

CAPITOLUL 2

ENTROPIE ȘI INFORMAȚIE

2.1. SURSE DE INFORMAȚIE

În această carte, ne ocupăm cu definiția și tratarea matematică a informației. Aceasta ne permite să construim sisteme de comunicație cu ajutorul cărora luăm legătura, confortabil și eficient, cu realități care se desfășoară la sute și poate mii de kilometri distanță: să ne gândim la telefon, la radio, la Internet. Spunem că transmitem informație. Dar ce transmitem concret? Dacă analizăm tipurile de mesaje pe care simțim nevoia să le emitem și să le recepționăm, vom constata că ele se reduc la următoarele:

- voce, vorbire (mesaj verbal)
- muzică (sunet ca și vocea, dar de bandă de frecvențe mai largă)
- imagine, statică și dinamică (mesaj vizual)
- semne și simboluri, reprezentând tot un mesaj vizual, dar abstract.

Vedem că, din cele cinci simțuri, numai două, auzul și văzul, sunt implicate în aceasta. Ca și animalele, noi primim desigur informație și prin alte simțuri (miros și gust, la care putem avea acces în comun), dar dacă vrem să împărtășim această informație cuiva, ne vom folosi de aparatul nostru fonator, vom gesticula, vom desena ideograme sau vom scrie. S-ar părea că simțul tactil este și mai intim, dar să nu uităm că semenii noștri nevăzători citesc și scriu (cu o mașină de dactilografiat specială) utilizând alfabetul Braille constituit din semne în relief.

În vederea înregistrării, prelucrării și transmiterii la distanță, sunetele, imaginile și simbolurile zise alfanumerice (litere, numere, semne diacritice și altele) sunt convertite în semnale electrice, electromagnetice sau

optice. Atunci când vorbim la telefon, undele sonore pe care le produce organul nostru fonator sunt transformate de microfon într-un curent electric variabil care este transmis pe un circuit electric la centrala telefonică și de acolo mai departe până la telefonul interlocutorului. Un dispozitiv care convertește o mărime neelectrică într-una electrică sau invers se numește *traductor*. Microfonul este un exemplu de traductor care convertește o undă sonoră într-un curent electric variabil; casca telefonică efectuează operația inversă. Din acest motiv, prin sursă de informație vom înțelege orice aparat care, incluzând dacă este cazul și traductoare, poate genera mesaje în formă electrică – cel mai adesea, un curent sau o tensiune. Exemple de surse de informație: un microfon, doza unui pick-up, capul de citire al unui casetofon, o cameră de luat vederi, interfața serială a unui calculator electronic.

Prin semnal, înțelegem o mărime fizică a cărei variație în timp poate transporta mesaje. Dacă nu se precizează altfel, această mărime fizică este o tensiune electrică, măsurată în general între un punct de circuit numit „bornă caldă“ și un punct de referință, numit „masă electrică“ sau „pământ“. Semnalele sunt *analogice* dacă sunt funcții continue de timp și *discrete* sau *digitale* dacă pot lua numai un număr finit de valori, iar o anumită valoare este menținută constantă pe un interval elementar de timp. Denumirea de *analogic* are o explicație istorică: în epoca de pionierat a calculatoarelor electronice, cele zise analogice realizau diverse operații matematice cu ajutorul unor circuite electrice R, L, C a căror funcționare, după cum se știe, este descrisă de ecuații integro-diferențiale și astfel, toate mărimile implicate erau funcții continue de timp, iar funcționarea avea loc prin analogie cu funcționarea unor circuite electrice liniare. Între timp, calculatoarele digitale s-au impus, iar din cele analogice n-a supraviețuit decât denumirea de *analogic*, drept sinonim pentru continuu.

Sursele de informație se clasifică în *analogice* (care generează voce, muzică, imagini fixe și în mișcare) și *discrete* (care generează fișiere de calculator, șiruri de simboluri numerice sau alfanumerice). Conform teoremei eșantionării, care se studiază la cursul de „Semnale, circuite și sisteme“, în general un semnal analogic poate fi transformat într-un semnal digital din care semnalul analogic originar poate fi recuperat, în limitele unei distorsiuni acceptabile. Având în vedere și nivelul foarte ridicat la care a ajuns producția de circuite integrate digitale și a celor de conversie (analogic-digitală și digital-analogică), în prezent, indiferent de forma lor la sursa primară, fie ea analogică sau digitală, semnalele sunt tratate unificat, prin tehnici pur numerice. Este ceea ce se numește *multimedia*.

2.2. ENTROPIE

Entropia este o măsură a incertitudinii cu privire la o variabilă aleatoare. Termenul de *entropie* a fost împrumutat din termodinamică, o ramură a fizicii în care fenomenele studiate sunt preponderent probabiliste. Pentru un observator exterior, semnalul de ieșire generat de o sursă de informație la un moment dat este o variabilă aleatoare. O sursă de informație discretă emite un șir de litere dintr-un alfabet de L litere posibile, să spunem $\{x_1, x_2, \dots, x_L\}$. Presupunem că fiecare literă din alfabetul $\{x_1, x_2, \dots, x_L\}$ are o probabilitate de apariție p_k dată:

$$p_k = P(X = x_k), \quad 1 \leq k \leq L \quad (2.1)$$

unde

$$\sum_{k=1}^L p_k = 1.$$

Entropia unei variabile aleatoare X este prin definiție mărimea

$$H(X) = -\sum_{k=1}^L p_k \log_2 p_k \quad (2.2)$$

Se observă că baza logaritmului este 2, ceea ce face ca entropia să se exprime în biți. Spre exemplu, în cazul aruncării unei monede nemăsluite, $p(\text{cap}) = p(\text{ban}) = \frac{1}{2}$ și $H(X) = 1$ bit. Entropia se poate exprima și într-o altă bază de logaritmi, spre exemplu numărul transcendent e sau numărul 10, în care caz unitatea de măsură este *nat* (de la natural) și, respectiv, *hartley* (denumită astfel în onoarea lui R.V. Hartley, cel care, în 1928, a sugerat utilizarea logaritmului drept măsură a informației). Mai observăm și că entropia nu depinde de valorile luate de variabila aleatoare X , ci doar de probabilitățile cu care sunt luate aceste valori.

Știm că, în teoria funcțiilor de o variabilă reală, funcția logaritm se definește numai pe mulțimi de numere strict pozitive. Având însă în vedere că $x \log x \rightarrow 0$ pentru $x \rightarrow 0$, vom adopta convenția că $0 \log 0 = 0$. Prin urmare, adăugarea unor termeni de probabilitate zero nu schimbă entropia.

Putem interpreta entropia lui X drept *expectația* (valoarea medie statistică, sau valoarea așteptată) funcției $\log_2 \frac{1}{p(x)}$:

$$H(X) = E\left\{\log_2 \frac{1}{p(x)}\right\} \quad (2.3)$$

Entropia este întotdeauna pozitivă:

$$H(X) \geq 0 \quad (2.4)$$

Într-adevăr, întrucât $0 \leq p_k \leq 1$ pentru $1 \leq k \leq L$, urmează că $\log_2(1/p_k) \geq 0$.

Fie o variabilă aleatoare X care nu ia decât două valori:

$$X = \begin{cases} 1 & \text{cu probabilitate } p \\ 0 & \text{cu probabilitate } 1-p \end{cases} \quad (2.5)$$

Conform relației de definiție (2.2), avem:

$$H(X) = -p \log_2 p - (1-p) \log_2 (1-p) \quad (2.6)$$

Prin definiție, aceasta se mai notează și $H(p)$. Graficul funcției $H(p)$ este arătat în figura 2.1.




Fig. 2.1. Graficul funcției entropie $H(p)$.

Se observă că entropia este o funcție concavă de p și este egală cu 0 pentru $p = 0$ sau 1. Pentru aceste valori, variabila nu este aleatoare și nu există nici o incertitudine, încât este normal ca entropia să fie zero. Incertitudinea este maximă pentru $p = \frac{1}{2}$, ceea ce corespunde valorii maxime a entropiei.

2.3. ENTROPIE COMUNĂ ȘI ENTROPIE CONDIȚIONATĂ

Fie două variabile aleatoare discrete, X cu rezultatele posibile $x_i, i = 1, 2, \dots, n$ și Y cu rezultatele posibile $y_j, j = 1, 2, \dots, m$. Considerăm variabila aleatoare (X, Y) care ia valori vectoriale (x_i, y_j) cu probabilitatea $p(x_i, y_j)$, ceea ce se scrie simbolic $(X, Y) \sim p(x, y)$. Prin definiție, entropia comună a variabilelor aleatoare discrete X și Y este entropia variabilei aleatoare discrete (X, Y) :

$$H(X, Y) = -\sum_{i=1}^n \sum_{j=1}^m p(x_i, y_j) \log_2 p(x_i, y_j) \quad (2.7)$$

Mai putem scrie aceasta și astfel:

$$H(X, Y) = -E \log_2 p(X, Y) \quad (2.8)$$

Prin definiție, entropia condiționată $H(Y|X)$ este entropia variabilei aleatoare Y condiționată de realizarea variabilei aleatoare X :

$$\begin{aligned} H(Y|X) &= \sum_{i=1}^n p(x_i) H(Y|X = x_i) \\ &= -\sum_{i=1}^n p(x_i) \sum_{j=1}^m p(y_j | x_i) \log_2 p(y_j | x_i) \\ &= -\sum_{i=1}^n \sum_{j=1}^m p(x_i, y_j) \log_2 p(y_j | x_i) \\ &= -E_{p(x,y)} \log_2 p(Y|X) \end{aligned} \quad (2.9)$$

Modul în care am definit entropia comună și entropia condiționată ne permite să scriem că entropia unei perechi de variabile aleatoare este egală

cu entropia uneia dintre ele plus entropia condiționată a celeilalte, ceea ce constituie enunțul teoremei următoare:

TEOREMA 2.1 (*Regula lanțului*):

$$H(X, Y) = H(X) + H(Y | X) \tag{2.10}$$

DEMONSTRAȚIE

$$\begin{aligned} H(X, Y) &= -\sum_{i=1}^n \sum_{j=1}^m p(x_i, y_j) \log_2 p(x_i, y_j) \\ &= -\sum_{i=1}^n \sum_{j=1}^m p(x_i, y_j) \log_2 p(x_i) p(y_j | x_i) \\ &= -\sum_{i=1}^n \sum_{j=1}^m p(x_i, y_j) \log_2 p(x_i) - \sum_{i=1}^n \sum_{j=1}^m p(x_i, y_j) \log_2 p(y_j | x_i) \tag{2.11} \\ &= -\sum_{i=1}^n p(x_i) \log_2 p(x_i) - \sum_{i=1}^n \sum_{j=1}^m p(x_i, y_j) \log_2 p(y_j | x_i) \\ &= H(X) + H(Y | X) \end{aligned}$$

O altă demonstrație a acestei teoreme, mai elegantă, este de a scrie

$$\log_2 p(X, Y) = \log_2 p(X) + \log_2 p(Y | X) \tag{2.12}$$

Aplicând în ambii membri ai ecuației (2.12) operatorul de expectație E , obținem (2.10).

EXEMPLUL 2.1: Fie perechea de variabile aleatoare (X, Y) având distribuția comună de probabilitate

$Y \backslash X$	1	2	3	4
1	$\frac{1}{8}$	$\frac{1}{16}$	$\frac{1}{32}$	$\frac{1}{32}$
2	$\frac{1}{16}$	$\frac{1}{8}$	$\frac{1}{32}$	$\frac{1}{32}$
3	$\frac{1}{16}$	$\frac{1}{16}$	$\frac{1}{16}$	$\frac{1}{16}$
4	$\frac{1}{4}$	0	0	0

Să calculăm mai întâi distribuția marginală a lui X . Avem:

$$p(x_1) = \sum_{j=1}^4 p(x_1, y_j) = \frac{1}{8} + \frac{1}{16} + \frac{1}{16} + \frac{1}{4} = \frac{1}{2}$$

$$p(x_2) = \sum_{j=1}^4 p(x_2, y_j) = \frac{1}{16} + \frac{1}{8} + \frac{1}{16} + 0 = \frac{1}{4}$$

$$p(x_3) = \sum_{j=1}^4 p(x_3, y_j) = \frac{1}{32} + \frac{1}{32} + \frac{1}{16} + 0 = \frac{1}{8}$$

$$p(x_4) = \sum_{j=1}^4 p(x_4, y_j) = \frac{1}{32} + \frac{1}{32} + \frac{1}{16} + 0 = \frac{1}{8}$$

Deci, distribuția marginală a lui X este $\left(\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{8}\right)$.

Calculăm și distribuția marginală a lui Y .

$$p(y_1) = \sum_{i=1}^4 p(x_i, y_1) = \frac{1}{8} + \frac{1}{16} + \frac{1}{32} + \frac{1}{32} = \frac{1}{4}$$

$$p(y_2) = \sum_{i=1}^4 p(x_i, y_2) = \frac{1}{16} + \frac{1}{8} + \frac{1}{32} + \frac{1}{32} = \frac{1}{4}$$

$$p(y_3) = \sum_{i=1}^4 p(x_i, y_3) = \frac{1}{16} + \frac{1}{16} + \frac{1}{16} + \frac{1}{16} = \frac{1}{4}$$

$$p(y_4) = \sum_{i=1}^4 p(x_i, y_4) = \frac{1}{4} + 0 + 0 + 0 = \frac{1}{4}$$

Distribuția marginală a lui Y este deci $\left(\frac{1}{4}, \frac{1}{4}, \frac{1}{4}, \frac{1}{4}\right)$.

Acum putem calcula entropiile lui X și Y astfel:

$$\begin{aligned} H(X) &= \sum_{i=1}^4 p(x_i) \log_2 \frac{1}{p(x_i)} \\ &= \frac{1}{2} \log_2 2 + \frac{1}{4} \log_2 4 + \frac{1}{8} \log_2 8 + \frac{1}{8} \log_2 8 = \frac{1}{2} + \frac{2}{4} + \frac{3}{8} + \frac{3}{8} = \frac{7}{4} \text{ biti} \end{aligned}$$

$$H(Y) = \sum_{j=1}^4 p(y_j) \log_2 \frac{1}{p(y_j)} = 4 \cdot \frac{1}{4} \log_2 4 = 2 \text{ biti}$$

Calculăm probabilitățile condiționate $p(y_j | x_i)$ astfel:

$$p(y_1 | x_1) = \frac{p(x_1, y_1)}{p(x_1)} = \frac{\frac{1}{8}}{\frac{1}{2}} = \frac{1}{4} \quad p(y_1 | x_2) = \frac{p(x_2, y_1)}{p(x_2)} = \frac{\frac{1}{16}}{\frac{1}{4}} = \frac{1}{4}$$

$$p(y_1 | x_3) = \frac{p(x_3, y_1)}{p(x_3)} = \frac{\frac{1}{32}}{\frac{1}{8}} = \frac{1}{4} \quad p(y_1 | x_4) = \frac{p(x_4, y_1)}{p(x_4)} = \frac{\frac{1}{32}}{\frac{1}{8}} = \frac{1}{4}$$

$$p(y_2 | x_1) = \frac{p(x_1, y_2)}{p(x_1)} = \frac{\frac{1}{16}}{\frac{1}{2}} = \frac{1}{8} \quad p(y_2 | x_2) = \frac{p(x_2, y_2)}{p(x_2)} = \frac{\frac{1}{8}}{\frac{1}{4}} = \frac{1}{2}$$

$$p(y_2 | x_3) = \frac{p(x_3, y_2)}{p(x_3)} = \frac{\frac{1}{32}}{\frac{1}{8}} = \frac{1}{4} \quad p(y_2 | x_4) = \frac{p(x_4, y_2)}{p(x_4)} = \frac{\frac{1}{32}}{\frac{1}{8}} = \frac{1}{4}$$

$$p(y_3 | x_1) = \frac{p(x_1, y_3)}{p(x_1)} = \frac{\frac{1}{16}}{\frac{1}{2}} = \frac{1}{8} \quad p(y_3 | x_2) = \frac{p(x_2, y_3)}{p(x_2)} = \frac{\frac{1}{16}}{\frac{1}{4}} = \frac{1}{4}$$

$$p(y_3 | x_3) = \frac{p(x_3, y_3)}{p(x_3)} = \frac{\frac{1}{16}}{\frac{1}{8}} = \frac{1}{2} \quad p(y_3 | x_4) = \frac{p(x_4, y_3)}{p(x_4)} = \frac{\frac{1}{16}}{\frac{1}{8}} = \frac{1}{2}$$

$$p(y_4 | x_1) = \frac{p(x_1, y_4)}{p(x_1)} = \frac{\frac{1}{4}}{\frac{1}{2}} = \frac{1}{2} \quad p(y_4 | x_2) = \frac{p(x_2, y_4)}{p(x_2)} = 0$$

$$p(y_4 | x_3) = \frac{p(x_3, y_4)}{p(x_3)} = 0 \quad p(y_4 | x_4) = \frac{p(x_4, y_4)}{p(x_4)} = 0$$

Putem acum calcula entropia condiționată $H(Y|X)$ conform definiției:

$$\begin{aligned}
H(Y|X) &= \sum_{i=1}^4 \sum_{j=1}^4 p(x_i, y_j) \log_2 \frac{1}{p(y_j | x_i)} \\
&= p(x_1, y_1) \log_2 \frac{1}{p(y_1 | x_1)} + p(x_1, y_2) \log_2 \frac{1}{p(y_2 | x_1)} + \\
&+ p(x_1, y_3) \log_2 \frac{1}{p(y_3 | x_1)} + p(x_1, y_4) \log_2 \frac{1}{p(y_4 | x_1)} + \\
&+ p(x_2, y_1) \log_2 \frac{1}{p(y_1 | x_2)} + p(x_2, y_2) \log_2 \frac{1}{p(y_2 | x_2)} + \\
&+ p(x_2, y_3) \log_2 \frac{1}{p(y_3 | x_2)} + p(x_2, y_4) \log_2 \frac{1}{p(y_4 | x_2)} + \\
&+ p(x_3, y_1) \log_2 \frac{1}{p(y_1 | x_3)} + p(x_3, y_2) \log_2 \frac{1}{p(y_2 | x_3)} + \\
&+ p(x_3, y_3) \log_2 \frac{1}{p(y_3 | x_3)} + p(x_3, y_4) \log_2 \frac{1}{p(y_4 | x_3)} + \\
&+ p(x_4, y_1) \log_2 \frac{1}{p(y_1 | x_4)} + p(x_4, y_2) \log_2 \frac{1}{p(y_2 | x_4)} + \\
&+ p(x_4, y_3) \log_2 \frac{1}{p(y_3 | x_4)} + p(x_4, y_4) \log_2 \frac{1}{p(y_4 | x_4)} \\
&= \frac{1}{8} \log_2 4 + \frac{1}{16} \log_2 8 + \frac{1}{16} \log_2 8 + \frac{1}{4} \log_2 2 + \frac{1}{16} \log_2 4 + \\
&+ \frac{1}{8} \log_2 2 + \frac{1}{16} \log_2 4 + 0 + \frac{1}{32} \log_2 4 + \frac{1}{32} \log_2 4 + \frac{1}{16} \log_2 2 \\
&+ 0 + \frac{1}{32} \log_2 4 + \frac{1}{32} \log_2 4 + \frac{1}{16} \log_2 2 + 0 \\
&= \frac{1}{8} \cdot 2 + \frac{1}{16} \cdot 3 + \frac{1}{16} \cdot 3 + \frac{1}{4} + \frac{1}{16} \cdot 2 + \frac{1}{8} + \frac{1}{16} \cdot 2 + \frac{1}{32} \cdot 2 + \\
&+ \frac{1}{32} \cdot 2 + \frac{1}{16} + \frac{1}{32} \cdot 2 + \frac{1}{32} \cdot 2 + \frac{1}{16} = \frac{13}{8} \text{ biti.}
\end{aligned}$$

Să calculăm și probabilitățile condiționate $p(x_i | y_j)$:

$$\begin{aligned}
 p(x_1 | y_1) &= \frac{p(x_1, y_1)}{p(y_1)} = \frac{\frac{1}{8}}{\frac{1}{4}} = \frac{1}{2} & p(x_1 | y_2) &= \frac{p(x_1, y_2)}{p(y_2)} = \frac{\frac{1}{16}}{\frac{1}{4}} = \frac{1}{4} \\
 p(x_1 | y_3) &= \frac{p(x_1, y_3)}{p(y_3)} = \frac{\frac{1}{16}}{\frac{1}{4}} = \frac{1}{4} & p(x_1 | y_4) &= \frac{p(x_1, y_4)}{p(y_4)} = \frac{\frac{1}{4}}{\frac{1}{4}} = 1 \\
 p(x_2 | y_1) &= \frac{p(x_2, y_1)}{p(y_1)} = \frac{\frac{1}{16}}{\frac{1}{4}} = \frac{1}{4} & p(x_2 | y_2) &= \frac{p(x_2, y_2)}{p(y_2)} = \frac{\frac{1}{8}}{\frac{1}{4}} = \frac{1}{2} \\
 p(x_2 | y_3) &= \frac{p(x_2, y_3)}{p(y_3)} = \frac{\frac{1}{16}}{\frac{1}{4}} = \frac{1}{4} & p(x_2 | y_4) &= \frac{p(x_2, y_4)}{p(y_4)} = 0 \\
 p(x_3 | y_1) &= \frac{p(x_3, y_1)}{p(y_1)} = \frac{\frac{1}{32}}{\frac{1}{4}} = \frac{1}{8} & p(x_3 | y_2) &= \frac{p(x_3, y_2)}{p(y_2)} = \frac{\frac{1}{32}}{\frac{1}{4}} = \frac{1}{8} \\
 p(x_3 | y_3) &= \frac{p(x_3, y_3)}{p(y_3)} = \frac{\frac{1}{16}}{\frac{1}{4}} = \frac{1}{4} & p(x_3 | y_4) &= \frac{p(x_3, y_4)}{p(y_4)} = 0 \\
 p(x_4 | y_1) &= \frac{p(x_4, y_1)}{p(y_1)} = \frac{\frac{1}{32}}{\frac{1}{4}} = \frac{1}{8} & p(x_4 | y_2) &= \frac{p(x_4, y_2)}{p(y_2)} = \frac{\frac{1}{32}}{\frac{1}{4}} = \frac{1}{8} \\
 p(x_4 | y_3) &= \frac{p(x_4, y_3)}{p(y_3)} = \frac{\frac{1}{16}}{\frac{1}{4}} = \frac{1}{4} & p(x_4 | y_4) &= \frac{p(x_4, y_4)}{p(y_4)} = 0
 \end{aligned}$$

Cu ajutorul acestor probabilități, calculăm entropia condiționată $H(X | Y)$:

$$\begin{aligned}
H(X|Y) &= -\sum_{i=1}^4 \sum_{j=1}^4 p(x_i, y_j) \log_2 p(x_i, y_j) = \\
&= p(x_1, y_1) \log_2 \frac{1}{p(x_1|y_1)} + p(x_1, y_2) \log_2 \frac{1}{p(x_1|y_2)} + \\
&+ p(x_1, y_3) \log_2 \frac{1}{p(x_1|y_3)} + p(x_1, y_4) \log_2 \frac{1}{p(x_1, y_4)} + \\
&+ p(x_2, y_1) \log_2 \frac{1}{p(x_2|y_1)} + p(x_2, y_2) \log_2 \frac{1}{p(x_2|y_2)} + \\
&+ p(x_2, y_3) \log_2 \frac{1}{p(x_2|y_3)} + p(x_2, y_4) \log_2 \frac{1}{p(x_2|y_4)} + \\
&+ p(x_3, y_1) \log_2 \frac{1}{p(x_3|y_1)} + p(x_3, y_2) \log_2 \frac{1}{p(x_3|y_2)} + \\
&+ p(x_3, y_3) \log_2 \frac{1}{p(x_3|y_3)} + p(x_3, y_4) \log_2 \frac{1}{p(x_3|y_4)} + \\
&+ p(x_4, y_1) \log_2 \frac{1}{p(x_4|y_1)} + p(x_4, y_2) \log_2 \frac{1}{p(x_4|y_2)} + \\
&+ p(x_4, y_3) \log_2 \frac{1}{p(x_4|y_3)} + p(x_4, y_4) \log_2 \frac{1}{p(x_4|y_4)} = \\
&= \frac{1}{8} \cdot \log_2 2 + \frac{1}{16} \cdot \log_2 4 + \frac{1}{16} \cdot \log_2 4 + \frac{1}{4} \cdot \log_2 1 + \frac{1}{16} \cdot \log_2 4 + \\
&+ \frac{1}{8} \cdot \log_2 2 + \frac{1}{16} \cdot \log_2 4 + 0 + \frac{1}{32} \cdot \log_2 8 + \frac{1}{32} \cdot \log_2 8 + \\
&+ \frac{1}{16} \cdot \log_2 4 + 0 + \frac{1}{32} \cdot \log_2 8 + \frac{1}{32} \cdot \log_2 8 + \frac{1}{16} \cdot \log_2 4 + 0 = \\
&= \frac{11}{8} \text{ biti.}
\end{aligned}$$

Să calculăm și entropia comună pe baza definiției:

$$\begin{aligned}
H(X, Y) &= \sum_{i=1}^4 \sum_{j=1}^4 p(x_i, y_j) \log_2 \frac{1}{p(x_i, y_j)} = \\
&= \frac{1}{8} \cdot \log_2 8 + \frac{1}{16} \cdot \log_2 16 + \frac{1}{32} \cdot \log_2 32 +
\end{aligned}$$

$$\begin{aligned}
 & + \frac{1}{32} \cdot \log_2 32 + \frac{1}{16} \cdot \log_2 16 + \frac{1}{8} \cdot \log_2 8 + \\
 & + \frac{1}{32} \cdot \log_2 32 + \frac{1}{32} \cdot \log_2 32 + \frac{1}{16} \cdot \log_2 16 + \\
 & + \frac{1}{16} \cdot \log_2 16 + \frac{1}{16} \cdot \log_2 16 + \frac{1}{16} \cdot \log_2 16 + \\
 & + \frac{1}{4} \cdot \log_2 4 = \frac{27}{8} \text{ biti.}
 \end{aligned}$$

Constatăm că $H(Y | X) \neq H(X | Y)$. Observăm însă că

$$H(X) - H(X | Y) = H(Y) - H(Y | X) = \frac{7}{4} - \frac{11}{8} = 2 - \frac{13}{8} = \frac{3}{8}.$$

2.4. ENTROPIE RELATIVĂ ȘI INFORMAȚIE MUTUALĂ

Entropia unei variabile aleatoare X este o măsură a incertitudinii cu privire la X ; ea este o măsură a cantității de informație necesare în medie pentru a descrie variabila aleatoare. Am văzut că entropia nu depinde de domeniul de existență al lui X , ci doar de distribuția de probabilitate a lui X . În practică, s-ar putea să nu dispunem de adevărata distribuție de probabilitate a unei variabile aleatoare, astfel încât suntem obligați să utilizăm în locul acesteia o distribuție pe care o considerăm adecvată, dar care nu este decât o aproximație a celei reale. Entropia relativă este o măsură a distanței dintre două distribuții. Să presupunem că mulțimea valorilor pe care le poate lua variabila aleatoare X este $\{x_1, x_2, \dots, x_L\}$. Conform adevăratei distribuții, X ia valoarea x_k cu probabilitatea $p_k = P(X = x_k)$, dar noi considerăm că ea este $q_k = P(X = x_k)$, $1 \leq k \leq L$. Prin definiție, *entropia relativă* sau *distanța Kullback Leibler* dintre funcțiile masă de probabilitate $p(x)$ și $q(x)$ este

$$D(p \parallel q) = \sum_{k=1}^L p_k \log_2 \frac{p_k}{q_k} = E_p \log_2 \frac{p(X)}{q(X)} \quad (2.13)$$

În definiția de mai sus, utilizăm convenția, bazată pe continuitatea funcțiilor, că $0 \log \frac{0}{q} = 0$ și $p \log \frac{p}{0} = \infty$.

Observăm că entropia relativă astfel definită nu este o veritabilă distanță între distribuții căci nu este simetrică și nu satisface inegalitatea triunghiului.

Să considerăm acum că semnalul generat de o sursă de informație este descris de variabila aleatoare X care ia L valori discrete $x_k, k=1, 2, \dots, L$. Acest semnal este aplicat la intrarea unui canal de comunicație. Din cauza zgomotului din canal, receptorul observă un semnal diferit de cel emis, acest semnal fiind descris de variabila aleatoare Y care ia M valori discrete $y_i, i=1, 2, \dots, M$. Nu este necesar ca $M = L$. La un moment dat, receptorul observă o valoare $Y = y_i$ și trebuie să determine cantitatea de informație pe care apariția acestui eveniment o furnizează cu privire la evenimentul $X = x_k$. Dacă variabilele aleatoare X și Y ar fi statistic independente, apariția lui $Y = y_i$ n-ar furniza nici o informație cu privire la apariția evenimentului $X = x_k$. Pe de altă parte, dacă X și Y ar depinde total una de alta astfel încât apariția lui $Y = y_i$ să determine apariția lui $X = x_k$, conținutul de informație nu este altul decât cel furnizat de evenimentul $X = x_k$. Prin definiție, *informația mutuală* dintre x_k și y_i este mărimea

$$I(x_k; y_i) = \log_2 \frac{P(x_k | y_i)}{P(x_k)} \quad (2.14)$$

Dacă variabilele aleatoare X și Y sunt statistic independente, $P(x_k | y_i) = P(x_k)$ și, deci, $I(x_k; y_i) = 0$. Pe de altă parte, dacă apariția evenimentului $Y = y_i$ determină univoc apariția evenimentului $X = x_k$, $P(x_k | y_i) = 1$ și deci

$$I(x_k; y_i) = \log_2 \frac{1}{P(x_k)} = -\log_2 P(x_k) \quad (2.15)$$

Aceasta este chiar informația cu privire la evenimentul $X = x_k$. Din acest motiv, se numește *auto-informația* evenimentului $X = x_k$ și se notează

$$I(x_k) = \log_2 \frac{1}{P(x_k)} = -\log_2 P(x_k) \quad (2.16)$$

Observăm că un eveniment cu probabilitate ridicată poartă mai puțină informație decât un eveniment cu probabilitate scăzută.

Conform definiției probabilității comune, avem că

$$\frac{P(x_k | y_i)}{P(x_k)} = \frac{P(x_k | y_i)P(y_i)}{P(x_k)P(y_i)} = \frac{P(x_k, y_i)}{P(x_k)P(y_i)} = \frac{P(y_i | x_k)}{P(y_i)} \quad (2.17)$$

Din (2.17), rezultă că

$$I(x_k; y_i) = I(y_i; x_k) \quad (2.18)$$

În cuvinte, informația furnizată de apariția evenimentului $Y = y_i$ cu privire la evenimentul $X = x_k$ este egală cu informația furnizată de apariția evenimentului $X = x_k$ cu privire la evenimentul $Y = y_i$. Acum, dacă cele două variabile aleatoare X și Y au funcția masă de probabilitate comună $p(x, y)$, funcțiile masă de probabilitate marginală sunt $p(x)$ și $p(y)$, respectiv. Prin definiție, *informația mutuală* $I(X; Y)$ este entropia relativă dintre distribuția comună și distribuția produs $p(x)p(y)$:

$$\begin{aligned} I(X; Y) &= \sum_{k=1}^L \sum_{i=1}^M p(x_k, y_i) \log_2 \frac{p(x_k, y_i)}{p(x_k)p(y_i)} \\ &= D(p(x, y) \| p(x)p(y)) = E_{p(x,y)} \log_2 \frac{p(X, Y)}{p(X)p(Y)} \end{aligned} \quad (2.19)$$

Putem rescrie informația mutuală astfel:

$$\begin{aligned} I(X; Y) &= \sum_{k=1}^L \sum_{i=1}^M p(x_k, y_i) \log_2 \frac{p(x_k, y_i)}{p(x_k)p(y_i)} \\ &= \sum_{k=1}^L \sum_{i=1}^M p(x_k, y_i) \log_2 \frac{p(x_k | y_i)}{p(x_k)} \\ &= - \sum_{k=1}^L \sum_{i=1}^M p(x_k, y_i) \log_2 p(x_k) + \sum_{k=1}^L \sum_{i=1}^M p(x_k, y_i) \log_2 p(x_k | y_i) \quad (2.20) \\ &= - \sum_{k=1}^L p(x_k) \log_2 p(x_k) - \left(- \sum_{k=1}^L \sum_{i=1}^M p(x_k, y_i) \log_2 p(x_k | y_i) \right) \\ &= H(X) - H(X | Y) \end{aligned}$$

Cu cuvinte, informația mutuală $I(X; Y)$ este reducerea incertitudinii cu privire la X datorită cunoașterii lui Y . Prin simetrie, avem și că

$$I(X; Y) = H(Y) - H(Y | X) \quad (2.21)$$

Conform regulii lanțului (2.10), avem:

$$I(X; Y) = H(X) + H(Y) - H(X, Y) \quad (2.22)$$

Observăm că

$$I(X; X) = H(X) - H(X | X) = H(X) \quad (2.23)$$

În cuvinte, informația mutuală a unei variabile aleatoare cu ea însăși este entropia variabilei aleatoare. Acesta este motivul pentru care entropia se mai numește și *auto-informație*.

2.5. INEGALITATEA LUI JENSEN

O funcție $f(x)$ se spune că este *convexă* pe un interval (a, b) dacă pentru orice $x_1, x_2 \in (a, b)$ și $0 \leq \lambda \leq 1$,

$$f(\lambda x_1 + (1 - \lambda)x_2) \leq \lambda f(x_1) + (1 - \lambda)f(x_2) \quad (2.24)$$

O funcție $f(x)$ se spune că este *strict convexă* dacă egalitatea are loc numai pentru $\lambda = 0$ sau $\lambda = 1$.

O funcție $f(x)$ este *concavă* dacă $-f(x)$ este convexă.

O funcție este convexă dacă se situează sub orice coardă. O funcție este concavă dacă se situează deasupra oricărei corzi.

TEOREMA 2.2: Dacă funcția $f(x)$ are o derivată a doua care este nenegativă (pozitivă) pe tot domeniul de definiție, ea este convexă (strict convexă).

DEMONSTRAȚIE

Dezvoltăm funcția în serie Taylor în jurul unui punct x_0 :

$$f(x) = f(x_0) + f'(x_0)(x - x_0) + \frac{f''(x^*)}{2}(x - x_0)^2 \quad (2.25)$$

unde x^* este între x_0 și x . Prin ipoteză, $f''(x^*) \geq 0$ astfel încât ultimul termen este nenegativ pentru orice x .

Fie $x_0 = \lambda x_1 + (1 - \lambda)x_2$. Pentru $x = x_1$, obținem:

$$f(x_1) \geq f(x_0) + f'(x_0)[(1 - \lambda)(x_1 - x_2)]. \quad (2.26)$$

Pentru $x = x_2$, avem:

$$f(x_2) \geq f(x_0) + f'(x_0)[\lambda(x_2 - x_1)]. \quad (2.27)$$

Înmulțind (2.26) cu λ și (2.27) cu $(1 - \lambda)$ iar apoi adunând, obținem (2.24).

TEOREMA 2.3 (*Inegalitatea lui Jensen*): Dacă $f(x)$ este o funcție convexă iar X este o variabilă aleatoare, avem

$$Ef(X) \geq f(EX) \quad (2.28)$$

Mai mult decât atât, dacă $f(x)$ este strict convexă, egalitatea din (2.28) implică faptul că $X = EX$ cu probabilitate 1, adică, X este o constantă.

DEMONSTRAȚIE

Vom demonstra teorema prin inducție după numărul de evenimente din spațiul de probabilitate.

Pentru o distribuție de probabilitate cu două evenimente elementare, inegalitatea se scrie

$$p_1 f(x_1) + p_2 f(x_2) \geq f(p_1 x_1 + p_2 x_2). \quad (2.29)$$

Având în vedere că $p_1 + p_2 = 1$, aceasta urmează direct din definiția funcțiilor convexe. Să presupunem că teorema este adevărată pentru distribuții cu $k-1$ evenimente elementare. Pentru o distribuție cu k evenimente elementare, avem

$$p_1 + p_2 + \dots + p_{k-1} + p_k = 1 \quad (2.30)$$

Din (2.30), rezultă imediat că

$$\frac{p_1 + p_2 + \dots + p_{k-1}}{1 - p_k} = 1 \quad (2.31)$$

Notăm $p'_i = p_i / (1 - p_k)$ pentru $i = 1, 2, \dots, k-1$. Avem atunci

$$\begin{aligned} \sum_{i=1}^k p_i f(x_i) &= p_k f(x_k) + \sum_{i=1}^{k-1} p_i f(x_i) \\ &= p_k f(x_k) + (1 - p_k) \sum_{i=1}^{k-1} p'_i f(x_i) \\ &\geq p_k f(x_k) + (1 - p_k) f\left(\sum_{i=1}^{k-1} p'_i x_i\right) \\ &\geq f\left(p_k x_k + (1 - p_k) \sum_{i=1}^{k-1} p'_i x_i\right) \\ &= f\left(\sum_{i=1}^k p_i x_i\right) \end{aligned} \quad (2.32)$$

Rămâne să demonstrăm partea a doua a teoremei. Dacă $f(x)$ este strict convexă, egalitatea are loc în (2.24) numai pentru $\lambda = 0$ sau $\lambda = 1$. Aceasta înseamnă că, în (2.29), $p_1 = 0$ și $p_2 = 1$ sau $p_1 = 1$ și $p_2 = 0$. Dar

aceasta înseamnă că mulțimea evenimentelor elementare se reduce la un singur punct și că X este o constantă cu probabilitate 1.

TEOREMA 2.4: Fie $p(x_k), q(x_k), k = 1, 2, \dots, L$ două funcții masă de probabilitate. Entropia relativă $D(p \parallel q)$ este nenegativă

$$D(p \parallel q) \geq 0 \quad (2.33)$$

cu egalitate dacă și numai dacă

$$p(x_k) = q(x_k) \text{ pentru toți } k. \quad (2.34)$$

DEMONSTRAȚIE

Fie $A = \{x_i : p(x_i) > 0\}$ mulțimea suport a lui $p(x)$. Reamintim că mulțimea suport a unei funcții este submulțimea domeniului de definiție pe care funcția este diferită de zero. Putem scrie

$$\begin{aligned} -D(p \parallel q) &= - \sum_{x_k \in A} p(x_k) \log_2 \frac{p(x_k)}{q(x_k)} \\ &= \sum_{x_k \in A} p(x_k) \log_2 \frac{q(x_k)}{p(x_k)} \end{aligned} \quad (2.35)$$

Fie funcția $f(t) = \log_2 t$. Avem $f'(t) = \frac{\log_2 e}{t}$ și $f''(t) = -\frac{\log_2 e}{t^2}$.

Conform Teoremei 2.1, funcția $\log_2 t$ este strict concavă. Aplicăm în (2.35) inegalitatea lui Jensen:

$$\begin{aligned} -D(p \parallel q) &\leq \log_2 \sum_{x_k \in A} p(x) \frac{q(x)}{p(x)} \\ &= \log_2 \sum_{x_k \in A} q(x) \leq \log_2 \sum_{k=1}^L q(x_k) = \log_2 1 = 0 \end{aligned} \quad (2.36)$$

COROLAR: Pentru oricare două variabile aleatoare X și Y , informația mutuală $I(X; Y)$ este nenegativă

$$I(X; Y) \geq 0 \quad (2.37)$$

cu egalitate dacă și numai dacă X și Y sunt independente.

DEMONSTRAȚIE

Am arătat că $I(X; Y) = D(p(x, y) \parallel p(x)p(y))$, iar conform Teoremei 2.3, aceasta este nenegativă. Egalitatea are loc dacă și numai dacă $p(x, y) = p(x)p(y)$, adică, dacă X și Y sunt independente.

TEOREMA 2.5: Fie o variabilă aleatoare X al cărei domeniu de definiție are L evenimente elementare. Avem $H(X) \leq \log_2 L$, cu egalitate dacă și numai dacă X are o distribuție de probabilitate uniformă (toate evenimentele elementare au aceeași probabilitate egală cu $\frac{1}{L}$).

DEMONSTRAȚIE

Fie $u(x_k) = \frac{1}{L}$, $k = 1, 2, \dots, L$ funcția masă de probabilitate uniformă și fie $p(x_k)$ funcția masă de probabilitate pentru X . Avem atunci

$$D(p \parallel u) = \sum_{k=1}^L p(x_k) \log_2 \frac{p(x_k)}{u(x_k)} = \log_2 L - H(X) \quad (2.38)$$

Având în vedere că entropia relativă este nenegativă, avem

$$0 \leq D(p \parallel u) = \log_2 L - H(X) \quad (2.39)$$

2.6. ENTROPIE DIFERENȚIALĂ

Entropia diferențială este entropia unei variabile aleatoare de tip continuu. Ea este similară în multe privințe cu entropia unei variabile aleatoare de tip discret, dar sunt și unele diferențe importante.

Fie o variabilă aleatoare de tip continuu X cu funcția densitate de probabilitate $p(x)$. Din capitolul 1, știm că

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

Mulțimea unde $p(x) > 0$ se numește *mulțimea suport* a lui X și o notăm cu S . Prin definiție, *entropia diferențială* $h(X)$ a variabilei aleatoare de tip continuu X cu densitate $p(x)$ este integrala

$$h(X) = - \int_S p(x) \log_2 p(x) dx \quad (2.40)$$

Definiția de mai sus este valabilă cu condiția ca integrala respectivă să existe.

Distribuție uniformă

Considerăm o variabilă aleatoare distribuită uniform de la 0 la a , astfel încât densitatea sa de probabilitate este $1/a$ de la 0 la a și 0 în rest. Entropia ei diferențială este

$$h(X) = - \int_0^a \frac{1}{a} \log_2 \frac{1}{a} dx = \log_2 a \quad (2.41)$$

Pentru $a < 1$, $\log_2 a < 0$, astfel încât entropia diferențială este negativă. Deci, spre deosebire de entropia discretă, entropia diferențială poate fi și negativă.

Distribuție normală (Gaussiană)

Fie

$$X \sim \phi(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-x^2/2\sigma^2} \quad (2.42)$$

Calculăm entropia diferențială astfel:

$$\begin{aligned} h(\phi) &= - \int \phi(x) \log_2 \phi(x) dx = - \log_2 e \int \phi(x) \ln \phi(x) dx \\ &= - \log_2 e \int \phi(x) \left[-\frac{x^2}{2\sigma^2} - \ln(\sqrt{2\pi}\sigma) \right] dx \\ &= \frac{\log_2 e}{2\sigma^2} \int x^2 \phi(x) dx + \log_2(\sqrt{2\pi}\sigma) \int \phi(x) dx \end{aligned} \quad (2.43)$$

Din Capitolul 1 știm că, pentru distribuția normală cu medie zero, avem:

$$EX^2 = \int x^2 \phi(x) dx = \sigma^2$$

iar ca pentru orice funcție densitate de probabilitate, $\int \phi(x) dx = 1$. De aceea, (2.43) se scrie:

$$\begin{aligned} h(\phi) &= \frac{1}{2} \log_2 e + \frac{1}{2} \log_2 (2\pi\sigma^2) \\ &= \frac{1}{2} \log_2 (2\pi e \sigma^2) \text{ biti.} \end{aligned} \quad (2.44)$$

2.7. RELAȚIA DINTRE ENTROPIA DIFERENȚIALĂ ȘI ENTROPIA DISCRETĂ

Considerăm o variabilă aleatoare X cu densitate de probabilitate $p(x)$ reprezentată grafic în figura 2.2.




Fig. 2.2. Cuantizarea unei variabile aleatoare de tip continuu.

Împărțim domeniul de definiție al lui X în intervale elementare de lungime Δ . În interiorul fiecărui interval elementar există un punct x_i astfel încât $p(x_i)$ este media lui $p(x)$ în acel interval elementar:

$$p(x_i) = \frac{1}{\Delta} \int_{i\Delta}^{(i+1)\Delta} p(x) dx \quad (2.45)$$

Definim variabila aleatoare cuantizată X_Δ astfel:

$$X_\Delta = x_i, \text{ dacă } i\Delta \leq X < (i+1)\Delta \quad (2.46)$$

Probabilitatea ca $X_\Delta = x_i$ este

$$p_i = \int_{i\Delta}^{(i+1)\Delta} p(x) dx = p(x_i)\Delta \quad (2.47)$$

Entropia lui X_Δ este

$$\begin{aligned} H(X_\Delta) &= - \sum_{i=-\infty}^{\infty} p_i \log_2 p_i \\ &= - \sum_{i=-\infty}^{\infty} p(x_i)\Delta \log_2 (p(x_i)\Delta) \\ &= - \sum_{i=-\infty}^{\infty} \Delta p(x_i) \log_2 p(x_i) - \sum_{i=-\infty}^{\infty} p(x_i)\Delta \log_2 \Delta \end{aligned} \quad (2.48)$$

Având în vedere că $\sum p(x_i)\Delta = \int p(x)dx = 1$, aceasta se poate scrie:

$$H(X_\Delta) = - \sum_{i=-\infty}^{\infty} \Delta p(x_i) \log_2 p(x_i) - \log_2 \Delta \quad (2.49)$$

Dacă funcția $p(x)\log_2 p(x)$ este integrabilă în sens Riemann, condiție necesară pentru a asigura că limita este bine definită, primul termen din (2.49) tinde spre integrala lui $-p(x)\log_2 p(x)$. Am demonstrat astfel următoarea teoremă.

TEOREMA 2.6: Dacă densitatea de probabilitate $p(x)$ a unei variabile aleatoare X este integrabilă în sens Riemann, avem:

$$H(X_\Delta) + \log_2 \Delta \rightarrow h(X) \text{ pentru } \Delta \rightarrow 0 \quad (2.50)$$

Să presupunem că variabila aleatoare X variază într-un domeniu finit, să spunem $x_1 \leq X \leq x_2$. Pentru o cuantă Δ , avem $(x_2 - x_1)/\Delta$ nivele de cuantizare. Dacă exprimăm fiecare eșantion printr-un cuvânt binar de n biți, avem că

$$\frac{x_2 - x_1}{\Delta} = 2^n. \quad (2.51)$$

Întrucât $x_2 - x_1$ este o constantă pe care o putem norma astfel încât să fie egală cu 1, avem din (2.51) că

$$\Delta = 2^{-n}. \quad (2.52)$$

Combinând (2.52) cu (2.50), obținem următorul rezultat: entropia versiunii cuantizate pe n biți a unei variabile aleatoare de tip continuu X este aproximativ egală cu $h(X) + n$.

2.8. ENTROPIE DIFERENȚIALĂ COMUNĂ ȘI CONDIȚIONATĂ

Fie două variabile aleatoare de tip continuu X și Y având funcția densitate de probabilitate comună $p(x, y)$. Definim entropia diferențială comună a lui X și Y astfel:

$$h(X, Y) = - \int p(x, y) \log_2 p(x, y) dx dy \quad (2.53)$$

De asemenea, definim entropia diferențială condiționată $h(X | Y)$ astfel:

$$h(X | Y) = - \int p(x, y) \log_2 p(x | y) dx dy \quad (2.54)$$

Întrucât în general $p(x | y) = p(x, y) / p(y)$, putem scrie și că

$$h(X | Y) = h(X, Y) - h(Y) \quad (2.55)$$

2.9. ENTROPIE RELATIVĂ ȘI INFORMAȚIE MUTUALĂ PENTRU VARIABILE ALEATOARE DE TIP CONTINUU

Prin definiție, *entropia relativă*, sau *distanța Kullback Leibler*, $D(f || g)$ a două densități de probabilitate $f(x)$ și $g(x)$ este

$$D(f || g) = \int f(x) \log_2 \frac{f(x)}{g(x)} dx \quad (2.56)$$

Aceasta este finită numai dacă mulțimea suport a lui $f(x)$ este conținută în mulțimea suport a lui $g(x)$.

Prin definiție, informația mutuală $I(X; Y)$ dintre două variabile aleatoare de tip continuu cu densitate de probabilitate comună $p(x, y)$ este:

$$I(X; Y) = \int p(x, y) \log_2 \frac{p(x, y)}{p(x)p(y)} dx dy \quad (2.57)$$

Din definiția (2.57), rezultă imediat că

$$I(X; Y) = D(p(x, y) || p(x)p(y)) \quad (2.58)$$

și că

$$I(X; Y) = h(X) - h(X | Y) = h(Y) - h(Y | X) \quad (2.59)$$

Proprietățile lui $D(f || g)$ și ale lui $I(X; Y)$ sunt aceleași ca și în cazul variabilelor aleatoare de tip discret. În particular, informația mutuală

dintre două variabile aleatoare de tip continuu X și Y este limita informației mutuale dintre versiunile lor cuantizate, căci

$$\begin{aligned} I(X_\Delta; Y_\Delta) &= H(X_\Delta) - H(X_\Delta | Y_\Delta) \\ &\approx h(X) - \log_2 \Delta - (h(X | Y) - \log_2 \Delta) \\ &= I(X; Y) \end{aligned} \quad (2.60)$$

Proprietățile entropiei diferențiale, ale entropiei relative și ale informației mutuale sunt similare celor din cazul variabilelor aleatoare de tip discret.

2.10. LANȚURI MARKOV

În Capitolul 1, am văzut că un proces stohastic este un șir indexat de variabile aleatoare. În general, aceste variabile aleatoare nu sunt independente. Un exemplu simplu de proces stohastic cu dependență este unul în care fiecare variabilă aleatoare depinde de cea precedentă și nu este condiționată de nici una din celelalte variabile aleatoare precedente.

Prin definiție, un *lanț Markov* sau un *proces Markov* este un proces stohastic discret X_1, X_2, \dots dacă, pentru $n = 1, 2, \dots$,

$$\begin{aligned} \Pr(X_{n+1} = x_{n+1} | X_n = x_n, X_{n-1} = x_{n-1}, \dots, X_1 = x_1) \\ = \Pr(X_{n+1} = x_{n+1} | X_n = x_n) \end{aligned} \quad (2.61)$$

pentru toate valorile $x_1, x_2, \dots, x_n, x_{n+1}$ pe care le poate lua procesul.

În acest caz, funcția masă de probabilitate comună a variabilelor aleatoare se poate scrie

$$p(x_1, x_2, \dots, x_n) = p(x_1)p(x_2 | x_1)p(x_3 | x_2) \cdots p(x_n | x_{n-1}) \quad (2.62)$$

Prin definiție, se spune că lanțul Markov este *invariant în timp* dacă probabilitatea condiționată $p(x_{n+1} | x_n)$ nu depinde de n , adică, pentru $n = 1, 2, \dots$

$$\Pr\{X_{n+1} = b | X_n = a\} = \Pr\{X_2 = b | X_1 = a\} \text{ pentru orice } a, b \quad (2.63)$$

Dacă $\{X_i\}$ este un lanț Markov, X_n se numește *starea* la timpul n .

Un lanț Markov invariant în timp se caracterizează prin starea sa inițială și o *matrice a tranziției de probabilitate*

$$P = [P_{ij}], i, j \in \{1, 2, \dots, m\} \text{ unde } P_{ij} = \Pr\{X_{n+1} = j | X_n = i\}.$$

Dacă este posibil să se meargă cu probabilitate pozitivă din orice stare a lanțului Markov în oricare altă stare într-un număr finit de pași, lanțul Markov se spune că este *irreductibil*.

Dacă funcția masă de probabilitate a unei variabile aleatoare la timpul n este $p(x_n)$, funcția masă de probabilitate a unei variabile aleatoare la timpul $n+1$ este

$$p(x_{n+1}) = \sum_{x_n} p(x_n) P_{x_n x_{n+1}} \quad (2.64)$$

O distribuție de probabilitate a stărilor astfel încât distribuția la timpul $n+1$ este aceeași cu distribuția la timpul n se numește *distribuție staționară*.

Dacă un lanț Markov cu un număr finit de stări posibile este irreductibil și aperiodic, distribuția staționară este unică, astfel încât din orice distribuție inițială, distribuția lui X_n tinde către distribuția staționară când $n \rightarrow \infty$.

EXEMPLUL 2.2: Considerăm un lanț Markov cu două stări având matricea tranziției de probabilitate

$$P = \begin{bmatrix} 1-\alpha & \alpha \\ \beta & 1-\beta \end{bmatrix} \quad (2.65)$$

Ilustrăm aceasta printr-un graf orientat în care cele două vârfuri reprezintă starea 1 și starea 2, arcele reprezintă tranzițiile iar etichetele arcelor sunt probabilitățile de tranziție corespunzătoare, așa cum se arată în figura 2.3.

Reprezentăm distribuția staționară prin vectorul $\mu = [\mu_1, \mu_2]$ ale cărui componente sunt probabilitățile staționare în starea 1 și în starea 2, respectiv. Putem găsi probabilitatea staționară rezolvând ecuația matriceală

$$\mu P = \mu \quad (2.66)$$

ceea ce ne dă că

$$\mu_1 \alpha = \mu_2 \beta \quad (2.67)$$

Având în vedere că $\mu_1 + \mu_2 = 1$, distribuția staționară este

$$\mu_1 = \frac{\beta}{\alpha + \beta}, \quad \mu_2 = \frac{\alpha}{\alpha + \beta} \quad (2.68)$$

Dacă lanțul Markov are o distribuție inițială egală cu distribuția staționară, procesul care rezultă va fi staționar. Entropia stării X_n la timpul n este

$$H(X_n) = H\left(\frac{\beta}{\alpha + \beta}, \frac{\alpha}{\alpha + \beta}\right) \quad (2.69)$$




Fig. 2.3. Lanț Markov cu două stări.

Dacă însă în starea inițială distribuția de probabilitate diferă de cea staționară, la aceasta din urmă se ajunge după un proces tranzitoriu.

Prin definiție, *rata de entropie* a unui proces stochastic $\{X_i\}$ este

$$H(X) = \lim_{n \rightarrow \infty} \frac{1}{n} H(X_1, X_2, \dots, X_n) \quad (2.70)$$

dacă limita există.

Pentru un lanț Markov staționar, rata de entropie este dată de

$$\begin{aligned} H(X) &= \lim_{n \rightarrow \infty} H(X_n | X_{n-1}, \dots, X_1) \\ &= \lim_{n \rightarrow \infty} H(X_n | X_{n-1}) = H(X_2 | X_1) \end{aligned} \quad (2.71)$$

Dacă lanțul Markov este ireductibil și aperiodic, el are o distribuție staționară unică a stărilor, iar orice distribuție inițială tinde către distribuția staționară când $n \rightarrow \infty$. În acest caz, rata de entropie este dată de (2.71).

În capitolul următor, vom utiliza noțiunea de entropie a unei variabile aleatoare introdusă mai sus pentru a optimiza codarea surselor de informație.