

# Nemlineáris template-el megvalósítása és használtuk CNN-el



*András Horváth*

## Röpzh

A

1, Ismertesse milyen boundary condition-öket ismer (név+rövid leírás)

2, DP plot segítségével igazolja, hogy a LOGOR template valóban bináris képekre értelmezett vagy kapcsolatot hajt végre:

A=2

B=1

Z=1

B

1, adja meg a CNN dinamikát leíró diffegyenletet, írja le a benne szereplő változók nevét MatCNN-ben

2, DP plot segítségével igazolja, hogy a LOGAND template valóban bináris képekre értelmezett és kapcsolatot hajt végre:

A=2

B=1

Z=-1

## Nemlineáris tamplate-k

A PDE-k egy jelentős osztályát egyszerűen szimulálhatjuk, azonban számos olyan egyenlet van, ahol a parciális deriváltak nemlineáris kombinációjára lenne szükség.

$$\begin{aligned} \frac{d}{dt} v_{x_{ij}}(t) = & -v_{x_{ij}}(t) + \sum_{kl \in N_r} A_{ij,kl} v_{y_{kl}}(t) + \sum_{kl \in N_r} B_{ij,kl} v_{u_{kl}}(t) + I_{ij} \\ & + \sum_{kl \in N_r} \hat{D}_{ij,kl}(\Delta v) \end{aligned}$$

Az extra tag esetében D template elemei függvények az argumentuma pedig a bemenet a state és a kimenet

# Nemlineáris Diffúzió

A PDE-k egy jelentős osztályát egyszerűen szimulálhatjuk, azonban számos olyan egyenlet van, ahol a parciális deriváltak nemlineáris kombinációjára lenne szükség.

Példa: Gradient, Gradient based diffusion

```
%% MEDIAN %%
```

```
MEDIAN_A = [0 0 0;
             0 1 0;
             0 0 0];
```

```
MEDIAN_Dd = 0.5*[1 1 1;
                 1 0 1;
                 1 1 1];
```

```
MEDIAN_d = [0 2 0 -1 2.5 1 12];
```

```
MEDIAN_I = 0;
```

|    |   |                                  |
|----|---|----------------------------------|
| 11 | – | $\Delta v = v_{u2kl} - v_{u1ij}$ |
| 12 | – | $\Delta v = v_{ukl} - v_{xij}$   |
| 13 | – | $\Delta v = v_{ukl} - v_{yij}$   |
| 21 | – | $\Delta v = v_{xkl} - v_{u ij}$  |
| 22 | – | $\Delta v = v_{xkl} - v_{xij}$   |
| 23 | – | $\Delta v = v_{xkl} - v_{yij}$   |
| 31 | – | $\Delta v = v_{ykl} - v_{u ij}$  |
| 32 | – | $\Delta v = v_{ykl} - v_{xij}$   |
| 33 | – | $\Delta v = v_{ykl} - v_{yij}$   |

# Nemlineáris Diffúzió

A PDE-k egy jelentős osztályát egyszerűen szimulálhatjuk, azonban számos olyan egyenlet van, ahol a parciális deriváltak nemlineáris kombinációjára lenne szükség.

Példa: Median

%% MEDIAN %%

```
MEDIAN_A = [0 0 0;
             0 1 0;
             0 0 0];
```

$$A = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}$$


$$\hat{D}^M = \begin{bmatrix} d & d & d \\ d & 0 & d \\ d & d & d \end{bmatrix}$$

$$z = \begin{bmatrix} 0 \end{bmatrix}$$

```
MEDIAN_Dd = 0.5*[1 1 1;
                  1 0 1;
                  1 1 1];
```

```
MEDIAN_d = [0 2 0 -1 2.5 1 12];
```

```
MEDIAN_I = 0;
```



# Nemlineáris Diffúzió

A PDE-k egy jelentős osztályát egyszerűen szimulálhatjuk, azonban számos olyan egyenlet van, ahol a parciális deriváltak nemlineáris kombinációjára lenne szükség.

Példa: Gradient



$$\frac{\partial I}{\partial t} = \Delta \left[ I(x, y, t) \cdot \left( 1 - k \cdot \left| \text{grad} \left( G(s) * I(x, y, t) \right) \right| \right) \right]$$

%% ANISO %%

```
ANISO_A = [0 0 0;
            0 1 0;
            0 0 0];
```

```
ANISO_Dd = [0.5 1.0 0.5;
             1.0 0.0 1.0;
             0.5 1.0 0.5];
```

```
ANISO_d = [1 5 -2 0 -0.3 0 0 1 0.3 0 2 0 122];
```



# Nemlineáris Diffúzió

A PDE-k egy jelentős osztályát egyszerűen szimulálhatjuk, azonban számos olyan egyenlet van, ahol a parciális deriváltak nemlineáris kombinációjára lenne szükség.

Példa: Gradient



```
%% GRADT %%
```

```
GRADT_A = [0 0 0;  
           0 2 0;  
           0 0 0];
```

```
GRADT_Bb = [1 1 1;  
            1 0 1;  
            1 1 1];
```

```
GRADT_b = [1 3 -3 3 0 0 3 3];
```


```
GRADT_I = -1.8;
```




# Nemlineáris templatek

Érdekes kérdés, hogy milyen nemlinearitást használjunk az eszközben?


Melyik lesz hatékony és milyen függvények valósíthatóak meg vele?



Standard CNN  
nemlinearitás




Abszolút érték  
nemlinearitás




Gaussi  
nemlinearitás

# Áramköri megvalósítás

A szakaszonként lineáris nemlinearitások áramköri megvalósítására a következő megoldásokat szokták használni:



Feszültségvezérelt áramforrások




Több lábú ellenállások (multi-terminal resistors)


Ezen áramköri megvalósítások nem igazán hatékonyak:  
Sok elem, magas disszipáció és zaj

# Áramköri megvalósítás

Mindemellett számos olyan áramköri elemet ismerünk, melyek önamgukban nemlineáris karakterisztikával rendelkeznek



CMOS eszközök karakterisztikája



Zener dióda I-V karakterisztikája


Kérdés, hogy használhatjuk-e ezen karakterisztikákat számításra?

# Quantum tunneling effect



Since every particle is wave-like (is), therefore there is a probability of its position

## Quantum Tunneling

### Classical Picture





### Quantum Picture



# T-FET

Tunneling field effect transistor

Quantum tunneling effect based transistors





Hagyományos tranzisztorok esetében 60 mV/dec (decade 10x Drain áram növelés)(300 K)(Maxwell-Boltzman)

Gyakorlatban legalacsonyabb érték 70 mV/dec – TFET esetében ez alá lehet menni

# TFET IV karakterisztikák


Milyen módon hasonlítanak ezek a karakterisztikák a hagyományos CNN nemlinearitásra?




Miként használhatóak és hogyan tervezhetőek template-ek ezen eszközökre?

## TFET Példa

TFET nemlinearitás használatával minden 'klasszikus' lineáris template megvalósítható




Bemeneti képek



Kimmeneti kép  
(LOGAND template)






Bemeneti kép



Kimmeneti kép  
(Threshold template)

## TFET Példa

TFET nemlinearitás használatával minden  
'klasszikus' lineáris template megvalósítható




Bemeneti képek

Kimmeneti kép  
(LABIRINT template)


# SymFET Példa

## Symmetric Graphene Tunneling Field Effect Transistor

n-type és p-type grafén átmenet



SymFET felépítése





SymFET IV karakterisztikák

**Resonant tunnelling and negative differential conductance in graphene transistors**



# SymFET Példa

Ha limitáljuk a lehetséges feszültségértékeket, akkor egy viszonylag szép 'Gaussi' görbét kapunk



## SymFET Példa

Mire használható egy SymFET karakterisztika? Míg a hagyományos eszközzel egy nyílt intervallumon tudtunk műveletet végezni, addig egy SymFET beiktatásával egy zárt intervallumot tudunk 'kiemelni' a képi értékek közül



Bemeneti kép



Kimeneti kép (intervallum threshold)

# SymFET Példa - Gradient



Bemeneti kép



Kimeneti kép


```
% GRADT %
```

```
GRADT_A = [0 0 0;  
           0 2 0;  
           0 0 0];
```


```
GRADT_Bb = [1 1 1;  
            1 0 1;  
            1 1 1];
```

```
GRADT_b = [1 3 -3 3 0 0 3 3];
```

```
GRADT_l = -1.8;
```



Abszolút érték függvény  
(Gradiens függvény  
nemlinearitása)



SymFET karakterisztika  
fejjel lefelé (-1 szeres és  
eltolt érték)

## SymFET Példa – Anisotrop diffusion

Ezen esetben is egy intervallumot szeretnénk kiemelni, ha a különbség két szomszédos érték között kicsi



% ANISO %

```
ANISO_A = [0 0 0;  
           0 1 0;  
           0 0 0];
```

```
ANISO_Dd = [0.5 1.0 0.5;  
            1.0 0.0 1.0;  
            0.5 1.0 0.5];
```

```
ANISO_d = [1 5 -2 0 -0.3 0 0 1 0.3 0 2 0 122];
```


Anizotróp diffúzió bemeneti és kimeneti kép

## SymFet Nemlineáris karaktereisztkák


A hagyományos CNN nemlinearitás helyén használva a:

$-x + f(x)$  karakterisztika

Esetében hasznoló kavlitatív viselkedést kapunk és hagyományos template-k is megvalósíthatóak SymFET használatával



Standard CNN  
karakterisztika





SymFET CNN  
karakterisztika

# Mintavételi probléma, diszkrét vagy folytonos idő



# Téridőbeli detekció a retinában

Analóg folytonos-idejű feldolgozás





© Deltagen Inc.


Az emberi látórendszer dinamikákat s nem képkockákat érzékel:  
Animációk, alacsony képkockájú videók




# An other video









# Késleltetés a chip-en

30 nm: > 10 milliárd tranzisztor


Wire delay vs Gate delay

Intel cloud: 48

Xeon Phi: 60

GPU: 1600 (Radeon 5870)

FPGA



# Késleltetett CNN template-ek

Nem csak csatolási erősségek,

Hanem késleltetések is vannak a hálózatban

$$\dot{x} = -x + \sum A_t y + \sum B_t u + z$$

A hagyományos cnn dinamika kiterjesztése


CNN implicit memóriával

$$A_t = [A_{coupl}, A_{delay}] \quad B_t = [B_{coupl}, B_{delay}]$$


$$\begin{aligned} \frac{dx_i(t)}{dt} = & -\gamma_i x_i(t) + \sum_{j \in S_i} A_{ij} y[x_j(t)] + \sum_{j \in S_i} A_{ij}^D y[x_j(t - \tau_{A_{ij}}(t))] \\ & + \sum_{j \in S_i} B_{ij} u_j(t) + \sum_{j \in S_i} B_{ij}^D u_j(t - \tau_{B_{ij}}(t)) + Z_i \end{aligned}$$

# Diagonális mozgás detekció

Input video



Output video



$$B_d = \begin{bmatrix} \tau_v & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}$$



$$B_c = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}$$

$$Z = -1$$

# Diagonális mozgás detekció

Input video



Output video



# Diagonális mozgás detekció

Input video

Output video




A teljes trajektória megmarad a mozgás után

# Egy adott trajektória detekciója

A cél, hogy a felfelé mozgó objektumokat detektáljuk.

Ezt egyetlen egyszerű delayed template-tel megtehetjük



Input video


$$A_c = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 4 & 0 \end{bmatrix} \quad 4_D = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & \tau_v & 0 \end{bmatrix}$$

$$B_c = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 2 & 0 \\ 0 & 2 & 0 \end{bmatrix} \quad B_D = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 1 & 0 \end{bmatrix}$$

$$Z = -2$$

# Egy adott trajektória detekciója

A cél, hogy a felfelé mozgó objektumokat detektáljuk.  
Ezt egyetlen, egyszerű delayed template-tel megtehetjük



Output video


$$A_c = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 4 & 0 \end{bmatrix} \quad A_D = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & \tau_v & 0 \end{bmatrix}$$

$$B_c = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 2 & 0 \\ 0 & 2 & 0 \end{bmatrix} \quad B_D = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 1 & 0 \end{bmatrix}$$

$$Z = -2$$

# Egy adott trajektória detekciója

Az előző eredmény kiterjeszthető más bonyolult és összetett trajektóriákra is.



Input Video

# Egy adott trajektória detekciója

Az előző eredmény kiterjeszthető más bonyolult és összetett trajektóriákra is.



Output video

# Delayed edge detection: Identification of movement speed and direction

$$B_d = \begin{bmatrix} \tau_e & 0 & 0 \\ \tau_e & 0 & 0 \\ \tau_e & 0 & 0 \end{bmatrix} B_c = \begin{bmatrix} -0.11 & 0 & 0.11 \\ -0.28 & 0 & 0.28 \\ -0.11 & 0 & 0.11 \end{bmatrix}$$

The dark edge will appear where we can detect an edge on the current input flow, while the bright edge will appear, where the edge was  $\tau_e$  this can be used to detect the speed and the direction of the moving object.



Input Video



Output video

# Beyond Moore's Law

The interconnect area


Kvantált világ

1 atomból biztosan  
nem lehet tranzisztort  
építeni

Hol a határ?

4 nm en már biztosan  
nem működik a  
mostani technológia

Microprocessor Transistor Counts 1971-2011 & Moore's Law



# Mi lehet az információ?

Jelenleg a töltés (elektron) az információ

Egy elektron már meglehetősen érzékeny

Probléma a fogyasztás



Statikus vagy dinamikus információ?

Spin:

Alacsony fogyasztás

Megbízható

Nehezen mérhető






# Spin oszcillátor modellje

Megfelelő bemenő áram esetén  
a spin oszcillál (1996 megjósolták):

$$\frac{d\mathbf{M}}{dt} = \gamma(\mathbf{M} \times \mathbf{H}) - \gamma\alpha \mathbf{M} \times (\mathbf{M} \times \mathbf{H}) - \gamma A \mathbf{M} \times (\mathbf{M} \times \mathbf{S})$$

$$\mathbf{H} = -M_s \begin{pmatrix} N_x M_x \\ N_y M_y \\ N_z M_z \end{pmatrix}$$



# Csatolt oszcillátorok szinkronizálódnak


$$\begin{aligned}\frac{dx_i}{dt} = & -\eta\delta y_i z_i + \alpha\eta\delta x_i z_i^2 - cAz_i x_i + \\ & + \eta r_z y_i z_{i+1} - \eta r_y z_i y_{i+1} \\ & - \eta\alpha r_y x_i y_i y_{i+1} - \eta\alpha r_z x_i z_i z_{i+1} \\ & + \eta\alpha r_x y_i^2 x_{i+1} + \eta\alpha r_x z_i^2 x_{i+1}\end{aligned}$$

$$\begin{aligned}\frac{dy_i}{dt} = & \eta\delta x_i z_i + \alpha\eta\delta y_i z_i^2 - cAz_i y_i + \\ & + \eta r_x z_i x_{i+1} - \eta r_z x_i z_{i+1} \\ & - \eta\alpha r_x x_i y_i x_{i+1} - \eta\alpha r_z y_i z_i z_{i+1} \\ & + \eta\alpha r_y x_i^2 y_{i+1} + \eta\alpha r_y z_i^2 y_{i+1}\end{aligned}$$

$$\begin{aligned}\frac{dz_i}{dt} = & -\alpha\eta\delta z_i(x_i^2 + y_i^2) + cA(x_i^2 + y_i^2) \\ & + \eta r_y x_i y_{i+1} - \eta r_x y_i x_{i+1} \\ & - \eta\alpha r_y y_i z_i y_{i+1} - \eta\alpha r_x x_i z_i x_{i+1} \\ & + \eta\alpha r_z y_i^2 z_{i+1} + \eta\alpha r_z x_i^2 z_{i+1}\end{aligned}$$

Megoldható a „describing function” módszerrel

$$\begin{aligned}x_i &= \sqrt{(1 - K_i^2)} \cos(\omega t + \phi_i) \\ y_i &= \sqrt{(1 - K_i^2)} \sin(\omega t + \phi_i) \\ z_i &= K_i\end{aligned}$$




# Szinkronizáció

Szép tulajdonság:

- zenekar
- sport
- taps (vastaps)
- szentjánosbogár


(Photinus Carolinus )



# Szinkronizáció

Huygens:


Ingaórák



A szinkronizáció az energia

Vagy energiaáramlás egy

minimális állapota



# Szinkronizáció



# OCNN dinamika

A szinkronizáció  
tetszőleges fázis  
különbséggel történhet:


A csatolás a mágneses  
mezőn keresztül történik

$$\frac{d\mathbf{M}}{dt} = \gamma(\mathbf{M} \times \mathbf{H}) - \gamma\alpha \mathbf{M} \times (\mathbf{M} \times \mathbf{H}) - \gamma A \mathbf{M} \times (\mathbf{M} \times \mathbf{S})$$



$$\mathbf{H}_{eff} = -\mathbf{H}_i + \mathbf{G}_j = -M_s \begin{pmatrix} N_x M_{xi} \\ N_y M_{yi} \\ N_z M_{zi} \end{pmatrix} + M_s \begin{pmatrix} C_x^j M_{xj} \\ C_y^j M_{yj} \\ C_z^j M_{zj} \end{pmatrix}$$

Az diffegyenlet rendszer megoldásából egy zárt formulában  
tudjuk számolni a fázis különbségeket:



$$\eta\alpha\delta\mathbf{K} \circ \mathbf{P} - c\mathbf{A} \circ \mathbf{P} - \eta\alpha(\mathbf{R}_z\mathbf{K}) \circ \mathbf{P} =$$

$$= -\eta\mathbf{R}_{xy}(\mathbf{P} \circ \sin(\Theta)) - \eta\alpha(\mathbf{R}_{xy}(\mathbf{P} \circ (\cos\Theta))) \circ \mathbf{P}$$

$$\mathbf{P}\omega = \eta\alpha\mathbf{K} \circ \mathbf{P} + \eta(\mathbf{R}_z\mathbf{K}) \circ \mathbf{P}$$


$$- \eta\mathbf{R}_{xy}(\mathbf{P} \circ \cos(\Theta)) \circ \mathbf{P} \circ \mathbf{K} + \eta\alpha\mathbf{R}_{xy}(\mathbf{P} \circ \sin(\Theta))$$

# Kétdimenziós élkeresés


Megfelelő távolságokkal (templattal) a hálózat beprogramozható, hogy élkeresést hajtson végre (EDGE+THRES)



*Bemeneti kép*



*Kimeneti kép*




*Kimeneti kép + threshold*




# Térbeli jelek detekciója

Egy ilyen hálózat nem csupán a jelek különbségét képes észlelni, hanem figyelembe veszi a térbeli elhelyezkedésüket is

Ezáltal tér és időbeli mintázatok figyelhetőek meg egyszerre:



*Bemeneti kép*



*Kimeneti eredmények különböző (heterogén) súlyokkal*