

MESTERSÉGES NEURONHÁLÓK ÉS ALKALMAZÁSAIK

Készítette: Dr. Tóth László

A kapcsolódó gyakorlati anyag itt található:

<http://www.inf.u-szeged.hu/~groszt/index.php?id=DLmaterials>

(Készítette: Dr. Grósz Tamás)

A tananyag az EFOP-3.5.1-16-2017-00004
pályázat támogatásával készült.

SZÉCHENYI 



MAGYARORSZÁG
KORMÁNYA

Európai Unió
Európai Szociális
Alap



BEFEKTETÉS A JÖVŐBE

GÉPI TANULÁSI ALAPFOGALMAK

A tananyag az EFOP-3.5.1-16-2017-00004
pályázat támogatásával készült.

SZÉCHENYI 



MAGYARORSZÁG
KORMÁNYA

Európai Unió
Európai Szociális
Alap



BEFEKTETÉS A JÖVŐBE




A gépi tanulás célja

- Cél: Olyan programok létrehozása, amelyek a működésük során szerzett tapasztalatok segítségével képesek javítani a saját hatékonyságukon
- Tanulóalgoritmus: Olyan algoritmusok, amelyek képesek szabályosságok, összefüggések megtalálására tanítópéldák egy halmaza alapján
 - 1. megj: A lényeg nem a konkrét tanítópéldák megtanulása, hanem a helyes általánosítás a tanulás során nem látott példákra is!
 - 2. megj: a feltételezett összefüggést „hipotézisnek” fogjuk hívni, ugyanis sosem lehetünk biztosak benne, hogy működni fognak a nem látott esetekre is
 - 3. megj: további példákat kapva a hipotézist javítjuk, az új példák alapján



Gépi tanulási feladatok típusai

- Felügyelt tanulás: minden tanítópéldához meg van adva, hogy milyen választ várunk a géptől
 - Tipikus feladat: osztályozás
 - Példa: karakterfelismerés
 - Input: betűket ábrázoló képek
 - Output: (ezt kell a gépnek kitalálnia): milyen betű van a képen
 - Felügyelt tanítás esetén a tanítópéldákhoz (betűk képei) az elvárt választ is megadjuk (milyen betű van a képen)
- Felügyelet nélküli tanulás: az osztályokat is automatikusan kell megtalálnia a gépnek, pl. valamilyen hasonlóság alapján
 - Tipikus feladat: klaszterezés



Feladattípusok (2)

- A neuronhálókat eredetileg az osztályozási feladat sémájára találták ki, azaz egy (fix méretű) inputra egy fix méretű outputot adnak
- Egyéb, fontos, speciális feladattípusok is léteznek, amelyek nem illenek ebbe a klasszikus sémába, pl:
- Időbeli folyamatok modellezése
 - Az aktuális kimenet a korábbi bemenetektől is függ(het), pl. videó felismerése, beszéd-felismerés, tőzsdei árfolyamok modellezése
- Sorozat→sorozat leképezés, pl. gépi fordítás
 - A sorozat hossza változó
 - Input-output hossza eltérhet
 - Nincsenek egyértelmű szó-szó párok, sorrend is keveredhet





Feladattípusok (3)

- Megerősítéses tanulás (reinforcement learning)
 - Pl. mesterséges „élőlények” létrehozása
 - Interakcióban van a környezetével, tapasztalatokat gyűjt, azokra reagál
 - Az osztályozással szemben itt nincs egyértelmű tanítócímke minden egyes eseményhez, csak egy hosszú távú cél (minél tovább életben maradni)
 - Kézzelfoghatóbb példa: sakk (vagy go) játszásának megtanulása
 - Cél: a parti megnyerése, az egyes lépések nem egyértelműen minősíthetők jónak vagy rossznak
- Összegzés: a neuronhálós modellt alapvetően az osztályozási feladat megoldására találták ki, de újabban próbálják alkalmazni más jellegű, bonyolultabb feladatok megoldására is (önmagában, vagy más algoritmusokkal kombinálva)

Az osztályozási feladat

- A leggyakoribb gépi tanulási feladat
- Cél: objektum-példányok besorolása előre adott $c_1, \dots, c_M$ osztályok valamelyikébe
- Input: valamilyen mérési adatokból álló (fix méretű) vektor
 - Jellemzővektor, feature vector, attributumvektor
- Tanítópéldák halmaza: jellemzővektorokból és hozzájuk tartozó osztálycímkekből álló párosok egy halmaza
 - Példa: Influenzás-e a beteg?

F e a t u r e v e c t o r			Osztálycímke (I/N)
Láz	Ízületi fájdalom	Köhögés	Influenzás
38,2	Van	Nincs	Igen
36,7	Van	Száraz	Nem
41,2	Nincs	Nyákos	Igen
38,5	Van	Száraz	Igen
37,2	Nincs	Nincs	Nem


} *tanító-
példányok*

A jellemzőtér


- Ha a jellemzővektorunk N komponensből áll, akkor a tanítópéldáink egy N -dimenziós tér pontjaiként jeleníthetők meg

- Példa:

- két jellemző $\rightarrow$ 2 tengely (x_1, x_2)
- Osztálycímke (c): színekkel jelölve




- A tanulási feladat tehát: becslést adni az $(x_1, x_2) \rightarrow c$ függvényre a tanítópéldák alapján
- M osztály esetén ez ekvivalens M db. $(x_1, x_2) \rightarrow \{0, 1\}$ karakterisztikus függvény megtanulásával
 - A karakterisztikus függvény szakadáson, folytonos jellemzőtér felett nehezen reprezentálható
 - Kétféle módon tudjuk megoldani, hogy folytonos modellel tudjuk reprezentálni a fenti szakadáson függvényt



A döntési felület reprezentálása

- Direkt (geometriai) szemlélet: közvetlen módon a határoló felületeket reprezentáljuk
 - Valamilyen egyszerű módon, pl. egyenesekkel
- Indirekt (döntésméleti) szemlélet:
 - Minden osztályhoz rendelünk egy függvényt, amely megmondja, hogy a tér egyes pontjai mennyire tartoznak az osztályhoz (tkp. olyan, mint a karakterisztikus fgv., de ez folytonos is lehet)
 - A diszkriminánsfüggvényekből úgy kapunk osztály-címkét, hogy a tér adott pontját az ott *maximális* értéket adó függvény osztályához soroljuk
 - Az osztályok határait indirekt módon a diszkriminánsfüggvények metszési görbéi határozzák meg
- A neuronhálók működése mindkét módon interpretálható!





A statisztikai alakfelismerés alapjai

- Az osztályozási feladat statisztikai alapú megközelítése
 - A gyakorlatban a gépi tanulás egyik legnépszerűbb irányzata
 - Szilárd matematikai háttér (valószínűesszámitás/statisztika)
 - Gyakorlatban is implementálható/használható megoldásokat ad
- Lényege a Bayes döntési szabály, amely matematikai formalizmust rak a döntéshozatali szemlélet mögé
 - Osztályozandó objektumok $\rightarrow \mathbf{x}$ jellemzővektor
 - Feladat: az objektumok $\{c_1, \dots, c_M\}$ osztályok valamelyikébe sorolása
 - Cél: a téves besorolások számának minimalizálása hosszú távon
 - Bayes döntési szabály: adott $\mathbf{x}$ vektor esetén azt az i osztályt kell választani, amelyre $P(c_i|\mathbf{x})$ maximális
 - Azaz a döntéshozatali módszer optimális megoldást ad, ha diszkrimináns-függvényként $P(c_i|\mathbf{x})$ -et használjuk!
- Innentől alakfelismerés = $P(c_i|\mathbf{x})$ minél pontosabb becslése a tanítópéldák alapján!



Statisztikai alakfelismerés és neuronhálók

- A neuronháló működését értelmezhetjük az egyszerűbb „geometriai” szemlélet alapján
 - Azaz tekinthetjük úgy, hogy a háló az egyes osztályok közötti határvonalat igyekszik megkeresni
 - Ez az egyszerűbb, szemléletesebb magyarázat
- A neuronháló statisztikai alakfelismerési modellként is értelmezhető
 - Bebizonyítható, hogy bizonyos feltételek teljesülése esetén a neuronháló kimeneteit értelmezhetjük úgy is, mint az egyes osztályok $P(c_i|\mathbf{x})$ valószínűségére adott becslések
 - Ezek pedig megfelelnek a korábban döntéshalméleti módszert által elvárt osztályonkénti diszkriminánsfüggvényeknek.
 - Ez a bonyolultabb értelmezés, viszont matematikailag sokkal hasznosabb (lehetővé teszi a modell matematikai értelmezését, elemzését...)
- A továbbiakban mindkét értelmezést megnézzük majd részletesebben



Kiértékelés

- A tanítás eredménye: a tanítópéldák alapján a tanítóalgoritmus készít egy modellt, azaz egy hipotézist a $(x_1, x_2) \rightarrow c$ függvényre
 - Ez a tér tetszőleges (x_1, x_2) pontjára meg tudja tippelni, hogy az melyik osztályba esik
- Honnan tudjuk, hogy ez a modell mennyire jó vagy rossz?
 - Megmérhetnénk, hogy a tanítópéldák hány százalékát osztályozza helyesen
- Fő célunk azonban nem a tanítópéldák címkéjének hibátlan megtanulása, hanem a tanítás során nem látott példákra való általánosítás!
 - A tanítópéldákon mért pontosság becsapós: kellően rugalmas modell jól be tudja tanulni a tanítópéldákat, azaz kicsi hibát ad rajtuk, mégis lehet, hogy rosszul általánosít a tanulás során látottaktól kicsit eltérő példákra





Kiértékelés (2)

- Hogyan tudunk becslést adni az általánosító képességre?
 - A tanítóadatokat nem használhatjuk a fentiek miatt
 - Viszont mindenképp címkézett adat kell a tippelt és a valódi címkék összehasonlításához
- Megoldás: a tanítópéldáink egy részét félretesszük, nem használjuk fel a tanítás során
 - Az lesz az ún. teszhalmaz
- A tanítás+kiértékelés lépései tehát:
 - A tanító és –tesztadatok szétválasztása
 - Háló betanítása a tanító halmazon
 - A háló kiértékelése a teszhalmazon → tippelt címkék
 - A tippelt és a valódi címkék összehasonlítása a teszhalmazon
 - Osztályozási hibaszázalék = $\frac{\text{elrontott címkék száma}}{\text{összes tesztpélda száma}}$



A gépi tanulási modell paraméterei és metaparaméterei

- Minden gépi tanulási algoritmusnak vannak beállítandó paraméterei
 - Tekintsük a korábbi példát, ahol egy egyenessel igyekeztünk elválasztani két osztályt
 - A modell paraméterei ekkor az egyenes együtthatói
 - Ezeket optimalizáljuk a tanítás során, ezzel tudjuk az egyenes optimális irányba és pozícióba igazítani
- És mik azok a meta-paraméterek (más szóval hiperparaméterek)?
 - Általánosítsuk a fenti modellt úgy, hogy egyenes helyett polinomot használjon
 - A polinom fokszáma lesz az algoritmus metaparamétere
 - A paraméterekkel általában a modell adatokra való illeszkedését, a meta-paraméterekkel pedig a modell flexibilitását, reprezentációs erejét tudjuk állítani
 - A paramétereket a tanítóalgoritmus hangolja be, a metaparamétereket általában mi választjuk meg kézzel, valamilyen heurisztika alapján
 - Neuronhálók esetén meta-paraméter: neuronok száma, rétegek száma,...






A gépi tanulási modell paraméterei és metaparaméterei

- Különböző paraméterértékek mellett kicsit különböző modelleket kapunk
 - Hogy tudjuk megtalálni az optimális meta-paramétereket?
- A tanítóhalmazból lecsípünk egy kisebb validációs (vagy development) példahalmazt
 - A példákat tehát train-dev-test halmazokra osztjuk
 - A tanítást a train halmazon többször elvégezzük, különböző metaparaméter-értékek mellett
 - A kapott modelleket kiértékeljük a development halmazon
 - Végül a development halmazon legjobbnak bizonyuló modellt értékeljük csak ki a teszhalmazon

A metaparaméterek szerepe

- Neuronháló esetén a paraméterek: a háló súlyai
- A fő metaparaméterek pedig: neuronok száma, rétegek száma, ...
 - Ezekkel a háló méretét állítjuk
 - Nagyobb háló bonyolultabb döntési felületeket képes kialakítani




- Különböző metaparaméter-értékek mellett különböző modelleket kapunk
 - Hogy tudjuk megtalálni az optimális meta-paramétereket?
 - Használjunk nagyon rugalmas modellt?
 - Sajnos nem feltétlenül jó, mert a tanuló példák félrevezetőek is lehetnek (véges mintát vettünk egy végtelen eloszlásból), vagy pl. hibásak (zajosak)



Általánosítás és túltanulás

- Végtelen jellemzőtér, véges számú tanító példa → sosem lehetünk biztosak benne, hogy a tanult modell jól általánosít a tanulás során nem látott esetekre
- A modell méretének növelésével a modell rugalmassága nő, egyre pontosabb lesz a tanítópéldákon
 - Viszont a teszt példákon egy ponton túl romlani fog a teljesítménye
 - Ezt hívják túltanulásnak (overfitting): a modell az általános tulajdonságok után már az aktuális véges mintahalmaz egyedi furcsaságait kezdi megtanulni





Optimális modellméret megtalálása

- Az optimális modellméret feladatonként nagyon eltérő lehet
 - A feladat jellege mellett függ a példaszámtól, jellemzők számától,...
 - Bonyolult elméleti háttere van: „No free lunch” tétel
- Gépi tanulási tapasztalatot igényel a belövése
 - bár egyre inkább vannak automatikus megoldások erre is...
- Néhány „hüvelykszabály”:
 - „There is no data like more data” - Minél több tanítópéldánk van, annál nagyobb hálózatot építhetünk a túltanulás veszélye nélkül
 - Érdekes kis jellemzőszámra törekedni („curse of dimensionality”)
 - Az (adatmennyiséghez képest) nagyon sok jellemző esetén szintén nő a túltanulás veszélye
 - Kevés adat és/vagy nagy jellemzőszám esetén érdemes regularizációs technikákat használni (ld. később)
 - Megjegyzés: a „deep learning”-nek csak nagyon nagy adatmennyiség mellett van igazán értelme...



A metaparaméterek belövése a gyakorlatban


- Különböző paraméterértékek mellett kicsit különböző modelleket kapunk
 - Hogy tudjuk megtalálni az optimális metaparamétereket?
 - Le kellene mérnünk a modell pontosságát különböző metaparaméter-értékek mellett egy teszhalmazon
 - A végső teszhalmaznak függetlennek kell lennie, mind a paraméterek, mind a metaparaméterek optimalizálása során használt adatoktól
- A tanítóhalmazból lecsípünk egy kisebb validációs (más szóval development) példahalmazt
 - A példákat tehát train-dev-test halmazokra osztjuk
 - A tanítást a train halmazon többször elvégezzük, különböző metaparaméter-értékek mellett
 - A kapott modelleket kiértékeljük a development halmazon
 - Végül a development halmazon legjobbnak bizonyuló modellt értékeljük csak ki a teszhalmazon



A metaparaméterek belövése a gyakorlatban

- Ábrával szemléltetve:

- A tanítást a train halmazon többször elvégezzük, különböző metaparaméter-értékek mellett – megkapjuk a kék görbét
- A kapott modelleket kiértékeljük a validációs halmazon – piros görbe
- Végül a development halmazon legjobbnak bizonyuló modellt értékeljük csak ki a teszhalmazon – kék pötty



KÖSZÖNÖM A FIGYELMET!

A tananyag az EFOP-3.5.1-16-2017-00004 pályázat támogatásával készült.

SZÉCHENYI 



MAGYARORSZÁG
KORMÁNYA

Európai Unió
Európai Szociális
Alap



BEFEKTETÉS A JÖVŐBE