

# Aplikace teorie neuronových sítí

Doc. RNDr. Iveta Mrázová, CSc.

Katedra teoretické informatiky

Matematicko-fyzikální fakulta

Univerzity Karlovy v Praze

# Neuronové sítě

## – Modulární architektury –

Doc. RNDr. Iveta Mrázová, CSc.

Katedra teoretické informatiky

Matematicko-fyzikální fakulta

Univerzity Karlovy v Praze

# Robustnost vrstevnatých neuronových sítí

- ◆ **Vzhledem ke ztrátě skrytého neuronu**
  - „1-neuronová“ robustnost
  - Modifikace chybové funkce pomocí tzv. „robustnostního členu“
  - „prořezávání a duplikace“ ~ zdvojení takových neuronů, jejichž ztráta způsobí největší chybu na výstupu sítě
- ◆ **Vzhledem k drobným odchylkám předkládaných vstupních vzorů**
  - **Separační charakteristika**
  - K libovolné vrstevnaté neuronové síti (a dané konečné množině vzorů) lze zkonstruovat „robustnější“ síť s „téměř stejnými“ výstupy (~  $\epsilon$ -ekvivalentní síť)

# $\varepsilon$ – ekvivalence

- ◆ Existuje mnoho vrstevnatých neuronových sítí s požadovaným vstupně / výstupním chováním
- ◆ Dvě vrstevnaté neuronové sítě jsou  $\varepsilon$ -ekvivalentní, jestliže dávají pro všechny vstupní vzory z dané konečné množiny vzorů tentýž výstup s jistou  $\varepsilon$ -přesností:

ností:  $\|\vec{y}_{B_1} - \vec{y}_{B_2}\| \leq \varepsilon$  ,      kde

$$\|\vec{y}_{B_1} - \vec{y}_{B_2}\| = \sum_{i=1}^m (y_{B_1,i} - y_{B_2,i})^2$$

- $m$  ... počet výstupních neuronů sítí  $B_1$  ,  $B_2$

# Robustnost vzhledem ke ztrátě skrytého neuronu

## 1-neuronová robustnost:

- ◆ Určena chybou způsobenou ztrátou jednoho skrytého neuronu

$$\varepsilon = E_{d_m} - E_1 = \frac{1}{2N_h} \sum_p \sum_i \sum_k (y_{i,k} - d_i)^2 - \frac{1}{2} \sum_p \sum_i (y_i - d_i)^2$$

- $N_h$  ... počet skrytých neuronů
- $d_i$  ... požadovaný výstup pro daný vstupní vzor  $p$
- $y_i$  ... skutečný výstup výstupního neuronu  $i$
- $y_{i,k}$  ... výstup neuronu  $i$ , jestliže chybí skrytý neuron  $k$

# Robustnost vzhledem ke ztrátě skrytého neuronu (2)

## Další možnosti vyjádření chyby:

- ♦ Určena odchylkou výstupu způsobenou ztrátou jednoho skrytého neuronu  $E_{y_m} = \frac{1}{2N_h} \sum_p \sum_i \sum_k (y_i - y_{i,k})^2$   
(  $E_{y_m} = 0$  , jestliže se při ztrátě skrytého neuronu výstup sítě pro trénovací množinu nezmění)

- ♦ Nejhorší možné následky

$$E_d = \max_{p,i,k} |y_{i,k} - d_i|$$

$$E_y = \max_{p,i,k} |y_{i,k} - y_i|$$

# Zvýšení robustnosti vrstevnatých NS

## 1) Modifikací chybové funkce: $F = E + \rho E_{rob}$

- $\rho$  ... nastavitelný parametr ovlivňující vzájemný poměr minimalizované střední kvadratické odchylky skutečných a požadovaných výstupů a robustnosti učené sítě

$$E_{y_m} = \frac{1}{2N_h} \sum_p \sum_i \sum_k (f(\xi_i) - f(\xi_{i,k}))^2$$

$$\xi_i = \sum_j x_j w_{ij} \quad \xi_{i,k} = \xi_i - x_k w_{ik}$$

- $x_j$  ... výstup skrytého neuronu  $j$
- $w_{ij}$  ... váha mezi skrytým neuronem  $j$  a výstupním neuronem  $j$
- $f(\xi)$  ... přenosová funkce (sigmoida)

# Zvýšení robustnosti vrstevnatých NS (2)

**TRIK:** minimalizace  $E_{y'}$  namísto minimalizace  $E_{y_m}$

$$E_{y'_{m'}} = \frac{1}{2N_h} \sum_p \sum_i \sum_k (\xi_i - \xi_{i,k})^2 = \frac{1}{2N_h} \sum_p \sum_i \sum_j (x_j w_{ij})^2$$

- Pro výstupní vrstvu

$$\frac{\partial E}{\partial w_{ij}} = (y_i - d_i) y_i (1 - y_i) x_j + \frac{\rho}{N_h} x_j^2 w_{ij}$$

- Pro skrytou vrstvu

$$\frac{\partial E}{\partial w_{il}} = \sum_i \left( \left( \frac{\partial E}{\partial y_i} y_i (1 - y_i) + \frac{\rho}{N_h} w_{ij} x_j \right) w_{ij} \right) x_j (1 - x_j) z_l$$

$z_l \dots$  aktivita vstupního neuronu  $l$



# Zvýšení robustnosti vrstevnatých NS (3)

## 2) Prořezáváním a duplikací

- ◆ Adaptace sítě pomocí standardního algoritmu zpětného šíření
- ◆ Otestování robustnosti sítě
  - Identifikace takového skrytého neuronu, jehož ztráta by způsobila největší změnu robustnosti
  - „zdvojení“ tohoto neuronu
  - „rozpūlit“ váhy obou „kopií“ vedoucí k výstupní vrstvě
  - („kopie“ nahradí některý z ostatních skrytých neuronů)


# „Prořezávání a duplikace“

## Výsledkem jsou:


- robustnější přesnější síť
- malá výpočetní složitost
- lepší generalizace
- omezení problémů souvisejících s výskytem lokálních minim

# Modulární struktura BP-sítí

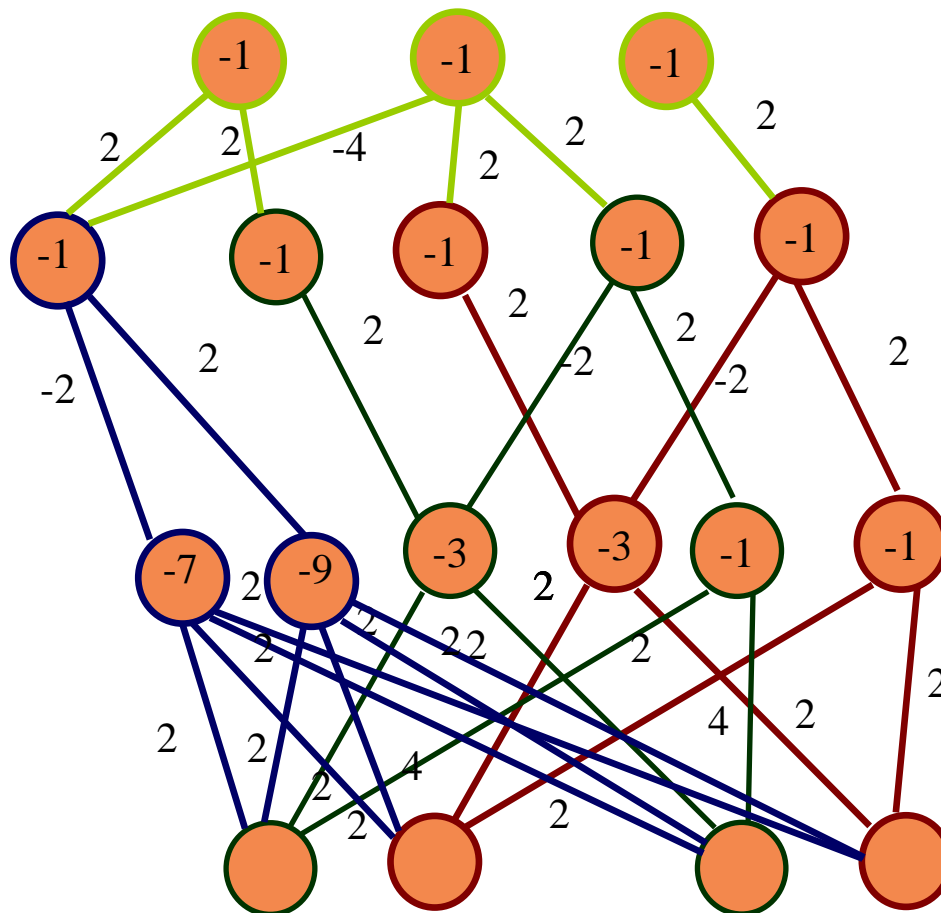
Jednoduchá vrstevnatá neuronová síť



Modulární vrstevnatá neuronová síť



# Modulární struktura BP-sítí: binární sčítání



A BP-network detecting those input patterns where the carry over two orders is necessary to add two binary 2-bit numbers (01 + 11 and 11 + 01)

A BP-network for the binary addition of two binary 1-bit numbers

A BP-network for the binary addition of two binary 1-bit numbers

# Modulární struktura BP-sítí

- ◆ Rozdělení úlohy do jednotlivých podúloh
- ◆ Návrh a vytvoření modulární architektury
  - Strategie pro extrakci  $\varepsilon$ -ekvivalentních modulů BP-sítí
    - Eliminace přebytečných skrytých a/nebo vstupních neuronů
    - Vhodná pro „již natrénované“ sítě
    - Kompromis mezi požadovanou přesností extrahovaného modulu a jeho optimální architekturou
- ◆ Vzájemná komunikace mezi jednotlivými moduly
  - Paralelní a sériová kompozice BP-sítí

# Definice modulu BP-sítě

Necht'  $B$  je BP-sít' s  $l$  skrytými vrstvami. BP-sít'  $M$  je modulem  $B$ , jestliže obě sítě mají stejný počet vrstev a jestliže je každá skrytá vrstva  $L_k^M$  sítě  $M$  podmnožinou skryté vrstvy  $L_k^B$  sítě  $B$ :

$$L_k^M \subseteq L_k^B ; 1 \leq k \leq l$$

# Věta o extrakci modulů

Nechť  $S$  je konečná množina vstupních vzorů  $\mathbf{x}$  a necht'  $B$  je BP-sít' s množinou  $H_l$  neuronů poslední skryté vrstvy,  $|H_l| > 1$ .


Potom k libovolnému  $\varepsilon > 0$  existuje taková konstanta  $K_\varepsilon > 0$ , že platí: Jestliže existuje v  $l$ -té skryté vrstvě neuron  $k$  takový, že:

$$(\forall \mathbf{x} \in S) (\forall i \in O); |w_{ki} z_k| \leq K_\varepsilon$$

potom je BP-sít'  $M^k$ , která je totožná se sítí  $B$  bez neuronu  $k$ ,  $\varepsilon$ -ekvivalentní modul  $B$ ,  $(M^k \sim_\varepsilon^S B)$ .

# Věta o extrakci modulů (2)

## Idea důkazu:





# Věta o extrakci modulů (3)

## Idea důkazu (pokračování):

- ◆ „povolená odchylka“ potenciálu  $\delta_r^-(\xi)$  je v tomto případě menší než „povolená odchylka“ potenciálu  $\delta_r^+(\xi)$
- ◆ Potenciál by se měl změnit „směrem k dělicí nadrovině“
- ◆ Změněný potenciál by měl zachovat umístění vzorku v témže poloprostoru

# Věta o extrakci modulů (4)

## Idea důkazu (pokračování):

- ◆ „povolené odchylky“ potenciálu by měly být nezávislé na jednotlivých vzorech.
- ◆ Eliminace neuronu, pokud je  $\forall x \in S$   
|  $w_{ki}z_k$  | malé
  - $\delta_r / (l + 1)$  pro poslední skrytou vrstvu
  - $l \delta_r / (l + 1)$  pro ostatní skryté vrstvy

# Neuronové sítě s modulární strukturou

- ◆ Adaptivní směsi lokálních neuronových sítí (Jacobs & Jordan)
- ◆ Selektorové sítě s množinou verzí (Partridge & Sharkey)
- ◆ Kombinační sítě s dynamickou volbou klasifikátoru => HYBRIDNÍ MODEL (Lee, Srihari & Nowlan)

# Neuronové sítě s modulární strukturou (2)

## Důležité vlastnosti modelů:


- ◆ Rychlost a konvergence procesu učení
- ◆ Optimalizace architektury
- ◆ Robustnost a generalizace
- ◆ „užitečná různorodost“ jednotlivých modulů  
(~ „useful diversity“)

# Adaptivní směsi lokálních neuronových sítí

## Soustava lokálních sítí s řídicí sítí:

- ◆ Lokální sítě jsou vrstevnaté neuronové sítě typu zpětného šíření
- ◆ Všechny lokální sítě mají stejné vstupy a stejný počet výstupních neuronů
- ◆ Řídicí síť je vrstevnatá síť s výstupy  $P_j$  a stejnými vstupy, jako mají lokální sítě
- ◆ Výstupy systému odpovídají  $\sum_j P_j y^{(j)}$

# Adaptivní směsi lokálních neuronových sítí (2)



# Adaptivní směsi lokálních neuronových sítí (3)

- ◆ Necht' se soustava skládá z  $t$  lokálních sítí  $N_i$  s vahami  $W^{(i)}$  a prahy  $\mathcal{G}^{(i)}$ ;  $i=1, \dots, t$ ; a jedné řídicí sítě  $N_g$  s vahami  $W^{(g)}$  a prahy  $\mathcal{G}^{(g)}$
- ◆ Dále necht' je pro daný trénovací vzor  $(\vec{x}, \vec{d})$  skutečný výstup lokálních sítí  $\vec{y}^{(i)} = (y_1^{(i)}, \dots, y_n^{(i)})$ ;  $1 \leq i \leq t$  a skutečný výstup řídicí sítě  $\vec{y}^{(g)} = (y_1^{(g)}, \dots, y_n^{(g)})$   
 $y_j^{(i)} \in (0,1)$ ;  $\forall j \in \{1, \dots, n\} \wedge i \in \{1, \dots, t\}$   
 $y_j^{(g)} \in (0,1)$ ;  $\forall j \in \{1, \dots, m\}$

# Adaptivní směsi lokálních neuronových sítí (4)

- ◆ Pro koeficienty  $p_i$  by mělo platit:

$$p_i = \frac{y_i^{(g)}}{\sum_{j=1}^t y_j^{(g)}} ; i = 1, \dots, t \quad \left( p_i \in (0,1) \wedge \sum_{i=1}^t p_i = 1 \right)$$

- ◆ Cílová funkce:  $E = \sum_p E_p$

$$E_p = \frac{1}{2} \sum_{i=1}^t \left( p_i \left( \vec{y}^{(i)} - \vec{d} \right) \right)^2 = \frac{1}{2} \sum_{i=1}^t \left( \sum_k g_k^{(i)2} \right)$$

$$g_k^{(i)} = \begin{cases} p_i \left( y_k^{(i)} - d_k \right) & \mathbf{k} \text{ je výstupní neuron} \\ \mathbf{0} & \text{jinak} \end{cases}$$



# Adaptivní směsi lokálních neuronových sítí (5)

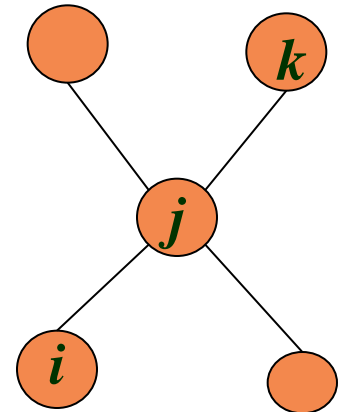
## Proces učení a adaptační pravidla:

- ♦ Adaptace vah a prahů lokálních sítí podle:

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial \mathcal{G}_j} y_i$$


$$\frac{\partial E}{\partial \mathcal{G}_j} = f'(\xi_j) \left( g_j + \sum_k \frac{\partial E}{\partial \mathcal{G}_k} w_{jk} \right)$$

$$g_j^{(i)} = \begin{cases} p_i (y_j^{(i)} - d_j) & j \text{ je výstupní neuron} \\ 0 & \text{jinak} \end{cases}$$



# Adaptivní směsi lokálních neuronových sítí (6)

- ♦ Adaptace vah a prahů řídicí sítě podle:




$$\frac{\partial E}{\partial w_{ij}^{(g)}} = \frac{\partial E}{\partial \mathcal{G}_j^{(g)}} y_i^{(g)}$$

$$\frac{\partial E}{\partial \mathcal{G}_j^{(g)}} = f'(\xi_j^{(g)}) \left( g_j^{(g)} + \sum_k \frac{\partial E}{\partial \mathcal{G}_k^{(g)}} w_{jk}^{(g)} \right)$$

$$g_j^{(g)} = \begin{cases} \left( \frac{1}{2} (\bar{y}^{(j)} - \vec{d})^2 - E \right) \cdot \left( \sum_i y_i^{(g)} \right)^{-1} & j \text{ je výstupní neuron} \\ 0 & \text{jinak} \end{cases}$$

# Adaptivní směsi lokálních neuronových sítí (7)

- ♦ tendence používat ke klasifikaci předkládaných vzorů vždy jen jednu síť
- ♦ **Sériová kompozice dvou soustav lokálních sítí s řídicí sítí:**



- ♦ Přenos chybových členů mezi nejnižšími skrytými neurony  $N_2$  (její vstupní neurony se nyní neuvažují) a výstupními neurony  $N_1$   $\mathcal{G}_i^{(k)}$  ... práh  $i$ -tého výstupního neuronu  $k$ -té lokální sítě z  $N_1$

# Adaptivní směsi lokálních neuronových sítí (8)

$$\begin{aligned}\frac{\partial E}{\partial \mathcal{G}_i^{(k)}} &= f'(\xi_i^{(k)}) \frac{\partial E}{\partial y_i^{(k)}} = f'(\xi_i^{(k)}) \sum_j \sum_l \frac{\partial E}{\partial y_l^{(j)}} \frac{\partial y_l^{(j)}}{\partial y_i^{(k)}} \\ &= f'(\xi_i^{(k)}) \sum_j \sum_l \frac{\partial E}{\partial y_l^{(j)}} f'(\xi_l^{(j)}) \frac{\partial y_l^{(j)}}{\partial y_i^{(k)}} \\ &= f'(\xi_i^{(k)}) \sum_j \sum_l \frac{\partial E}{\partial \mathcal{G}_l^{(j)}} \frac{\partial \xi_l^{(j)}}{\partial y_i^{(k)}}\end{aligned}$$

$j$  ... index přes všechny lokální sítě a řídicí síť z  $N_2$

$l$  ... index neuronů nad vstupy  $j$

# Adaptivní směsi lokálních neuronových sítí (9)

$$\frac{\partial \xi_l^{(j)}}{\partial y_i^{(k)}} = w_{il}^{(j)} p_k^{(1)}$$

$$\frac{\partial E}{\partial \mathcal{G}_i^{(k)}} = f'(\xi_i^{(k)}) p_k^{(1)} \sum_j \sum_l \frac{\partial E}{\partial \mathcal{G}_l^{(j)}} w_{il}^{(j)}$$

pro lokální síť

$$\frac{\partial E}{\partial \mathcal{G}_i^{(g)}} = \frac{1}{\sum_n y_n^{(g)}} f'(\xi_i^{(g)}) \sum_j \sum_l \frac{\partial E}{\partial \mathcal{G}_l^{(j)}} \sum_m w_{ml}^{(j)} (y_m^{(i)} - y_m^{(j)})$$

pro řídicí síť

$m$  ... index přes všechny lokální sítě z  $N_1$

$y_m^i$  ...  $m$ -tý výstup  $i$ -té lokální sítě z  $N_1$

$y_m^j$  ...  $m$ -tý vstup  $j$ -té lokální/řídicí sítě z  $N_2$


# Modulární neuronové sítě: inverzní kinematika robota

- ◆ Kinematická rovnice:  $\vec{x} = \vec{f}(\theta)$ 
  - Převod informace (kartézské souřadnice  $(\vec{x}) \Rightarrow$  polární  $(\theta)$ )
- ◆ Požadavky na rychlost:  $\dot{\mathbf{x}} = \mathbf{J}(\theta) \dot{\theta}$
- ◆ Prvky  $\mathbf{J}$ :  $\partial x_i / \partial \theta_j \quad \forall i, j$
- ◆ Řešení:  $\dot{\theta} = \mathbf{J}^{-1}(\theta) \dot{\mathbf{x}}$
- ◆ Problémy:
  - Inverze matice  $\mathbf{J}$
  - Znalost přesných kinematických parametrů robota, případně jejich odhad

# Modulární neuronové sítě: inverzní kinematika robota (2)


„Naivní“ architektura neuronové sítě pro inverzní kinematiku

$n$  úhlů  
 $n$  kartézských souřadnic (rychlost)



$n$  úhlových rychlostí

Rameno se 2 stupni volnosti



# Simulace ramene se 2 stupni volnosti

- ◆ **Kartézské souřadnice ( x , y ):**

$$\begin{bmatrix} x \\ y \end{bmatrix} = \begin{bmatrix} d_1 \cos \theta_1 + d_2 \cos(\theta_1 + \theta_2) \\ d_1 \sin \theta_1 + d_2 \sin(\theta_1 + \theta_2) \end{bmatrix}$$

- ◆ **Rovnice pro vyjádření rychlosti:**

$$\begin{bmatrix} \dot{x} \\ \dot{y} \end{bmatrix} = \begin{bmatrix} -d_1 \sin \theta_1 - d_2 \sin(\theta_1 + \theta_2) & -d_2 \sin(\theta_1 + \theta_2) \\ d_1 \cos \theta_1 + d_2 \cos(\theta_1 + \theta_2) & d_2 \cos(\theta_1 + \theta_2) \end{bmatrix} \cdot \begin{bmatrix} \dot{\theta}_1 \\ \dot{\theta}_2 \end{bmatrix}$$


- ◆ **Analytické řešení:**

$$\begin{bmatrix} \dot{\theta}_1 \\ \dot{\theta}_2 \end{bmatrix} = \begin{bmatrix} \frac{\cos(\theta_1 + \theta_2)}{d_1 \sin \theta_2} & \frac{\sin(\theta_1 + \theta_2)}{d_1 \sin \theta_2} \\ -\frac{\cos \theta_1}{d_2 \sin \theta_2} - \frac{\cos(\theta_1 - \theta_2)}{d_1 \sin \theta_2} & -\frac{\sin \theta_1}{d_2 \sin \theta_2} - \frac{\sin(\theta_1 - \theta_2)}{d_1 \sin \theta_2} \end{bmatrix} \cdot \begin{bmatrix} \dot{x} \\ \dot{y} \end{bmatrix}$$

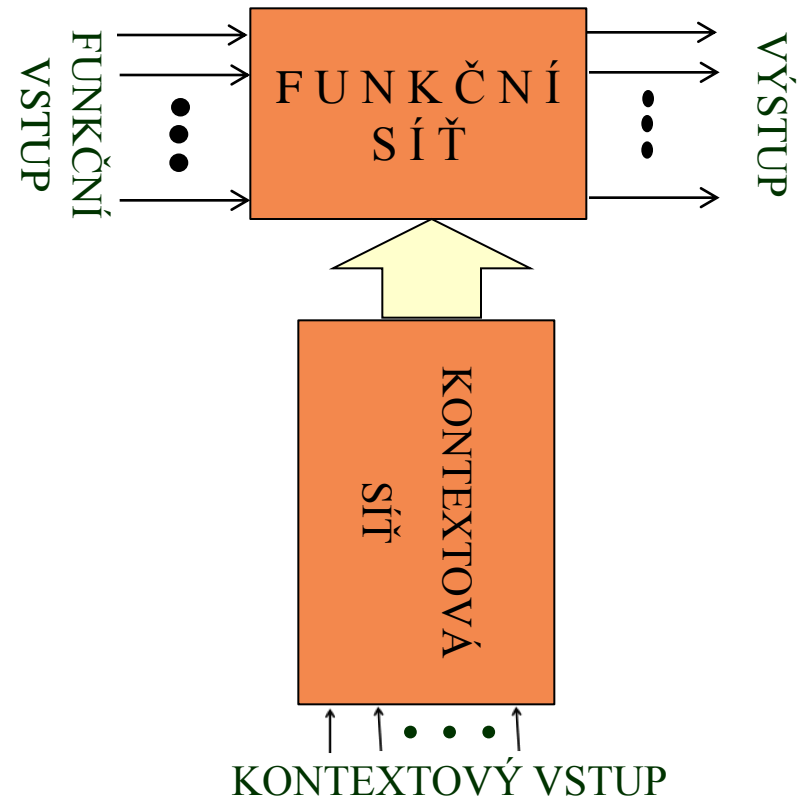


# Modulární neuronové sítě: inverzní kinematika robota (3)

„Standardní“ neuronová síť



Kontextová síť



# Kontextové sítě

## Inverzní kinematický problém:

- ◆ Vstup sítě:  $\theta, \dot{x}$
  - ◆ Výstup sítě:  $\theta^*$
  - ◆ Příklad:
    - robot se 6 stupni volnosti
    - (12 vstupních a 6 výstupních neuronů)
- => velká časová náročnost

# Kontextové sítě (2)


## Architektura a vlastnosti:

- ◆ Dopředné sítě (feed-forward)
- ◆ Algoritmus zpětného šíření
- ◆ Potenciál neuronu  $j$ :  $x_j = \sum_i w_{ij} y_i + b_j$ 
  - $w_{ij}$  ... váha mezi neuronem  $i$  a  $j$
  - $x$  ..... potenciál neuronu
  - $y$  ..... výstup neuronu
  - $b_j$  ..... Práh neuronu  $j$
- ◆ Výstup neuronu  $j$ ,  $y_j$ , pomocí sigmoidy

# Kontextová síť pro inverzní kinematiku robota (4)

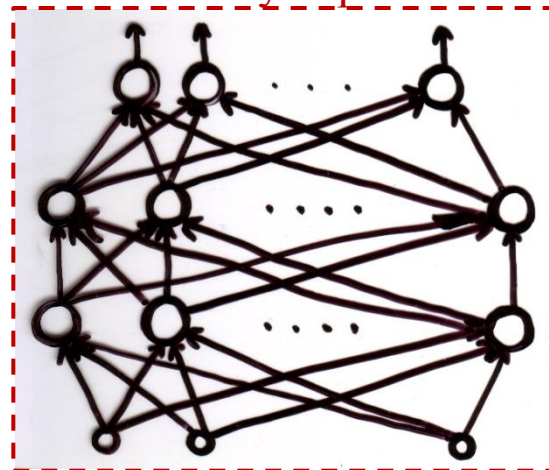
FUNKČNÍ SÍŤ

$n$  kartézských souřadnic  
(rychlost)



$n$  úhlových rychlostí

$n^2$  výstupů



$n$  úhlů

KONTEXTOVÁ SÍŤ

# Kontextové sítě (3)

## Přenos informace mezi kontextovou a funkční sítí:

- ◆ Potenciál neuronu  $j$  funkční sítě:


$$x_j = \sum_i w_{ij} y_i = \sum_i g_l(y_l) y_i$$

- $w_{ij}$  ... váha (funkční sítě) mezi neuronem  $i$  a  $j$
  - $l$  ..... neuron ve výstupní vrstvě kontextové sítě  
(určují váhy funkční sítě)
  - $g(\cdot)$  ... přenos informace mezi neuronem  $l$  kontextové sítě a váhou  $w_{ij}$  funkční sítě
- ◆ Speciální případ:  $g$  je lineární funkce

$$g(x) = a_l x ; a_l \neq 0 \text{ je konstanta } \Rightarrow x_j = \sum_i a_l y_l y_i$$

# Kontextová síť pro inverzní kinematiku robota (5)

Propojení kontextové a funkční sítě:



# Kontextové sítě (4)

## Přenos informace mezi kontextovou a funkční sítí (pro $n$ stupňů volnosti):

- ◆ Volba kontextu: funkční síť by měla reprezentovat lineární funkci  $\Rightarrow$  menší složitost
- ◆ Kontextový vstup:
  - konfigurace ramene (dána vektorem  $\theta$ )
- ◆ Funkční vstup:  $\vec{x}$ 
  - Pro daný kontext  $\theta$  – lineární vztah  $\theta \cdot$  a  $\vec{x}$
  - Funkční síť tedy reprezentuje lineární funkce

# Kontextové sítě (5)

## Přenos informace mezi kontextovou a funkční sítí (pro $n$ stupňů volnosti):

### ◆ Funkční síť:

- $n$  vstupních a  $n$  výstupních neuronů
- Výstupní neurony nemají práh  $\Rightarrow$  výstup  $f(\mathbf{x}) = \mathbf{x}$
- Síť má  $n^2$  vah; ty odpovídají  $J^{-1}(\theta)$

### ◆ Kontextová síť:

- $n^2$  „podsítí“; každá z nich odpovídá skalární funkci pro položky  $J$
- $n$  vstupních neuronů společných pro všechny „podsítě“ (se dvěma skrytými vrstvami)
- Sigmoidální přenosové funkce



# Kontextové sítě (6)

## Přenos informace mezi kontextovou a funkční sítí (pro $n$ stupňů volnosti):

### ◆ Zjednodušení:

- Převod zobrazení  $n \rightarrow n^2$  na  $n^2$  funkcí  $n \rightarrow 1$
- Jasnější funkce skrytých neuronů
- Paralelní učení jednotlivých funkcí
- S rostoucím počtem stupňů volnosti roste pouze počet funkcí