

# ИНТЕЛИГЕНТНИ ТЕХНОЛОШКИ СИСТЕМИ

## АТ-5 Когнитивна роботика:

Аутономни мобилни роботи – когнитивне способности мобилних робота

## Когнитивне способности мобилних робота у домену унутрашњег транспорта материјала

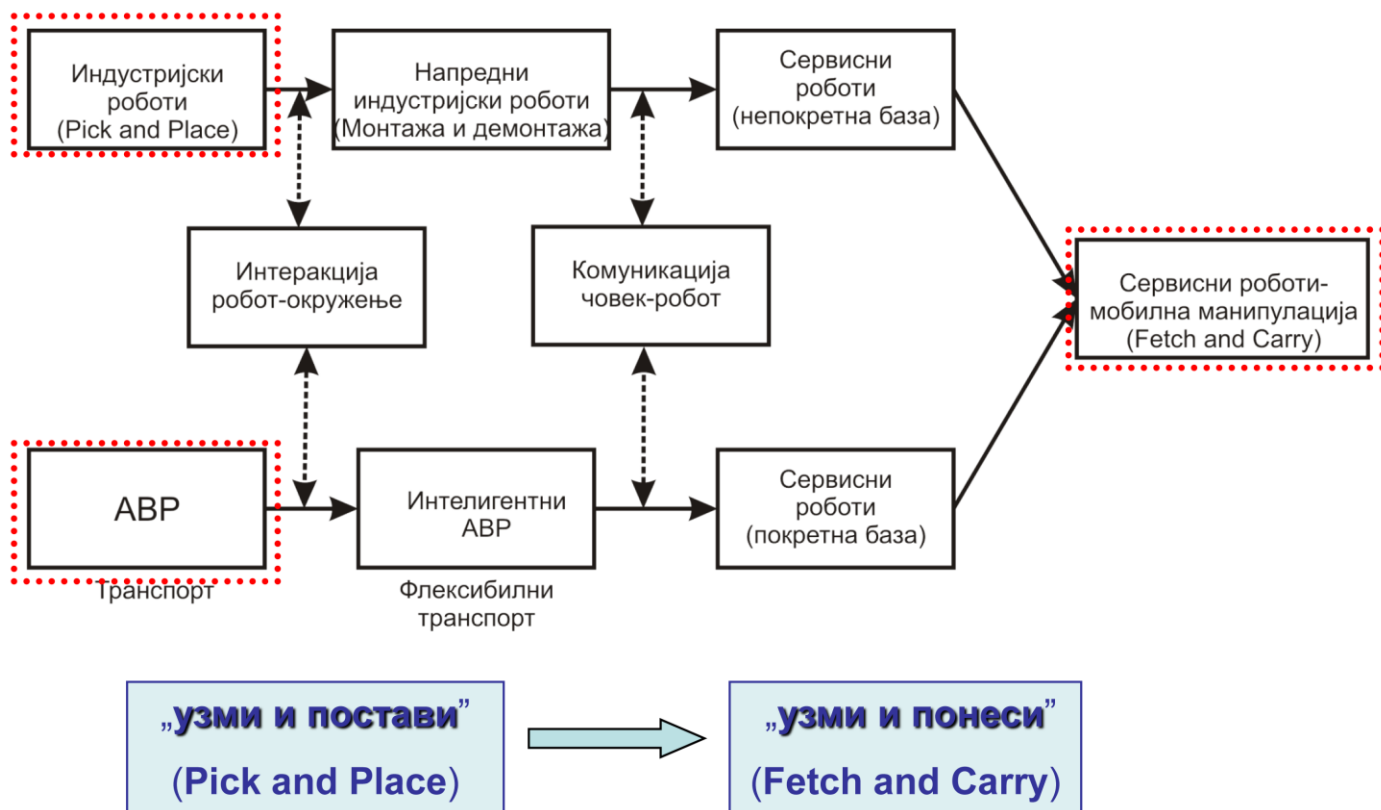
Примена мобилних робота за унутрашњи транспорт у оквиру интелигентног технолошког система подразумева висок степен интелигентног понашања самог мобилног робота. Интелигентно понашање мобилног робота настаје као резултат синергијског деловања свих појединачних (интелигентних) способности. За одређене специфичне случајеве потребно је досегнути и **ниво аутономног понашања**. Модерни приступ у развоју мобилних робота у домену интелигентних технолошких система базиран је на аутономности у погледу зависности од (специјалне) транспортне инфраструктуре која није предвиђена у постојећем технолошком окружењу. Уколико би експлоатација мобилног робота зависила од распореда одговарајућих објеката онда би концепт примене интелигентних мобилних робота био доведен у питање.

Експлоатација мобилних робота у оквиру интелигентних технолошких система, за потребе унутрашњег транспорта, претпоставља способност мобилног робота да „препозна” промене у радном окружењу и да им се прилагоди. У случају да ова способност није омогућена, транспорт сировина, полуфабриката, материјала и готових делова би могао да буде прекинут, а тиме и цео производни процес. Ситуација у којој мобилни робот треба да преузме палету са готовим производима, а да услед промене осветљења није у стању да препозна нијансе у бојама, могући је исход. Наравно, оваква ситуација може да доведе до евентуалног заустављања производног процеса и самим тим до непожељног тзв. *изгубљеног технолошког времена*. Такав исход може да се превазиђе моделирањем поменутог проблема, развојем модела за све евентуалне догађаје у којима мобилни робот треба/може да се нађе, али познато је да није реално оствариво предвиђање свих могућих ситуација у реалном окружењу. Чак и када би формирали овакав модел, не постоји довољна вероватноћа да се у будућности неће појавити нови проблем који није предвиђен у иницијалној поставци. Флексибилно понашање према променама изискује један потпуно другачији приступ. У том смислу, флексибилност према променама може да се моделира применом **концепта машинског учења на бази вештачке неуронске мреже** која у *online* режиму **модификује параметре** сходно променама у окружењу и врши предикцију стања. Овакав приступ обезбеђује довољну флексибилност потребну за експлоатацију без сталног надзора од стране оператера.

Основна структура ИТС-а почива на данас познатим производним концептима базираним на примени вештачке интелигенције за моделирање комплексних проблема. Заједничко деловање две основне структуре ИТС-а (ВИ и РИТ) треба да резултира следећим особинама ИТС-а:

- ♦ Аутономност – према нивоу сталног надзора и контроле од стране оператера, односно његовог присуства и утицаја;
- ♦ Децентрализација – полазни проблем је рашчлањен на више елементарних проблема;
- ♦ Флексибилност – у погледу измене полазног проблема;
- ♦ Поузданост – обављање основне функције без бојазни везане за појаву евентуалне грешке у систему која може значајно да угрози функционисање самог система;
- ♦ Ефикасност – остваривање предвиђених циљева;
- ♦ Способност учења – перформансе ИТС-а могу да буду значајно побољшане уколико би се систему омогућила способности машинског учења и закључивања.

Доминантни правци развоја у 21. веку указују на основни недостатак тзв. стационарних индустријских робота који се огледа у ограничењу у погледу промене положаја његове базе. Константан облик и константна запремина радног простора стационарних индустријских робота представљају данас све веће ограничење при извршавању технолошких задатака, посебно у погледу промене основног положаја базе индустријског робота, уколико постоји таква потреба у технолошком систему. С друге стране, приметна је тенденција померања основне парадигме у области роботике као научно-техничке дисциплине заснована на значајнијој примени мобилних робота, односно на интеграцији стационарних структура (углавном је у питању серијска, али исто важи и за паралелну) са покретном базом у циљу обављања комплекснијег радног задатка дефинисаног технолошким процесом. С обзиром на све израженију промену основних технолошких задатака који се постављају пред индустријске роботе у 21. веку – од „узми и постави“ задатака (*Pick & Place*) до „узми и понеси“ задатака (*Fetch & Carry*), ова фузија представља још један могући облик интеграције мобилних робота у производно технолошко окружење.



Померање истраживачког фокуса доминантне парадигме намеће и нове идеје примене развијених производних технологија. Унутрашњи транспорт материјала, сировина, полуфабриката и готових делова представља један од домена примене нових парадигми насталих у оквиру развоја роботике као научно-техничке дисциплине. „Узми и понеси“ парадигма технолошког развоја може релативно једноставно да се „повеже“ са транспортним задацима у оквиру технолошког окружења. „Узми и понеси“ технолошки задатак подразумева следеће способности мобилног робота:

- ♦ мобилни робот у сваком тренутку **зна свој положај и положај објеката у радном окружењу** у односу на произвољно изабрани спољашњи референтни координатни систем;
- ♦ аквизицијом података од сензора, накнадним процесирањем и интерпретацијом, мобилни робот, применом одговарајућег математичког алгорита, може да **детектује и препозна карактеристичне објекте**;
- ♦ у сваком тренутку мобилни робот може да, на основу знања о сопственом положају и положају карактеристичних објеката у окружењу, **самостално дефинише путању кретања** и спроведе планирано кретање у складу са технолошким задатком;
- ♦ **итеративно понављање поменутих способности** се подразумева.

## Аутономни мобилни работи у интелигентном технолошком систему

Интензиван развој у области пројектовања и производње аутоматски вођених робоколица (данас мобилних робота) резултирао је унапређењем основног концепта у смислу обезбеђивања специфичних способности које иницијално нису биле планиране. Једно од првих побољшања полазног концепта унутрашњег транспорта представља имплементацију сензора у оквиру постојеће платформе у циљу обезбеђивања повратне информације о стању околине. Међутим, увођење сензорске информације претпоставља постојање посебног подсистема у оквиру централног управљачког система чија је основна улога читавање и тумачење повратне информације добијене од сензора. Услед непостојања способности одлучивања о будућим акцијама система и/или појединачних робоколица, централна управљачка јединица је аутоматски заустављала одговарајућа вођена робоколица испред којих се појавила препрека. Тек након укљанања препреке, процес транспорта се настављао. Производни радници били су задужени за отклањање ових проблема, тако да је брзина повратка система у радни режим директно зависила од њихове благовремене реакције. Претходна констатација односи се и на технолошки систем у коме је **људски оператер управљао системом вођених робоколица**, али и на систем у коме је централни рачунар контролисао рад система вођених робоколица.

Основне мане овог решења унутрашњег транспорта у оквиру пређашњег технолошког система су:

- ♦ Немогућност адекватне и правовремене интерпретације сензорске информације;
- ♦ Немогућност промене путање кретања;
- ♦ Неспособност самосталног доношења одлука;
- ♦ Недостатак флексибилности.


Уочени недостаци овог концепта су условили да се у наредном периоду посегне за интензивним развојем напредног решења унутрашњег транспорта. У складу са изразито динамичким карактером производних погона, неопходно је било да се, кроз интензиван развој који је у току, имплементира напредни систем унутрашњег транспорта, изразито способан да **разуме и препозна стање окружења система** и да на основу тако одређеног стања самостално доноси одлуку о будућим акцијама. Дакле, да би успешно и ефикасно могао да решава проблеме у реалном времену и реалном окружењу, недвосмислено следи да систем унутрашњег транспорта мора да буде интелигентан. У том смислу, у наставку се наводе основне карактеристике које одређују интелигентни систем, а које сходно томе и интелигентни систем унутрашњег транспорта треба да поседује:

- ♦ Способност аквизиције података/сензорске информације,
- ♦ Способност расуђивања,
- ♦ Способност аквизиције знања,
- ♦ Способност машинског учења,
- ♦ Способност извођења закључака,
- ♦ Способност самосталног доношења одлука,
- ♦ Способност спровођења акција.

Поменуте особине су у складу са раније поменутиим основним способностима које мобилни робот у 21. веку мора да поседује. Уместо утврђивања комплексних математичких модела технолошких задатака и процеса, савремени аутономни работи заснивају своје активности на бази прикупљених емпиријских информација из окружења. За реализацију оваквог понашања, неопходно је да робот у својој управљачкој меморији складишти информације о претходним догађајима, стањима система и окружења, као и да врши предикцију будућих и оцењивање остварених акција (види претходно предавање **АТ4-Емпиријско управљање**).

Одређивање позиције и оријентације мобилног робота у односу на неки изабрани спољашњи референтни координатни систем назива се **локализација**. Аквизицијом и процесирањем информација добијених од сензора, мобилни робот треба да одреди свој положај (позицију и оријентацију). Услед грешака у управљачком и сензорском систему мобилног робота неизбежна је примена *метода теорије оцена* (тј. једноставније речено: оцена - естимација) током самог процеса. Примена *метода теорије оцена* омогућава мобилном роботу да у сваком тренутку у току експлоатације зна одговор на основна питања:

- ♦ Где сам?
- ♦ Где сам био?
- ♦ Где идем, где ми је циљ?
- ♦ Како да дођем до циља?



Прва два питања потпадају под проблем **локализације** (оцењивање положаја мобилног робота) док се друга два односе на **планирање** путање мобилног робота и акција у општем смислу.

Одговори на ова питања треба да реше следеће комплексне проблеме:

- **Проблем #1:** Локализација – одређивање положаја мобилног робота (позиција и оријентација) у радном (технолошком) окружењу;
- **Проблем #2:** Изградња мапе радног окружења;
- **Проблем #3 (Проблем #1 + Проблем #2):** Симултана локализација и изградња мапе радног окружења;
- **Проблем #4:** Генерисање плана + **Проблем #3**;
- **Проблем #5:** **Проблем #4** + Управљачка архитектура.

## Дефиниција стања мобилног робота

*„Стање је скуп свих акција робота и окружења које могу да интерактивно утичу на будућа понашања мобилног робота у погледу предузетих акција.“*

Другим речима, стање могу да чине компоненте које су искључиво резултат акција робота, али и резултат интеракције мобилни робот - окружење. У претходној дефиницији стања уочава се да и окружење у општем случају може бити променљиво и непредвидиво, чиме и оно испољава утицај на акције и самим тим стање мобилног робота. У том смислу, окружење може да се класификује на:

- ♦ Динамичко окружење (позиција и оријентација објеката у окружењу се мењају током времена, нпр. кретање људи у околини робота, као и кретање других робота), и
- ♦ Статичко окружење (мобилни робот је једини покретни објекат у радном окружењу).

Стање мобилног робота се обележава са  $x$  док се стање у тренутку  $k$  обележава са  $x_k$ . Вектор стања је  $n$ -димензиони вектор чије компоненте једнозначно дефинишу стање система.

Основне величине које могу да представљају елементе вектора стања  $\mathbf{x}$  су:


- ♦ Положај (позиција и оријентација) робота у односу на неки спољашњи референтни координатни систем;
- ♦ Брзина кретања робота;
- ♦ Положај и брзина кретања покретних објеката у радном окружењу;
- ♦ Положај карактеристичних објеката у окружењу који се могу употребити у процесу локализације мобилног робота;
- ♦ Параметри поузданости сензора.

На основу претходних ставова може да се уочи да променљиве величине које могу да представљају елементе вектора стања варирају у зависности од специфичности проблема. Оваква интерпретација компонената стања мобилног робота се не разликује од дефиниције стања у општој теоријској поставци теорије оцена (естимације). Овај закључак о компоненатама вектора стања искоришћен је за **увођење параметара вештачке неуронске мреже у оквиру вектора стања** у наставку *handout*-а.

У општем случају, компоненте вектора стања роботског система чине спољашње координате:

$$\mathbf{x}_k = [x \ y \ z \ \theta \ \psi \ \phi]^T$$

где су  $x$ ,  $y$  и  $z$  – компоненте вектора које дефинишу позицију мобилног робота, а  $\theta$ ,  $\psi$  и  $\phi$  углови који одређују оријентацију мобилног робота у односу на неки спољашњи референтни координатни систем. У даљем појашњењу, кретање робота ће бити моделирано као **равно кретање**, па је сходно броју степени слободе крутог тела у равни довољно дефинисати вектор стања чије су компоненте дате у наставку:



**Модел кретања** мобилног робота је представљен следећом релацијом:

$$p(\mathbf{x}_k | \mathbf{x}_{k-1}, \mathbf{u}_k).$$

Иако је термин модел промене стања погоднији, није грешка ни да се назове *модел кретања*. Мобилни робот из стања које је дефинисано вектором  $\mathbf{x}_{k-1}$  у тренутку  $k-1$  управљањем  $\mathbf{u}_k$  прелази у стање које је одређено вектором  $\mathbf{x}_k$  у тренутку  $k$ . С обзиром на то да мобилни робот мора да промени позицију, а у општем случају и оријентацију да би променио стање, сасвим је јасно да то може да буде остварено једино кретањем (то је и основни разлог увођења термина *модел кретања*).

Могуће је дефинисати два основна модела кретања мобилног робота:

- ♦ Модел кретања на основу брзина (*Брзински модел кретања*) – у овом моделу трансляторна и угаона брзина кретања мобилног робота представљају **управљања** **и** која изазивају промену позиције и оријентације током експлоатације. Основна претпоставка овог модела кретања је да се трансляторна и угаона брзина кретања могу контролисати, односно да се њима може директно управљати.
- ♦ Модел кретања на основу пређеног пута (*Одометрија*) – у овом моделу **управљање** **и** је дефинисано пређеним путем тачкова мобилног робота током тачно дефинисаног временског интервала. На основу читавања података са *енкодера* могу се одредити параметри пређеног пута који су неопходни за постављање модела. Посматрано са гледишта управљања роботом, пређени пут тачкова потпада под мерења (сензорске информације). Ипак, у овом моделу кретања пређени пут је усвојен за управљачку величину.

Познато је да се основна подела сензора у роботизици односи се на **физичке величине које је потребно идентификовати**. У том смислу, сензори се деле на:

- ♦ Унутрашње – сензори који мере величине унутар самог мобилног робота (број обртаја електро мотора, енергетске резерве, итд.)
- ♦ Спољашње – мере величине у односу на окружење у коме се мобилни робот креће (давачи пута, тактилни сензори, итд.)

Следећа подела коју такође можемо усвојити односи се на **енергетски утицај окружења на систем** и обрнуто. Дакле, можемо дефинисати следеће сензоре:

- ♦ Пасивне сензоре – врше мерење енергетског утицаја окружења на систем мобилног робота (микрофони, камере)
- ♦ Активне сензоре – емитују енергију у окружење и врше мерење одговора окружења на енергетски стимуланс (ласер, ултразвук)

Детерминистичким приступом моделирању перцепције мобилног робота не могу се потпуно обухватити најважније карактеристике окружења, као ни грешке у мерењу које су неизбежне. Уколико се управљачки алгоритам мобилног робота базира на детерминистичкој функцији перцепције окружења облика  $z_k = z_k(x_k)$  и ако се полази од претпоставке **апсолутне тачности** сензора на основу чијег мерења ће доћи до акције/реакције актуатора, комплетан модел ће веома брзо у експлоатацији доживети „гомилање” грешака. Оваква ситуација резултира поновном *калибрацијом* сензора и модификацијом параметара у управљачком софтверу, а све то са собом повлачи и прекид експлоатације мобилног робота. Наравно, овај процес би морао да се понавља довољан број пута, што поприлично снижава обим обављеног задатка, услед чега се и цена експлоатације знатно повећава.

Описана ситуација представља основни разлог увођења пробабалистичке формулације перцепције мобилног робота усвајањем следећег модела сензора (перцепције)  $p(z_k | x_k)$ . Моделирање перцепције мобилног робота применом метода математичке вероватноће резултира робуснијим системом. На овај начин се може адекватније одговорити захтевима у експлоатацији и карактеристикама окружења. Основна идеја која се налази у темељу овог модела је претпоставка да се за сваки објекат у окружењу мобилног робота који је идентификован сензорским подсистемом, може одредити *растојање* и *оријентација* објекта у односу на локални координатни систем робота. Такође, претпоставља се да робот може да идентификује сваку класу карактеристичних објеката помоћу величине која се назива *параметар идентификације*. У општем случају параметар идентификације може бити скалар, вектор или матрица. Параметром идентификације се може дефинисати боја објекта, висина, ширина, дебљина, итд. Функција идентификације карактеристичних објеката је дата као:

$$f(z_t) = \{f_t^1, f_t^2, \dots, f_t^n\} = \left\{ \begin{bmatrix} r_t^1 \\ \phi_t^1 \\ s_t^1 \end{bmatrix}, \begin{bmatrix} r_t^2 \\ \phi_t^2 \\ s_t^2 \end{bmatrix}, \dots, \begin{bmatrix} r_t^n \\ \phi_t^n \\ s_t^n \end{bmatrix} \right\}$$

где су  $r_t^i$  и  $\phi_t^i$  растојање и оријентација објекта респективно у односу на мобилни робот, док је  $n$  број карактеристичних објеката у једном мерењу и у општем случају је променљива величина. Ако са  $m_{jx}$  и  $m_{jy}$  обележимо  $x$  и  $y$  координате положаја  $j$ -тог карактеристичног објекта онда ће **сензорски модел (модел перцепције)** бити:

$$\begin{pmatrix} r_t^n \\ \phi_t^n \\ s_t^n \end{pmatrix} = \begin{pmatrix} \sqrt{(m_{jx} - x)^2 + (m_{jy} - y)^2} \\ a \tan 2(m_{jy} - y, m_{jx} - x) - \theta \\ s_j \end{pmatrix} + \begin{pmatrix} \varepsilon_{\sigma_r^2} \\ \varepsilon_{\sigma_\phi^2} \\ \varepsilon_{\sigma_s^2} \end{pmatrix}$$

где се за грешке (шумове)  $\varepsilon_{\sigma_r^2}$ ,  $\varepsilon_{\sigma_\phi^2}$  и  $\varepsilon_{\sigma_s^2}$  претпоставља да подлежу нормалној густини расподеле, као и да су међусобно независне.

## **Формирање математичког модела проблема на основу прикупљеног скупа података о перформансама система/процеса**

Вештачке неуронске мреже представљају математичко-софтверски алат намењен за моделирање проблема које је тешко (или пак потпуно немогуће) дефинисати експлицитно математички. Вештачке неуронске мреже су током низа година развоја успешно примењене на различите проблеме из инжењерске праксе. Предности развоја модела проблема, применом вештачких неуронских мрежа, огледају се у могућности развоја моделирања комплексних проблема без потребе за познавањем експлицитног математичког модела. Посебно је битно нагласити да у неким случајевима, развој експлицитног математичког модела не би у потпуности решио проблем, те је стога потребно спровести другачији приступ.

Развијање модела проблема применом вештачких неуронских мрежа, подразумева спровођење поступка кога чине следећи кораци:

- 1) Дефинисање улазних и излазних величина;
- 2) Избор система за генерисање потребних података;
- 3) Аквизиција експерименталних података;
- 4) Претпроцесирање експерименталних података.
- 5) Избор вештачке неуронске мреже, архитектуре и типа активационих функција;
- 6) Избор типа машинског учења (надгледано или ненадгледано) и одговарајућег алгорита учења;
- 7) Оптимизација параметара вештачке неуронске мреже-машинско учење;
- 8) Валидација квалитета обучености мрежа;
- 9) Тестирање „перформанси” добијених модела.

Корак бр. 1 потпуно је дефинисан полазним проблемом. Као инжењери, треба да смо увек у могућности да знамо зависност једних величина од других. Познавање физичких постулата изучаваног проблема, представља основу за примену вештачких неуронских мрежа. На овај начин се кораци бр.2, и бр.3 једноставно спроводе познавањем физичког утицаја једних величина на друге. У кораку бр. 4 се врши скалирање експерименталних података које за циљ има пресликавање полазног експерименталног скупа у неки од уобичајених опсега промене. Основна идеја је

обухватање утицаја свих величина (поступак скалирања или нормализације [види *З.Миљковић, Д.Александрић-збирка*]). Након претпроцесирања експерименталних података потребно је изабрати тип вештачке неуронске мреже, тип активационе функције и број неурона, као и број слојева ако је у питању вишеслојна мрежа. Наведени параметри директно утичу на перформансе и квалитет предикције. У корацима бр.6 и бр.7 треба дефинисати вид машинског учења који директно зависи од полазног проблема (надгледано или ненадгледано машинско учење), као и алгоритама учења. Од седмог корака започиње итеративни поступак који се састоји од оптимизације параметара и провере „наученог“ (оцене квалитета предикције).

У наставку су приказане перформансе алгоритама машинског учења вештачких неуронских мрежа са радијалним активационим функцијама који су развијени на бази Калмановог филтра.

Вештачка неуронска мрежа са радијалним активационим функцијама представљена је следећим изразом:

$$y_i = \sum_{j=1}^N w_{ij} f(x_i, \mu_j, \sigma_j)$$

Основни параметри су:

- ♦ Вектор тежинских параметара вештачке неуронске мреже  $w_{ij}$ ;
- ♦ Вектор прототипова (репера)  $\mu_j \in \mathbb{R}^{n_x}$ , где  $n_x$  означава број димензија;
- ♦ Радијална дистанца  $\sigma_j$ ; ( $\sigma_j \in \mathbb{R}^1$ );
- ♦  $f(\cdot, \cdot, \cdot)$  је активациона функција вештачке неуронске мреже,
- ♦  $x_i \in \mathbb{R}^{n_x}$  и  $y_i \in \mathbb{R}^{n_y}$  су улазни и излазни вектор (респективно) који формирају скуп за оптимизацију.

Постоји више могућности избора активационе функције, а сам избор зависи од проблема за који се развија овај тип вештачке неуронске мреже. Могући типови активационих функција су (види слику на следећој страници):

- ♦ Гаусова активациона функција:

$$f(x_i) = \exp\left(-\frac{1}{2\sigma_j^2} \xi_{ij}^T \xi_{ij}\right)$$

- ♦ Инверзна квадратна активациона функција:

$$f(x_i) = (\xi_{ij}^T \xi_{ij} + \sigma_j^2)^{-1/2}$$

- ♦ Квадратна активациона функција:


$$f(x_i) = (\xi_{ij}^T \xi_{ij} + \sigma_j^2)^{1/2}$$

- ♦ Логаритамска активациона функција:

$$f(x_i) = \xi_{ij}^T \xi_{ij} \ln(\xi_{ij})$$

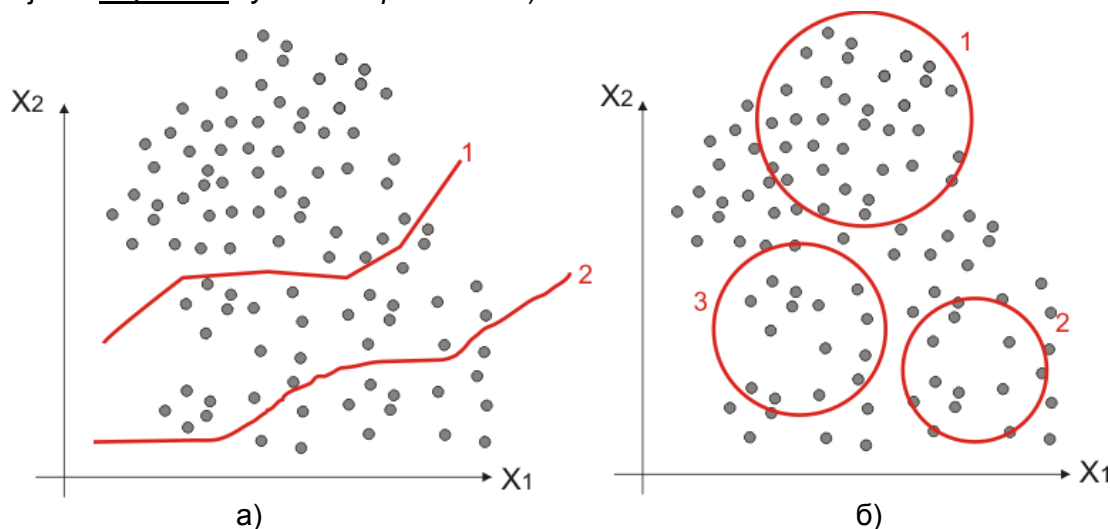
где је  $\xi_{ij} = x_i - \mu_j$ ; ( $\xi_{ij} \in \mathbb{R}^{n_x}$ ) разлика између  $i$ -тог улазног вектора  $x_i$  и  $j$ -тог прототип вектора  $\mu_j$ .





Типови активационих функција: а) Гаусова активациона функција.; б) Инверзна квадратна активациона функција; в) Квадратна активациона функција; г) Логаритамска активациона функција.

За разлику од вишеслојног перцептрона, радијалне активационе функције су базиране на успостављању сличности између елемената улазног скупа података. Свака кружница на слици испод представља једну радијалну активациону функцију чији је пречник једнак радијалној дистанци  $\sigma_i$  (аналогија са Гаусовом густином расподеле).



Графички приказ основне разлике између вишеслојног перцептрона (а) и вештачке неуронске мреже са радијалним активационим функцијама (б) у простору улазног вектора  $x_i \in \mathbb{R}^2$ .

За потребе оптимизације параметара вештачке неуронске мреже online поступком анализирани су следећи алгоритми (види презентацију):

- Линеаризовани Калманов филтар (ЛКФ);
- Линеаризовани информациони филтар (ЛИФ);
- Алгоритам специфичне апроксимације момената (АСАМ),

чији су основни параметри:  $\lambda_{0|0}$  - почетни вектор стања,  $P_{0|0}$  - почетна матрица коваријанси, матрица шума система  $Q$  и матрица шума мерења  $R$ .

Да би се формирао вектор стања у овом случају неопходно је написати тежинске параметре у векторском облику:

$$\mathbf{w} = [\mathbf{w}_1^T \quad \mathbf{w}_2^T \quad \dots \quad \mathbf{w}_i^T]^T$$

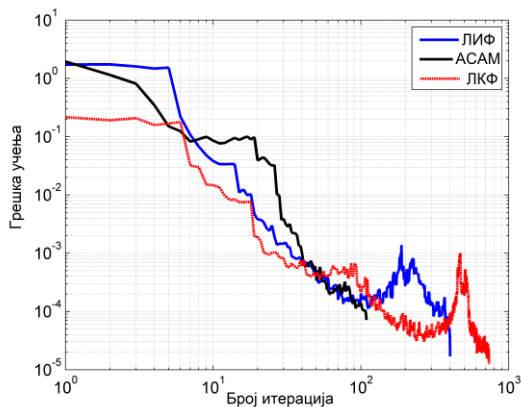
Преостали елементи вектора стања чине прототип вектори  $\boldsymbol{\mu}_j$  и све радијалне дистанце  $\sigma_j$  које одређују припадност  $j$ -том прототип вектору, односно:

$$\mathbf{t} = [\boldsymbol{\mu}_1^T \quad \boldsymbol{\mu}_2^T \quad \dots \quad \boldsymbol{\mu}_j^T \quad \sigma_1^T \quad \sigma_2^T \quad \dots \quad \sigma_j^T]^T$$


Дакле, вектор стања чине сви тежински параметри вештачке неуронске мреже  $\mathbf{W}_{i \times j}$  и параметри свих активационих функција  $\mathbf{t}$ :

$$\begin{aligned} \boldsymbol{\lambda} &= [\mathbf{w}^T \quad \mathbf{t}^T]^T = \\ &= [\mathbf{w}_1^T \quad \mathbf{w}_2^T \quad \dots \quad \mathbf{w}_i^T \quad \boldsymbol{\mu}_1^T \quad \boldsymbol{\mu}_2^T \quad \dots \quad \boldsymbol{\mu}_j^T \quad \sigma_1^T \quad \sigma_2^T \quad \dots \quad \sigma_j^T]^T \end{aligned}$$

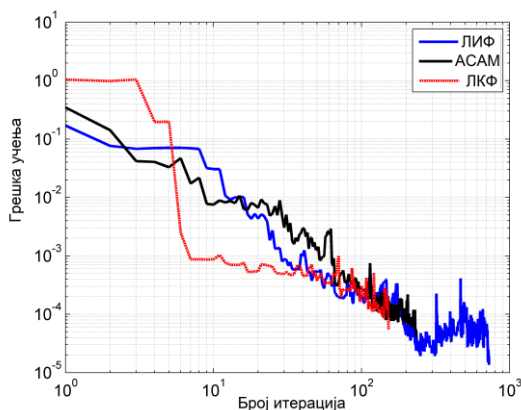
Да би се оценила употребна вредност развијених алгоритама машинског учења (ЛКФ, ЛИФ, АСАМ), изабране вештачке неуронске мреже су тестиране на „стандардним” скуповима података који представљају реалне проблеме регресије/класификације из различитих домена (**види слику доле**). Главна предност ових алгоритама (**секвенцијалност**) искоришћена је током решавања проблема симултаног оцењивања положаја мобилног робота и карактеристичних објеката у технолошком окружењу (види следеће предавање - **АТ6**).




а)  $p = 1 ; q = 1 ; r = 10;$



б)  $p = 1 ; q = 1 ; r = 1;$



в)  $p = 100 ; q = 10 ; r = 10;$



г)  $p = 100 ; q = 100 ; r = 10;$