


### 13. Rekurentné neurónové siete, architektúry, spôsoby učenia, úlohy s časovým kontextom (klasifikácia sekvencií, predikcia)

**Motivácia:** k jednému vstupu viacero výstupov, v závislosti od časového kontextu. Viacvrstvá sieť by mala byť rozšírená o možnosť reprezentovať časový kontext, aby tak mohla na základe predloženého vstupu lepšie rozhodnúť o výstupe.

Príklad – paralela: **Mealyho automat:**

- ⇒ generuje postupnosti znakov z množ.  $\{\alpha, \beta\}$
- ⇒ nedá sa simulovať normálnymi doprednými ANN
- ⇒ V informatike sa pojem Mealyho stroj označuje konečný automat s výstupem. Výstup je generovaný na základe vstupu a stavu, ve ktorém se automat nachází. To znamená, že stavový diagram automatu bude pro každý přechod obsahovat výstupní signál.
- ⇒ viac o konečných automatoch: [http://en.wikipedia.org/wiki/Finite\\_state\\_machine](http://en.wikipedia.org/wiki/Finite_state_machine) alebo stručne v češtine: [http://cs.wikipedia.org/wiki/Mealyho\\_automat](http://cs.wikipedia.org/wiki/Mealyho_automat)

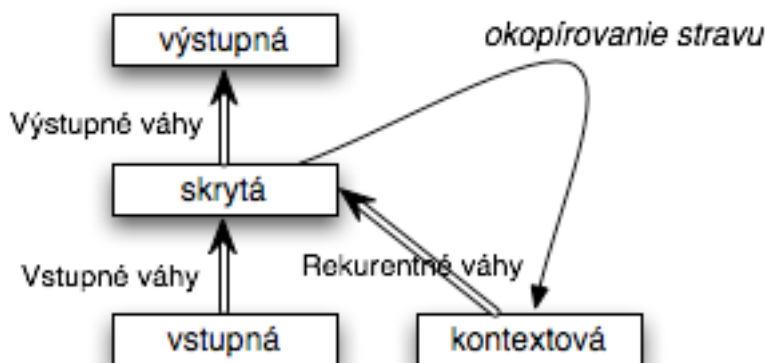


**Riešenie:** pridáme do siete tzv. kontextovú vrstvu, ktorá si „pamätá“ výstup z predošlého času, ktorý sa dá chápať ako akási vnútorná pamäť siete (v Mealyho automate: info o stave, na obr. 1,2,3).

### Architektúry

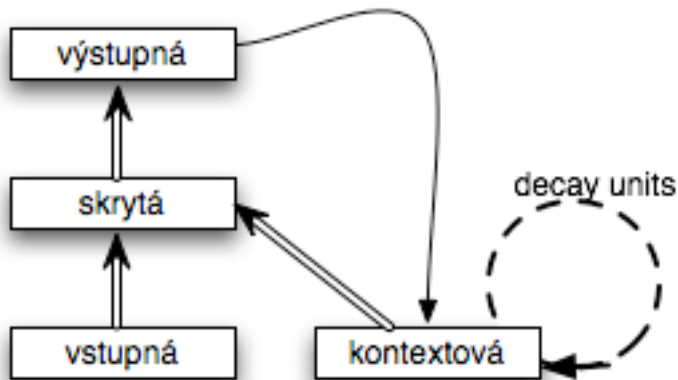
#### Elmanova sieť

najznámejšia a najjednoduchšia architektúra



- kontextová vrstva = skrytá vrstva z predošlého kroku:  $t-1$
- rozpoznávanie sekvencií, predikcia, dopĺňanie krátkych sekvencií

## Jordan

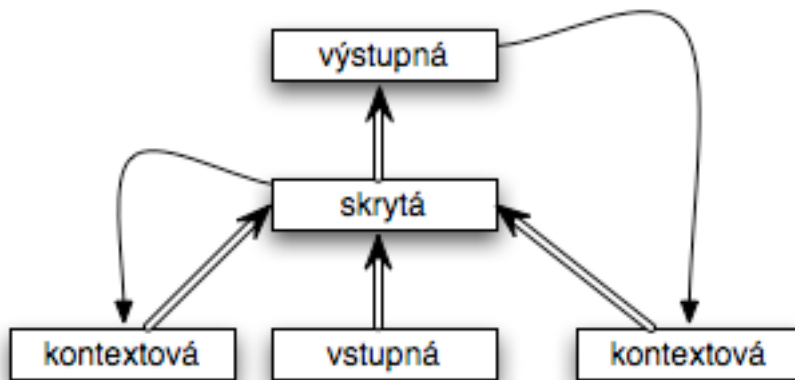


Ak pridáme decay units – pre obsah kontext. vrstvy v  $t+1$  zoberieme časť obsahu kontextovej vrstvy z  $t-1$ :  $C_i(t+1) = y_i(t) + \alpha C_i(t-1)$


Schopnosť nie len rozpoznávať sekvencie ale aj generovať sekvencie rôznej dĺžky

Možnosť: teacher forcing = pri učení nahradíme kontextovú vrstvu žiadaným výstupom v  $t-1$

## Bengio

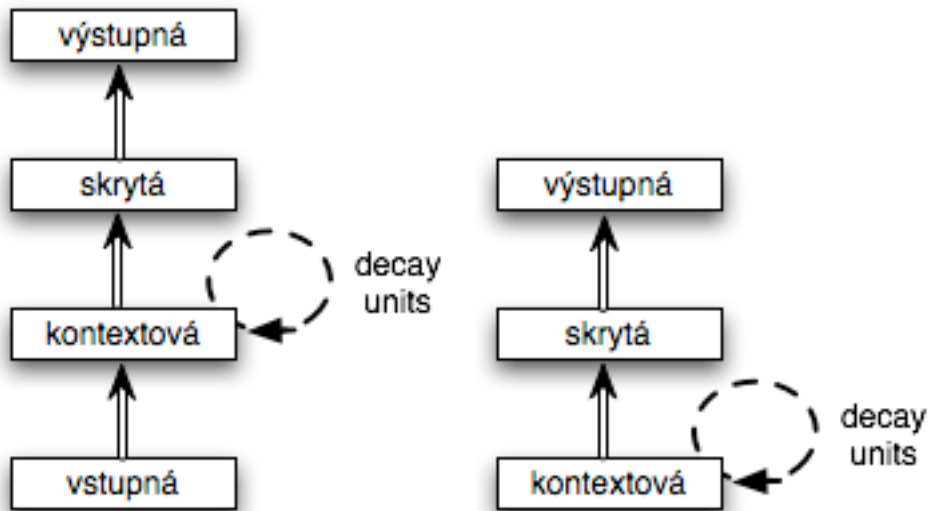


## Williams a Zipser



plne prepojená rekurentná NS

## Mozer a Stornetta




lokálna rekurzia = neurón je rekurentne spojený iba sám so sebou, tzv. local-recurrent-global-feedforward networks.

## Učenie

### Backpropagation through time

- učenie spätným šírením chyby v čase
- rozvinutie rekurentnej siete v čase do potenciálne mnohovrstvovej doprednej siete a použitie klasického backpropu



- v praxi stačí rozvinúť len niekoľko krokov do minulosti (veľkosť okna)

- vzorec:  $\Delta w_{ij} = -\alpha \partial E_{\text{total}}(T) / \partial w_{ij} = \alpha \sum_{t=2}^T \delta_i(t) x_i(t-1)$  kde  $x_i$  je aktivita na  $i$ -tom neuróne v čase  $t-1$ ,  $\delta_i$  je chyba výstupu (očakávaný – skutočný) a  $\alpha$  je rýchlosť učenia a

$$\text{for } t = T: \delta_i(t) = f'(net_i) e_i(t)$$

$$\text{for } 1 < t < T: \delta_i(t) = f'(net_i) [e_i(t) + \sum_{j \in O} w_{ij} \delta_j(t+1)]$$

- problém pri sekvenciách neurčenej dĺžky, pretože treba mať veľké okno (sieť potrebuje vidieť ďaleko do minulosti)

### Real time recurrent learning

- rekurentné učenie v reálnom čase

$$\Delta w_{ij} = -\alpha \partial E(t) / \partial w_{ij} = \alpha \sum_{k \in O} e_k(t) \partial s_k(t) / \partial w_{ij}$$

$$\partial s_k(t) / \partial w_{ij} = f'(net_k(t)) [\delta_{ki}^{kr} s_j(t-1) + \sum_l w_{kl} \partial s_l(t-1) / \partial w_{ij}]$$

$l \in$  units feeding to unit  $k$ , and  $\delta_{ki}^{kr} = 1$ , if  $k = i$ , else 0.

- **Ludove intuitívne vysvetlenie:** pre každú váhu si pamätáme jej **vplyv na aktivitu každého neurónu**. Vplyv váhy  $ij$  (z neurónu  $j$  do  $i$ ) na neurón  $k$  počítame ako váhovanú sumu vplyvov váhy  $ij$  na neuróny, ktoré krmia neurón  $k$ . V prípade, že  $k = i$ , pripočítame aktivitu neurónu  $j$  v čase  $t-1$  (člen delta-kr...). Celé to vynásobíme deriváciou aktivačnej funkcie. Váhu  $ij$  upravujeme ako sumu chýb na výstupných neurónoch  $e_k$  násobenú vplyvom váhy  $ij$  na tieto neuróny  $\partial s_k(t) / \partial w_{ij}$ .

- výpočtovo veľmi náročné: zložitosť  $O(n^4)$ , kde  $n$  je počet neurónov

### Úlohy pre RNN

- **rozpoznávanie postupností:** na vstup prichádzajú znaky, sieť naučená na nejaký automat (gramatiku) signalizuje pozitívne (1) ak znak ešte patrí do postupnosti generovanej automatom a negatívne (0) ak znak už nemôže patriť do postupnosti

- podobne: **doplňanie** postupností, **predikcia** ďalších znakov, **generovanie** nových postupností

- ... simulovanie konečno-stavových automatov – formálnych automatov a jazykov – akéhokoľvek turingovho stroja (výpočtová sila)

- **lingvistické úlohy:** predikcia ďalšieho znaku v slove alebo vete, slova vo vete a pod.