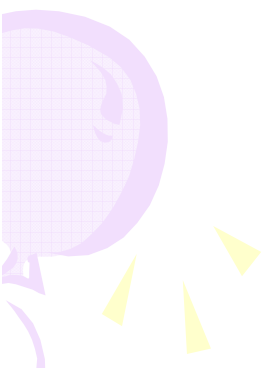


AT-7 Примена вештачке интелигенције у тражењу оптималног решења

Проф. др Зоран Миљковић, асист. Милица Петровић, дипл.инж.маш.



Одлучивање - анализа перформанси система

- Подразумева коришћење одговарајуће процедуре у домену теорије одлучивања;
 - Вештачки неуронски систем (Artificial Neural System-ANS) је у стању да оствари циљ *ако и само ако* је могуће да се изврши одговарајућа анализа перформанси система;
 - Анализа је базирана на мерењима способности неуронске мреже преко утврђивања *тачности и генерализације* решења проблема;
 - *Тачност* зависи од:
 - комплексности (условљено нелинеарношћу проблема);
 - величине мреже;
 - времена обучавања (тренирања) и
 - алгоритма учења.
- 

Одлучивање - анализа перформанси система

- Најважнији фактори који се користе приликом анализе перформанси вештачког неуронског система су:

1. Стабилност/конвергентна способност мреже;
2. Време извршења задатка (синхроно и асинхроно);
3. Меморијски капацитет (број узорака који се могу меморисати);
4. Толеранција на поремећаје;
5. Избегавање сумњивих стања меморије;
6. Просторни или временски дефинисани узорци и њихов утицај.

- Сваки од фактора подразумева мерење перформанси ANS (врши се параметризација критеријума);

- Одређује се утицајност сваког од параметра на друге;

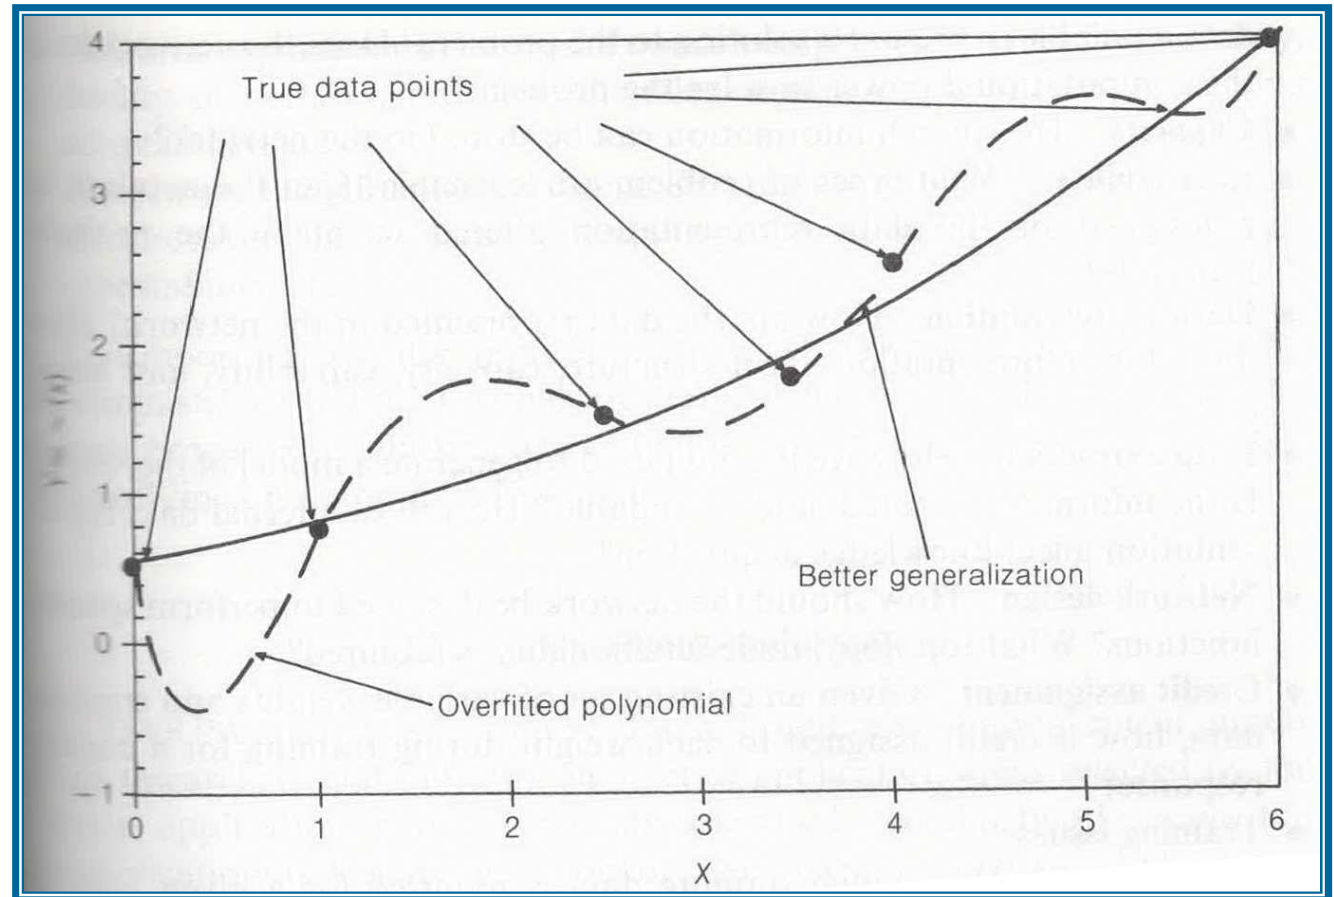
- Коначан исход => *матрица одлучивања* (АТ-1).

Конструктиван сукоб: Генерализација vs. тачност

- Шест посматраних тачака леже скоро на правој;

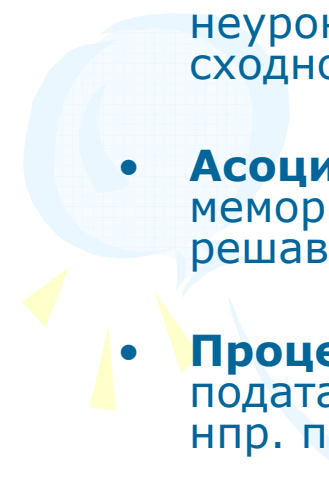
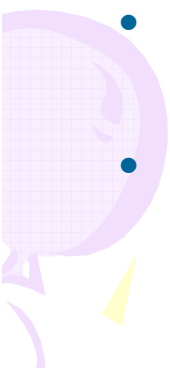
- Највећа могућа тачност ANS утврђена преко полинома приказаног испрекиданом линијом (overtraining);

- Најбоље решење (резултујуће) је приказано пуном линијом: **генерализација** решења проблема.







Кључни когнитивни задаци вештачког неуронског система (DARPA)

- **Класификација.** Тренирање ANS је супервизорско, лабелисано преко скупова података који су разврстани у различите класе;
 - **Самоорганизација/Формирање категорија.** Самоорганизоване неуронске мреже остварују груписање улазних података у кластере, сходно одређеном критеријуму;
 - **Асоцијативна меморија.** Асоцијативна или садржајно адресирана меморија обезбеђује кључну способност ANS да издвоји суштину при решавању задатог проблема одлучивања;
 - **Процесирање сензорских података.** Велики број сензорских података се појављује и третира унутар ANS у реалним условима, код нпр. процесирања слике, звука, итд.;
 - **Проблеми компјутерског израчунавања.** Због њих се и даље развијају архитектуре ANS;
 - **Вишеструко-сензорски аутоматски системи.** Многобројни инжењерски проблеми захтевају фузију података који се добијају од различитих сензора, што је посебно изражено у роботици (пројектни задатак).
- 
- 

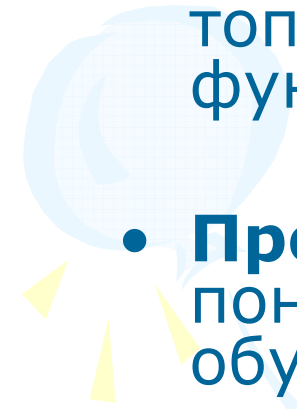



Фундаменталне категорије при анализи перформанси ANS:

- **Вишеструкост способности.** Да ли је довољно богат расположиви скуп података, да би успешно репрезентовао проблем? Да ли ANS има потребну компјутерску снагу за решавање проблема?
 - **Капацитет.** Колико информација може да се складишти у оквиру ANS?
 - **Могућност учења.** Који тип проблема се третира и учи? Да ли може да се редизајнира ANS у функцији побољшања машинског учења при решавању задатог проблема?
 - **Представљање података.** Како су подаци представљени ANS-у у погледу структуре, капацитета, способности репрезентативног учења, итд.?
 - **Издајање релевантних података.** Да ли су меморисане информације „разумљиве“ и како утичу на аквизицију знања унутар ANS?
- 
- 



Фундаменталне категорије при анализи перформанси ANS:

- **Пројектовано решење неуронске мреже.** Како би мрежа требало да буде пројектована да би извршавала специфичне функције? Која топологија мреже се користи и каква функционалност неурона се захтева?
 - **Процена кредибилитета.** Како се ANS понаша у контексту третираног сета обучавајућих парова (кредибилитет и валидност података), са аспекта тежинских односа током тренирања и после завршеног обучавања мреже? Да ли је кредибилитет ANS адекватан и да ли је у складу са захтеваним одзивима које неуронска мрежа даје после тренинга?
- 
- 

Фундаменталне категорије при анализи перформанси ANS:

- **Обучавање - утицаји тренирања.**

Ефективност. Колико обиман скуп обучавајућих парова се захтева за дати ниво перформанси ANS?

Делотворност учења. Колико је дуго потребно обучавати мрежу да би се оствариле захтеване вредности на излазу?

Комплексност. Како се мења време учења са скалирањем комплексности проблема који се третира?

Генерализација. Да ли се врши ваљана генерализација решења после класификације?

Пластичност. Могу ли нове ставке, класе или понашања бити додате ANS без нарушавања тренутних перформанси.

Сензитивност. Да ли је одзив мреже инваријантан на ирелевантне варијабилности на улазу у мрежу?

Адаптабилност. Да ли је време тренирања мреже условљено интерним представљењем репрезентативних података?

Фундаменталне категорије при анализи перформанси ANS:

- **Перформансе/Оперативни утицаји.**

Ширина опсега. Колико дуго ANS тражи оптимално очекивано решење задатог проблема?

Тачност. Колико је тачно решење задатог проблема?

Величина. Како перформансе и капацитет ANS варирају са величином мреже?

Робусност. Колико је решење проблема осетљиво (сензитивно) на тачност („нетачност“) компонената које чине ANS?

Толеранција грешке учења. Колико је мрежа толерантна на грешку учења због пропуста и или неуспешности (несавршености) компонената ANS?

Портабилност. Да ли је лако оствариво да ANS буде имплементиран на различитим типовима хардвера?

Стабилност. Да ли је оперативност ANS, глобално посматрано, стабилна?

Сепарабилност. Да ли су перформансе ANS условљене интерним представљењем репрезентативних података?

Ограничења и захтеви приликом пројектовања ANS

- **Захтевани ресурси:** Број неурона, комплексност неуронске функционалности, робусност неурона, број веза унутар неуронске мреже, адаптабилност тежинских односа и параметра учења, итд.
- **Захтеване перформансе:** Надокнадивост времена (у вези је са ширином опсега за проблем који се третира), способност учења - учљивост, скалирање, опоравак од грешака, толеранција грешке учења, протоколи тренирања (обучавања), генерализација, тачност, поновљивост, итд.



„Типови“ ANS:

- Неуронска мрежа може да:

буде стохастичка, детерминистичка или хибридна;



користи статичке, динамичке или цикличне процесе;

учи у off-line или у on-line режиму (реалном времену);

- Сигнали могу бити:



бинарни, аналогни, континуални или дискретни.

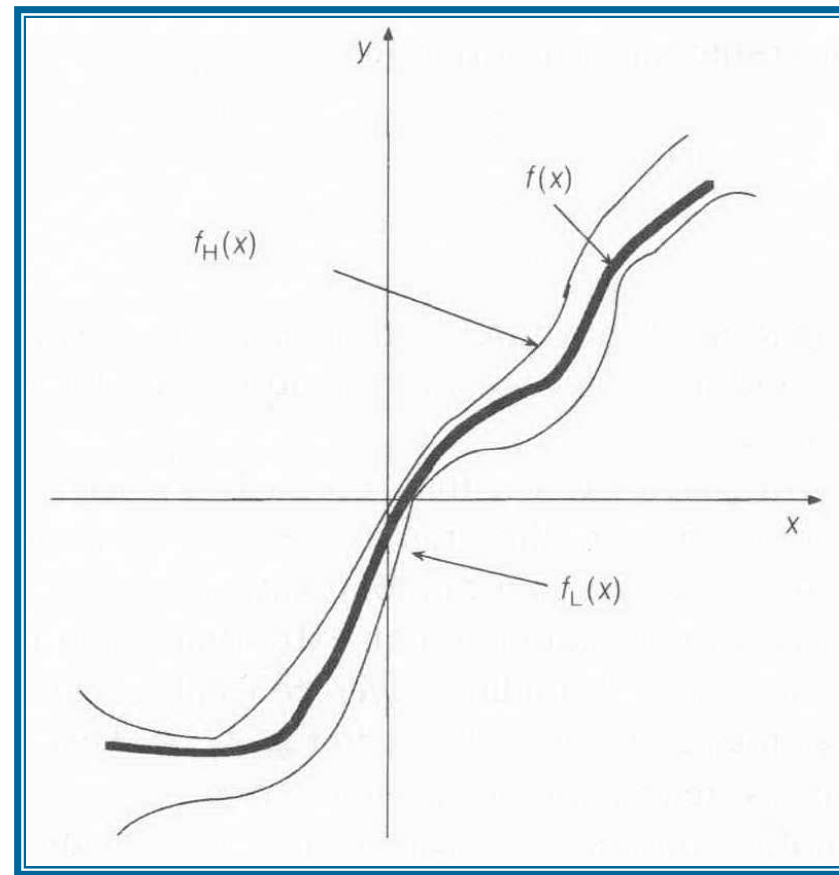
Мерење перформанси система

Bayes-ова теорија одлучивања

- Задата функција $f(x)$;
- ANS може да оствари две класе (коректна асоцијација - класа ω_1 , а некоректна асоцијација - класа ω_2);
- $f_H(x)$ има највише вредности дозвољене толеранције - одступања (класа $f_H(x)$ - *High*), а класа $f_L(x)$ најниже вредности (*Low*);
- Мерење перформанси система изражава се преко вероватноће коректног класификовања узорака из класе ω_1 :

$$P(d_1|\omega_1) = \int_{\mathfrak{R}_1} p(x|\omega_1) dx$$

- d_1 означава одлуку да је класа ω_1 тражена класа, $p(x|\omega_1)$ репрезентује густину условне вероватноће за мерења x сходно непознатом узорку који припада класи ω_1 , док је $dx = [dx_1, dx_2, \dots, dx_N]^T$ за N -димензионални вектор који је јединствено класификовао сва мерења у једну од две класе преко датог критеријума одлучивања.



Мерење перформанси система

Бауес-ова теорија одлучивања

- Задата функција $f(x)$;
- ANS може да оствари две класе (коректна асоцијација - класа ω_1 , а некоректна асоцијација - класа ω_2);
- $f_H(x)$ има највише вредности дозвољене толеранције - одступања (класа $f_H(x)$ - *High*), а класа $f_L(x)$ најниже вредности (*Low*);
- Мерење перформанси система изражава се преко вероватноће коректног класификовања узорака из класе ω_1 :

$$P(d_1|\omega_1) = \int_{\mathfrak{R}_1} p(x|\omega_1) dx$$

- d_1 означава одлуку да је класа ω_1 тражена класа и да је $dx = [dx_1, dx_2, \dots, dx_N]^T$.

Бауес-ова дискриминантна функција која дефинише границе одлучивања између класа ω_1 и ω_2 је:

$$f_{\mathfrak{R}}(x) = \frac{1}{p(x)} [P_1 p(x|\omega_1) L(\omega_1, d_2) - P_2 p(x|\omega_2) L(\omega_2, d_1)]$$


која је нормализована преко:

$$p(x) = \sum_{i=1}^2 P_i p(x|\omega_i)$$

$L(\omega_i, d_j)$ за $i, j = 1, 2$ је губитак условљен одлуком d_j док је i -та класа коректно асоцирана преко ANS.

Функције одлучивања

- За m класа узорака постоји $\frac{1}{2}m(m-1)$ могућих линеарних граница;
- Нелинеарне хиперравни су понекад једино решење за класификацију;
- Класификовати тачку А коришћењем линеарних функција одлучивања B_{12} , B_{13} и B_{23} , респективно;
- Линеарне границе класификују (неправилно!) тачку А и у сектору Б.



- Неопходно је одредити оптималну линеарну дискриминантну функцију одлучивања:

$$f_j(x) = w_j \cdot x + w_{j0}$$

а тражена хиперраван је

$$f_j(x) = w_j \cdot x + w_{j0} = \sum_{i=1}^N w_{ij} \cdot x_i + w_{j0}$$

w_{ij} тежински коефицијенти хиперравни, а w_{j0} је праг хиперравни.

Гранични региони одлучивања

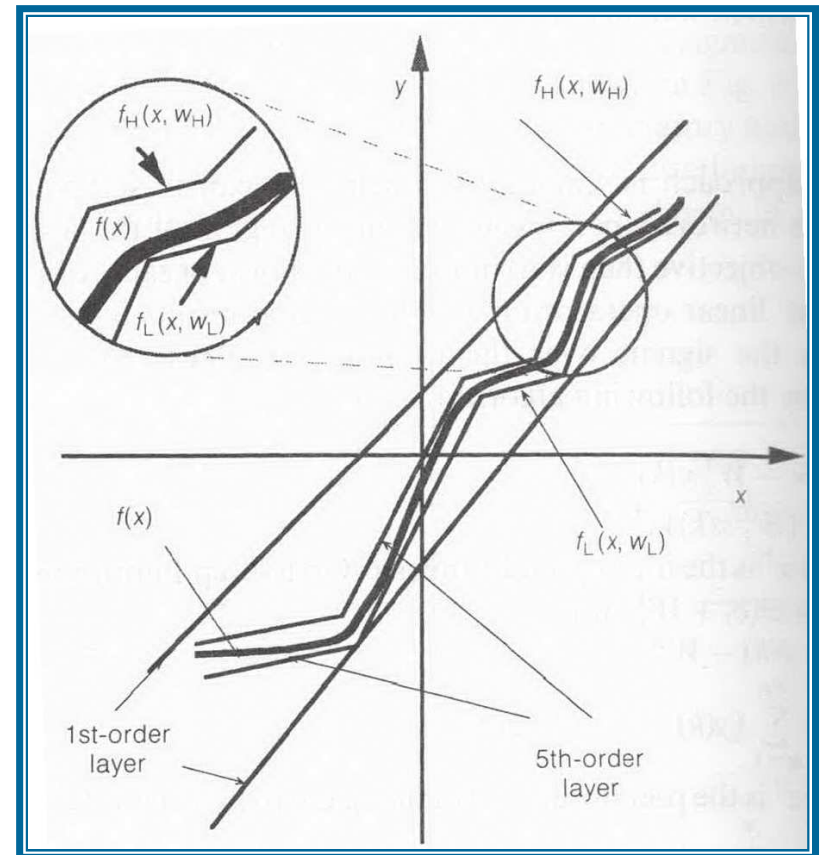
- Првенствено идентификовати граничне функције одлучивања;
- Оствариво коришћењем два конкурентна нивоа одлучивања (нпр. првог и петог реда);
- Две граничне функције одлучивања су:

$$y_H = f_H(W_H, z) \quad \text{и} \quad y_L = f_L(W_L, z)$$

- За селектоване векторе тежинских односа W_L и W_H и за познате излазне вредности неурона z , одређивање граница функција одлучивања тако, да важи следеће:


$$f_L(W_L, z) \leq f(W, z) \leq f_H(W_H, z)$$

- Дакле, на основу овако утврђених граница функција одлучивања, ANS је стању да одреди оптимално решење задатог проблема, уз значајно смањење времена тренирања захваљујући побољшању конвергентне способности неуронске мреже која је изабрана да третира дати проблем.



Закључак

- Генерализано делта правило (примењено и у **BPnet**-у) даје способност ВР мрежи да конвергира после 100 итерација са негде око 2% смањења грешке учења;
- Применом граничних функција одлучивања исто је оствариво у само једној итерацији (погледати фундаменталне категорије и на основу тога закључити колико је то важно за перформансе ANS);
- Редуковањем скупа података коришћењем граничних функција одлучивања, пре свега линеарних, врши се апроксимација функције $f(x)$ преко $f_H(x, W_H)$ и $f_L(x, W_L)$;
- Брже се остварује глобални минимум ВР неуронске мреже (апроксимација – водити рачуна о процени кредибилитета ANS!).



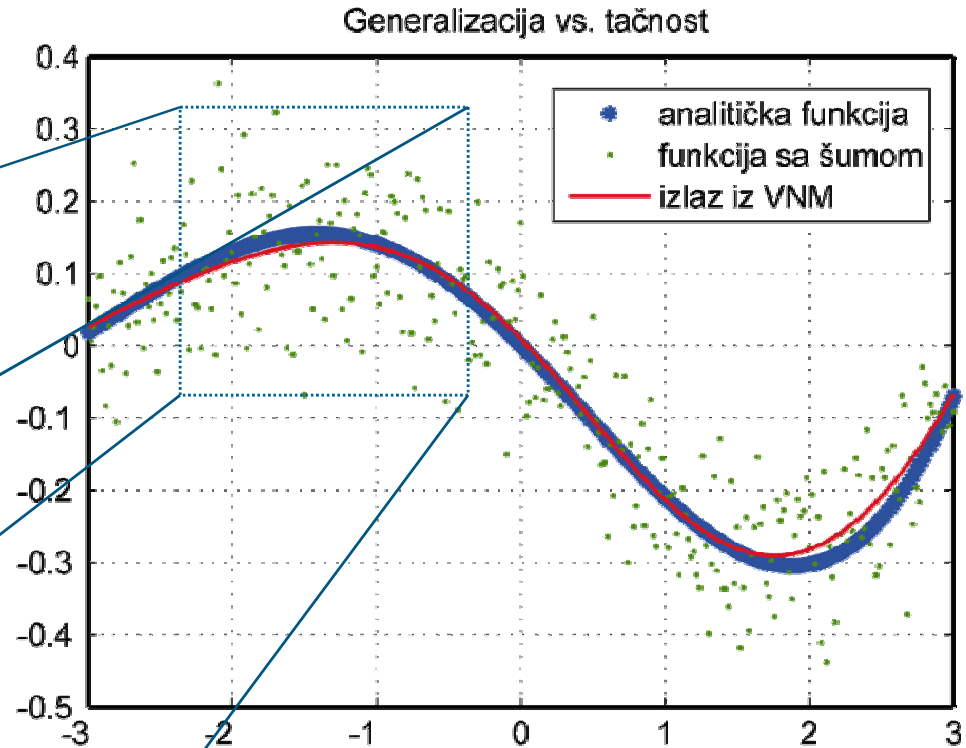
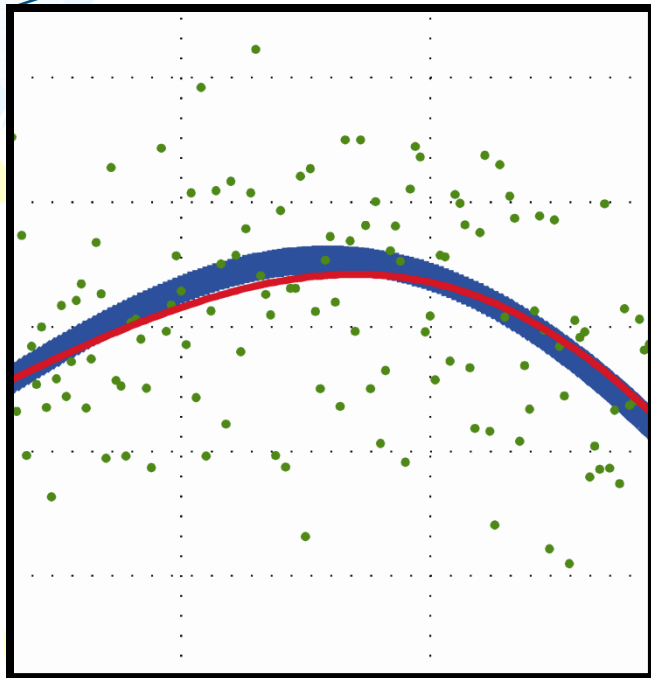
Важно!

- Примена овако комплексног процедуралног приступа развоју ANS базираног на функцијама одлучивања, не би требало очекивати од неискусних пројектаната;
=> докторске студије!

Примери примене ВММ у одлучивању

- Анализа перформанси система

Функција: $y = \frac{1}{x-5} \cdot \sin(x)$



Црвена линија: генерализација решења проблема применом ВММ.

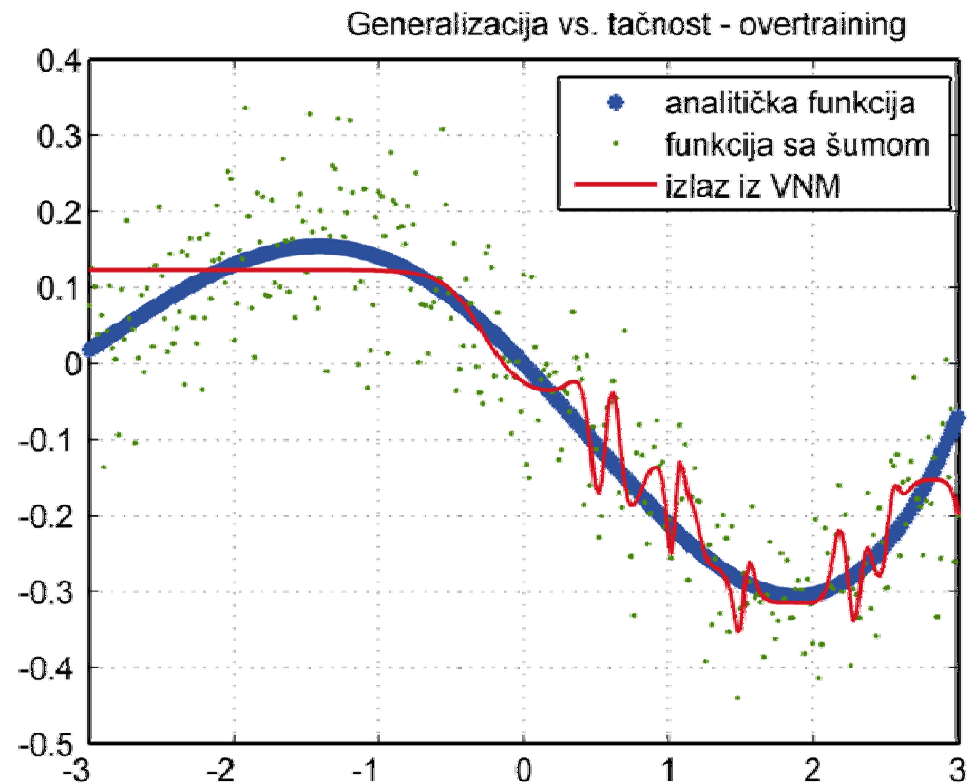
Примери примене ВММ у одлучивању

- Анализа перформанси система - *overtraining*

До преобучавања (*overtraining*) вештачке неуронске мреже може доћи ако се мрежа сувише добро обучи за обучавајући скуп података.

Последица преобучавања је добијање лошијих резултата за нови сет података (црвена линија на графику).

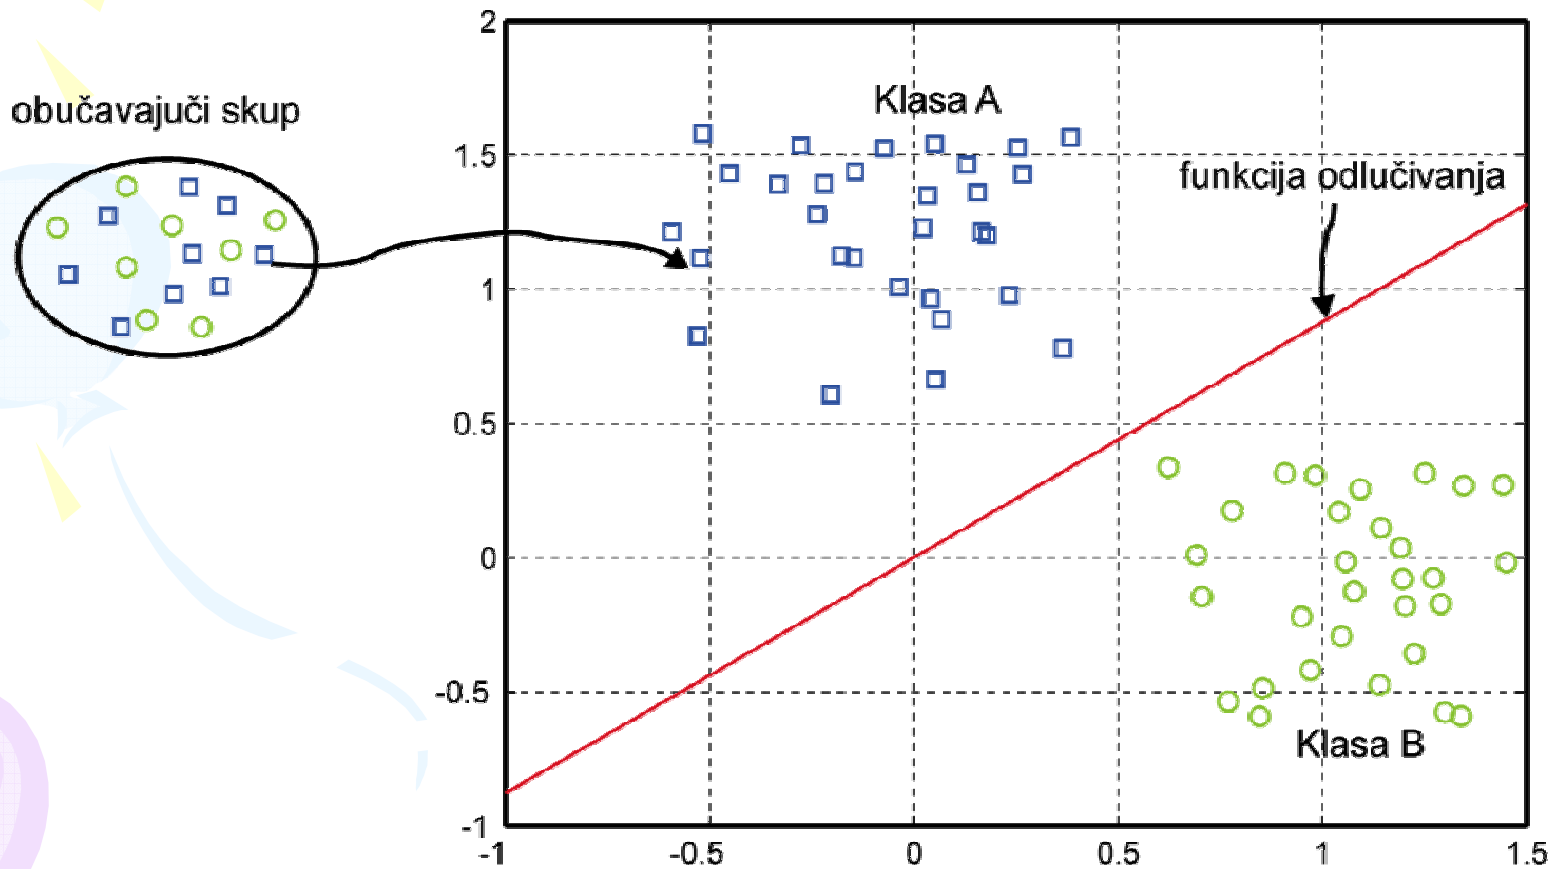
На примеру са слике, преобучавање је последица повећавања броја чворова у слојевима.



Функција:
$$y = \frac{1}{x-5} \cdot \sin(x)$$

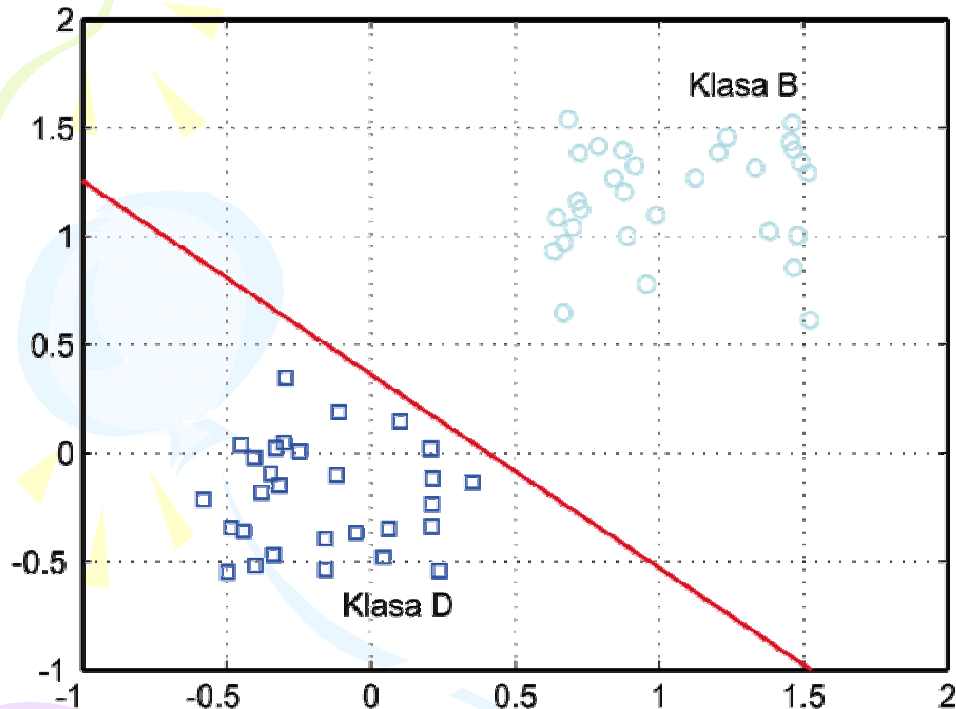
Примери примене ВММ у одлучивању

- Класификација коришћењем функција одлучивања




Примери примене ВМ у одлучивању

- Перцептрон - линеарно раздвајање




пример раздвајања две класе

пример раздвајања четири класе



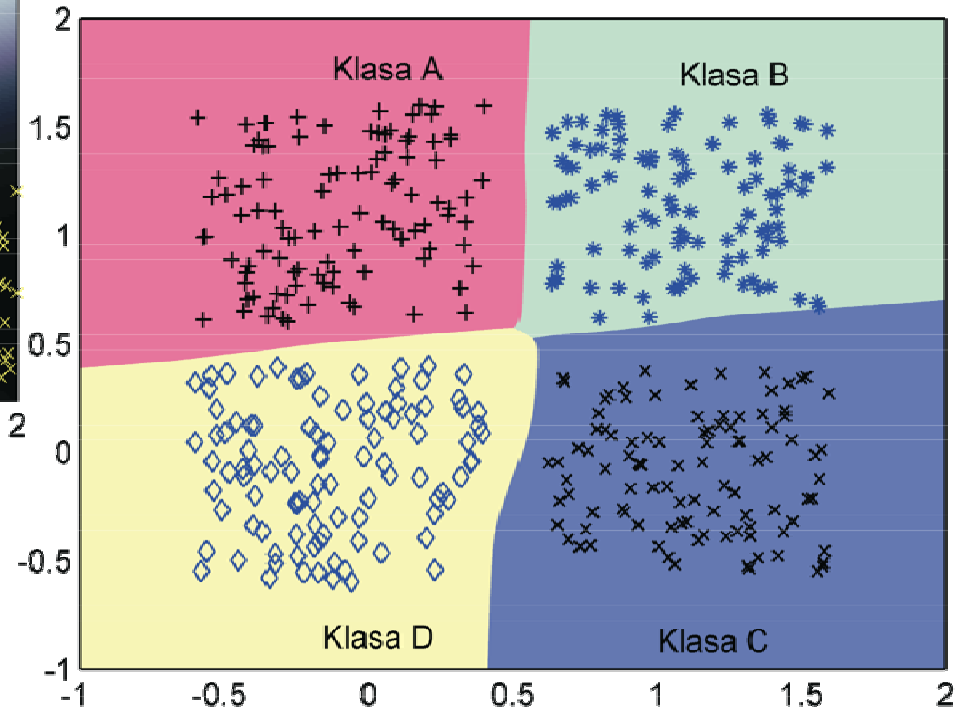
Примери примене ВММ у одлучивању

- ВММ- нелинеарно раздвајање

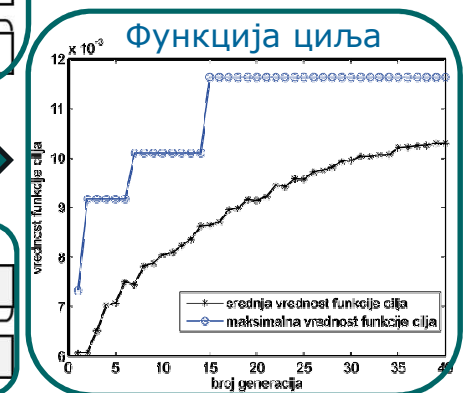
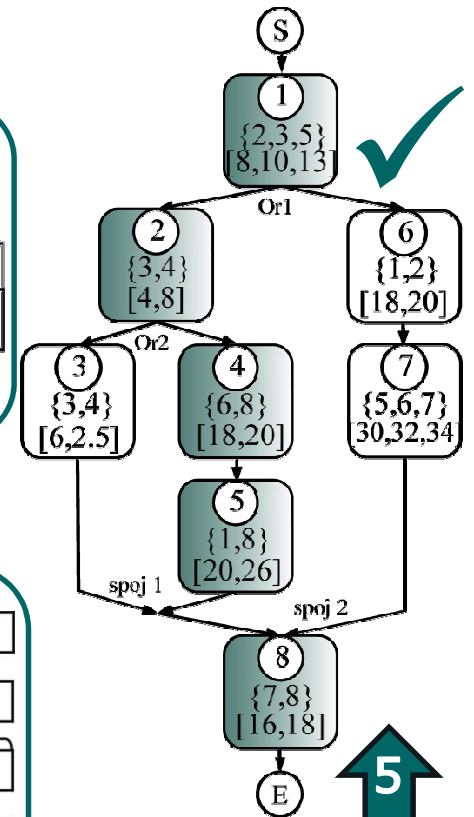

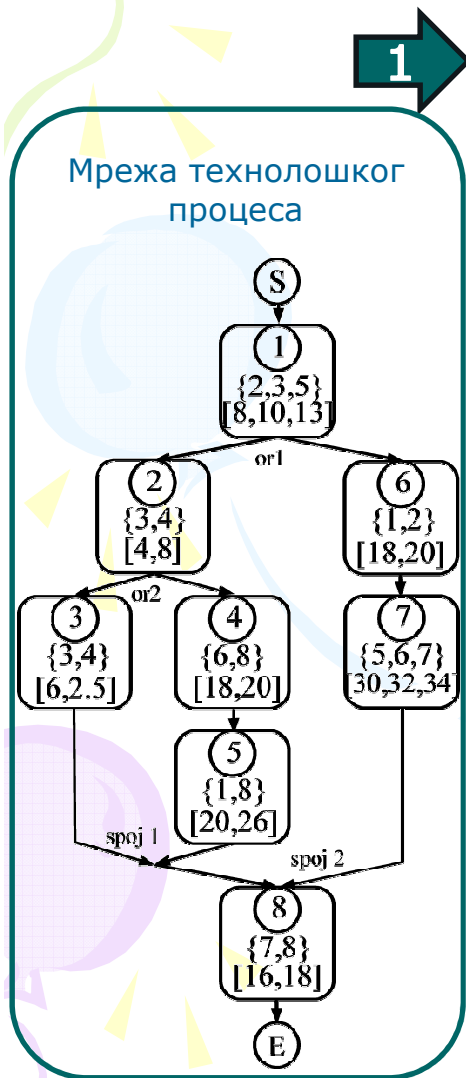


пример раздвајања две класе

пример раздвајања четири класе



Примери примене генетичких алгоритама у одлучивању





Хвала на пажњи!

Питања?

:: Методе одлучивања ::