

Invenția se referă la domeniul rețelelor neuronale și poate fi aplicată la restabilirea și perceperea imaginilor.

Este cunoscută rețeaua neuronală Hamming, ce reprezintă o memorie asociativă (în continuare memorie asociativă Hamming), ce poate fi considerată cel mai simplu procesor intelectual pe bază de memorie asociativă pentru restabilirea imaginilor (în continuare procesor intelectual), ce aplică la ieșire acea imagine memorizată, a cărei distanță Hamming față de imaginea aplicată la intrare, este mai mică, astfel, se realizează restabilirea propriu-zisă a

imaginii adevărate x_c , pe baza imaginii denaturate \tilde{x}_{ci} , unde indicii au următoarea semnificație:

~ - semnifică că imaginea este denaturată;

c – numărul clasei de obiecte;

i – numărul imaginii din clasa c.

Dezavantajul memoriei asociative Hamming constă în aceea că, rețeaua dată generează la ieșire numărul asociației și nu însăși asociația, imaginea, și că, poate realiza asocieri doar în limitele unei singure clase de obiecte [1].

Mai este cunoscută memoria asociativă Hopfield ce permite restabilirea propriu-zisă a imaginii adevărate x_c , pe baza

imaginii denaturate \tilde{x}_{ci} , ce reprezintă un fragment al imaginii adevărate sau imaginea adevărată cu zgomot, iar dacă pragul de coincidență T cu orice imagine adevărată x_1, x_2, \dots, x_c , păstrată în memoria asociativă este mai mic ca cel stabilit, rețeaua constată incoincidența imaginii denaturate cu nici una din imaginile adevărate [2].

Dezavantajul memoriei asociative Hopfield constă în aceea că, ea poate realiza asocieri A_c doar în limitele unei clase de obiecte, deoarece rețeaua nu poate modifica numărul parametrilor, genera sau lichida unii parametri neechivalenți x_k , ce descriu obiectul denaturat, mărimea vectorului de ieșire este egală cu mărimea vectorului de intrare. Prima asociere o vom numi asociere de nivelul întâi, cea de a doua – de nivelul doi. Reiesă că rețeaua dată realizează numai restabilirea propriu-zisă a imaginii și nu permite restabilirea imaginii după modelul creierului uman, adică, realizarea unui lanț de asocieri. De exemplu, un fragment muzical poate fi asociat cu întreaga operă muzicală, restabilire propriu-zisă, asocierea de nivelul întâi, iar opera muzicală la rândul său, poate fi asociată cu concertul la care ea a fost auzită pentru prima dată, asociere de nivelul doi, între clase de obiecte.

Problema pe care o rezolvă prezenta invenție este realizarea asocierilor între clase de obiecte.

Procesorul, conform primei variante a invenției, constă din memorie asociativă Hopfield. Noutatea constă în aceea că procesorul conține suplimentar o rețea neuronală Kohonen, intrările căreia sunt conectate cu ieșirile memoriei asociative Hopfield, astfel încât numărul de intrări ale rețelei neuronale Kohonen este egal cu numărul de ieșiri ale memoriei asociative Hopfield, și o memorie de tip von Neumann, intrările căreia sunt conectate cu ieșirile rețelei neuronale Kohonen.

Procesorul, conform variantei a doua invenției, constă din memorie asociativă Hopfield. Noutatea constă în aceea că procesorul conține suplimentar perceptroni esponderi în două straturi, numărul cărora

$$N_{per_es}=N_{as}-1, (1)$$

unde N_{as} este numărul asocierilor pentru realizare, intrările fiecărui perceptron esponder sunt conectate cu ieșirile perceptronului esponder anterior, primul perceptron esponder este conectat cu ieșirile memoriei asociative Hopfield, iar numărul de ieșiri ale fiecărui perceptron esponder este mai mare ca numărul lui de intrări și egal cu numărul de parametri ce descriu obiectul asociat.

Procesorul, conform variantei a treia invenției, constă din memorie asociativă Hopfield. Noutatea constă în aceea că procesorul conține suplimentar o succesiune de rețele perceptron esponder – memorie asociativă Hopfield, numărul cărora

$$N_{PE-MAH}=N_{as}-1, (2)$$

unde N_{as} este numărul asocierilor pentru realizare, intrările fiecărei rețele perceptron esponder – memorie asociativă Hopfield sunt conectate cu ieșirile rețelei perceptron esponder – memorie asociativă Hopfield anterioare, prima rețea perceptron esponder – memorie asociativă Hopfield este conectată cu ieșirile primei memorii asociative Hopfield, iar numărul de ieșiri ale fiecărei rețele perceptron esponder – memorie asociativă Hopfield este mai mare ca numărul ei de intrări și egal cu numărul de parametri ce descriu obiectul asociat.

Procesorul, conform variantei a patra invenției, constă din memorie asociativă Hopfield. Noutatea constă în aceea că procesorul conține suplimentar un perceptron compander, intrările căruia sunt conectate la ieșirile memoriei asociative Hopfield, numărul de intrări ale perceptronului compander este egal cu numărul de ieșiri ale memoriei asociative Hopfield, iar numărul de ieșiri ale perceptronului este mai mic ca numărul lui de intrări.

Rezultatul invenției constă în restabilirea și perceperea imaginilor.

Invenția se explică prin desenele din fig. 1...6, care reprezintă:

- fig. 1, rețea neuronală ce conține o memorie asociativă Hopfield, o rețea neuronală Kohonen și o memorie de tip von Neumann;
- fig. 2, rețea neuronală ce conține o memorie asociativă Hopfield și o succesiune de perceptroni esponder;
- fig. 3, rețea neuronală ce conține o memorie asociativă Hopfield și o succesiune de rețele perceptron esponder – memorie asociativă Hopfield;
- fig. 4, rețea neuronală ce conține o memorie asociativă Hopfield și un perceptron compander;
- fig. 5, exemplu de defectare a imaginii cinescopului;
- fig. 6, exemplu de asociere a mai multor obiecte cu un singur obiect.

Rețeaua neuronală din varianta I funcționează în modul următor. Memoria asociativă Hopfield 1 găsește asociația de nivelul întâi a obiectelor \tilde{x}^{ci} și x_c , de aceeași clasă $x_c = A_c(\tilde{x}^{ci})$, ceea ce semnifică că în procesul de restabilire a imaginii are loc corecția parametrilor echivalenți ai imaginii denaturate $\tilde{x}^{ci} = (\hat{x}_{ci1}, \hat{x}_{ci2}, \dots, \hat{x}_{cik})$, ce sunt aduse până la valorile ce corespund imaginii adevărate $x_c = (\hat{x}_{c1}, \hat{x}_{c2}, \dots, \hat{x}_{ck})$, unde $\hat{x}_{ci1} = \hat{x}_{c1}$, $\hat{x}_{ci2} = \hat{x}_{c2}, \dots, \hat{x}_{cik} = \hat{x}_{ck}$, adică, se înlătură defectele imaginii \tilde{x}^{ci} . În rețeaua neuronală Kohonen 2 neuronii concurează între ei, pentru dreptul de a reflecta cât mai reușit vectorul de intrare x_c (vectorul de ieșire al memoriei asociative Hopfield). Câștigă acel neuron, al cărui vector de ponderi v_{mk} este mai aproape de vectorul de intrare. Vectorul de ieșire al rețelei Kohonen:

$$y_k = x_c \cdot v_{mk} \quad (3)$$

- reprezintă codul ce corespunde adresei pe care se păstrează imaginea adevărată.

Vectorii imaginilor adevărate x_1, x_2, \dots, x_c ce conțin parametri echivalenți \hat{x}_k și neechivalenți x_k , se păstrează într-o memorie aparte de tip von Neumann 3, cu adresare după codul y_k format de rețeaua neuronală Kohonen. Astfel, rețeaua neuronală Kohonen găsește asociațiile de nivelul doi. Instruirea memoriei asociative Hopfield și a rețelei neuronale Kohonen se efectuează după metode cunoscute, luându-se în considerație faptul că, vectorii de ieșire ai memoriei asociative Hopfield reprezintă setul vectorilor de instruire pentru rețeaua neuronală Kohonen.

Exemplu. Punem următoarea sarcină: aplicând la intrările procesorului intelectual imaginea denaturată a cinescopului, la ieșire să obținem imaginea obiectului cărui îi aparține cinescopul dat, fie radar, televizor sau calculator (fig. 5). Instruim memoria asociativă Hopfield astfel ca să păstreze cele trei imagini (vectori de parametri) adevărate: a cinescopului de radar, de televizor și calculator, iar rețeaua neuronală Kohonen o instruiem astfel încât la aplicarea la intrările ei a uneia din cele trei imagini ale cinescopului, la ieșire să genereze un vector unical. Vectorul generat de rețeaua neuronală Kohonen reprezintă adresa pe care se păstrează imaginea adevărată (a radarului, televizorului sau calculatorului) în memoria von Neumann.

Dacă vom aplica la intrările memoriei asociative Hopfield imaginea denaturată a cinescopului de radar, la ieșirile memoriei asociative Hopfield vom obține imaginea adevărată a acestui cinescop. La rândul său, rețeaua neuronală Kohonen având la intrare imaginea cinescopului de radar, va genera la ieșire adresa pe care se păstrează imaginea adevărată a radarului, în memoria von Neumann, iar pe șina de date a memoriei von Neumann $d_1 \dots d_q$ vom obține imaginea însăși a radarului (vectorul de parametri al radarului).

Analog și în cazul aplicării la intrările procesorului intelectual a imaginii denaturate a cinescopului de calculator sau televizor. La ieșirile procesorului intelectual vom obține imaginea adevărată a calculatorului sau televizorului.

Varianta dată a procesorului intelectual realizează asocieri de desfășurare – când un obiect poate fi asociat cu mai multe obiecte.

Rețeaua neuronală din varianta II funcționează în modul următor. Memoria asociativă Hopfield 1 pentru obiectul denaturat, de exemplu de clasa întâi \tilde{x}^{1i} , găsește obiectul adevărat x_1 din această clasă (asociație de nivelul întâi), iar perceptronul instruit 4, cu structură în două straturi, prin generarea proprietăților suplimentare ale obiectului x_1 , generează un nou obiect asociat, adevărat, de altă clasă, de exemplu, de clasa a doua x_2 (asociație de nivelul doi).

Obiectul de clasa doi x_2 , apare datorită generării pe baza vectorului de parametri echivalenți \hat{x}_k , ce descriu obiectul asociat x_1 (de la ieșirea memoriei asociative Hopfield), a vectorului de parametri neechivalenți x_k . Atunci, obiectul de a doua clasă x_2 , determinat de P parametri, este descris de vectorul de ieșire al primului perceptron $\hat{x}_p = \hat{x}_k + x_k$. Astfel, perceptronul în două straturi îndeplinește funcția de expander al proprietăților obiectelor.

Pentru găsirea următorului obiect asociat, adevărat, este nevoie de un perceptron expander suplimentar 5. Pentru

găsirea obiectului asociat, adevărat, de clasa C x_c , descris de R parametri $\hat{x}_r = \hat{x}_p + x_p$ (asociație de nivelul C), avem nevoie de c-1 perceptroni expanderi. În perceptron, ca funcție de activare a fiecărui neuron g poate fi aleasă funcția sigmoidală sau funcția tangentei hiperbolice. Instruirea memoriei asociative Hopfield și a perceptronilor expanderi se efectuează după metode cunoscute, luându-se în considerație faptul că, setul vectorilor de instruire pentru primul perceptron expander 4 constă din vectorii de ieșire x_1, x_2, \dots, x_c ai memoriei asociative Hopfield 1, ce reprezintă asociații de nivelul întâi, și un vector etalon, ce reprezintă imaginea asociată, adevărată, de nivelul doi. Astfel, primul perceptron expander memorizează imaginile asociate adevărate de nivelul doi sub formă de vector de ponderi $v_c = (v_{11}, v_{12}, \dots, v_{pk})$. La instruirea fiecărui următor perceptron expander c, setul vectorilor de instruire constă din vectorii de ieșire ai perceptronului expander anterior c-1, și imaginea etalon, ce reprezintă imaginea asociată adevărată de nivelul c. Astfel, fiecare al c-lea perceptron expander memorizează imaginile asociate adevărate de nivelul c sub formă de vector de coeficienți de ponderi $e_c = (e_{11}, e_{12}, \dots, e_{rp})$. Toți perceptronii expanderi sunt instruiți astfel ca să găsească asociații între obiecte de diferite clase, adică, exercită funcția memoriei asociative.

Exemplu. Examinăm sarcina de sus și pentru varianta dată a procesorului intelectual de restabilire a imaginii.

Instruim memoria asociativă Hopfield astfel ca să păstreze cele trei imagini (vectori de parametri) adevărate: a cinescopului de radar, de televizor și de calculator.

Determinăm numărul necesar de perceptroni expanderi. În cazul dat avem un lanț de două asocieri:

cinescop denaturat ->cinescop adevărat

cinescop adevărat -> radar, televizor sau calculator

Conform relației 1, numărul necesar de perceptroni espanderi este:

$$N_{per\ es} = N_{as} - 1 = 2 - 1 = 1 \quad (4)$$

Perceptronul espander îl instruiem astfel ca pentru vectorul de parametri adevărat a cinescopului de radar, televizor sau calculator să generează la ieșiri un vector ce conține și parametri noi, neechivalenți, ce caracterizează însăși radarul, televizorul sau calculatorul, adică să genereze la ieșiri imaginea adevărată a radarului, televizorului sau calculatorului.

Aplicând la intrările memoriei asociative Hopfield imaginea denaturată a cinescopului de radar, la ieșirile memoriei asociative Hopfield vom obține imaginea adevărată a acestui cinescop. La rândul său, perceptronul espander va genera la ieșire un vector de parametri ce conține și parametri noi, neechivalenți, ce caracterizează radarul, adică, imaginea adevărată a radarului.

Analog și în cazul aplicării la intrările procesorului intelectual a imaginii denaturate a cinescopului de calculator sau televizor. La ieșirile procesorului intelectual vom obține imaginea adevărată a calculatorului sau televizorului. Varianta dată a procesorului intelectual realizează asocieri de desfășurare.

Rețeaua neuronală din varianta III funcționează în același mod ca și rețeaua neuronală din varianta II, deosebirea constând în faptul că, pentru instruirea fiecărui perceptron espander în calitate de obiect etalon nu este neapărată utilizarea imaginii adevărate a obiectului, este suficientă doar imaginea lui apropiată, adică, o imagine denaturată a clasei date de obiecte, deoarece, memoria asociativă Hopfield 6, fiind instruită, este aptă să genereze la ieșire imaginea adevărată pentru imaginea denaturată aplicată la intrare.

Exemplu. Examinăm sarcina de sus și pentru varianta dată a procesorului intelectual de restabilire a imaginii.

Instruim memoria asociativă Hopfield astfel ca să păstreze cele trei imagini (vectori de parametri) adevărate: a cinescopului de radar, de televizor și de calculator.

Determinăm numărul necesar de rețele perceptron espander – memorie asociativă Hopfield. În cazul dat avem un lanț din două asocieri:

cinescop denaturat -> cinescop adevărat

cinescop adevărat -> radar, televizor sau calculator

Conform relației 2, numărul necesar de perceptroni espanderi este:

$$N_{PE_MAN} = N_{as} - 1 = 2 - 1 = 1 \quad (5)$$

La instruirea perceptronului espander ținem cont de faptul că, în calitate de obiect etalon nu e neapărată utilizarea imaginii adevărate a obiectului, ci e destulă doar imaginea lui apropiată, adică, o imagine denaturată a clasei date de obiecte.

Memoria asociativă Hopfield ce urmează după perceptronul espander o instruiem astfel ca să păstreze imaginea adevărată a radarului, televizorului și calculatorului.

Aplicând la intrările procesorului intelectual, adică, a memoriei asociative Hopfield imaginea denaturată a cinescopului, la ieșirile ei vom obține imaginea adevărată a acestui cinescop. La rândul său, perceptronul espander va genera la ieșire un vector de parametri denaturat, ce conține și parametri noi, neechivalenți, ce caracterizează radarul, adică, imaginea denaturată a radarului. Imaginea obținută este denaturată deoarece la instruirea perceptronului espander în calitate de imagini etalon s-au folosit imagini denaturate. La rândul său, memoria asociativă Hopfield, ce urmează după perceptronul espander, având la intrări imaginea denaturată a radarului, va genera la ieșire imaginea lui adevărată.

Analog și în cazul aplicării la intrările procesorului intelectual a imaginii denaturate a cinescopului de calculator sau televizor. La ieșirile procesorului intelectual vom obține imaginea adevărată a calculatorului sau televizorului. Acest procesor intelectual realizează asocieri de desfășurare.

Rețeaua neuronală din varianta IV funcționează în modul următor. Memoria asociativă Hopfield 1 pentru obiectul

denaturat, de exemplu de clasa întâi \tilde{x}_{1i}^1 , găsește obiectul adevărat x_1 din această clasă (asociație de nivelul întâi),

iar perceptronul compander 7, cu structură în două straturi, prin lichidarea unor parametri \hat{x}'_k din vectorul de

parametri echivalenți \hat{x}_k , generează la ieșire obiectul asociat adevărat (asociație de nivelul doi). Obiectul asociat adevărat, generat la ieșirile perceptronului compander, determinat de P parametri, $P < K$, este descris de vectorul de

parametri echivalenți $\hat{x}_p = \hat{x}_k - \hat{x}'_k$. Astfel, perceptronul în două straturi îndeplinește funcția de compander al

parametrilor obiectelor. Instruirea memoriei asociative Hopfield și a perceptronului compander se efectuează după metode cunoscute, luându-se în considerație faptul că, setul vectorilor de instruire pentru perceptronul compander 6 constă din vectorii de ieșire ai memoriei asociative Hopfield 1, ce reprezintă asociații de nivelul întâi, și un vector etalon, ce reprezintă imaginea asociată, adevărată, de nivelul doi.

Exemplu. Fie că, este necesar de a realiza următoarea asociație de înfășurare (când mai multe obiecte sunt asociate cu un singur obiect):

Cameră video denaturată -> televizor

Antenă denaturată - > televizor

Antenă parabolică denaturată - > televizor

adică, de a realiza asocieri direcționate spre un obiect, în cazul nostru – televizorul (fig. 6).

Memoria asociativă o instruiem astfel ca să păstreze imaginea adevărată a camerei video, a antenei, și a antenei parabolice, iar perceptronul compander prin lichidarea unor parametri din vectorul de parametri echivalenți îl instruiem să genereze la ieșire obiectul asociat adevărat – imaginea televizorului.

Aplicând la intrările procesorului intelectual imaginea denaturată a camerei video, la ieșirile memoriei asociative Hopfield vom obține imaginea ei adevărată. La rândul său, perceptronul compander lichidând unii parametri echivalenți va genera la ieșire imaginea televizorului. Analog și în cazul aplicării la intrările procesorului intelectual a imaginii denaturate a antenei sau antenei parabolice. Procesorul intelectual va genera la ieșire imaginea adevărată a televizorului.