

Универзитет у Београду – Машински факултет

Мастер академске студије

Модул: *Дизајн у машинству*

Предмет: *Методе одлучивања*

## ПА-4 Машинско учење-алгоритми машинског учења

**Предметни наставник:** *Проф. др Зоран Миљковић*

**Предметни сарадници:** *Доц. др Божица Бојовић*

*Најдан Вуковић, дипл. инж. маш.*

*Марко Митић, дипл. инж. маш.*

*Милица Петровић, дипл. инж. маш.*

# Машинско учење – увод и основни појмови

- Деф: *the design and development of algorithms that allow computers to improve their performance over time based on data (sensor data or databases);*
- Пројектовање и развој алгоритама у циљу обезбеђивања аутономног понашања интелигентних система у одговарајућем домену;
- Машинско учење представља програмирање интелигентних система (рачунара, мобилних робота итд.) тако да је систем у стању да самостално донеси одлуке приликом интеракције са окружењем;
- Машинско учење представља процес обучавања одговарајућег параметарског модела система или процеса сходно усвојеном алгоритму обучавања и критеријуму перформансе.
- Кључне речи:

Design (пројектовање)

Development (развој)

Algorithms

Computers

Improved performance

Based on data

# Основни видови машинског учења

## 1. Надгледано (учење под надзором)

- ученик добија инструкције од стране учитеља шта треба да научи,
- реализује се у форми увођења функције циља (критеријум перформансе) која представља учитеља.

## 2. Ненадгледано (учење без надзора)

- учитељ није експлицитно одређен,
- ученик мора сам да донесе закључак о пореклу и припадности података,
- пример Self Organized Maps (SOM), Adaptive Resonance Theory (ART)



## 3. Машинско учење ојачавањем

- машинско учење базирано на емпиријским информацијама из окружења
- оцена стања система са становишта успешности понашања <sup>3</sup>

# Основни видови надгледаног машинског учења

## 1. Класификација

- издвајање класа из доступних података
- технолошко препознавање (типске технолошке форме)
- препознавање карактеристичних обележја окружења,
- препознавање говора,
- постављање дијагноза у медицини на основу прикупљених података (нпр. рендген, ултразвук итд.)





# Основни видови надгледаног машинског учења



## 2. Регресија

- функционална апроксимација,
- предикција вредности одговарајућих индекса на берзи

Линеарна апроксимација:



Нелинеарна апроксимација:



# Надгледано машинско учење

Обучавајући скуп:

$$s = \{x^{(i)}, y^{(i)}\}$$

Улазни подаци

Жељени излаз

Нпр.  
класификација  
електронске  
поште:

$S = \{primljena\ pošta, (spam, non-spam, poslovna\ prepiska, privatna\ prepiska)\}$

Или...

Предикција квадратуре стана на основу цене:

Цена	<50.000	50.000-70.000	70.000-90.000	>100.000
Квадратура	~ 1.000	1.500	~2.000	>2.000

Локација?

## Пример #2: цена половног аутомобила (регресија)

- $x$  : карактеристике аутомобила


$y$  : цена

$$y = g(x | \theta)$$

$g(\ )$  - регресиони модел,

$\theta$  – параметри

- Усвојити критеријум перформансе и одредити регресиони модел



# Пример #3: препознавање лица

Обучавајући скуп:



$x = \{d(\text{između dva oka}), d(\text{između očiju i usta}), \text{dužina nosa}, \dots\}$

$y = \{\text{Petar Petrović}, \text{Marko Marković} \dots\}$

Скуп за верификацију



Бајесовско препознавање,  
Вештачке неуронске мреже,  
Статистички алгоритми...


Примена:

Безбедност објеката  
(коцкарнице?!, тероризам, итд.)

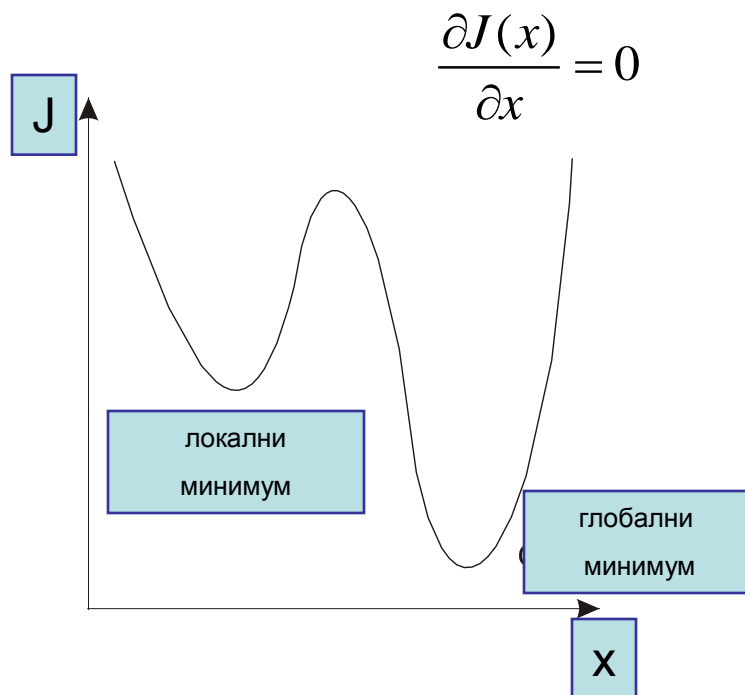


Критеријум прерформансе (основни еталон приликом доношења одлука):

$$J(x) = \frac{1}{2}(x^{(1)} - y^{(1)})^2 + \frac{1}{2}(x^{(2)} - y^{(2)})^2 + \dots + \frac{1}{2}(x^{(n)} - y^{(n)})^2$$



Вредност вектора  $x$  одређујемо на основу итеративног поступка и тражења минимума функције циља:



$$x_{k+1} = x_k - \mu \frac{\partial J(x)}{\partial x}$$

Идеална ситуација:

Ако функција циља има један и само један минимум проблем је линеаран


На жалост...

Критеријум прерформансе (основни еталон приликом доношења одлука):

$$J(x) = \frac{1}{2} (x^{(1)} - y^{(1)})^2 + \frac{1}{2} (x^{(2)} - y^{(2)})^2 + \dots + \frac{1}{2} (x^{(n)} - y^{(n)})^2$$



- Одређивање оног градијента функције циља који једнозначно одређује правац највећег опадања саме функције циља.



$$o = w_0 + w_1 * x_1 + \dots + w_n * x_n$$

$$E[w_1, \dots, w_n] = \frac{1}{2} \sum_{d \in D} (t_d - o_d)^2$$

$$\nabla \text{SSE}(W) = \left[ \frac{\partial \text{SSE}}{\partial w_1}, \frac{\partial \text{SSE}}{\partial w_2}, \dots, \frac{\partial \text{SSE}}{\partial w_m} \right]$$

$$\Delta W_m \rightarrow - \left( \frac{\partial \text{SSE}}{\partial W_m} \right)$$


# Ненадгледано машинско учење

- Нема учитеља;
- Ученик самостално учи;
- Ученик на основу низа

$$X = \{x_1, x_2, \dots, x_n\}$$

који представља скуп прикупљених података треба нешто да закључи;

- Нема излазних величина (нису експлицитно дефинисане);



# Пример: EM алгоритам (Expectation-Maximization)

$$X = \{x_1, x_2, \dots, x_n\}$$

=> Улазни скуп

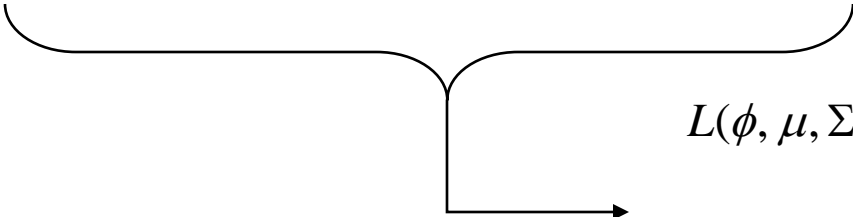
$$p(x^{(i)}, z^{(i)}) = p(x^{(i)} | z^{(i)})p(z^{(i)})$$

$$z^{(i)} \sim \text{Multinomial}(\phi); \quad \phi_j \geq 0; \quad \sum_{j=1}^k \phi_j = 1$$

$$p(z^{(i)} = j)$$

$$x^{(i)} | z^{(i)} = j \sim N(\mu_j, \Sigma_j)$$

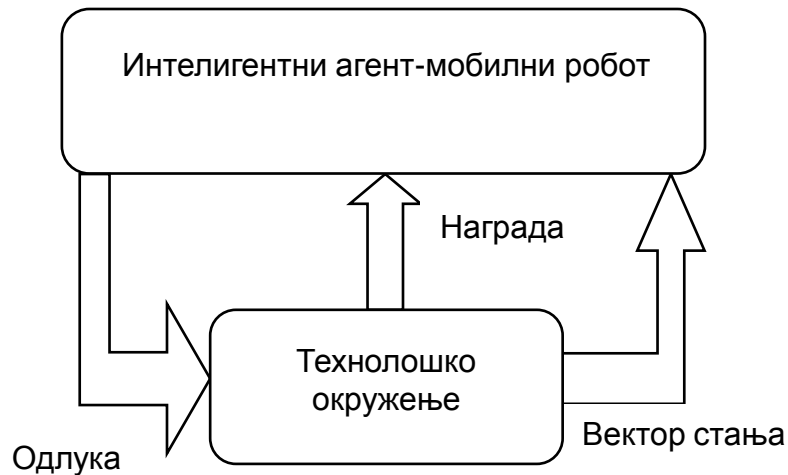
Дакле, сваки улазни вектор  $x$  одређен је случајним избором  $z$  из скупа  $\{1, \dots, k\}$ . Након тога  $x$  је добијено из једне од  $k$  нормалних расподела које зависе од промењљиве  $z$ .


$$L(\phi, \mu, \Sigma) = \sum_{i=1}^m \log p(x^{(i)}; \phi, \mu, \Sigma)$$

$$= \sum_{i=1}^m \log \sum_{z^{(i)}=1}^k p(x^{(i)} | z^{(i)}; \mu, \Sigma) p(z^{(i)}; \phi)$$

# Машинско учење ојачавањем

- Пример: интелигентни мобилни робот




- Оцена стања система на основу сензорске информације из окружења
- Одабир одлуке према одабраном алгоритму (нпр. унапред дефинисано кретање унапред, сретање, ...)
- Нумеричка оцена повољности новог стања мобилног робота

# Машинско учење ојачавањем

- Q - учење ојачавањем:
- Вредносна оцена стања се ажурира према:

$$Q_{t+1}(s_t, a_t) = Q_t(s_t, a_t) + \alpha \left[ r_{t+1} + \gamma \max_{a_{t+1} \in A} Q_t(s_{t+1}, a_{t+1}) - Q_t(s_t, a_t) \right]$$



$Q(s, a)$  values ( $\gamma = 0.9$ )

- Остали алгоритми машинског учења ојачавањем: *SARSA*, *Actor-Critic*, ...

Хвала на пажњи!

Питања?