n . Atunci σ -algebra generată de $\mathcal{D}(n)$ se notează $\mathcal{B}(n)$ iar un element din această σ -algebră se numește *mulțime boreliană*.

Definiția 3.6 Se numește *măsură probabilistică* sau *măsură de probabilitate* pe spațiul măsurabil (Ω, \mathcal{F}) o funcție $Pr : \mathcal{F} \rightarrow \mathbb{R}$ satisfăcând axiomele:

P1) $Pr(A) \geq 0$ pentru orice $A \in \mathcal{F}$

P2) $Pr(\Omega) = 1$

P3) dacă $\{A_i\}_{i \in \mathbb{N}} \in \mathcal{F}$ este un șir *disjunct* i.e. $A_i \cap A_j = \emptyset$ pentru $i \neq j$ atunci:

$$Pr(\cup_{i \in \mathbb{N}} A_i) = \sum_{i \in \mathbb{N}} Pr(A_i). \quad (3.4)$$

Tripletul $(\Omega, \mathcal{F}, Pr)$ se numește *spațiu de probabilitate*.

Exemplul 3.7 Avem că $\mathcal{P}(\Omega)$ este o σ -algebră pe Ω ; chiar cea mai mare în sensul incluziunii. Astfel, definiția 2.6 din Cursul 2 este un caz particular al precedentei definiții și deci pentru Ω finită avem un exemplu de măsură de probabilitate dat de relația (2.3).

Definiția 3.8 Fixăm din nou spațiul măsurabil (Ω, \mathcal{F}) . Aplicația $X : \Omega \rightarrow \mathbb{R}$ se numește *variabilă aleatoare* dacă pentru orice $r \in \mathbb{R}$ avem:

$$\{X < r\} := \{\omega \in \Omega; X(\omega) < r\} \in \mathcal{F}. \quad (3.5)$$

Dacă mulțimea valorilor lui X este finită sau numărabilă spunem că X este o *variabilă aleatoare discretă* iar în caz contrar o numim *variabilă aleatoare continuă*; în particular dacă X ia un număr finit de valori spunem că este o *variabilă aleatoare simplă*.

Observația 3.9 Se poate arăta că următoarele afirmații sunt echivalente pentru $X : (\Omega, \mathcal{F}) \rightarrow \mathbb{R}$:

1) $\{X < r\} \in \mathcal{F}$ pentru orice $r \in \mathbb{R}$

2) $\{a \leq X \leq b\} \in \mathcal{F}$ pentru orice a și b din \mathbb{R} .

În particular, luând $a = b = x \in \mathbb{R}$ avem că pentru o variabilă aleatoare $\{X = x\} \in \mathcal{F}$ ceea ce permite introducerea următoarei noțiuni:

Definiția 3.10 Fie X o variabilă aleatoare discretă pe spațiul de probabilitate $(\Omega, \mathcal{F}, Pr)$. Se numește *distribuția* lui X tabloul:

$$X : \begin{pmatrix} x_1 & x_2 & x_3 & \dots \\ p_1 & p_2 & p_3 & \dots \end{pmatrix} \quad (3.6)$$

unde x_i sunt valorile lui X iar $p_i = Pr(\{\omega \in \Omega; X(\omega) = x_i\})$.

În particular, distribuția unei variabile aleatoare simple este:

$$X : \begin{pmatrix} x_1 & x_2 & x_3 & \dots & x_n \\ p_1 & p_2 & p_3 & \dots & p_n \end{pmatrix} \quad (3.7)$$

unde n este numărul valorilor lui X .

Exemplul 3.11 (Urna cu bile de două culori) O urnă conține a bile albe și b bile negre. Fie A evenimentul extragerii unei bile albe și B evenimentul extragerii unei bile negre. Fie probabilitățile asociate:

$$p := p(A) = \frac{a}{a+b} \quad q = p(B) = \frac{b}{a+b}. \quad (3.8)$$

Avem deci $\Omega = \{1, \dots, a+b\}$ și fie $X : \Omega \rightarrow \mathbb{R}$ ce ia valoarea 1 când apare o bilă albă și 0 pentru o bilă neagră. Avem că X este o variabilă aleatoare în raport cu σ -algebra generată de $\mathcal{C} = \{A, B\}$. Distribuția lui X este:

$$X : \begin{pmatrix} 1 & 0 \\ p & q \end{pmatrix}. \quad (3.9)$$

O astfel de variabilă aleatoare se cheamă *de tip Bernoulli*.

Seminar 3

S3.1 Să se studieze urna cu număr egal de bile.

Soluție Avem aceeași variabilă aleatoare ca în cazul monedei:

$$X : \begin{pmatrix} 1 & 0 \\ \frac{1}{2} & \frac{1}{2} \end{pmatrix}. \quad (3.10)$$

Putem desena în Matlab această distribuție:

```
>> x=[0 1];
>> y=[0.5 0.5];
>> plot(x, y, 'ok', 'markerfacecolor', 'k', 'markersize', 10) (+Enter)
```

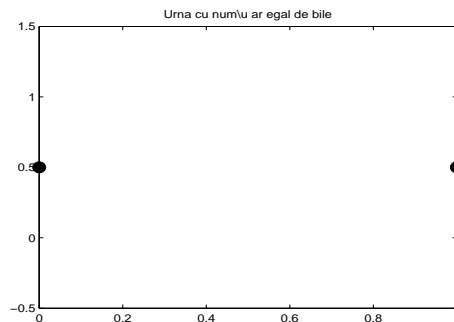


Figura 3.1: Schema bilei întoarse

Dacă realocăm valorile variabilei aleatoare așa încât să înceapă de la 1 și nu de la zero:

$$X : \begin{pmatrix} 1 & 2 \\ \frac{1}{2} & \frac{1}{2} \end{pmatrix}. \quad (3.11)$$

putem reprezenta în Matlab astfel:

```
>> y=[0.5 0.5];
>> plot(y, 'ok', 'markerfacecolor', 'k') (+Enter)
```

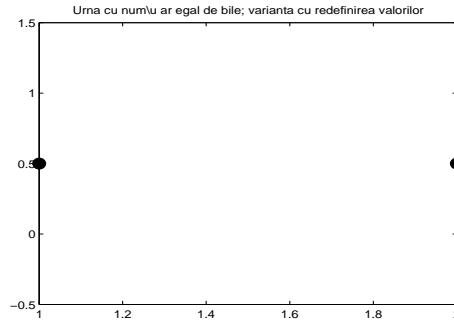


Figura 3.2: Varianta distribuției Bernoulli

S3.2 Să se reprezinte în MATLAB zarul.

Soluție Avem:

$$X : \begin{pmatrix} 1 & 2 & 3 & 4 & 5 & 6 \\ \frac{1}{6} & \frac{1}{6} & \frac{1}{6} & \frac{1}{6} & \frac{1}{6} & \frac{1}{6} \end{pmatrix}. \quad (3.12)$$

și programul MATLAB:

```
>> x=[1 2 3 4 5 6]; sau x=[1:6];
>> y=[1/6 1/6 1/6 1/6 1/6 1/6];
>> plot(x, y, 'o') (+Enter)
```

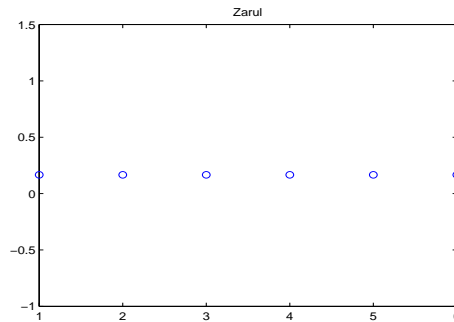


Figura 3.3: Zarul

Am utilizat comanda $plot(x, y, string)$ unde $string$ poate combina cel mult trei elemente: culoare, marker pentru punctul y și stilul liniei.

Culorile sunt:

r	Red
g	Green
b	Blue
c	Cyan
m	Magenta
y	Yellow
k	Black
w	White

Markerele în MATLAB

o	Circle
*	Asterisk
.	Point
+	Plus
x	Cross
s	Square
d	Diamond
^	Upward triangle
v	Downward triangle
>	Right triangle
<	Left triangle
p	Five-point star
h	Six-point star

Am ales 'o' pentru că altfel punctele de pe linia orizontală nu s-ar fi distins. Astfel, programul simplu:

```
>>x=[1:6];
>>y=[1/6 1/6 1/6 1/6 1/6 1/6];
plot(x, y) (+Enter)
```

dă figura următoare:




Figura 3.4: Zarul cu plot(x, y)

Stiluri de linie MATLAB

-	Solid line (default)
- -	Dashed line
· · ·	Dotted line
- ·	Dash-dot line

Exemple:

1) $plot(x, y, 'r * - -')$ pune un asterix roșu în punctul $M(x, y)$ și unește punctele cu o "red dashed line".

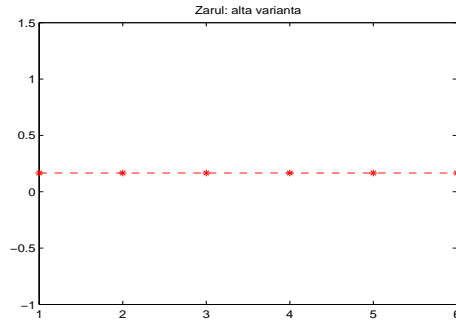


Figura 3.5

2) $plot(x, y, 'y+')$ pune o cruciuliță galbenă în puncte și nu le unește.

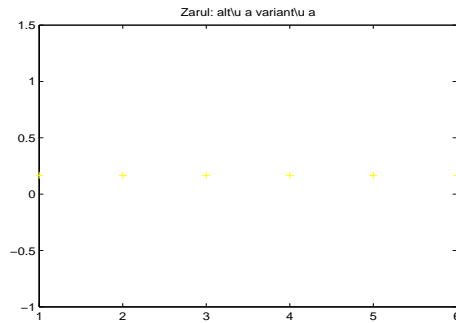


Figura 3.6

3) $plot(x, y, 'kd :')$ unește cu o linie punctată punctele marcate cu diamante.



Figura 3.7

Cele trei elemente din 'string' pot apare în orice ordine; astfel: $plot(x, y, 'ms - -')$ și $plot(x, y, 's - -m')$ sunt echivalente.

S3.3 Să se reprezinte în MATLAB variabila aleatoare:

$$X : \begin{pmatrix} 1 & 2 & 3 & 4 \\ \frac{1}{8} & \frac{1}{4} & \frac{1}{8} & \frac{1}{2} \end{pmatrix}.$$

Soluție Programul:

```
>>x=[1:4];
>>y=[1/8 1/4 1/8 1/2];
>>plot(x, y) (+Enter)
```

dă:




Figura 3.8

3.4 Să se calculeze cu MATLAB produsul scalar dintre vectorii $\bar{x} = (1, 3, 5, 7)$ și $\bar{y} = (2, 4, 6, 8)$ și normele lor.

Soluție Avem:

$$\langle \bar{x}, \bar{y} \rangle = \bar{x} \cdot \bar{y}^t = (x^1, \dots, x^n) \cdot \begin{pmatrix} y^1 \\ \vdots \\ y^n \end{pmatrix} \quad (3.13)$$

unde indicele superior t semnifică transpusa matricii respective.

În MATLAB transpusa se notează cu ' iar produsul matricilor cu *. Pentru normă avem comanda $norm(x)$.

Deci programul cerut este:

```
>>x=[1 3 5 7];
>>y=[2 4 6 8];
>>x*y' (+Enter)
>>norm(x) (+Enter)
>>norm(y) (+Enter)
```

Avem $\langle \bar{x}, \bar{y} \rangle = 2 + 12 + 30 + 56 = 100$, $\|\bar{x}\| = \sqrt{1 + 9 + 25 + 49} = \sqrt{84} = 2\sqrt{21}$ și $\|\bar{y}\| = \sqrt{4 + 16 + 36 + 64} = \sqrt{120} = 2\sqrt{30}$. Cu programul anterior obținem:

```
>>ans =
    100
>>ans =
    9.1652
>>ans =
    10.9545
```

Definiția 3.11 Vectorii $\bar{x}, \bar{y} \in \mathbb{R}^n$ se numesc *ortogonali* sau *perpendicularari* dacă $\langle \bar{x}, \bar{y} \rangle = 0$.

Mai general avem noțiunea de unghi:

Definiția 3.12 Dați vectorii nenuli $\bar{x}, \bar{y} \in \mathbb{R}^n$ unghiul dintre ei este dat de:

$$\cos \phi = \frac{\langle \bar{x}, \bar{y} \rangle}{\|\bar{x}\| \|\bar{y}\|}. \quad (3.14)$$

Deci unghiul dintre vectorii ortogonali este $\phi = \frac{\pi}{2}$.

S3.5 Să se verifice că următorii vectori sunt ortogonali: $\bar{x} = (1, 2, -3)$, $\bar{y} = (4, 4, 4)$.

Definiția 3.13 Un set de n vectori ortogonali doi câte doi și de normă 1 spunem că formează o *bază ortonormată* în \mathbb{R}^n . Un vector de normă 1 se numește *versor* sau *vector unitar*.

S3.6 Să se verifice că următorul set de vectori este o bază ortonormată în spațiu:

$$\begin{cases} e_1 = (1, 0, 0) \\ e_2 = (0, 1, 0) \\ e_3 = (0, 0, 1). \end{cases} \quad (3.15)$$

Această bază se numește *baza canonică* din \mathbb{R}^3 și se extinde natural la orice \mathbb{R}^n .

S3.7 Să se arate că următorii vectori constituie o bază ortonormată în spațiu:

$$\begin{cases} x = \frac{1}{3}(-1, 2, 2) \\ y = \frac{1}{3}(2, -1, 2) \\ z = \frac{1}{3}(2, 2, -1). \end{cases}$$

Soluție O metodă de arăta că n vectori constituie o bază ortonormată este următoarea: formăm o matrice pătratică de ordin n cu acești vectori scriși pe coloană. Atunci avem concluzia dorită doar dacă:

$$A \cdot A^t = I_n \quad (2.15)$$

unde I_n este *matricea unitate de ordin n* :

$$I_n = \begin{pmatrix} 1 & \dots & 0 \\ 0 & \dots & 0 \\ 0 & \dots & 1 \end{pmatrix} \quad (2.16)$$

adică matricea ce are 1 pe diagonala principală și în rest 0. O matrice ce satisface (2.15) se numește *matrice ortogonală* de ordin n .

Observația 3.8 Produsul a două matrici pătratice se efectuează cu \cdot nu cu $*$ simplu ! Liniile unei matrici se separă cu $;$.

Exemplu: Matricea corespunzătoare exercițiului dat este:

$$\gg A = [-1/3 \ 2/3 \ 2/3; \ 2/3 \ -1/3 \ 2/3; \ 2/3 \ 2/3 \ -1/3]$$

Chapter 4

Funcția de repartiție a unei variabile aleatoare

Fie $(\Omega, \mathcal{F}, Pr)$ un spațiu de probabilitate și $X : \Omega \rightarrow \mathbb{R}$ o variabilă aleatoare pe spațiul suport Ω .

Definiția 4.1 Funcția $F : \mathbb{R} \rightarrow [0, 1]$:

$$F(x) = Pr(\{X < x\}) \quad (4.1)$$

se numește *funcția de repartiție a lui X*.

Avem o exprimare concretă a acestei funcții pentru cazul discret prin:

Propoziția 4.2 *Funcția de repartiție a unei variabile aleatoare discrete este un funcție în scară.*

Demonstrație Presupunem:

$$X : \begin{pmatrix} x_1 & x_2 & x_3 & \dots \\ p_1 & p_2 & p_3 & \dots \end{pmatrix}.$$

Atunci:

$$F(x) = \begin{cases} 0, & x \in (-\infty, x_1] \\ \sum_{i=1}^n p_i, & x \in (x_n, x_{n+1}), n \geq 1 \end{cases} \quad (4.2)$$

ceea ce dă concluzia. \square

Proprietățile de bază ale funcției de repartiție sunt date de:

Propoziția 4.3 *Funcția de repartiție a unei variabile aleatoare oarecare satisface următoarele proprietăți:*

FR1) *este monoton crescătoare.*

FR2) $\lim_{x \rightarrow -\infty} F(x) = 0, \lim_{x \rightarrow +\infty} F(x) = 1.$

FR3) *F este continuă la stânga în orice punct $x \in \mathbb{R}$.*

Reciproc, o funcție $F : \mathbb{R} \rightarrow \mathbb{R}$ ce satisface aceste trei proprietăți este funcția de repartiție a unei variabile aleatoare

Avem de asemenea o utilizare a funcției de repartiție în determinarea de probabilități (în continuare, pentru simplificarea scrierii vom nota P în loc de Pr):

Propoziția 4.4 *Funcția de repartiție are următoarele proprietăți:*

FR4) $F(x+0) = F(x) + P(X = x)$ pentru orice $x \in \mathbb{R}$; deci F este continuă în punctul x dacă și numai dacă $P(X = x) = 0$.

FR5) pentru intervale mărginite arbitrare avem:

$$\begin{cases} P(a \leq X < b) = F(b) - F(a) \\ P(a < X < b) = F(b) - F(a+0) \\ P(a \leq X \leq b) = F(b+0) - F(a) \\ P(a < X \leq b) = F(b+0) - F(a+0). \end{cases} \quad (4.3)$$

O altă noțiune foarte importantă în teoria variabilelor aleatoare este:

Definiția 4.5 Fie X o variabilă aleatoare (continuă) și F funcția sa de repartiție. Dacă există o funcție $\rho : \mathbb{R} \rightarrow [0, +\infty)$ așa încât pentru orice $x \in \mathbb{R}$ avem:

$$F(x) = \int_{-\infty}^x \rho(t) dt \quad (4.4)$$

atunci ρ se numește *densitatea de repartiție* sau *densitatea de probabilitate* a lui X .

Proprietățile acestei noi funcții sunt date de:

Propoziția 4.6 *Fie X o variabilă aleatoare ce admite densitatea ρ . Atunci:*

D1) $P(a \leq X \leq b) = \int_a^b \rho(x) dx$.

D2) $\int_{-\infty}^{+\infty} \rho(x) dx = +1$.

D3) F este derivabilă în orice punct $x \in \mathbb{R}$ în care ρ este continuă și atunci:

$$F'(x) = \rho(x). \quad (4.5)$$

Exemple de variabile aleatoare remarcabile

I) Discrete

1) *variabilă aleatoare binomială*

$$X : \left(C_n^k p^k q^{n-k} \right) \quad (4.6)$$

cu $k \in \{0, 1, \dots, n\}$ iar $p, q \in [0, 1]$ satisfac $p + q = 1$. Se mai numește și *schema bilei revenite* deoarece modelează următorul experiment: avem o urnă cu a bile albe și b bile negre și efectuăm n extrageri, de fiecare dată punând bila extrasă înapoi în urnă. Vrem probabilitatea ca să apară de k ori o bilă albă.

Același experiment se poate modela și altfel: avem n urne cu un conținut identic de bile, ca mai sus. Din fiecare urnă extragem o singură bilă. Denumirea de binomială se datorează faptului că probabilitățile respective sunt exact coeficienții din dezvoltarea *binomului lui Newton*:

$$(q + p)^n = \sum_{k=0}^n C_n^k p^k q^{n-k}. \quad (4.7)$$

Există și o generalizare numită *variabilă aleatoare multinomială* pentru care trimitem la pagina 32 din:

I. Gh. Șabac și alții, *Matematici speciale*, vol. II, EDP, București, 1983.

2) Variabila aleatoare X este *de tip Poisson* cu parametrul $\lambda \in (0, +\infty)$ dacă are o distribuție de forma:

$$X : \left(\begin{array}{c} k \in \mathbb{N} \\ \frac{\lambda^k}{k!} e^{-\lambda} \end{array} \right). \quad (4.8)$$

O lege de tip Poisson se mai numește *lege a evenimentelor rare* și se poate obține ca un caz limită al legii binomiale pentru p foarte mic și n foarte mare dar astfel încât produsul $np = \lambda$ este constant.

II) Continue

3) Fie numerele reale μ, σ cu $\sigma > 0$. Variabila aleatoare X se numește *de tip Gauss* sau spunem că X *satisface legea normală* $N(\mu, \sigma)$ dacă X admite o densitate de repartiție:

$$\rho(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-\frac{(x-\mu)^2}{2\sigma^2}\right]. \quad (4.9)$$

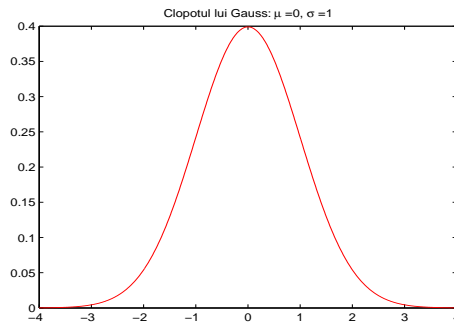


Figura 4.1: Curba clopot

4) Variabila aleatoare X are *repartiție uniformă* pe $[a, b] \subset \mathbb{R}$ cu a, b finite dacă admite:

$$\rho(x) = \begin{cases} \frac{1}{b-a}, & x \in [a, b] \\ 0, & x \in \mathbb{R} \setminus [a, b]. \end{cases} \quad (4.10)$$

Seminar 4

S4.1 Să se studieze variabila aleatoare:

$$X : \left(\begin{array}{ccc} -1 & 0 & 1 \\ \frac{1}{2} & \frac{1}{3} & \frac{1}{6} \end{array} \right).$$

Soluție X determină pe mulțimea Ω a evenimentelor elementare partiția $\{A_1, A_2, A_3\}$ cu $Pr(A_1) = \frac{1}{2}$, $Pr(A_2) = \frac{1}{3}$, $Pr(A_3) = \frac{1}{6}$ și avem:

$$\{X < x\} = \begin{cases} \emptyset, & x \in (-\infty, -1] \\ A_1, & x \in (-1, 0] \\ A_1 \cap A_2, & x \in (0, 1] \\ \Omega, & x \in (1, +\infty). \end{cases}$$

Funcția de repartiție a lui X este:

$$F(x) = \begin{cases} 0, & x \in (-\infty, -1] \\ \frac{1}{2}, & x \in (-1, 0] \\ \frac{5}{6}, & x \in (0, 1] \\ 1, & x \in (1, +\infty). \end{cases}$$

Putem desena în Matlab această distribuție:

```
>>x=[-1 0 1];
>>y=[1/2 1/3 1/6];
>>plot (x, y) (+Enter)
```

sau:

```
>>plot (x, y, 'ok', 'markerfacecolor', 'k', 'markersize', 10) (+Enter)
```

De asemeni, putem reprezenta grafic funcția de repartiție obținută:

```
>>x1=-3:.01:-1; y1=0;
>>x2=-0.99:.01:0; y2=1/2;
>>x3=0.01:.01:1; y3=5/6;
>>x4=1.01:.01:3; y4=1;
>>plot(x1, y1, x2, y2, x3, y3, x4, y4); axis equal
```




Figura 4.2

De asemeni, pentru o mai bună vizualizare putem folosi culori; ultima linie:

```
>>plot(x1, y1, 'r', x2, y2, 'g', x3, y3, 'b', x4, y4, 'm'); axis equal
dă:
```




Figura 4.3

S4.2 Se cer repartițiile variabilelor aleatoare: X_i =numărul de apariții ale banului la i aruncări ale monezii pentru $i = 1, 2$.

Soluție Avem:

$$X_1 : \begin{pmatrix} 0 & 1 \\ \frac{1}{2} & \frac{1}{2} \end{pmatrix} \quad (4.11)$$

respectiv:

$$X_2 : \begin{pmatrix} 0 & 1 & 2 \\ \frac{1}{4} & \frac{1}{2} & \frac{1}{4} \end{pmatrix} \quad (4.12)$$

Reprezentarea cu bare a acestor variabile aleatoare este dată de:

```
>>x=[0 1];
>>y=[1/2 1/2];
>>bar(x, y); axis equal (+Enter)
```

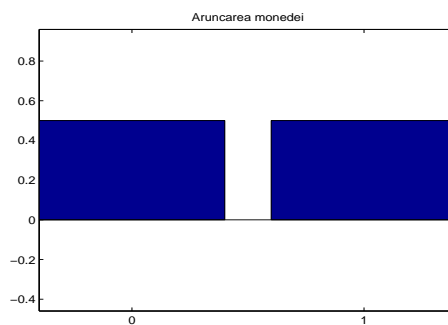


Figura 4.4

respectiv:

```
>>x=[0 1 2];
>>y=[1/4 1/2 1/4];
>>bar(x, y); axis equal (+Enter)
```

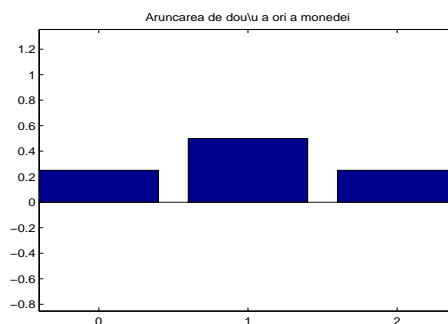


Figura 4.5

S4.3 Se dă variabila aleatoare:

$$X : \begin{pmatrix} 0 & 1 & 2 & 3 \\ p^2 & \frac{7p}{4} & \frac{1}{3} & \frac{1}{6} \end{pmatrix}.$$

Se cere probabilitatea ca X să ia o valoare cel mult egală cu 2.

Soluție Mai întâi aflăm valoarea lui p punând condiția ca suma elementelor inferioare să fie 1. Avem:

$$p^2 + \frac{7}{4}p - \frac{1}{2} = 0$$

Discriminantul acestei ecuații de gradul doi este:

$$\Delta = \frac{49}{16} + \frac{4}{2} = \frac{49}{16} + \frac{32}{16} = \frac{81}{16} = \left(\frac{9}{4}\right)^2.$$

Avem atunci soluțiile:

$$p_1 = \frac{-\frac{7}{4} - \frac{9}{4}}{2} = -\frac{4}{2} = -2$$

o soluție imposibilă deoarece termenii inferiori trebuie să fie pozitivi respectiv soluția:

$$p_2 = \frac{-\frac{7}{4} + \frac{9}{4}}{2} = \frac{1}{4}.$$

Deci X are distribuția:

$$X : \begin{pmatrix} 0 & 1 & 2 & 3 \\ \frac{1}{16} & \frac{7}{16} & \frac{1}{3} & \frac{1}{6} \end{pmatrix}.$$

Evenimentul $X \leq 2$ se poate scrie:

$$\{X \leq 2\} = \{X = 0\} \cup \{X = 1\} \cup \{X = 2\}$$

și deci:

$$P(\{X \leq 2\}) = P(\{X = 0\}) + P(\{X = 1\}) + P(\{X = 2\}) = \frac{1}{16} + \frac{7}{16} + \frac{1}{3} = \frac{1}{2} + \frac{1}{3} = \frac{5}{6}.$$

Evident, pentru problema pusă puteam raționa și astfel:

$$\{X \leq 2\} = C\{X = 3\}$$

ceea ce dă:

$$P(\{X \leq 2\}) = 1 - P(\{X = 3\}) = 1 - \frac{1}{6} = \frac{5}{6}.$$

În termeni de funcția de repartiție avem că probabilitatea cerută este exact $F(2) + P(\{X = 2\})$. Rezultă că:

$$F(2) = \frac{5}{6} - \frac{1}{3} = \frac{1}{2}.$$

Chapter 5

Valori medii. Momente, dispersie, corelație

Definiția 5.1 Fie X o variabilă aleatoare.

i) Dacă X este discretă cu expresia:

$$X : \left(\begin{array}{c} x_i \\ p_i \end{array} \right)_{i \in I \subset \mathbb{N}}$$

atunci numărul real:

$$\bar{x} = M(X) := \sum_{i \in I} p_i x_i \quad (5.1)$$

se numește *media* lui X .

ii) Dacă X este continuă și admite densitatea de repartiție ρ atunci definim *media* lui X prin:

$$\bar{x} = M(X) := \int_{-\infty}^{+\infty} x \rho(x) dx. \quad (5.2)$$

iii) Fie $n \in \mathbb{N}^*$. Valoarea medie a variabilei aleatoare X^n :

$$M_n(X) := M(X^n) \quad (5.3)$$

se numește *momentul de ordin n* al lui X .

Exemplul 5.2 Dacă X este discretă atunci:

$$M_n(X) = \sum_{i \in I} p_i x_i^n \quad (5.4)$$

iar dacă X este continuă și admite densitatea de repartiție ρ atunci:

$$M_n(X) = \int_{-\infty}^{+\infty} x^n \rho(x) dx. \quad (5.5)$$

Propoziția 5.3 Fie variabilele aleatoare X, Y și numărul real a . Avem:

M1) $M(a + X) = a + M(X)$

M2) $M(aX) = aM(X)$.

M3) $\inf X \leq M(X) \leq \sup X$.

M4) $M(X + Y) = M(X) + M(Y)$.

Demonstrație Vom face demonstrația pentru v. a. simple.

M1) Avem:

$$a + X : \begin{pmatrix} a + x_0 & a + x_1 & \dots & a + x_n \\ p_0 & p_1 & \dots & p_n \end{pmatrix} \quad (5.6)$$

și:

$$aX : \begin{pmatrix} ax_0 & ax_1 & \dots & ax_n \\ p_0 & p_1 & \dots & p_n \end{pmatrix}. \quad (5.7)$$

Rezultă:

$$M(a + X) = \sum p_i(a + x_i) = a \sum p_i + M(X) = a + M(X)$$

M2)

$$M(aX) = \sum p_i(ax_i) = a \sum p_i x_i.$$

M3) Înmulțim cu p_i relația:

$$\inf X \leq x_i \leq \sup X$$

și însumăm după i .

M3) $X + Y$ are distribuția:

$$X + Y : \begin{pmatrix} x_i + y_j \\ r_{ij} \end{pmatrix} \quad (5.8)$$

cu $r_{ij} = Pr(A_i \cap B_j)$; a se vedea și Exemplul 5.7 de mai jos. Avem imediat:

$$\begin{cases} \sum_{j \in J} r_{ij} = p_i \\ \sum_{i \in I} r_{ij} = q_j \end{cases} \quad (5.9)$$

Prin urmare:

$$M(X + Y) = \sum_{i \in I} \left(\sum_{j \in J} r_{ij} \right) x_i + \sum_{j \in J} \left(\sum_{i \in I} r_{ij} \right) y_j = \sum_{i \in I} p_i x_i + \sum_{j \in J} q_j y_j$$

ceea ce dă concluzia. \square

Definiția 5.4 Momentul *centrat* de ordinul doi:

$$D(X) = M_2(X - \bar{x}) \quad (5.10)$$

se numește *dispersia* sau *varianța* lui X .

Observația 5.5 Dispersia, așa cum îi arată numele, este un indicator al împrăștierii valorilor lui X față de valoarea sa medie \bar{x} și o formulă utilă de calcul este:

$$D(X) = M_2(X) - \bar{x}^2. \quad (5.11)$$

Motivația pentru introducerea acestui indicator de împrăștiere este aceea că valoarea medie este, în general, insuficientă pentru determinarea unei variabile aleatoare. Astfel, două v. a. simple pot lua același număr de valori și pot avea aceeași medie, dar, în timp ce una ia valori apropiate mediei, cealaltă ia valori foarte îndepărtate. Avem exemplul următor:

$$X_1 : \begin{pmatrix} -1 & 1 \\ \frac{1}{2} & \frac{1}{2} \end{pmatrix}$$

$$X_2 : \begin{pmatrix} -1000 & 1000 \\ \frac{1}{2} & \frac{1}{2} \end{pmatrix}$$

ambele cu media nulă.

Demonstrația formulei (4.9) este imediată:

$$D(X) = M((X - \bar{x})^2) = M(X^2 - 2\bar{x}X + \bar{x}^2) = M(X^2) - 2\bar{x}M(X) + \bar{x}^2 = M(X^2) - 2\bar{x}^2 + \bar{x}^2$$

ceea ce dă concluzia.

Definiția 5.6 Fie X și Y două variabile aleatoare. Definim *produsul* lor prin $XY : \mathcal{F} \rightarrow \mathbb{R}$:

$$(XY)(\omega) = X(\omega) \cdot Y(\omega) \quad (5.12)$$

unde, în membrul drept considerăm produsul numerelor reale $X(\omega)$ și $Y(\omega)$.

Exemplul 5.7 Presupunem că X și Y sunt discrete cu:

$$X : \begin{pmatrix} x_i \\ p_i \end{pmatrix}_{i \in I \subset \mathbb{N}}, \quad Y : \begin{pmatrix} y_j \\ q_j \end{pmatrix}_{j \in J \subset \mathbb{N}}.$$

Deci $p_i = Pr(A_i)$ cu $A_i = \{X = x_i\}$ și $q_j = Pr(B_j)$ cu $B_j = \{Y = y_j\}$. Atunci:

$$XY : \begin{pmatrix} x_i y_j \\ r_{ij} \end{pmatrix}_{(i \in I, j \in J)} \quad (5.13)$$

cu $r_{ij} = Pr(A_i \cap B_j)$.

Definiția 5.8 i) Variabilele aleatoare X, Y se numesc *independente* dacă pentru orice $x, y \in \mathbb{R}$ avem:

$$P(\{X < x\} \cap \{Y < y\}) = P(\{X < x\}) \cdot P(\{Y < y\}). \quad (5.14)$$

ii) Date variabilele aleatoare X, Y numerele reale:

$$C_{XY} = M(XY) - M(X)M(Y) \quad (5.15)$$

$$\rho_{XY} = \frac{C_{XY}}{\sqrt{D(X)D(Y)}} \quad (5.16)$$

se numesc *covarianța* (sau *corelația*) respectiv *coeficientul de corelație* al lor. Dacă $C_{XY} = 0$ spunem că X și Y sunt *necorelate* iar dacă $C_{XY} \neq 0$ atunci spunem că X și Y sunt *corelate*.

Propoziția 5.9 Dacă X și Y sunt v. a. independente atunci:

$$M(XY) = M(X) \cdot M(Y). \quad (5.17)$$

Seminarul 5

S5.1 Se cere media și dispersia variabilei aleatoare binomiale.

Soluție Să derivăm în raport cu x formula binomului lui Newton:

$$(q + px)^n = \sum_{k=0}^n C_n^k q^{n-k} p^k x^k. \quad (5.18)$$

Obținem:

$$np(q + px)^{n-1} = \sum_{k=0}^n C_n^k q^{n-k} p^k k x^{k-1}. \quad (5.19)$$

Facem $x = 1$ în ultima relație și obținem:

$$np = \sum_{k=0}^n k \cdot C_n^k q^{n-k} p^k \quad (5.20)$$

care este exact media variabilei aleatoare binomiale. Deci:

$$M(X) = np. \quad (5.21)$$

Înmulțim (5.19) cu x :

$$np(q + px)^{n-1}x = \sum_{k=0}^n C_n^k q^{n-k} k x^k \quad (5.22)$$

și derivăm ultima relație:

$$n(n-1)p^2(q + px)^{n-2}x + np(q + px)^{n-1} = \sum_{k=0}^n C_n^k q^{n-k} k^2 p^k x^{k-1}. \quad (5.23)$$

Înlocuim din nou $x = 1$ și avem:

$$n(n-1)p^2 + np = \sum_{k=0}^n k^2 \cdot C_n^k q^{n-k} p^k \quad (5.24)$$

care este exact $M_2(X)$.

Pentru dispersie folosim formula (5.10):

$$D(X) = n(n-1)p^2 + np - n^2p^2 = -np^2 + np = np(1-p) = npq. \quad (5.25)$$

S5.2 Se aruncă 4 zaruri și se cere valoarea medie a numărului de puncte obținute.

Soluție Deoarece:

$$M(\text{zar}) = \frac{1}{6}(1 + 2 + \dots + 6) = \frac{1}{6} \cdot \frac{6 \cdot 7}{2} = \frac{7}{2} \quad (5.26)$$

rezultă că pentru n zaruri avem:

$$M(n \text{ zaruri}) = \frac{7n}{2}. \quad (5.27)$$

În cazul $n = 4$ obținem: $M = 14$. \square

S5.3 Se aruncă 4 zaruri și se cere valoarea medie a produsului numărului de puncte ce apar.

Soluție Fie X_i numărul de puncte de la zarul $i \in \{1, 2, 3, 4\}$. Aceste v. a. sunt independente și deci:

$$M(X_1 X_2 X_3 X_4) = M(X_1)M(X_2)M(X_3)M(X_4) = \left(\frac{7}{2}\right)^4 = \frac{2401}{16}.$$

S5.4 Se cere media și dispersia variabilei aleatoare de tip Poisson cu parametrul $\lambda \in (0, +\infty)$.

Soluție Avem:

$$M(X) = \sum_{k \geq 0} k \frac{\lambda^k}{k!} e^{-\lambda} = \lambda e^{-\lambda} \sum_{k \geq 1} \frac{\lambda^{k-1}}{(k-1)!} = \lambda e^{-\lambda} \cdot e^{\lambda} = \lambda. \quad (5.28)$$

$$M_2(X) = \sum_{k \geq 0} k^2 \frac{\lambda^k}{k!} e^{-\lambda} = \lambda e^{-\lambda} \sum_{k \geq 1} k \frac{\lambda^{k-1}}{(k-1)!} = \lambda e^{-\lambda} \sum_{p \geq 0} (p+1) \frac{\lambda^p}{p!}.$$

Deci:

$$M_2(X) = \lambda e^{-\lambda} \left(\sum_{p \geq 1} \frac{\lambda^p}{(p-1)!} + \sum_{p \geq 0} \frac{\lambda^p}{p!} \right) = \lambda e^{-\lambda} \cdot (\lambda e^{\lambda} + e^{\lambda}) = \lambda(\lambda + 1). \quad (5.29)$$

Rezultă:

$$D(X) = \lambda^2 + \lambda - \lambda^2 = \lambda. \quad (5.30)$$

S5.5 Se cere media și dispersia variabilei aleatoare de tip normal $N(\mu, \sigma)$.

Soluție Valoare medie este:

$$\begin{aligned} M(X) &= \int_{-\infty}^{+\infty} x \rho(x) dx = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^{+\infty} x \exp\left[-\frac{(x-\mu)^2}{2\sigma^2}\right] dx = \\ &= \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^{+\infty} (x-m) \exp\left[-\frac{(x-\mu)^2}{2\sigma^2}\right] dx + \frac{m}{\sigma\sqrt{2\pi}} \int_{-\infty}^{+\infty} \exp\left[-\frac{(x-\mu)^2}{2\sigma^2}\right] dx. \end{aligned}$$

În prima integrală facem schimbarea de variabilă $x - m = t$ și obținem:

$$I_1 = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^{+\infty} t \exp\left[-\frac{t^2}{2\sigma^2}\right] dt = 0$$

deoarece funcția de sub integrală este impară: $F(-t) = -F(t)$. Pentru a doua integrală facem schimbarea de variabilă: $x - m = \sigma\sqrt{2\pi} \cdot t$ și avem:

$$I_2 = \frac{\mu}{\sigma\sqrt{2\pi}} \int_{-\infty}^{+\infty} \sigma\sqrt{2\pi} e^{-t^2} dt = \mu$$

deoarece:

$$\int_{-\infty}^{+\infty} e^{-t^2} dt = \sqrt{\pi}. \quad (5.31)$$

În concluzie:

$$M(X) = \mu. \quad (5.32)$$

Să observăm că:

$$\frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^{+\infty} \rho(x) dx = \frac{\sigma\sqrt{2\pi}}{\sigma\sqrt{2\pi}} = 1 \quad (5.32)$$

ceea ce confirmă buna definire a variabilei aleatoare normale.

Pentru calculul dispersiei:

$$D(X) = \int_{-\infty}^{+\infty} (x - \mu)^2 \rho(x) dx$$

vom integra prin părți:

$$D(X) = \frac{1}{\sigma\sqrt{2\pi}} \left[-\sigma^2(x - \mu) \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right) \Big|_{-\infty}^{+\infty} + \sigma^2 \int_{-\infty}^{+\infty} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right) dx \right].$$

Primul termen este nul din nou din motive de (im)paritate iar integrala a fost calculată deja.

În concluzie:

$$D(X) = \sigma^2. \quad (5.32)$$

Vedem astfel motivația pentru notația $N(\mu, \sigma)$. \square

Dacă X și Y sunt independente atunci ele sunt necorelate. Reciproca nu este adevărată după cum o arată exercițiul următor:

S5.6 Se cere covarianța următoarelor v. a.:

$$X : \begin{pmatrix} -2 & -1 & 1 & 2 \\ \frac{1}{4} & \frac{1}{4} & \frac{1}{4} & \frac{1}{4} \end{pmatrix} \quad Y : \begin{pmatrix} -1 & 1 \\ \frac{1}{2} & \frac{1}{2} \end{pmatrix}.$$

Soluție Avem $M(X) = M(Y) = 0$. Produsul XY ia valorile $z_{ij} = x_{1i}y_j$ cu:

$$\begin{cases} z_{11} = 2, z_{21} = 1, z_{31} = -1, z_{41} = -2 \\ z_{12} = -2, z_{22} = -1, z_{32} = 1, z_{42} = 2. \end{cases}$$

Avem probabilitățile:

$$\begin{cases} r_{11} = 0, r_{21} = \frac{1}{4}, r_{31} = \frac{1}{4}, r_{41} = 0 \\ r_{12} = \frac{1}{4}, r_{22} = 0, r_{32} = 0, r_{42} = \frac{1}{4}. \end{cases}$$

Deci:

$$XY : \begin{pmatrix} -2 & -1 & 1 & 2 \\ \frac{1}{4} & \frac{1}{4} & \frac{1}{4} & \frac{1}{4} \end{pmatrix}.$$

Rezultă că $M(XY) = 0 = M(X)M(Y)$ și deci $C_{XY} = 0$. Avem și $p_i q_j = \frac{1}{8} \neq r_{ij}$ pentru unele valori ale indicilor i, j . Deci cele două variabile aleatoare sunt necorelate dar nu sunt independente. \square

Chapter 6

Teoria deciziilor

Fixăm A o mulțime nevidă ale cărei elemente "a" le numim *acțiuni* și Ω o altă mulțime nevidă numită *spațiul parametrilor*. Fie \mathcal{F}_Ω o σ -algebră pe Ω .

Definiția 6.1 Aplicația $X : \Omega \rightarrow \mathbb{R}$ o numim \mathcal{F} -*măsurabilă* dacă pentru orice $r \in \mathbb{R}$ avem:

$$\{X < r\} : \{\omega \in \Omega : X(\omega) < r\} \in \mathcal{F}_\Omega. \quad (6.1)$$

Observația 6.2 Comparând relația anterioară cu relația (3.5) din Cursul 3 observăm că sunt identice. Deci o variabilă aleatoare este exact o funcție \mathcal{F}_Ω -măsurabilă.

Definiția 6.3 Numim *funcție pierdere* o funcție $Pierd : \Omega \times A \rightarrow \mathbb{R}_+$.

În exemplele care urmează $\Omega \subseteq \mathbb{R}^m$ și atunci $\mathcal{F}_\Omega = \mathcal{B}(m) \cap \Omega$.

Exemple 6.4

1) *pierdere eroare-pătratică*: $A = \Omega \subseteq \mathbb{R}$

$$Pierd(\omega, a) = \rho(\omega - a)^2 \quad (6.2)$$

cu $\rho \in \mathbb{R}_+^*$ fixat.

2) *pierdere eroare-pătratică ponderată*: $A = \Omega \subseteq \mathbb{R}$

$$Pierd(\omega, a) = \rho(\omega)(\omega - a)^2 \quad (6.3)$$

cu $\rho : \Omega \rightarrow \mathbb{R}_+^*$, \mathcal{F}_Ω -măsurabilă.

3) *pierdere liniară* $A = \Omega \subseteq \mathbb{R}$

$$Pierd(\omega, a) = \begin{cases} \rho_1(\omega - a), & \omega \geq a \\ \rho_2(a - \omega), & \omega < a \end{cases} \quad (6.4)$$

cu ρ_1, ρ_2 numere reale pozitive.

4) *pierdere liniară ponderată* ca mai sus dar cu $\rho_1, \rho_2 : \Omega \rightarrow (0, +\infty)$, \mathcal{F}_ω -măsurabilă.

5) *pierdere eroare-absolută*: $A = \Omega \subseteq \mathbb{R}$

$$Pierd(\omega, a) = \rho|\omega - a| \quad (6.5)$$

cu $\rho > 0$.

6) *pierdere* $c_1 - c_2$: $A = \{a_1, a_2\}$, $\Omega = \Omega_1 \cup \Omega_2$ cu $\Omega_1 \cap \Omega_2 = \emptyset$

$$Pierd(\omega, a_i) = \begin{cases} c_1, & \omega \in \Omega_i \\ c_2, & \omega \in \Omega_j \end{cases} \quad (6.6)$$

cu $i \neq j$.

Fie $\mathcal{X} \subseteq \mathbb{R}^n$ o mulțime nevidă numită *spațiul de selecție* și σ -algebra $\mathcal{F}_{\mathcal{X}} = \mathcal{B}(n) \cap \mathcal{X}$.

Definiția 6.5 Numim *problemă de decizie* un ansamblu $(A, \Omega, \mathcal{X}, X)$ cu $X : \Omega \times \mathcal{X} \rightarrow \mathcal{X}$ așa încât pentru orice $\omega \in \Omega$ aplicația $X(\omega, \cdot) : \mathcal{X} \rightarrow \mathcal{X}$ este $\mathcal{F}_{\mathcal{X}}$ -măsurabilă i.e. pentru orice $F \in \mathcal{F}_{\mathcal{X}}$ avem:

$$\{x \in \mathcal{X} : X(x) \in F\} \in \mathcal{F}_{\mathcal{X}}. \quad (6.7)$$

Fie $g : \mathcal{X} \rightarrow \mathbb{R}$ ce este $\mathcal{F}_{\mathcal{X}}$ -măsurabilă și $\omega \in \Omega$ fixat. Putem defini *media g-ponderată* a lui $X(\omega, \cdot)$ la fel ca în Cursul precedent:

$$M(g(X(\omega, \cdot))) := \begin{cases} \sum_{x \in \mathcal{X}} g(x) X(\omega, x) & X(\omega, \cdot) \text{ este discretă} \\ \int_{\mathcal{X}} g(x) \rho(\omega, x) dx & X(\omega, \cdot) \text{ este continuă cu densitatea de repartiție } \rho(\omega, \cdot). \end{cases} \quad (6.8)$$

Definiția 6.6 O funcție $d : \mathcal{X} \rightarrow A$ ce este $\mathcal{F}_{\mathcal{X}}$ -măsurabilă o numim *funcție de decizie* sau *regulă de decizie*. Fie \mathcal{D} mulțimea regulilor de decizie pentru problema de decizie dată.

Am ajuns astfel la noțiunea centrală întregului Curs și anume *riscul* unei decizii:

Definiția 6.7 *Funcția risc* a problemei de decizie $(A, \Omega, \mathcal{X}, X)$ este $R : \Omega \times \mathcal{D} \rightarrow \mathbb{R}$:

$$R(\omega, d) = M(Pierd(\omega, d \circ X(\omega, \cdot))) \quad (6.9)$$

Deci riscul este o medie a pierderilor asociatei unei perechi (parametru ω , decizie a), parametrul ω fiind luat în considerare pentru adoptarea deciziei a din mulțimea A a tuturor deciziilor.

Exemplul 6.8 (*Acceptarea unui lot de produse*)

O firmă produce un tip de produse și vrem să decidem dacă acceptăm sau nu un lot de astfel de n produse. Fie ω probabilitatea de a găsi un produs defect. Există $\omega_0 \in (0, 1]$, numit *prag de acceptare-respingere*, astfel încât:

-dacă $\omega \leq \omega_0$ facem acțiunea a_1 =acceptăm,

-dacă $\omega > \omega_0$ facem acțiunea a_2 =respingem.

În practică $\omega_0 = 0,05$ adică acceptăm cel mult 5 produse defecte. Avem $A = \{a_1, a_2\}$, $\mathcal{X} = \{0, \dots, n\}$ și $X = X(\omega, x)$ va da numărul de produse defecte din lotul de $x \in \mathcal{X}$ cu probabilitatea ω . Avem că $X(\omega, \cdot)$ este continuă cu densitatea de tip binomial:

$$\rho(\omega, x) = C_n^x \omega^x (1 - \omega)^{n-x}. \quad (6.10)$$

Fixăm $\rho > 0$ un coeficient de *calibrare* iar funcția pierdere va fi:

$$Pierd(\omega, a_1) = \begin{cases} 0 & \omega \leq \omega_0 \\ \rho(\omega - \omega_0) & \omega > \omega_0 \end{cases} \quad (6.11)$$

$$Pierd(\omega, a_2) = \begin{cases} \rho(\omega_0 - \omega) & \omega \leq \omega_0 \\ 0 & \omega > \omega_0. \end{cases} \quad (6.12)$$

Funcția decizie este $d: \mathcal{X} = \{0, \dots, n\} \rightarrow A = \{a_1, a_2\}$:

$$d(x) = \begin{cases} a_1 & \frac{x}{n} \leq \omega_0 \\ a_2 & \frac{x}{n} > \omega_0. \end{cases} \quad (6.13)$$

Atunci funcția risc devine:

$$R(\omega, d) = \sum_{x=0}^n Pierd(\omega, d(x))\rho(\omega, x) \quad (6.14)$$

și are expresia finală:

$$R(\omega, d) = \begin{cases} \sum_{x \in \mathcal{X}, n\omega_0 \leq x \leq n} \rho(\omega_0 - \omega) C_n^x \omega^x (1 - \omega)^{n-x} & \omega \leq \omega_0 \\ \sum_{x \in \mathcal{X}, 1 \leq x \leq n\omega_0} \rho(\omega_0 - \omega) C_n^x \omega^x (1 - \omega)^{n-x} & \omega > \omega_0. \end{cases} \quad (6.15)$$

Exemplul 6.9 O firmă dorește să-și modernizeze fluxul tehnologic și epntru aceasta este necesară achiziționarea a 10 dispozitive automate de prelucrare a unor piese. Dintre acestea, un număr de ω vor avea o durată de funcționare de 10.000 de ore fără reparații majore, durată ce aduce un beneficiu de k_1 lei. Pentru celelalte $10 - \omega$ dispozitive ce au suferit defecțiuni importante pe durata funcționării de 10.000, firma va suporta cheltuieli de k_2 lei.

Pentru achiziționarea acestor 10 dispozitive firma are la dispoziție un timp pentru a testa unul singur. Dacă acest dispozitiv funcționează la anumiți parametri atunci testul este considerat satisfăcător și dispozitivele sunt achiziționate. În caz contrar, nu se acceptă aceste dispozitive. Cheltuielile pentru acest test sunt de k_3 lei.

Avem din nou $A = \{a_1, a_2\}$ cu $a_1 =$ acceptare iar $a_2 =$ respingere; avem $\Omega = \{0, \dots, 10\}$. Fie $\mathcal{X} = \{x_1, x_2\}$ cu:

- x_1 corespunde unui rezultat satisfăcător la test,

- x_2 corespunde unui rezultat nesatisfăcător la test.

X are densitatea:

$$\begin{cases} \rho(\omega, x_1) = \frac{\omega}{10} \\ \rho(\omega, x_2) = 1 - \frac{\omega}{10}. \end{cases} \quad (6.16)$$

Funcția pierdere are expresia:

$$\begin{cases} Pierd(\omega, a_1) = k_3 - \omega k_1 + (10 - \omega)k_2 \\ Pierd(\omega, a_2) = k_3. \end{cases} \quad (6.17)$$

Funcțiile de decizie $d: \mathcal{X} = \{x_1, x_2\} \rightarrow \{a_1, a_2\}$ sunt în număr de patru:

$$\begin{aligned} d_1(x) &= a_1, \forall x \in \mathcal{X} \\ d_2(x) &= \begin{cases} a_1 & x = x_1 \\ a_2 & x = x_2 \end{cases} \\ d_3(x) &= \begin{cases} a_2 & x = x_1 \\ a_1 & x = x_2 \end{cases} \\ d_4(x) &= a_2, \forall x \in \mathcal{X}. \end{aligned} \quad (6.18)$$

Observăm că d_1 și d_4 ignoră rezultatul testului; astfel d_1 acceptă lotul în orice condiții iar d_4 îl respinge indiferent de rezultatul testului. O astfel de situație este posibilă; spre exemplu firmei i se oferă un contract mai avantajos, prin care se acoperă și cheltuielile efectuării testului.

Pentru un parametru ω dat, riscul asociat funcțiilor de decizie considerate este:

$$R(\omega, d) = \text{Pierd}(\omega, d(x_1))\rho(\omega, x_1) + \text{Pierd}(\omega, d(x_2))\rho(\omega, x_2) \quad (6.19)$$

care devine, în fiecare din cele patru cazuri particulare:

$$\begin{aligned} R(\omega, d_1) &= k_3 - \omega k_1 + (10 - \omega)k_2 \\ R(\omega, d_2) &= \frac{\omega}{10}[k_3 - \omega k_1 + (10 - \omega)k_2] + \left(1 - \frac{\omega}{10}\right)k_3 \\ R(\omega, d_3) &= \frac{\omega}{10}k_3 + \left(1 + \frac{\omega}{10}\right)[k_3 - \omega k_1 + (10 - \omega)k_2] \\ R(\omega, d_4) &= k_3. \end{aligned} \quad (6.19)$$

Seminar 6 Diagrama *pie* afișează procentul cu care fiecare element al unui vector (sau matrice) contribuie la suma elementelor structurii.

S6.1 Să se figureze fenomenele echiprobabile $\bar{p}_n = (\frac{1}{n}, \dots, \frac{1}{n})$ (vezi Cursul 1) pentru $n \in \{2, 3, 4, 5, 6\}$.

Soluție Programul MATLAB:

```
>>x=[1 1];
>>pie(x) (+Enter)
```

dă:



Figura 6.1

Analog avem:

```
>>x=[1 1 1];
>>pie(x) (+Enter)
```




Figura 6.2

```
>>x=[1 1 1 1];  
>>pie(x) (+Enter)
```




Figura 6.3

```
>>x=[1 1 1 1 1];  
>>pie(x) (+Enter)
```




Figura 6.4

```
>>x=[1 1 1 1 1 1];  
>>pie(x) (+Enter)
```




Figura 6.5

Putem utiliza și *pie3(.)* pentru o reprezentare spațială:

```
>>x=[1 1];
>>pie3(x) (+Enter)
```




Figura 6.6

```
>>x=[1 1 1];
>>pie3(x) (+Enter)
```




Figura 6.7

```
>>x=[1 1 1 1];
>>pie3(x) (+Enter)
```





Figura 6.8

```
>>x=[1 1 1 1 1];
>>pie3(x) (+Enter)
```




Figura 6.9

```
>>x=[1 1 1 1 1 1];
>>pie3(x) (+Enter)
```




Figura 6.10

S6.2 Să se figureze cu *pie* variabila aleatoare dată de Exercițiul 3.3

Soluție Înmulțim cu 8 ultima linie pentru a norma această variabilă aleatoare și avem:
 $x = (1, 2, 1, 4)$.

```
>>x=[1 2 1 4];
>>pie(x) (+Enter)
```




Figura 6.11

```
>>x=[1 2 1 4];
>>pie3(x) (+Enter)
```




Figura 6.12

S6.3 Se dau variabilele aleatoare independente:

$$X : \begin{pmatrix} -1 & 0 & 1 \\ p + \frac{1}{6} & q + \frac{1}{3} & \frac{1}{3} \end{pmatrix}$$

$$Y : \begin{pmatrix} -1 & 0 & 1 \\ \frac{1}{3} & 2p - q & 12p^2 \end{pmatrix}.$$

Se cere distribuția lui XY .

Soluție Să determinăm mai întâi p și q punând condiția ca suma elementelor din linia inferioară să fie 1:

$$\begin{cases} p + \frac{1}{6} + q + \frac{1}{3} + \frac{1}{3} = 1 \\ \frac{1}{3} + 2p - q + 12p^2 = 1. \end{cases}$$

Avem deci sistemul:

$$\begin{cases} p + q = \frac{1}{6} \\ 2p - q + 12p^2 = \frac{2}{3} \end{cases}$$

și prin adunarea celor două ecuații avem:

$$3p + 12p^2 = \frac{5}{6}.$$

Putem scrie:

$$p^2 + \frac{1}{4}p - \frac{5}{72} = 0$$

care are discriminantul:

$$\Delta = \frac{1}{16} + \frac{5}{18} = \frac{18 + 80}{16 \cdot 18} = \frac{98}{16 \cdot 18} = \frac{49}{16 \cdot 9} = \left(\frac{7}{12}\right)^2.$$

Rezultă soluțiile:

$$p_1 = \frac{1}{2} \left(-\frac{1}{4} - \frac{7}{12}\right)$$

imposibilă respectiv:

$$p_2 = p = \frac{1}{2} \left(-\frac{1}{4} + \frac{7}{12}\right) = \frac{4}{12 \cdot 2} = \frac{1}{6}$$

la care corespunde $q = 0$. Deci:

$$X : \begin{pmatrix} -1 & 0 & 1 \\ \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \end{pmatrix}$$

$$Y : \begin{pmatrix} -1 & 0 & 1 \\ \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \end{pmatrix}$$

V. a. XY ia valorile $-1, 0$ și 1 . Avem: $\{XY = -1\} = \{X = 1; Y = -1\} \cup \{X = -1; Y = 1\}$ și deci:

$$\begin{aligned} P(XY = -1) &= P(X = 1; Y = -1) + P(X = -1; Y = 1) = \\ &= P(X = 1) \cdot P(Y = -1) + P(X = -1) \cdot P(Y = 1) = \frac{1}{3} \cdot \frac{1}{3} + \frac{1}{3} \cdot \frac{1}{3} = \frac{2}{9}. \end{aligned}$$

Analog:

$$P(XY = 1) = \frac{2}{9}$$

și deci:

$$P(XY = 0) = 1 - \frac{4}{9} = \frac{5}{9}.$$

În concluzie:

$$XY : \begin{pmatrix} -1 & 0 & 1 \\ \frac{2}{9} & \frac{5}{9} & \frac{2}{9} \end{pmatrix}.$$

S6.4 Se dau v. a. independente de la exercițiul anterior. Se cere $X^2 + Y^2$.

Soluție Avem:

$$X^2 = Y^2 : \begin{pmatrix} 0 & 1 \\ \frac{1}{3} & \frac{2}{3} \end{pmatrix}$$

și deci v. a. ia valorile $0, 1$ și 2 . Deoarece X^2 și Y^2 sunt independente avem:

$$X^2 + Y^2 : \begin{pmatrix} 0 & 1 & 2 \\ \frac{1}{9} & \frac{4}{9} & \frac{4}{9} \end{pmatrix}.$$

S6.5 Se cer numerele reale a, b, c așa încât următoarea funcție să fie o funcție de repartiție continuă:

$$F(x) = \begin{cases} a & x \in (-\infty, 0] \\ bx^2 & x \in (0, 1] \\ c & x \in (1, +\infty). \end{cases}$$

Soluție Din FR2), Cursul 4, avem: $0 = \lim_{x \rightarrow -\infty} F(x) = a$ și $1 = \lim_{x \rightarrow +\infty} F(x) = c$. Din continuitatea în $x = 1$ avem: $F(1) = b = \lim_{x \searrow 1} F(x) = c = 1$. \square

Chapter 7

Invarianță în teoria deciziilor

Fie problema de decizie $(A, \Omega, \mathcal{X}, X)$ și $S(\mathcal{X})$ mulțimea funcțiilor bijectiv pe \mathcal{X} i.e. elementele lui $S(\mathcal{X})$ sunt funcții $g : \mathcal{X} \rightarrow \mathcal{X}$ bijectiv.

Propoziția 7.1 $S(\mathcal{X})$ este grup relativ la compunerea funcțiilor.

Definiția 7.2 $S(\mathcal{X})$ se numește *grupul bijecțiilor* lui \mathcal{X} sau încă *grupul simetric* al lui \mathcal{X} . O funcție $g \in S(\mathcal{X})$ o numim *transformare a lui \mathcal{X}* sau *pe \mathcal{X}* .

Fixăm $G \subset S(\mathcal{X})$ un subgrup; deci G este submulțime nevidă (conține măcar funcția identică $1_{\mathcal{X}}$) cu proprietățile:

sg1) dacă $g_1 \in G$ și $g_2 \in G$ atunci $g_2 \circ g_1 \in G$.

sg2) dacă $g \in G$ atunci și inversa g^{-1} aparține lui G .

Vom mai presupune că orice $g \in G$ este transformare *bimăsurabilă* în sensul că pentru orice $B \in \mathcal{F}_{\mathcal{X}}$ avem $g(B) \in \mathcal{F}_{\mathcal{X}}$ și $g^{-1}(B) \in \mathcal{F}_{\mathcal{X}}$. Cum compunerea de aplicații măsurabile este măsurabilă rezultă că pentru orice $\omega \in \Omega$ aplicația $g(X(\omega, \cdot)) : \mathcal{X} \rightarrow \mathcal{X}$ este $\mathcal{F}_{\mathcal{X}}$ -măsurabilă.

Definiția 7.3 Aplicația $X : \Omega \times \mathcal{X} \rightarrow \mathcal{X}$ o numim *G-invariantă* dacă pentru orice $g \in G$ și orice $\omega \in \Omega$ există și este unic $\bar{\omega} \in \Omega$ astfel încât dacă $X(\omega, \cdot)$ are distribuția de probabilitate $P(\omega)$ atunci $g(X(\omega, \cdot))$ are distribuția $P(\bar{\omega})$.

În limbajul densităților de probabilitate avem că dacă $X(\omega, x)$ are distribuția $\rho(\omega, x)$ atunci $g(X(\omega, x))$ are distribuția $\rho(\bar{\omega}, y = gx)$. Notăm $\bar{\omega} = \bar{g}(\omega)$. Rezultă invarianța mediei:

$$M(h \circ g(X(\omega, \cdot))) = M(h \circ X(\bar{g}(\omega), \cdot))$$

și faptul că pentru $g \in G$ fixam avem că $\bar{g}(\omega)$ este o funcție de ω . Putem deci considera $\bar{G} = \{\bar{g}; g \in G\}$ ca submulțime în $F(\Omega) = \{f : \Omega \rightarrow \Omega\}$ = mulțimea tuturor funcțiilor de la Ω la Ω .

Propoziția 7.4 \bar{G} este subgrup în $S(\Omega)$.

Elementul neutru din \bar{G} este $\bar{e} = 1_{\Omega} : \omega \in \Omega \rightarrow \omega$ corespunzător elementului neutru $e = 1_{\mathcal{X}} : x \in \mathcal{X} \rightarrow x$.

Presupunem că funcția pierdere satisface proprietatea: $Pierd(\omega, a_1) = Pierd(\omega, a_2)$ pentru orice $\omega \in \Omega$ implică $a_1 = a_2$. Această presupunere este naturală în sensul că având aceleași pierderi pentru orice parametru ω e clar că cele două acțiuni a_1, a_2 sunt echivalente.

Definiția 7.5 i) Funcția pierdere este G -invariantă dacă pentru orice $g \in G$ și orice $a \in A$ există și este unic $\tilde{a} \in A$ astfel ca: $Pierd(\omega, a) = Pierd(\omega, \bar{g}(\omega), \tilde{a})$ pentru orice $\omega \in \Omega$.
ii) Problema de decizie dată este G -invariantă dacă X și $Pierd$ sunt G -invariante.

Mai notăm $\tilde{a} = \tilde{g}(a)$ și obținem $\tilde{G} = \{\tilde{g}; g \in G\}$ ca submulțime în $F(A)$. Avem ca mai sus:

Propoziția 7.5 \tilde{G} este subgrup în $S(A)$.

O observație importantă este că pentru o problemă de decizie G -invariantă avem:

$$Pierd(\omega, a) = Pierd(\bar{g}(\omega), \tilde{g}(\omega)) \quad (7.1)$$

pentru orice $\omega \in \Omega$. Relativ la funcții de decizie avem următoarea noțiune de invarianță:

Definiția 7.6 Considerăm că problema de decizie dată este G -invariantă și fie $d \in \mathcal{D}$ o regulă de decizie. Spunem atunci că d este G -invariantă dacă pentru orice $x \in \mathcal{X}$ și orice $g \in G$ avem:

$$d(g(x)) = \tilde{g}(d(x)). \quad (7.2)$$

Vom nota cu $\mathcal{D}(G)$ mulțimea funcțiilor de decizie G -invariante.

Definiția 7.7 Considerăm că problema de decizie dată este G -invariantă și fie parametrii $\omega_1, \omega_2 \in \Omega$. Spunem că ω_1 și ω_2 sunt *echivalenți* dacă există $g \in G$ așa încât $\omega_2 = \bar{g}(\omega_1)$.

Obținem astfel o relație de echivalență pe spațiul Ω al parametrilor. O clasă de echivalență se va numi *orbită*. Următorul rezultat este central în acest Curs și spune în esență că pentru funcțiile de decizie G -invariante funcția risc este invariantă pe orbită:

Teorema 7.8 Considerăm că problema de decizie dată este G -invariantă și fie $d \in \mathcal{D}(G)$. Atunci pentru orice $\omega \in \Omega$ avem:

$$R(\omega, d) = R(\bar{g}(\omega), d). \quad (7.3)$$

Cazul particular de constanță totală a riscului merită menționat.

Definiția 7.9 Grupul \bar{G} se numește *tranzitiv* dacă există $\omega_0 \in \Omega$ astfel încât întreg Ω este orbita lui ω_0 .

Prin urmare, în cazul \bar{G} tranzitiv, avem o singură orbită iar din Teorema avem că riscul asociat la orice funcție de decizie este același indiferent de parametrii din Ω . O funcție de decizie invariantă care minimizează acest risc constant se numește *cea mai bună funcție de decizie invariantă*.

Exemplul 7.10 Fie $A = \Omega = (0, +\infty)$ și $\{P(\omega); \omega \in \Omega\}$ familia distribuțiilor exponențiale de parametru ω . Fie funcția pierdere”

$$Pierd(\omega, a) = (a - a\omega)^2. \quad (7.4)$$

Fie $G = g_c; c \in (0, +\infty)$ grupul transformărilor de scală ale dreptei reale i.e. $g_c : (0, +\infty) \rightarrow (0, +\infty)$, $g_c(x) = cx$. Se observă că \bar{G} este tranzitiv.

Avem că această problemă de decizie este invariantă iar o funcție de decizie va fi invariantă dacă $d(cx) = cd(x)$ pentru orice $x \in (0, +\infty)$. Ultima egalitate este o *ecuație funcțională* adică o ecuație având ca necunoscută o funcție.

Soluția acestei ecuații funcționale este: $d(x) = \lambda x$ cu $\lambda > 0$. Funcția risc pentru această decizie este:

$$R(\omega, d) = M(1 - \omega d(X(\omega, \cdot)))^2 = M(1 - \lambda \omega X(\omega))^2 = 1 - 2\lambda + 2\lambda^2. \quad (7.5)$$

Derivăm această funcție risc și egalăm cu zero derivata pentru a-i afla minimumul.

$$\frac{dR}{d\lambda} = 4\lambda - 2 = 0$$

și prin urmare cea mai bună decizie invariantă este $d_0(x) = \frac{x}{2}$ iar riscul corespunzător este: $R(\omega, d_0) = 1 - 1 + \frac{2}{4} = \frac{1}{2}$.

Seminar 7

S7.1 (Exemplu de v. a. numărabilă) Se aruncă un zar și fie X numărul de aruncări efectuate până apare cifra 1. Se cere distribuția lui X .

Soluție X poate lua orice valoare 1, 2, 3, ... Să calculăm probabilitatea $p_k = P(X = k)$. Avem $p_1 = P(X = 1) = \frac{1}{6}$. $p_2 = P(X = 2)$ este probabilitatea ca la prima aruncare să nu iasă fața 1 combinată cu probabilitatea ca la aruncarea a doua să iasă fața 1. Avem deci $p_2 = \frac{5}{6} \cdot \frac{1}{6}$. Analog $p_3 = \frac{5}{6} \cdot \frac{5}{6} \cdot \frac{1}{6}$. Rezultă că pentru cazul general avem:

$$p_k = \left(\frac{5}{6}\right)^{k-1} \cdot \frac{1}{6}$$

iar distribuția este:

$$X : \left(\begin{array}{c} k \in \mathbb{N}^* \\ \left(\frac{5}{6}\right)^{k-1} \cdot \frac{1}{6} \end{array} \right).$$

Cazul general: v. a. a primei realizări Fie o experiență și un eveniment A legat de această experiență și care se realizează cu probabilitatea p . Fie X numărul de efectuări ale experienței până la prima realizare a lui A . Avem:

$$X : \left(\begin{array}{c} k \in \mathbb{N}^* \\ q^{k-1} p \end{array} \right) \quad (7.5)$$

cu $q = 1 - p$.

Avem că:

$$1 + q + \dots + q^n = \frac{1 - q^{n+1}}{1 - q} \quad (7.6)$$

și deci suma elementelor din linia inferioară a lui (6.5) este: $p \cdot \frac{1}{1-q} = 1$ deoarece $\lim_{n \rightarrow +\infty} q^n = 0$, q fiind un număr subunitar.

S7.2 Se cer numerele reale a, b, c așa încât următoarea funcție să fie o funcție de repartiție continuă:

$$F(x) = \begin{cases} \frac{(a-2b)x^3}{x^3+1} & x \leq 0 \\ c \sin x & 0 < x \leq \frac{\pi}{2} \\ \frac{(a+b-2)x^2-1}{x^2-1} & x > \frac{\pi}{2}. \end{cases}$$

Soluție Din FR2), Cursul 4, avem: $0 = \lim_{x \rightarrow -\infty} F(x) = a - b$ și $1 = \lim_{x \rightarrow +\infty} F(x) = a + b - 2$. Avem un sistem în necunoscutele a și b cu soluția: $a = 1, b = 1$, obținută înlocuind

$a = 2b$ în a doua ecuație.

Din continuitatea în $x = \frac{\pi}{2}$ avem: $F(\frac{\pi}{2}) = c = \lim_{x \searrow 1} F(x) = 1$. \square

S7.3 Se cere $a \in \mathbb{R}$ astfel ca funcția următoare să fie o densitate de repartiție:

$$\rho(x) = \begin{cases} 0 & x \notin [0, 1] \\ 2ax & x \in [0, 1]. \end{cases}$$

Soluție Folosim D2) din Cursul 4:

$$1 = \int_{-\infty}^{+\infty} \rho(x) dx = \int_0^1 \rho(x) dx = ax^2 \Big|_0^1 = a.$$

S7.4 Se dă v. a. X cu densitatea:

$$\rho(x) = \begin{cases} 0 & x \leq 0 \\ \lambda e^{-2x} & x > 0. \end{cases}$$

Se cere $P(X > 3)$.

Soluție Determinăm λ din aceeași condiție D2):

$$1 = \int_{-\infty}^{+\infty} \rho(x) dx = \int_0^{+\infty} \lambda e^{-2x} dx = \frac{\lambda}{-2} e^{-2x} \Big|_0^{+\infty} = \frac{\lambda}{-2} (e^{-\infty} - e^0) = \frac{\lambda}{2}$$

de unde rezultă $\lambda = 2$.

Avem atunci:

$$P(X > 3) = P(3 < X < +\infty) = \int_3^{+\infty} 2e^{-2x} dx = -e^{-2x} \Big|_3^{+\infty} = e^{-6} - 0 = \frac{1}{e^6}.$$

Chapter 8

Utilitate și pierdere

Reamintim că am notat cu \mathcal{D} mulțimea deciziilor asociate unei probleme de decizie.

Definiția 8.1 Fie deciziile $d_1, d_2 \in \mathcal{D}$. Spunem că:

- 1) d_1 *domină* d_2 sau că d_1 *este mai bună decât* d_2 și notăm $d_1 > d_2$ dacă: $R(\omega, d_1) \leq R(\omega, d_2)$ pentru orice $\omega \in \Omega$ cu inegalitate strictă pentru cel puțin un parametru ω .
- 2) d_1 *este cel puțin tot așa de bună ca și* d_2 și notăm $d_1 \geq d_2$ dacă: $R(\omega, d_1) \leq R(\omega, d_2)$ pentru orice $\omega \in \Omega$.
- 3) d_1 și d_2 sunt *echivalente* și notăm $d_1 \sim d_2$ dacă: $R(\omega, d_1) = R(\omega, d_2)$ pentru orice $\omega \in \Omega$.

Relațiile 1) și 2) sunt de ordine iar 3) este o relație de echivalență.

Fie C mulțimea consecințelor unei decizii luate. Fie $u : C \rightarrow \mathbb{R}$ o funcție de "cuantificare" a acestor consecințe. Dacă avem o probabilitate P pe C atunci "valoarea" unei consecințe este media $M(u(c))$, care pentru orice P definește o funcție utilitate.

Fie deci $\mathcal{P}(C)$ mulțimea tuturor distribuțiilor de probabilitate *simple* pe C . Pentru o consecință fixată $c \in C$ notăm cu $\langle c \rangle$ distribuția de probabilitate care asociază valoarea 1 mulțimii $\{c\}$ și 0 în rest.

Definiția 8.2 Fie $p_1, p_2 \in \mathcal{P}(C)$. Spunem că:

- u1) p_2 *este preferat față de* p_1 și notăm $p_1 < p_2$ dacă: $M_{p_1}(u(c)) < M_{p_2}(u(c))$ unde M_p înseamnă media în raport cu probabilitatea p .
- u2) Notăm $p_1 \leq p_2$ dacă p_1 nu este preferat față de p_2 .
- u3) Notăm $p_1 \sim p_2$ dacă p_1 și p_2 sunt *echivalente*.

Să observăm că $\mathcal{P}(C)$ este o *mulțime convexă*: dacă $p_1, p_2 \in \mathcal{P}(C)$ și $\alpha \in [0, 1]$ atunci avem următorul element $p = \alpha p_1 + (1 - \alpha)p_2$ în $\mathcal{P}(C)$ definit de: $p(C') = \alpha p_1(C') + (1 - \alpha)p_2(C')$ pentru orice $C' \subseteq C$. În particular, dacă $c_1, c_2 \in C$ atunci $\alpha \langle c_1 \rangle + (1 - \alpha) \langle c_2 \rangle$ este o distribuție de probabilitate.

Fixăm o mulțime nevidă M .

Definiția 8.3 Numim *mixtură* o pereche (M, m) cu $m : [0, 1] \times M \times M \rightarrow M$ satisfăcând:

- M1) $m(1, P, Q) = P$,
- M2) $m(\alpha, P, Q) = m(1 - \alpha, Q, P)$,
- M3) $m(\alpha, m(\beta, P, Q), Q) = m(\alpha\beta, P, Q)$.

Vom mai nota $m(\alpha, P, Q)$ prin $\alpha P + (1 - \alpha)Q$. Avem atunci:

- m1) $1P + 0Q = P$,

- m2) $\alpha P + (1 - \alpha)Q = (1 - \alpha)Q + \alpha P$,
 m3) $\alpha[\beta P + (1 - \beta)Q] + (1 - \alpha)Q = \alpha\beta P + (1 - \alpha\beta)Q$.

Propoziția 8.4 Fie (M, m) o *mixtură*. Atunci:

- m4) $\alpha P + (1 - \alpha)P = P$,
 m5) $\alpha[\beta Q + (1 - \beta)R] + (1 - \alpha)[\gamma Q + (1 - \gamma)R] = [\alpha\beta + (1 - \alpha)\gamma]Q + [\alpha(1 - \beta) + (1 - \alpha)(1 - \gamma)]R$.

Demonstrație m4)

$$\alpha P + (1 - \alpha)P = \alpha[1P + 0P] + (1 - \alpha)P = \alpha[0P + 1P] + (1 - \alpha)P = 0P + 1P = 1P + 0P = P.$$

m5) Presupunem că $\beta \leq \gamma$.

$$\begin{aligned} & [\alpha\beta + (1 - \alpha)\gamma]Q + [\alpha(1 - \beta) + (1 - \alpha)(1 - \gamma)]R = \left[\frac{\alpha\beta}{\gamma} + (1 - \alpha)\gamma\right]Q + 1 - \left[\frac{\alpha\beta}{\gamma} + (1 - \alpha)\right]\gamma R = \\ & = \left[\frac{\alpha\beta}{\gamma} + (1 - \alpha)\right][\gamma Q + (1 - \gamma)R] + \left[1 - \frac{\alpha\beta}{\gamma} - (1 - \alpha)\right]R = \\ & = \alpha\left(1 - \frac{\beta}{\gamma}\right)R + \left[1 - \alpha\left(1 - \frac{\beta}{\gamma}\right)\right][\gamma Q + (1 - \gamma)R] = \alpha\frac{\beta}{\gamma}[\gamma Q + (1 - \gamma)R] + \left(1 - \frac{\beta}{\gamma}\right)R + (1 - \alpha)[\gamma Q + \\ & (1 - \gamma)R] = \alpha[\beta Q + (1 - \beta)R] + (1 - \alpha)[\gamma Q + (1 - \gamma)R]. \end{aligned}$$

Demonstrația a fost realizată în ipoteza $\gamma \neq 0$. Dacă $\gamma = 0$ atunci relația cerută este imediată.

□

Definiția 8.5 Fie \leq o relație binară pe M . Pentru $P, Q \in M$ definim $P < Q$ dacă $P \leq Q$ dar nu avem $Q \leq P$. Definim $P \sim Q$ dacă $P \leq Q$ și $Q \leq P$.

Vom considera următoarele axiome:

- a1) \leq este o ordine slabă i.e. este tranzitivă și completă.
 a2) Dacă $\alpha \in (0, 1]$ și $P < Q$ atunci $\alpha P + (1 - \alpha)R < \alpha Q + (1 - \alpha)R$.
 a3) Dacă $P < Q < R$ atunci există $\alpha, \beta \in (0, 1)$ așa încât: $\alpha P + (1 - \alpha)R < Q < \beta P + (1 - \beta)R$.

Propoziția 8.6 Dacă avem a_1, a_2 și a_3 atunci:

- i1) dacă $P < Q$ și $0 \leq \alpha < \beta \leq 1$ atunci $\beta P + (1 - \beta)Q < \alpha P + (1 - \alpha)Q$.
 i2) dacă $P \leq Q, Q \leq R$ și $P < R$ atunci există $\alpha \in [0, 1]$ unic așa încât $Q = \alpha P + (1 - \alpha)R$.
 i3) dacă $P < Q, R < S$ și $\alpha \in [0, 1]$ atunci $\alpha P + (1 - \alpha)R < \alpha Q + (1 - \alpha)S$.
 i4) dacă $P \sim Q$ și $\alpha \in [0, 1]$ atunci $\alpha P + (1 - \alpha)Q \sim P$.
 i5) dacă $P \sim Q$ și $\alpha \in [0, 1]$ atunci $\alpha P + (1 - \alpha)R \sim \alpha Q + (1 - \alpha)R$.

Propoziția 8.7 Fie (M, m) o *mixtură* cu axiomele a1, a2, a3. Atunci există $u : M \rightarrow \mathbb{R}$ astfel încât:

- (1) $P < Q$ dacă și numai dacă $u(P) < u(Q)$.
 (2) $u[\alpha P + (1 - \alpha)Q] = \alpha u(P) + (1 - \alpha)u(Q)$.

Să presupunem că u satisface aceste două condiții. Atunci $v : M \rightarrow \mathbb{R}$ satisface (1)-(2) dacă și numai dacă există $a > 0$ și $b \in \mathbb{R}$ astfel încât: $v = au + b$ i.e. $v(P) = au(P) + b$ pentru orice $P \in M$.

Materialul acestui Curs a fost prelucrat după: Vasile Preda, *Teoria deciziilor statistice*, Ed. Academiei Române, 1992.

Chapter 9

Teoria credibilității

Fixăm mulțimea nevidă Ω , nu neapărat finită.

Definiția 9.1 Numim *măsură de credibilitate* pe Ω o aplicație $Cr : \mathcal{P}(\Omega) \rightarrow \mathbb{R}$ satisfăcând axiomele:

cr1) (normalitate) $Cr(\Omega) = 1$.

cr2) (monotonie) dacă $A \subset B$ atunci $Cr(A) \leq Cr(B)$.

cr3) (autodualitate) pentru orice eveniment A avem $Cr(A) + Cr(\bar{A}) = 1$.

cr4) (maximalitate) pentru orice șir $\{A_i\}_{i \in I}$ cu $\sup_{i \in I} Cr(A_i) < 0.5$ avem:

$$Cr(\cup_{i \in I} A_i) = \sup_{i \in I} Cr(A_i) \quad (9.1)$$

Perechea (Ω, Cr) o numim *spațiu de credibilitate*.

Exemplul 9.2 Fie $\Omega = \{\omega_1, \omega_2\}$ și funcția Cr dată astfel:

$$Cr(\omega_1) = 0,7, \quad Cr(\omega_2) = 0,3$$

iar $Cr(\Omega) = 1 = 1 - Cr(\emptyset)$. Atunci Cr este o măsură de credibilitate pe Ω .

Exemplul 9.3 Fie $\Omega \subseteq \mathbb{R}$ și $\mu : \Omega \rightarrow [0, +\infty)$ așa încât:

$$\sup_{x \in \Omega} \mu(x) = 1.$$

Atunci următoarea funcție este o măsură de credibilitate pe Ω :

$$Cr(A) = \frac{1}{2} \left(\sup_{x \in A} \mu(x) + \sup_{x \in \bar{A}} \mu(x) \right). \quad (9.2)$$

Exemplul 9.4 Fie Ω o mulțime nevidă oarecare și pentru orice $A \in \mathcal{P}(\Omega)$ diferită de \emptyset și Ω definim:

$$Cr(A) = 0,5 \quad (9.3)$$

iar $Cr(\Omega) = 1 = 1 - Cr(\emptyset)$. Atunci Cr este o măsură de credibilitate pe Ω .

Propoziția 9.5 Fie Ω nevidă și $A \in \mathcal{P}(\Omega)$ oarecare. Dacă Cr este o măsură de credibilitate pe Ω atunci:

cr5) $Cr(\emptyset) = 0$.

cr6) $Cr(A) \in [0, 1]$.

Demonstrație cr5 rezultă imediat din cr1 și cr3. cr6 rezultă din cr2 aplicată incluziunii: $\emptyset \subseteq A \subseteq \Omega$. \square

O serie de proprietăți ale credibilității sunt date de:

Propoziția 9.6 Fie (Ω, Cr) un spațiu de credibilitate și $A, B \in \mathcal{P}(\Omega)$. Avem:

cr7) dacă $Cr(A \cup B) \leq 0,5$ atunci: $Cr(A \cup B) = \max\{Cr(A), Cr(B)\}$.

cr8) dacă $Cr(A \cap B) \geq 0,5$ atunci: $Cr(A \cap B) = \min\{Cr(A), Cr(B)\}$.

cr9) $Cr(A \cup B) \leq Cr(A) + Cr(B)$.

Demonstrație i) Dacă $Cr(A \cup B) < 0,5$ atunci din cr2 avem $\max\{Cr(A), Cr(B)\} < 0,5$ și obținem cr7 din cr4. Să presupunem acum că $Cr(A \cup B) = 0,5$ și cr7 nu are loc; rezultă că $\max\{Cr(A), Cr(B)\} < 0,5$. Putem atunci aplica axioma cr4:

$$Cr(A \cup B)(= 0,5) = \max\{Cr(A), Cr(B)\} < 0,5$$

ceea ce este o contradicție.

ii) Deoarece $Cr(A) \cap Cr(B) \geq 0,5$ aplicând cr3 avem: $Cr(\bar{A} \cup \bar{B}) \leq 0,5$ și deci:

$$Cr(A \cap B) = 1 - Cr(\bar{A} \cup \bar{B}) = 1 - \max\{Cr(\bar{A}), Cr(\bar{B})\} = \min\{Cr(A), Cr(B)\}$$

ceea ce dă cr8.

iii) Avem trei cazuri posibile.

Cazul I) $\max\{Cr(A), Cr(B)\} < 0,5$. Avem, conform cr4:

$$Cr(A \cup B) = \max\{Cr(A), Cr(B)\} \leq Cr(A) + Cr(B).$$

Cazul II) $Cr(A) \geq 0,5$. Din cr2 și cr3 avem: $Cr(\bar{A}) \leq 0,5$ și $Cr(A \cup B) \geq Cr(A) \geq 0,5$ ceea ce implică:

$$Cr(\bar{A}) = \max\{Cr(\bar{A} \cap B), Cr(\bar{A} \cap \bar{B})\} \leq Cr(\bar{A} \cap B) + Cr(\bar{A} \cap \bar{B}) \leq Cr(B) + Cr(\bar{A} \cap \bar{B}).$$

Rezultă atunci:

$$Cr(A) + Cr(B) = 1 - Cr(\bar{A}) + Cr(B) \geq 1 - Cr(B) - Cr(\bar{A} \cap \bar{B}) + Cr(B) = 1 - Cr(\bar{A} \cap \bar{B}) = Cr(A \cup B)$$

adică concluzia.

Cazul III) $Cr(B) \geq 0,5$. Se aplică același argument ca mai sus cu A schimbat cu B . \square

Observații 9.7 i) O măsură de credibilitate nu este doar finit-subaditivă ci chiar numărabil subaditivă adică:

$$Cr(\cup_{i \in \mathbb{N}} A_i) \leq \sum_{i \in \mathbb{N}} Cr(A_i). \quad (9.4)$$

ii) Din demonstrația de la cr9 rezultă că o măsură de credibilitate este nul-aditivă adică: $Cr(A \cup B) = Cr(A) + Cr(B)$ dacă $Cr(A) = 0$ sau $Cr(B) = 0$.

Propoziția 9.8 Fie (Ω, Cr) un spațiu de credibilitate și $\{B_i\}_{i \in \mathbb{N}}$ un șir descrescător de evenimente cu: $\lim_{i \rightarrow \infty} Cr(B_i) = 0$. Atunci pentru orice eveniment A avem:

$$\lim_{i \rightarrow \infty} Cr(A \cup B_i) = \lim_{i \rightarrow \infty} Cr(A \setminus B_i) = Cr(A). \quad (9.5)$$

Demonstrație Avem, din cr2 și cr9, pentru orice i :

$$Cr(A) \leq Cr(A \cup B_i) \leq Cr(A) + Cr(B_i)$$

și deci, cum $Cr(B_i) \rightarrow 0$ avem $Cr(A \cup B_i) \rightarrow Cr(A)$. Deoarece $A \setminus B_i \subset A \subset (A \setminus B_i) \cup B_i$ avem:

$$Cr(A \setminus B_i) \leq Cr(A) \leq Cr(A \setminus B_i) + Cr(B_i)$$

și avem a doua egalitate când trecem la limită. \square

Prezentăm fără demonstrație și alte proprietăți ale măsurilor de credibilitate:

Propoziția 9.9 *O măsură de credibilitate este aditivă dacă și numai dacă există cel mult două elemente din Ω ce au credibilitatea nenulă.*

Propoziția 9.10 (Legea semicontinuității credibilității) *Fie $\{A_i\}_{i \in \mathbb{N}}$ un șir de evenimente. Atunci are loc relația:*

$$\lim_{i \rightarrow \infty} Cr(A_i) = Cr(\lim_{i \rightarrow \infty} A_i) \quad (9.6)$$

dacă și numai dacă una din următoarele identități este satisfăcută:

1. $A_i \uparrow A$ cu $Cr(A) \leq 0,5$.
2. $A_i \downarrow A$ cu $Cr(A) \geq 0,5$.
3. $A_i \uparrow A$ cu $Cr(A) < 0,5$.
4. $A_i \downarrow A$ cu $Cr(A) > 0,5$.

Seminar 9

S9.1 Fie $\Omega = \{\omega_1, \omega_2, \omega_3\}$ și:

$$Cr(\omega_1) = 0,6, Cr(\omega_2) = 0,3, Cr(\omega_3) = 0,2$$

$$Cr(\{\omega_1, \omega_2\}) = 0,8, Cr(\{\omega_1, \omega_3\}) = 0,7, Cr(\{\omega_2, \omega_3\}) = 0,4$$

iar $Cr(\Omega) = 1 = 1 - Cr(\emptyset)$. Este Cr o măsură de credibilitate pe Ω ?

Chapter 10

Variabile fuzzy pe spații de credibilitate

Fie (Ω, Cr) un spațiu de credibilitate.

- Definiția 10.1** i) O aplicație $\xi : \Omega \rightarrow \mathbb{R}$ se numește *variabilă fuzzy*.
ii) O funcție $\xi : \Omega \rightarrow \mathbb{R}$ se numește *vector fuzzy n-dimensional*.
iii) Se numește *funcția de apartenență* (sau *membership*) a variabilei fuzzy ξ , funcția $\mu = \mu_\xi : \mathbb{R} \rightarrow [0, 1]$:

$$\mu_\xi = \min\{2Cr(\xi = x), 1\}. \quad (10.1)$$

Funcția membership reprezintă gradul de posibilitate ca un număr real să fie valoare a variabilei fuzzy respective. Astfel, $\mu_\xi(x) = 0$ dacă x este o valoare "imposibilă" respectiv $\mu_\xi(x) = 1$ dacă x este cea mai posibilă valoare a lui ξ .

Este evident că unei variabile fuzzy i se asociază o unică funcție membership dar este posibil ca o aplicație de la \mathbb{R} la \mathbb{R} să fie funcția membership pentru mai multe variabile fuzzy. Spre exemplu, fie $\Omega = \{\omega_1, \omega_2\}$ și definim $Cr(\omega_1) = Cr(\omega_2) = 0,5$. Avem atunci că (Ω, Cr) este un spațiu de credibilitate pentru care definim variabilele fuzzy:

$$\xi_1(\omega) = \begin{cases} 0, & \omega = \omega_1 \\ 1, & \omega = \omega_2. \end{cases}$$

$$\xi_2(\omega) = \begin{cases} 1, & \omega = \omega_1 \\ 0, & \omega = \omega_2 \end{cases}$$

Aceste două variabile fuzzy au aceeași funcție membership:

$$\mu(x) = \begin{cases} 1, & x \in \{0, 1\} \\ 0, & x \notin \{0, 1\}. \end{cases}$$

Un rezultat important în teoria credibilității este următoarea teoremă ce afirmă că știind funcția membership a unei variabile aleatoare date putem determina credibilitatea unui eveniment:

Teorema 10.2 (Teorema inversă a credibilității) Fie ξ o variabilă fuzzy pe spațiul de credibilitate (Ω, Cr) având funcția membership μ . Atunci, pentru orice submulțime B a lui

\mathbb{R} , avem:

$$Cr(\xi \in B) = \frac{1}{2} \left(\sup_{x \in B} \mu(x) + 1 - \sup_{x \in \bar{B}} \mu(x) \right). \quad (10.2)$$

Drept consecințe avem:

$$Cr(\xi = x) = \frac{1}{2} \left(\mu(x) + 1 - \sup_{y \neq x} \mu(y) \right) \quad (10.3)$$

$$Cr(\xi \leq x) = \frac{1}{2} \left(\sup_{y \leq x} \mu(y) + 1 - \sup_{y < x} \mu(y) \right) \quad (10.4)$$

$$Cr(\xi \geq x) = \frac{1}{2} \left(\sup_{y \geq x} \mu(y) + 1 - \sup_{y < x} \mu(y) \right). \quad (10.5)$$

Dacă funcția μ este continuă atunci pentru orice $x \in \mathbb{R}$ avem:

$$Cr(\xi = x) = \frac{\mu(x)}{2}. \quad (10.6)$$

Propoziția 10.3 (Caracterizarea funcțiilor membership) *Funcția $\mu : \mathbb{R} \rightarrow [0, 1]$ este funcția membership a unei variabile fuzzy dacă și numai dacă $\sup \mu(x) = 1$.*

Definiția 10.4 Se numește *distribuția credibilă* a variabilei fuzzy ξ , funcția $\Phi : \mathbb{R} \rightarrow [0, 1]$:

$$\Phi(x) = Cr(\omega \in \Omega : \xi(\omega) < x). \quad (10.7)$$

Folosind teorema inversă a credibilității avem:

Propoziția 10.4 *Fie variabila fuzzy ξ cu funcția membership μ . Atunci pentru orice $x \in \mathbb{R}$ avem:*

$$\Phi(x) = \frac{1}{2} \left(\sup_{y \leq x} \mu(y) + 1 - \sup_{y > x} \mu(y) \right). \quad (10.8)$$

Chapter 11

Entropia, energia și corelația surselor de informație

Definiția 11.1 Numim *sursă de informație* o pereche $S = (\Sigma, \pi)$ cu Σ alfabet și π o *distribuție de probabilitate* pe Σ adică o aplicație $\pi : \Sigma \rightarrow \mathbb{R}_+$ satisfăcând $\sum_{s \in \Sigma} \pi(s) = 1$. Distribuția π o numim *pozitivă* dacă $\pi(s) > 0$ pentru orice $s \in \Sigma$.

- Observații 11.2** i) Avem că $\pi(s) \in [0, 1]$ pentru orice $s \in \Sigma$.
ii) O sursă de informație poate fi gândită ca un dispozitiv "black-box" care emite simboluri din Σ fiecare astfel de simbol s fiind emis cu probabilitatea $\pi(s)$.
iii) Fixăm $|\Sigma| = n$ și notăm $S = (\Sigma = (s_i), \pi = (\pi_i)), 1 \leq i \leq n$ cu convenția $p_1 \geq \dots \geq p_n$. Vom nota tabelar:

S	s_1	\dots	s_n
π	p_1	\dots	p_n

Exemplul 11.3 $\pi_u(s) = \frac{1}{n}$ pentru orice $s \in \Sigma$ este o distribuție pozitivă de probabilitate numită *distribuția uniformă*.

Putem extinde π la monoidul cuvintelor obținându-se un morfism de la Σ^* la monoidul multiplicativ al lui $[0, 1]$, $\pi : \Sigma^* \rightarrow ([0, 1], \cdot, 1)$ considerând:

- i) $\pi(\varepsilon) = 0$,
ii) $\pi(w) = \pi(w(1)) \dots \pi(w(k))$ pentru orice $w \in \Sigma^k, k \geq 2$.

Proprietatea de morfism o interpretăm astfel: probabilitatea emiterii unui simbol este independentă de simbolurile emise anterior; din acest motiv, sursele de informații astfel definite mai sunt numite *fără memorie*, cele cu memorie mai fiind numite *surse Markov*. Obținem astfel o extindere a lui π la limbaje peste Σ :

- iii) $\pi(\emptyset) = 0$,
iv) $\pi(L) = \sum_{w \in L} \pi(w)$ dacă L este submulțime nevidă a lui Σ^* .

Numărul real nenegativ $\pi(L)$ îl numim π -*măsura* lui L . Astfel, π_u -*măsura* lui L o numim *indicatorul de cod* al lui L .

Definiția 11.4 Limbajul produs $L_1 L_2$ se numește *neambiguu* dacă pentru orice $w \in L_1 L_2$ există cuvintele unice $u \in L_1$ și $v \in L_2$ așa încât $w = uv$.

- Propoziția 11.5** 1) $\pi(\Sigma^k) = 1$ pentru orice $k \geq 1$.
2) $\pi(\cup_{i \in I} L_i) \leq \sum_{i \in I} \pi(L_i)$ pentru orice familie $L_i, i \in I$ cel mult numărabilă de submulțimi ale lui Σ^* cu următoarea convenție: dacă există $i \in I$ așa încât $\pi(L_i) = \infty$ atunci $\pi(\cup_{i \in I} L_i) = \infty$.

Dacă familia L_i are mulțimile disjuncte atunci avem egalitate.

3) $\pi(L_1 L_2) \leq \pi(L_1)\pi(L_2)$. Dacă produsul $L_1 L_2$ este neambiguu atunci avem egalitate.

4) $\pi(L^*) \leq \sum_{i \geq 0} \pi(L^n) \leq \sum_{i \geq 0} (\pi(L))^n$ cu convenția: $\pi(L) = \infty$ implică $\pi(L^*) = \infty$.

Conceptul de entropie ca măsură a informației și a gradului de incertitudine, a fost introdus în 1948 de către Claude Shannon. Această noțiune este profund analoagă conceptului similar din termodinamică unde a fost introdus de către Clausius în 1864 ca măsură a gradului de dezordine al unui sistem fizic.

Deoarece din punct de vedere matematic, informația furnizată de simbolul $s_k \in \Sigma$ este $I_k = -\log p_k$ rezultă că media ponderată a informațiilor furnizate de sursa dată este:

Definiția 11.6 Se numește *entropie* a sursei S numărul real nenegativ:

$$H(\pi) = -\sum_{i=1}^n p_i \log p_i \quad (11.1)$$

unde logaritmul este în baza 2 și avem convenția $0 \cdot \log 0 = 0$. Unitatea de măsură a entropiei este "biți/simbol".

Alegerea bazei 2 se poate considera ca fiind neimportantă matematic datorită proprietății de schimbare a bazei logaritmilor și este impusă din punct de vedere tehnic de utilizarea calculului binar în procesarea datelor de către calculatoare.

Lema 11.7 Dacă $b > 0$ și $x > 0$ atunci $\log_b x \leq x - 1$ cu egalitate doar pentru $x = 1$.

Propoziția 11.8 Inegalitatea Gibbs Fie numerele reale $(p_i, q_i), 1 \leq i \leq n$ satisfăcând:

i) $0 \leq p_i, q_i \leq 1$,

ii) $\sum_{i=1}^n q_i \leq 1 = \sum_{i=1}^n p_i$.

Atunci: $-\sum_{i=1}^n p_i \log p_i \leq -\sum_{i=1}^n p_i \log q_i$. Avem egalitate dacă și numai dacă $p_i = q_i$ pentru toți $i \in \mathbb{N}_n$.

Corolar 11.9 Pentru orice sursă de n informații avem: $0 \leq H(\pi) \leq \log n = H(\pi_u)$.

Demonstrație Avem $H(\pi_u) = -\sum_{i=1}^n \frac{1}{n} \log \frac{1}{n} = -\log \frac{1}{n} = \log n$. Deoarece $p_i \in [0, 1]$ avem $-p_i \log p_i \geq 0$ și rezultă membrul stâng. Pentru membrul drept aplicăm inegalitatea Gibbs cu $q_i = \frac{1}{n}, 1 \leq i \leq n$. \square

Cazurile de egalitate pentru inegalitatea precedentă sunt precizate de:

Propoziția 11.10 i) $H(\pi) = 0$ dacă și numai dacă $p_1 = 1$.

ii) $H(\pi) = \log n$ dacă și numai dacă $\pi = \pi_u$.

Demonstrație i) $H(\pi) = 0$ dacă și numai pentru orice $i \in \mathbb{N}_n$ avem $p_i \log p_i = 0$. Cum nu putem avea că toți p_i sunt nuli deoarece suma lor este 1 rezultă că trebuie să existe măcar un indice i așa încât $p_i = 1$. Din ordonarea probabilităților p_i rezultă $p_1 = 1$.

ii) rezultă din cazul de egalitate al Inegalității Gibbs. \square

Observația 11.11 În termodinamică unui sistem fizic izolat, o stare de echilibru este caracterizată de entropie maximă. Prin analogie, am putea numi distribuția uniformă ca fiind starea de echilibru "informațional" al sursei date, toate cele n simboluri (stări) fiind la fel de probabile.

Definiția 11.12 Se dau sursele de informație $S_1 = (\Sigma_1, \{p_i\}, i \in I), S_2 = (\Sigma_2, \{q_j\}, j \in J)$. Numim *produsul* lor sursa $S_1 S_2 = (\Sigma_1 \times \Sigma_2, \{p_i q_j\})$. (Avem imediat $\sum_{i,j} p_i q_j = 1$.)

Putem spune că sursa produs S^2 generează grupe de câte două mesaje ale sursei S . Analog pentru o putere $k \geq 2$ oarecare.

Propoziția 11.13 $H(S_1 S_2) = H(S_1) + H(S_2)$. În consecință $H(S^k) = kH(S)$.

Demonstrație $-\sum_{i,j} p_i q_j \log(p_i q_j) = -\sum_{i,j} p_i q_j \log p_i - \sum_{i,j} p_i q_j \log q_j = \sum_j q_j H(S_1) + \sum_i p_i H(S_2)$. \square

Definiția 11.14 Pentru sursa dată inițial definim:

- 1) *redundanța* $R = \log n - H(\pi)$,
- 2) *eficiența* $\eta = \frac{H(\pi)}{\log n}$.

Exemplul 11.15 (n=2) Notând $p_1 = p$ avem:

$$\begin{array}{c|cc} S & s_1 & s_2 \\ \hline \pi & p & 1-p \end{array}$$

- i) $H(p, 1-p) = \eta = -p \log p - (1-p) \log(1-p)$,
- ii) $R = 1 + p \log p + (1-p) \log(1-p)$.

Inspirat de expresia energiei cinetice care este suma pătratelor vitezelor, matematicianul român Octav Onicescu a introdus în 1964 conceptul următor:

Definiția 11.16 Numim *energia* sursei date numărul real strict pozitiv:

$$E(\pi) = \sum_{i=1}^n p_i^2. \quad (11.2)$$

- Propoziția 11.17**
- i) $E(\pi_u) = \frac{1}{n} \leq E(\pi) \leq 1$.
 - ii) $E(\pi) = \frac{1}{n}$ dacă și numai dacă $\pi = \pi_u$.
 - iii) $E(\pi) = 1$ dacă și numai dacă $p_1 = 1$.
 - iv) $E(S_1 S_2) = E(S_1) E(S_2)$.

Demonstrație i) Faptul că $E(\pi_u) = \frac{1}{n}$ este imediat ca și inegalitatea din dreapta deoarece p_i fiind subunitare avem $E(\pi) \leq \sum_{i=1}^n p_i$. Pentru a arăta inegalitatea din stânga fie $x_i = p_i - \frac{1}{n}$; rezultă $\sum_{i=1}^n x_i = 0$. Avem $E(\pi) = \frac{1}{n} + \sum_{i=1}^n x_i^2$.

ii) Avem egalitate în stânga dacă și numai dacă toți x_i sunt nuli.

iii) Avem egalitate în dreapta dacă și numai dacă $p_i^2 = p_i$ ceea ce revine la $p_1 = 1$ și $p_2 = \dots = p_n = 0$.

iv) $\sum_{i,j} (p_i q_j)^2 = (\sum p_i^2)(\sum q_j^2)$ din independența celor două surse. \square

Definiția 11.18 Date sursele S_1 și S_2 de aceeași dimensiune n numim:

i) *corelația* lor numărul real nenegativ $C(\pi_1, \pi_2) = \sum_{i=1}^n p_i q_i$.

ii) *coeficientul de corelație* numărul real nenegativ $CC(\pi_1, \pi_2) = \frac{C(\pi_1, \pi_2)}{\sqrt{E\pi_1 E\pi_2}}$.

Propoziția 11.19 $CC(\pi_1, \pi_2) \leq 1 = CC(\pi, \pi)$ cu egalitate dacă și numai dacă $\pi_1 = \pi_2$.

Demonstrație Faptul că $CC(\pi, \pi) = 1$ este imediat iar inegalitatea este exact inegalitatea Cauchy-Buniakowski-Schartz (CBS) din teoria produselor scalar. Avem egalitate în inegalitatea CBS dacă și numai dacă vectorii n -dimensionali π_1, π_2 sunt coliniari adică există numărul real λ așa încât $\pi_2 = \lambda \pi_1$. Dar din $\sum p_i^1 = \sum p_i^2 = 1$ rezultă $\lambda = 1$. \square

SEMINAR 11

S11.1 Se dă o sursă cu $n = 5$ și $p_1 = \frac{1}{2}, p_2 = \frac{1}{4}, p_3 = \frac{1}{8}, p_4 = p_5 = \frac{1}{16}$. Se cere entropia, redundanța, eficiența și energia acestei surse.

Rezolvare $H = \frac{1}{2} \cdot 1 + \frac{1}{4} \cdot 2 + \frac{1}{8} \cdot 3 + \frac{1}{16} \cdot 4 \cdot 2 = \frac{15}{8} = 1.875$ biți/simbol.
 $R = \log 5 - H = 2.3219 - 1.8750 = 0.4469, \eta = \frac{1.875}{2.3219} = 0.8075,$
 $E = \frac{1}{4} + \frac{1}{16} + \frac{1}{64} + \frac{2}{256} = 0.25 + 0.0625 + 0.0156 + 0.0078 = 0.3359$

Index

- π -măsura unui limbaj, 53
- σ -algebră, 11
- σ -algebra generată de o familie, 11

- acceptarea unui lot de produse, 32
- apartenența la o mulțime, 3
- aplicație G -invariantă, 41
- aplicație măsurabilă, 31

- bază ortornormată, 18
- bila deschisă, 12
- binomul lui Newton, 20

- câmp de probabilitate, 5
- câmpul evenimentelor, 5
- caracterizarea funcțiilor membership, 52
- cea mai bună funcție de decizie invariantă, 42
- clasa de echivalență, 4
- coeficientul de corelație a două surse, 55
- coeficientul de corelație a două v. a., 27
- combinări, 8
- complementara unei submulțimi, 4
- corelația a două surse, 55
- corelația a două v. a., 27
- covarianța a două v. a., 27
- culori MATLAB, 14

- decizie ce domină pe o alta, 45
- decizie cel puțin la fel de bună ca o alta, 45
- decizii echivalente, 45
- definiția clasică a probabilității, 6
- densitatea de repartiție a unei v. a., 20
- dispersia unei v. a., 26
- dispersia variabilei aleatoare normale, 30
- dispersia variabilei binomiale, 28
- dispersia variabilei Poisson, 29
- distanța Euclidiană, 11
- distribuția credibilă a unei variabile fuzzy, 52
- distribuția unei variabile aleatoare, 12
- distribuția uniformă de probabilitate, 53

- distribuție de probabilitate, 53
- domeniu de definiție al unei relații, 4

- ecuație funcțională, 42
- eficiența unei surse de informație, 55
- element într-o mulțime, 3
- energia unei surse de informație, 55
- entropie, 54
- eveniment, 5
- eveniment elementar, 5
- eveniment imposibil, 5
- eveniment sigur, 5
- evenimente echiprobabile, 6

- factorialul, 7
- funcția caracteristică a unei submulțimi, 4
- funcția de apartenență a unei variabile fuzzy, 51
- funcția de repartiție a unei v.a., 19
- funcția risc a unei probleme de decizie, 32
- funcție, 4
- funcție de decizie, 32
- funcție de decizie G -invariantă, 42
- funcție măsurabilă, 31

- grup tranzitiv, 42
- grupul bijecțiilor, 41
- grupul simetric, 41
- grupul transformărilor de scală, 42

- indicatorul de cod al unui limbaj, 53
- inegalitatea Gibbs, 54
- intersecția mulțimilor, 4

- lege a evenimentelor rare, 21
- lege normală, 21
- limbaj produs neambiguu, 53
- linii MATLAB, 15

- măsură de credibilitate, 47
- măsură de probabilitate, 12

- măsură nul-aditivă, 48
 markere MATLAB, 15
 matrice ortogonală, 18
 matricea unitate, 18
 media a n zaruri, 28
 media unei variabile aleatoare, 25
 media unui zar, 28
 media variabilei aleatoare normale, 29
 media variabilei binomiale, 28
 media variabilei Poisson, 29
 mixtură, 45
 momentele unei v. a., 25
 mulțime, 3
 mulțime boreliană, 12
 mulțime deschisă, 12
 mulțime finită, 3
 mulțime măsurabilă, 11
 mulțime numărabilă, 11
 mulțimea numerelor întregi, 3
 mulțimea numerelor iraționale, 3
 mulțimea numerelor naturale, 3
 mulțimea numerelor raționale, 3
 mulțimea numerelor reale, 3
 mulțimea valorilor unei relații, 4

 norma, 11

 parametri echivalenți într-o relație de decizie, 42
 partiție a unei mulțimi, 4
 pierdere G -invariantă, 42
 probabilitate, 5
 problemă de decizie, 32
 problemă de decizie G -invariantă, 42
 produsul a două v. a., 27
 produsul a două v. a. discrete, 27
 produsul scalar, 11

 redundanța unei surse de informație, 55
 regulă de decizie, 32
 regula de adunare a probabilităților, 5
 relație, 4
 relație de echivalență, 4
 relație de ordine, 4
 reuniunea mulțimilor, 4

 schema bilei revenite, 20
 spațiu de credibilitate, 47

 spațiu de probabilitate, 12
 spațiu măsurabil, 11
 spațiul Euclidian, 11
 spațiul evenimentelor, 5
 sursă de informație, 53
 sursa produs de informații, 54

 teorema de invarianță a riscului, 42
 teorema inversă a credibilității, 52
 transformare bimăsurabilă, 41
 transformare pe o mulțime, 41

 unghiul dintre doi vectori nenuli, 18
 urna cu bile de două culori, 13

 v. a. a primei realizări, 43
 v. a. cu repartiție uniformă, 21
 v. a. de tip Bernoulli, 13
 v. a. de tip Poisson, 21
 variabilă aleatoare, 12
 variabilă aleatoare binomială, 20
 variabilă aleatoare continuă, 12
 variabilă aleatoare de tip Gauss, 21
 variabilă aleatoare discretă, 12
 variabilă aleatoare simplă, 12
 variabilă fuzzy, 51
 variabile aleatoare corelate, 27
 variabile aleatoare independente, 27
 variabile aleatoare necorelate, 27
 vector fuzzy n -dimensional, 51
 vector unitar, 18
 vectori ortogonali, 17
 vectori perpendiculari, 17
 versor, 18