

STRUCTURILE MEMORIEI ASOCIATIVE ÎN PROBLEMELE DE RESTABILIRE A IMAGINILOR



dr. în șt. tehnice,
conf. univ. Igor MARDARE, șef catedră CPAE,
Universitatea Tehnică a Moldovei

Rezolvarea practică a sarcinii de restabilire a imaginilor defectate este analizată de pe poziția noilor tipuri de asociații dintre imaginile defectate ale obiectelor și imaginile lor adevărate. Pentru noile tipuri de asociații se propun procesoarele, construite în baza rețelei Hopfield și orientate la specificul unor astfel de asociații.

Introducere

Tipurile memoriei asociative existente permit rezolvarea cu succes a sarcinilor de căutare a asociațiilor dintre obiectele care au același număr de parametri, ce descriu caracteristicile obiectelor (asociațiile uniforme). Asociațiile identificate neuniforme inversate, legate inversate, direcționate inversate și asociațiile direcționate derulate care reflectă legătura dintre obiectele ce aparțin diferitelor clase și care au un număr diferit de parametri descriptivi, trebuie să fie cercetate de pe pozițiile practice de găsire a asociațiilor prin rețelele clasice de neuroni, de exemplu prin memoria asociativă Hopfield. În caz de necesitate, la rezolvarea problemelor de restabilire a imaginilor defectate e nevoie să fie antrenate resurse suplimentare pentru sporirea posibilităților rețelelor de neuroni existente.

Elaborarea procesoarelor intelectuale, orientate la tipurile de asociații

Fie că se cere a fi restabilită scena care reprezintă obiectul de ordinul 1- \mathbf{x}_{Σ}^1 . Scena \mathbf{x}_{Σ}^1 poate fi compusă dintr-o multitudine de obiecte defectate. Presupunem că scena este constituită din două obiecte $\tilde{\mathbf{x}}_i^1$ și $\tilde{\mathbf{x}}_j^1$, ce aparțin la două clase diferite – 1-a și 2-a: $\mathbf{x}_{\Sigma}^1 = \{\tilde{\mathbf{x}}_{1i}^1, \tilde{\mathbf{x}}_{2j}^1\}$. În fiecare clasă de obiecte toți parametrii imaginii defectate și a celei adevărate sunt echivalenți. Și fie că obiectele diferitelor clase \mathbf{x}_{cn}^1 au un număr echivalent de parametri $\hat{\mathbf{x}}_k$. Atunci, pentru restabilirea diferitor obiecte defectate $\tilde{\mathbf{x}}_{1i}^1$ și $\tilde{\mathbf{x}}_{2j}^1$ va fi nevoie de o memorie asociativă. O astfel de situație corespunde căutării asociațiilor uniforme $\mathbf{A}_{i,E}$ dintre imaginile defectate și imaginile adevărate conform expresiei:

$$\begin{cases} \mathbf{x}_{1NE}^1 = \mathbf{A}_{1,E}(\tilde{\mathbf{x}}_{1n}^1) \\ \mathbf{x}_{2NE}^1 = \mathbf{A}_{2,E}(\tilde{\mathbf{x}}_{2n}^1) \\ \dots \\ \mathbf{x}_{cNE}^1 = \mathbf{A}_{c,E}(\tilde{\mathbf{x}}_{cn}^1). \end{cases} \quad (1)$$

În calitate de memorie asociativă se alege rețeaua Hopfield. Numărul de intrări de neuroni și de ieșiri ale memoriei asociative corespunde numărului de parametri echivalenți $\hat{\mathbf{x}}_k$ ai obiectelor. Fiecare neuron al stratului doi măsoară suma ponderată a intrărilor sale, care mai apoi, cu ajutorul funcției de prag f , se transformă în semnal de ieșire. Rețeaua Hopfield, în procesul de restabilire a imaginilor, este capabilă doar să schimbe (fără generare sau înlăturare) semnificațiile parametrilor echivalenți ai imaginii defectate, de exemplu:

$$\tilde{\mathbf{x}}_{li}^1 = (\hat{x}_{li1}, \hat{x}_{li2}, \dots, \hat{x}_{liK}), \text{ și să le aducă până la semnificațiile corespunzătoare ale imaginii adevărate } \mathbf{x}_{1E}^1 = (\hat{x}_{11E}, \hat{x}_{12E}, \dots, \hat{x}_{1KE}):$$

$$\hat{x}_{li1} = \hat{x}_{11E}, \hat{x}_{li2} = \hat{x}_{12E}, \dots, \hat{x}_{liK} = \hat{x}_{1KE}.$$

La început trebuie să fie învățată memoria asociativă. Învățarea se reduce la calculul coeficienților de pondere a sinapselor w_{mk} , conform expresiei:

$$w_{mk} = \begin{cases} \sum_{n=1}^N x_{nm} x_{nk}, & m \neq k \\ 0, & m = k, \end{cases} \quad (2)$$

unde m, k – numărul de neuroni, în baza informației despre imaginile adevărate ale obiectelor \mathbf{x}_{1E}^1 și \mathbf{x}_{2E}^1 . Rețeaua memorează imaginile adevărate \mathbf{x}_{1E}^1 și \mathbf{x}_{2E}^1 și în forma unui singur vector al coeficienților de pondere

$$\mathbf{w}_{cNE} = (w_{11}, w_{12}, \dots, w_{MK}).$$

În procesul de restabilire a imaginilor defectate, vectorul de ieșire al memoriei asociative, care corespunde imaginii defectate $\tilde{\mathbf{x}}_{li}^1$ ($\tilde{\mathbf{x}}_{2j}^1$), se folosește ca stare inițială a rețelei. La vectorul de ieșire, după stabilirea rețelei de neuroni cu legătură inversă a stării stabile (minimum

energetic), memoriei asociative i se va da imaginea adevărată, memorată din timp \mathbf{x}_{1E}^1 (\mathbf{x}_{2E}^1) sau se va da raportul despre absența asociațiilor pentru imaginea defectată $\tilde{\mathbf{x}}_{li}^1$ ($\tilde{\mathbf{x}}_{2j}^1$).

$$\begin{cases} \mathbf{x}_{1E}^1 = \mathbf{A}_{1,E}(\tilde{\mathbf{x}}_{li}^1) \\ \mathbf{x}_{2E}^1 = \mathbf{A}_{2,E}(\tilde{\mathbf{x}}_{2j}^1). \end{cases} \quad (3)$$

Numărul de intrări, de neuroni și de ieșiri la fiecare memorie asociativă a lui Hopfield corespunde cu numărul parametrilor echivalenți ai imaginilor defectate și imaginilor adevărate.

Învățarea fiecărei memorii asociative se reduce la calculul momentan al coeficienților de pondere ai sinapselor w_{mk} , conform expresiei 2, în baza informației despre imaginile adevărate ale obiectelor \mathbf{x}_{1E}^1 și \mathbf{x}_{2E}^1 . Fiecare rețea memorează imaginile adevărate \mathbf{x}_{1E}^1 și \mathbf{x}_{2E}^1 sub formă de vectori ai coeficienților de pondere

$$\mathbf{w}_{1E} = (w_{111}, w_{112}, \dots, w_{1MK}) \text{ și}$$

$$\mathbf{w}_{2E} = (w_{211}, w_{212}, \dots, w_{2MR}).$$

În procesul de restabilire a imaginilor defectate, la vectorul de intrare $\tilde{\mathbf{x}}_{li}^1$ ($\tilde{\mathbf{x}}_{2j}^1$), memoriei asociative i se va da imaginea adevărată, memorată din timp \mathbf{x}_{1E}^1 (\mathbf{x}_{2E}^1) sau se va da raportul despre lipsa asociațiilor pentru imaginea defectată $\tilde{\mathbf{x}}_{li}^1$ ($\tilde{\mathbf{x}}_{2j}^1$).

Fie că trebuie să se restabilească imaginea defectată $\tilde{\mathbf{x}}_{ci}^1$, pentru care se presupun câteva imagini adevărate

$\mathbf{x}_{1NE}^1, \mathbf{x}_{2NE}^1, \dots, \mathbf{x}_{cNE}^1, \dots, \mathbf{x}_{cNE}^1$, fiecare din ele reprezentând o clasă aparte de obiecte \mathbf{C} . În perechea de obiecte asociative ale unei clase \mathbf{C} $\tilde{\mathbf{x}}_{ci}^1 - \mathbf{x}_{cNE}^1$ sunt doar parametri echivalenți $\hat{\mathbf{x}}_k$, iar la perechile obiectelor asociative ale diferitor clase

$\tilde{\mathbf{x}}_{ci}^1 - \mathbf{x}_{1NE}^1, \tilde{\mathbf{x}}_{ci}^1 - \mathbf{x}_{2NE}^1, \dots, \tilde{\mathbf{x}}_{ci}^1 - \mathbf{x}_{cNE}^1$ sunt parametri echivalenți $\hat{\mathbf{x}}_k$ și parametri neechivalenți \mathbf{x}_k . O astfel de situație

corespunde căutării asociațiilor uniforme inversate dintre imaginile defectate $\tilde{\mathbf{x}}_{ci}^1$ și imaginile adevărate

$\mathbf{x}_{1NE}^1, \mathbf{x}_{2NE}^1, \dots, \mathbf{x}_{cNE}^1, \dots, \mathbf{x}_{cNE}^1$ conform expresiei:

$$\left\{ \begin{array}{l} \mathbf{x}_{cNE}^1 = A_{c,E}(\tilde{\mathbf{x}}_{ci}^1) \\ \mathbf{x}_{1NE}^1 = A_{1,E}(\mathbf{x}_{cNE}^1) \\ \mathbf{x}_{2NE}^1 = A_{2,E}(\mathbf{x}_{cNE}^1) \\ \dots \\ \mathbf{x}_{cNE}^1 = A_{c,E}(\mathbf{x}_{cNE}^1) \end{array} \right. \quad (4)$$

Atunci, pentru restabilirea obiectului defectat $\tilde{\mathbf{x}}_{ci}^1$ trebuie să se schimbe parametrii echivalenți $\hat{\mathbf{x}}_k$ (înlăturarea defectelor), la fel să se genereze parametri noi sau să se înlătore parametri neechivalenți \mathbf{x}_k (schimbarea însușirilor obiectelor, adică transformarea obiectului). Transformarea obiectului se face pentru a căuta asociațiile dintre obiectele diferitelor clase. Memoria asociativă Hopfield este capabilă să păstreze imaginile adevărate, numărul de parametri care corespund numărului de parametri ai imaginii defectate (parametrii echivalenți $\hat{\mathbf{x}}_k$). Însă, o astfel de memorie nu poate găsi asociațiile inversate, adică nu poate genera noi parametri neechivalenți pentru imaginea defectată (dimensiunea vectorului de ieșire a rețelei Hopfield este egală cu dimensiunea vectorului de intrare). De aceea, pentru acest caz se propune o structură combinată care conține memoria asociativă Hopfield și rețeaua de neuroni Kohonen (fig.1).

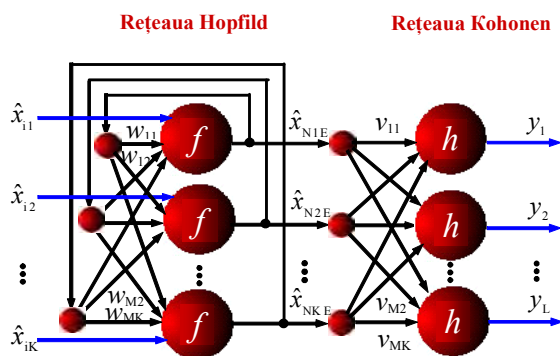


Figura 1. **Rețeaua de neuroni Hopfield-Kohonen.**

Vectorul de ieșire al rețelei Hopfield se va folosi în calitate de vector de intrare al rețelei Kohonen pentru formarea codului de adresă la ieșirea rețelei Kohonen, pe care se găsește obiectul asociativ necesar sau grupa de obiecte asociative. Rețeaua lui Hopfield găsește asociația 1-lui nivel al obiectelor $\tilde{\mathbf{x}}_{ci}^1$ și \mathbf{x}_{cNE}^1 ale unei

clase \mathbf{c} : $\mathbf{x}_{cNE}^1 = A_{c,E}(\tilde{\mathbf{x}}_{ci}^1)$. Aceasta semnifică, că în procesul de restabilire a imaginii se îndeplinește corecția semnificațiilor parametrilor echivalenți ai imaginii defectate $\tilde{\mathbf{x}}_{ci}^1 = (\hat{x}_{ci1}, \hat{x}_{ci2}, \dots, \hat{x}_{ciK})$, care se aduc până la valoarea imaginii adevărate $\mathbf{x}_{cNE}^1 = (\hat{x}_{cN1E}, \hat{x}_{cN2E}, \dots, \hat{x}_{cNK E})$: $\hat{x}_{ci1} = \hat{x}_{cN1E}$, $\hat{x}_{ci2} = \hat{x}_{cN2E}$, ..., $\hat{x}_{ciK} = \hat{x}_{cNK E}$ adică se înlătură defectele imaginii $\tilde{\mathbf{x}}_{ci}^1$. În rețeaua lui Kohonen neuronii concurează între ei pentru dreptul de a se combina cel mai reușit cu vectorul de intrare \mathbf{x}_{cNE}^1 (vectorul de ieșire a lui Hopfield). Învinge neuronul, al cărui vector cu ponderea \mathbf{v}_{mk} este mai aproape de vectorul de intrare. Neuronii lui Kohonen au funcția liniară de activare h . Vectorul de ieșire al rețelei Kohonen:

$$\mathbf{y}_l = \mathbf{x}_{cNE}^1 \cdot \mathbf{v}_{mk} \quad (5)$$

prezintă codul, corespunzător adresei de păstrare a imaginilor asociative adevărate

$\mathbf{x}_{1NE}^1, \mathbf{x}_{2NE}^1, \dots, \mathbf{x}_{cNE}^1$. Vectorii imaginilor adevărate $\mathbf{x}_{1NE}^1, \mathbf{x}_{2NE}^1, \dots, \mathbf{x}_{cNE}^1$, care conțin parametrii echivalenți $\hat{\mathbf{x}}_k$ și parametrii neechivalenți regeneratori \mathbf{x}_k , se păstrează într-un bloc separat al memoriei cu adresare după \mathbf{y}_l , format de rețeaua Kohonen: $\mathbf{y}_l = \{\mathbf{x}_{1NE}^1, \mathbf{x}_{2NE}^1, \dots, \mathbf{x}_{cNE}^1\}$. În așa fel, rețeaua Kohonen găsește asociațiile nivelului 2 $\mathbf{x}_{1NE}^1 = A_{1,E}(\mathbf{x}_{cNE}^1)$, $\mathbf{x}_{2NE}^1 = A_{2,E}(\mathbf{x}_{cNE}^1)$, ..., $\mathbf{x}_{cNE}^1 = A_{c,E}(\mathbf{x}_{cNE}^1)$. Asociația inversată, realizată de rețeaua Hopfield-Kohonen pentru căutare, de exemplu, a imaginilor adevărate, se descrie în felul următor:

$$\mathbf{x}_{1NE}^1, \mathbf{x}_{2NE}^1, \dots, \mathbf{x}_{cNE}^1 = A_{1,2,\dots,C,E} \quad (6)$$

$$[\mathbf{x}_{cNE}^1 = A_{c,E}(\tilde{\mathbf{x}}_{ci}^1)],$$

unde $A_{1,2,\dots,C,E}$ – multitudinea de asociații neuniforme a obiectelor \mathbf{x}_{cNE}^1 .

Învățarea rețelei Hopfield constă în calcularea coeficienților de pondere a sinapselor w_{mk} , conform expresiei 2, în baza informației despre imaginile adevărate ale obiectelor \mathbf{x}_{cNE}^1 . Rețeaua memorează imaginile adevărate \mathbf{x}_{cNE}^1 sub forma de vectori ai coeficienților de pondere $\mathbf{w}_{cNE} = (w_{11}, w_{12}, \dots, w_{MK})$. Înainte de învățare,

ponderei rețelei Kohonen v_{mk} i se atribuie mărimi nu prea mari întâmplătoare normalizate. În timpul învățării, la intrarea rețelei Kohonen se dau vectorii x_{cNE}^1 , și se calculează produsul lor scalar cu vectorii ponderelor v_{mk} , legați cu toți neuronii Kohonen. Pentru j-l neuron cu o valoare maximă a produsului scalar (x_{cNE}^1, v_j) se va efectua construirea valorilor ponderilor v_j :

$$v_{jk}^{t+1} = v_{jk}^t + \gamma (x_k^t - v_{jk}^t), \quad (7)$$

$$v_{jk}^{t+1}$$

unde – valoarea nouă a ponderii, care a câștigat j-l neuron;

v_{jk}^t – valoarea anterioară a ponderii j-lui neuron;

γ – coeficientul vitezei de învățare.

În procesul de restabilire a imaginilor defectate vectorul de intrare \tilde{x}_{ci}^1 al rețelei Hopfield se folosește ca stare inițială a rețelei. Pe vectorul de intrare memoriei asociative i se dă una din imaginile adevărate, memorate anterior x_{cNE}^1 sau i se va da unul din raportul despre absența asociațiilor pentru imaginea defectată \tilde{x}_{ci}^1 . În caz că se găsesc imagini asociative adevărate x_{cNE}^1 , de către y_l rețeaua Kohonen se formează codul de căutare al imaginilor asociative adevărate $x_{1NE}^1, x_{2NE}^1, \dots, x_{CNE}^1$.

Fie că trebuie să se restabilească imaginea defectată \tilde{x}_{ci}^1 , care presupune asociații legate inversate pentru obținerea obiectului adevărat cerut x_{cNE}^1 , care este asociația C-lui nivel. Asociațiile legate inversate se determină conform expresiei:

$$x_{cNE}^1 = A_{C-1,C} \dots \{x_{2NE}^1 = A_{1,2} [x_{1NE}^1 = A_{1,1}(\tilde{x}_{1i}^1)]\}. \quad (8)$$

În acest caz, numărul de parametri ai fiecărei imagini ulterioare asociative adevărate

$x_{1NE}^1 = (\hat{x}_{1N1E}, \hat{x}_{1N2E}, \dots, \hat{x}_{1NKE})$,
 $x_{2NE}^1 = (x_{2N1E}, x_{2N2E}, \dots, x_{2NPE})$,
 $x_{cNE}^1 = (x_{cN1E}, x_{cN2E}, \dots, x_{cNRE})$ este mai mare decât cel precedent: $K < P < \dots < R$. În perechea obiectelor asociative $\tilde{x}_{1i}^1 - x_{1NE}^1$ sunt doar parametri echivalenți \hat{x}_k , iar în perechile obiectelor asociative $x_{1NE}^1 - x_{2NE}^1, \dots, x_{c-1NE}^1 - x_{cNE}^1$ sunt parametri echivalenți \hat{x}_k și neechivalenți x_k . Atunci, pentru restabilirea obiectului defectat \tilde{x}_{1i}^1 trebuie să se schimbe parametrii echivalenți \hat{x}_k (în clasa sa), iar pentru găsirea asociațiilor inversate să se genereze parametri noi neechivalenți x_k (în alte clase). Aceste funcții pot fi realizate de către funcțiile rețelei Hopfield-Kohonen sau de către presupusa rețea Hopfield – perceptron-espander (fig.2).

Rețeaua Hopfield găsește pentru obiectul defectat, de exemplu de clasa 1, \tilde{x}_{1i}^1 obiectul asociativ adevărat x_{1NE}^1 în interiorul clasei 1 (asociația 1-lui nivel), iar perceptronul învățat cu două straturi, pe calea generării de însușiri suplimentare ale obiectelor x_{1NE}^1 , se procesează un obiect nou asociativ adevărat al unei alte clase, de exemplu al clasei a 2-a x_{2NE}^1 (asociația nivelului 2).

Obiectul de clasa a 2-a x_{2NE}^1 apare datorită generării în baza vectorului parametrilor echivalenți \hat{x}_k ai obiectului asociativ x_{1NE}^1 (ieșirea rețelei Hopfield) a vectorului legat al parametrilor neechivalenți x_k . Atunci, obiectul

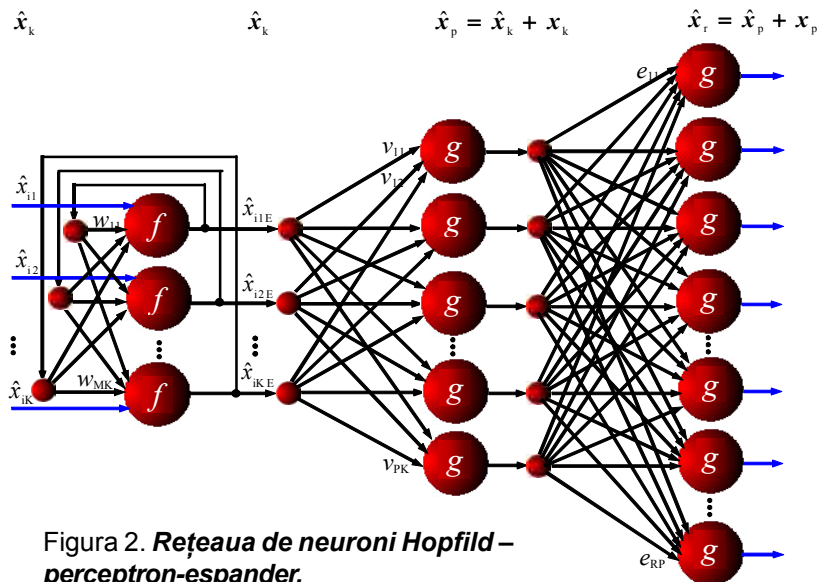


Figura 2. Rețeaua de neuroni Hopfield – perceptron-espander.

clasei a 2-a, determinat de parametrii P , se descriu de către vectorul de ieșire al perceptronului $\hat{\mathbf{x}}_r = \hat{\mathbf{x}}_p + \mathbf{x}_p$. În așa fel, perceptronul cu două straturi îndeplinește funcțiile esponderului însușirilor obiectelor. Pentru găsirea fiecărui obiect ulterior asociativ adevărat \mathbf{x}_{cNE}^1 e nevoie de un perceptron-espander învățat suplimentar. De exemplu, obiectul asociativ adevărat căutat al clasei C \mathbf{x}_{cNE}^1 , descris de parametrii R

$\hat{\mathbf{x}}_r = \hat{\mathbf{x}}_p + \mathbf{x}_p$ (asociația nivelului C), se cere esponderul $C-1$. În perceptron, în calitate de funcție activatoare a fiecărui neuron g se alege funcția sigmoidală sau funcția tangenței hiperbolice.

Pentru învățarea rețelei Hopfield se calculează coeficienții de pondere ai sinapselor w_{mk} , conform expresiei 2, în baza informației despre imaginile adevărate ale obiectelor \mathbf{x}_{cNE}^1 . Rețeaua reține imaginile adevărate \mathbf{x}_{cNE}^1 în forma vectorului coeficienților de pondere

$$\mathbf{w}_{cNE} = (w_{11}, w_{12}, \dots, w_{MK}).$$

Învățarea fiecărui perceptron-espander se face prin metoda de învățare cu profesor (Back Propagation, Resilient Propagation). Grupa de învățare pentru primul perceptron-espander constă din vectori de ieșire ai rețelei Hopfield \mathbf{x}_{cNE}^1 , care sunt asociațiile 1-lui nivel și unul din posibilele etaloane ale imaginilor, care reprezintă imaginea asociativă adevărată a nivelului 2. Atunci, primul perceptron învățat memorează imaginile asociative adevărate de nivelul 2 sub forma vectorului coeficienților de pondere

$\mathbf{v}_{cNE} = (v_{11}, v_{12}, \dots, v_{PK})$. Pentru învățarea fiecărui perceptron-espander ulterior C , grupa de învățare constă dintr-o multitudine de vectori de ieșire ai perceptron-espanderului precedent $C-1$ și unul din posibilele etaloane ale imaginilor de nivelul C . Atunci, fiecare perceptron C învățat memorează imaginile asociative adevărate ale nivelului C în forma vectorului coeficienților de pondere $\mathbf{e}_{cNE} = (e_{11}, e_{12}, \dots, e_{RP})$. Toți percep-

troni-espanderii se învață în așa fel, pentru a găsi asociațiile dintre obiectele din clase diferite (asociațiile diferitelor niveluri), adică, execută funcția memoriei asociative. În afară de aceasta, funcțiile perceptronului nu se limitează numai la memorarea obiectelor asociative adevărate. Datorită capacității generale a rețelei, se găsesc imaginile asociative adevărate care nu participă la procesul de învățare, deoarece vectorul de ieșire al perceptronului nu este nou din cauza neîntreruperii și funcțiilor activatoare diferențiate sub formă de sigmoidă sau tangență hiperbolică. Astfel, vectorii de ieșire necunoscuți nu trebuie să se deosebească prea mult de vectorii mulțimii de instruire.

În procesul de restabilire a imaginilor defectate memoria asociativă Hopfield găsește în mod obișnuit asociația de 1-lui nivel al obiectului $\tilde{\mathbf{x}}_{ci}^1$ și \mathbf{x}_{cNE}^1 al unei clase C : $\mathbf{x}_{cNE}^1 = A_{c,E}(\tilde{\mathbf{x}}_{ci}^1)$. Apoi, fiecare perceptron-espander, realizând funcția asociativă $A_{c-1,c}$ după legea, caracterizată de consecutivitatea vectorilor sinaptici \mathbf{v}_{cNE} , \mathbf{e}_{cNE} ..., determină consecutivitatea imaginilor legate asociative adevărate $\mathbf{x}_{2NE}^1, \dots, \mathbf{x}_{C-1NE}^1, \mathbf{x}_{cNE}^1$, care aparțin diferitelor clase:

$$\mathbf{x}_{2NE}^1 = A_{1,2}(\mathbf{x}_{1NE}^1), \dots,$$

$$\mathbf{x}_{cNE}^1 = A_{c-1,c}(\mathbf{x}_{c-1NE}^1) - \text{asociațiile } 2, \dots, C-1, C \text{ niveluri.}$$

Pentru sarcina de restabilire a imaginii defectate $\tilde{\mathbf{x}}_{ci}^1$, ce presupune asociații legate inversate, poate fi propusă structura, ce conține consecutivitatea rețelelor Hopfield – perceptron-espander (fig.3).

Această rețea permite găsirea obiectelor asociative din interiorul fiecărei clase de obiecte și între obiectele diferitelor clase. În legătură cu aceasta, la învățarea fiecărui perceptron-espander nu este obligatoriu să se utilizeze imaginea reală a obiectului în calitate de obiect-etalon, ci e suficient să fie o imagine aproape de etalon, adică una din imaginile defectate ale clasei date de obiecte. Următoarea după




Figura 3. **Rețeaua de neuroni, ce conține consecutivitatea rețelelor Hopfield – perceptron-expander.**

perceptronul-expander, rețeaua Hopfield este capabilă să determine imaginea asociativă reală pentru imaginea defectată.

Fie că trebuie să se restabilească câteva imagini defectate ce aparțin diferitelor clase de obiecte $\tilde{x}_{cn}^1 = \{\tilde{x}_{1n}^1, \tilde{x}_{2n}^1, \dots, \tilde{x}_{C-1n}^1\}$, pentru care există o singură imagine asociativă adevărată x_{CNE}^1 . În acest caz, multitudinea asociațiilor direcționate inversate sau direcționate derulate pentru fiecare din obiectele $\tilde{x}_{1n}^1, \tilde{x}_{2n}^1, \dots, \tilde{x}_{C-1n}^1$ se descrie prin sistemul:

$$\begin{cases} x_{CNE}^1 = A_{1,C} [x_{1NE}^1 = A_{1,1}(\tilde{x}_{1n}^1)] \\ x_{CNE}^1 = A_{2,C} [x_{2NE}^1 = A_{2,2}(\tilde{x}_{2n}^1)] \\ \dots \\ x_{CNE}^1 = A_{C-1,C} [x_{C-1NE}^1 = A_{C-1,C-1}(\tilde{x}_{C-1n}^1)]. \end{cases} \quad (9)$$

În perechile de asociații de nivelul 1

$$\tilde{x}_{1n}^1 - x_{1NE}^1, \tilde{x}_{2n}^1 - x_{2NE}^1, \dots, \tilde{x}_{C-1n}^1 - x_{C-1NE}^1$$

sunt numai parametri echivalenți \hat{x}_k . În fiecare pereche de asociații de nivelul 2 sunt parametri

echivalenți \hat{x}_k și neechivalenți x_k . Atunci,

restabilirea unui obiect defectat \tilde{x}_{ci}^1 constă în găsirea obiectului asociativ, care este obiectul real x_{CNE}^1 , și semnifică, că în imaginea defectată \tilde{x}_{ci}^1 se modifică parametri echivalenți \hat{x}_k și generează sau se înlătură parametri neechivalenți x_k .

Pentru restabilirea imaginii defectate, ce corespunde cazului schimbării parametrilor echivalenți \hat{x}_k și generării parametrilor neechivalenți x_k (asociațiile direcționate inversate), se poate aplica rețeaua Hopfield-Kohonen sau rețeaua Hopfield – perceptron-expander. În cazul schimbării parametrilor echivalenți \hat{x}_k și înlăturării parametrilor neechivalenți x_k (asociațiile direcționate derulate) se poate aplica rețeaua Hopfield-Kohonen sau rețeaua Hopfield – perceptron-compander propusă mai jos (fig.4).

Învățarea și funcționarea rețelei Hopfield – perceptron-compander în regimul de restabilire a imaginilor defectate se realizează analog rețelei




Figura 4. **Rețeaua de neuroni Hopfield – perceptron-compander.**

Hopfield – perceptron-espander. Numai că obiectul asociativ adevărat, la ieșirea perceptron-companderului (asociația nivelului 2), apare datorită înlăturării unei părți din parametri echivalenți \hat{x}'_k din vectorul parametrilor echivalenți \hat{x}_k ai obiectului asociativ adevărat la ieșirea rețelei Hopfield (asociația nivelului 1). Atunci obiectul asociativ adevărat la ieșirea perceptron-companderului, determinat de parametrii $P, P < K$, se descrie de vectorii parametrilor echivalenți $\hat{x}_p = \hat{x}_k - \hat{x}'_k$. În așa fel, perceptronul cu două straturi îndeplinește funcțiile companderului de însușiri a obiectelor.

ÎNCHEIERE

La căutarea asociațiilor uniforme, în care imaginile defectate și cele adevărate au numai parametri echivalenți, pot fi utilizate rețelele standard Hopfield, Heming sau memoria asociativă bidirecțională. Aceste rețele restabilesc doar asociațiile de nivelul 1 și sunt incapabile să realizeze asociații la un nivel mai înalt.

Pentru asociațiile neuniforme inversate, asociațiile legate inversate, direcționate inversate și asociațiile direcționate derulate în care imaginile defectate și cele adevărate au atât parametri echivalenți, cât și neechivalenți, rețelele standard pot fi utilizate numai pentru căutarea asociațiilor obiectelor unei clase. Pentru căutarea asociațiilor obiectelor ce aparțin diferitelor clase, este nevoie de espanderii sau companderii însușirilor obiectelor.

Structurile combinate propuse: rețelele Hopfield-Kohonen, Hopfield – perceptron-espander, Hopfield

perceptron-compander largesc semnificativ posibilitățile de căutare a asociațiilor dintre obiecte, permițând găsirea asociațiilor inversate și derulate datorită determinării legăturilor dintre obiectele diferitelor clase. Aceste rețele de neuroni prezintă un instrumentariu destul de efectiv pentru restabilirea unei clase vaste de obiecte defectate.

BIBLIOGRAFIE

1. Mardare I. Intellectual system for images restoration// Proceedings of SPIE "Information technologies 2004", Volume 5822, Chișinău, Republic of Moldova, pag. 46...57, 2004.
2. Mardare I., Perju V. Restoration of images by neural networks and associative memory// Proceedings of SPIE "Information technologies 2004", Volume 5822, Chișinău, Republic of Moldova, pag. 35...45, 2004.
3. Cornea I., Mardare I. Methods of Artificial Intellect in Images Restoration// CSCS-14. 14th International Conference on Control Systems and Computer Science, Bucharest, Romania, pag.141...143. 2003.