

BME Folyamatszabályozási Tanszék

Az NN automata, mint viselkedési modell

Gyórfy Zoltán és Hajnal Miklós

Az NN (Nearest Neighbor) alakfelismerő módszerek az elmúlt két évtizedben kifejlesztett számos, tanítóval működő tanuló algoritmus egyik lényeges csoportját alkotják. Az NN módszerek kitűnnek egyszerűségükkel és természetes voltukkal. Az NN algoritmusok lényege, hogy előre megadott - megtanult - szituáció-viselkedés párok alapján ismeretlen helyzetben a hozzá legjobban hasonlító ismert szituációnak megfelelően cselekszenek.

Az irodalomban szokásos matematikai megfogalmazás meglehetősen korlátozza az NN stratégia általános voltát. A szerzők ugyanis általában megkövetelik, hogy a szituációk (bemenetek) halmaza metrikus tér legyen, s az intuitív hasonlóság-fogalmat e tér metrikája definiálja (Cover és Hart, 1967).

Előadásunkban az NN algoritmus algebrai jellegű általánosításaként bevezetjük az NN automata fogalmát, majd bemutatunk egy adaptív tanulási modellt, amely változó környezetben is megőrzi a helyes viselkedési képességet. Ezután ismertetjük azokat a szimulációs eredményeket, melyek ez utóbbi módszer jó alkalmazási lehetőségeit bizonyítják pl. a biológiában, vagy a szabályozástechnikában.

1. Az NN automata algebrai modellje

NN automatának nevezzük az

$$A = (X, \otimes, L(t), H, d)$$

algebrai rendszert, ahol X, Θ nem üres halmazok. X a bemenő jelek, Θ a kimenetek (válaszok) halmaza. Az A NN automata az $x \in X$ bemenet hatására kibocsát egy $\vartheta \in \Theta$ választ. Ezt a következőképpen jelöljük:

$$A(x) = \vartheta$$

$L(t) \subset X \times \Theta$ a rendezett bemenet-kimenet párok t -től függő halmaza. A t valós paraméter az idő, mely diszkrét skálán fut végig. Az L halmazt tananyagnak, elemeit tanulópontoknak nevezzük.

H lineárisan rendezett halmaz.

d kétváltozós függvény, $d : X \times X \rightarrow H$.

d -re vonatkozólag a következő két természetes kikötést tesszük:

$$a.) \quad \forall_{x,y} \left[d(x,y) = d(y,x) \right] \\ x,y \in X$$

$$b.) \quad \forall_{x,y,z} \left[d(x,y) = \min_z d(x,z) \iff x = y \right] \\ x,y,z \in X$$

Az NN automata működése tehát a következő:

A bemenetre érkező ismeretlen objektumot (szituációt) állítsuk párba a tananyagban specifikált bemenetekkel. Az így kapott párokat d által képezzük le a H rendezett halmazra. Válasszuk ki a legkisebb (legközelebbi, legnagyobb hasonlóságot mutató) párt, s az ehhez tartozó - tananyagban specifikált - viselkedési módot válasszuk. Látható, hogy a most vázolt modellnek speciális esete az NN algoritmus: X ekkor metrikus tér, d e tér metrikája, mely két feltételünket természetesen kielégíti, H a nemnegatív valós számok halmaza. A tananyag az NN algoritmus esetében, a diszkrét időskálán előre haladva egyszerűen úgy változik, hogy a beérkező bemeneteket és a

szerzett tapasztalatokat (visszaigazolás) párba állítjuk és tanulópontokként tároljuk. Az automata a következő döntést az ily módon kiegészített tananyag alapján hozza. Fontos kérdés, hogy az üres tananyaggal induló NN automata esetében hogyan alakul a hibás döntések relatív gyakorisága az idő függvényében és milyen végleges biztonság érhető el. E kérdésekkel Cover és Hart foglalkoztak, eredményeik elég általános feltételek teljesülése mellett az átlagos NN hiba R és az elméletileg optimális Bayes hiba R^* viszonyáról a következőket mondják:

$$R^* < R < 2R^* ,$$

metrikus veszteségfüggvény esetén, és


$$R^* \leq R \leq 2R^* (1 - R^*) ,$$

Kronecker féle veszteség függvényt alkalmazva, válaszlehetőséget feltételezve.

Ezek az eredmények azonban csak stabil, változatlan környezetben igazak. Ennek illusztrációjaként tekintsük a következő szimulációs kísérletet!

A tanulópontokat két, különböző várható értékű normális eloszlásból sorsoltuk. Az NN automatának a bemenetére adott mintát megfigyelve következtetnie kellett arra, hogy az melyik várható értékhez tartozik. Az automata minden lépés után megkapta a helyes választ, s az így nyert információt (tanulópontot) tárolta. Az ábrán (pontozott vonal, $1 \leq n < 20$) a helyes döntések relatív gyakoriságának alakulását rajzoltuk fel a beérkezett minták számának függvényében (több lefutás eredményeit átlagolva).

A görbe első szakasza ($1 < n \leq 10$) nagy hasonlóságot mutat az ilyen jellegű pszichológiai tesztkísérletek eredményeivel.



A 20. lépés után hirtelen 180° -kal megváltoztatva a környezetet (ugy, hogy a két várható érték egymással helyet cseréljen), mint az ábrán látható ($20 \leq n < 40$) a helyes döntések relatív gyakorisága zérusra csökken, ugyanis az eddigi tapasztalatok ettől a pillanattól fogva, az új környezetben tévesnek bizonyulnak. A tanulási görbe további szakasza laposabb, mint az első volt.

Tulajdonképpen ez is megfelel annak az általános tapasztalatnak, hogy a megváltoztatott környezethez nehezebben alkalmazkodnak a kísérleti alanyok. Amíg azonban a fent bemutatott NN automata-reprezentáció csak egyféle sebességgel képes a változó környezethez alkalmazkodni, és ez az alkalmazkodás a környezet sorozatos megváltozásai után egyre kevésbé hatásos, addig a különféle intelligenciájú lények különféle alkalmazkodási képességet mutatnak. Ez a képesség állandó marad, ha a környezetváltozás periódusa lassabb, mint alkalmazkodási idejük.

Célunk egy olyan NN automata-reprezentáció megkonstruálása, mely beállítható alkalmazkodási képességgel rendelkezik, s ez nem romlik el a változó környezetben sem.

2. Az F-NN modell

Az előző pontban felvetett problémát általánosságban a következőképpen oldhatjuk meg: Minden tanulópontot beérkezésétől fogva egy T tesztnek vetjük alá, mely az adott tanulópont "hatásosságát" méri az automata viselkedése szempontjából. A T tesztet sokféleképpen definiálhatjuk, így több NN automata-reprezentációhoz jutunk. Mi a következő megoldást választottuk: minden tanulópont mellé egy un. felejtési függvényt rendeltünk, mely t -vel szigoruan monoton változik. Ha a felejtési függvény elér egy bizonyos limitet, az adott tanulópontot egyszerűen kiejtjük a memóriából. Ha egy tanulópont részt vesz egy döntés meghozatalában, akkor a döntés kimenetelétől függően a felejtési függvényt vagy visszaállítjuk egy alacsonyabb szintre, vagy megnöveljük.

A felejtési függvény paramétereinek megfelelő megválasztásával más-más alkalmazkodási szint modellezhető. Az ábrán folytonos vonallal húztuk be egy ilyen típusu modell viselkedésére jellemző tanulási görbét, melyet a már ismertett szimulációs kísérlet elvégzése során nyertünk.

Irodalom

Cover, T.M., P.E. Hart: The Nearest Neighbor pattern classification, IEEE Trans. on Information Theory, vol. IT-13, (1967.)

