

Stabilitás, Optikai Folyam Számítás és Sztochasztikus
Rezonancia Számítások
Celluláris Hullám Számítógépen

Török Levente

Ph.D. Disszertációjának tézis füzet

Témavezető

Ph.D. Zarándy Ákos

Analogikai és Neurális Számítások Laboratórium,
Magyar Tudományos Akadémia – Számítástechnikai és
Automatizálási Kutató Intézet

2005

Tartalomjegyzék

1 Bevezetés.....	4
2 Sok-rétegű CNN hálózatok stabilitása.....	6
2.1 A főbb kérdések.....	6
2.2 Módszerek.....	6
2.3 Főbb eredmények	
Első tézis: Sok-rétegű Celluláris Nem-lineáris/Neurális Hálózatok stabilitása.....	8
3 Optikai Folyam Becslése.....	11
3.1 A főbb kérdések.....	11
3.2 Módszer az Optikai Folyam Becslésének a Rosszul Kondicionáltságának Feloldására.....	11
3.3 Főbb eredmények	
Második tézis: Analóg VLSI alapú, Multi-skálás Optikai Folyam becslés.....	14
4 Sztochasztikus rezonancia.....	17
4.1 A főbb kérdések.....	17
4.2 Módszer: Az Integro-differenciális rendszerek konstrukciója.....	18
4.3 Főbb eredmények	
Harmadik tézis – I. rész: A Sima Sztochasztikus Rezonancia.....	20
4.4 A főbb kérdések: Tér-időbeli sima Sztochasztikus Rezonancia.....	21
4.5 Módszerek.....	21
4.5 Főbb eredmények:	24
Harmadik tézis – II. rész: CNN alapú Sima Sztochasztikus Rezonátor	

5 Publikációk.....	25
5.1 Folyóirat cikkek.....	25
5.2 Konferencia cikkek.....	26
5.3 Riportok.....	27
5.4 Referenciák.....	27
6.5 Díjak.....	29

1 Bevezetés

A nagy-sebességű számítástechnikában (HPC) régóta folyik ádáz küzdelem az optimális számítási architektúra megtalálásáért és annak optimális fizikai megvalósításáért, amelyet leginkább a Moore¹ törvény érvényességének feltehető korlátossága erősített fel (lásd. [14]).

Ezen feltehető korlát miatt, az architektúrális kérdések kulcsszerephez jutottak. Ennek következtében új architektúrájú eszközök jelentek meg. Ezek közös jellemzője, a korábbi soros végrehajtású eszközökkel szemben - amelynek megalkotása elsősorban Neumann János nevéhez fűződik - a párhuzamosság. A párhuzamosság fokától függően beszélhetünk erősen párhuzamos (VLIW - Very Long Instruction Word, azaz nagyon hosszú utasítás szélességű, multi pipelined – sokszorozot pipeline-ú architektúra) vagy celluláris architektúrájú (mely utóbbi úgyszintén Neumann János nevéhez köthető) eszközökről. Ez utóbbin, egyszerű számító elemek négyzetrácsba rendezett struktúráját értjük, melyben ezen elemek a rács élein keresztül kommunikálnak egymással. Annak ellenére, hogy a számító elemek lassabbak és képességeikben rendszerint jóval szerényebbek, mint egy hagyományos soros processzor, a skálázhatóságnak köszönhetően, olyan alkalmazási területeken, ahol a számítások átalakíthatóak a párhuzamosság ilyen fokára, az celluláris architektúra gyorsabb és végeredményben sikeresebb.

17 évvel ezelőtt mutattak be egy ún. Celluláris Nem-lineáris/Neurális Hálózatot (CNN, [15]), amely több szempontból ígéretes választásnak tűnt. Ez egyszerű volt ahhoz, hogy könnyű legyen implementálni, például aVLSI-ben (analog very large scale integrated circuitry, nagy integráltságú analóg áramkör), mégis általános ahhoz, hogy nehéz számítási feladatokat is meg lehessen oldani vele. A celluláris számítógépet, amelyet korábban

1 “A Moore törvény azt az empirikus észrevételt rögzíti, miszerint a jelenlegi technológiai fejlődés mellett, a minimális költséggel előállított integrált áramkörök komplexitása megkétszereződik minden 24 hónapban.” [en.wikipedia.org]

CNN-Univerzális-Gépnek hívtak (CNN-UM – CNN-Universal-Machine, [16]), azzal a céllal alkották meg, hogy a CNN-t leíró differenciál egyenlet rendszert algoritmikusan programozhatóvá tegyék és ezzel kiaknázzhatóvá váljon a CNN tér-időbeli dinamikájában rejlő számítóképesség. A CNN-UM aVLSI implementációjára egy optikai érzékelő tömböt is építettek, melynek segítségével a cellákba párhuzamosan lehet optikai információt bejuttatni. Innen származik az eszköz közkeletű neve is a „vizuális mikroprocesszor”. Segítségével, szilícium alapú, emlős retina modellezési kutatások is folynak.

Tekintettel arra, hogy a CNN-t egy időben folytonos differenciál egyenlet rendszer írja le, az analóg VLSI implementáció kézenfekvő, ugyanakkor más implementációk is napvilágot láttak, mint például az optikai vagy az emulált digitális. Különösen az analóg implementáció okán központi kérdéssé válik a kezelhetőség, a megbízhatóság és a kézben tarthatóság, amelyek természetes elvárások egy algoritmikusan programozható eszköztől. Így a CNN minőségileg helyes viselkedésének biztosíthatósága, adott esetben sztochasztikus leírása és a mindig jelen levő zajjal szembeni optimalizáció lehetősége a disszertációm központi kérdése.

2 Sok-rétegű CNN Hálózatok Stabilitása

2.1 A főbb kérdések

Differenciál egyenlet rendszerek által vezérelt analóg, tér-időbeli rendszereket legtöbbször nem egyszerű kézben tartani és tulajdonságaikat kiaknázva működését a hasznunkra fordítani. Ebből a szempontból a rendszer stabilitása kulcs kérdés. Ennek megfelelően, a CNN megjelenése óta, sok dolgozat foglalkozott a CNN stabilitási kérdéseivel.

Az eredeti CNN-ben a számító elemeket egy rétegben helyezték el. A korábban is említett emlős retina modellezési kísérletek indokoltá tették egy sok-rétegű CNN architektúra - az ún. CACE architektúra [17] - megtervezését és aVLSI implementálását. Bár az áramkör el készült, nem sok tapasztalat vagy elméleti eredmény volt ismert az új eszköz stabilitásáról, azaz történetesen arról, ami kulcs kérdésként merül fel annak megítélésében, hogy mire és hogyan lehet felhasználni az áramkört. Látható tehát, hogy nagy szükség volt arra, hogy a mérnöki gyakorlatban is jól használható szabályok készüljenek arra, hogy egyáltalán milyen tartományban érdemes a rendszer paramétereit (template-eket) hangolni, azaz hogy hol lehet a számításokkal egyáltalán értelmes eredményre jutni.

2.2 Módszerek

Az olvashatóság kedvéért, megadjuk a „teljes tartományú” (Full-Range) FR-CNN definícióját (ref. [18])

$$\tau \hat{x} = -g(\hat{x}) + \hat{A} * \hat{x} + \hat{B} * \hat{u} + \hat{z}, \quad (1)$$

ahol a $*$ a konvolúciót jelenti. Ugyan ebben a modellben, a sok-rétegű CNN (MLCNN – Multi-Layer CNN), így definiálható

$$\tau_p \dot{\hat{x}}_p = -g(\hat{x}_p) + \sum_{o=1}^L \hat{A}_{op} * \hat{x}_o + \hat{B}_p * \hat{u}_p + \hat{z}_p, \quad (2)$$

ahol a p réteget, L a rétegek számosságát, τ_p a p réteg időkonstansát, \hat{A}_{op}, \hat{B}_p pedig az o rétegről a p rétegre vissza és előre csatoló mátrixokat (template-ek) jelenti. A $\hat{x}, \hat{u}, \hat{z}$ mátrixok az állapot, a bemenet és eltolást (bias) reprezentálják. Végül, a $g()$ egy nem analitikus függvény és így definiáljuk

$$g(x) = \begin{cases} 0, & , ha |x| < 1 \\ \lim_{m \rightarrow \infty} (|x| - 1) \cdot m \cdot \text{sgn}(x) & , egyébként. \end{cases}$$

Kompakt vektorok segítségével (felül hullámos felül vonallal jelöljük), a (2)-es egyenlet a 2 rétegű esetben az alábbi formát ölti

$$\begin{aligned} \tau_1 \dot{\tilde{x}} &= -g(\tilde{x}_1) + \tilde{A}_{11} \tilde{x}_1 + \tilde{A}_{21} \tilde{x}_2 + \tilde{B}_1 \tilde{u}_1 + \tilde{z}_1 \\ \tau_2 \dot{\tilde{x}} &= -g(\tilde{x}_2) + \tilde{A}_{12} \tilde{x}_1 + \tilde{A}_{22} \tilde{x}_2 + \tilde{B}_2 \tilde{u}_2 + \tilde{z}_2. \end{aligned} \quad (3)$$

Vegyük észre, hogy mátrix konkatenációval az $\tilde{A}_{op}, \tilde{B}_p$ mátrixok és a $\tilde{x}_p, \tilde{u}_p, \tilde{z}_p$ vektorok összevonhatóak egyetlen A, B, x, u, z , mátrixba, vektorba az alábbi megfeleltetéssel

$$A = \begin{pmatrix} \tilde{A}_{11} & \tilde{A}_{21} \\ \tilde{A}_{12} & \tilde{A}_{22} \end{pmatrix} \quad B = \begin{pmatrix} \tilde{B}_1 \\ \tilde{B}_2 \end{pmatrix} \quad x = \begin{pmatrix} \tilde{x}_1 \\ \tilde{x}_2 \end{pmatrix}, \dots$$

amely segítségével az (3)-as egyenletet így írhatjuk fel

$$\tau \dot{x} = -g(x) + Ax + Bu + z,$$

amely pontosan egyezik az eredeti CNN egyenlet formájával ([15]). Ez a felismerés tette lehetővé, hogy sok CNN körben ismert tételt átfogalmazzunk sok-rétegű CNN-re, MLCNN-re.

2.3 Főbb eredmények

Első tézis: Sok-rétegű Celluláris Nem-lineáris/Neurális

Hálózatok Stabilitása

A fentebb leírt módszer segítségével, egy egyszerű módszert adtam meg, aminek segítségével egy rétegű CNN köréből ismert tételek (ref. [20,21,22,23,30]) könnyen és természetes módon ültethetők át több rétegre ([2,6]). Ennek az eszköznek a használatával, számos új tételt és egy erős sejtést adtam meg kettő és több rétegű celluláris nem-lineáris/neurális hálózatok körében. A tételek kiválasztását a tételek a mérnöki gyakorlatban való felhasználhatósága vezérelte.

Egy 2 rétegű CNN *kompletten stabilis* az alábbi esetekben:

- a) **Szimmetrikus eset:** ha nemcsak azok a template-ek, amelyek egy rétegen belül (intra-layer template) működnek szimmetrikusak, hanem azok is, amelyek a rétegek között (inter-layer). Ezen utóbbiak azonban csak egymásra nézvést (ún. kereszt) szimmetrikusak.
- b) **τ -kereszt szimmetrikus eset:** ha az intra-layer template elemek szimmetrikusak és az inter-layer template elemek kereszt-szimmetrikusak legalább egy konstans szorzó tényező (ún. τ - réteg időkonstans) erejéig.
- c) **Nem szimmetrikus eset:** ha az egy ún. konstans-arány szabály teljesül az intra-layer template-ekre (mértani sorozatot alkotnak mind horizontális, mind vertikális irányban) és ugyanez a szabály érvényesül a kereszt csatoló template-ekre (lásd a példát és a disszertáció 2.6.3-as fejezetét),

d) τ -nem-szimmetrikus eset: ha a fenti tétel feltételezései bármely réteg konstans esetén fenn állnak.

Egy két rétegű CNN (2LCNN) *majdnem mindenütt stabil* (SAE – stable almost everywhere) az alábbi esetekben:

e) Előjel szimmetrikus esetben: ha az intra-layer template-ek mindegyikének előjel mintázata egy szigorúan szimmetrikus mintát követ és az inter-layer template-ek mintája ezzel megegyezik vagy ezzel ellentétes (lásd az alábbi példán)

<p>Egy példa a nem-szimmetrikus 2LCNN template-re (a “c” eset)</p> $\hat{A}_{11} = \begin{pmatrix} 0.4 & 0.4 & 0.8 \\ 0.4 & 0 & 0.8 \\ 0.1 & 0.1 & 0.2 \end{pmatrix} \quad \hat{A}_{12} = \begin{pmatrix} 1.2 & 1.2 & 2.4 \\ 1.2 & 0.3 & 2.4 \\ 0.1 & 0.3 & 0.6 \end{pmatrix}$ $\hat{A}_{21} = \begin{pmatrix} 0.4 & 0.4 & 0.8 \\ 0.4 & 0.1 & 0.8 \\ 0.1 & 0.1 & 0.2 \end{pmatrix} \quad \hat{A}_{22} = \begin{pmatrix} 1.6 & 1.6 & 3.2 \\ 1.6 & 0 & 3.2 \\ 0.4 & 0.4 & 0.8 \end{pmatrix}$	<p>Egy példa az előjel szimmetrikus 2LCNN template esetére (az “e” eset)</p> $\hat{A}_{11} = \begin{pmatrix} -1 & 0.1 & -1 \\ 0.1 & 1 & 0.1 \\ -1 & 0.1 & -1 \end{pmatrix} \quad \hat{A}_{12} = \begin{pmatrix} 0.2 & -2 & 0.2 \\ -2 & 2 & -2 \\ 0.2 & -2 & 0.2 \end{pmatrix}$ $\hat{A}_{21} = \begin{pmatrix} 0.3 & -3 & 0.3 \\ -3 & 3 & -3 \\ 0.3 & -3 & 0.3 \end{pmatrix} \quad \hat{A}_{22} = \begin{pmatrix} -4 & 0.4 & -4 \\ 0.4 & 4 & 0.4 \\ -4 & 0.4 & -4 \end{pmatrix}$
---	---

f) “Előjel mintázat nagy template-ekhez” esete: ha az inter-layer template elemek előjel váltakozási frekvenciája mind horizontális, mind vertikális irányban vagy 0 vagy 1, míg intra-layer előjel mintázata ezzel egyezik vagy ezzel ellentétes.

Majdnem mindenütt stabilitás tetszőleges számú réteg CNN esetében:

g) „Előjel mintázat nagy template-ek esetén, több mint 2 réteg esetében”: ha az inter-layer template elemek előjel váltakozási frekvenciája mind horizontális, mind vertikális irányban vagy 0 vagy 1, míg az a bizonyos mátrix, ami leírja a template-ek ehhez képesti inverzióit (ún.

előjel módosító mátrix) ún. *sakk-tábla* típusú.

1. Definíció : Egy mátrix akkor sakk-tábla típusú, ha kizárólag olyan téglalap alakú, homogén régiókból áll, amelyek csak 1-et vagy -1-et tartalmaznak, továbbá nincs két ugyanolyan előjelű régió, ami a „4 szomszédság”-gal értelmezett, kontaktusban egymással.

Például:

$$J = \begin{pmatrix} +1 & +1 & +1 & +1 & +1 & -1 & -1 \\ +1 & +1 & +1 & +1 & +1 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 & +1 & +1 \\ +1 & +1 & +1 & +1 & +1 & -1 & -1 \end{pmatrix}$$

Végül egy erős stabilitási **sejtés**, amely az 1 dimenziós CACE architektúra² körében fogalmazódott meg:

Stabil kimenet érhető el a CNN szaturált régiójában a

h) “Nem-reciprok 1D CACE” esetben: ha mind az inter-layer és mind az intra-layer template-ek előjel-anti-szimmetrikusak, valamint a visszacsatoló template-ek központi elemei nagyobbak, mint 1.

Például: $\hat{A}_{11} = (1 \quad 2.5 \quad -1)$, $\hat{A}_{12} = (-1)$, $\hat{A}_{21} = (1)$, $\hat{A}_{22} = (1 \quad 2.5 \quad -1)$

3 Optikai Folyam Becslése

3.1 A főbb kérdések

Egy részről a sztochasztikus megközelítés egy zajjal terhelt analóg rendszer

² A CACE architektúra olyan 2LCNN, aminek csak az inter-layer template-jében csak a központ elem lehet zérustól különböző.

esetében sokszor célszerűbb lehet, mint determinisztikus körülményekkel számolni és optimalizálni, másrésztől sokszor maguk a probléma felvetések kívánják meg a sztochasztikus leírást. Ez különösen rosszul kondicionált problémák esetében lehet igaz.

Sok CNN-UM chip implementáció rendelkezik nagy sebességű on-chip integrált optikai érzékelő tömbbel, továbbá egy optikával, amelynek segítségével tárgyak képét vetíthetjük a fókuszsíkban elhelyezett chip-re, a processzorra. A vizuális mikroprocesszorok körében az egyik legközismertebb feladat - gyakran a célchip-et is terveznek erre az egyetlen feladatra - az Optikai Folyam (OF) becslése.

2. Definíció: *Az optikai folyamat gyakran úgy szokás megadni, mint kép szekvenciák képmintázatainak látszólagos mozgása.*

Az általam vizsgált kérdés az volt, hogy hogyan lehet megtalálni egy az optikai folyam becslés sztochasztikus leírásában rejlő szinergiákat.


3.2 Módszer az Optikai Folyam Becslésének a Rosszul Kondicionáltságának Feloldására

Az Optikai Folyam (OF) becslésének a célja, a lehető legnagyobb pontossággal megadja azt a vektor mezőt, amely leírja tárgyak a vizuális reprezentációban történő mozgását. Legtöbbször ezt olyan vektorokkal teszik meg, amelyek a megfelelő pixeleket köti össze. Ez nem feltétlenül pontos vagy korrekt megközelítés.

A megközelítések nagyjából a következő csoportokba sorolhatóak: *fázis korrelációs alapú, blokk korrelációs alapú vagy gradiens korlátozásos alapú.* A blokk korrelációs (vagy blokk illesztéses) megközelítést, egy kép egy régiójának és a másik kép ugyanekkora régiójának korrelációs maximumaként származtathatjuk.

Hogy bemutathassuk, hogy mi is a probléma ezzel a megközelítéssel,

képzeljük el az alábbi egyszerűen megérthető kísérleti helyzetet. (lásd 1. kép). Tegyük föl, hogy a fekete téglalap a fehér háttér előtt a nyíllal megjelölt irányban mozog.



1. Ábra: Példa arra, hogy a mozgó fekete négyzet mozgását korrelációs módszer segítségével bizonyos helyeken ki lehet mutatni (1-es terület), míg ez bizonyos helyeken nehézségekbe ütközik (2,3-es területek).

Ha a módszerben használt régió jelentősen kisebb, mint a fekete téglalap, akkor nehézségekbe ütközünk a téglalap élein és a közepén. Ennek megfelelően a képet partíciókra oszthatjuk, amelyekben a vektor mező meghatározása helyenként:

- *jól definiált*, mivel korrekt korrelációs maximum létezik (1-es terület) ;
- *nem meghatározható*, mivel a korrelációnak nincs pont szerű, izolált maximuma, de a becslés egy lineáris kétértelműségig megadható (*apertúra probléma*, 2-es terület);
- *nem meghatározható*, ahol egyáltalán nincs korrelációs csúcs, annak ellenére, hogy az adott területen a mozgás jelen van (*blank wall probléma*, a 3-as terület)

A mozgás vektor becslő eljárással szemben, az OF becslők célja ezen helyzetek kiküszöbölése, amelyek ugyanakkor a mozgás vektorokban mérhető hibák legnagyobb forrása is.

Megoldásként, első ránézésre, logikusnak tűnhet nagyobb blokk (régió)

használata. Sajnos ez azonban csökkenti a módszer térbeli sávszélességét, ami pontosan ugyanannyira nem kívánatos. Jól látható tehát, hogy az ún. „pontosság – sávszélesség” dilemmával állunk szemben.

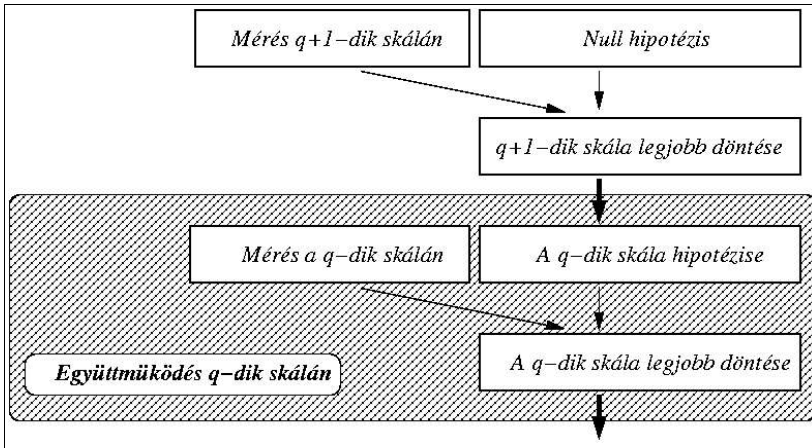
Bár, mint említettük, a nagyobb régió használata rontja a felbontást, mégis jó hipotézisként szolgálhat egy ilyen korrelációból származó vektor. Algoritmusomban kihasználtam azt, hogy ez a bizonyos vektor megegyezik azzal, mintha képeket egy más skálán – rosszabb felbontás mellett - vizsgáltam volna és onnan nyertem volna a vektor mezőt. (Ez csak akkor és csak akkor áll, ha skálázás operátora disztributálható a használt illeszkedési kritériumban, esetünkben az L_1 -ben. Részletesebben lásd a [3]-ban).

Alapvetően, ezt a blokk illesztéses megközelítést transzformáltam egy sztochasztikus megoldásba, amelyben az illeszkedés foka (azaz a DFD) fordítottan arányos az alábbi ún. likelihood függvénnyel,

$$p_q(I^{(2)}|v, I^{(1)}) = \exp\left\{-DFD(I^{(1)}, I^{(2)}, v, R_q)\right\},$$

mely kifejezésben az $I^{(1)}, I^{(2)}$ az egymást követő képekre, v a feltételezett mozgásvektorra és a R_q a q függvényében meghatározott korrelációs blokk méretére utal.

Ennek a valószínűségi megközelítésnek a segítségével megadtam a probléma egy lehetséges feloldásának rekurzív leírását (2. Ábra), amelyben több skála együttműködésekképpen remélhető, hogy a probléma megadásában rejlő dilemma feloldható és egy pontos OF becslő eljárást kaphatunk.



2. Ábra: Az új OF algoritmus rekurzív számolási sémája, amelyben a Bayes tételnek megfelelően valószínűség eloszlási függvényeket származtatunk minden skálán ez egyel nagyobb skálából.

3.3 Főbb eredmények

Második tézis: Analóg VLSI alapú, Multi-skálás Optikai Folyam becslés

Egy alapvetően új számítási eljárást adtam meg Optikai Folyamok becslésre, amely a képsorozatokban megjelenő mozgások sztochasztikus leírását egy multi-skálás keretben integrálja. Megmutattam két formalizmusban is ennek sok skálának a Bayes-i együttműködését, amely végeredményben ugyanahhoz a számolási sémához vezetett ([3,5]).

Az új algoritmus optimálisan használja ki a CNN-UM architektúráját, amelynek segítségével 3 nagyságrend gyorsítást lehet elérni a hagyományos egy processzoros digitális architektúrákhoz képest. Az algoritmus teljesítőképességére jellemző, hogy kb. 10-15 éves (ref. [28,29]), csak digitális hardware-en megvalósítható, OF algoritmusokkal összemérhető a

pontossága, de jobban teljesít, mint bármely analóg VLSI megoldás ideértve pontosságot (mind a szimulációk mind a on-chip kísérletekben), sebességet és felbontást. Mindazonáltal, az említett digitális megoldások legtöbbször olyan operációkat használnak, amelyeket nem vagy csak nagyon nehezen lehet VLSI átültetni.

A VLSI és aVLSI megoldások (ref. [24,25,26,27]) ezidáig csak alacsony felbontású, saját készítésű teszt képeket használtak teljesítmény mérésre, amelyek így legfeljebb csak a koncepció igazolására voltak alkalmasak. Megoldásomat elviselhető felbontás mellett teszteltem (128x128) egy standard benchmark képszekvencián (Yosemite, lásd 3. ábrán), amely a legelfogadottabb OF teljesítmény mérő alkalmazás a világ vizuális/képi információ számítógépes feldolgozásával foglalkozó közösségében.

A pontosságról elmondható, hogy a hiba vektor hossza (AVE – average vector norm error) átlagosan kisebb, mint egy pixel és az átlagos szöghiba (AAE – average angular error) kb. 10 fokos. Meglepő, hogy a chip-en futtatott eredmények milyen jól illeszkednek a szimulációkhoz (AAE ≈ 3.5 fok).


A digitális megoldásokkal szemben, on-chip megoldásom 100 képet is képes feldolgozni másodpercenként (ld. 4. Ábra), ami, a másodpercenként feldolgozott pixelek számát tekintve, nagyságrendekkel gyorsabb, mint bármely OF megoldás, ráadásul a felhasznált eszköz (CNN-UM) egy általános célú hardware, a legtöbb aVLSI cél-hardware-rel szemben. Az algoritmust sikeresen teszteltük valós alkalmazásokban felvett videó szekvencián, amelyet például automatikus ütközés megelőző alkalmazáshoz készítettünk (5. Ábra).



3. Ábra: A klasszikus Yosemite videó szekvencia, a becsült optikai folyam vektorokkal együtt. A képsor egy szintetikus szekvencia, amelyben a kamera egy völgy fölött „repül”, oly módon, hogy a horizont jobb sarka fixált. A kis vektorok a lokálisan érzékelhető mozgás irányába mutatnak.

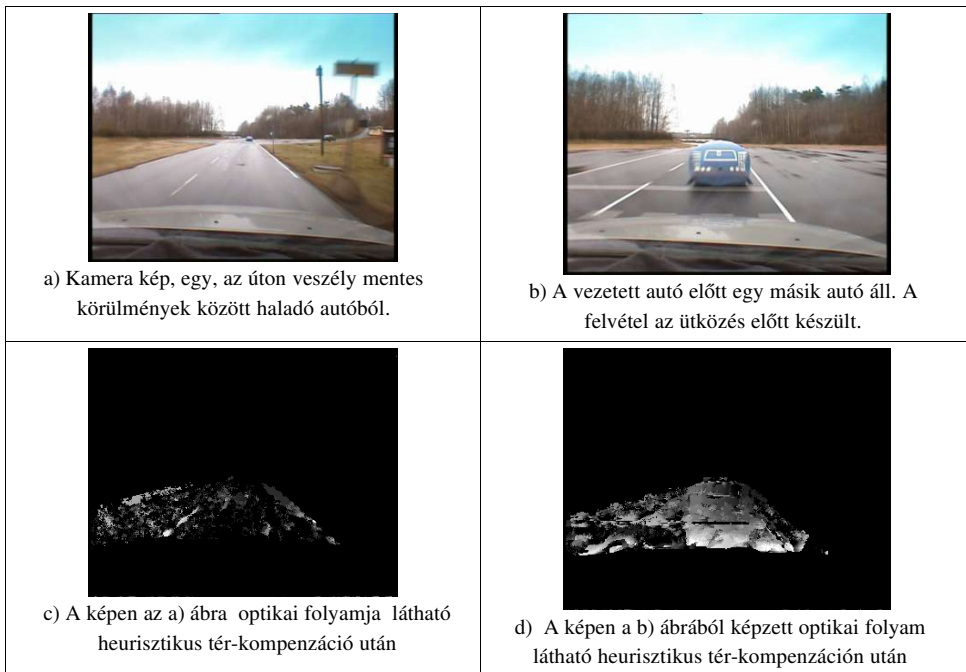


a) A tablettá dél, dél-keleti irányba (↘) mozog nagy sebességgel.



Az a) ábrán érzékelhető OF on-chip becslése: a vektorok a lokálisan mérhető mozgásvektorok irányába mutatnak.

4. Ábra: A kép rögzítés on-chip 1/1000 sec, a OF becslés 1/100 sec



5. Ábra. Ütközés detekciós teszt alkalmazás. Vegyük észre a d) ábrán az a) ábrához képest megnövekedett intenzitásokat. Ha ezen intenzitások pixelenkénti összege meghalad egy korlátot, figyelmeztető vészjelzés küldendő a vezetőnek.

4 Sztochasztikus rezonancia

4.1 A főbb kérdések

Legtöbb mérnök számára a zaj egy kellemetlen korlátozó tényező. Ez a felfogás bizonyos rendszerekre nem helyt álló. A sztochasztikus rezonátorok (SRT) például zaj segítségével valósítanak meg jeltovábbítást.

3. Definíció: A sztochasztikus rezonancia (SR) egy olyan jelenség, amelyben egy rendszer, amelynek a bemenetére jel és zaj keveréket bocsátunk, a kimenetén a jel-zaj viszonyban (SNR) jól definiált

maximumot mutat a bemeneti zaj effektív értékének (RMS) függvényében.

Bár a sztochasztikus rezonanciát már régóta ismerték, a használhatóságát mégis erősen korlátozta az a tény, hogy minden ilyen rendszer „hirtelen” ugrásokkal válaszolt a kimenetén.


Így tehát a kérdés, amivel foglalkoztam az az volt, hogy vajon ezt a kellemetlen tulajdonságot el tudjuk-e kerülni valami módon vagy sem.

4.2 Módszer: Az Integro-differenciális rendszerek konstrukciója

A level crossing detector (LCD) nevű konstrukcióról, mind analitikusan mind kísérletileg igazolták, hogy SRT-ként viselkedik ([19]). Ez a rendszer, hasonlóan elődeihez, a kimenetén kellemetlen karakterisztikájú dirac-deltával válaszol. Alkalmazásokban nehéz ilyen rendszerekre tervezni. Kívánatos volt tehát egy olyan rendszert tervezni, amely ugyan rendelkezik SR tulajdonságokkal, de megpróbálja a bemeneti jelet a lehető legpontosabban (azaz a legsimábban, fázisában leghelyesebben és legkisebb háttér zajjal) rekonstruálni a kimeneten.

Javaslatom erre a kellemetlen tulajdonságra kínál áthidaló megoldást, továbbá képes tetszőlegesen sima kimenetet produkálni és mindazonáltal továbbra is SR tulajdonságot mutat a jel n -edik deriváltjáig.

Ehhez a konstrukcióhoz integráló komponenseket használtam fel egy SRT után, míg a jelhűség kedvéért ugyanennyi deriváló komponenst a bemeneten, így jutva végül egy integro-differenciális rendszerhez (lásd 6. Ábra).



6. Ábra: A „sima sztochasztikus rezonátor” struktúrája. A bemeneten megjelenő jel és a zaj keverékét először deriváljuk, azután egy hagyományos sztochasztikus rezonátoron átvezetjük (például egy level cross detector-on), utána integráljuk a kimeneten.

Egy level-crossing-detector kimeneti jel-zaj viszonya (SNR) kifejezhető a kimeneti a threshold szint (U_t) függvényében változó, átlagos tüzelési frekvenciával (ν), a bemeneti jel amplitúdóval (A , *szinuszos jelet feltételezve*) és zaj varianciával σ úgy mint

$$SNR_{lcd} = \frac{U_t^2}{\sigma_{in}^4} \nu(U_t) A^2.$$


Ez a háttér zaj és a jel teljesítményből vezethető le.

Először kiterjesztettem a level-crossing-detector-t oly módon, hogy a zérus szinthez képest szimmetrikus jelet is képes legyen reprezentálni. Ezt két egymással szembe fordított level-crossing-detector-ral értem el, amely így képes két irányú tüzelésre is a kimenetén. Ennek a leírásához az átlagos tüzelési gyakoriság szeparált kezelésére volt szükség (azaz $\nu^{poz}(U_t), \nu^{neg}(U_t)$). Ennek használatával a kimeneten az átlagos jel teljesítmény megnégyszereződik, míg a zaj csak kétszereződik (azaz $SNR_{lcd} = 2 SNR_{asymlcd}$). A felhasznált integrátor és derivátor viszont a jel-zaj viszonyt érintetlenül hagyja (azaz $SNR_{int} = SNR_{lcd}$, $SNR_{diff} = SNR_{in}$). Ezeket a felismeréseket mind analitikus eredményekkel, mind kísérletekkel alátámasztottam.

4.3 Főbb eredmények

Harmadik tézis – I. rész: A Sima Sztochasztikus Rezonancia

A sztochasztikus rezonátorok (SRT) és a sztochasztikus rezonancia (SR) egy új, speciális osztályát alkottam meg. Az új SRT egy klasszikus rezonátorból és egy vagy több deriváló és ugyanennyi számú integrátorból áll. A beérkező jel először áthalad a deriváló elemeken, a rezonátoron, majd az integrátorokon. Ez az Integro-Differenciális Sztochasztikus Rezonátor (IDSRT). A kialakuló sztochasztikus rezonancia jelensége jól definiált SR tulajdonságokkal bír (lásd 7. Ábra).



7. Ábra: A jel-zaj viszony az additív bemeneti zaj függvényében maximalizálható a kimeneten. Az erősítés a jel frekvenciájának függvényében változik.

Az új rendszer legnagyobb előnye, hogy képes tetszőleges simaságú kimenetet produkálni, amely jelenséget nem figyelték meg ezelőtt sztochasztikus rezonátorokban.

4. Definíció: Tetszőlegesen (avagy n -ed rendűen) sima jelről beszélünk

akkor, ha az leírható egy C^n osztályba tartozó függvényvel.

Érdemes megjegyezni, hogy a rendszer, ugyancsak a sztochasztikus rezonátoroktól eltérően, a magas frekvenciákon viselkedik a legjobban (ref. [1,4]).

4.4 A főbb kérdések: Tér-időbeli sima Sztochasztikus


Rezonancia

Az előző szakaszban, egydimenziós rendszerekkel foglalkoztunk. Természetes módon vetődik fel az a kérdés, hogy ugyanez a jelenség, a sima sztochasztikus rezonancia, megfigyelhető-e tér-időbeli rendszerek esetében is? (például élőlények látó rendszerében)

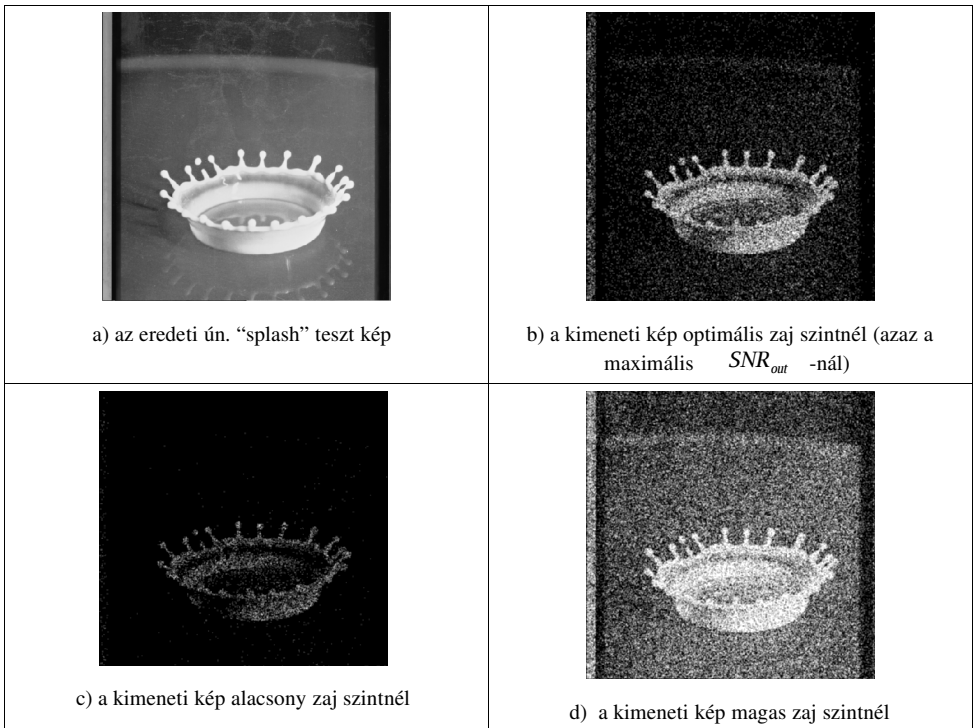
A kérdés jelentőségét növeli az a tény, hogy az idegrendszer jeltovábbítása, amennyire az jelen körülmények között kimérhető, oly mértékben zajjal terhelt, hogy jogosan merülhet fel az a feltételezés, hogy az idegrendszer a belső struktúrájában a zajt inkább igyekszik kihasználni és erre optimalizálni, mint elnyomni ([31,32]).

4.5 Módszerek

A legegyszerűbb sztochasztikus rezonátor egy threshold operátor. Ez természetes módon erősíti fel additív zaj segítségével a threshold alatti jeleket. Vegyük például a 8.a ábrát, rakjunk rá különböző erősségű sáv korlátozott Gauss-i, fehér zajt (lásd 9.b – 9.d ábrákat) és mérjük meg az SNR_{output} -ot egy threshold után. Nem meglepő, hogy, hogy az SNR maximalizálható a zaj effektív értékének (RMS) függvényében (lásd 8. ábra).



8. Ábra: A 9. a. ábrán látható kép és zaj, egy threshold operáció után, a zaj effektív értékének (*RMS*) függvényében a fenti SNR_{out} diagramhoz vezet.




9. Ábra: A legegyszerűbb sztochasztikus rezonátort szemléltetjük. Amikor egy képen egy threshold operációt alkalmazunk, az *SNR* a zaj függvényében maximalizálható.

Egy tér-időbeli integro-differenciális sztochasztikus rezonátor megkonstruálásánál a lehetőségek széles tárháza nyílik meg előttünk a tekintetben, hogy milyen építőelemet használunk fel, hiszen a képeken értelmezett deriválást és integrálást sokféleképpen végezhetjük el (lásd a 4.12. ábrát a disszertációban). A disszertációban megmutattam, hogy egy triviális konstelláció is elégséges volt ahhoz, hogy az IDSR jelensége 2 dimenzióban kimérhető legyen. Ha az idő tengelyen egy level-crossing-detector-t feltételezünk, melyet sokan az integrate-and-fire neuron modell legprimitívebb verziójának tekintenek, egy tér-időbeli IDSRT-t kapunk.


4.5 Főbb eredmények:

Harmadik tézis – II. rész: CNN alapú Sima Sztochasztikus Rezonátor

Néhány CNN template alkalmazásával kísérletileg kimutattam, hogy a sima SR megfigyelhető tér-időbeli rendszerekben is, amely egy új jelenség (lásd: 10. ábra, 11. ábra).



10. Ábra Sima sztochasztikus rezonancia képeken. Jól definiált maximum tapasztalható a zaj teljesítményének függvényében. A deriválás és integrálás operátorokat, valamint az SRT-t CNN-ben megvalósítható módon szimuláltam.



11. Ábra. A felső blokkban, a módszer rekonstrukciós fázisának felső korlátját láthatjuk zajmentes esetben. Az alsó blokkban, ugyanezen a bemeneti képen egy egyszeri zajjal terhelt, illetve egy időben integrált rekonstrukciót láthatunk.

5 Publikációk

5.1 Folyóirat cikkek

- [1] L. Török, L. B. Kish, *Integro-Differential Stochastic Resonance, Fluctuation and Noise Letters*, Vol. 5, No. 1 (2005) L27-L42,

- [2] L. Török, T. Roska, *Stability of Multi-Layer Cellular Neural/Non-linear Networks*, Int. Journal of Bifurcations and Chaos, Vol. 14, No. 10, pp. 3567-3586, October, 2004,
- [3] L. Török, Á. Zarándy, *Analog VLSI, Array Processor Based, Bayesian, Multi-Scale Optical Flow Estimation*, Circuits Theory and Applications, Special Issue 2005, (elfogadott).

5.2 Konferencia cikkek

- [4] L. Török, L.B. Kish, *Integro-Differential Stochastic Resonance*, SPIE's Second International Symposium on Fluctuations and Noise (FaN'04), Proc. of SPIE, Vol. 5467, Ref. 18 , May 26-28, Canary Islands, 2004,
- [5] L. Török and Á. Zarándy, *Bayesian Incorporation of Multiple Scales in Optical Flow Estimation*, Proc. of 8th IEEE International Workshop on Cellular Neural Networks and their Applications, (CNNA2004), pp. 309-314, 22-24 July, Budapest, Hungary, 2004,
- [6] L. Török and T. Roska, *Stability of Multi-Layer Cellular Neural/Non-linear Networks including a 2-layer complex cell CNN-UM*, Proc. of European Conference on Circuit Theory and Design 2003, (ECCTD'03), Vol 1., pp. 117-120, Cracow, Poland, 2003,
- [7] L. Török and Á. Zarándy, *CNN Based Color Constancy Algorithm*, Proc. of IEEE Int. Workshop on Cellular Neural Networks and their Applications, (CNNA2002), pp. 452-458, July 22-26, Frankfurt, Germany , 2002,
- [8] S. Tőkés, L. Orzó, L. Török, A. Ayoub and T. Roska, *An advanced joint Fourier transform correlator (JTC)*, Proc. of DO'01 Topical Meeting on DIFFRACTIVE OPTICS, Budapest, Hungary, 2001,
- [9] L. Török, Á. Zarándy and T. Roska, *High Speed Stand-alone Mobile Visual Decision Maker Device Based on Focal Plane Analog Processor Array Chip*, Proc. of IEEE Virtual Instrumentation & Measurements, (VIMS2001), pp. 81-84, 19-20 May,

Budapest, Hungary, 2001,

- [10] L. Török and T. Ádám, *Multiprocessor configuration of Digital Signal Processors*, Proc. of International Computer Science Conference, (microCAD'99), pp. 107-111, 23-25 Feb, Miskolc, Hungary, 1999,
- [11] L. Török, *Method for separation of partially occluded objects by image processing*, Proc. of European Material Science Conference, (Euromat'96), pp. 522-523, 21-23 Oct, Lausanne, Switzerland, 1996,
- [12] L. Török, *Crystal Growth Simulation - from fractals to compacts*, Proc. of Second International Conference on Solidification and Gravity, pp. 161-162, 26-29 Apr, Miskolc-Lillafüred, Hungary, 1995.

5.3 Riportok

- [13] L. Török and Á. Zarándy, *Analog VLSI Array Processor Based Bayesian Multi-Scale Optical Flow Estimation*, Technical Report at SZTAKI (Computer and Automation Research Institute), DNS-7-2004, Budapest, Hungary, 2004.

5.4 Referenciák

- [14] G. E. Moore, *Cramming more components onto integrated circuits*, Electronics Magazine 19 April, 1965,
- [15] L. O. Chua and L. Yang, *Cellular Neural Networks: Theory*, IEEE Trans. on Circuits and Systems (TCAS), Vol. 35, No. 1, pp. 1257-1272, Oct 1988,
- [16] T. Roska and L. O. Chua, *The CNN Universal Machine*, IEEE Trans. on Circuits and Systems II (TCAS), Vol. 40, pp. 163-173, 1993,
- [17] R. G. Carmona, F. Jimenez Garrido, R. Dominguez Castro, S. Espejo Meana and A. Rodriguez Vazquez, *CACEIK User's Guide*, Instituto de Microelectronica de

Sevilla, Sevilla, 2002,

- [18] S. Espejo, A. Rodriguez-Vazquez, R. Dominiguez Castro, and R. Carmona, *Convergence and Stability of the FSR CNN model*, In Proc. of IEEE Int. Workshop on Cellular Neural Networks and their App., pp. 411-416, Rome, 1994,
- [19] L. B. Kiss, *Possible breakthrough: Significant improvement of signal to noise ratio by Stochastic Resonance*, In Chaotic, Fractals and Nonlinear Signal Processing, Mystic, Vol. 375, pp. 880-897, Connecticut, USA, 1996, American Institute of Physics Press,
- [20] L. O. Chua and T. Roska, *Stability of a Class of Nonreciprocal Cellular Neural Networks*, IEEE Trans. on Circuits and Systems (TCAS), Vol. 37, No. 12, pp. 1520-1527, 1990,
- [21] L. O. Chua and C. W. Wu, *On the Universe of Stable Cellular Neural Networks*, International Journal of Circuits Theory and Applications (CTA), Vol. 20, 497-518, 1992,
- [22] M. Gilli, *A Lyapunov Functional Approach to the Study of the Stability of Cellular Neural Networks*, In Proc of IEEE Int. Simp. on Circ. And Sys. (ISCAS'93), Vol. 4, pp. 2584-2587, Chicago, 1993,
- [23] M. Forti, *Some Extension of a New Method to Analyze Complete Stability of Neural Networks*, IEEE Trans. on Neural Networks (NN), Vol. 13, No. 5, pp. 1230-1238, 2002,
- [24] B. Shi, T. Roska, and L. O. Chua, *Estimating Optical Flow With Cellular Neural Networks*, International Journal of Circuits Theory and Applications (CTA), Vol. 26, pp. 343-364, 1998,
- [25] A. Stocker and R. Douglas, *Analog Integrated 2-d Optical Flow Sensor With Programmable Pixels*, In Proc. of IEEE Int. Simp. on Circ. And Sys. (ISCAS'04), Vol. 3, pp. 9-12, Vancouver, Canada, May 2004,
- [26] S. Mehta and R. Etienne-Cummings, *Normal Optical Flow Measurement on CMOS APS Images*, In Proc. of IEEE Int. Simp on Circ. And Sys. (ISCAS'04), pp. 23-26,

Vancouver, Canada, May 2004,

- [27] Jose L. Martin, Aitzol Zuloaga, Carlos Cuadrado, Jesus Lazaro and Unai Bidarte, *Hardware Implementation of Optical Flow Constraint Equation Using FPGAs*, Comp. Vision and Image Understanding (CVIU), Vol. 98, No. 462-490, 2005,
- [28] S. Uras, F. Girosi, A. Verri and V. Torre, *A Computational Approach to Motion Perception*, Biological Cybernetics (BC), Vol. 60, pp. 79-87, 1988,
- [29] B. K. P. Horn and G. Schunk, *Determining Optical Flow*, Artificial Intelligence (AI), Vol. 17, pp. 185-203, 1981,
- [30] L. O. Chua and T. Roska, *Cellular Neural Networks and Visual Computing, Foundations and Applications*, Chapter 8, pp. 205-231. Cambridge University Press, Cambridge, 2002,
- [31] M. Rudolph and A. Destexhe, *Do Neocortical Pyramidal Neurons Display Stochastic Resonance?*, Journal of Computational Neuroscience, Vol. 11, pp. 19-42, 2001,
- [32] Y. Yu, R. Romero and T. S. Lee, *Preference of Sensory Neural Coding for $1=f$ Signals*, Phys. Rev. Lett. (PRL), Vol. 94, pp. 1-4, 2005.

6.5 Díjak

Second Prize: M.Sc. Thesis competition of Hungarian Electro-technical Association:

L. Török, "*Cellular Neural Network Engine Board Design*", Hungary, 2001,

First Prize on National Award for University and College Students, (XXI. OTDK) with presentation

L. Török, *Crystal Growth Simulation Based on Fractal Theory*, Proc. pp. 28. (presentation), Kecskemét, Hungary, 1993.