

Evaluarea rezultatelor la testele grilă prin metode conexioniste

Prof.dr. Constanța BODEA, ec. Octavian RENGA,
Catedra de Informatică Economică, A.S.E. București

Concursurile organizate sub forma testelor grilă reclamă preluarea din cadrul formularelor de concurs a răspunsurilor candidaților, compararea acestor răspunsuri cu cele corecte, din barem, determinarea punctajelor și calcularea notelor. Preluarea răspunsurilor din formulare se poate realiza manual sau prin scanare. Interpretarea imaginii scanate este dificil de realizat, datorită variațiilor individuale de marcare a răspunsurilor și a condițiilor particulare de realizare a scanării (poziția formularului în timpul scanării, intensitatea culorilor, rezoluția etc). Având în vedere faptul că metodele conexioniste permit obținerea unor rezultate bune în prelucrarea imaginilor cu zgomote, articolul prezintă aplicarea rețelelor neuronale feedforward multinivel în prelucrarea grilelor de la examenele de licență din cadrul ASE. Concluziile formulate în articol sunt obținute pe baza unei aplicații realizată de autori și testată în cadrul unei colectivități de studenți de la specializarea Informatică, anii V-zi și VI-serial, în timpul pregătirii și susținerii examenelor de licență.

Cuvinte cheie: prelucrare imagine, rețele neuronale feedforward multinivel, instruire backpropagation accelerată, simulatoare de rețele neuronale, programare vizuală.

1. Prelucrarea imaginilor prin metode conexioniste

Metodele conexioniste sunt aplicate în numeroase domenii ([1]). O categorie importantă de aplicații o constituie prelucrarea imaginilor. O serie de operații legate de manipularea imaginilor (determinarea și accentuarea contururilor, segmentarea imaginii, simplificarea - scheletizarea, extragerea caracteristicilor, segmentarea imaginii, compresia și recunoașterea imaginilor) pot fi realizate cu ajutorul rețelelor neuronale.

Algoritmii Rosenfeld-Kak și Wang-Zhang permit implementarea paralelă a operațiilor de subțiere și scheletizare, utile la extragerea caracteristicilor imaginilor ([2]). La baza acestor algoritmi se află analiza tuturor vectorilor ce pot fi formați într-o vecinătate a unui pixel.

Segmentarea imaginilor se realizează cu succes cu ajutorul rețelelor autoorganizabile, în timp ce extragerea și selecția informațiilor esențiale (caracteristicilor) presupun utilizarea rețelelor feedforward multinivel.

Diferite soluții bazate pe calcul neuronal vizează compresia imaginilor. Nu toate soluțiile definite au permis și o bună reconstruire a imaginilor pe baza datelor comprimate. Astfel, Anthony S. ([3]) a studiat perfor-

manțele rețelelor backpropagation în aplicații de acest tip, arătând că metodele clasice, prin analiza componentelor principale se dovedesc totuși superioare. Sonehara prezintă o rețea backpropagation pentru compresia imaginilor reprezentând figuri umane, în timp ce Manikopoulos propune o soluție cu rețele LVQ. Ahalt S. ([3]) realizează o analiză comparativă a performanțelor sistemelor cu instruire competitivă, bazate pe metoda LVQ și a celor funcționând după metoda Linde-Buzo-Gray. Naillon și Theeten au utilizat o rețea Hopfield pentru compresia imaginilor TV.

O soluție ideală pentru compresia imaginilor ar presupune memorarea atât a unei descrieri simbolice (de nivel înalt) a imaginii, cât și a reprezentării propriu-zise, într-un mod extrem de compact. Descrierea de nivel înalt ar putea ușura sarcina reconstituirii imaginii și realizarea diferitelor operații asupra imaginii. O serie de rezultate au fost deja obținute ([1]), în acest sens putând fi menționată metoda structurii ierarhice a scenelor (HSS), introdusă de Minsky și Maren. O altă metodă ce produce o reconstituire foarte exactă a imaginii a fost propusă de Okamoto, pe baza utilizării unor cunoștințe despre segmentarea imaginii. Discontinuitățile imaginii sunt reprezentate printr-un model stochastic de tip

MRF (Markov Random Field). Reconstrucția imaginii se realizează cu ajutorul modelului MRF, printr-un proces de relaxare stochastică. Un aspect interesant al manipulării imaginilor, abordat prin metode conexioniste îl reprezintă corelarea imaginilor multispectrale, obținute de la mai mulți senzori concomitent ("imagini stereo"). O serie de metode conexioniste utilizate în prelucrarea imaginilor pot fi utilizate și pentru fuzionarea imaginilor. Există particularități ale acestui tip de prelucrare a imaginilor, care impun definirea unor metode de lucru specifice. Aceleași regiuni cu diferite caracteristici (mărime, formă, localizare), pot să se regăsească în mai multe imagini, cu rezoluție și alte proprietăți grafice distințe. Corelarea la nivel de pixel nu este întotdeauna posibilă și nici recomandabilă. Totodată, datorită diferențelor, la nivelul caracteristicilor nu este posibilă corelarea imaginilor nici la acest nivel înalt, al atributelor. Descrările structurale, de nivel înalt, ce pun în evidență asociările semnificative la nivel perceptual pot reprezenta o bază solidă pentru corelarea imaginilor. În acest sens, se poate menționa metoda HSS, introdusă de Minsky și Maren.

2. Posibilități de prelucrare prin metode conexioniste a grilelor de la examenele din cadrul ASE, București

Testul grilă reprezintă, în prezent, forma cea mai răspândită de organizare și desfășurare a examenelor. Această modalitate de verificare a cunoștințelor simplifică procedura de desfășurare și de evaluare a rezultatelor. În mod ușual, formularele de grilă sunt proiectate astfel încât să fie posibilă prelucrarea optică a răspunsurilor candidaților. Scanarea grilelor de concurs este o tehnică curentă de preluare a informațiilor din grilele de examen, în ciuda dificultăților de

analiză a imaginilor scanate.

Analizând formularele de grilă utilizate în ASE în cursul ultimilor doi ani universitari la diferitele examene (licență, admitere) se poate constata că la proiectarea acestora nu au fost avute în vedere eventuale soluții de prelucrare automată a formularelor, întrucât: - căsuțele destinate marcării răspunsurilor sunt prea mari și candidații pot întâmpina dificultăți în marcarea omogenă a unor zone atât de întinse. Datorită acestui fapt și a numărului mare de pixeli cu informație utilă, analiza răspunsurilor este mult îngreunată.

- căsuțele pentru marcarea răspunsurilor au o formă dreptunghiulară. Acest format nu asigură robustețe procesului de identificare și preluare a pixelilor cu informație utilă în caz de poziționare greșită a formularului în timpul scanării;

- căsuțele pentru marcarea răspunsurilor sunt lipite. Acest mod de aranjare a căsuțelor crează dificultăți la completare (depăși-rea limitelor unei căsuțe determină, de cele mai multe ori, intrarea în zona aferentă căsuței adiacente și poate duce la anularea răspunsului, prin identificarea a două căsuțe marcate pentru aceeași întrebare). Lipirea căsuțelor de marcarea a răspunsurilor crează dificultăți și la identificarea pixelilor cu informație utilă, în cazul poziționării inexacte a formularului în timpul scanării.

Aplicarea metodelor conexioniste la prelucrarea imaginilor de grilă impune deci, reprojecțarea formularelor de grilă utilizate în ASE. Figura 1 prezintă formularul propus, ca alternativă la cel utilizat în prezent, pentru baterii de 45 de întrebări.

Se observă că s-a optat pentru marcarea răspunsurilor în spații circulare, depărtate unele de altele, pentru asigurarea fiabilității în cazul scanării unei grile într-o poziție ușor deviată.

ACADEMIA DE STUDII ECONOMICE

Facultatea:

Specializarea:

EXAMEN DE LICENȚĂ

Disciplina:

Sesiunea:

Grila:

	RASPUNSURI				
	a	b	c	d	e
1	○	○	○	○	○
2	○	○	○	○	○
3	○	○	○	○	○
4	○	○	○	○	○
5	○	○	○	○	○
6	○	○	○	○	○
7	○	○	○	○	○
8	○	○	○	○	○
9	○	○	○	○	○
10	○	○	○	○	○
11	○	○	○	○	○
12	○	○	○	○	○
13	○	○	○	○	○
14	○	○	○	○	○
15	○	○	○	○	○
16	○	○	○	○	○
17	○	○	○	○	○
18	○	○	○	○	○
19	○	○	○	○	○
20	○	○	○	○	○
21	○	○	○	○	○
22	○	○	○	○	○
23	○	○	○	○	○
24	○	○	○	○	○
25	○	○	○	○	○
26	○	○	○	○	○
27	○	○	○	○	○
28	○	○	○	○	○
29	○	○	○	○	○
30	○	○	○	○	○
31	○	○	○	○	○
32	○	○	○	○	○
33	○	○	○	○	○
34	○	○	○	○	○
35	○	○	○	○	○
36	○	○	○	○	○
37	○	○	○	○	○
38	○	○	○	○	○
39	○	○	○	○	○
40	○	○	○	○	○
41	○	○	○	○	○
42	○	○	○	○	○
43	○	○	○	○	○
44	○	○	○	○	○
45	○	○	○	○	○

Fig. 1. Formular de grilă pentru baterii de 45 de întrebări

Pentru recunoașterea unei zone marcate, se extrag din grilă biții de culoare ai unui pătrat ce conține cercul rezervat marcării răspunsului corect pentru fiecare întrebare (figura 2). Zona hașurată reprezintă informație inu-

tilă, extrasă însă din imagine, în forma inițială a aplicației, pentru simplificarea prelucrărilor. Pătratul care include zona pentru marcarea are latura de 18 pixeli.

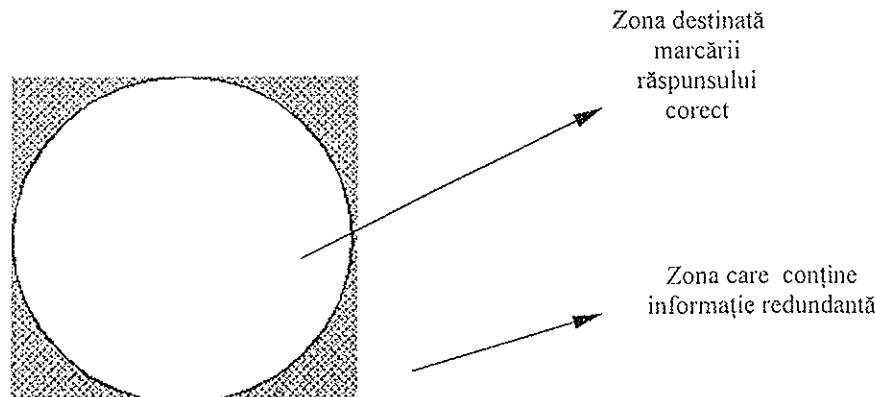


Fig. 2. Încadrarea zonei cu informație utilă

3. Arhitectura rețelei neuronale pentru prelucrarea informațiilor din grilă

Autorii au optat pentru utilizarea unei rețele feedforward multinivel pentru analiza imaginii de grilă. Arhitectura rețelei este prezentată în figura 3. Numărul nivelurilor intermedie a fost fixat la doi, deoarece rezultatele experimentale au arătat că varietatea de mărcăje a răspunsurilor nu poate fi memorată de o rețea cu un singur nivel intermediar.

Numărul unităților de input este de $18 \times 18 = 324$, considerând că rețeaua trebuie să stabilească, la un moment dat starea unor singure zone de marcăre a răspunsurilor. Stratul de output al rețelei are dimensiunea unu, unitatea de output putând prezenta două stări: 0 (pentru zonă nemarcată) și 1 (pentru zonă marcată). Prin încercări s-a putut realiza și dimensionarea starturilor intermedie: 5, respectiv 4 unități.

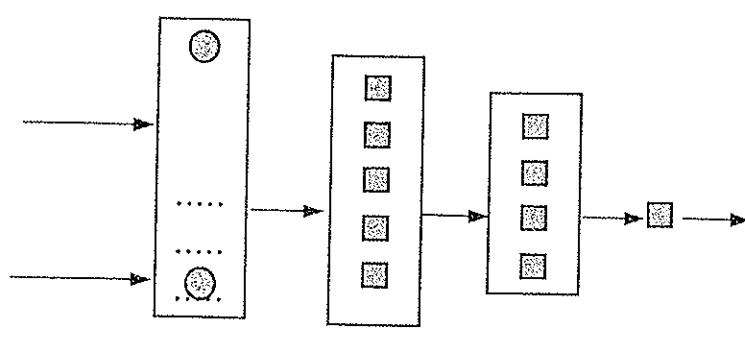


Fig. 3. Arhitectura rețelei neuronale

Unitățile intermediare din rețea sunt neuroni tansig (cu funcție de activare tangentă hiperbolică), în timp ce unitatea de output este neuron liniar (cu funcție de activare liniară).

4. Instruirea rețelei neuronale

Instruirea rețelei s-a realizat pe baza unui set de formulare completate de către studenți din anii V și VI. Algoritmul ales pentru realizarea instruirii a fost backpropagation, varianta accelerată, prin utilizarea unui factor moment variabil. În procesul de instruire, eroarea limită admisă a fost stabilită la 0,01. Evoluția erorii și a ratei de instruire pe parcursul a 700 de epoci de instruire este prezentată în figura 4.

5. Testarea rețelei

S-a realizat cu ajutorul unui set de formulare de grilă, completate de studenți din anii V și VI, diferite de cele utilizate la instruire.

Rezultatele la testare sunt satisfăcătoare, indicând o rată medie de recunoaștere de 91,2%.

6. Sistem bazat pe rețele neuronale pentru evaluarea rezultatelor la teste de grilă

Autorii au integrat rețeaua feedforward într-un sistem software care să ofere o serie de facilități la prelucrarea grilelor de concurs (figura 5).

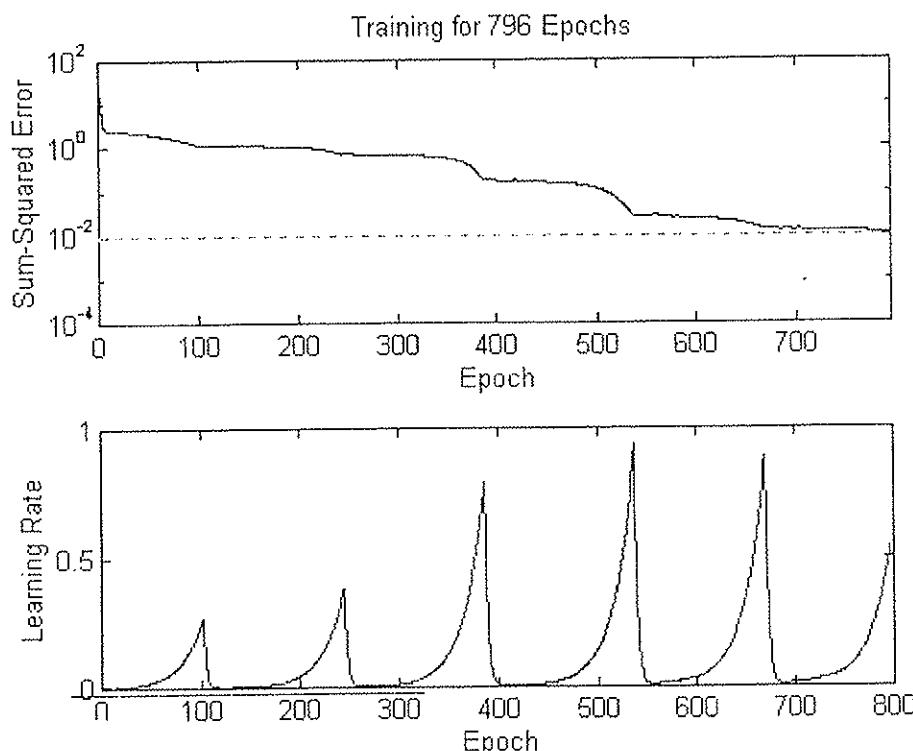


Fig. 4. Evoluția erorii și a ratei de instruire în procesul de instruire

Sistemul este realizat în Visual Basic și simulatorul Matlab, comunicarea realizându-se prin intermediul fișierelor de date. Componenta *Identificare* este realizată în Matlab, celelalte în Visual Basic. Sistemul prezintă două grupuri de componente:

- A) componente pentru prelucrarea baremilor (componenta *Barem*);
- B) componente pentru evaluarea tezelor (componentele *Extragere*, *Identificare* și *Evaluare*).

Componenta *Barem* permite încarcarea, actualizarea și afișarea răspunsurilor corecte pentru un anumit tip de grilă.

Componenta *Extragere* asigură preluarea din fișierul obținut prin scanarea formularului de grilă a pixelilor cu informație utilă (225 de siruri de 324 pixeli, corespunzând celor 45*5 căsuțe de marcări a răspunsurilor prezente în formular). Pozițiile din care se extrag pixelii sunt "învățate" anterior și memorate într-un fișier.

Componenta *Identificare* conține apelarea rețelei, instruită anterior pentru fiecare grup de 324 pixeli. Se determină pe rând starea tuturor celor 225 de căsuțe (căsuțe marcate sau nemarcate). Acești 225 de indicatori

sunt transferați componentei care stabilește punctajul și nota.

Componenta *Evaluare* preia informațiile privind starea zonelor de marcări a răspunsurilor din teză, stabilește pe baza baremului care sunt răspunsurile corecte și care sunt greșite sau incorrect marcate, calculează punctajul și nota, afișând aceste informații, concomitent cu memorarea lor într-un fișier de teze prelucrate.

7. Concluzii

Dezvoltarea ulterioară a sistemului va urmări, în principal, perfecționarea componentei *Extragere*, în sensul de a ține seama de variațiile semnificative ale condițiilor de scanare, în special a pozitiilor de la care să se extragă informația (pixelii de culoare). Se are în vedere renunțarea la utilizarea unor poziții predefinite, trecându-se la determinarea acestor poziții în raport de modul în care a decurs scanarea.

De asemenea, obiectivul autorilor este de a realiza perfecționarea componentei *Identificare*, continuându-se studiul experimental al arhitecturii actuale de rețea neuronală, precum și simularea altor modele de rețea.

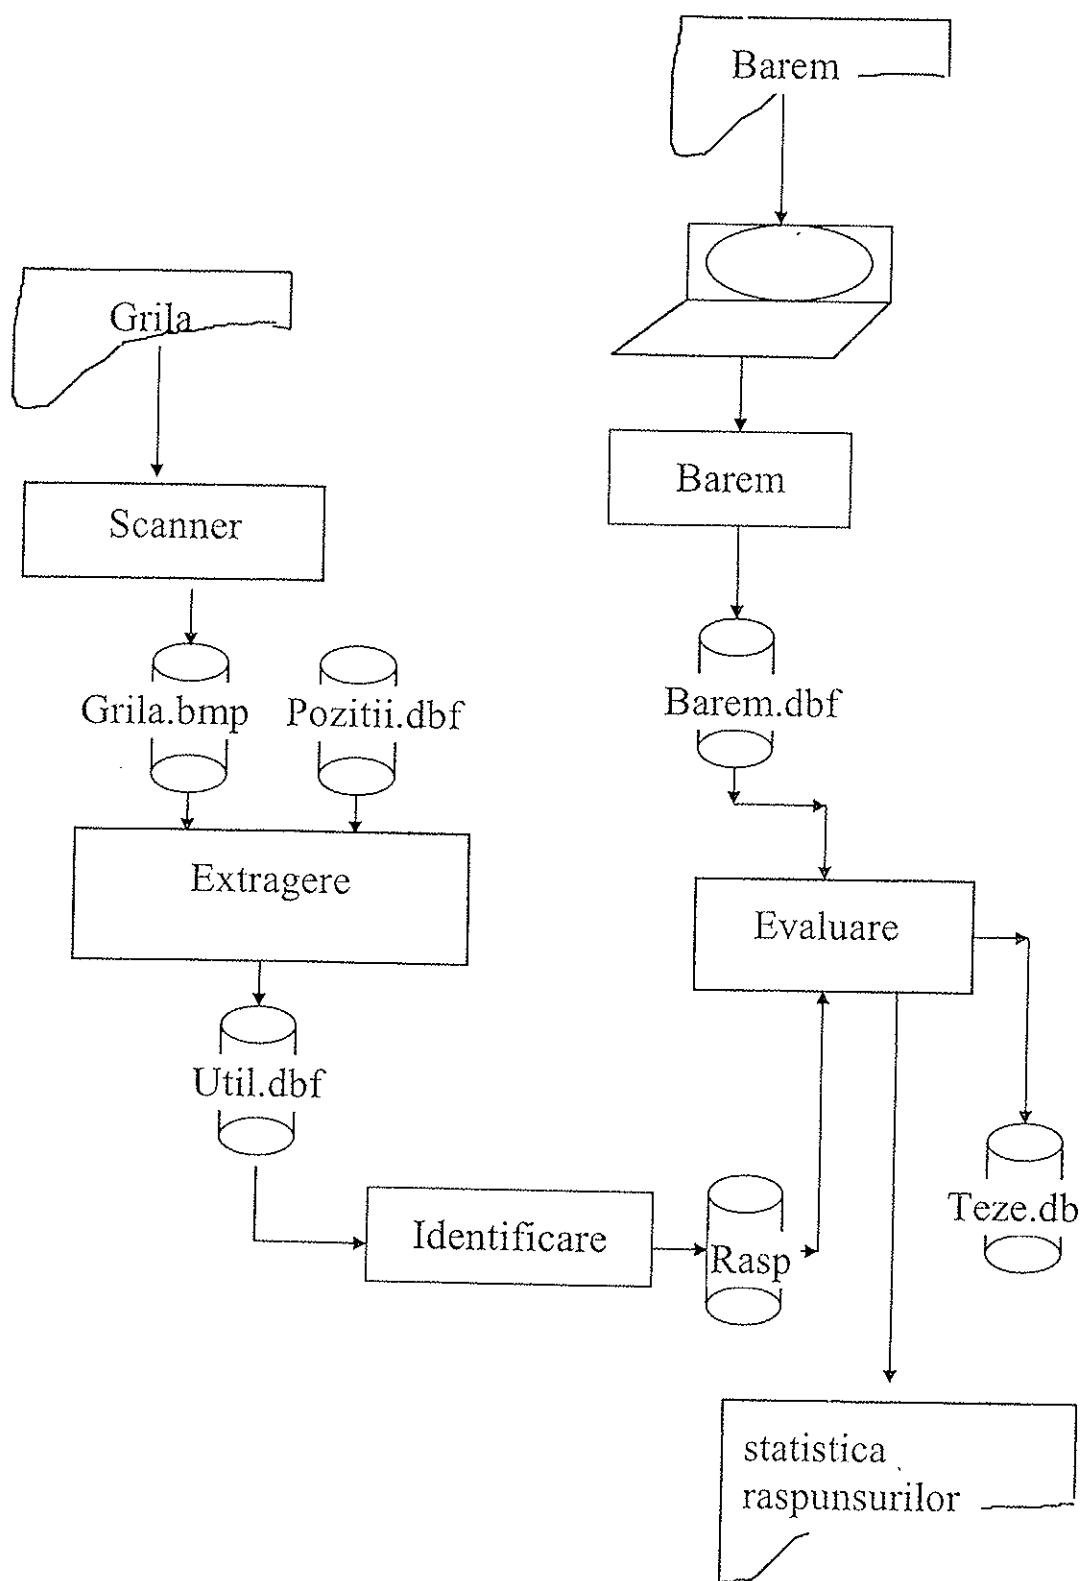


Fig. 5. Schema bloc a sistemului de evaluare a rezultatelor la testele grilă

Bibliografie

- [1] Bodea C., Ivan I., Crețu A. - Aplicații ale rețelelor neuronale în economic, Editura Inforec, București, 1997.
[2] Dumitrescu D., Costin H. - Rețele neu-

ronale. Teorie și aplicații, Editura Teora, București, 1996.

[3] Maren A., Harston C., Pap R. (eds) - Handbook of Neural Computing Applications, Academic Press, Inc., 1990.

*Cel mai important eveniment științific
al anului 1999:*

*Al patrulea Simpozion Internațional
de Informatică Economică – IE'99*

(vezi pagina 111)