


Modellkiválasztás és struktúrák tanulása




Szervezőelvek keresése

- Az unsupervised learning egyik fő célja
 - Optimális reprezentációk
 - Magyarázatok
 - Predikciók
- Az emberi tanulás alapja
- Általános strukturális relációk az objektumok vagy koncepciók között - gráfstruktúrák
- Kognitív tudomány – a neurális szint messzebb van



Taxonómiák tanulása




- Egyes objektumok megfigyelése alapján kell kikövetkeztetni azt a struktúrát, ami jól megjeleníti az objektumok közti viszonyokat
- Gyerekek nyelvtanulási folyamata
- Nagyon kevés mintából jó következtetések levonása
- Jellemző struktúra a fa, de általános gráf is lehet

Statisztikai modellek összehasonlítása

- Komplexitás és illeszkedés egyensúlya
- Ockham borotvája
- Teljes hierarchikus modell illesztése
 - poszterior eloszlás becslése a modellek tere fölött
 - Prior modelleloszlás
- Becslések a magasabb szintek paramétereire
 - Illesztett likelihood – túlillesztést preferálja
 - Marginal likelihood (evidence)
 - Becslések evidence-re: AIC, BIC


Hierarchikus modellek

- Struktúra $\rightarrow$ paraméterek $\rightarrow$ változók
- Prior eloszlás a modellek halmaza fölött
- Paraméterek becslése inverzióval – numerikus módszerek, VB
- Számításigényesebb, de konzisztens reprezentáció



Evidence mint modelljóság

- Az adatok valószínűsége egy modellstruktúrára kondicionálva, a paramétereket kiintegrálva
- Átlagosan milyen valószínűségű az adat
- Komplex modell:
nagyon sokféle
adathalmazt ír le
nemnulla
valószínűséggel, de
mindegyiket kisebbel
- Egyszerű modell:
nagy valószínűséggel
ír le kevés
adathalmazt




$$p(\mathcal{D}|\mathcal{M}) = \int p(\mathcal{D}|\theta, \mathcal{M}) p(\theta|\mathcal{M}) p(\theta)$$

Modellterek definíciója

- Milyen térben keressük a legjobb modellt?
- Network discovery
 - Nincs előre beépített tudás
 - A számítási komplexitás nagyon nagy lehet
 - Ha nem metrikus a tér, nehéz bejárni
- Előre definiált halmazok
 - A hierarchia felső szintjén
 - Hipotézisvizsgálat lehetséges
 - Ki lehet számolni
- No input – high throughput – no output

Háromszintű generatív modell



- Felépítés


- Objektum-tulajdonság adatmátrix
- Gráfstruktúra a hasonló tulajdonságok alapján
- Gráfstruktúrát generáló növesztési szabály

- Matematikai forma





- Generálási szabályok felett egyenletes prior
- Struktúrák felett kisebb elemszámot preferáló prior
- Minél nagyobb súlyú él van a pontok között, annál hasonlóbb a tulajdonságvektoruk

$$p(F, S|D) \propto p(D|S) p(S|F) p(F)$$

Gráfnyelvvtani formák struktúrák generálására



Példák strukturális inferenciára




Magasszintű tulajdonságok kategóriáinak tanulása

- Feature-hierarchiák
 - Önmagukban nem feltétlenül értelmesek
 - Jól tanulható unsupervised módon
 - Elosztott reprezentációk
 - Kevés példából nem tanul jól
- Kategória-hierarchiák
 - Egy kategória magasszintű feature-ök összessége
 - Explicit reprezentációk
 - Új kategória felvételénél a hierarchia felsőbb szintjei segítenek a körülhatárolásban
 - Kevés példából tanulható kategóriák

Kombinált kauzális-energia modellek

- HD-compound model
- Deep Boltzmann Machine
 - Feature-hierarchyák
- Hierarchikus Dirichlet-folyamat
 - Mixture modell témakörökre
 - Kategória-hierarchiák
- Automatikus tanulás és hatékony kategóriaformáció együtt
- Új kategóriák tanulása hatékonyan



Karakterkészletek tanulása HD-moddal





Figure 5: A random subset of the training images along with 1st and 2nd layer DBM features, as well as higher-level class-sensitive HDP features/topics.

Learning with 3 examples




Összefoglalás

- A koritkális komputáció alapelvét keressük
- Generatív modellek építése
- A bizonytalanság reprezentációja
- Új megfigyelések és előzetes tudás integrációja (Bayes)
- Kauzális vagy energialapú modellek
- Tulajdonságok és kategóriák hierarchiája
- Struktúrák magyarázóereje

Modellek tesztelhetősége

- Viselkedési adatok
 - Teljesítménygörbék reprodukciója
 - Azonos hibákat csinál-e az algoritmus és az ember?
- Predikciók ellenőrzése fiziológiai adatokon
 - Tüzelési statisztikák
 - Populációs aktivációk
- Anatómiai korrelátumok
 - Cortical microcircuitry
 - Moduláris komputáció
 - Kérgi területek hálózatai
- Neurális aktivitás mérése
 - Lokálisan, elektródarácsokkal
 - Állatokban



Továbbblépési lehetőségek

- Új adatok
 - Átlátszó agy fehérjekiütésekkel
 - Human Connectome Project (és HBP)
- Új elmélet
 - Deep learning
 - Dendritikus komputáció
- Reprezentáció kérdése
 - Populációs kódok
 - Prediktív kódolás



Ajánlott irodalom

- Unsupervised learning
 - Geoffrey Hinton <https://www.coursera.org/course/neuralnets>
 - Ruslan Salakhutdinov
<http://www.utstat.toronto.edu/~rsalakhu/publications.html>
 - Yann LeCun
 - Zoubin Ghahramani
 - Christopher Bishop: Pattern Recognition and Machine Learning
- Bayesian brain
 - Rajesh Rao: Probabilistic models of the brain: perception and neural function
 - Kenji Doya: Bayesian Brain
 - Karl Friston http://www.fil.ion.ucl.ac.uk/~karl/#_Free-energy_principle
 - Joshua Tenenbaum
 - Lengyel Máté
 - Alex Pouget