



# Koneksionismus

PSY 481

# Motivace





Zájem o vývoj umělých neuronových sítí pramení z poznání, že lidský mozek pracuje jiným způsobem než běžné číslicové počítače. Počítače přesně a rychle provádějí posloupnosti instrukcí, které pro ně byly formulovány. Lidský mozek je tvořen neurony, které pracují přibližně milionkrát pomaleji než obvody číslicové ho počítače, přesto člověk dokáže lépe řešit řadu výpočetně náročných úkolů (zpracování vizuální informace, porozumění řeči, hraní šachů , a podobně). Proto vzniká snaha napodobit schopnosti mozku a vytvořit umělou neuronovou síť, která by uměla simulovat chování biologické neuronové sítě živých organismů .

# Konekcionalismus

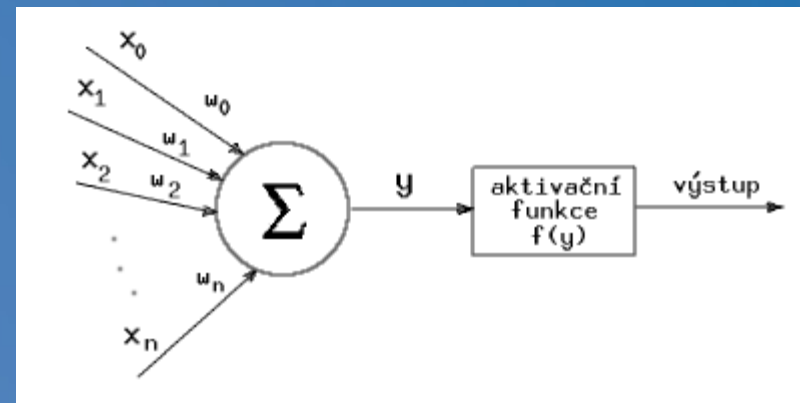

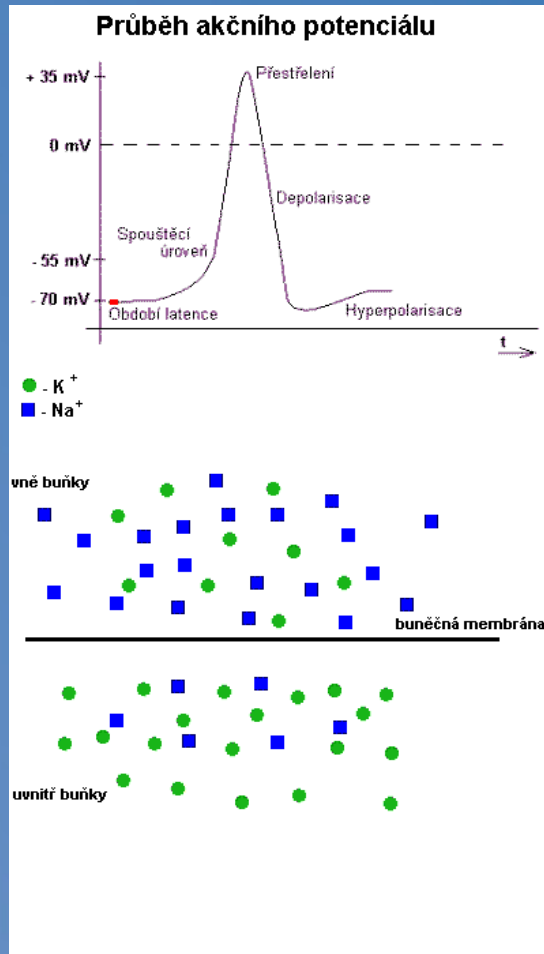


- V 80-tých letech se začíná objevovat nová technika modelování, či přesněji nová architektura.
- Pro svou fundamentální odlišnost od předchozích způsobů se tento přístup stává paradigmatem v oblasti kognitivních věd.
- Přístup se nazývá konekcionalismus a jeho aplikovanou oblastí jsou neuronové sítě, architektura principiálně odlišná od předchozích přístupů.
- Základ tvoří samostatné velmi jednoduché jednotky, jejichž propojení konstituuje síť.
- Výchozí myšlenkou je postulace základní jednotky, funkčně podobné lidskému neuronu.
- Největší rozdíl oproti klasické von neumannovské architektury spočívá v paralelním způsobu práce.

# Neuron



# Neuron





# Historie




|                                                      |                                                                                                                                                                              |
|------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| 1943                                                 | považován za začátek vývoje umělých neuronových sítí, navržen McCullochův-Pittsův model neuronu                                                                              |
| 1949                                                 | Hebbův zákon učení (1. zákon učení neuronových sítí)                                                                                                                         |
| 1958                                                 | navržen nejznámější model neuronu (perceptron), autorem Frank Rosenblatt                                                                                                     |
| začátek 60. let<br>20. stol                          | první model neuronových sítí (lineární sítě), navržena pravidla pro jejich učení                                                                                             |
| polovina 60. let<br>až polovina 80.<br>let 20. stol. | pokles zájmu o neuronové sítě, někteří nadšenci přesto pokračují ve výzkumu (např. T. Kohonen navrhuje tzv. samoorganizující se sítě a S. Grossberg zákony pro jejich učení) |
| od poloviny<br>80. let 20. stol.<br>dosud            | období renesance neuronových sítí, objevují se tzv. vícevrstvé nelineární sítě a pravidla pro jejich učení                                                                   |

# Lineární separovatelnost



# Lineární separovatelnost



Na konci 80-tých let přichází období stagnace klasického symbolického přístupu v oblasti modelování, hledají se alternativní metody a konekcionismus prožívá svou renesanci. Důležitým je i fakt, že Minsky opravil svá tvrzení o omezenosti neuronových sítí jako architektury vhodné pro simulaci (funkce XOR je řešitelná neuronovou sítí za použití více vrstev).



# Charakteristika neuron. sítí




1. Jsou tvořeny velkým počtem jednoduchých procesních jednotek, komunikujících přes množinu propojení, které mají různou váhu a sílu.
1. Paměť je reprezentována jako vzorec hodnot vah, mající propojení mezi jednotlivými prvky. Informace je zpracovávána jako šíření se měnících se vzorců aktivity mezi prvky.
1. Sítě jsou spíše učeny a trénovány než programovány.
1. Místo oddělené paměti, procesoru a externímu programu, který řídí operace systému jako u digitálního počítače, operace neuronových sítí jsou implicitně kontrolovány třemi vlastnostmi: kombinační funkcí neuronu, způsobem propojení a učícím pravidlem

# Charakteristika neuron. sítí




1. Neuronové sítě jsou schopny generalizace; mohou se naučit charakteristiky obecné kategorie.
1. Jsou odolné proti chybám. Díky paralelní distribuované formě uložení paměti „degradují s grácií“
1. Neuronové sítě mají schopnost sebeorganizace. Dokáží reagovat na vstupy z prostředí změnou své funkční dynamiky
1. Neuronové sítě jsou schopné emergence nových vlastností či chování.


# Základní typy neuron. sítí



Jednovrstvé dopředné síť

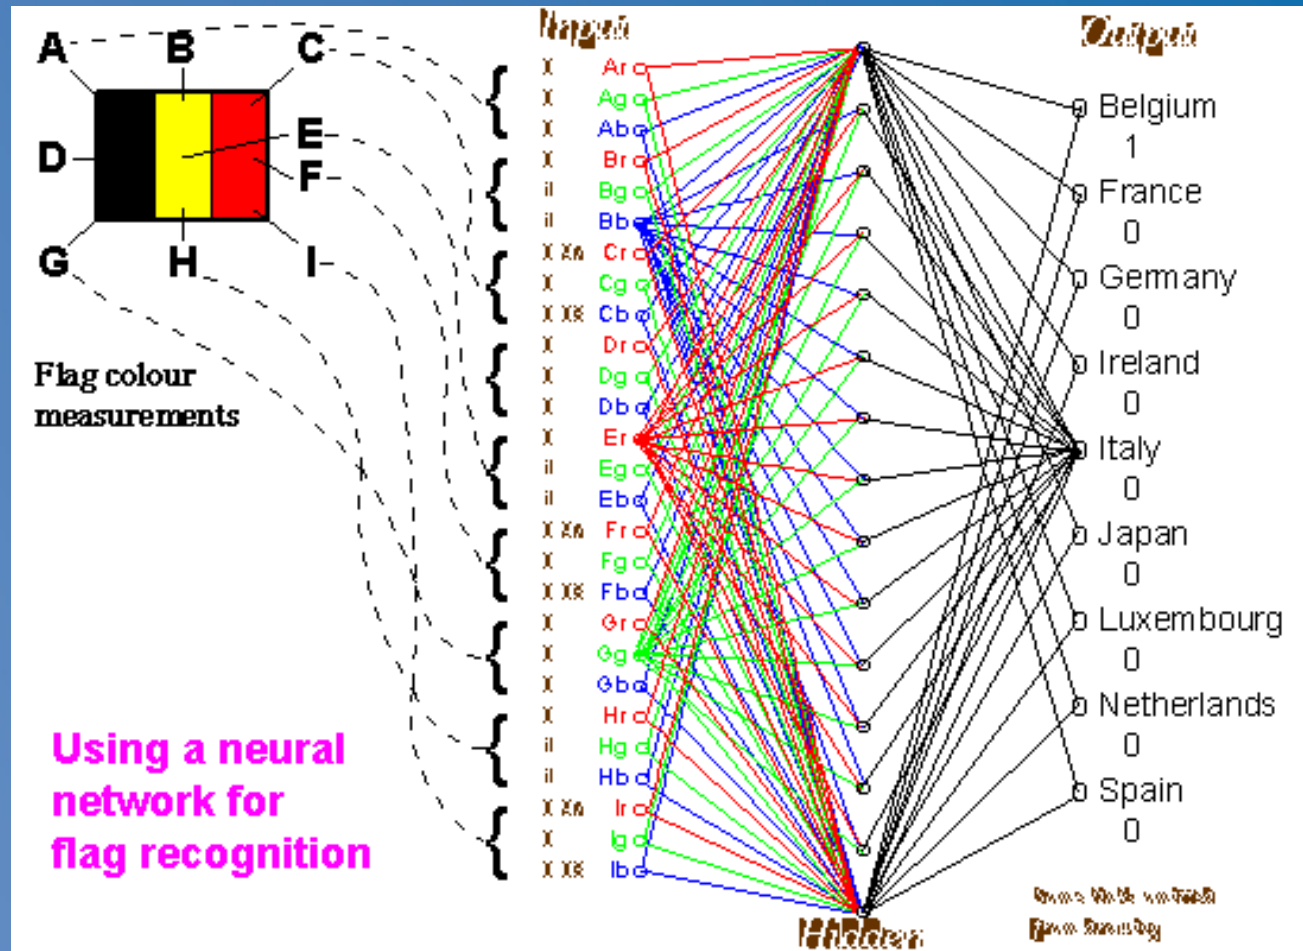


Mnohovrstvé dopředné síť



Plně propojené síť

# Základní funkce



# Typy neuronových sítí



- Neuronové sítě bývají nejčastěji rozděleny podle způsobu svého propojení.
- Dopředné (feedforward) sítě obsahuje pouze dopředné propojení, tedy propojení v jednom směru neobsahující zpětnovazebné smyčky.
- Sítě obsahující několik vrstev propojených pouze dopředně se nazývají vícevrstvé dopředné sítě.
- Je-li každý neuron v jedné vrstvě sítě propojen s každým neuronem následující vrstvy sítě pouze jednosměrně, nazýváme tuto síť plně propojenou.
- Sítě, kde jsou všechny neurony propojeny s ostatními obousměrně se nazývají Hopfieldovy sítě

# Příklady použití neuron. sítí



## **Klasifikátory**

- úkolem je zařadit vstupní data do skupin (tříd) podle vzájemné podobnosti

## **Aproximátory funkcí**

- z několika naměřených hodnot je třeba sestavit funkční závislost (např. predikce počtu slunečních skvrn, vývoj kursu koruny apod.)

## **Asociativní paměti**

- na základě předloženého vstupu je síť schopna “vybavit si” odpovídající výstup.

# Fáze činnosti neuronové sítě



- 1) fáze nastavování (učení , trénování)
- 2) fáze pracovní

## Fáze učení

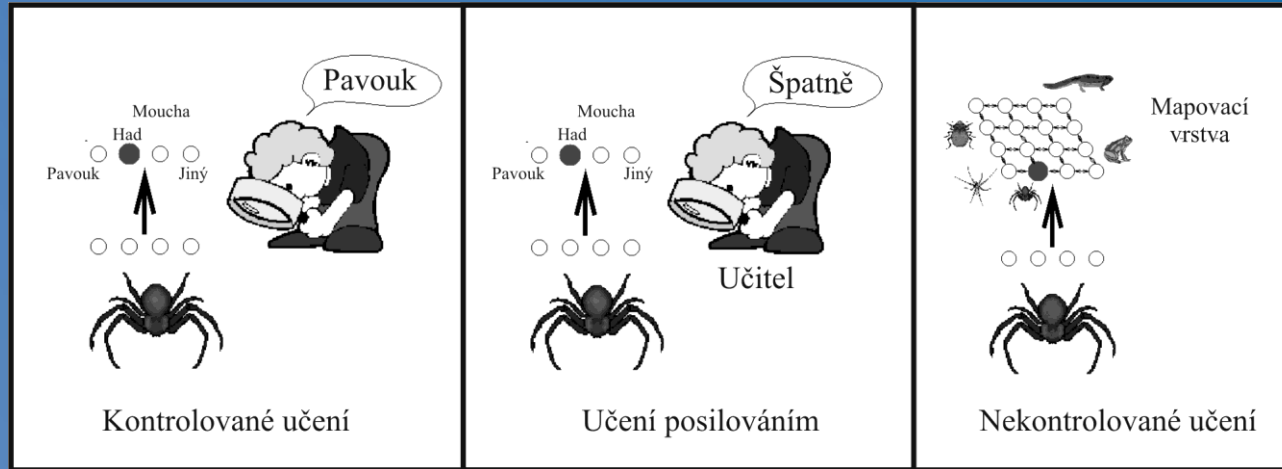
Cílem učení je nastavit váhy jednotlivých neuronů tak, aby síť prováděla požadovanou činnost. Existují 3 způsoby učení:

- a) učení s učitelem (supervised learning)
- b) učení bez učitele (unsupervised learning)
- c) učení posilováním (conditioned learning)

## Fáze pracovní

Neuronová síť reaguje na předložené vstupy podle nastavení, které se “naučila” ve fázi učení.

# Typy učení



Kontrolované (supervised) typy učení se používají při aplikaci v oblastech kontroly, automatizace, robotiky a počítačového vidění. Nekontrolované (unsupervised) učení se používá při plánování, osvojování si zkušeností (akvizice) a při převodu analogového do digitálního kódu.



# Paměť neuronových sítí



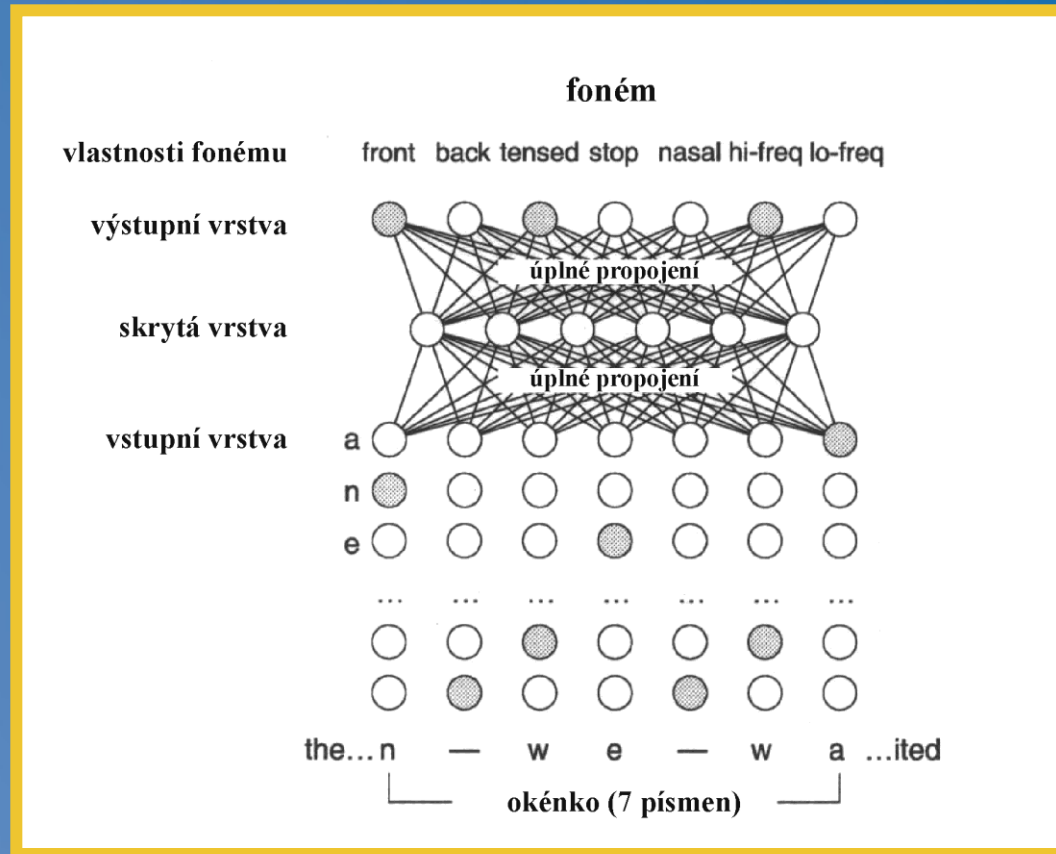
Nejčastěji hovoříme o celé síti neuronů, ve které je paměť obsažena v distribuované formě. Konekcionistické modely paměti se dají rozčlenit do tří základních skupin.

První je tvořena vícevrstevnými dopřednými sítěmi pro rekognici a kategorizaci.

Druhou tvoří autoasociativní síť pro rekognici a rozpoznávání vzorů.

Třetí tvoří rekurentní heteroasociativní síť paměťových sekvencí.

# NetTalk



Jedná se o neuronovou síť spojenou s řečovým syntetizérem, která je schopná převádět psaný anglický text do mluvené podoby. Práce sítě končí přiřazením fonému, jehož expresi již provádí samostatný hlasový syntetizér.

# Hopfieldovy sítě



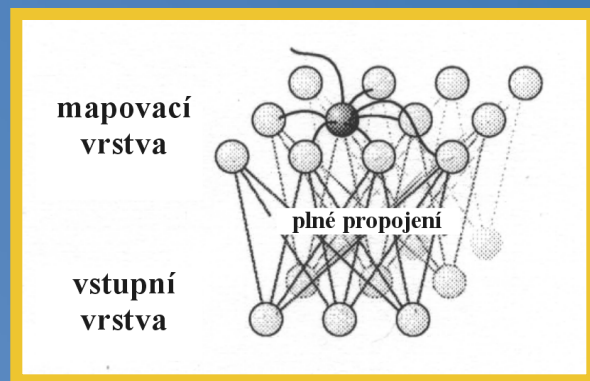
- Hopfieldova neuronová síť, navržená začátkem osmdesátých let, je typickým příkladem autoasociativní sítě.
- V současné době existuje několik modifikací sítě. Může být použita jako asociativní paměť, klasifikátor (kategorizace) nebo k řešení optimalizačních problémů.
- Asociativnost hopfieldovské paměti je dána tím, že vybavovaný vzor zadáváme jistou jeho částí, do značné míry libovolnou. Vzor je vybavován podle části svého „obsahu“, tj. prostorového umístění, nikoliv odkazem na nějakou jeho „adresu“ (jako u paměti RAM). Jedná se o content adressable memory (CAM).

# Kohonenovy sítě



Jestliže tvoří Hopfieldovy sítě způsob paměťového systému blízký lidskému, rozšiřuje Kohonenův model schopnosti neuronových sítí ještě blíže směrem k lidské inteligenci.



Jím navržená síť obsahuje schopnosti, které bychom v psychologii nazvali: exaktnější kategorizace, zapomínání, selektivita a díky mapovací vrstvě, informace o funkci systému s možností jejich využití při kontrole či zpětné vazbě.



# Samooorganizující se sítě



Základem Kohonenových sítí je plné propojení vstupní vrstvy s mapovací vrstvou. Tato vrstva má laterální propojení se všemi neurony své vrstvy. Pro neblížší neurony jsou propojení posilující, pro vzdálené inhibiční při zachování topologie. V praxi to znamená, že jsou blízké body ve vstupním prostoru mapovány na blízké body ve výstupním prostoru. Již zmíněnou vlastností Kohonenových sítí je schopnost Hebbovského učení. Díky tomu se sítě dají považovat jako neurobiologicky plausibilní.

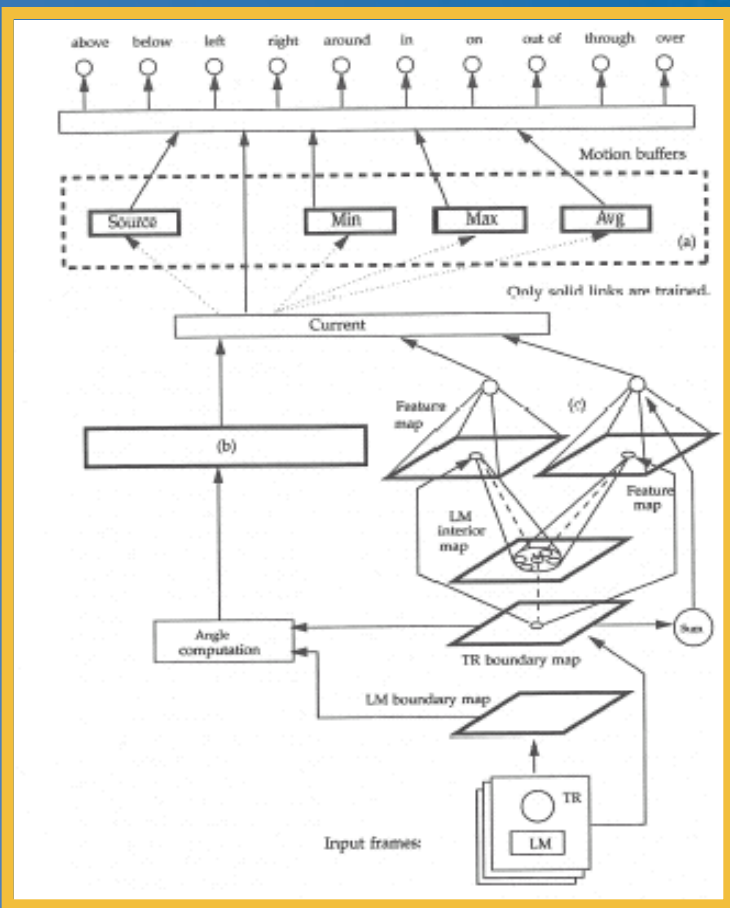
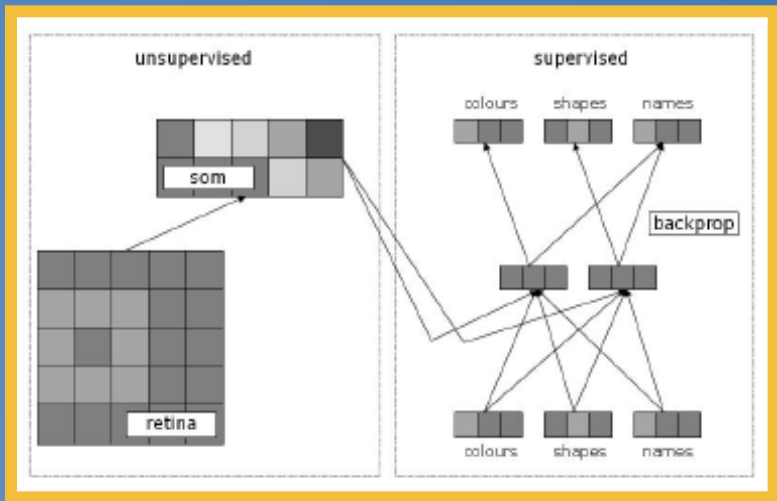


# Hebbovské učení



- Základní pravidlo kanadského neurobiologa Donalda Hebba říká, že pokud se nachází neuron A v dostatečné blízkosti, aby excitoval neuron B a opakovaně pálí, tak v obou neuronech nastanou metabolické procesy, které zvýší pálení. A podporuje pálení B, je-li dostatečně blízko.
- Možnosti biologických sítí se dají převést i do jejich umělých variant. Základní princip Hebbovského učení vychází ze zvyšování hodnot vah neuronů, které jsou spolu propojeny a během učení jsou aktivovány společně.
- Koukolík uvádí složitější variantu Hebbovského učení, kdy neurony mají schopnost se koaktivovat podle vzorce pálení. Nestačí pouhá aktivita a blízkost v prostoru, ale nutná je i znalost vzorce. Využití pulzních neuronů v oblasti Hebbovského učení rozšiřuje možnosti koaktivace i mezi vzdálenými neurony.

# Model přenosu ukotvení



# Konkrétní model



**Audio vstup** – 2D audio vektor

**Video vstup** – 2D vektor polohy

**Audio síť** – SOM 2D grid


**Video síť** – SOM 2D grid

**Výstupní funkce** – WTA, WTM

**Multimodální vstup** - výstup audio a video

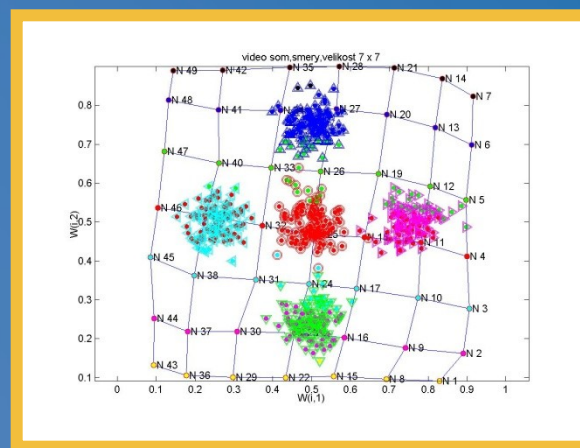
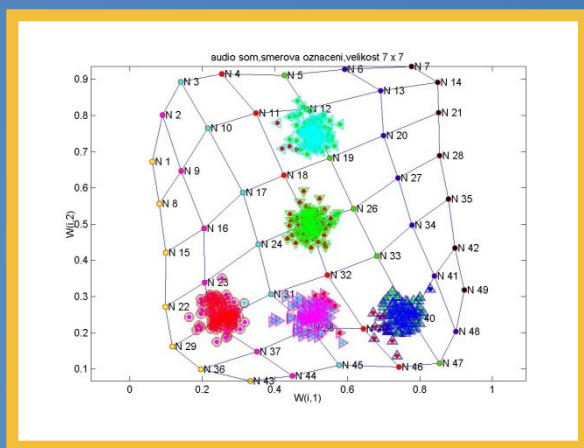
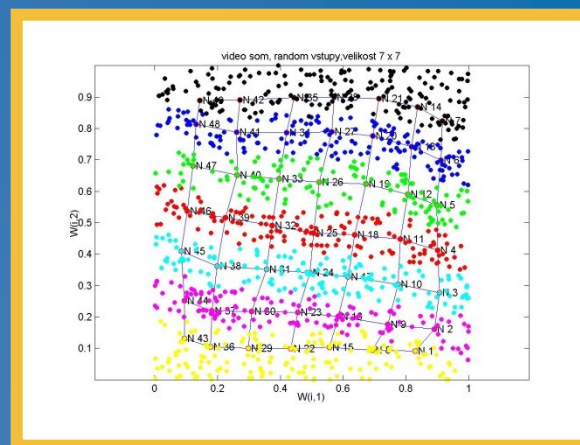

**Multimodální síť** – 1D SOM nebo Neural Gas

**Výstup** – WTA (pro ověření správné kategorizace)

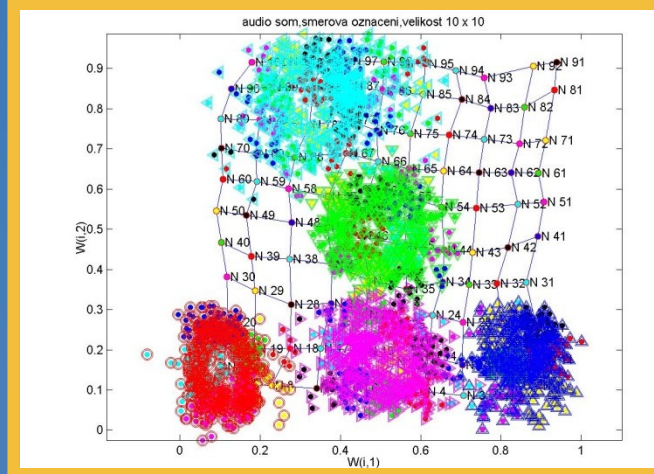
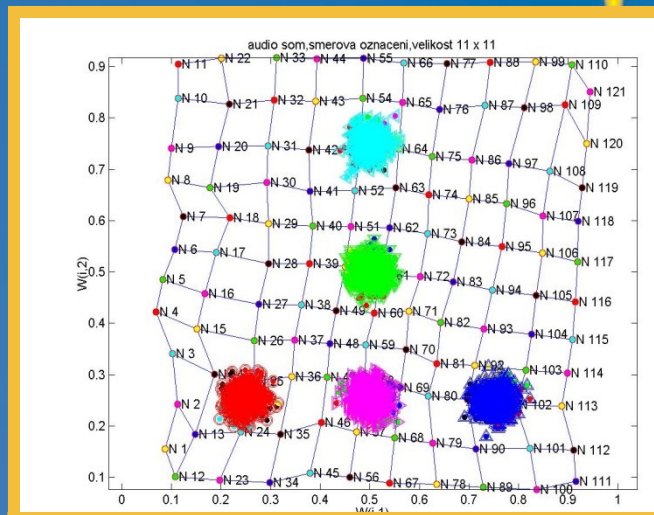
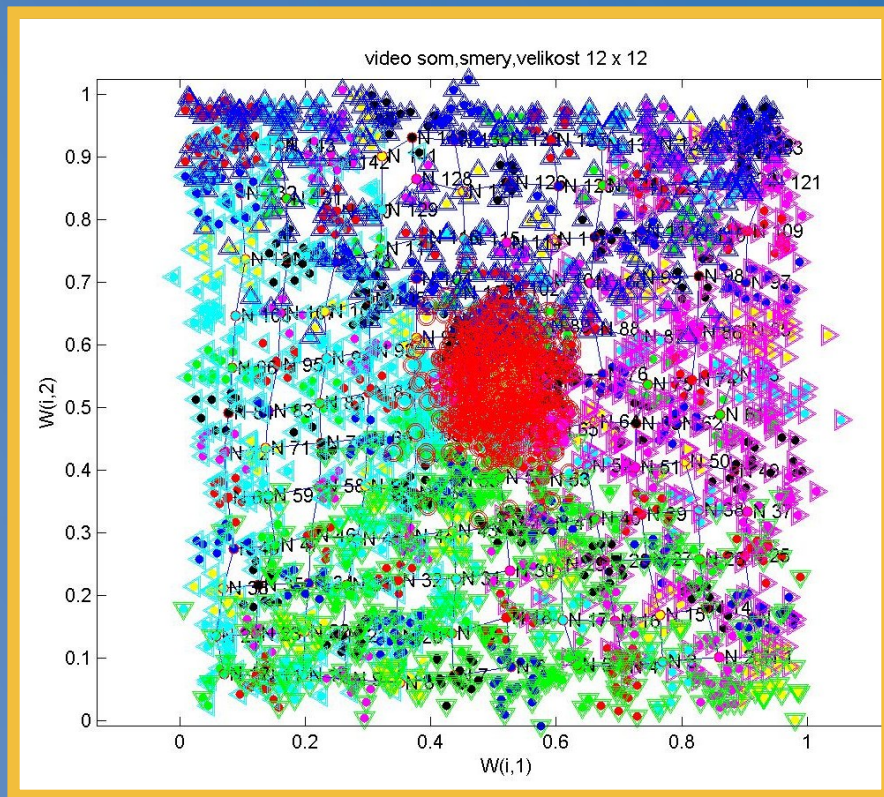




# Model s umělými vstupy



# Model s reálnými vstupy

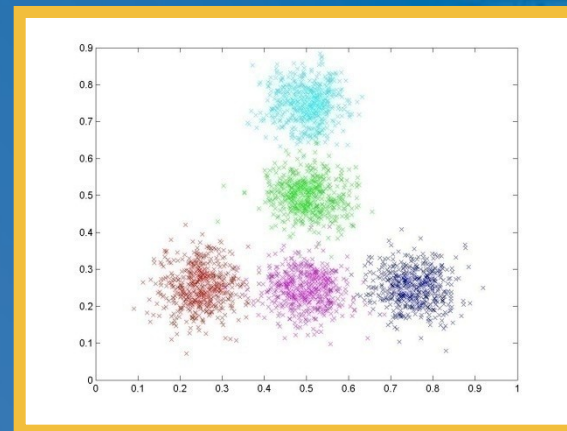
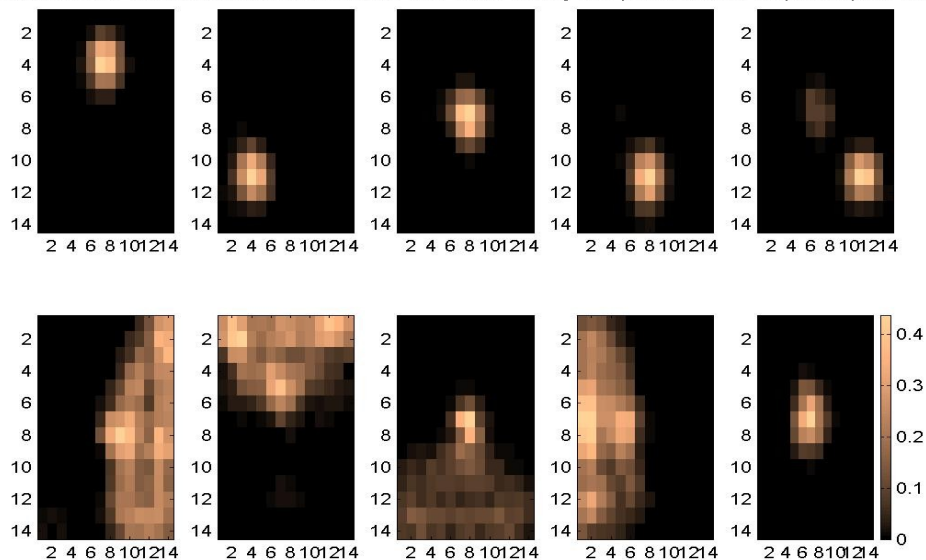


2. Model – Síť testovaná pomocí reálných vizuálních „fuzzy” vstupů a „fuzzy” auditivních vstupů

# Analýza multimodální vrstvy

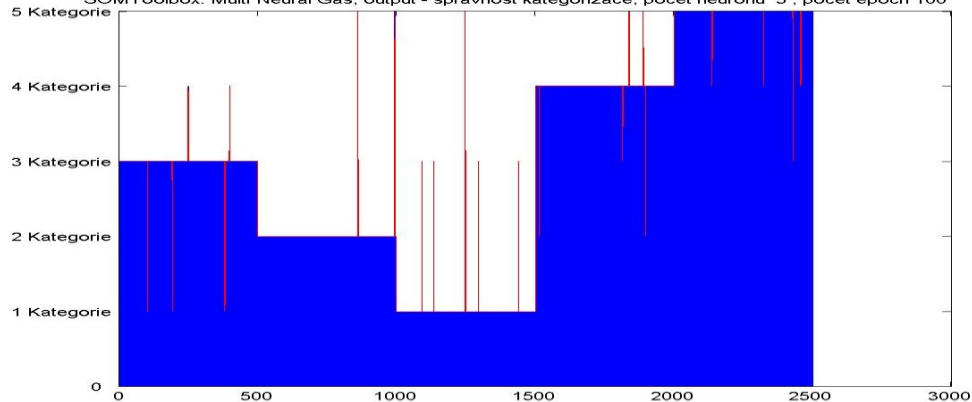


SOMToolbox: Multi Neural Gas, nahore Audio dole Video vektory vah, pocet neuronu 5 , pocet epoch 100

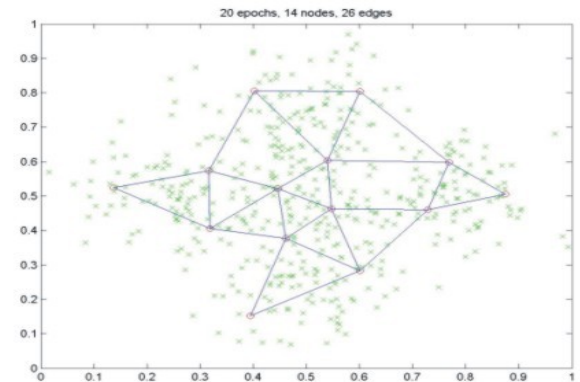
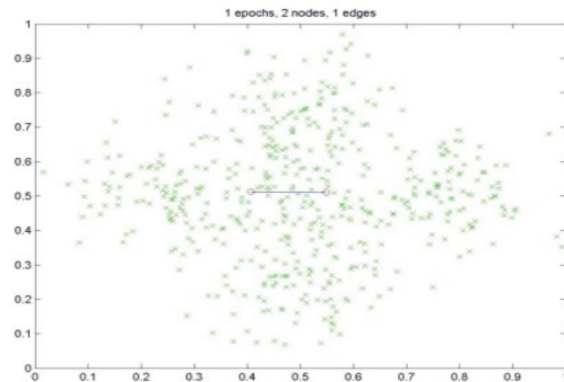




Použití sítě typu  
Neural Gas


SOMToolbox: Multi Neural Gas, output - spravnost kategorizace, pocet neuronu 5 , pocet epoch 100




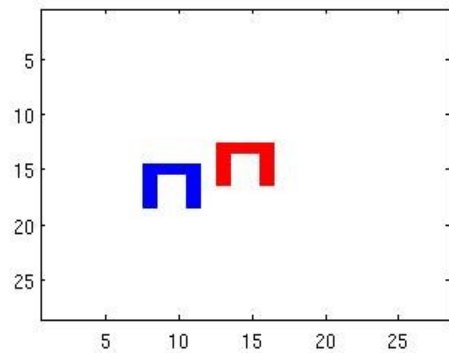
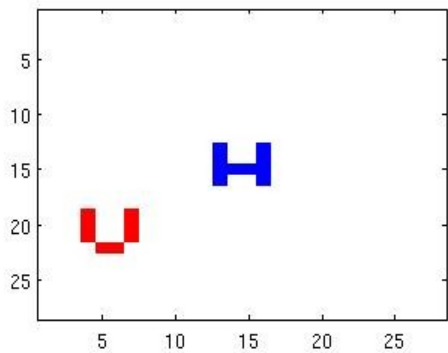






# Rostoucí síť




# Nová verze modelu






SOM Weights - size 3x3

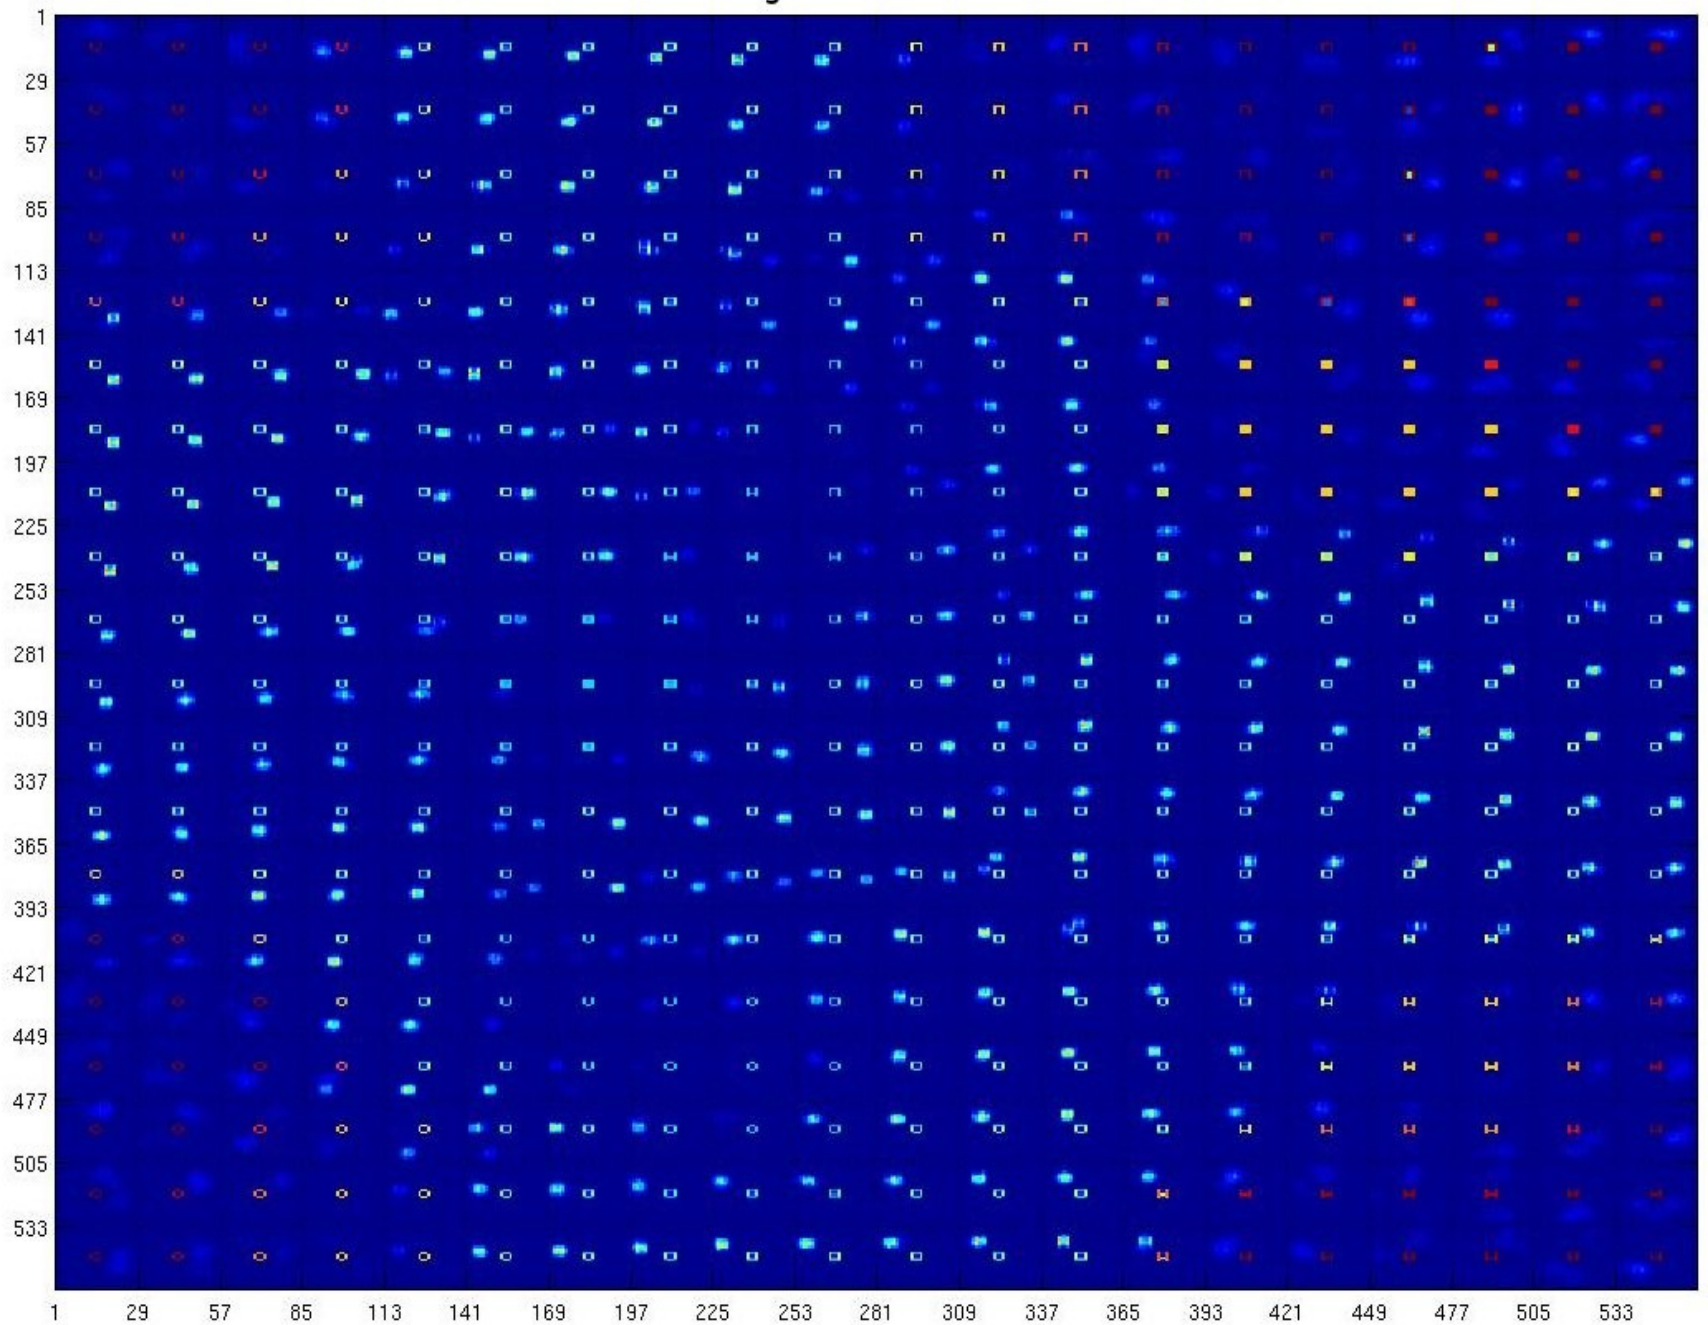



Som weights - size 6x6 neurons







Som weights - size 20x20 neurons














Recsom - size 3x3 neurons

Text input


sentence      reversed order sentence

|       |       |       |     |     |     |     |       |       |       |
|-------|-------|-------|-----|-----|-----|-----|-------|-------|-------|
| green | box   | above | red | box | red | box | above | green | box   |
| blue  | box   | above | red | box | red | box | above | blue  | box   |
| red   | bed   | above | red | box | red | box | above | red   | bed   |
| green | bed   | above | red | box | red | box | above | green | bed   |
| blue  | bed   | above | red | box | red | box | above | blue  | bed   |
| red   | ball  | above | red | box | red | box | above | red   | ball  |
| green | ball  | above | red | box | red | box | above | green | ball  |
| blue  | ball  | above | red | box | red | box | above | blue  | ball  |
| red   | cup   | above | red | box | red | box | above | red   | cup   |
| green | cup   | above | red | box | red | box | above | green | cup   |
| blue  | cup   | above | red | box | red | box | above | blue  | cup   |
| red   | table | above | red | box | red | box | above | red   | table |
| green | table | above | red | box | red | box | above | green | table |
| blue  | table | above | red | box | red | box | above | blue  | table |

recsSOM BMUs - number

sentence      reversed order sentence

|   |   |   |   |   |   |   |   |   |   |
|---|---|---|---|---|---|---|---|---|---|
| 9 | 3 | 2 | 7 | 3 | 7 | 3 | 2 | 9 | 3 |
| 8 | 3 | 2 | 7 | 3 | 7 | 3 | 2 | 8 | 3 |
| 7 | 8 | 2 | 7 | 3 | 7 | 3 | 2 | 7 | 8 |
| 9 | 8 | 2 | 7 | 3 | 7 | 3 | 2 | 9 | 8 |
| 8 | 8 | 2 | 7 | 3 | 7 | 3 | 2 | 8 | 8 |
| 7 | 3 | 2 | 7 | 3 | 7 | 3 | 2 | 7 | 3 |
| 9 | 3 | 2 | 7 | 3 | 7 | 3 | 2 | 9 | 3 |
| 8 | 3 | 2 | 7 | 3 | 7 | 3 | 2 | 8 | 3 |
| 7 | 2 | 2 | 7 | 3 | 7 | 3 | 2 | 7 | 2 |
| 9 | 2 | 2 | 7 | 3 | 7 | 3 | 2 | 9 | 2 |
| 8 | 2 | 2 | 7 | 3 | 7 | 3 | 2 | 8 | 2 |
| 7 | 4 | 2 | 7 | 3 | 7 | 3 | 2 | 7 | 4 |
| 9 | 4 | 2 | 7 | 3 | 7 | 3 | 2 | 9 | 4 |
| 8 | 4 | 2 | 7 | 3 | 7 | 3 | 2 | 8 | 4 |



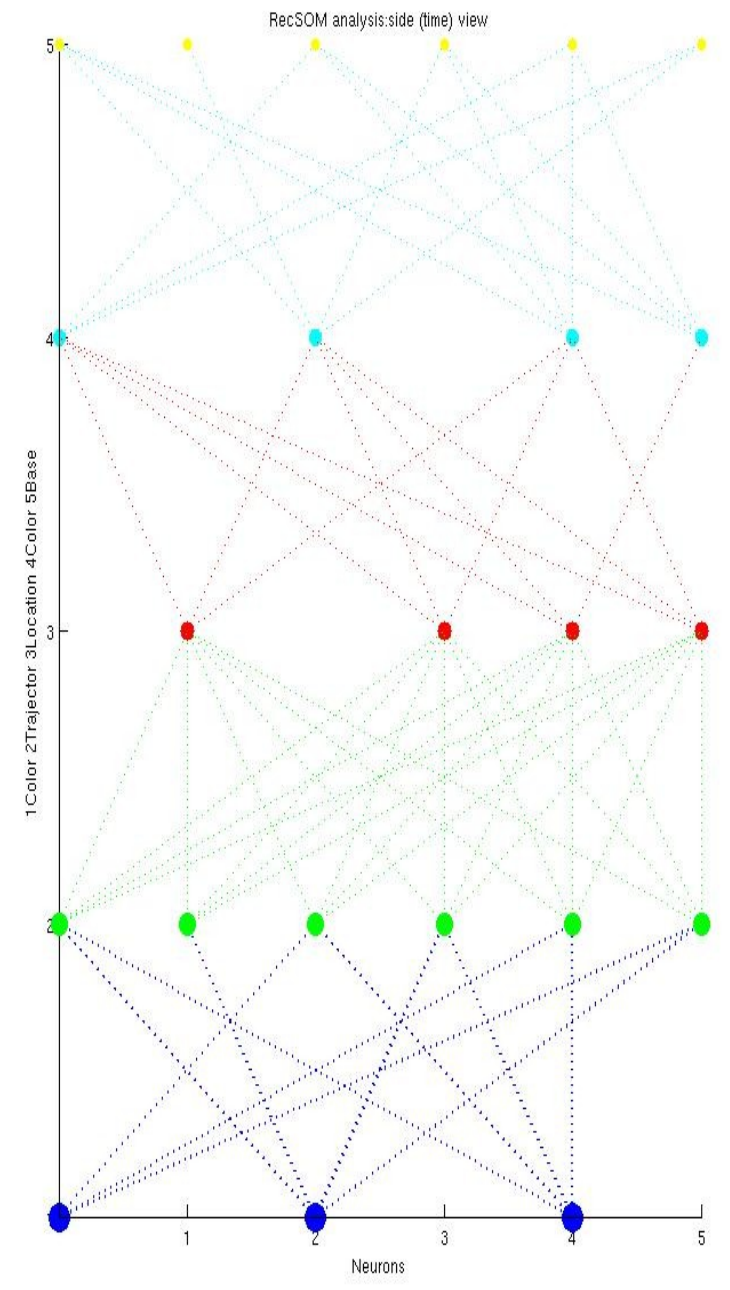
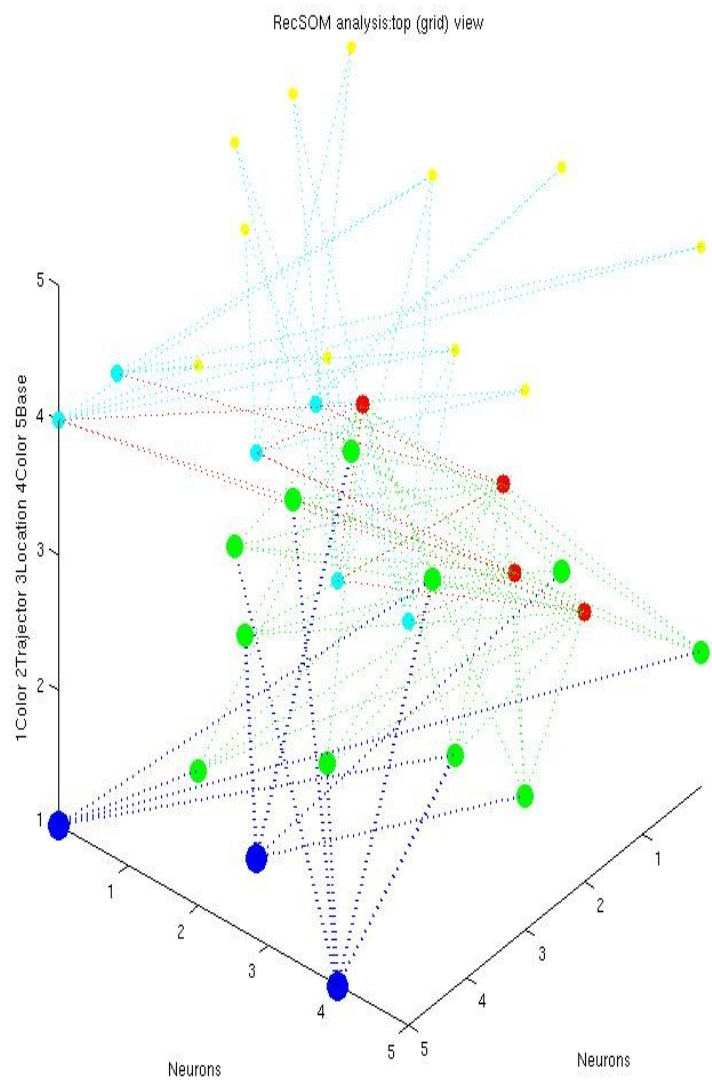
Recsom (without reset) - size 13x13 neurons

Text input



| sentence |       |       |     |     | reversed order sentence |     |       |       |       |
|----------|-------|-------|-----|-----|-------------------------|-----|-------|-------|-------|
| green    | box   | above | red | box | red                     | box | above | green | box   |
| blue     | box   | above | red | box | red                     | box | above | blue  | box   |
| red      | bed   | above | red | box | red                     | box | above | red   | bed   |
| green    | bed   | above | red | box | red                     | box | above | green | bed   |
| blue     | bed   | above | red | box | red                     | box | above | blue  | bed   |
| red      | ball  | above | red | box | red                     | box | above | red   | ball  |
| green    | ball  | above | red | box | red                     | box | above | green | ball  |
| blue     | ball  | above | red | box | red                     | box | above | blue  | ball  |
| red      | cup   | above | red | box | red                     | box | above | red   | cup   |
| green    | cup   | above | red | box | red                     | box | above | green | cup   |
| blue     | cup   | above | red | box | red                     | box | above | blue  | cup   |
| red      | table | above | red | box | red                     | box | above | red   | table |
| green    | table | above | red | box | red                     | box | above | green | table |
| blue     | table | above | red | box | red                     | box | above | blue  | table |

recsSOM BMUs - number


| sentence |     |    |     |   | reversed order sentence |    |    |     |     |
|----------|-----|----|-----|---|-------------------------|----|----|-----|-----|
| 45       | 53  | 52 | 150 | 2 | 112                     | 28 | 52 | 58  | 40  |
| 119      | 27  | 52 | 150 | 2 | 112                     | 28 | 52 | 158 | 27  |
| 112      | 135 | 26 | 150 | 2 | 162                     | 28 | 52 | 150 | 94  |
| 98       | 157 | 26 | 150 | 2 | 126                     | 54 | 52 | 58  | 157 |
| 119      | 108 | 26 | 150 | 2 | 126                     | 54 | 52 | 158 | 108 |
| 112      | 16  | 39 | 150 | 2 | 165                     | 54 | 52 | 150 | 42  |
| 98       | 55  | 39 | 150 | 2 | 124                     | 28 | 52 | 58  | 66  |
| 119      | 30  | 39 | 150 | 2 | 140                     | 28 | 52 | 158 | 30  |
| 112      | 36  | 13 | 150 | 2 | 163                     | 28 | 52 | 150 | 36  |
| 98       | 47  | 13 | 150 | 2 | 139                     | 54 | 52 | 58  | 23  |
| 119      | 62  | 13 | 150 | 2 | 139                     | 54 | 52 | 158 | 62  |
| 112      | 130 | 25 | 150 | 2 | 152                     | 54 | 52 | 150 | 130 |
| 98       | 104 | 25 | 150 | 2 | 125                     | 14 | 52 | 58  | 88  |
| 119      | 103 | 25 | 150 | 2 | 151                     | 14 | 52 | 158 | 116 |









RecSOM analysis:top (grid) view




RecSOM analysis:side (time) view





RecSOM analysis:top (grid) view




RecSOM analysis:side (time) view






RecSOM analysis:top (grid) view




RecSOM analysis:side (time) view



# Výhody neuronových sítí



- Paralelismus
- Schopnost adaptace
- Sebeorganizace
- Distribuovaná paměť
- Odolnost proti chybám
- Schopnost generalizace
- Jednoduchá konstrukce



# Nevýhody neuronových sítí



- Neuronové sítě jsou paralelní systémy, ale bývají často simulované pomocí klasických sériových počítačů.
- Čas na zpracování úlohy roste exponenciálně se složitostí úlohy – Scaling problem
- Neuronové sítě jsou tedy využívány pouze k řešení jednoduchých úloh.
- Výkonnost sítě je závislá na kvalitě a druhu předzpracovaných dat.
- Neuronové sítě nedokáží vysvětlit své výsledky. Pravidla podle kterých operují jsou neznámá.

# Příště



## Závěrečné shrnutí



# Konec



Děkuju za pozornost

