

# Iseorganiseeruvus

Võistlev dünaamika

Maarika Traat

# Ise-organiseeruvus

## (Self-organisation)

- Ilma õpetajata õppimine (unsupervised learning)
  - ei kasutata treeningandmeid: puudub igasugune eelnev info sisendi-väljendi seose kohta
  - eriti kasulik juhul, kui uuritava valdkonna kohta pole olemas piisavalt informatsiooni anoteeritud treeningandmete produtseerimiseks
  - võimaldab avastada (kõrgdimensionaalsetest) andmetest mustreid, mis muidu andmete hulga või keerukuse tõttu inimpilgu eest varjule jääksid


# Võistleva dünaamikaga närvivõrk

## Väljundikiht:

Igal neuronil positiivne ühendus iseendaga ja negatiivne ümbrusega (kõik neuronid on kõigi teistega ühenduses)

## Sisendid:

iga sisend seotud  
iga neuroniga

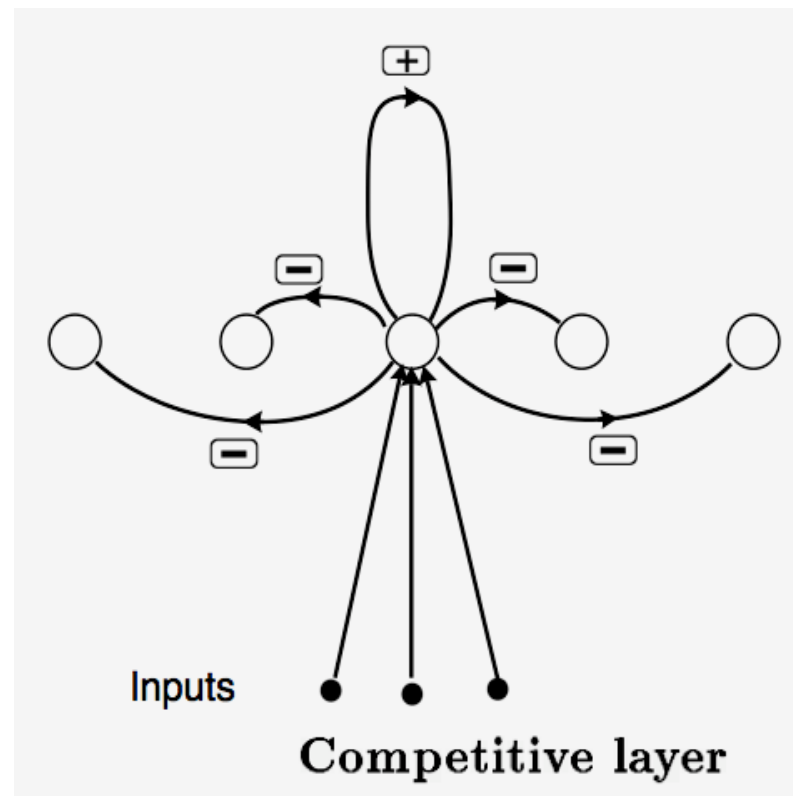


# Üks neuron

- Enda kaalu kasvatan, teiste oma vähendan (on-centre, off-surround)

- Negatiivsed kaalud on sümmeetrilised

$$V_{ij} = V_{ji}$$



# Võistlev dünaamika: matemaatika

neuroni sisend (s):

$$\mathbf{s} = \mathbf{W} \cdot \mathbf{x}$$

w - kaaluvektor  
x - sisendvektor

Kihi kõigi neuronite panus ( $l$ ) neuroni j aktivatsioonile:

$$l_j = v_j^{(+)} y_j + \sum_{i \neq j} v_{ij}^{(-)} y_i \quad y_j = \sigma(a_j)$$

Neuroni aktivatsiooni muutumise tase:

$$\frac{da_j}{dt} = c_1(s_j + l_j) - c_2 a_j$$

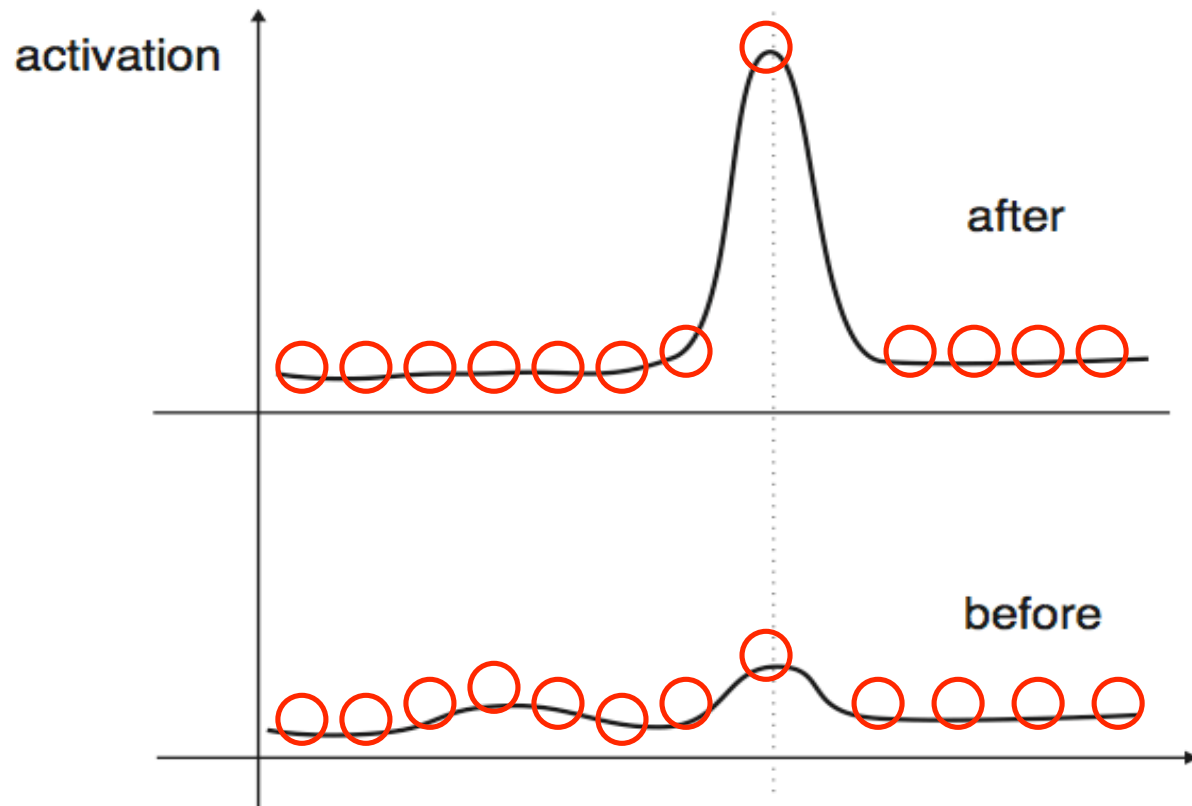
kihi teiste neuronite  
negatiivne panus

neuroni j  
positiivne panus

# Võistlev dünaamika sõnades

- 1) Üks konkreetne võrgu neuron j reageerib sisendile tugevamalt kui teised (s.t. tema arvutatud sisendi s väärtus on suurim)
  - 2) Selle neuroni j aktivatsioonitase kasvab veelgi tänu tema positiivsele ühendusele iseendaga, samas kui kihi teised neuronid surutakse negatiivsete ühendustega alla
  - 3) Neuroni j aktivatsioon kasvab, kuni võrgukiht jõuab tasakaaluseisundisse
- ★ Võrgus oleks justkui piiratud hulk aktiivsust, mida erinevad neuronid peavad jagama oma aktivisatsiooni eest võideldes. Neuron, mis algselt võistlust juhib, lõpuks ka võidab.
- ‘Võitja-võtab-kõik’ (winner-takes-all)

# Võitev neuron



# Võistlev õppimine

- Normaliseerime sisend- ja kaaluvektorid, teisendades nad ühikvektoriteks

$$\mathbf{x}' = \frac{1}{\|\mathbf{x}\|} \mathbf{x}$$

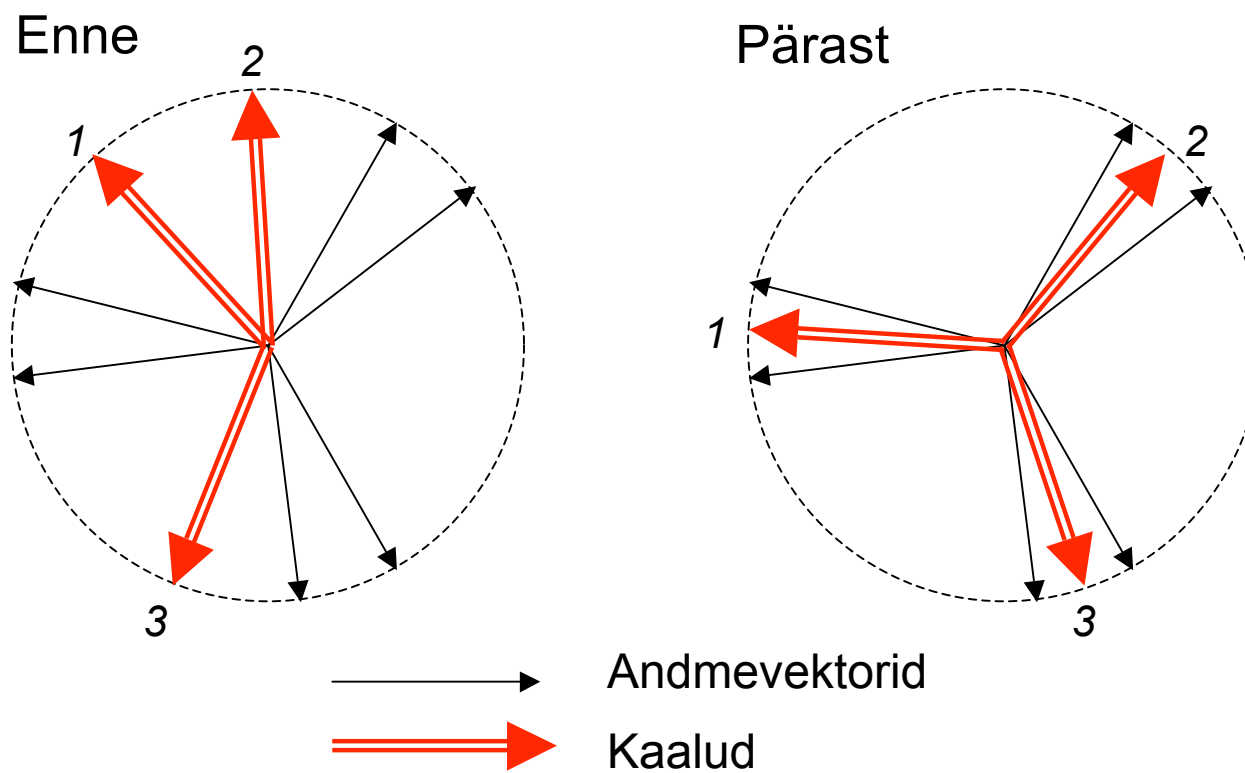
- Sel juhul vektori  $\mathbf{x}$  ja vastava kaaluvektori  $\mathbf{w}$  skalaarkorrutis väljendab otseselt nende kahe vektori omavahelist kaugust

$$s = \mathbf{w} \cdot \mathbf{x} \Rightarrow s = \underbrace{\|\mathbf{x}\| \|\mathbf{w}\|}_{1} \cos \theta$$

Mida suurem on  $s$ , seda suurem on vektorite vahelise nurga  $\theta$  koossinus, s.t. seda lähemal on vektorid  $\mathbf{x}$  ja  $\mathbf{w}$  üksteisele



# Võistlev õppimine: näide



# Võistlev õppimine: õppimise valem

- Võistlev õppimine: keerame mingile sisendile  $\mathbf{x}$  kõige lähemal asuvat kaaluvektorit  $\mathbf{w}_k$  natuke sisendvektorile lähemale lisades  $\mathbf{w}_k$  väärtusele vektori  $\Delta\mathbf{w}$

$$\Delta\mathbf{w}_j = \begin{cases} \alpha(\mathbf{x} - \mathbf{w}_j) & : j = k \\ 0 & : j \neq k \end{cases} \quad \begin{array}{l} \alpha - \text{mingi väike} \\ \text{murdarv} \\ k - \text{võitev neuron} \end{array}$$

- Pärast võrgu tasakaaluseisu jõudmist võib seda õppimisreeglit väljendada ka ilma tingimusteta, kuna ainult võitev neuron on tugevalt aktiveeritud - teiste aktivatsioon on nullilähedane

$$\Delta\mathbf{w}_j = \alpha(\mathbf{x} - \mathbf{w}_j)y$$

# Võistlev õppimine: algoritm

Tee iga sisendvektori puhul korduvalt kuni kaalude stabiliseerumiseni:

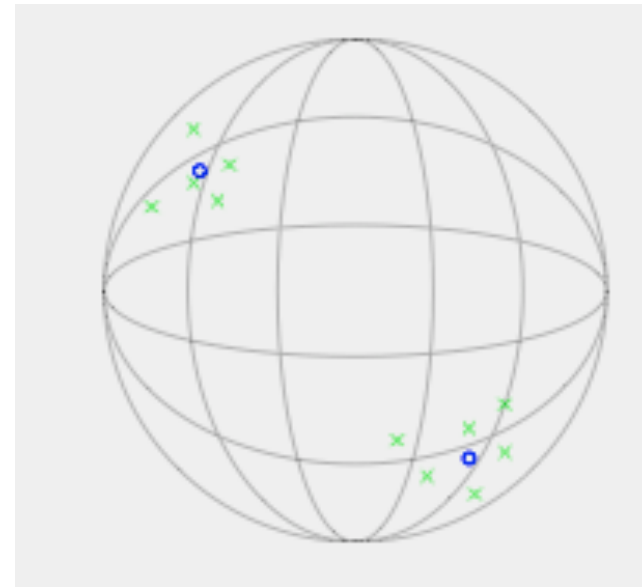

- 1) esita võrgule mingi sisendvektor  $j$  ja arvuta sisendi väärtus  $s$  iga neuroni puhul
- 2) kohanda võrku alloleva valemiga kuni ta jõuab tasakaaluseisundisse

$$\frac{da_j}{dt} = c_1(s_j + l_j) - c_2a_j$$

- 3) Treeni kõiki neuroneid vastavalt valemile

$$\Delta \mathbf{w}_j = \alpha(\mathbf{x} - \mathbf{w}_j)y$$

# Veel üks illustratsioon kaaluvektorite liikumise kohta



# Vektorite normaliseerimine

- Kui kaaluvektoreid õppimise käigus kohandatakse, siis võivad nende pikkused muutuda. Üks lahendus oleks neid pidevalt normaliseerida eeltoodud valemiga, aga see on arvutuslikult kulukas. Positiivsete sisendite puhul leidub teine väljapääs.

- Kasutame  $\sum_i w_i = 1$  kui lähendust valemile  $\sum_i w_i^2 = 1$

Sellise pikkuse definitsiooni puhul vaatleme vektoreid vektorisfääri asemel kui punkte tasandil

- Eelmisel slaidil toodud õppimisreegli korral kehtib siis

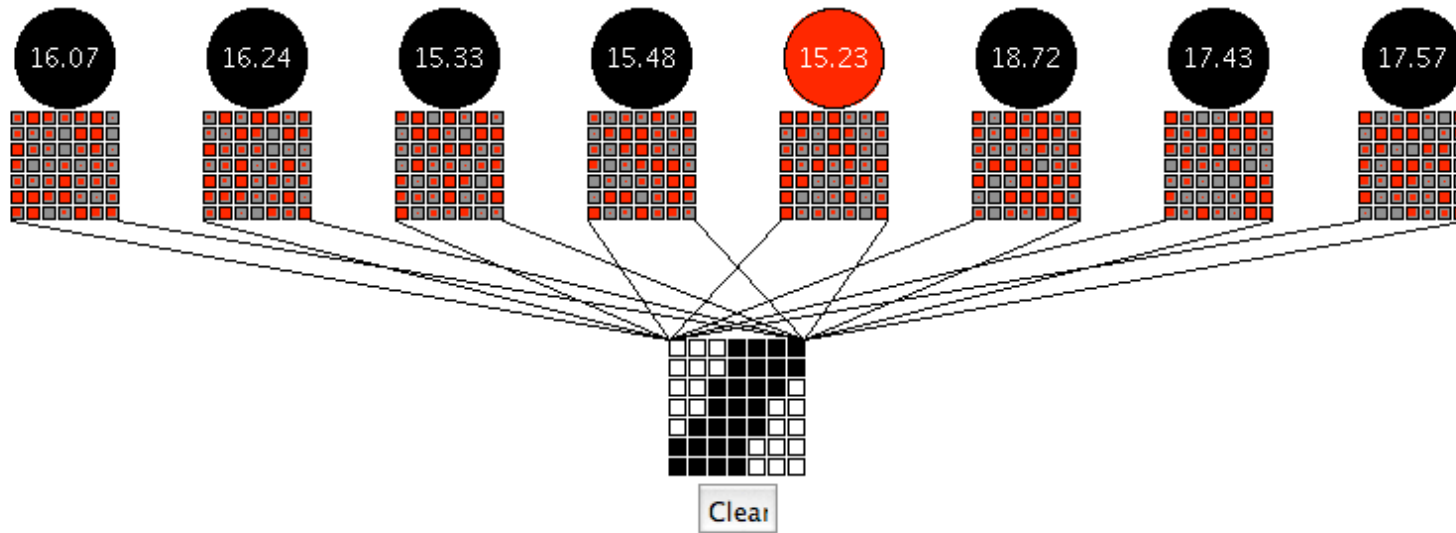
$$\sum_i \Delta w_i = \alpha y \left( \sum_i x_i - \sum_i w_i \right)$$

Sisendvektorite komponentide summa võrdub alati 1ga, kuna sisendid ei muutu. Kui kaaluvektorid enne õppimist normaliseeriti, siis jääb ka kaaluvektorite komponentide summa konstantselt 1ks. (Mõttele vektorite vahe geomeetrilisele vormile.)

# Rakendus: “sõnade” tuvastus


- Rumelharti ja Zipseri eksperiment:
  - 4 sisendmustrit AA, AB, BA, BB (pikselimustritena)
  - 2 neuroniga võistlev võrk klassifitseeris mustrid kas
    - {AA, AB}, {BA, BB}: esimesed tähed samad või
    - {AA, BA}, {BB, AB}: viimased tähed samad
  - 4 neuroniga võrk paneb iga tähepaari erinevasse klassi

# Demo: võistlev võrk



Training data:

Clear patterns



<http://www.psychology.mcmaster.ca/4i03/demos/competitive1-demo.html>