

Lanturi Markov. Aplicatii in procese cognitive implicate in studiul Performantei Umane*

Alex. Agapie - prof. dr. ASE Bucuresti

*Seminar STARWALKER - 28 Aprilie 2015

Introducere (scurta) in Teoria Probabilitatilor

EXPERIMENT ALEATOR = un experiment al carui rezultat nu poate fi previsus dinainte. Rezultatele posibile se numesc EVENIMENTE

PROBABILITATEA măsoară evenimentele, asociind numere din intervalul $[0, 1]$

$$P(A) = \frac{\text{Nr. cazuri favorabile lui } A}{\text{Nr. cazuri posibile}}$$

A, B independente $\iff P(A \cap B) = P(A) \cdot P(B)$

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

A, B nu comută - grad diferit de incertitudine:
B este CERTA, în timp ce A este INCERT, se poate întâmpla sau nu

VARIABILA ALEATOARE (v.a.) caracterizeaza complet un experiment aleator:

- X - variabila aleatoare
- x - valoare posibila
- (X=x) - eveniment
- P(X=x) - probabilitate

Toata informatie asupra unei v.a. este continuta in distributia ei, unde $p_i = P(X = x_i)$:

$$X : \begin{pmatrix} \cdots & x_i & \cdots \\ \cdots & p_i & \cdots \end{pmatrix}, \quad \sum_i p_i = 1$$

MEDIA unei v.a. X este data de:

$$M(X) = \sum_i x_i \cdot p_i$$

PROCESE STOCHASTICE

O familie $\{X_t\}_{t \geq 0}$ de v.a. caracterizata printr-o relatie speciala intre variabile

- Pentru fiecare indice $t \in \{0, 1, 2, \dots\}$, X_t este o variabila aleatoare, conectata printr-o proprietate comună de v.a. care o preced sau o succed
- Multimea valorilor pe care le pot lua v.a. X_t se numeste SPATIUL STARILOR
- Indicele t este deobicei interpretat ca *timp*, deci X_t reprezinta starea procesului la timpul t

Exemplul 1 X_t reprezinta numarul persoanelor aflate intr-o banca la timpul t (**teoria asteptarii**), sau pozitia unui algoritm de optimizare la iteratia t (**computer science**)

LANTURI MARKOV

Cele mai cunoscute procese stochastice:

- interpretare intuitiva: Viitorul depinde doar de prezent, **trecutul nu conteaza!**
- o teorie eleganta
- arie larga de aplicatii

$\{X_t\}_{t \geq 0}$ este *lant Markov* daca

$$\begin{aligned} & P(X_{t+1} = i_{t+1} | X_t = i_t, X_{t-1} = i_{t-1}, \dots, X_0 = i_0) \\ & = P(X_{t+1} = i_{t+1} | X_t = i_t) \end{aligned}$$

LANTURI MARKOV - matrice

- proces cu spatiul starilor $S = \{1, 2, \dots, n\}$
- trecerea dintr-o stare in alta se face pe baza unor probabilitati
- probabilitatea de trecere dintr-o stare in alta depinde doar de starea curenta
- probabilitatea de trecere din starea i in starea j e notata p_{ij}
- reunim toate probabilitatile de trecere intr-o matrice patrata ne-negativa =**matrice de trecere** $P = (p_{ij})_{i,j=1,n}$
- suma elementelor pe fiecare linie e 1

- probabilitatile de trecere in t pasi $p_{t;ij}$ sunt elementele matricii P^t
- O stare i se numeste *absorbanta* (*atractor*) daca $p_{ii} = 1$. O stare absorbanta nu poate fi parasita
- P se numeste *primitiva* daca exista o putere a ei (strict) pozitiva
- P se numeste *ergodica* daca puterile ei tind la o matrice cu toate liniile identice
- Fie p^0 un vector (coloana) de probabilitate. Daca p^0 este distributia initiala a lantului Markov cu matrice de trecere P , atunci distributia lantului dupa t pasi este $p^{(t)'} = p^{(0)'} P^t$
- Daca $\pi' = \pi' P$, atunci π se numeste *distributie stationara*

EXEMPLU: Vremea probabila

- Starea 1: ploaie
- Starea 2: nori
- Starea 3: soare

	ploaie	nori	soare
ploaie	0.4	0.3	0.3
nori	0.2	0.6	0.2
soare	0.1	0.1	0.8

Daca in ziua 1 este soare, $p'^{(0)} = (0, 0, 1)$, care e probabilitatea ca saptamana urmatoare sa avem succesiunea soare-soare-ploaie-ploaie-soare-nori-soare?

$$P(3, 3, 1, 1, 3, 2, 3 | 1) =$$

$$1 \cdot 0.8 \cdot 0.8 \cdot 0.1 \cdot 0.4 \cdot 0.3 \cdot 0.1 \cdot 0.2 = 0.0001536$$

Daca modelul se afla la timpul 0 in starea i , probabilitatea de a ramane exact d zile in starea i este

$$P(\underbrace{i, i, \dots, i}_d, \underbrace{k \neq i}_{d+1}) = p_{ii}^{d-1} (1 - p_{ii}) = p_i(d)$$

- $p_i(\cdot)$ este o distributie de probabilitate peste multimea infinita $\{1, 2, 3, \dots\}$
- DURATA D_i de sedere in starea i este o variabila aleatoare cu valori in $\{1, 2, 3, \dots\}$, a carei medie se calculeaza:

$$\begin{aligned} M(D_i) &= \sum_{d=1}^{\infty} d \cdot p_i(d) = \\ &\sum_{d=1}^{\infty} d \cdot p_{ii}^{d-1} (1 - p_{ii}) = \frac{1}{1 - p_{ii}} \end{aligned}$$

Pasii unei Analize Markov

- Comportarea sistemului pe termen scurt, in timp finit
Determinarea matricii de trecere
- Comportarea pe termen lung, ergodica.
Exista distributia stationara π ?
- Daca da, se poate gasi o formula?
- Estimarea timpului de absorbtie

Teorema 2 Fie P o matrice de trecere primătiva. Atunci P^t converge cand $t \rightarrow \infty$ la o matrice cu toate liniile identice $P^\infty = \mathbf{1}\pi'$, iar viteza de convergentă este exponentială.
Mai mult, distributia limită $\pi = p^0 P^\infty$ are proprietatile:

- este unică, independent de distributia initială p^0
- este (strict) pozitiva pe fiecare componentă
- este unică distribuție stationară a lantului Markov considerat

Observatia 3 O exceptie importanta dela cazul matricei primitive apare cand lantul Markov are una sau mai multe stari absorbante. In aceasta situatie lantul va ajunge, cu probabilitate 1 dupa un timp finit, intr-una din starile absorbante (*atractori*), unde va si ramane.

- Se poate prezice starea finala pornind dela cea initiala?
- Se poate estima timpul pana la absorbtie?

Lant Markov pentru un proces de INVATARE

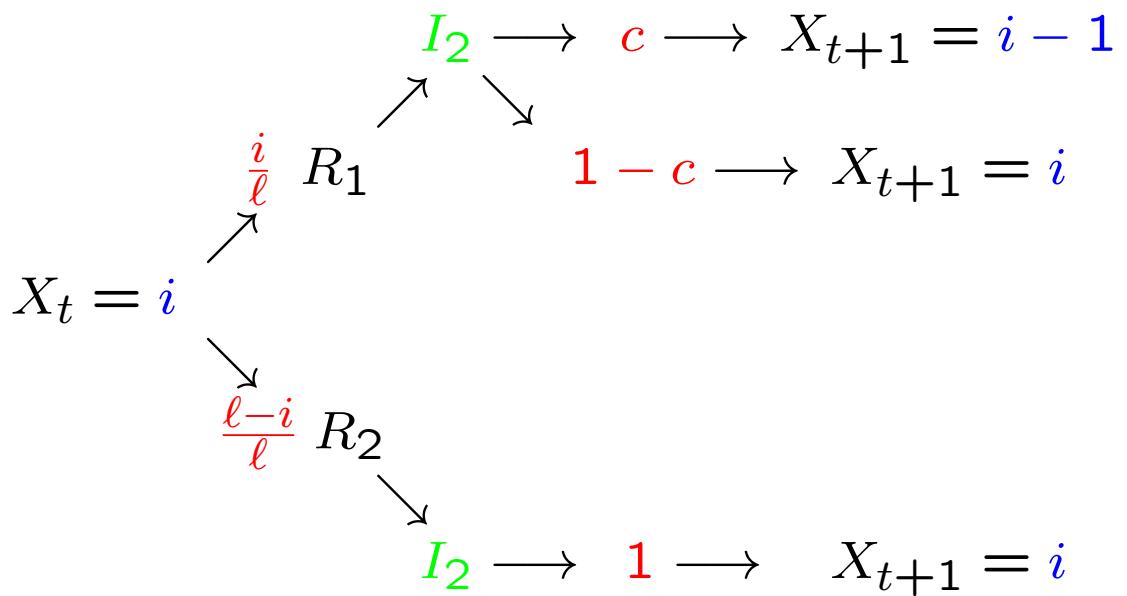
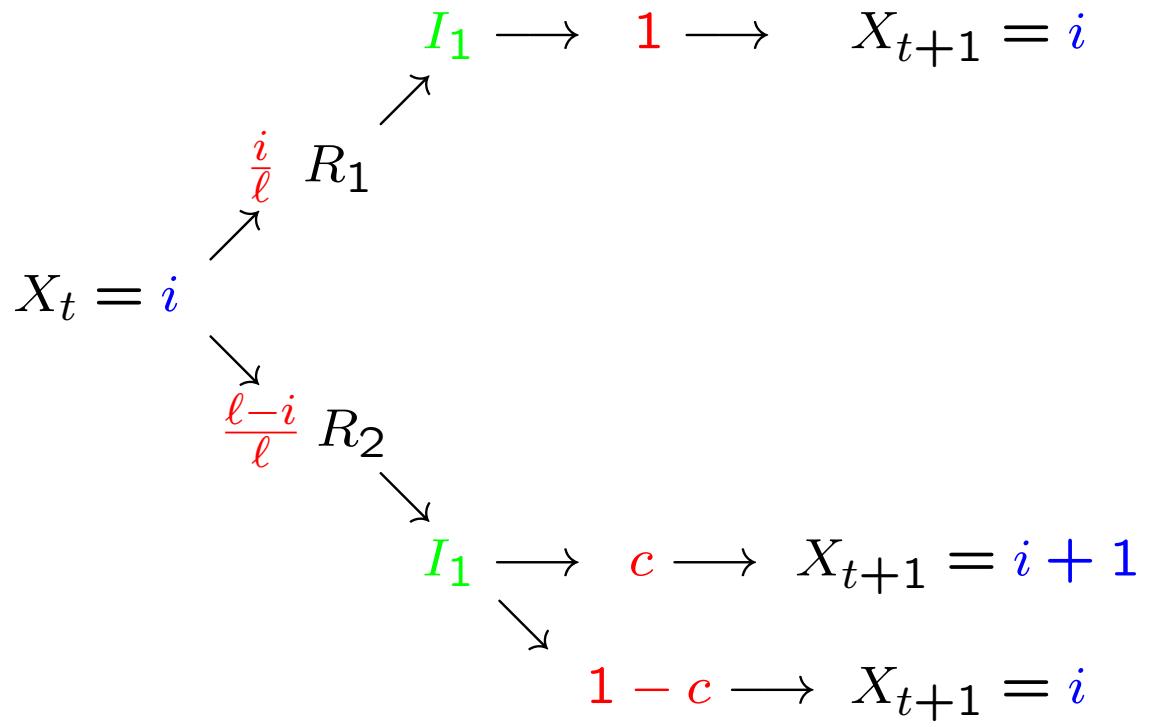
- modelul selectarii stimulilor -

- **stimul**..... conditiile in care este observata comportarea
- **raspuns**..... comportarile observabile
- **intarire**..... recompense, penalizari

situatia conditionarii la inceputul probei →
selectarea unui stimul → raspuns → intarire
→ situatia conditionarii la inceputul probei urmatoare

- doua raspunsuri posibile R_1 si R_2
- doua evenimente de intarire I_1 si I_2
- **stare** a subiectului = numarul stimulilor care conditioneaza raspunsul R_1 la un moment dat, $S = \{0, 1, \dots, \ell\}$
- un singur stimul este selectat la fiecare proba, uniform
- un stimul selectat intr-o proba isi schimba conditionarea in proba urmatoare cu o probabilitate **c**, conditionand raspunsul intarit
- NU isi schimba conditionarea cu probabilitatea **1-c**

- daca stimulul a conditionat chiar raspunsul intarit, atunci NU isi schimba conditionarea la proba urmatoare (probabilitate **1**)
- probabilitatea aparitiei intr-o proba a unui eveniment de intarire depinde doar de raspunsul dat de subiect la proba considerata, fara a depinde de rangul probei si nici de starea subiectului:
- $P(I_1(t) | R_2(t), X_t = i) = q_{21} = a$
- $P(I_2(t) | R_1(t), X_t = i) = q_{12} = b$



Matricea de trecere a lantului Markov

$$\begin{array}{c|cccccc} & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ i-1 & \dots & \dots & \dots & \dots & \dots & \dots \\ i & \dots & cb\frac{i}{\ell} & 1 - (st+dr) & ca\left(1 - \frac{i}{\ell}\right) & \dots & \dots \\ i+1 & \dots & \dots & \dots & \dots & \dots & \dots \\ & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \end{array}$$

Distributia stationara π e data de termenii dezvoltarii binomului

$$\left(\frac{b}{a+b} + \frac{a}{a+b}\right)^\ell = \left(\frac{q_{12}}{q_{21} + q_{12}} + \frac{q_{21}}{q_{21} + q_{12}}\right)^\ell$$

Viteza de convergenta a probabilitatilor $p_{t;ij}$ catre aceasta distributie este de ordinul

$$\left[1 - \frac{c}{\ell}(q_{21} + q_{12})\right]^t$$

Probabilitatea ca subiectul sa dea raspunsul R_1

$$\frac{q_{21}}{q_{21} + q_{12}}$$

Cazul ASIMETRIC: R_1 BUN, R_2 GRESIT

$q_{21} = q > 0$ și $q_{12} = 0$... LM absorbant, ℓ atractor - toti stimulii vor conditiona R_1

$$\begin{array}{c|ccccccccc} 0 & 1 - cq & cq & 0 & \dots & 0 \\ 1 & 0 & 1 - (1 - \frac{1}{\ell}) cq & (1 - \frac{1}{\ell}) cq & \dots & 0 \\ 2 & 0 & 0 & 1 - (1 - \frac{2}{\ell}) cq & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ \ell - 1 & 0 & 0 & 0 & \dots & 1 - \frac{cq}{\ell} \end{array}$$

- în cele din urma subiectul va răspunde R_1
- plecând din i , timpul mediu de absorbtie:

$$M_i(T) = \frac{\ell}{cq} \sum_{j=i}^{\ell-1} \frac{1}{\ell-j}$$

- numarul mediu de erori R_2 este $\frac{\ell-i}{cq}$
- Probabilitatile $c, q = 0.5$; din 10 stimuli doar 2 conditioneaza initial raspunsul BUN
- invatarea va dura 108 repetitii, la 32 dintre acestea subiectul va răspunde GRESIT

Lanturi Markov ASCUNSE (LMA)

- pana acum am considerat modele in care o stare corespunde unui eveniment observabil, acum vom considera observatia ca o functie probabilistica de stare
- modelul este al unui proces stochastic pe doua nivele, dintre care unul nu este direct observabil, ci poate fi observat doar printr-un alt set de procese stochastice care produc sirul de observatii

Experiment: aruncarea monezilor

Ne aflam intr-o camera cu inca o persoana, aflata in spatele unei cortine. Persoana din spatele cortinei arunca o moneda/mai multe si ne comunica rezultatul dupa fiecare aruncare. Are loc un sir de experimente ascunse de aruncare a monezii, iar rezultatul observabil este un sir de evenimente $S(\text{tema})$ sau $B(\text{an})$, de exemplu:

$$\mathbf{O} = O_1 O_2 O_3 \dots O_T = S S T \dots S$$

Model I: 1 moneda

- lant Markov simplu
- 2 stari: S , T

Model II: 2 monezi

- lant Markov ascuns
- 2 stari: cele 2 monezi
- matrice de trecere 2×2
- 2 parametri (grade de libertate)

Model III: 3 monezi

- lant Markov ascuns
- 3 stari: cele 3 monezi
- matrice de trecere 3×3
- 6 parametri (grade de libertate)

Experiment: urnă cu bile

$$O = (\text{negru}, \text{rosu}, \text{rosu}, \text{negru}, \text{verde}, \text{verde}, \text{verde})$$

<u>URNA 1</u>	<u>URNA 2</u>	<u>URNA 3</u>
$P(\text{alb}) = b_1(1)$	$P(\text{alb}) = b_2(1)$	$P(\text{alb}) = b_3(1)$
$P(\text{rosu}) = b_1(2)$	$P(\text{rosu}) = b_2(2)$	$P(\text{rosu}) = b_3(2)$
$P(\text{verde}) = b_1(3)$	$P(\text{verde}) = b_2(3)$	$P(\text{verde}) = b_3(3)$
\vdots	\vdots	\vdots
$P(\text{negru}) = b_1(M)$	$P(\text{negru}) = b_2(M)$	$P(\text{negru}) = b_3(M)$

- lant Markov ascuns
- 3 stari: cele 3 urne
- matrice de trecere 3×3
- $3(M - 1) + 6$ parametri (grade de libertate)

Elementele unui LMA

- N , numarul de stari ale sistemului. Desi sunt ascunse, uneori li se poate asocia o semnificatie fizica. $S = \{S_1, \dots, S_N\}$, iar starea la momentul t o notam cu s_t
- M , numarul simbolurilor observabile - iesirile sistemului, alfabetul. $V = \{v_1, \dots, v_M\}$
- matricea probabilitatilor de trecere $P = (p_{ij})$ intre cele N stari. Daca se poate trece intre oricare doua stari, exista $t > 0$ a.i. $p_{t;ij} > 0$, atunci modelul este ergodic
- distributiile fiecarei stari j , $b_j(\cdot)$, aggregate in matricea $B = \{b_j\}$
- distributia initiala p^0

Daca se cunosc N, M, P, B si p^0 , LMA poate fi folosit ca generator al unui sir de observatii

$$\mathbf{O} = O_1 O_2 O_3 \dots O_T$$

ALGORITM LMA

1. Alege o stare initiala $s_1 = S_i$ dupa distributia p^0
2. Seteaza $t = 1$
3. Alege $O_t = v_k$ dupa distributia din starea S_i , anume $b_i(\cdot)$
4. Treci intr-o noua stare $s_{t+1} = S_j$, dupa distributia de trecere din starea S_i , p_i .
5. Seteaza $t = t + 1$ si intoarce-te la pasul (3) daca $t < T$; altfel STOP

Trei probleme pentru LMA

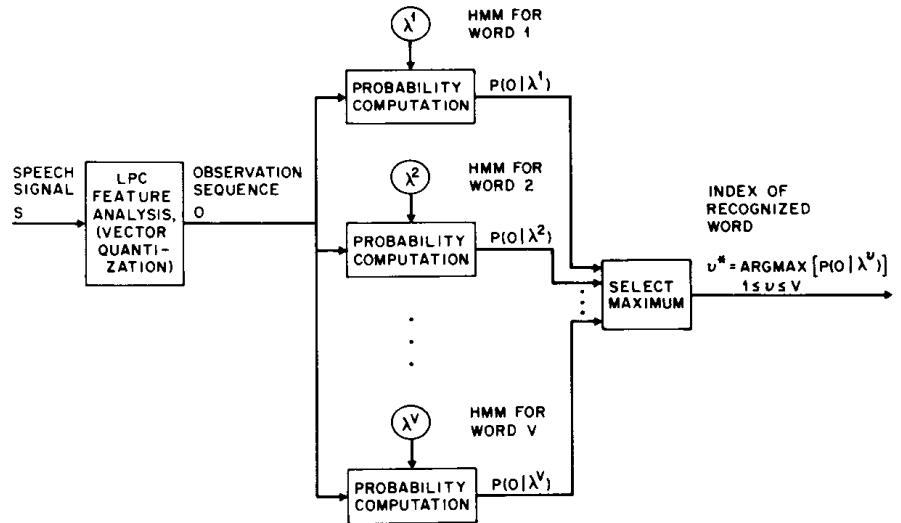
- I Dandu-se un sir de observatii \mathbf{O} si un model $\lambda = (P, B, p^0)$, cum calculam EFICIENT $P(\mathbf{O}|\lambda)$, probabilitatea ca sirul observatiilor sa fie generat de model?
- II Dandu-se un sir de observatii \mathbf{O} si un model λ , cum alegem o succesiune de stari (ascunse) $\mathbf{Q} = s_1 s_2 \dots s_T$ care sa fie OPTIMA intr-un anume sens (adica sa explice cat mai bine observatiile)?
- III Cum ajustam parametrii modelului λ a.i. sa maximizam $P(\mathbf{O}|\lambda)$?

Recunoasterea cuvintelor vorbite

Pentru fiecare cuvant dintr-un vocabular de W cuvinte vrem sa modelam un LMA cu N stari. Reprezentam semnalul asociat fiecarui cuvant ca un sir de vectori spectrali codati, luate dintr-o multime de M vectori spectrali unici. Deci fiecare observatie este un sir finit de indici ai vectorilor spectrali cei mai apropiati de semnalul real. Pentru fiecare cuvant avem o secventa de invatare formata din siruri de indici spectrali, corespunzatoare mai multor repetitii ale cuvantului, de catre unul sau mai multi vorbitori: (e_1, e_3, e_1) , (e_2, e_3, e_1) , (e_1, e_2, e_1)

- prima sarcina - construirea unui model LMA.
Se foloseste solutia Problemei (III) pentru estimarea optima a parametrilor modelului pentru fiecare cuvant

- pentru a dobandi o intrelegere a semnificatiei fizice a starilor modelului folosim Problema (II) pentru a segmenta fiecare secventa de invatare a unui cuvant in stari, si apoi a studia proprietatile vectorilor spectrali care conduc la observatiile ce apar in fiecare stare
- in final, odata ce setul de W LMA-uri a fost conceput si optimizat, recunoasterea unui cuvant NOU este realizata folosind solutia la Problema (I) pentru a asocia cate un scor fiecarui cuvant modelat, si selectarea cuvantului cu scorul cel mai mare (verosimilitate maxima)



Block diagram of an isolated word HMM recognizer.

- pentru fiecare cuvant v construim un LMA λ^v , estimand parametrii modelului $\lambda^v = (P, B, p^0)$ pe baza setului de antrenare pentru cuvantul v
- pentru un cuvant 'nou' care trebuie recunoscut, masuram sevenita observabila $O = O_1 O_2 O_3 \dots O_T$, calculam verosimilitatile pentru fiecare din cele V modele posibile, apoi alegem **MAXIMUL**

Recunoasterea cuvintelor: ZERO, ONE, . . . NINE

- un model *stanga* → *dreapta* e mai indicat decat unul ergodic, succesiunea in timp a starilor fiind naturala
- starile au o semnificatie fizica clara: sunetele distincte ('phoneme', silabe) din componenta cuvantului ce trebuie modelat
- **NUMARUL** starilor, doua variante:
 1. egal cu numarul 'phoneme'-lor: 2 – 10
 2. egal cu numarul mediu de observatii ce apar in versiunea vorbita a cuvantului, o stare \approx un subinterval \approx 15 ms

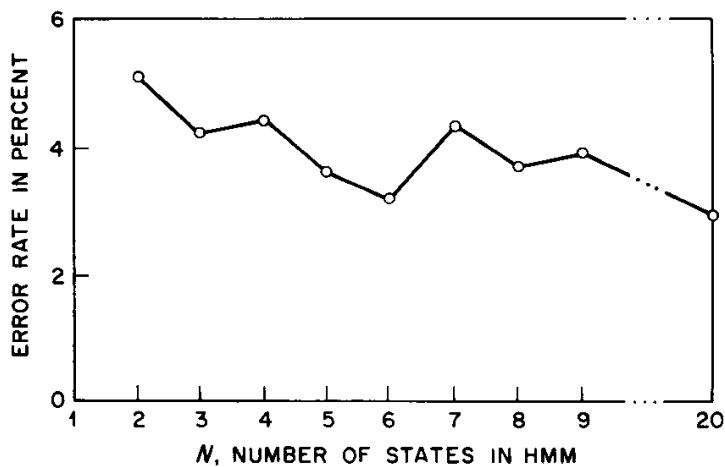


Fig. 15. Average word error rate (for a digits vocabulary) versus the number of states N in the HMM.

- Se observă ca eroare este insensibilă la numărul de stări N
- eroarea minima se obține pentru sase stări

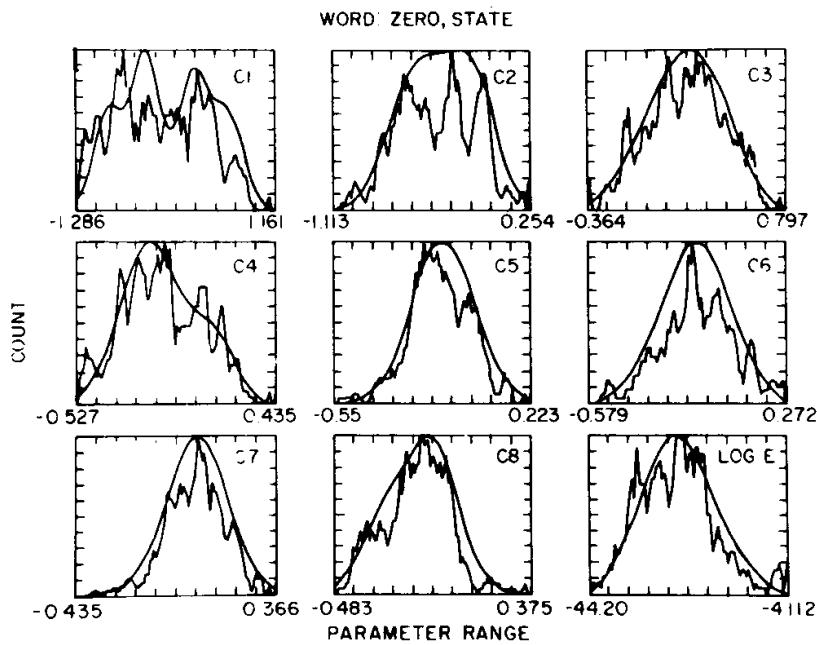


Fig. 16. Comparison of estimated density (jagged contour) and model density (smooth contour) for each of the nine components of the observation vector (eight cepstral components, one log energy component) for state 1 of the digit zero.

- Pentru starea S_1 a cuvantului *ZERO* se foloseste o mixtura de (maxim) M variabile aleatoare normale pentru a estima fiecare din cele 9 componente ale vectorului de observatie generat de aceasta stare
- in figura $M = 5$. Componentele 1, 2, 4, 8 sunt evident multi-modale, celelalte s-ar putea insa aproxima si printr-o singura normala

Cele 5 stari ale cuvantului SIX

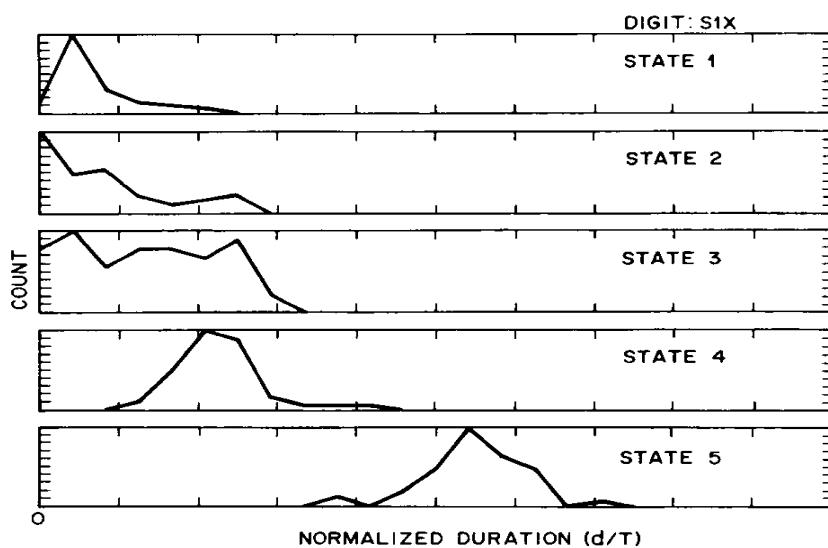
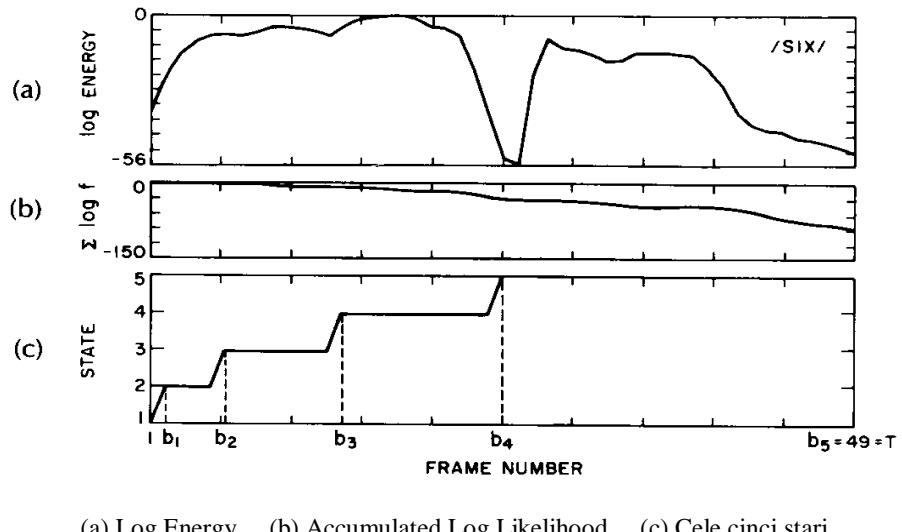


Fig. 20. Histograms of the normalized duration density for the five states of the digit "six."

Rezultate LMA pentru recunoasterea cuvintelor

- ANTRENARE: 100 subiecti - 50 F, 50 B - fiecare a pronuntat cele 10 cuvinte
- TESTARE: UN set nou cu aceeasi subiecti + DOUA seturi cu subiecti noi
- mai multe variante de LMA, alte metode

Eroare - cuvinte clasificate gresit (din 1000)

<i>antrenare</i>	<i>test1</i>	<i>test2</i>	<i>test3</i>
0	2	13	18

LMA pentru recunoasterea scrisului de mana

<i>scris</i>	<i>vorbit</i>
distorsiunea elastică a caracterelor scrise	distorsiunea temporală a cuvintelor vorbite
segmentarea în litere și cuvinte	segmentarea în unități fonetice și cuvinte
dependenta de literele vecine scrise	coarticulatia literelor vorbite
dependenta de literele vecine scrise	coarticulatia literelor vorbite

LMA pentru recunoasterea scrisului de mana

- segmentarea textului in cuvinte si caractere
- modelul devine 2-D

$$O = \{o(x, y) \mid (x, y) \in L_{X,Y}, o \in V\}$$

- V este acum multimea tonurilor de gri . . . 50 shades of . . .
- starile LMA sunt pixelii imaginii, situati pe un grid (latice) dreptunghiular
- sunt $N = X_R \cdot Y_R$ stari, fiecare avand o distributie de probabilitate $b_{i,j}(\cdot)$ peste spatiul observatiilor \mathcal{V}

- o singura stare este activa in generarea pixelului $o(x, y)$, notata $s(x, y)$
- conditionarea Markov se reduce la

$$P \{s(x, y) \mid s(x - 1, y), s(x, y - 1)\}$$

- definim un LMA *stanga* \rightarrow *dreapta*, \rightarrow *sus* prin conditia

$$P \{(m, n) \mid (i, j), (l, k)\} \neq 0$$

doar pentru starile cu $i \leq m$ si $l \leq n$

- matricea de trecere este cubica: $N \times N \times N$

EXPERIMENT

- 12 subiecti (6 pentru antrenare, 6 pentru testare) au fost pusi sa completeze fiecare 10 exemplare ale cifrelor $\{0, \dots, 9\}$
- fiecare cifra a fost scrisa in interiorul unui patrat de aceeasi marime
- fiecare imagine a fost reprezentata ca o imagine binara 16×16
- fiecare cifra a fost modelata de un LMA, cu matricea starilor S trecand prin toate starile modelului - fara a sari nicio stare
- fiecare stare e reprezentata de probabilitatea binara ca pixelul respectiv sa fie 1 (negru) sau 0 (alb)

Nr. stari	Erori antrenare %	Erori testare %
6 × 6	13	13.6
8 × 6	6	8.3
9 × 9	5.8	8
10 × 10	4.3	5.3
11 × 11	3.5	6.3
12 × 12	3	7
16 × 16	6	10.6

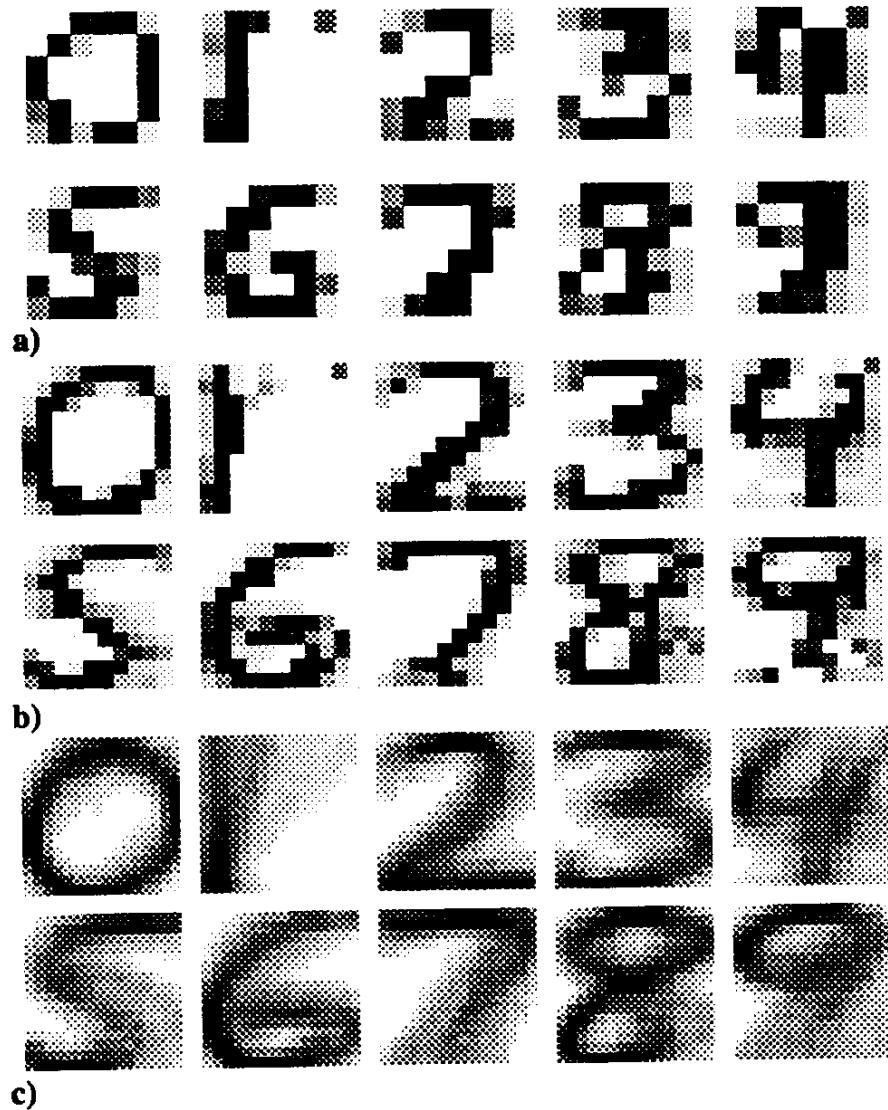


Figure 1. Digit models with a different number of states (a-6, b-10, c-16). The grey level encodes the value of $P(g=1)$ for each state.

LMA pentru recunoasterea STRESULUI

- Optical Computer Recognition (OCR) of Facial Expressions Associated with Stress Induced by Performance Demands - Dinges et al., *Aviation, Space and Environmental Medicine*, 2005
- Grant NASA cooperative agreement NCC 5-98 with the National Space Biomedical Research Institute
- nevoia de a identifica stresul comportamental ce afecteaza performanta astronautilor
- in special in timpul misiunilor lungi, cand cerintele de performanta cresc brusc sau se adauga la o stare de stres deja existenta

- au fost situatii cand membrii echipajului au intrerupt legatura cu baza, sau cand, presati sa continue operatiunea, au facut erori ce puteau pune in pericol intreaga misiune
- masurarea emotiilor umane prin expresiile fetzei
- OCR pentru expresii faciale . . . istorie lunga: modele 2-D, 3-D, deterministe, probabiliste
- EXPERIMENT: 60 adulti (31 F, 29 M), varsta medie 30 ani, ciclu normal somn-veghe, fara abuz de alcool sau medicamente, ne-fumatori, fara depresie si ochelari
- in laborator, subiectilor li s-au atasat electrozi EKG, au fost supusi sarcinilor de performanta, au completat chestionare privind

personalitatea, starea de moment, percepția stresului

- fetzele le-au fost înregistrate video pe tot parcursul testării performanței cognitive, iar reacțiile de stress au fost urmărite atât în timpul sesiunilor solicitante cât și a celor ne-solicitante, prin auto-raportarea scorurilor de stare, analiza salivei și a batăilor inimii
- **sesiuni solicitante:** sarcini mai dificile, feedback social negativ, presiune de timp, feedback negativ pe ecranul calculatorului, uniform pentru toți subiecții, independent de răspunsurile lor
- înainte și după fiecare sesiune, subiecții își auto-evaluau stările de obosalea mentală și fizică, de alertă, epuizare, stres

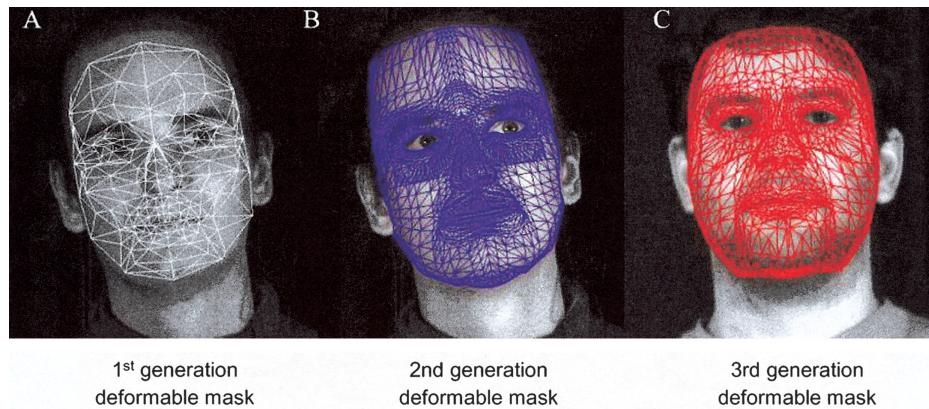
- **expert uman in citirea fetzelor...** a clasificat corect (L / H stressor) 85% din inregistrarile video
- **Semne ale stresului:** miscari ale sprancenei stangi, muscarea buzei de jos, miscari laterale simultane ale buzelor, clipit des, miscare a intregului corp
- Tehnica noua de transformare a inregistrarii video 2-D intr-o forma ce permite identificarea orientarii 3-D a fetzei, precum si a parametrilor ce descriu miscarea sprancenelor, buzelor etc.
- **Alexithymia**= dificultate de a-si identifica si descrie sentimentele, senzatiile corporale, focalizare pe evenimentele exterioare

- Sunt astronautii alexithymici?
- 25% din subiectii testului au fost incadrati ca 'moderat' alexithymici
- studiile viitoare vor analiza acuratetea algoritmului OCR, functie de alexithymie si de efectele microgravitatiei asupra 'facial edema'



Imagini faciale ale subiectilor ce executa sarcini nesolicitante (A1, B1), respectiv **solicitante** (A2–4, B2–4)

Fetzele sunt aproape fara expresie in timpul sarcinilor nesolicitante, si expresive in timpul celor solicitante – stresante, dificile, frustrante



Im bunatatiri succesive in programarea MASTII

produse de algoritmului OCR:

- Dela 7 (A,B) la10 parametri (C)
- 3 modeleaza doar deformarea gurii
- Dela 192 (A) la1100 noduri (C)
- Mecanism semi-automat de fixare a mastii

ALGORITM in doi pasi

1. Recunoasterea expresiilor ce denota **stresul** ... analizand seriile de timp corespunzatoare parametrilor mastii. EXP: pentru detectarea miscarilor rapide de cap urmarim componenta 'rigid body'; pentru detectarea unor expresii faciale negative urmarim deformarea componentelor 'spranceana' si 'miscarile gurii'. Aici se aplica LMA, cu avantajele:
 - de a segmenta semnalul continuu, in componente discrete
 - de a ingloba perturbatiile, data fiind natura lor probabilista - oamenii nu repeta de doua ori aceeasi miscare in mod identic

Intai antrenam LMA pe exemple etichetate, apoi il punem sa urmareasca inregistrarile

si sa izoleze expresiile faciale negative invatate

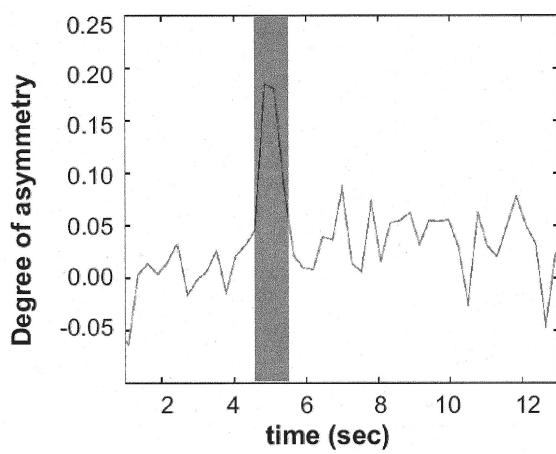
2. **Acumularea informatiei asupra manifestarilor stresului** LMA dela pasul (1) ne spune cat de des apar expresii negative si cat timp tin acestea. Recunoasterea STRESULUI e data de frecventa acestor expresii, precum si de aparitia simultana a mai multor astfel de indicii: clipitul des + miscari rapide de cap

REZULTATE

- Pentru antrenare s-au folosit ca indicatori de stres (la sugestia expertului uman), miscarile gurii si buzelor
- Testare pe 20 de subiecti
- A clasificat corect 75-88% dintre subiecti



A



B

A – expresie facială în timpul unei sarcini solicitante

**B – reprezentare a miscării buzelor, prin cuantificarea
distanței dintre buze.**

Zona gri corespunde expresiei stresate din figura (A)