

**GRÖBLER TAMÁS**

*MTA KFKI Részecske- és Magfizikai Kutatóintézet Biofizikai Osztály,  
Budapest*

## **TANULÁS BIOLÓGIAI ÉS MESTERSÉGES HÁLÓZATOKON**

### **BEVEZETÉS**

Azt az elképzelést, amely szerint a tanulás agyi folyamatának alapja a szinapszisok (a neuronok közötti specializált kapcsolatok) időbeli módosulása, mintegy száz éve fogalmazták meg (TANZI, 1893). Azóta e hipotézist számosan finomították (például RAMÓN Y CAJAL, 1909; WOOD-JONES és PORTEUS, 1928), de kétségtelen, hogy a legtovább ható formába HEBB (1949) öntötte. Az idegtudomány fő áramlata ma is ezt a feltevést tekinti úgy, mint a tanulás idegi folyamatainak kiindulópontját.

Ugyanakkor a szinaptikus plaszticitás biofizikai mechanizmusának részleteiről egészen a legutóbbi évtizedekig szinte semmit sem tudtak. A biológiai részletek ismeretének hiánya tág teret engedett az elméletet mennyiségi részletekkel kitöltő *tanulóalgoritmusok* létrejöttének. Miután az idegsejt formális modellje már megszületett (McCULLOCH és PITTS, 1943), a formális idegsejtekből álló hálózatokon (*a mesterséges neuronhálózatokon, ANN*) való tanulás különféle formáinak tanulmányozására új tudományág jött létre, a *konnekcionizmus*. A konnekcionizmus meghatározó elve éppen a fenti hipotézis, vagyis az, hogy az ismeretek tárolása a hálózat egyszerű elemei (a neuronok) közötti bonyolult kapcsolatrendszerben (a szinapszisokban) történik, a tanulás pedig e kapcsolatok módosulása. A konnekcionista modellek ezen a kereten belül *tetszőleges* algoritmusokkal próbálkozhatnak, céljuk nem a tanulás biológiai mechanizmusának megértése, hanem hatékony, „intelligens” algoritmusok létrehozása.

A modellek egy másik osztálya a biológiai realitás által megszabott keretek között maradva próbál tanulási feladatokat megoldani. A Hebb nevéhez fűződő feltevés további finomításának új lendületet adott az elmúlt húsz év biológiai áttörése, hiszen a hippocampusban sikerült egyes szinapszisok hatékonyságának hosszú távú növekedését (*long term potentiation, LTP*) kimutatni (BLISS és LØMO, 1973). Az LTP egyik formája, az asszociatív LTP lényegében Hebb-típusú szinapszis-módosulásnak tekinthető, és valószínűleg lényeges szerepet játszik bizonyos típusú tanulási folyamatokban (KELSO és BROWN, 1986). A kisagyban megtalálták az LTP ellentétét, a szinapszisok hosszú távú gyengülését (*long term depression, LTD*) is (ITO, 1984). Az LTD lehet homoszinaptikus vagy *heteroszínaptikus* attól függően, hogy az ingerelt szinapszisban jön létre, vagy a posztzinaptikus sejt egy másik szinapszisában.

## TANULÁS ÉS IDEGRENDSZERI MODELLEK: MECHANIZMUSOK ÉS ALGORITMOSOK

### Hálózatképződés és -módosulás

A neuronok közötti kapcsolatok megváltozásának, vagyis az idegrendszer *plaszticitásának* különböző formái lehetségesek:

Az egyedfejlődés során az idegsejtek nyúlványainak növekedése határozza meg azt a hálózati struktúrát, amely a későbbiekben az idegrendszer megfelelő működését biztosítja (ontogenezis).

Ha a kialakult hálózat valamilyen okból károsodik vagy egy terület működése kiesik, az idegsejtek nyúlványaik átrendezésével képesek lehetnek a kieső funkciók részleges pótlására (regeneratív plaszticitás).

A változatlan hálózati struktúrában egyes szinaptikus kapcsolatok hatékonysága változik meg, ami a további működést módosítja (tanulás).

Mindhárom jelenséget dinamikus folyamatnak kell tekintenünk, és általában hasonló megközelítéssel tárgyalhatjuk őket. A legtöbbször azzal a feltételezéssel élhetünk, hogy a kapcsolatok módosulása *önszervező* módon történik (*self-organization*), vagyis nem egy meghatározott cél irányítja a változást, hanem a külső környezet és a hálózat állapota éppen olyan változást hoz létre, amely valamilyen szempontból előnyösebb működést tesz lehetővé.

*Ontogenezis.* Az egyedfejlődés problémájának két szélsőséges megközelítése lehet: Az egyik szerint a hálózat szerkezete genetikailag előre

meghatározott, a másik megközelítés pedig kizárólag a kapcsolatok használatfüggő kialakulását hangsúlyozza, a rendszer aktivitását tekinti alapvetőnek a struktúra létrejötte szempontjából. A kizárólag genetikai meghatározottság elvethető azzal a megfontolással, hogy a hálózat összes kapcsolatát kódoló információ meghaladná a DNS teljes információtartalmát. Áthidaló megoldást kínál a szelektív stabilizációs feltevés (CHANGEUX és DANCHIN, 1976), amely a genetikai információ szempontjából takarékos mechanizmust tételez fel a hálózat kialakulására.

Az idegrendszeri egyedfejlődés vizsgálatának jelentős része a látókéregre koncentrált. Az agykéreg moduláris felépítésének (SZENTÁGOTHAI, 1983) jellemző példája a látókérgi *okuláris dominancia (OD)* oszlopok léte (HUBEL és WIESEL, 1962). Sikerült kimutatni a spontán működés döntő szerepét is az OD kialakulásában (STRYKER és HARRIS, 1986). GOODHILL (1992) az OD kialakulásának ontogenetikus modelljeit foglalta össze. A szinaptikus módosulásra vonatkozó szabályt véletlen zajjal kiegészítő modell (ÉRDI és BARNA, 1984; BARNA és ÉRDI, 1986) az axonnövekedés topografikus rendezettségét (retinotópia) és az OD kialakulását egyszerre írja le. Ez az egyedfejlődési modell a szinapszisok helyi együttműködésén és egészleges versengésükön alapszik.

*Regeneratív mechanizmusok.* Az idegsejtek közötti kapcsolatrendszer a felnőtt agyban is módosulhat. Szinapszisok megszűnésének számos oka lehet, pl. sejtpusztulás, az axon visszahúzódása, eltávolodása, illetve sérülés. Mivel új idegsejtek nem keletkeznek, egyedül a meglévő sejtek nyúlványainak átrendeződése hozhatja helyre a károsodást. A leglátványosabb szerkezeti változások sérülések nyomán következnek be. Feltételezhető, hogy az idegsejtek aktivitásának döntő szerepe van az idegrendszeri rugalmasság e regeneratív formájában is (részletesen lásd Kovács Ilona, ugyanitt).

*Tanulás.* Az idegrendszer különböző részein az egyes agyterületekre jellemző, sajátos tanulási mechanizmusokat találtak. Mivel ez a dolgozat inkább a hálózati tanulás közös vonásait foglalja össze, itt csak utalok GLUCK és GRANGER (1993) tanulmányára, amely három agyterület, a szaglórendszer, a kisagykéreg és a hippocampus tanulási mechanizmusait hasonlítja össze. Gluck és Granger a szaglórendszer tanulási mechanizmusait alulról felfelé (*bottom up*) építkezve, a sejt szintű biofizikai folyamatokból kiindulva vizsgálja. A kisagy esetében azonban éppen fordítva, egyes konnekcionalista tanulási algoritmusoktól próbálnak eljutni a biológiai részletekig (*top down* megközelítés). A hippocampus vizsgálatok a *bottom up* és a *top down* tárgyalásmódot hasonlítják össze.

A különbségek ellenére minden esetben feltűnik a tanulás hebbi hipotézise, amely szerint a szinapszis hatékonyságának változását is a szinapszisban részt vevő idegsejtek működése határozza meg (HEBB, 1949).

„Ha az A sejt axonja elég közel van a B sejthez, és ismétlődően vagy folyamatosan hozzájárul annak tüzeléséhez, akkor valemely, egyik vagy mindkét sejtre jellemző növekedési folyamat vagy metabolikus változás következménye az lesz, hogy az A sejt hatékonysága a B sejt tüzeléséhez való hozzájárulás szempontjából megnő.”

Igen hasonló a hippocampusban megfigyelt LTP asszociatív típusának mechanizmusa is. Eszerint ha egy (B) sejtet egy erős szinaptikus bemenetén keresztül erős ingerrel aktiválunk és egyidejűleg egy másik, gyenge szinaptikus bemenetén (A) keresztül is kap ingert, akkor ez a gyenge szinapszis hatékonyabbá válik. Asszociatív LTP tehát nem jön létre, ha csak az egyik sejt működik, vagy ha a két sejt nagyon különböző időben válik aktívvá.

#### A Hebb-típusú tanulás alapjai

A fentiek alapján meghatározhatjuk az asszociatív LTP-vel összhangban álló Hebb-típusú tanulás ismérveit. BROWN és munkatársai (1990) meghatározása szerint a Hebb-típusú szinapszis hatékonysága *lokális, interaktív és időzített* folyamat során növekszik. Ez részletesebben azt jelenti, hogy (i) a szinapszis módosulásában csak a pre- és a posztzinaptikus sejt működése játszik szerepet, (ii) a szinaptikus változáshoz csak ez a két sejt szükséges és (iii) a két sejt aktivitása időben összehangolt kell hogy legyen.

HEBB (1949) nem tárgyalta azt az esetet, amikor a pre- és posztzinaptikus sejt aktivitása korrelálatlan vagy negatív együttjárást mutat. A Hebb-típusú szinapszis fogalmát STENT (1973) úgy terjesztette ki, hogy a szinaptikus kapcsolatban álló két sejt nem egyidejű aktivitása a szinapszis gyengülését okozza. Az ily módon általánosított Hebb-típusú szinapszis (BROWN és munkatársai, 1990) tehát együttjáró pre- és posztzinaptikus aktivitás hatására erősödik, korrelálatlan és/vagy negatívan együttjáró működés esetén pedig gyengül.

Matematikailag a hálózatba szervezett idegsejtek aktivitásának és a szinapszisok módosításának leírására általában kétszintű dinamikát használunk, vagyis az aktivitásokra vonatkozó egyenletet *tanulási szabály* egészíti ki. Ennek legáltalánosabb formája:

$$S_{ij}(t+1) = S_{ij}(t) + \Delta S_{ij}(t) \quad (0)$$

és

$$\Delta S_{ij}(t) = F(a_i, a_j, S_{ij}) \quad (1)$$

ahol  $t$  az időlépések sorszáma,  $a_i$  és  $a_j$  a posztszinaptikus, illetve a preszinaptikus sejt aktivitás-idő függvényei (nem pedig aktuális értékeik),  $S_{ij}$  a közöttük lévő szinaptikus kapcsolat hatékonysága (erőssége),  $F$  pedig egy általános funkcionál, amely tetszőleges kapcsolatot létesíthet a fenti mennyiségek és a szinaptikus erősség megváltozása között. A tanulási szabály<sup>1</sup> különféle változatai az  $F$  funkcionál egy-egy sajátos esetének felelnek meg.

Észre kell vennünk, hogy a (1) tanulási szabály tartalmazza azokat az eseteket is, amelyek nem felelnek meg az általánosított Hebb-típusú tanulás követelményeinek. Ezeket PALM (1982) nyomán csoportosíthatjuk. Azokat a szabályokat, amelyek együttjáró aktivitás esetén a szinapszist gyengítik, *anti-Hebb*- típusú tanulási szabálynak nevezzük (SUTTON és BARTO, 1981; PALM, 1982; BARLOW és FÖLDIÁK, 1989). *Nem-Hebb*- típusúnak nevezi Palm azokat a szabályokat, amelyek nem tesznek eleget az interaktív, lokális és időzített mechanizmus követelményének.

#### Változatok a Hebb-szabályra

A legegyszerűbb esetben az  $F$  funkcionál egyszerű függvény, vagyis csak a működések pillanatnyi értékétől függ. Az eredeti Hebb-szabály legegyszerűbb alakja tehát:

$$\Delta S_{ij}(t) = k a_i(t) a_j(t) \quad k > 0. \quad (2)$$

Az  $a_i$  és  $a_j$  aktivitások jelentése nincs egyértelműen meghatározva. Speciálisan jelenthetik például a sejtek  $\bar{x}_i$ ,  $\bar{x}_j$  átlagos tüzelési frekvenciáit:

$$\Delta S_{ij}(t) = k \bar{x}_i(t) \bar{x}_j(t) \quad k > 0. \quad (3)$$

Tüzelési frekvencia helyett állhat az aktivitások pillanatnyi értékének tetszőleges  $g$  és  $h$  függvénye:

$$\Delta S_{ij}(t) = k g(a_i(t)) h(a_j(t)) \quad k, g, h > 0, \quad (4)$$

vagy a teljes aktivitás-idő függvényektől függő  $G$  és  $H$  funkcionálok:

$$\Delta S_{ij}(t) = k G(a_i) H(a_j) \quad k, G, H > 0, \quad (5)$$

<sup>1</sup> A tanulási szabályok itt következő osztályozását lényegében Érdi Péter kéziratából (In: Szentágothai, J., Arbib, MA, Érdi, P. előkészületben) vettem át.

aminek sajátos esete, ha a működések összes múltbeli értékét figyelembe vesszük.

A (2)-(5) szabályok fontos tulajdonsága, hogy a szinaptikus erősség csak növekedni képes, sőt a növekedést semmi sem korlátozza. A korlátlan növekedés megakadályozható külső beavatkozással, ami azonban a szabály lokális jellegét sérti. Ilyen beavatkozás például a felső korlát bevezetése, amelyet a szinapszis-erősség nem léphet át. Egy másik hasonló módszer a szinaptikus erősségek normalizálása, vagyis összegük állandó értéken tartása (von der MALSBERG, 1973).

Ennél „természetesebb” megoldást kínálnak az általánosított Hebb-típusú tanulási szabályok, amelyek szelektíven csökkentik egyes szinapszisek erősségét. Ezek a szabályok az interaktív, Hebb-típusú növekedési tag mellett szelektív csökkentő tagot tartalmaznak, amely nem feltétlenül interaktív.

Az alábbi szabály szerint a szinapszis erőssége növekszik, ha a preszinaptikus működés egy (időben változó)  $\Theta(t)$  küszöbnél nagyobb, és csökken, ha kisebb:

$$\Delta S_{ij}(t) = kg(a_i(t))h(a_j(t)) - \Theta(t) \quad k, g, h > 0. \quad (6)$$

Itt a csökkentő tag a  $-g(a_i(t))\Theta(t)$  szorzat, vagyis a posztzinaptikus aktivitással arányos. Ez a bevezetésben említett heteroszínaptikus csökkenés jelenségének feleltethető meg. A homoszinaptikus csökkenést írja le a fenti szabály párja:

$$\Delta S_{ij}(t) = kg(a_i(t)) - \Theta(t)h(a_j(t)) \quad k, g, h > 0. \quad (7)$$

Ezt a szabályt alkalmazta BIENENSTOCK és munkatársai (1982) és BEAR és munkatársai (1987) a látókérgi plaszticitás leírására azzal a sajátos megkötéssel, hogy a küszöb az átlagos posztzinaptikus működés függvénye.

A pre- és posztzinaptikus aktivitás együttjárásának előjelétől függően nő vagy csökken a szinaptikus erősség a kovariancia-szabály szerint (SEJNOWSKI, 1977).

$$\Delta S_{ij}(t) = k(a_i(t)a_j(t) - \bar{a}_i\bar{a}_j) \quad k > 0, \quad (8)$$

ahol  $\bar{a}$  az átlagos aktivitást jelöli. A kovariancia-szabályt javasolta STANTON és SEJNOWSKI (1989) a hippocampus asszociatív LTD mechanizmusának leírására.

Egy másik lehetőség a szinaptikus erősség csökkentésére a spontán csökkenés („felejtés”) bevezetése:

$$\Delta S_{ij}(t) = k_1 a_i(t) a_j(t) - k_2 S_{ij}(t) \quad k_1, k_2 > 0, \quad (9)$$

A szinaptikus erősségek állandóságát tovább növeli, ha a lineáris fejtési tag helyett négyzetes függést feltételezünk (RIEDEL és SCHILD, 1992).

Egyes konnekcionista hálózatok kedvelt algoritmus a versengő, a *kompetitív tanulás* (pl. GROSSBERG, 1976; KOHONEN, 1984), amely azonban megfelel az általánosított Hebb-típusú tanulás követelményeinek. Nevét onnan kapta, hogy a posztszinaptikus idegsejtek versengenek be-meneteik módosításáért. Minél nagyobb a posztszinaptikus aktivitás, annál nagyobb mértékben módosulnak a szinapszisok:

$$\Delta S_{ij}(t) = a_i(t)(k_1 a_j(t) - k_2 S_{ij}(t)) \quad k_1, k_2 > 0, \quad (10)$$

A versengő tanulás differenciális változatában (KOSKO, 1990) a posztszinaptikus aktivitás megváltozása szabályozza a szinaptikus módosulás irányát és nagyságát:

$$\Delta S_{ij}(t) = \Delta a_i(t)(k_1 a_j(t) - k_2 S_{ij}(t)) \quad k_1, k_2 > 0, \quad (11)$$

A differenciális és átlagolási szabályokat ötvözi az a szabály, amelyet a kondicionálás leírására vezettek be (lásd pl. SEJNOWSKI és TESAURO, 1990):

$$\Delta S_{ij}(t) = k \Delta a_i(t) \bar{a}_j \quad k > 0, \quad (12)$$

A (9) szabály módosított változatát egészíti ki szelektív csökkentő taggal az alábbi tanulási szabály (ÉRDI és mts., 1993; ARADI és mts., megjelenés alatt):

$$\Delta S_{ij}(t) = k_1 a_i(t) a_j(t) - k_2 S_{ij}^2(t) - k_3 S_{ij}(t) [a_i(t) - a_j(t)]^2 \quad k_1, k_2 > 0. \quad (13)$$

A (13) szabállyal a szaglógumó egyfajta asszociatív tanulását sikerült modellezni (GRÖBLER és munkatársai, 1992).

## TANULÁS ÉS KONNEKCIONIZMUS: ALGORITMUSOK

A konnekcionizmus az agyműködés mechanizmusának értelmezése, magyarázata helyett az idegsejthálózatok működését hasznos analógiának tekintí, amelynek alapján az intelligens viselkedés egyes formáit utánzó al-

goritmusok készíthetők. Ennek az analógiának értelmében ebben a fejezetben idegsejtek helyett számítási egységek, aktivitás helyett az egységek bemeneti ( $x_i$ ) és kimeneti ( $y_i$ ) értékei, szinaptikus hatékonyság helyett pedig kapcsolaterősségek vagy súlyok ( $w_{ij}$ ) szerepelnek. A tanulóalgorithmus (0)-hez hasonlóan

$$w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij}(t) \quad (14)$$

de itt  $w_{ij}(t)$  alakja tetszőleges lehet.

A konnekcionista hálózatok kapcsolaterősségeit módosító tanulási algoritmusokat három osztályba szokás sorolni. Aszerint, hogy a tanulási feladat megkívánta kimeneti értékek közvetlenül befolyásolják-e a kapcsolatok módosítását, megkülönböztethetünk tanulást külső tanítóval (*supervised learning*), tanító nélkül (*unsupervised learning*), illetve megerősítéssel tanulást (*reinforcement learning*).

#### Tanulás tanítóval

A tanítóval való tanítás lehetővé teszi, hogy akár a kapcsolatban részt vevő sejtek, akár az egész hálózat elvárt kimenete explicit módon megjelenjen a tanulási algoritmusban. Ez a lehetőség nyilvánvaló ellentmondásban áll a 2. fejezet tanulási szabályainak lokalitási ismérével, hiszen a sejtaktivitásokon kívül olyan információt is felhasznál az algoritmus, amit nem a hálózat működése határoz meg, hanem csak a programozó (tanító) ismerhet. (Meg szokás említeni azonban, hogy a kisagy területére érkező kúszórostok alkalmasak lehetnek ilyen jellegű információ közvetítésére.)

A legkézenfekvőbb ilyen megoldás az, ha a szinaptikus súlyokat úgy változtatjuk, hogy a kapott kimeneti értékek és a hálózat elvárt kimenete közötti különbség minimális legyen. Az ilyen algoritmusokat *hibajavító* tanulási szabálynak is nevezik, és a legtöbb tanítóval tanuló algoritmus ezen az elven alapszik.

Az első hibajavító tanulóalgorithmus a *perceptron-szabály* (lásd ROSENBLATT, 1962). A perceptron nevű hálózat kimeneti egysége a 0 vagy 1 kimeneti értékek egyikét veheti fel. A kimeneti egységhez érkező kapcsolatok erőssége a perceptron-szabály szerint

„változatlan, ha a kimenet megfelel az elvártnak;

a bemenő jel értékével növekszik, ha a kimenet 0 volt, de 1-et vártunk el;

a bemenő jel értékével csökken, ha a kimenet 1 volt, de 0-t vártunk el.”

A tanulá algoritmusok első nagy sikere volt, hogy a fenti szabályra bebizonyítható a perceptron-konvergencia tétel, amely szerint ha a bemenetek és kimenetek egy párosítása a perceptronnal megoldható, akkor a perceptron-szabály éppen olyan súlykészlethez fog konvergálni, amely ezt a párosítást megvalósítja.

A perceptron-szabály továbbfejlesztett változata folytonos be- és kimeneti értékekre, illetve súlyokra a *delta-szabály* (WIDROW és HOFF, 1960). A delta-szabály szerint

$$\Delta w_{ij}(t) = \eta \delta_i x_j \quad \eta > 0, \quad \delta_i = t_i - y_i \quad (15)$$

ahol  $x_j$  a  $j$  egységtől érkező bemenet,  $t_i$  a kívánt,  $y_i$  pedig a tényleges kimenet.

A delta-szabály hiányossága többrétegű hálózatok esetén mutatkozott meg. A tanulási feladat ugyanis csak a kimeneti egységek kimenetét határozza meg, a hálózat belső, úgynevezett rejtett egységeinek kimenetére nincs elvárt érték, amelyhez a tényleges kimeneti értéket hasonlítani lehetne. E probléma megoldására született meg az általánosított delta-szabály, más néven a *back propagation* algoritmus (WERBOS, 1974; PARKER, 1985, RUMELHART és munkatársai, 1986). Belátható ugyanis, hogy a hiba csökkenése akkor lesz a legnagyobb, ha a kimeneti réteg a delta-szabály szerint tanul, a rejtett rétegek súlyaira pedig

$$\Delta w_{ij}(t) = \eta \delta_j x_k \quad \eta > 0, \quad \delta_j = \sum_i w_{ij} \delta_i, \quad (16)$$

vagyis a kimeneti réteg  $\delta_i$  hibája visszafelé terjed (innen az algoritmus elnevezése) a rejtett rétegek felé. A back propagation ma a legelterjedtebb, hatékony és gyors tanulá algoritmus. A tanítóval való tanulás másik típusa a nem hibajavító algoritmusok. HOPFIELD (1982) hálózatában nincsenek bemeneti egységek, és az egységek kimeneteinek előre meghatározott mintázatok egyikét kell kiadniuk. A tanulás itt egyszerűen a mintázatok egyszeri beégetése a kapcsolaterőségekbe:

$$w_{ij} = \frac{1}{N} \sum_{\mu} t_i^{\mu} t_j^{\mu}, \quad (17)$$

ahol  $N$  az egységek száma.

Ismét más megközelítést jelent a *Boltzmann-gép* (ACKLEY és munkatársai, 1985), amely az egységek kimeneteit véletlenszerűen határozza meg, és így a tanulás csak a kimeneti értékek statisztikus átlagának meghatározása után lehetséges. A statisztikát kétszer kell elvégezni: egyszer úgy, hogy a kimeneti egységekre az elvárt kimeneti értékeket kényszerítjük, másodsor pedig e kényszer nélkül. A tanulási szabály ekkor:

$$\Delta w_{ij} = \eta (\langle y_i y_j \rangle_k - \langle y_i y_j \rangle) \quad \eta > 0, \quad (18)$$

ahol  $\langle \rangle$  a statisztikus átlagot, a  $k$  index pedig a kényszer alkalmazását jelöli.

A tanulási algoritmusokat egy statisztikus mintázatfelismerési problémán hasonlította össze (BARNA és munkatársai, 1988; BARNA és KASKI, 1989). Ez a vizsgálat megállapította, hogy a Boltzmann-gép egy determinisztikus változata magasabb dimenziószám esetén a back propagation algoritmusnál is hatékonyabban működik.

### Tanulás tanító nélkül

A tanító nélküli tanulás feltétele, hogy az algoritmus csak a hálózat bemeneteiből és (aktuális vagy múltbeli) állapotából származó információt használhatja fel a súlyok módosításához, vagyis a tanulás elvárt végeredménye semmilyen formában nem befolyásolhatja a tanulás folyamatát. A tanító nélküli tanulás tehát a tanítóval való tanulással ellentétben megfelel a 2. fejezetben meghatározott önszervező mechanizmus feltételének. Valóban, a 2. fejezet tanulási szabályai mind tanító nélküli tanulást valósítanak meg.

Az önszervező tanulási algoritmusoknak azonban van egy olyan csoportja, amely nem felel meg egy, az idegrendszeri mechanizmusok szempontjából szükségesnek gondolt feltételnek, a lokalitás ismérvének. Ide tartozik az a már említett algoritmus (von der MALSBERG, 1973), amely a Hebb-típusú szabály korlátlan növekedését a súlyok normalizálásával akadályozza meg.

A *cognitron* nevű hálózat (FUKUSHIMA, 1975) vizuális mintázatokat dolgoz fel. A *cognitron* tanulási algoritmus azért nem lokális, mert csak a legnagyobb kimeneti értékű egység bemenő szinapszisai tanulnak. A legnagyobb érték kiválasztása azonban nem lokális szabály, ezt *winner-take-all* algoritmusnak szokás nevezni, mert csak a „nyertes” egység változtathatja bemenő súlyait. Ebben az esetben a súlyok a bemeneti értékekkel arányosan változnak.

Talán a legismertebb tanító nélküli tanulási algoritmus KOHONEN (1982) *topologikus térképe*. Az algoritmus a súlyokon topologikus rendezést hajt végre rendezetlen bemenetek segítségével, az alábbi szabály alapján:

$$\Delta w_{ij}(t) = \lambda_{i-i^*} (x_j(t) - w_{ij}(t)), \quad (19)$$

ahol a  $\lambda$  eloszlás az  $i^*$  egységre a legnagyobb, és attól távolodva egyre 0-hoz közelít.

Az algoritmus azért nem lokális, mert az  $i^*$  sorszámú egységet itt is a winner-take-all algoritmus választja ki. A nemlokális tulajdonság azonban megszüntethető a winner-take-all algoritmus „lágyításával”, ami a 2. fejezetben említett versengő tanuláshoz vezet.

### Megerősítéses tanulás

A megerősítéses tanulási algoritmusok a tanítóval való tanulásnál kevesebb információval is megelégszenek a feladat végrehajtásának kimeneteléről. Az algoritmus itt nem a kívánt eredménytől való eltérést használja fel, hanem csak „jutalmat” vagy „büntetést” kap aszerint, hogy a hálózat kimenete az elvárt érték közelében volt-e vagy sem.

A megerősítéses tanulás egy lehetséges algoritmusja zajos környezetben (BARTO és munkatársai, 1981):

$$\Delta w_{ij}(t) = \begin{cases} k_1(y_i(t) - \langle y_i \rangle)x_j(t) & \text{jutalom} \\ k_2(-y_i(t) - \langle y_i \rangle)x_j(t) & \text{büntetés} \end{cases} \quad \text{esetén} \quad (20)$$

ahol  $\langle \rangle$  a kimenet várható értékét jelöli.  $k_1, k_2 > 0$

A megerősítéses tanulás egy érdekes problémáját fogalmazta meg SAMUEL (1959) a dámapjáték gépi tanulásával kapcsolatban: hogyan lehet egy lépést a játék közepén kiértékelni, ha az egyetlen visszajelzés (nyertem vagy vesztem) a játék végén érkezik? Ez motiválta a késleltetett megerősítés bevezetését (BARTO és munkatársai, 1982), amely csak egy-egy próbálkozás végső kimenetele után fejt ki hatását.

Bár a megerősítéses tanulási algoritmusok létrehozásának elsődleges célja általában nem biológiai mechanizmusok modellezése, meg kell említeni, hogy a megerősítő jel megfelelhet valamilyen kémiai anyagnak, amely neuromodulációs hatást fejt ki. Ezt fejezi ki LEVY és BURGER (1987) algoritmus (a 2. fejezet jelöléseivel):

$$\Delta S_{ij}(t) = g[a_i(t)](k_1 a_j(t) - k_2 S_{ij}(t)) \cdot P \quad k_1, k_2 > 0. \quad (21)$$

ahol  $P$  a neuromodulációs jel, amelynek értéke 0 és 1 között lehet.

### ÖSSZEFOGLALÁS

A tanulás hálózati algoritmusait tehát osztályozhatjuk attól függően, hogy mennyire veszik figyelembe a szinapszisok módosulásának biológiai me-

chanizmusait. Egyelőre igaznak látszik az a megállapítás, hogy a leghatékonyabb, legtöbb fajta tanulási feladat megoldására képes algoritmusok nem feleltethetők meg valódi biológiai mechanizmusnak.

Ugyanakkor azok az algoritmusok, amelyek igyekeznek a biológia által megszabott kereteken belül maradni, szintén nem a szinaptikus módosulás részletes biofizikai mechanizmusát írják le, hanem többnyire a Hebb által megfogalmazott fenomenologikus szabály különféle matematikai formákba öntött változatai. A tanulás átfogó biológiai elméletének megszületéséhez vezető kutatásokban tehát még nem következett be áttörés.

A kézirat elfogadva: 1996 május

## IRODALOM

- ACKLEY, D. H., HINTON, G. E., SEJNOWSKI, T. J., 1985, A learning algorithm for Boltzmann machines, *Cognitive Science*, 9, 147—169.
- ARADI, I., BARNÁ, G., ÉRDI, P. GRÖBLER, T., megjelenés alatt, Chaos and learning in the olfactory bulb., *Int. J. Intelligent Systems*.
- BARLOW, H., FÖLDIÁK, P., 1989, Adaptation and decorrelation in the cortex, In: DURBIN, R. et al. (eds.), *The computing neuron*, Addison-Wesley.
- BARNÁ, G., ÉRDI, P., 1986, Pattern formation in neural systems: II. Noise induced formation of ocular dominance columns, In: TRAPPL, R. (Ed.), *Cybernetics and Systems '86*, Reidel Publ., 335—342.
- BARNÁ, G., CHRISLEY, KOHONEN, T., 1988, Statistical pattern recognition with neural networks, *Neural Networks*, 1, 1, 7.
- BARNÁ, G., KASKI, K., 1989, Variations on the Boltzmann machine, *J. Phys. A Math Gen*, 22, 5143—5151.
- BARTO, A. G., SUTTON, R. S., BROUWER, P. S., 1981, Associative search network: A reinforcement learning associative memory, *Biol. Cybern.*, 40, 201—211.
- BARTO, A. G., ANDERSON, C. W., SUTTON, R. S., 1982, Synthesis of nonlinear control surfaces by a layered associative search network, *Biol. Cybern.*, 43, 175—185.
- BEAR, M. F., COOPER, L. N., EBNER, F. F., 1987, A physiological basis for a theory of synapse modification, *Science*, 237, 42—48.
- BIENENSTOCK, E. L., COOPER, L. N., MUNRO, P. W., 1982, Theory for the development of neuron selectivity, Orientation specificity and binocular interaction in visual cortex, *J. Neurosci.*, 2, 32—48.
- BLISS, T. V. P., LØMO, T., 1973, Long-lasting potentiation of synaptic transmission in the dentate area of the unanaesthetized rabbit following stimulation of the perforant path, *J. Physiol.*, 232, 331—356.

- BROWN, T. H., KAIRISS, E. W., KEENAN, C. L., 1990, Hebbian synapses: Biophysical mechanisms and algorithms, *Ann. Rev. Neurosci.*, *13*, 475—511.
- CHANGEURX, J. P., DANCHIN, A., 1976, Selective stabilization of developing synapses as a mechanism for the specification of neuronal networks, *Nature*, *264*, 705—712.
- ÉRDI, P., BARNA, G., 1984, Self-organizing mechanism for the formation of ordered neural mappings, *Biol. Cybern.*, *51*, 93—101.
- ÉRDI, P., GRÖBLER, T., BARNA, G., KASKI, K., 1993, Dynamics of the olfactory bulb: bifurcations, learning, and memory, *Biol. Cybern.*, *69*, 57—66.
- FUKUSHIMA, K., 1975, Cognitron: A self-organizing multilayered neural network, *Biol. Cybern.*, *20*, 121—136.
- GLUCK, M. A., GRANGER, R., 1993, Computational models of the neural bases of learning and memory, *Ann. Rev. Neurosci.*, *16*, 667—706.
- GOODHILL, G., 1992, Correlations, competition, and optimality: modelling the development of topography and ocular dominance, CSRP 226.
- GROSSBERG, S., 1976, Adaptive pattern classification and universal recoding: I. Parallel development and coding of neural feature detectors, *Biol. Cybern.*, *23*, 121—134.
- GRÖBLER, T., ÉRDI, P., KASKI, K., 1992, Dynamic phenomena in the olfactory bulb: II. Model for a simple associative memory, In: ALEKSANDER, I., TAYLOR, J. (eds.), *Artificial Neural Networks*, *2*, *ICANN '92*, Vol. 2, Elsevier, North Holland, 877—880.
- HEBB, D. O., 1949, *Organization of Behavior*, Wiley, New York.
- HOPFIELD, J. J., 1982, Neural networks and physical systems with emergent collective computational properties, *Proc. Natl. Acad. Sci. USA*, *79*, 2554—2558.
- HUBEL, D. H., WIESEL, T. N., 1962, Receptive fields, binocular interaction, and functional architecture in the cat's visual cortex, *J. Physiol. (London)*, *160*, 106—154.
- ITO, M., 1984, In: *The Cerebellum and Neural Control*, Raven, New York.
- KELSO, S. R., BROWN, T. H., 1986, Differential conditioning of associative synaptic enhancement in hippocampal brain slices, *Science*, *232*, 85—87.
- KOHONEN, T., 1982, Self-organized formation of topologically correct feature maps, *Biol. Cybern.*, *43*, 59—69.
- KOHONEN, T., 1984, *Self-Organization and Associative Memory*, Springer-Verlag, Berlin/Heidelberg.
- KOSKO, B., 1990, Unsupervised learning in noise, *IEEE Trans Neural Networks*, *1*, 44—57.
- LEVY, W. B., BURGER, B., 1987, *IEEE 1st Int. Conf. on Neural Networks*, Vol. 4, IEEE, San Diego, 11—15.
- Von der MALSBERG, C., 1973, Self-organization of orientation sensitive cells in the striate cortex, *Kybernetik*, *14*, 85—100.

- McCULLOCH, W. S., PITTS, W. H., 1943, A logical calculus of the ideas immanent in nervous activity, *Bull. Math. Biophys.*, 5, 115—133.
- PALM, G., 1982, *Neural Assemblies: An Alternative Approach*, Springer-Verlag, Berlin/Heidelberg/New York.
- PARKER, D., 1985, Learning logic, Technical report TR-87, Center for Computational Research in Economics and Management, MIT Cambridge, MA.
- RAMÓN Y CAJAL, S., 1909, *Histologie du Système Nerveux de l'Homme et des Vertèbres*, Maloine, Paris.
- RIEDEL, H., SCHILD, D., 1992, The dynamics of Hebbian synapses can be stabilized by a nonlinear decay term, *Neural Networks*, 5, 459—463.
- ROSENBLATT, F., *Principles of Neurodynamics*, Spartan Books.
- RUMELHART, D. E., HINTON, G. E., WILLIAMS, R. J., 1986, Learning representations by back-propagating errors, *Nature*, 323, 533—536.
- SAMUEL, A. L., 1959, Some studies in machine learning using the game of checkers, *IBM J. Res. and Dev.*, 3, 210—229.
- SEJNOWSKI, T. J., 1977, Strong covariance with nonlinearly interacting neurons, *J. Math. Biol.*, 4, 303—321.
- SEJNOWSKI, T. J., TESAURO, G., 1990, Building network learning algorithms from Hebbian synapses, In: McGAUGH, J. L. et al. (eds.), *Brain Organization and Memory: Cells, Systems, and Circuits*, Oxford Univ. Press, New York/Oxford.
- STANTON, P. K., SEJNOWSKI, T. J., 1989, Associative long-term depression in the hippocampus induced by Hebbian covariance, *Nature*, 339, 215—218.
- STENT, G. S., 1973, A physiological mechanism for Hebb's postulate of learning, *Proc. Natl. Acad. Sci., USA*, 70, 997—1001.
- SUTTON, R. S., BARTO, A. G., 1981, Toward a modern theory of adaptive networks: expectation and prediction, *Psychol. Rev.*, 88, 135—170.
- STRYKER, M. P., HARRIS, W. A., 1986, Binocular impulse blockade prevents the formation of ocular dominance columns in cat visual cortex, *J. Neurosci.*, 6, 2117—2133.
- SZENTÁGOTHAI, J., 1983, The modular architectonic principle of neural centers, *Rev. Physiol. Biochem. Pharmacol.*, 98, 11—61.
- TANZI, E., 1893, I fatti e le induzioni nell' odierna istologia del sistema nervoso, *Riv. Sperimentale Freniatria Med. Leg.*, 19, 419—472.
- WERBOS, 1974, *Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences*, Harvard Univ. PhD thesis.
- WIDROW, B., HOFF, M. E., 1960, Adaptive switching circuits, In: 1960 IRE WESCON Conv. Rec. IRE, New York, 96—104.
- WOOD-JONES, F., PORTEUS, S. D., 1928, *The Matrix of the Mind*, Mercantile, Honolulu.

TAMÁS GRÓBLER

## LEARNING IN BIOLOGICAL AND ARTIFICIAL NETWORKS

The paper reviews the algorithms proposed for learning mechanisms. It gives a classification of the different proposed network algorithms for learning on the basis of how much they consider the biological constraints given by the modification of synaptic connections. In particular varieties of the Hebb-rule, supervised and unsupervised learning algorithms as well as learning models with reinforcement are discussed. For the moment it seems to be true that the most powerful algorithms do not have corresponding biological mechanisms.

At the same time algorithms that try to remain within the constraints of biology also ignore the biophysical details of synaptic modification. They mostly use different mathematical versions of the phenomenological rule proposed by Hebb. No real breakthrough can thus be seen in modeling learning in real biological systems.