

*Brendel Mátyás*  
**Plaszticitás Celluláris Neurális Hálózatokban  
CNN-backpropagation, adaptív képérzékelés és  
képjavítás**

A Ph.D. disszertáció tézisei

Analogikai és Neurális Számítások Laboratórium  
Számítástechnikai és Automatizálási Kutatóintézet  
Magyar Tudományos Akadémia

Tudományos vezető: Dr. Roska Tamás

Budapest, 2003.

*Miért van az, hogy a technológia, ami munkát takarít meg, egyszerűbbé teszi életünket, oly kevés örömet ad? Az válasz egyszerű: még nem tanultuk meg ésszerűen használni... ...Az ember maga kell alkossa a technológiai fejlesztés fő tárgyát.*

Albert Einstein, a Kalifornia Intézet Technológia tanszékén tartott egyik előadásán, Pasadena 1931. február

## Bevezetés

A „plaszticitás” fogalma a neurobiológiából ered és a számítástudományban különösebben nem használatos<sup>1</sup>, habár úgy gondolom, érdemes volna alkalmazni. Az idegrendszer plaszticitása több tulajdonságokból tevődik össze: tanulás, redundancia, hibatűrés, extrém bemenetek rugalmas feldolgozásának képessége, azaz adaptivitás. Mivel ezek a funkciók nem függetlenek, hanem átfedők, plauzibilis azok emergens tulajdonságáról beszélni, ez a plaszticitás.

Az első számítógépeknek igen csekély „plaszticitása” volt: Csak jól meghatározott inputokra működtek, ha rossz bemenő adatot kaptak, vagy belső hiba történt, akkor az eredmény teljesen rossz lehetett. Ha valamely alkatrész elromlott, sokszor az egész gép működésképtelenné vált. Ahogy az információs technológia fejlődik, a számítástechnikai eszközökkel szemben támasztott igények egyre nagyobbak. A technológia fejlődése egy jelentős részben képes is kielégíteni ezeket az igényeket: olyan hardverek és szoftverek jelennek meg, amelyek maguktól tanulnak, kisebb hibákat kijavítanak, és különböző bemenő adatokat intelligens módon kezelnek.

Még nem mondhatjuk el, hogy a mesterséges intelligenciát kifejlesztettük, és az a személyes magánvéleményem, hogy abban az értelemben, ahogy azt a naiv sci-fi bemutatja, soha nem is fogjuk. De nyilvánvaló, hogy nagyszerű eredményeket értünk el, néhány ezek közül olyan, hogy a témában járatlan embereknek alig hihető. A jövőbeli fejlődés pedig minden bizonnyal még inkább lenyűgöző lesz. Azt gondolom, hogy ennek a fejlődésnek egy fontos része a plaszticitáshoz fog kapcsolódni.

A fejlődés egy másik síkja alternatív számítástechnikai eszközökhöz kapcsolódik, párhuzamos számítási technikák, neurális hálózatok, fuzzy rendszerek és más fejlődő technikák. A Celluláris Neurális Hálózat (Cellular Neural Network, CNN) egyike a legérdekesebb számítástudományi elgondolásoknak ([9]), amely kapcsolódik a fejlődés e vonalához. Alapjában véve egy analóg technológia, de a CNN Univerzális Gép (CNN Universal Machine, CNN-UM) révén az analóg és digitális műveletek analogikai számítássá integrálódnak ([10]). A CNN egyúttal egy speciális neurális hálózatnak is tekinthető, és így része a számítástudomány egyik legeredetibb eredményének, az „összeköttetés”-paradigmának (connectionist-paradigm). A CNN ötletét ezen kívül a neurobiológiai ismereteink közvetlenül is inspirálták, különösen a látórendszerünk első szintjének modelljei.

A CNN tanítása fontos témája volt a CNN kutatásnak, már a CNN történetének kezdete óta [13]. A CNN-tanítás elméletének számos problémával kell megküzdenie. A tanulás mindig egy optimalizálási feladat is egyben. Az alkalmazott matematika

---

<sup>1</sup> Használatos a „roboszus”, „adaptív”, „intelligens” fogalmak, amik hasonlóak, vagy a plaszticitás egy részét ragadják meg, de nem pont ugyanazt fedik le. Ezek mellett a „plaszticitás” egy gyómolcsöző fogalom lehetne.

egyik leginkább szerteágazó területe a (globális) optimalizálás, számos megoldatlan problémával, és néhányal, amely feltehetően megoldhatatlan. Egy másik probléma a CNN tanításban, amelyet mindig figyelembe kell venni, a nagy számítási igény.

A CNN, mint párhuzamos és analóg számítási eszköz egy különlegesen nagy számítási kapacitást jelent. De ezt a számítási kapacitást eddig nem használták fel magához a CNN tanításához. A disszertációm első részének (1. tézis) ez az alapötlete.

A plaszticitás nem merül ki a tanulásban. Egy másik fontos szempont a bejövő adatok intelligens feldolgozása. Mivel a CNN fizikai megvalósítása egy kétdimenziós processzor-tömb, a legfőbb alkalmazások kézenfekvően képek (vagy más, kétdimenziós jelmátrixok) feldolgozása. A képeket valamilyen képrögzítő eszközzel kapjuk. Így itt az első fontos feladat a minőségi képalkotás.

A képalkotás egyik legfontosabb problémája az, hogy az eszközök nem működnek megfelelően szélsőséges megvilágítási viszonyok között. Például a fényképezőgépek és videokamerák nem tudnak megfelelő képet alkotni, ha a megvilágítás túl erős vagy túl gyenge. Lehetséges a kamera globális paramétereinek kézi beállítása, de ez nem kielégítő megoldás. Mostanában már automatikus megoldások is megjelentek, de ezek még mindig nem elég jók, ha a megvilágítási körülmények egyazon képen térben változnak. Ebben az esetben térbeli adaptáció szükséges.

A jelenlegi helyzet az, hogy az eszközök egyre intelligensebbé válnak, és sok problémát meg tudnak oldani. Például néhány globális paramétert, mint a fényesség automatikusan állítanak be. Ugyanakkor komoly hardveres korlátjai vannak az említett automatikus térbeli adaptáció megvalósíthatóságának. A CNN megoldást nyújthat ehhez a számítási problémához, egyben a globális paraméterek beállítását is elvégezheti. A másik előnye a CNN alkalmazásának, hogy egy általános megoldás, így egyúttal más képfeldolgozási feladatok is programozhatóak lesznek, ha már alkalmazásra került.

A disszertációm második része (2. tézis) ehhez kapcsolódóan adaptív képalkotással foglalkozik a CNN-UM alkalmazásával. Ez véleményem szerint egyúttal egy olyan alkalmazás amely áttörő lehet a CNN technológiában. A megoldás, amit javaslok ugyanis teljesen megvalósítható a jelenlegi architektúrán.

A képjavítás a képfeldolgozás talán legfontosabb területe, amelynek tekintélyes története van immár. Számos digitális algoritmust kidolgoztak, sok ezek közül már része is a legjobb képfeldolgozó programoknak. Ezek jó megoldásokat szolgáltatnak, de korlátaik is vannak. A CNN technológia alkalmazásának előnye a számítási sebességének növelése, amely a soros, digitális eszközöknél problémát jelent. Az érzékelés és feldolgozás integrálása szintén jobban megvalósítható ily módon – különösen, ha az érzékelőt a feldolgozott tartalom alapján hangolják.

Kutatásom célja olyan egyszerű módszerek felől való megközelítés volt, amelyek a jelenlegi technológiával vagy a közeljövőben tervezettekkel ([15]) megvalósíthatóak. A CNN technológia architektúra-fejlődésének egyik fő irányvonala a többretegű vagy komplex cellák, amelyek az adaptív alkalmazásokban különösen jól használhatóak.

A 3. tézisben bemutatott két adaptív képjavítási algoritmus szorosan beilleszkedik ezekbe a lehetőségekbe. Ezek nem az optimális elméleti megoldások a feladatra, hanem inkább a komplexitás és megvalósíthatóság dimenziójában képzett kompromisszumok.

A disszertációm szorosan kapcsolódik neurobiológiához. Pontosabban, a módszerek ihletője többek között a biológia, de ez nem jelenti, hogy a biológiai funkciók anatómiailag megfelelő modelljének tekinthetők. A kutatásom fő célja hasznosítható alkalmazások keresése volt, nem pedig biológiai szimuláció. Azonban,

mivel a módszereket a biológia sugallta, ezért a disszertációmban felvázolom a neurobiológia azon ismereteit, amelyek kapcsolódnak a kutatásomhoz.

## A vizsgálatok módszerei

A kutatásom legfőbb elméleti háttere a CNN paradigma. A CNN tanítás témájában a neurális hálózatok tanításának elmélete is alapvető. A 2. és 3. tézishez a képfeldolgozás elméletei is szükségesek.

A kutatások kezdetén a módszereket szimulációval teszteltem. Az Analogikai és Neurális Számítások Laboratórium ALADDIN nevű szimulációs eszközt használtam, melyet speciálisan CNN kutatásra fejlesztettünk ki. Néhány szimulációhoz szükségem volt egy általánosabb eszköz, a MATLAB matematikai szoftver alkalmazására. Alkalmam volt azonban az algoritmusok hardveren, pontosabban az ACE4k CNN-UM chip és környezetben való tesztelésére is. A képfeldolgozáshoz két eszközt használtam, az első egy Sony típusú kamera, melyet C nyelven lehetett meghajtani és programozni, a másik eszköz egy kereskedelmi digitális fényképezőgép volt.

Az adaptív érzékelés opto-elektronikus megoldásához az opto-elektronikus laboratóriumunkban összerakott eszközt használtam.

## Új tudományos eredmények (tézisek)

### 1. Az egyrétegű, CNN lineáris template-paramétereinek gradiens-számítása magának a CNN-UM-nek a használatával ([1],[5] és 4. fejezet)

#### 1.1. Gradiens-számítás diszkrét-idejű-CNN (DT-CNN) esetén

Technikai előzetes: A DT-CNN deriváltjai

*Egzakt analitikus formulákat dolgoztam ki a deriváltak számításához, minden egyes paraméter-típushoz.*

Ha  $x$  a CNN állapotváltozója,  $y$  a kimenet és  $p$  a paraméter, vezessük be a következő rövidítéseket:

$$dpy_{i,j}(n) = \frac{dy_{i,j}(n)}{dp}$$

$$dpx_{i,j}(n) = \frac{dx_{i,j}(n)}{dp}$$

Ezek segítségével a derivált-számítás egyenletei a következő alakban adhatóak meg. Először is a kimeneti egyenlet deriváltja a következő:

$$dpy_{i,j}(n) = f'(x_{i,j}(n))dpx_{i,j}(n) \tag{1}$$

A hálózati egyenlet deriváltjának alakja pedig függ a paraméter típusától.

$$dpx_{i,j}(n+1) = y_{i+v,j+\mu}(n) + \sum_{(k,l) \in S_r(i,j)} A(k-i,l-j) dpy_{k,l}(n) \quad (2)$$

ha  $p=A(v,\mu)$ ,

$$dpx_{i,j}(n+1) = u_{i+v,j+\mu}(n) + \sum_{(k,l) \in S_r(i,j)} A(k-i,l-j) dpy_{k,l}(n)$$

ha  $p=B(v,\mu)$ , és

$$dpx_{i,j}(n+1) = 1 + \sum_{(k,l) \in S_r(i,j)} A(k-i,l-j) dpy_{k,l}(n) \quad (3)$$

ha  $p=z$ .

### 1.1.1. A gradiens számítása CNN segítségével

Megmutattam, hogy az egyrétegű DT-CNN un. adjoint vagy reciprok hálózata - amely az eredeti hálózat deriváltját számolja ki valamely lineáris template-paraméterre – maga is egy egyrétegű DT-CNN lineáris template-tel, de módosított kimeneti függvénnyel, bemenettel és template-kkel. Így a DT-CNN gradiensei egy másik DT-CNN-nel vagy magával számolható.

Az (1)-(3) egyenletek 3 különböző DT-CNN-t írnak le, amelynek állapotváltozói dpx, kimeneti változója dpy, bemenete pedig y,u vagy 0 a típustól függően. A template-jei speciálisan származnak az eredeti template-kből, a kimeneti függvénye pedig az eredeti függvény deriváltjából és az eredeti állapotváltozóból tevődik össze.

Ezek az un. reciprok hálózatok kiszámítják az eredeti hálózat deriváltjait. Az reciproc hálózat származását az eredeti hálózatból az 1. táblázat mutatja.

Paraméter	Eredeti hálózat	Reciproc hálózat, CNN <sub>p</sub>
$p=A(v,\mu)$	A,B,z,x,y,u,f	$A, E_{v,\mu}, 0, dpx, dpy, y, f'(x_{i,j}(n))$ .
$p=B(v,\mu)$		$A, E_{v,\mu}, 0, dpx, dpy, u, f'(x_{i,j}(n))$ .
$p=z$		$A, 0, 1, dpx, dpy, 0, f'(x_{i,j}(n))$ .

1 Táblázat. A reciprok CNN származása az eredeti CNN-ből.  $E_{v,\mu}$  egy speciális template, amelynek értéke 1 a  $(v,\mu)$  helyen és 0 máshol. “ $f'(x_{i,j}(n))$ ” szorzást jelent az  $f'(x_{i,j}(n))$  értékkel.

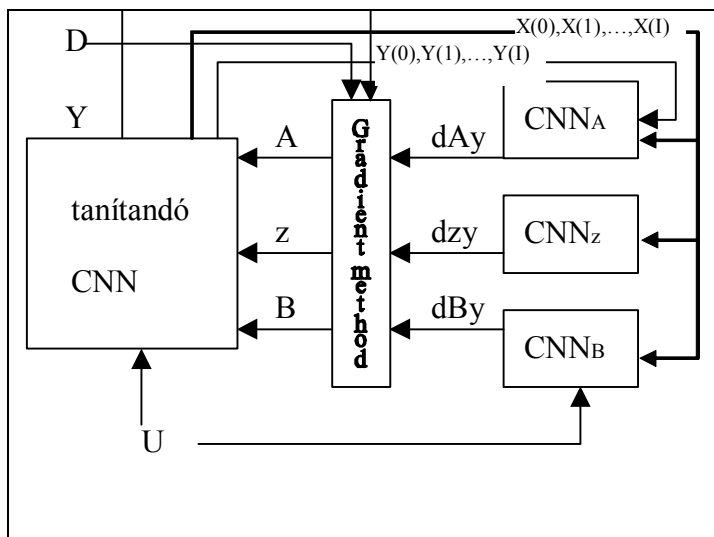
A gradienst egy egyszerű képlet alapján lehet a deriváltból számolni:

$$\frac{dE(p)}{dp} = - \sum_i \sum_j (d_{i,j} - y_{i,j}(T)) \frac{dy_{i,j}}{dp}(T) = - \sum_i \sum_j (d_{i,j} - y_{i,j}(T)) dpy_{i,j}(T)$$

ahol d a kívánt kimenet, y a tényleges kimenet és T az az idő, ahol a végső kimenetet vettük.

### 1.1.2. A tanító-rendszer

Az 1. ábra egy olyan rendszert mutat be, amely gradiens alapú tanulásra képes. A  $CNN_A$  jelölés 9 A típusú reciprok hálózatot jelöl, a  $CNN_B$  9 B típusú reciprok hálózatot, és a  $CNN_z$  egy z típusú reciprok hálózatot.



1Ábra A DT-CNN felügyelt tanítása reciprok DT-CNN-ek segítségével.  $D$  a kívánt kimenet,  $Y(i)$  a tényleges kimenet az  $i$ . időlépésben,  $X(i)$  az állapot változó az  $i$ . időlépésben,  $U$  a bemenet. Mindegyik változó mátrixot jelöl.  $dAy$ ,  $dzy$  és  $dBy$  19 megfelelő deriváltat jelöl,  $CNN_A$ ,  $CNN_B$  és  $CNN_z$  pedig a 19 reciprok hálózatot.

### 1.2. Gradiens-számítás folytonos-idejű-CNN (CT-CNN) esetén

Technikai előzetes: A CT-CNN deriváltjai

*Egzakt analitikus formulákat dolgoztam ki a deriváltak számításához, minden egyes paraméter-típushoz.*

Ha  $x$  a CNN állapotváltozója,  $y$  a kimenet és  $p$  a paraméter, vezessük be a következő rövidítéseket:

$$\delta p y_{i,j}(t) = \frac{dy_{i,j}(t)}{dp}$$

$$\delta p x_{i,j}(t) = \frac{dx_{i,j}(t)}{dp}$$

Ezek segítségével a derivált-számítás egyenletei a következő alakban adhatóak meg. Először is a kimeneti egyenlet deriváltja a következő:

$$\delta p y_{i,j}(t) = \frac{\delta f}{\delta x}(x_{i,j}(t)) \delta p x_{i,j}(t)$$

(4)

A hálózati egyenlet deriváltjának alakja pedig függ a paraméter típusától.

$$\frac{d}{dt} \delta p x_{i,j}(t) = -\delta p x_{i,j}(t) + \sum_{k,l \in S(i,j)} A(k-i, j-l) \delta p y_{k,l}(t) + y_{i+m, j+n}(t) \quad (5)$$

ha  $p = A(v, \mu)$ ,

$$\frac{d}{dt} \delta p x_{i,j}(t) = -\delta p x_{i,j}(t) + \sum_{k,l \in S(i,j)} A(k-i, j-l) \delta p y_{k,l}(t) + u_{i+m, j+n}(t)$$

ha  $p = B(v, \mu)$ , és

$$\frac{d}{dt} \delta p x_{i,j}(t) = -\delta p x_{i,j}(t) + \sum_{k,l \in S(i,j)} A(k-i, j-l) \delta p y_{k,l}(t) + 1 \quad (6)$$

ha  $p = z$ .

### 1.2.1. A gradiens számítása CNN segítségével

*Megmutattam, hogy az egyrétegű CT-CNN un. adjoint vagy reciproc hálózata - amely az eredeti hálózat deriváltját számolja ki valamely lineáris template-paraméterre - maga is egy egyrétegű CT-CNN lineáris template-tel, de módosított kimeneti függvénnyel, bemenettel és template-kkel. Így a CT-CNN gradiensei egy másik CT-CNN-nel vagy magával számolható.*

Az (4)-(6) egyenletek 3 különböző CT-CNN-t írnak le, amelynek állapotváltozói  $dpx$ , kimeneti változója  $dpy$ , bemenete pedig  $y, u$  vagy  $0$  a típustól függően. A template-jei speciálisan származnak az eredeti template-kből, a kimeneti függvénye pedig az eredeti függvény deriváltjából és az eredeti állapotváltozóból tevődik össze.

Ezek az un. reciprok hálózatok kiszámítják az eredeti hálózat deriváltjait. Az reciprok hálózat származását az eredeti hálózatból ugyanaz, mint a DT-CNN esetében, és az 1. táblázat mutatja.

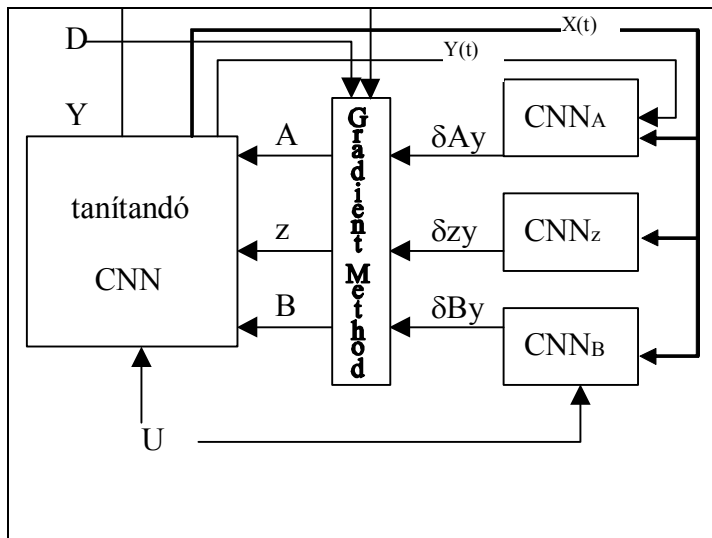
A gradienst egy egyszerű képlet alapján lehet a deriváltból számolni:

$$\frac{dE(p)}{dp} = - \sum_i \sum_j (d_{i,j} - y_{i,j}(T)) \frac{dy_{i,j}}{dp}(T) = - \sum_i \sum_j (d_{i,j} - y_{i,j}(T)) dpy_{i,j}(T)$$

ahol  $d$  a kívánt kimenet,  $y$  a tényleges kimenet és  $T$  az az idő, ahol a végső kimenetet vettük.

### 1.2.2. A tanító-rendszer

Az 1. ábra egy olyan rendszert mutat be, amely gradiens alapú tanulásra képes. A  $CNN_A$  jelölés 9 A típusú reciprok hálózatot jelöl, a  $CNN_B$  9 B típusú reciprok hálózatot, és a  $CNN_z$  egy z típusú reciprok hálózatot.



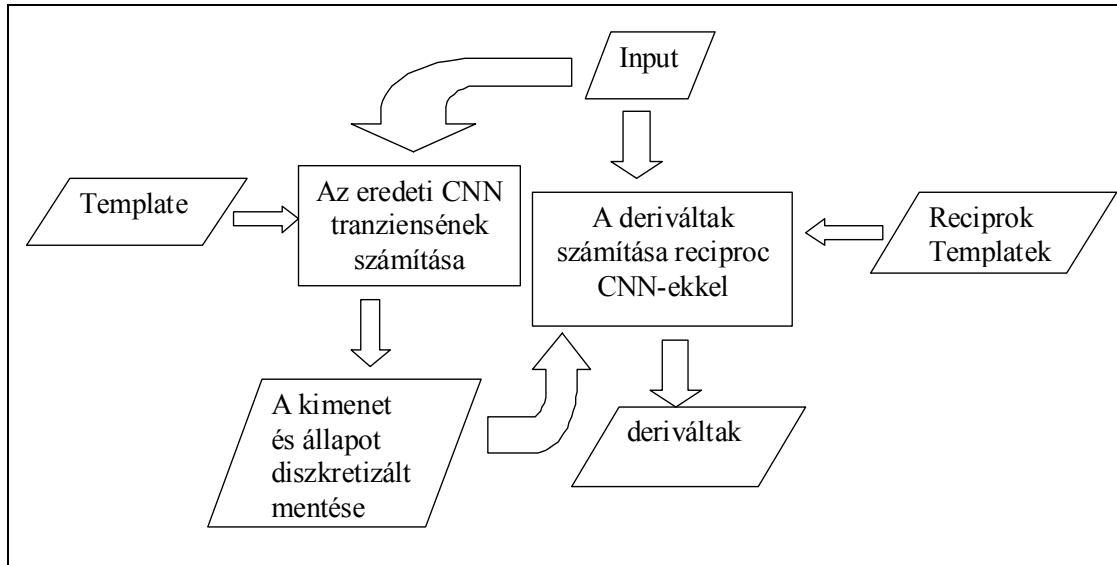
2. Ábra A CT-CNN felügyelt tanítása reciprok CT-CNN-ek segítségével.  $D$  a kívánt kimenet,  $Y(t)$  a tényleges kimenet a  $t$  időpontban,  $X(t)$  az állapot változó az  $t$  időpontban,  $U$  a bemenet. Mindegyik változó mátrixot jelöl.  $\delta A_y$ ,  $\delta z_y$  és  $\delta B_y$  19 megfelelő deriváltat jelöl,  $CNN_A$ ,  $CNN_B$  és  $CNN_z$  pedig a 19 reciprok hálózatot.

### 1.2.3. A gradiens közelítő számítása chipen

*A CNN-UM felhasználásával kifejlesztettem egy módszert, amellyel közelíteni lehet a gradiens számítását, és a jelenlegi chipen teszteltem azt.*

Ha külön chip áll rendelkezésre az eredeti és a reciprok hálózat számára pontos gradiens számítás végezhető. A közelítő számításra akkor van szükség, ha az eredeti CNN számítását és a reciprok hálózatokat egyetlen chipen akarjuk megvalósítani. Az eredeti tranziens folytonos tranziensét ilyenkor közelíteni kell időbeli diszkretizálással (ld. 3 ábra). Ugyanis ha a gradienst ugyanazon a chipen akarjuk számolni, akkor a folytonos idejű tranziens nem tárolható a gradiens számításhoz. Kézenfekvő, hogy e helyett időben diszkretizált változatát tároljuk. Ennek lehetőségét teszteltem, és megfelelőnek bizonyult.





3. Ábra A gradiens közelítő számítása CNN-UM algoritmussal és időbeli diszkrétizálással. az eredeti CNN kimenetét és állapotát analóg memóriákban elmentjük, és a reciproproc hálózatokban használjuk. A reciproproc hálózatnak származtatott reciproproc template-jei vannak és kiszámítja a deriváltakat.

## 2. Interaktív, tartalomvezérelt, adaptív (CDA) képalkotás ([2],[3],[4],[6] és 6. fejezet)

Bevezettem egy interaktív, tartalom által vezérelt, adaptív képalkotási módszert. A módszer célja olyan képalkotás, amelyet a kép tartalma adaptív módon vezérel. A módszer általánosságban írja le, hogy hogyan programozzuk a képalkotó eszközt lokálisan a kép regionális minőségi mértékét használva. A módszer eredménye egy olyan kép ahol ez a minőség jobb lesz.

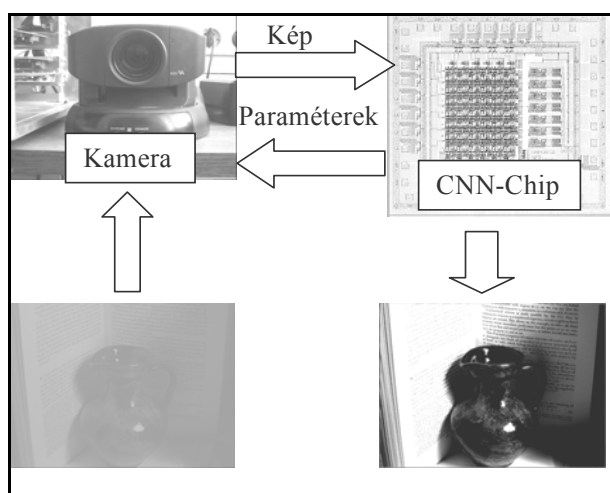
Egy adaptív képalkotási eljárást dolgoztam ki olyan jelenetekhez, ahol a megvilágítás és kontraszt minősége térben változik. A képalkotás adaptív, és függ a regionális képminőségtől, ami intenzitás és kontraszt információn alapul. A módszer kiegyenlíti a kontrasztot és intenzitást és ezúton elkerüli a túltelítődést. A regionális minőség kiszámítására egy CNN algoritmussal történik, amely kontraszt és diffúziós templatet használ.

A módszert interaktívnak nevezem, mivel a szenzorok lokálisan állíthatóak, így visszahatás lehetséges. Tartalomvezérelt, mivel a programozás a kép tartalmától fog függeni. Végül adaptív, mivel a programozást a céllal végezzük el, hogy a képalkotás a regionális változásokra adaptív legyen. Ezzel a módszerrel a specifikált tartalmat javítjuk fel. Az általános módszert a következőképpen vázolhatjuk:

- (i) Az előzőleg beállított paraméterekkel egy képet alkotunk
- (ii) A tartalomtól függő minőséget pontról pontra és real-time számítjuk.
- (iii) A globális és lokális paramétereket a minőségtől függően állítjuk be

Az eszköz és a paraméter technikai lehetőségei szerint az (i) - (iii) lépések lehetnek folyamatos vagy diszkrét idejű interakcióban. Például ha a paraméter lokális

kontraszt, akkor egy kicsi, állandó kontraszttal vett próbakép alapján állíthatjuk be a végső expozíció kontrasztját lokálisan. Ha azonban a paraméter az expozíciós idő, akkor lehetővé válik az expozíció folyamatos kontrollálása, és az expozíció lokális leállítása, ha a képpont megfelelő.



4. ábra Interaktív, tartalomvezérelt, adaptív képérzékelés lokálisan programozható képalkotó eszközzel. A képalkotó eszközt (ez esetben kamera) a CNN által a képből kiszámított információ alapján programozzuk. A cél olyan kép alkotása, amely javított minőségű.

A CNN-UM alkalmazását a regionális minőség kiszámításához szükséges nagy kapacitás indokolja. A jelenlegi digitális technikával csak lokális és globális információt lehet felhasználni adaptív eljárásokban, ami nem elégséges. A regionális számítások viszont jóval több kapacitást igényelnek. A CNN-UM párhuzamos számítási eszközként ideális ezen nehézség leküzdésére. Így egy CNN-UM-re alapozott intelligens érzékelő ideális megoldás adaptív képérzékeléshez.

A változó megvilágítási körülmények egy kép kontraszt és intenzitása változó lehet területileg. Az algoritmusom - a lokális kontraszt kiszámítása után - diffúzió területi képminőséget számol, amely regionális kontraszt- és intenzitás-információn alapul.

$$Q(x, y) := c_1 D((I(x, y) - I_a)^2) + c_2 D(C^2(x, y))$$

ahol  $I$  az input és egyben intenzitás,  $I_a$  az átlagos intenzitás,  $C$  a kontraszt és  $D$  a diffúziós operátor.

Ezen információ felhasználásával, a képalkotó eszköz paraméterét állítjuk be lokálisan. A beállítás módja függ a paraméter fajtájától. Egyik lehetőség, hogy a paramétert úgy állítjuk be, hogy  $Q$ -t maximalizáljuk, a másik, hogy úgy, hogy egy minőségi határértéket érjünk el. A választás technikai lehetőségektől függ. A módszer egy olyan képet eredményez, amely intenzitásban kiegyenlítettebb és a túltelítődést elkerüljük.

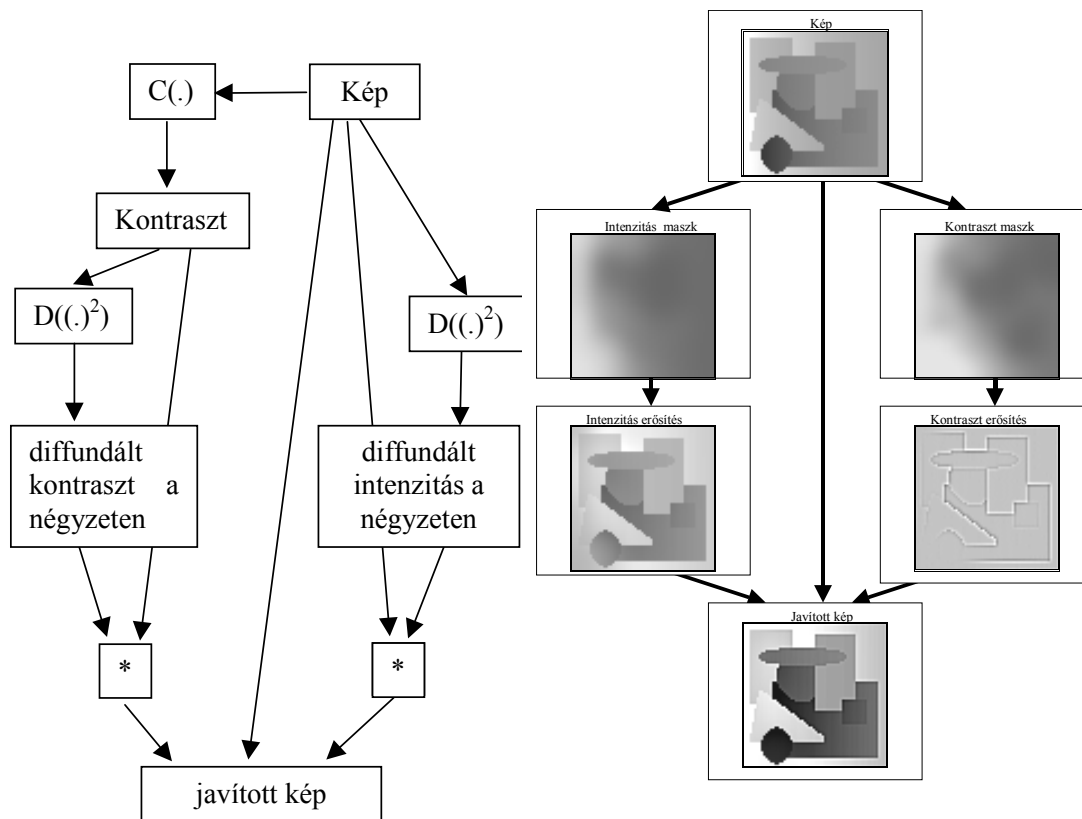
A módszer az adaptív CNN-UM architektúrára lett tervezve [15], amely hamarosan megjelenik. A jelenlegi architektúrán is megvalósítható.

### 3. Adaptív képjavítás CNN segítségével ([2],[3],[4],[6] és 7. fejezet)

Két adaptív képjavítási módszert dolgoztam ki. Mindkettő regionális intenzitás- és kontraszt-számításon alapul. Mindkét módszer célja a kontraszt és intenzitás javítása, kiegyenlítése a túltelítés elkerülésével.

#### 3.1. Statikus módszer

Egy statikus képjavítási módszert dolgoztam ki, amely diffúziós és kontraszt template-kből, illetve aritmetikai műveletekből áll. A módszer intenzitást és kontrasztot javít egy olyan szűrőn keresztül, amely a túltelítődést akadályozza. a módszer a jelenlegi CNN-UM chipen megvalósítható, de a tervezett adaptív chip előnyeit is ki tudja használni.



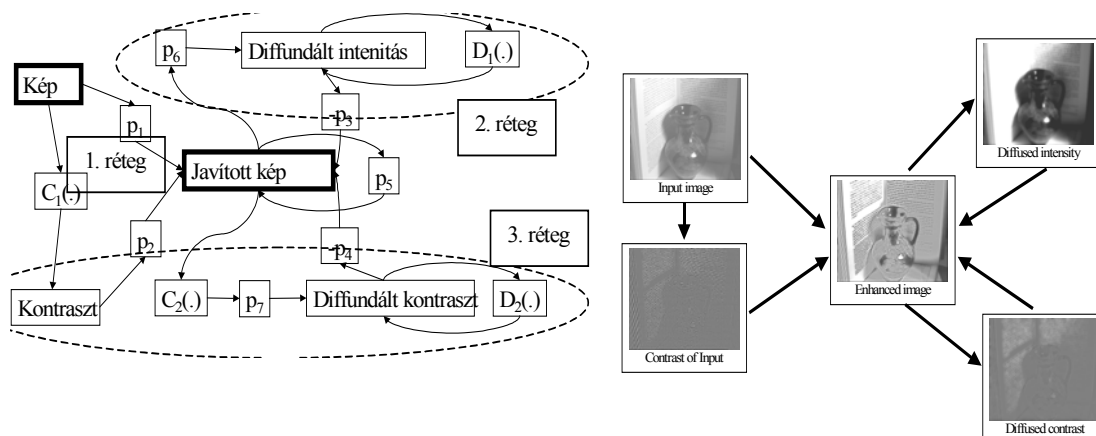
5. ábra A statikus algoritmus és képekkel való illusztrálása

Az 5. ábra a statikus módszert ábrázolja. a kontraszt-javítás rész kontraszt-számításból áll, majd erre diffúziót alkalmazunk, ebből kiszámítjuk a maszkot, és végül a kontrasztot úgy erősítjük, hogy ezt a maszkot szűrőként használjuk, hogy a túltelítődést elkerüljük. Ehhez hasonlóan a intenzitás-erősítés részénél az intenzitást diffundáltatjuk, ebből kiszámítjuk a maszkot, amelyet az intenzitás erősítésénél szűrőként használunk.

Ezt az egylépéses módszert könnyen megvalósíthatjuk az Adaptív Kiterjesztett CNN-UM Cellában ([17]). azonban a jelenlegi architektúrán is implementálható, ha a térben változó template-t kiváltjuk néhány aritmetikai művelettel.

### 3.2. A dinamikus módszer

Egy dinamikus módszert is kifejlesztettem, amelyet egy többrétegű/komplex-cellás architektúrán lehet megvalósítani. Az eredmény négy egymásra ható komponens egyensúlyaként jön létre. A négy komponens az intenzitást, a kontrasztot, a regionális intenzitást és kontrasztot reprezentálják. Az erősítő és gátló behatások egy olyan képet eredményeznek, amelynek kontrasztja és intenzitása erősített, ugyanakkor kiegyenlített.



6. ábra A többrétegű képjavító rendszer illusztrációja és folyamatábrája

A 6. ábra a dinamikus képjavító módszert mutatja. Az eredmény egy többrétegű rendszer egyensúlyi állapotaként adódik. A kimenetet több tényező befolyásolja. Először a bemenet intenzitása, amely a  $p_1$  súlyon keresztül erősítőleg hat. Másodsor, a kiszámított kontraszt, amely a  $p_2$  súlyon keresztül kontraszt erősítést eredményez. Harmadszor, az aktuális intenzitás diffúziója egy negatív  $-p_3$  súlyon keresztül hatva megakadályozza az intenzitás túltelítődését. Végül pedig az aktuális kontraszt a  $-p_4$  súlyon keresztül akadályozza a kontraszt túlvezérlését.

A dinamikus algoritmus megvalósítása egy real-time, térben változó template-t szükségeltet. A közeljövőben valószínűleg csak az intenzitás erősítés és kiegyenlítés rész valósítható meg, de ez már egy jelentős módszer magában is. Ez a rész a másodrendű komplex cellával lesz megvalósítható, melyet terveznek [16].

### Az eredmények alkalmazása

Az első tézis eredményei általánosságban a CNN tanításához kapcsolódnak. A gradiens gyors számítása lehetővé teszi egy kompakt, öntanuló, adaptív rendszer kifejlesztését. A CNN-tanítás eddig csak külső számítógép alkalmazásával volt lehetséges, ami lassú, és off-line. Fejlesztéssel a real-time adaptivitás és tanulás válik elérhetővé, ahol a szükséges tanulási algoritmusok ugyanabba a hardverbe vannak integrálva. Ez azzal vált lehetővé, hogy a gradiens számítását magával a CNN-nel végezzük el.

A Real-time tanulás ott válik fontossá, ahol példák alapján, gyorsan új template-eket kell fejleszteni vagy beállítani. Ebben az esetben az adaptivitás is megoldható tanítással: a template-k gyorsan alkalmazkodnak a speciális feltételekhez. Például képzeljünk el egy képfeldolgozási feladatot, ahol a kép valamely befolyásoló másodlagos tulajdonsága változik. A hagyományos módszer olyan algoritmus kidolgozásából áll, amely robosztus, azaz kezelni tudja ezt a változást. De ennek határai lehetnek a technológia miatt. Real-time tanulás segítségével egy egyszerű

algoritmussal is megoldhatjuk a problémát, amelynek template-jeit alkalmanként állítjuk be minták alapján.

Tipikus alkalmazás lehet egy olyan felügyeleti és biztonsági rendszer, ahol az érzékelt képet CNN segítségével feldolgozzuk. Az algoritmus template-jeit a bevetési hely speciális körülményeihez állíthatjuk be on-line tanulás segítségével, tesztképekkel.

A második tézis egy adaptív érzékelési módszert mutatott be. Egy természetes alkalmazása az, ha a CNN technológiát érzékelő eszközökbe beépítjük, és ezzel egy CNN-UM alapú intelligens érzékelőt kapunk. Ez az érzékelő kereskedelmi videó kamerákban és fényképezőgépekben is szükséges lehet, de még inkább elengedhetetlen olyan alkalmazásokban, ahol kifejezetten szélsőséges megvilágítási körülmények vannak. Ilyen például az űrkutatás, víz és föld alatti kutatás.

A CNN-UM által felmutatott számítási kapacitás a real-time működést olcsón teszi lehetővé. Ez a megoldás egyúttal azt a lehetőséget is magában foglalja, hogy mivel univerzális architektúrán alapul, további képfeldolgozás is olcsón beépíthető az eszközbe, ha az már alkalmazásra került.

A 3. tézis egy jó példa erre, hiszen egy további képjavító algoritmus építhető be az érzékelés után. De természetesen kész képekre is alkalmazható. Ez a módszer oly módon is alkalmazható, hogy a CNN-UM egy grafikus kártyaként beépül a személyi számítógépekbe és további algoritmusokhoz is rendelkezésre áll. A CNN kutatást összegezve azt láthatjuk, hogy egy képfeldolgozási program szinte összes feladatában alkalmazható a CNN-UM. A képek látványának javítása olyan alkalmazásokban a legfontosabb, ahol képek alapján emberek végeznek fontos döntéseket. Ilyen például az orvosi képi informatika.

## Köszönetnyilvánítás

Szakmai téren legelső és legfőbb köszönet témavezetőmet, Roska Tamás professzor urat illeti, aki az Analogikai Laboratórium vezetője is egyben. Azonban tanárként is köszönettel tartozok Neki, hiszen a számítástudomány ezen témájában és néhány más témában is felkeltette az érdeklődésemet még egyetemi tanárként. Szeretnék továbbá köszönetet mondani néhány – első ránézésre mellékesnek látszó, de igen fontos – részletért is: a szinte zavartalan technikai körülményekért, azért, hogy csak tanítással és kutatással kellett foglalkoznunk, hogy önálló laboratóriumban, szellemi és egzisztenciális értelemben „védett helyen”<sup>2</sup> dolgozhattunk.

A laboratóriumi munkatársaimnak is köszönettel tartozom, hiszen mind a kutatásban, mind tanulmányaimban néha segítségre szorultam. Ugyanakkor a labor szelleme és jó légköre számomra nagyon fontos körülmény. Közülük különösen hálás vagyok Török Leventének, Orzó Lászlónak és Gál Viktornak, akik a dolgozatomat átnézték és igen kritikus bírálatukkal minőségének javításában sokat segítettek. Munkatársaim közül Viktorral és Leventével közelebbi barátságba is kerültem, ami alkalmat adott néhány még mélyebb szakmai beszélgetésre, illetve emberi értékekéikért is hálával tartozom.

A Ph.D. tanulmányi részében sok tanárnak tartozom köszönettel. Közülük Lőrincz Andrásnak különösen, hiszen a neurális hálózatok gradiens-számításában olyan eredményekre hívta fel figyelmemet, amelyek esszenciálisak voltak az első tézisben. Nem csak tanárom volt, hanem egy nyáron megkíséreltünk egy közös kutatást,

---

<sup>2</sup> Ez a kifejezés célzás a tudományfilozófiai „védett tér” elméletére, amely szerint a tudománynak fontos eleme az autonómia, és ennek megfelelően mind szellemi, mind egzisztenciális értelemben a védett hely megléte, ahol ez az autonómia biztosítva van.

amelynek során mesterséges intelligenciából, optimalizálásból sokat tanultam, és elmélyítettem korábbi elképzeléseimet.

Egy Ph.D. nem a posztgraduális fázisban kezdődik, az alapok sokkal előbbre nyúlnak vissza az ember életében. Ezek közül néhány fontos személyt meg kell említenem, akik nélkül semmiképpen nem érhettem volna el ezeket az eredményeket. Köszönettel tartozom Veszprémben az egyetemi tanárainknak, közülük különösen témavezetőmnek Friedler Ferencnek, hiszen már akkor lehetőségem nyílt kutatásokat végezni, és e szakma művészetében Őtőle tanultam először nagyon sokat.

A tudományos gondolkodás kialakulása viszont még ennél is korábban eredeztethető. Nobel-díjasaink életrajzában legtöbbször egy-egy gimnázium szerepel, amely nagyon meghatározó elem. Szerényebb eredményeimre is hasonló „törvény” igaz: A veszprémi Lovassy László Gimnáziumban erős képzésben volt részem nemcsak a reál tárgyakban, de történelemből, irodalomból is olyan alapokat kaptam, amely gondolkodásmódom egészében tükröződik. Matematika tanárom Jakab Ilona volt. Őtőle tanultam meg az absztrakt racionális gondolkodás emberi értékét, hogy micsoda fegyver, amikor valami homályosnak látszó dolgot definiálni tudunk, és formális eszközökkel kezelni. Kevés emléket őrzök régmúltamból, de ezek között vannak azok az esték, amikor lakásán készültünk az OKTV-re, és mindig volt valami finomság, érdekes csecse-becse, beszédtema is.

A Ph.D.-hez vezető út, az ember életében nem egy „külön” út, hanem beágyazódik az ember személyes fejlődésébe. Így minden barátnak és barátnőnek köszönetet mondhatok, akiktől valamit is tanultam. És kitől ne tanulhatna az ember legalább egyvalamit? Nehéz volna mindenkit felsorolni egy mértékletes terjedelemben, listázás nélkül is remélem, tudja minden ismerősöm, hogy mit köszönhetek neki.

A személyes fejlődés legfontosabb gyökere azonban a család: nekem édesapám, édesanyám és húgom. Szüleimnek sokat köszönhetek nem csupán a személyes, hanem bizony a tudományos érdeklődés szempontjából is. Emlékszem, hogy már igen fiatal koromban érdekes fizikai és kémiai könyveket olvastam, mert a polcon ilyenek voltak. Ezek vezettek tovább a könyvtárba, a könyvtár a gimnáziumba, a gimnázium az egyetemre... Már akkoriban lenyűgözött a kozmológia, elemi részecske fizika (...) egyszerűen a tudomány csodája. Se csillagász, se űrhajós, sem atomfizikus nem lettem: azóta ez már csak személyes érdeklődés, és a szakmai pályám - saját döntésem alapján - más irányba fordult. Ám valahol akkor kezdődött minden...

## A szerző publikációi

[1] **M. Brendel**, Gusztáv Bártfai, Tamás Roska, "Reciprocal CNN gradient computing for back-propagation-through-time learning of cellular neural networks", Research report of the Analogic (Dual) and Neural Computing Systems Laboratory, (DNS-5-1999), Budapest, MTA SZTAKI, 1999.

[2] **M. Brendel**, "Adaptive image sensing and enhancement using the Cellular Neural Network Universal Machine", Research report of the Analogic (Dual) and Neural Computing Systems Laboratory, (DNS-9-2000), Budapest, MTA SZTAKI, 2000.

[3] **M. Brendel**, T. Roska, "Adaptive Image Sensing and enhancement using Adaptive Cellular Neural Network Universal Machine", Proceedings of IEEE Int. Workshop on Cellular Neural Networks and Their Applications, (CNNA'2000), pp. 93-98, Catania, 0-7803-6344-2, 2000.

[4] **M. Brendel**, T. Roska, "Adaptive image sensing and enhancement using the cellular neural network universal machine", International Journal of Circuit Theory and Applications, vol. 30, pp. 287-312, 2002.

[5] **M. Brendel**, T. Roska and Gusztáv Bártfai, " Gradient computation of continuous-time Cellular Neural/Nonlinear Networks with linear templates via the CNN Universal Machine", *Neural Processing Letters*, vol. 16, pp. 111-120, 2002.

[6] **M. Brendel**, " Adaptív képérzékelés CNN-UM segítségével ", Research report of the Analogic (Dual) and Neural Computing Systems Laboratory, (DNS--2002), Budapest, MTA SZTAKI, 2002.

[7] T. Roska, L. Kék, L. Nemes, Á. Zarándy, **M. Brendel** and P. Szolgay (eds.), "CNN Software Library (Templates and Algorithms) Version 7.2", Research Report (DNS-1-1998), Analogical and Neural Computing Laboratory, MTA SZTAKI, Budapest 1998.

[8] J. Hámori, and T. Roska (ed.), D. Bálya, Zs. Borostyánkői, **M. Brendel**, V. Gál, J. Hámori, K. Lotz, L. Négyessy, L. Orzó, I. Petrás, Cs. Rekeczky, T. Roska, J. Takács, P. Venetiáner, Z. Vidnyánszky, Á. Zarándy, „Receptive Field Atlas the Retinotopic Visual Pathway and some other Sensory Organs using Dynamic Cellular Neural Network Models”, Research report of the Analogic (Dual) and Neural Computing Systems Laboratory, (DNS-8-2000), Budapest, MTA SZTAKI, 2000.

## **A tézisek bevezetéséhez használt egyéb publikációk**

[9] L. O. Chua and L. Yang, "Cellular Neural Networks: Theory and Applications", *IEEE Transactions on Circuits and Systems*, Vol. 35, pp. 1257-1290, 1988.

[10] T. Roska and L. O. Chua, "The CNN Universal Machine: An Analogic Array Computer", *IEEE Transactions on Circuits and Systems-II*, Vol. 40, pp. 163-173, 1993.

[11] W. K. Pratt, "Digital Image Processing", John Wiley & Sons Inc., 1991.

[12] S. M. Smirnakis, M. J. Berry, D. K. Warland, W. Bialek and M. Meister, "Adaptation of retinal processing to image contrast and spatial scale" *Nature*, vol. 386, pp. 69-73, 1997.

[13] J. A. Nossek "Design and learning with cellular neural networks" *Proceedings of (CNNA-94)*, pp. 137-146, 1994.

[14] F. Beaufays and E. Wan, "A Unified Approach to Derive Gradient Algorithms for Arbitrary Neural Network Structures", *Proc. ICANN'94*, vol. 1, pp. 545-548, Sorrento, Italy, 26-29 May 1994.

[15] T. Roska, "Computer-Sensors: spatial-temporal computers for analog array signals, dynamically integrated with sensors", *Journal of VLSI Signal Processing Special Issue: Spatiotemporal Signal Processing with Analogic CNN Visual Microprocessors, (JVSP Special Issue)*, pp. 221-238, vol. 23, No.2/3, November/December 1999, Kluwer

[16] Cs. Rekeczky, T. Serrano-Gotarredona, T. Roska, and A. Rodriguez-Vazquez "A stored program 2<sup>nd</sup> order/ 3-layer complex cell CNN-UM", *Proceedings of the 6<sup>th</sup> IEEE International Workshop on Cellular neural Networks and their Applications (CNNA-2000)*, Catania, pp. 213-217, 2000.

[17] T. Roska, "Analogic CNN computing: Architectural, Implementational and Algorithmic Advances – a Review", *Proceedings of the 4<sup>th</sup> IEEE International Workshop on Cellular neural Networks and their Applications (CNNA-1996)*, 14-17 April, London, pp. 3-11, 1998.