

МЕТОДЕ ОДЛУЧИВАЊА

АТ-7 Примена вештачке интелигенције у тражењу оптималног решења

ФУНКЦИЈЕ ОДЛУЧИВАЊА

Одлучивање - анализа перформанси система

Анализа перформанси система подразумева коришћење одговарајуће процедуре у домену теорије одлучивања при евалуацији тих перформанси, сходно захтеваном когнитивном задатку или циљу који после учења вештачки неуронски систем (ANS-Artificial Neural System) треба да оствари. Дакле, вештачки неуронски систем је у стању да оствари циљ ако и само ако је могуће да се изврши одговарајућа анализа перформанси система, базирана на мерењима способности неуронске мреже преко утврђивања, пре свега њене *тачности*, као и кроз важну *генерализацију* решења проблема.

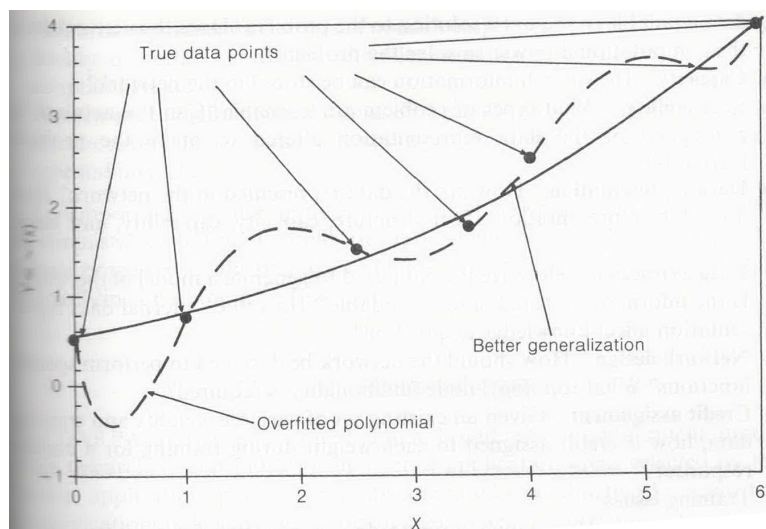
Тачност процеса пресликавања-обучавања унутар вештачког неуронског система зависи од: комплексности најчешће условљене нелинеарношћу проблема; величине мреже; времена обучавања (тренирања) и свакако од алгорита учења који је коришћен.

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

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

Сваки од ових фактора подразумева одговарајуће мерење перформанси ANS, чиме се врши параметризација критеријума, а затим се одређује и утицајност сваког од параметра на друге, што се коначно уврштава у *матрицу одлучивања* (АТ-1).

С друге стране, поред чињенице да вештачки неуронски систем има задатак да оствари малу прихватљиву грешку (утврђује се после мерења) за проблем који је у обучавајућем скупу третиран, *генерализација* као важна способност неуронске мреже може да буде неостварена. За тривијалан пример који је приказан на слици у наставку, може да се уочи конструктиван сукоб - конфликт између тачности и генерализације. Шест посматраних тачака леже скоро на правој! Дакле, иако је највећа могућа тачност вештачког неуронског система утврђена преко полинома приказаног испрекиданом линијом (*overtraining*¹), најбоље решење (резултујуће) је ипак изражено моделом приказаним пуном линијом провученом између тачака, а што је заправо остварено генерализацијом решења проблема.



Генерализација vs. тачност

¹ Overtraining – претерано обучавање, претренирање

Студија коју је још 1988. реализовала DARPA, сугерише кључне когнитивне задатке на које вештачки неуронски систем треба да се фокусира:

- **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 кластере² (редукују одговарајућу количину информација потребних за успешно процесирање на вишим нивоима одлучивања), сходно одређеном критеријуму.
- **Асоцијативна меморија.** Асоцијативна или садржајно адресирана меморија обезбеђује кључну способност ANS да издвоји суштину (битно од небитног) при решавању задатог проблема одлучивања.
- **Процесирање сензорских података.** Енормни 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 роботизи (пројектни задатак).

При анализи перформанси ANS, а у складу са овим кључним когнитивним задацима, потребно је обратити пажњу на следеће фундаменталне категорије:

- **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.?
- **Издавање релевантних података.** Да ли су меморисане информације „разумљиве” и како утичу на аквизицију знања унутар 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?
- **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 тренирања (учења) са скалирањем комплексности проблема који се третира?
 - Генерализација.** Да ли се врши ваљана генерализација решења после класификације?
 - Пластичност.** Могу ли нове ставке (податак, информација, сигнал, итд.), класе или понашања (пројектни задатак) бити додате ANS без нарушавања тренутних перформанси.
 - Сензитивност.** Да ли је одзив мреже инваријантан на ирелевантне³ варијабилности на улазу у мрежу? Како се ове инваријансе остварују?
 - Адаптабилност.** Да ли је време тренирања мреже условљено интерним представљењем репрезентативних података?
- **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?

² Кластер – уређени скуп података

³ Ирелевантан – незнатан, безначајан, сићушан, мали, који је без важности, неважан, безвредан

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

Искуство пројектанта у коришћењу широког спектра различитих модела неуронских мрежа и репрезентативних података представља полазиште у остваривању пројектантских водилја ка адекватној примени ANS, а у складу је са појединим ограничењима и захтевима, попут:

- **Захтеваних ресурса**⁴. Број неурона, комплексност неуронске функционалности, робусност неурона, број веза унутар неуронске мреже, адаптабилност тежинских односа и параметра учења, итд.
- **Захтеваних перформанси.** 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.


Да би се пројектовање одговарајућег ANS подржало на адекватан начин, неопходно је пре свега знати да би имплементирана неуронска мрежа могла да буде *стохастичка*, *детерминистичка* или *хибридна*; могла би да користи *статичке*, *динамичке* или *цикличне процесе*; док сигнали који се процесирају унутар ње могу бити *бинарни*, *аналогни*, *континуални* или *дискретни*; а могла би да учи *off-line* или да се адаптира у реалном времену (*on-line*); итд.

Мерење перформанси система

Елементарна *Bayes*-ова теорија одлучивања може да буде узета у разматрање како би се описале перформансе ANS, што је приказано примером (слика у наставку). Наиме, види се да је за задату функцију $f(x)$ ANS могао да оствари две класе које асоцирају на задату функцију (нека је: коректна асоцијација - класа ω_1 , а некоректна асоцијација - класа ω_2), и то $f_H(x)$ која има највише вредности дозвољене толеранције - одступања (класа $f_H(x)$ - *High*), а класа $f_L(x)$ најниже вредности (*Low*). Дакле, оставарено мерење перформанси система изражава се преко вероватноће коректног класификовања узорака из класе ω_1 , на основу познатог критеријума одлучивања који узима у обзир све обсервације (мерења x) у простору стања ANS, дате преко скупа \mathfrak{X}_1 (за класу ω_1) сходно изразу

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

где 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.



Функционално пресликавање и одређивање граница одлучивања ANS

⁴ Ресурс – помоћно средство, извор помоћи

Bayes-ова дискриминантна функција $f_{\mathfrak{R}}(x)$ која дефинише границе одлучивања између класа ω_1 и ω_2 , дата је следећим изразом

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

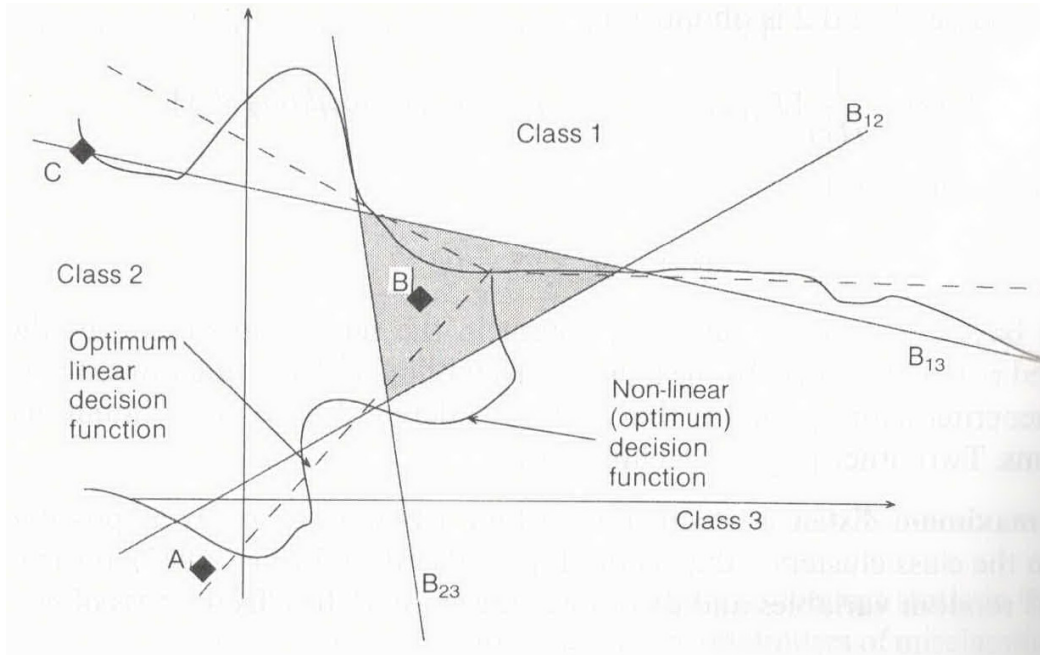
који је нормализован преко

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

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

Функције одлучивања

За сваки пар неке класе узорака, могуће је конструисати једну хиперраван (AT-5) која их раздваја. Тако, за m класа узорака који се уводе у ANS, постоји $\frac{1}{2}m(m-1)$ могућих линеарних граница. Међутим, то и даље није гаранција да ће се помоћу њих успоставити сви класификациони захтеви (види слику у наставку). Нелинеарне хиперравни, као могуће функције одлучивања (веома су сложене - види слику доле), понекад су једино решење за коректну класификацију!



Функције одлучивања

Пример

Посматрајмо тачку А на слици горе, која треба да буде класификована тако што је потребно одредити којој класи припада (1, 3 или 2), коришћењем линеарних функција одлучивања B_{12} , B_{13} и B_{23} , респективно. Међутим, ове линеарне границе класификују (неправилно!) и тачку у сектору В која припада класама 2, 1 и 3, респективно. Дакле, треба уочити да се, због неправилног класификовања, сектор В у овом примеру елиминира, јер не припада ни једној од класа.


Да би се овај проблем класификације решио, неопходно је одредити оптималну линеарну дискриминантну функцију одлучивања која је дата изразом $f_j(x) = w_j \cdot x + w_{j0}$, где је на производ вектора мерења x и вектора тежинских односа w додато иницијално стање тежинских односа. Даље је, на бази линеарне дискриминантне функције одлучивања могуће коначно одредити и тражену хиперраван преко

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

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

Гранични региони одлучивања

За потребе пројектовања/управљања веома је важно првенствено идентификовати граничне функције одлучивања, пре него што их затим „тачно” процењујемо током примене унутар ANS. Ово је оствариво коришћењем два конкурентна нивоа одлучивања (нпр. првог и петог реда), приказаних на слици доле.



Границе функција одлучивања

Дакле, две граничне функције одлучивања могу да се представе на следећи начин:

$$y_H = f_H(W_H, z)$$
$$y_L = f_L(W_L, z)$$

Даље, предлаже се 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:

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

На основу овако утврђених граница функција одлучивања, ANS је у таквом стању да се реално може очекивати оптимално решење задатог проблема, уз значајно смањење времена тренирања захваљујући побољшању конвергентне способности неуронске мреже која је изабрана да третира дати проблем.

Наиме, показало се да генерализовано делта правило (најчешће коришћено, па је примењено и у **BPnet**-у) даје способност BP неуронској мрежи да конвергира после 100 итерација са негде око 2% смањења грешке учења, а применом граничних функција одлучивања исто је оствариво у само једној итерацији (види претходно приказане фундаменталне категорије – закључи колико је то важно за перформансе ANS). Дакле, редуковањем скупа података који се третирају унутар ANS коришћењем граничних функција одлучивања, пре свега линеарних (види слику горе), врши се апроксимација функције $f(x)$ преко $f_H(x, W_H)$ и $f_L(x, W_L)$, чиме се брже остварује глобални минимум BP неуронске мреже (апроксимација – водити рачуна о процени кредибилитета ANS!).

Важно је знати да примену овако комплексног, али и конкурентног процедуралног приступа развоју ANS базираног на функцијама одлучивања, не би требало очекивати од неискусних пројектаната (у домену напредне примене вештачких неуронских мрежа и метода одлучивања), што не значи да га не треба сматрати изазовом за ниво мастер студија (а посебно после завршетка!). Реално је и очекује се да га заинтересовани истраживачи користе на докторским студијама када је то оправдано и сврсисходно (комплексно моделирање вештачких неуронских мрежа изискује ангажовање свих захтеваних ресурса и перформанси ANS – види претходно приказане фундаменталне категорије!).