

## A MESTERSÉGES NEURONHÁLÓZATOK BEVEZETÉSE AZ OKTATÁSBA A GAMF-ON

*Pintér István, pinter@gandalf.gamf.hu*

*Nagy Zoltán*

*Gépipari és Automatizálási Műszaki Főiskola, Informatika Tanszék*

*Gépipari és Automatizálási Műszaki Főiskola, végzős informatika szakos hallgató*

### Abstract

In this paper our results in teaching of the artificial neural networks (ANN) are given. After a short introduction the ANNs and the pattern recognition framework are summarized and the concepts used are defined. The educational results in single layer perceptron and multi layer perceptron (MLP) algorithms are discussed and the comparison of a new MLP-based algorithm and the MLP itself is given by illustrations in some well-known classification problems. The Hamming-MAXNET system is summarized succinctly, and finally a new direction, the wavelet-neural network is mentioned.

### 1. Bevezető gondolatok, eredmények

A hazai felsőfokú intézményekben, így főiskolánkon is jól bevált módszer az új tananyagok "kipróbálása" fakultatív tantárgy vagy speciális kollégium formájában. Különösen fontos ez olyan témakörök oktatásba vitelénél, amelyeknek nincs elegendő, publikált, főiskolai szintű oktatási előzménye – ilyen új terület a mesterséges neuronhálózatok oktatása is. Véleményünk szerint ennek főiskolai szintű oktatása indokolt: nemcsak azért, mert sok új műszaki rendszer "működési elve" itt keresendő [1], hanem azért is, mert "a tanítvány nem edény, amit meg kell tölteni, hanem fáklya, amit lánggra kell lobbantani". A speciális kollégium meghirdetésének legfőbb konkrét motivációja az új informatika szakos tantervünk volt – nevezetesen ennek "Ismeretalapú rendszerek" tantárgya, melynek e témakör egy részét jelenti –, ám fontos szerepet játszottak a szóban forgó tudományterület letisztult, hozzáférhető (részben hazai) eredményei is. A témakör a "Jelfelismerés" speciális kollégium tananyagában szerepelt, melyet 1994 -95-ben tartottunk érdeklődő másodéves hallgatóinknak. Az évfolyam megválasztásának oka az volt, hogy a nyári hallgatói termelési gyakorlat ideje is rendelkezésre álljon a tanultak begyakorlására, illetve a C programok megírására (főiskolánkon a képzési idő 3 év).

A neuronhálózatok modellezésének problémájával egyikünk (Pintér) először 1984-ben találkozott egy lebilincselő előadás formájában [2]. Bár helyesnek tartjuk élesen különválasztani a valóságos neuronok matematikai modellezését a mesterséges neuronhálózat-modellek műszaki alkalmazásától, a fenti előadás szemléletünket alapvetően befolyásolta (amit erősített egy későbbi előadás is [3]). A speciális kollégium anyagát ennek a hozzáállásnak megfelelően a [4] cikke és az [5] könyvre alapoztuk. Időközben megjelent a témakör átfogó

magyar nyelvű jegyzete is [6] – ez sajnos még nem állt rendelkezésünkre. Tanszékünkön eddig a következő részterületek oktatására került sor: egyrétegű perceptron hálózat, többretegű perceptron hálózat (MLP), az MLP algoritmus különféle módosított változatai, a Hamming- és MAXNET hálózat. A tanultak eredményeképp jól működő, a hallgatók által írt programok születtek, amelyeket módunk volt a "GERENIA" nevű, pályázaton elnyert fejlesztő rendszer osztályozási képességével is összehasonlítani [7],[8].

## 2. A jelfelismerési feladat és a mesterséges neuronhálózat

A jelfelismerés során a *bemenő adatok* (alakzatok, pattern) alapján azt kell meghatározni, hogy azok mely *osztályból* származnak. Ezt a feladatot az *osztályozó rendszer* végzi el, ami e képességét a *tanulási folyamat* során éri el; ehhez a *tanítóval történő tanulás* során (supervised learning) elegendő számú *reprezentáns* (prototípus) áll rendelkezésre minden, *előre ismert osztályból*, a *tanító nélküli tanulás* (unsupervised learning) során az osztályok megalkotása is feladat a tanulás során. A tanulás után következik a tanultak "felidézése" és "alkalmazása", vagyis elvárjuk, hogy a rendszer egy számára eddig még ismeretlen bemenő alakzatot is a lehető legkisebb tévesztési aránnyal osztályozzon. Kézenfekvő hazai példa ilyen rendszerre a Recognita OCR szoftver, amely egy képolvasó eszközből nyert adatok alapján eldönti, hogy a vizsgált képrész szöveg-e vagy ábra, és pl. a szöveg esetén további döntést hoz a karakterek kódjáról és attribútumairól. Ha az osztályozó feladata valamely mért jel alapján történő osztályba sorolás, akkor kritikus lehet a – konkrét feladattól függő – *jelreprezentáció* : ebből lehet további transzformációkkal a *lényegkiemelés* (feature extraction) során az osztályozó betanításához – és ezután a "működtetéséhez" – szükséges *lényegvektorokat* előállítani. Ebben az értelemben tehát elválasztható a jelreprezentáció és a lényegkiemelés problémája az osztályozási feladattól. A gyakorlati tapasztalatok azt mutatják, hogy sok feladat megoldható az imént vázolt módszerrel; a fentebbi példa esetében pl. a lényegkiemelés ún. kontúrelemzésen alapszik [9].

A fentiek miatt a speciális kollégium során a tárgyalt mesterséges neuronhálózatokat (MNH) egyszerűen osztályozóknak tekintettük (ez a hivatkozott jegyzetben megadott 5 felhasználási terület egyike). A tárgyalt eseteknek megfelelő MNH szorosan összekapcsolt, elemi műveletvégző egységekből (csomópontokból) felépített, rétegekbe szervezett rendszer. Egy csomópont skaláris szorzás, kivonás és nemlineáris leképezés műveletek elvégzésére képes több bemenetű, egy kimenetű részrendszer; a csomópont aktív, ha az  $y$  kimenet "nagy":

$$y = f\left(\sum_{i=0}^{N-1} w_i x_i - J\right), \text{ ahol } x_i \text{ a bemenő lényegvektor } i\text{-edik komponense, } w_i \text{ az ehhez rendelt}$$

*súlytényező*,  $J$  a *küszöbérték*,  $f(\cdot)$  a *nemlineáris leképezés* (tipikusan vagy előjel-függvény jellegű, vagy lineáris, de telítésszerű jellegű, vagy szigmoid jellegű). A tanítás a súlytényezők *iteratív beállítása* át jelenti; az iterációnkénti súlytényező-módosítást a tanító algoritmus adja meg. Felfoghatjuk ezt úgy is, hogy a MNH "tudását" a súlytényezőkbe "sulykoljuk".


Ezekből a csomópontokból, mint rész-rendszerekből rétegekbe szervezéssel alakíthatunk ki nagyobb rendszert; ekkor a bemenő vektor komponensei az első (rejtett) rétegbe futnak, e réteg kimenetei alkotják a következő rejtett réteg bemeneteit s. í. t. amíg a kimeneti rétegbe nem érünk: ennek feladata már a kívánt osztályhoz rendelt kód előállítása (pl. ez épp annyi

csomópontot tartalmaz, ahány osztály van, s ezek közül csak egy aktív kimenetű: épp az, amelyhez tartozó osztályba sorolja a MNH a "bemutatott" lényegvektort). A súlytényezők beállítására a konkrét elrendezéstől függő algoritmusokat lehet előállítani.


### 3. Egyrétegű és többrétegű perceptron hálózat (MLP)

Először az *egyrétegű perceptron* hálózatot tárgyaltuk, mivel ezen jól bemutatható a bonyolultabb MLP tanulóalgoritmus levezetése során használt apparátus. Ehhez bevezettük az *ismeretmátrix* segédfogalmat: ez a  $M$  osztályba tartozó, osztályonként  $L$  prototípus alakzatot és alakzatonként  $N$  komponensű lényegvektort tartalmazó  $ML \times N$ -es mátrix. Adott ezen kívül minden prototípus alakzat esetén a *célértékvektor* is, aminek  $j$ -edik komponense a  $j$ -edik kimeneti csomópont aktivitása az egyes bemutatott bemenő vektorok esetén; így a kimeneti réteg csomópontjaira *kritériumfüggvényt* lehet definiálni, aminek extrémumát keresve adódik a tanító algoritmus. A tanító algoritmust két lépésben kaptuk meg: először a tényleges és az elvárt kimenetek különbségeinek négyzetösszegét minimalizáló eljárást elemeztük a gradiens módszer használata mellett és nem vettük figyelembe a kimeneti signum-típusú nemlinearitást (levezetésünk nem tér el lényegesen az itt is hivatkozott szakirodalomban olvashatóktól, ezért nem részletezzük). A kapott összefüggésben ezután figyelembe vettük, hogy itt a kimenő érték csak  $\pm 1$  lehet, így adódott az egyszerű, ismert alak. Megjegyezzük azonban, hogy – bár az egyrétegű perceptron csak lineárisan szeparálható esetben jó, és pl. már az ún. XOR problémát sem tudja megoldani – nagyon hasznos volt részletesen végigvizsgálni, mivel a felhasznált fogalmak és a levezetés módszere hasonló a többrétegű perceptron esetéhez, tehát ott már csak a valóban új gondolatokra illetve fogásokra kellett figyelni. Érdekes észrevétel az is, hogy bár a szakirodalom nem tér ki részletesen a küszöbérték iterációjának problémájára, ez nagyon fontos része az algoritmusnak (legalábbis csak ennek helyes tanítása során tudtuk visszakapni a szakirodalmi ábrákat ill. eredményeket). A MLP hálózat tanító algoritmusának levezetése során ugyanazt a fogalomrendszert lehetett használni, mint az egyrétegű esetben, de itt új elemként megjelenik a kimeneti nemlinearitást jelentő függvény deriváltja is. Az MLP algoritmus eleganciájának okaként azt jelöltük meg, hogy e derivált egyszerűen előállítható magából a függvényből, s erre két tipikus nemlinearitás is található: a logisztikus leképezés (szigmoid függvény) illetve a  $th(.)$  függvény. A megírt programokkal szerzett tapasztalatok szerint jobb eredmény érhető el az utóbbival. Itt is jelentkezett a küszöbérték iterációjával kapcsolatos probléma: a legjobbnak az XOR probléma vizsgálata alapján az bizonyult, amikor a küszöbértékeket egy tanítási ciklus után módosítottuk (tanítási ciklus alatt az ismeretmátrix egyszeri teljes bemutatását értjük, az ábrák 200 tanítási ciklussal készültek 1.1., 1.2., 1.3. ábrák).


Ezután következhetett a MLP algoritmus részletes vizsgálata különféle 2D osztály-elrendezésekre. A 2. ábra a MLP algoritmust mutatja az XOR probléma tanulása közben: látható a hibafüggvény alakulása és két kiragadott állapot képe az osztályokkal és a diszkriminancia függvényvel, a 3. ábra esetén ez a SAKK problémán követhető.



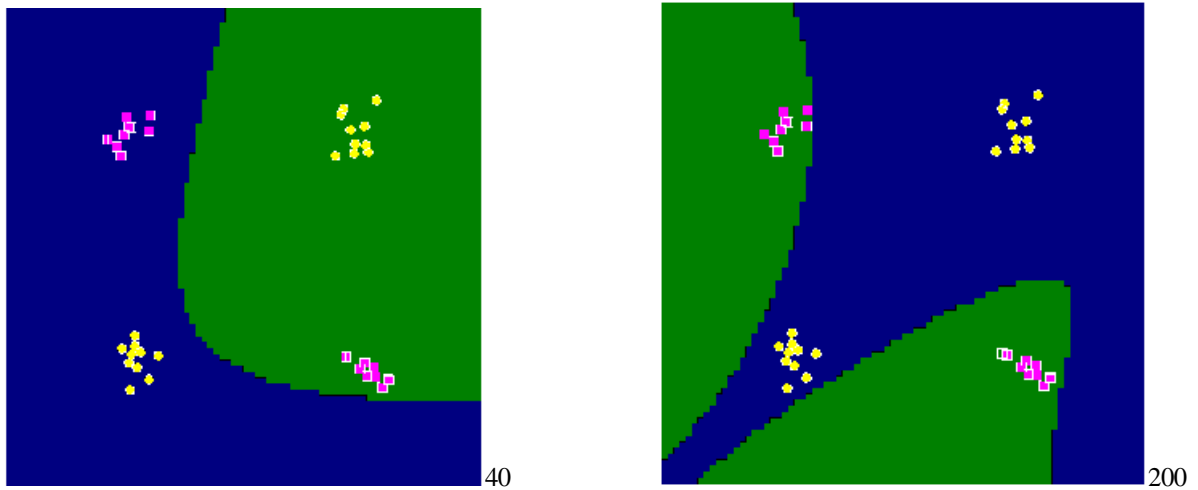
1.1 ábra.  
Az XOR probléma tanítása a küszöbértékek módosítása nélkül (MLP).



1.2 ábra.  
Az XOR probléma tanítása a küszöbértékek cikluson kívüli módosításával (MLP).




1.3 ábra.  
Az XOR probléma tanítása a küszöbérték cikluson belüli módosításával (MLP).



2. ábra.

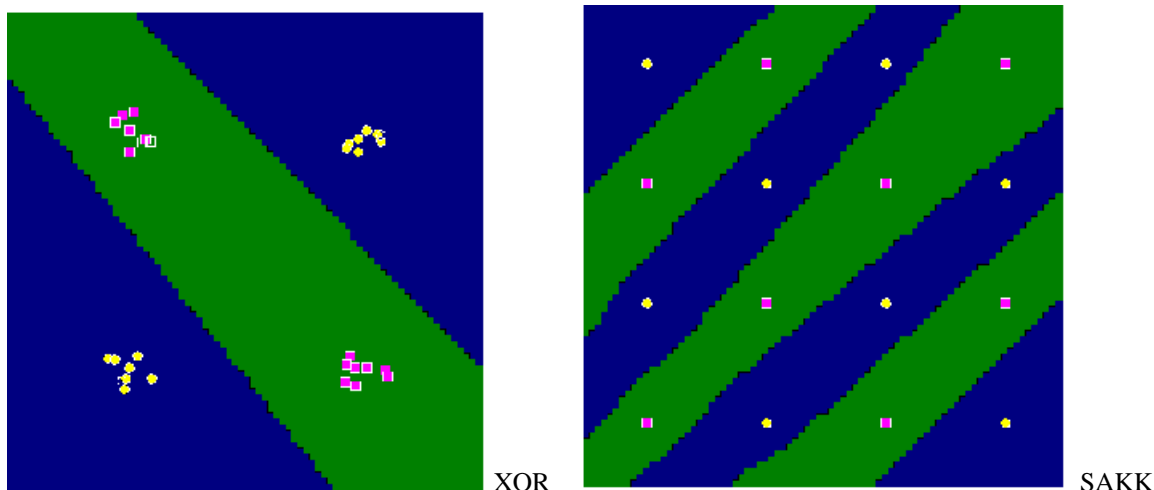
A MLP és az XOR probléma (40 ill. 200 iteráció után).



3. ábra.

A MLP és a SAKK probléma

A tapasztalatok birtokában egyikünk (Nagy) kidolgozott egy módosított MLP algoritmust, amivel ezek a problémák (is) pontosabban oldhatók meg (4. ábra).



4.ábra.

A módosított MLP algoritmus eredménye.

#### 4. A Hamming- és a MAXNET hálózat

Vizsgálatainkban az egyrétegű Hamming-hálózat *asszociatív memória*ként szolgált: ismert, ideális alakzatokra (ezek  $\pm 1$  értékű elemekből álló  $16 \times 16$ -os képek, amiket a hálózat tárol) kellett a hálózatnak a bemutatott, zajos bemenet alapján "asszociálnia". A hálózat először kiszámítja a bemutatott alakzat és prototípus alakzatok Hamming-távolságának és a maximális Hamming-távolságnak az eltérését:

$$\frac{1}{N} \sum_{i=1}^N |x_i - p_i|, \text{ ahol } N \text{ az alakzatok elemi jeleinek számát (esetünkben 256), a}$$

Hamming-távolságot,  $p_i$  egy prototípus-alakzat egy elemi jelét,  $x_i$  pedig a bemutatott alakzat (feladat-alakzat) egy elemi jelét jelöli. Ezt úgy is értelmezhetjük, hogy az egyes ismert ideális képeknek egy-egy neuron felel meg, amelyek küszöbértéke  $N/2$ , az egyes súlytényezők értéke pedig  $1/N$ . A Hamming-távolság meghatározása után a *maximális értékű kimenet* meghatározása következik; ezt a feladatot végzi el a *MAXNET hálózat*. Ez a Hamming-hálózatra épülő egyrétegű hálózat, amelynek csomópontjai az *oldalirányú gátlás* révén kapcsolódnak egymáshoz: egy csomópont a többi azonos  $0 < e < 1$  értékkel gátolja, s a döntést az alábbi iteráció után kapjuk:

$$x_i = \max_j \{ w_{ij} - e \sum_{k \neq i} x_k \}, \text{ ahol } f(.) \text{ a lineáris,}$$

telítéses nemlinearitás. A "zajt" egyenletes eloszlású álvéletlenszám-generátorral állítottuk elő az egyes elemi jelek ellentettbe forgatásával; a döntéshez szükséges iterációs szám gátlástól való függését vizsgáltuk. A Hamming-hálózattal kapcsolatban a kutatás jelenleg is élénk [10].

#### 5. Wavelet-neuronhálózatok

Jelenlegi vizsgálataink a wavelet-neuronhálózatokkal kapcsolatosak. A wavelet-analízis a jelfeldolgozás új eszközeinek számít; munkánk során beszédfeldolgozási feladatokra dolgoztunk ki új, wavelet-alapú módszereket [11]. A neuronhálózatos megközelítést az kínálja,

hogy egy jelet waveletek segítségével így közelíthetünk:  $\hat{x} = \sum_{k=1}^K w_k \phi_k$ , ahol  $K$  a

waveletek száma,  $w_k$  a súlytényezőknek felel meg,  $b_k$  és  $a_k$  pedig az adott waveletnek megfelelő eltolási érték ill. skálatényező. Ebben az esetben tehát a  $t$  pontbeli *approximáció* ról van szó: a  $t$  bemenet esetén szeretnénk megkapni a jel közelítő értékét e pontban. A  $w_k$ ,  $b_k$  és  $a_k$  paraméterek ismét a kimeneti hibanégyzet minimalizálásával kaphatók meg. Természetesen osztályozó elrendezés is konstruálható [12].

## 6.Összefoglalás

A dolgozatban közölt gyakorlati eredményeink alapján megállapítható, hogy a mesterséges neuronhálózatok oktatása lehetséges főiskolánkon. Kitértünk jelenlegi vizsgálatainkra is.

## Irodalomjegyzék

- [1] Neuralogix: NLX420 NSP (Neural Processor Slice) Data Sheet, 1992.
- [2] Lábos E.: A neuronális és neuronhálózati tevékenység szimulációjának néhány problémája. MTA KKP-3 Tudományos ülészak. Budapest, 1984. márc. 13-14.
- [3] Lábos E.: Mesterséges neuronhálózatok - state of the art. HTE előadás. Budapest, 1994. 05. 02.
- [4] Lippmann, R. P.: An introduction to computing with neural nets. IEEE ASSP Magazine, April 1987, pp. 4-22.
- [5] Pao, Y. H.: Adaptive Pattern Recognition. Academic Press, 1989.
- [6] Horváth Gábor szerk.: Neurális hálózatok és műszaki alkalmazásaik. Műegyetemi Kiadó, 1995.
- [7] Nagy Z.: Nyári szakmai gyakorlati feladat. GAMF Informatika Tanszék, 1995.
- [8] Hízsnay G.: Nyári szakmai gyakorlati feladat. GAMF Informatika Tanszék, 1995.
- [9] Marosi István személyes közlése.
- [10] Meilijson, I, Ruppín, E., Sipper, M.: A single-iteration threshold Hamming Network. IEEE Trans. on Neural Network, January 1995. pp. 261 - 266.
- [11] Pintér, I.: Perceptual wavelet representation of speech signals and its application to speech enhancement. Computer Speech and Language, Vol. 10. No. 1. 1996. pp. 1-22.
- [12] Szu, H., H., Telfer, B., Kadambe, S.: Neural network adaptive wavelets for signal representation and classification. Optical Engineering, September 1992, pp. 1907-1916.