

# АТ-3 Вештачке неуронске мреже


Проф. др Зоран Миљковић

Интелигентни технолошки  
системи



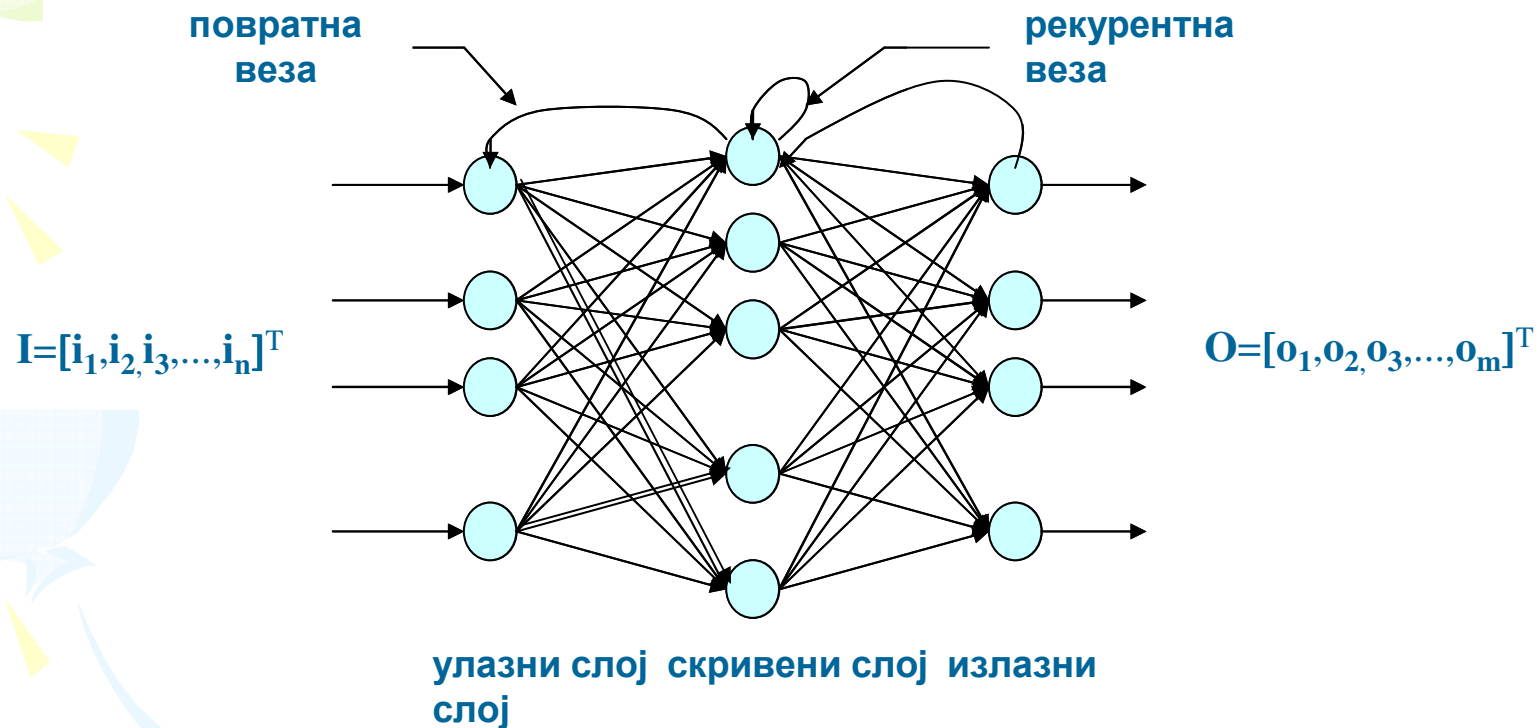
# Вештачке неуронске мреже

- **Деф:** Неуронска мрежа је *парадигма* вештачке интелигенције која се дефинише као *конективни* модел за резоновање заснован на аналогiji са мозгом, уз наглашену *когнитивну* способност да учи и врши генерализацију стеченог знања.
- Парадигма – образац, узор, пример за углед;
- Конективан – повезан;
- Когнитиван – који се тиче сазнања, сазнајни, спознајни;



*Неуронске мреже обезбеђују значајне предности при решавању проблема процесирања који захтевају рад у реалном времену и интерпретацију односа између променљивих у вишедимензионалним просторима.*

# Општа структура вештачке неуронске мреже



- У општем смислу, неуронске мреже представљају скуп једноставних процесирајућих елемената-неурона, међусобно повезаних везама са одговарајућим тежинским односима;
- Неуронске мреже имају способност адаптивног понашања према променама, што значи да могу да уче пресликавања између улазног и излазног простора и да синтетизују асоцијативну меморију.


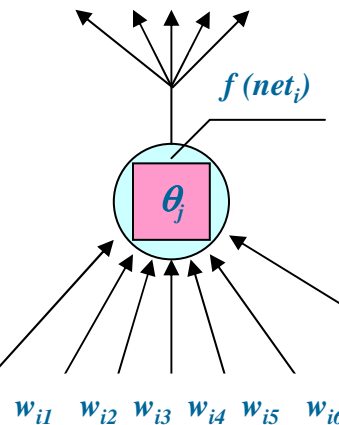
# Основне компоненте

Три основне компоненте:

- Неурон;
- Топологија мреже;
- Алгоритам учења;

Додатне компоненте:

- Величина мреже;
- Функционалност неурона;
- Обучавање;
- Имплементација.



• Неурони (*процесирајући елементи*) примају улазне сигнале/информације од окружења или од других неурона преко веза које могу бити *екситационе* (побуђивачке) или *инхибиторне*.

• Праг активације неурона  $\theta_j$  је његов „окидач”.

# Неурон – основни процесирајући елемент

Три саставна елемента:

- **улазни оператор**  $f(w, x)$ , који обједињује улазе и тежинске односе међусобних веза  $w$  и формира јединствену вредност  $s = f(w, x) = w^T x$  ;
- **функција преноса**  $h(s)$ , која обрађује излаз из неуронског улазног оператора (врши интеграцију), формирајући потребну вредност за активациону функцију;
- **активациона функција**  $f_i(net_i)$  која обрађујући излаз функције преноса управља излазном вредношћу неурона.

# Математичка формулација улазног оператора неурона

| Тип улазног оператора | Математички израз                                    | Напомена   |
|-----------------------|--|--|
| Линеаран              | $net_j = \sum w_{ij} x_j$                            | Линеарна функција  |
| Тежинска сума         | $net_j = \sum w_{ij} x_j + \theta_j$                 | Најчешће коришћен; у неким случајевима праг $\theta_j = 0$ |
| Повратна веза         | $net_j = \alpha net_{старо} + \beta \sum w_{ij} x_j$ | $\alpha, \beta$ су тежинске константе                      |

- Активација неурона (општа једначина):

$$a_i = F_i(a_i(t-1), net_i(t))$$

- Неурон генерише излазни сигнал који је у релацији са његовом активацијом преко **активационе функције**, што се математички може изразити на следећи начин:

$$o_i = x_i(t) = f_i(a_i(t)) = f_i(net_i(t))$$

# Активационе функције неурона

## Основне АФ:

- линеарне,
- бинарне,
- сигмоидне,
- компетитивне и Гаусове.


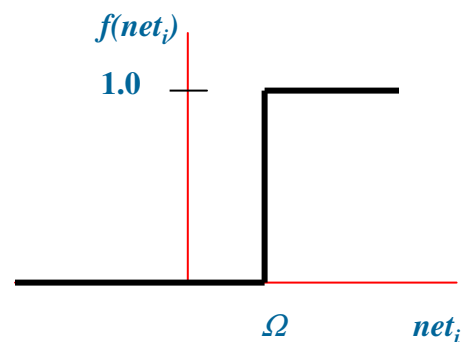
## Линеарна активациона функција

- најједноставнија;
- сумира све улазе у неурон;

$$f_i^l(net_i(t)) = net_i(t)$$

## Бинарна активациона функција

$$f_i^b(net_i(t)) = \begin{cases} 1 & \text{ако је } net_i(t) > \Omega \\ 0 & \text{остало} \end{cases}$$



# Активационе функције неурона

## Сигмоидна активациона функција


- Генерише излазни сигнал који има такође два стабилна стања;
- Континуална и диференцијабилна;
- Нелинеарна и неопадајућа.

Математичка формулација:

$$f_i^s(net_i(t)) = \frac{1}{1 + e^{-(net_i(t) - \Theta) / \tau}}$$

или...

$$f_i^{s*}(net_i(t)) = \frac{1}{2} (1 + \tanh(\lambda net_i(t)))$$





# Алгоритми учења

- Модели неурона су динамички => општа диференцијална једначина:

$$\dot{x} = g_i(x_i, net_i)$$

- излаз  $i$ -тог неурона, при чему је очигледно да се, због **динамичких неуронских модела**, ради о диференцирању по времену;
- улаз  $i$ -тог неурона  $net_i$ , зависи од излаза многих неурона са којима је у вези, практично се развија *систем спрегнутих нелинеарних диференцијалних једначина*.

$$\dot{w}_{ij} = A_i(w_{ij}, x_i, x_j, \dots)$$

- И модификацију тежинских односа потребно посматрати као динамички систем => систем диференцијалних једначина за тежинске односе
- $A_i$  представља **алгоритам учења**;
- Процес учења: одређивање тежинских односа кроз итеративни поступак њихове модификације;
- **Избор** одговарајућег **алгоритма учења**, сходно апликацији за коју се мрежа користи, представља значајан проблем при пројектовању мреже.

# Алгоритми учења

| Алгоритам учења  | Математичка формулација   | Напомене   |
|--|---|--|
| <b>Hebb-ово правило</b> (1949)   | $\partial \Phi / \partial t = O(t)[I_i(t) - O(t)\Phi_i(t)]$                 | $O(t)$ – излаз неурона<br>$I_i(t)$ – улази у неурон<br>$\Phi_i(t)$ – јачина синаптичких веза   |
| <b>Widrow-Hoff-ово правило</b> (1960)<br>(LMS-„least mean square“ алгоритам,<br>тј. алгоритам најмање квадратне разлике) | $\mathbf{w}(t+1) = \mathbf{w}(t) + 2\mu \varepsilon_k \mathbf{x}_k$         | $\mathbf{x}_k$ – $k$ -ти улазни вектор<br>$\mathbf{w}$ – тежински вектор<br>$\mu$ – позитивна константа<br>$\varepsilon_k$ – тренутна разлика (грешка) између захтеване вредности излаза ( $d_k$ ) и актуелне вредности ( $y_k$ )  |
| <b>Генералисано делта правило</b> (1986)<br>(простирање грешке уназад)   | $\mathbf{w}_{ji}(t+1) = \mathbf{w}_{ji}(t) + \eta \delta_{pj} \mathbf{x}_i$ | $\mathbf{x}_i$ – $i$ -ти улазни вектор<br>$\mathbf{w}_{ji}$ – вектор тежинских односа<br>$\eta$ – параметар учења<br>$\delta_{pj}$ – грешка везана за излаз неурона<br>$\delta_{pj} = (y_{pj} - o_{pj}) - y_{pj}$ је захтевана вредност излаза, а $o_{pj}$ је актуелна вредност<br>$p$ -тог обучавајућег вектора за $j$ -ти неурон |

# Алгоритми учења – основна питања

- Које перформансе треба да има систем неуронске мреже у погледу обучавања?
- Да ли је потребно развити чисто динамички систем неуронске мреже?
- Хоће ли фаза учења бити реализована у „on-line“ или „off-line“ режиму?
- Да ли је брзина конвергенције важна за учење неуронске мреже?





# Примена вештачких неуронских мрежа

- *Функционална апроксимација* је представљена скупом независних променљивих  $\mathbf{x} = [x_1, x_2, \dots, x_m]^T$  и излазним сигналом  $y = f(x_1, x_2, \dots, x_m)$ , који су груписани у парове  $\{y, f(\mathbf{x})\}$ .
- *Предикција* је представљена претходним вредностима стања система,  $\mathbf{X} = [x(k), x(k-1), \dots, x(k-n)]^T$ , као и тренутним и претходним вредностима улаза,  $\mathbf{U} = [u(k), u(k-1), \dots, u(k-m)]^T$ , које са будућим стањима система,  $x(k+1) = f(\mathbf{X}, \mathbf{U})$  формирају парове  $\{x(k+1), (\mathbf{X}, \mathbf{U})\}$ .
- *Класификација* је представљена скупом улаза  $\{^c x_i, i=1, \dots, N_j\}$ , који са специфицираном класом  $C_j$  формира парове  $\{C_j, ^c \mathbf{x}_j\}$ .





## „Најраспрострањенији“ модели вештачких неуронских мрежа

- Перцептрон;
  - **„Backpropagation“ (BP) неуронска мрежа;**
  - Асоцијативне неуронске мреже;
  - *Hopfield*-ове неуронске мреже;
  - ART неуронске мреже (ART-1, ART-2, ART-3);
  - *Fuzzy* асоцијативне неуронске мреже;
  - Самоорганизујуће неуронске мреже.
- 
- 

# Перцептрон


- Представља најранији модел вештачке неуронске мреже;
- Пионирски радови:

*McCulloch&Pitts (1943.); Rosenblatt (1958,1962.); Minsky&Papert (1969).*




# Перцептрон

- Једноставна архитектура;
- Користи простирање сигнала у једном смеру („*feedforward*”);
- Има један или више слојева неурона између улазних и излазних неурона (најчешће цео перцептрон има два слоја);
- Функционише на бази супервизорског учења;
- Линеарни тип неурона са прагом активације  $\theta$ .



# Структура перцептрона - *Rosenblatt*

- Структуру перцептрона чини:
  - $\{s\}$ -неурони),
  - $\{a\}$ -неурони) и
  - један излазни неурон ( $\{r\}$ -неурон);



- *Rosenblatt*-ова основна идеја: јачину веза између улазног слоја неурона и скривеног слоја неурона случајно изабрати по неком закону вероватноће и фиксирати њихове вредности током целог процеса учења;
- Алгоритам учења реализује подешавање тежинских односа између скривеног слоја неурона и јединог излазног неурона;
- Ако има довољно различитих типова неурона у скривеном слоју (репрезентују различите логичке исказе из улазног слоја), онда је процес учења од неурона из скривеног слоја до излазног неурона у стању да реализује комплексно логичко закључивање.