

Statisztikus tanulás az idegrendszerben

ORBÁN GERGŐ

www.eng.cam.ac.uk/go223



Somogyvári Zoltán



Bányai Mihály



Orbán Gergő

1. Bevezetés - G
2. Perceptron, előrecsatolt hálózatok
3. Rekurrens hálózatok, a Hopfield hálózat
4. Rejtett változós modellek
5. Reprezentációs tanulás
6. Eloszlások tanulása, a Boltzmann-gép
7. MAP paraméterbecslés, bayesi modelösszehasonlítás
8. Az EM-algoritmus, keverékmodellek
9. Az EM speciális esetei
10. PCA, ICA, divisive normalisation
11. Bayes nets, Helmholtz machine
12. DBN, kontrasztív divergencia
13. Sampling

Kontextus

- Gatsby Computational Neuroscience Unit, UCL
Peter Dayan
- Dept Computer Science, University of Toronto
Geoff Hinton
- Cavendish Laboratory, University of Cambridge
David MacKay
- CBL, University of Cambridge
Mate Lengyel
- Centre for Integrative Neuroscience, Universitat Tübingen
Matthias Bethge
- Dept Statistics, Columbia University
Liam Paninski
- Dept Neural Science, NYU
Eero Simoncelli

Miért vagyunk itt?

- Idegtudomány
- Adattudomány
- Kredit aratás
- Egyéb


Miért vagyok én itt?

- Hiánypótlás: Ilyen kurzus nincsen az országban
- Lehetőséget teremteni

Percepció és akció




©patita , SXC



Marr-i osztályozás

- **Komputáció**
Mi a célja a megfigyelőnek?
- **Algoritmus**
Milyen matematikai eszközzel valósítja meg a célt?
- **Implementáció**
Milyen wetware/hardware megoldásokat használ a megvalósításhoz?



Szenzáció vs. Percepció






© nova, SXC

Miért statisztikus modellek?

“I keep saying that the sexy job in the next 10 years will be statisticians”
Hal Varian, chief economist at Google.

- A statisztikus modellek nem tesznek mást, mint komolyan veszik a “zaj” struktúráját
- Explicitté teszik a feltételezéseket
- A stimulusok inherens tulajdonsága a bizonytalanság, ezért nem engedheti meg az agy azt a luxust, hogy ezt elhanyagolja


Zaj struktúra



átlag és szórás megegyezik

- Ha jósolni akarjuk a jövőbeni pontokat, akkor nem árt komolyan venni azt, hogy milyen processz generálta a pontokat

Explicit feltételezések



$$\mathbf{P}(y \mid x, a, b) = x + \mathcal{N}(0, \epsilon)$$


$$\mathbf{P}(\mathcal{D} \mid x, \theta)$$

Bíonytalanság forrása


Contrast/brightness





3D→2D projection



Multiple interpretations: Bistability





Aperture problem: Incomplete information




Tanulás típusok

- Supervised
- Unsupervised
- Reinforcement
- (Semi-supervised)



Hol vannak a neuronok?

- Történetileg ideghálózatok inspirálták MI-t: ANN



- Filozófia: a neuronhálózatok egzotikusak és hatékonyak, a mi problémáink is elég egzotikusak, tehát a neuronok vonzóak

Recept:

aktiválódási függvények
súlyok
tanulási szabályok

$P(x)$
$P(\{x\} \theta)$
közelítés



Somogyvári Zoltán



Bányai Mihály



Orbán Gergő

1. Bevezetés - G
2. Perceptron, előrecsatolt hálózatok
3. Rekurrens hálózatok, a Hopfield hálózat
4. Rejtett változós modellek
5. Reprezentációs tanulás
6. Eloszlások tanulása, a Boltzmann-gép
7. MAP paraméterbecslés, bayesi modelösszehasonlítás
8. Az EM-algoritmus, keverékmodellek
9. Az EM speciális esetei
10. PCA, ICA, divisive normalisation
11. Bayes nets, Helmholtz machine
12. DBN, kontrasztív divergencia
13. Sampling