

Statisztikai tanulás az idegrendszerben, 2015.

Látórendszer modellezése

Bányai Mihály


banyai.mihaly@wigner.mta.hu

<http://golab.wigner.mta.hu/people/mihaly-banyai/>

- A látórendszer felépítése
- Prediktálhatóság az idegrendszerben
- V1 statisztikai modelljei
- Top-down hatások neurális szinten

- A látórendszer felépítése
- Prediktálhatóság az idegrendszerben
- V1 statisztikai modelljei
- Top-down hatások neurális szinten

Hierarchikus objektumfelismerés



- A szenzor tulajdonságai
 - pálcikák
 - csapok: fajok között változó a színlátás
 - két szem


Vizuális bemenet feldolgozása

- átkapcsolás a talamuszban
- V1 egyszerű és összetett sejtek (serkentő és gátló, sok típus)
 - szín-opponens sejtek
 - binokuláris diszparitás (autosztereogrammok)
- összekötöttség lokális topológiája
- top-down input
- más szenzorikus területek beidegzése
- adaptáció


Receptív mezők

- Olyan stimulusok összessége, amire a sejt érzékeny


V1 simple



V1 complex






Hippocampus



Magasabbrendű területek szelektivitása

- Dorzális stream
 - mozgás, lokáció
- Ventrális stream
 - V2 - textúra
 - IT - objektumok, kategóriák



Aktivitás mérhetősége

- kiváltott és spontán aktivitás
 - éber vs. altatott állatban
 - Berkes et al: a spontán aktivitás a prior mintavételezése, a kiváltott válaszok stimulusok felett vett átlagához közelít
- membránpotenciál és tüzelés: nemlineáris kapcsolat, mérni általában a tüzelést tudjuk, néhány tíz sejtből egyszerre
- együttes aktivitás
 - signal variance és correlation - a neurális válasz átlagára jellemző mennyiségek, amit használt stimulushalmaz korreláltan befolyásol
 - noise correlation és variance - a neurális válasz variabilitása és korrelációja ugyanazon stimulus ismételt prezentációja során

- A látórendszer felépítése
- Prediktálhatóság az idegrendszerben
- V1 statisztikai modelljei
- Top-down hatások neurális szinten

Prediktáljunk neurális választ

- Adat: membránpotenciál vagy tüzelések
- Modell: valószínűségi
- Receptív mező - átlagstatisztika
- A teljes predikció a konkrét idősor lenne
- Ehelyett prediktálhatjuk a neurális válaszok együttes valószínűségi eloszlását
 - minden struktúrát, információt megpróbálunk valószínűségi modellben megfogalmazni
 - a konkrét, idősorral történő realizációt esetlegesnek tekintjük
- Hogyan reprezentáljuk a valószínűségi eloszlásokat és sűrűségeket az idegrendszerben?
 - sampling - a modellt ki kell egészíteni egy samplerrel



Stacionárius és tranziens predikciók

- Ha a sampler konvergál, egy idő után a minták reprezentatívak lesznek a stacionárius eloszlásra, amit a valószínűségi modell ír le
 - maga az algoritmus lehet csak egy eszköz a mi kezünkben, hogy eljussunk eddig az eloszlásig (mert mondjuk analitikusan nem tudjuk megadni a poszterior eloszlást)
 - megpróbálhatjuk prediktálni biofizikai mennyiségek konkrét időgörbáját a sampler mint dinamikus rendszer időgörbéjével
 - Hamiltonian sampler, Lengyel et al, 2014.
- Ugyanígy a paraméterbecslésre használt algoritmusoknál

Black box predikciók

- Általános machine learning modelleket illeszthetünk a stimulusokra, és megpróbálhatjuk prediktálni a változóikkal a neurális aktivációt
- Deep learning módszerek
 - képekre illesztve úgy, hogy azokat minél jobban klasszifikálják
 - a felsőbb rétegek aktivitása annál jobban prediktálja a ventrális stream magasabb régióiban mért aktivitást, minél jobb a klasszifikáció
 - kb. a mért variancia 50%-át tudják így prediktálni a temporális kortexbeli méréseknél

Deep convolutional network prediktivitás



Informált predikciók


- Válasszuk meg úgy a változókat, hogy azok minél jobban tükrözzék a neurális aktivitásról a mérésekből szerzett tudásunkat
- a változóink szerepe a modell definíciójából fog következni
- a vizuális feldolgozás első lépéseitől építjük fel a modelljeinket
- a célunk az alacsonyszintű reprezentációk feltárása, és onnan továbblépni

- A látórendszer felépítése
- Prediktálhatóság az idegrendszerben
- V1 statisztikai modelljei
- Top-down hatások neurális szinten

- Szorítkozzunk a V1-re
- Hanyagoljuk el
 - a színlátást
 - azt a tényt, hogy két szemünk van
 - Más szenzorikus területekről jövő bemenetet
 - az összekötöttség topológiáját
 - a sejtípusok különbözőségét
 - az adaptációt
- Kezdeként szintén hagyoljuk el
 - A top-down hatásokat
 - a komplex sejteket
 - minden laterális összekötöttséget
- Tehát kezdjük az egyszerű sejtek választulajdonságaival minden mástól függetlenül

Olshausen-Field modell


- természetes képek független komponensei
- pontbecslés, kombinálva a maximum likelihood és a sparsity kritériumokat
- log-poszterior = kvadratikusan log-likelihood + sparse prior
- Egyszerre optimalizáljuk az adatra illeszkedést és a látens aktivációk ritkaságát
- Gradiens-módszerrel lépkedünk az így konstruált hibafüggvényen
- 32x32 képek -> 1024 dimenziós poszterior eloszlás, $\sim 2^{20}$ szabad paraméter



$$p(x \mid y) = \mathcal{N}(x; Ay, \sigma I)$$



sparsity



Gaussian Scale Mixture



- relaxáljuk a függetlenségi feltételezést - kovarianciamátrix a látens aktivációk priorjában
- következtessünk a kontrasztra is - folytonos keverékmoddelt kapunk
- a skálaváltozó biztosítja a sparse aktivációt

$$P(\mathbf{u}) = \mathcal{N}(\mathbf{u}; \mathbf{0}, \mathbf{C})$$

$$P(z) = \text{Gamma}(z; k, \theta)$$

$$p(\mathbf{x} \mid \mathbf{u}, z) = \mathcal{N}(\mathbf{x}; zA\mathbf{u}, \sigma^2 I)$$

$$\text{image} = \text{contrast} \times (a_1 \text{feature}_1 + a_2 \text{feature}_2 + \dots + a_N \text{feature}_N + \text{noise})$$



Prior kovariancia tanulása

- Szűrőhalmaz és prior kovariancia nem tanulható függetlenül - a szűrőket vegyük egy OF-modellből vagy analitikus Gábor wavelet-bázisból, és tanuljuk a korrelációikat
- EM

$$p(z \mid \mathbf{x}) \sim p(z)p(\mathbf{x} \mid z) = \text{Gamma}(z; k, \theta) \mathcal{N}(\mathbf{x}; \mathbf{0}, \sigma^2 \mathbf{I} + z^2 \mathbf{A} \mathbf{C} \mathbf{A}^T)$$

$$p(\mathbf{u} \mid \mathbf{x}, z) = \mathcal{N}(\mathbf{u}; \mu_{u|xz}, C_{u|xz})$$



$$C_{u|xz} = \left(\mathbf{C}^{-1} + \frac{z^2}{\sigma^2} \mathbf{A}^T \mathbf{A} \right)^{-1}$$

$$\mu_{u|xz} = \frac{z}{\sigma^2} C_{u|xz} \mathbf{A}^T \mathbf{x}$$


$$\mathbf{C}^* = \frac{1}{N} \int_0^\infty C_{u|xz} \sum_{n=1}^N p(z \mid \mathbf{x}) + \sum_{n=1}^N p(z \mid \mathbf{x}) \mu_{u|xz} \mu_{u|xz}^T \mathrm{d}z$$

GSM predikciói korrelációkra

- membránpotenciál





- tüzelés




- A látórendszer felépítése
- Prediktálhatóság az idegrendszerben
- V1 statisztikai modelljei
- Top-down hatások neurális szinten

Kontextusfüggő kovariancia és variancia




- komplex sejtek aktivitásának predikciója: Karklin és Lewicki, 2009.
- ML pontbecslés a paraméterekre





Top-down hatások a korrelációkban






- Illuzórikus kontúrokkal vizsgálható
- Az IC-re adott válasz V1-ben is mérhető
- Az amplitúdója kisebb
- A sorrend megfordul
 - tényleges él: V1 -> V2
 - IC: V2 -> V1



Top-down hatások modellezése



- Component Scale Mixture
- Gibbs sampling



Tehát végülis mit tudunk az agyról?

- Leíró jelleggel sokat
- Viselkedési szinten közepes mennyiségűt (volt és lesz is még róla szó)
- Neurális szinten keveset
 - V1 sejtjeinek válaszstatisztikáját tudjuk viszonylag jól prediktálni
 - tranziensekre léteznek javaslatok
 - más szenzorikus kérgekben hasonló szintű modellek léteznek
 - magasszintű reprezentációkat megvalósító sejtek válaszait csak black box módszerekkel, részlegesen
 - hippocampusban helysejtek aktivitásának átlagát tudjuk jósolni
 - döntéshozási modellekben (reinforcement learning) egyes sejtpopulációk átlagos válasza jósolható az alany kísérleti szituációra vonatkozó predikciós hibájából

Házi feladat

- írd föl grafikus valószínűségi modellt binokuláris diszparitás predikciójára
 - a megfigyelt változó két pixelvektor
 - térbeli mélységet szeretnénk leírni
- hogyan lehet inferenciát végezni a modellben?
- hogyan becsülnéd a modell paramétereit?
- milyen kísérleti adatokkal hasonlítanád össze a modell predikcióit és hogyan?