



Effects of higher-order statistics on activity in V1



Research talk, 24.09.2014.



Reprezentáció

- Milyen modellek jönnek létre?
 - változók, paraméterek
 - mik a korlátozások?
- Milyen algoritmusok alapján változnak a modellek?
 - paraméterillesztés
 - modellkiválasztás
- Mik a modellek biofizikai korrelátumai?
 - neurális kód
 - segíti a keresést




Ismert neurális kódok

- Elsődleges szenzoros
 - Hubel-Wiesel
 - Auditórikus
 - Taktilis-szomatoszenzoros
 - Olfactory, ...
- Magasabb szintű szenzoros
 - V2, textúra, élkombinációk, ...
- Multimodális
 - objektumok, koncepciók
 - place és grid sejtek



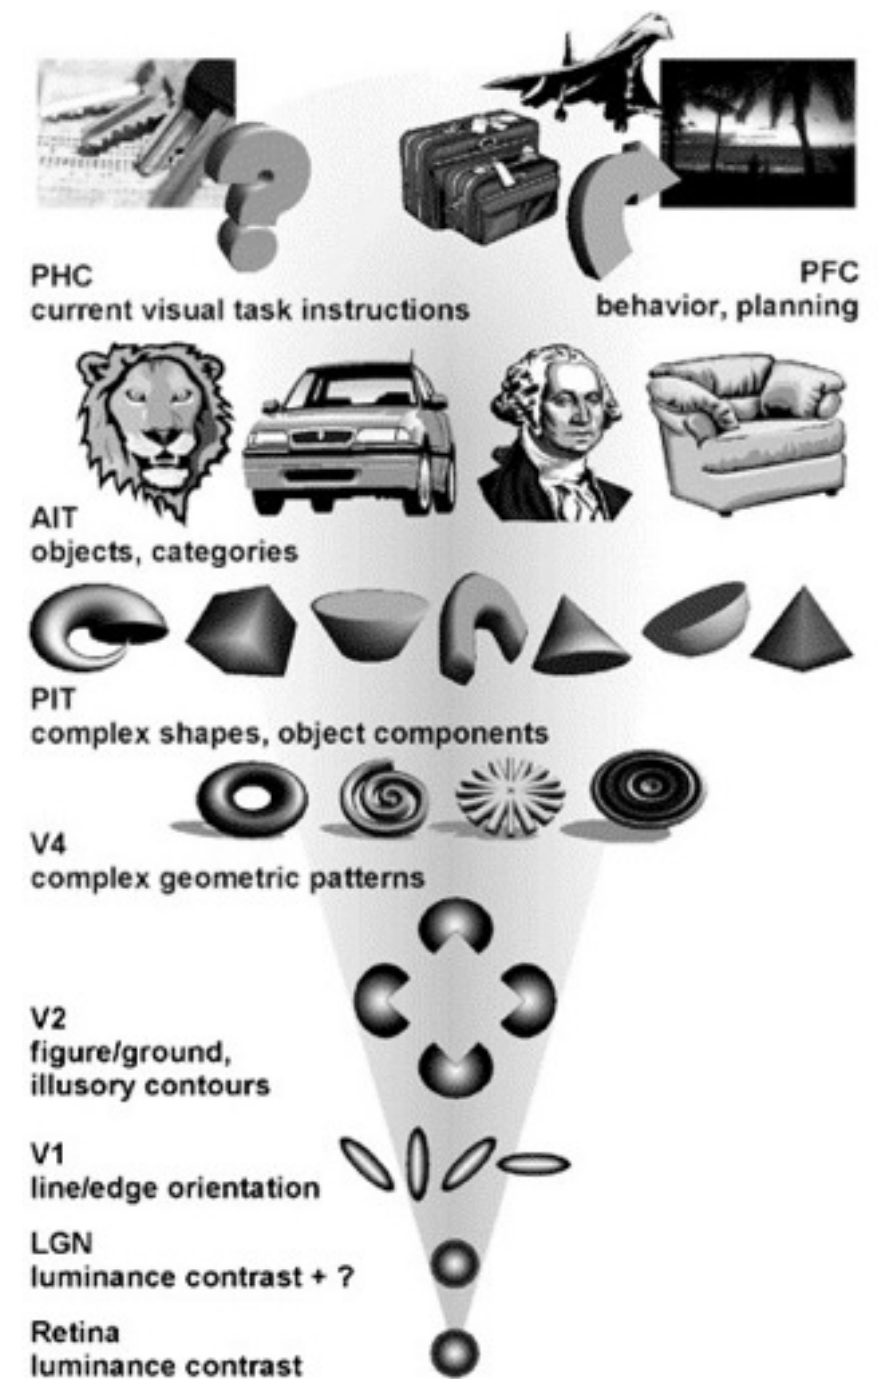
Hova kellene eljutni?

- Mentális modellek:
empirikriticizmus, erkölcsi
bizonyítvány, szójafasírt
- Nyelvi információ integrációja
- Eszköz a valószínűségi modellek
keretrendszerre
- valószínűség mint információ
- valszám mint logika
- neurális variabilitás



A vizuális feldolgozás hierarchiája

- Azt gondoljuk, hogy van, részben csak pletyka
- Hubel és Wiesel óta minden gyanús egy kicsit
- Azt is gondoljuk, hogy az egész egy generatív modell
- Természetes képek statisztikája
- Top-down és bottom-up folyamatok integrációja
- Unconscious inference
- Sampling from the posterior (and prior)



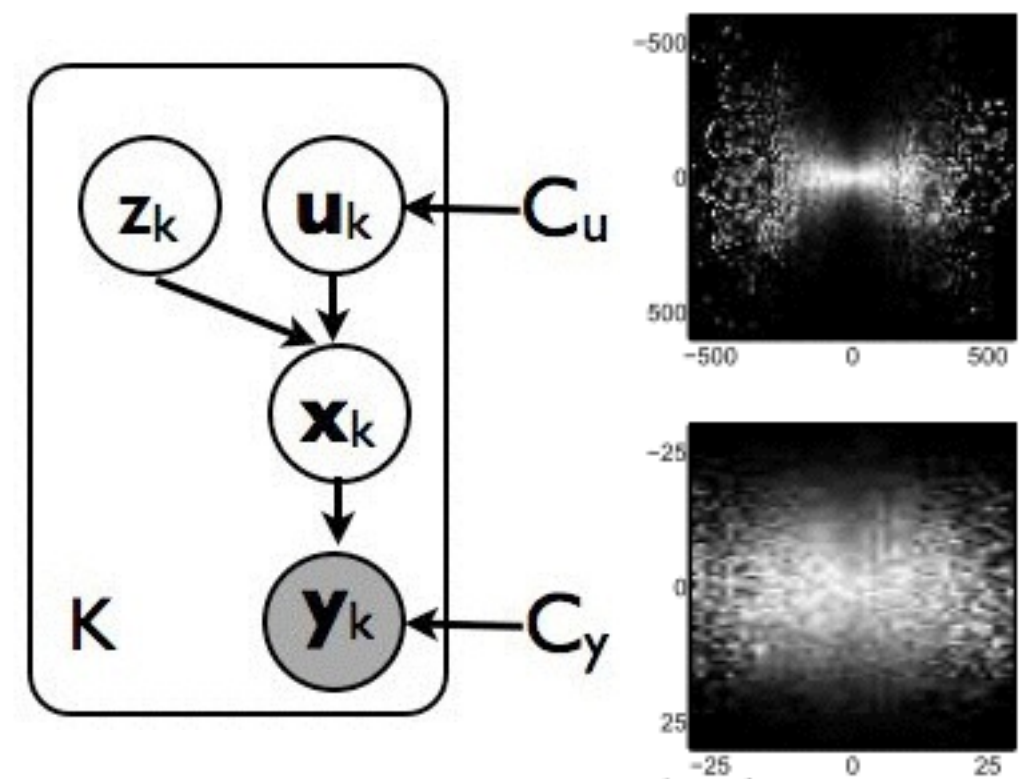

Ibn al-Haytham, 1021



Helmholtz, 1867


Hogy állunk V1-(simple cell-)modellekkel?

- Olshausen-Field modell
 - Gábor-szűrők
 - sparse eloszlás az együtthatók fölött
 - Independent Component Analysis
- GSM
 - folytonos keverék
 - kontrasztinvariancia
 - divisive normalisation

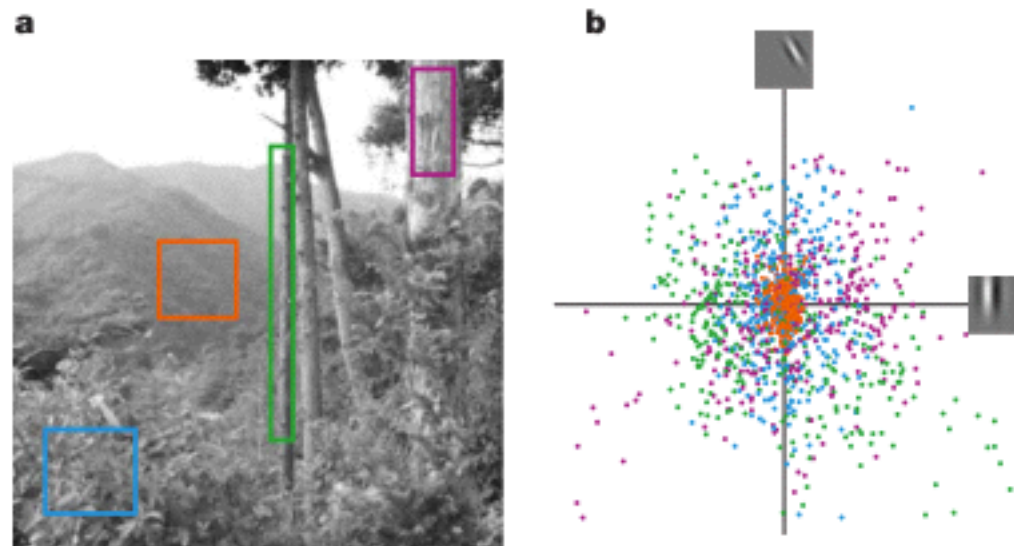


Mi van följebb?

- Freeman és tsai: textúrák V2-ben





- Karklin és Lewicki: a simple sejtek kovarianciája látensek kombinációjából épül fel (komplex sejtek)



- és még sokan mások


Machine learning megközelítések

- Adja magát a hierarchikus sztochasztikus neurális háló
 - Deep Boltzmann Machine, Deep Belief Network, Convolutional Neural Network
 - Vizuális objektumfelismerésben state of the art
 - Neurális aktivitást is prediktálnak
- Nincs “értelme” a modellnek
 - nehéz értelmezni, hogy mit is fejez ki egy változó





Top-down hatások

- Az objektumok (alakzatok) percepciója visszahat az alkotóelemek jelenlétének érzékelésére
- Gestalt-elvek
 - folytonosság időben és térben
- Illuzórikus kontúrok
 - élt látunk ott is, ahol a stimulusban nincs, de a kép értelme alapján van



Komponentenmodell



$$p(\mathbf{v} \mid \mathbf{g}) = \mathcal{N}(\mathbf{v}; 0, \sum_{j=1}^K g_j \mathbf{C}_j)$$

$$p(\mathbf{x} \mid \mathbf{v}, \mathbf{z}) = \mathcal{N}(\mathbf{x}; \mathbf{z} \mathbf{A} \mathbf{v}, \sigma_x \mathbf{I})$$

- Gestalts are learned from data as covariance components $\mathbf{C}_{1..K}$
- Coefficient variables of covariance components, \mathbf{g} , are generated from Gamma priors
- The global contrast variable, \mathbf{z} , is also generated from a Gamma prior
- Linear filter set \mathbf{A} transforms V1-level variables, \mathbf{v} to pixels, \mathbf{x} , adding independent observation noise

Minták a poszteriorból

- Gibbs sampling

$$p(v \mid x, g, z) = \mathcal{N} \left(v; \frac{z}{\sigma_x} C_{v|x,g,z} A^T x, C_{v|x,g,z} \right), \quad C_{v|x,g,z} = \left(\frac{z^2}{\sigma_x} A^T A + \left(\sum_{j=1}^K g_j C_j \right)^{-1} \right)^{-1}$$

- Conditional \mathbf{g} and \mathbf{z} activations can be sampled by MCMC schemes

$$\log p(g \mid x, v, z) \sim -\frac{1}{2} \left[\log \left(\det \left(\sum_{k=1}^K g_k C_k \right) \right) + v^T \left(\sum_{k=1}^K g_k C_k \right)^{-1} v \right] + \log p(g)$$

$$\log p(z \mid x, v, g) \sim -\frac{1}{2} \left[D_x \log(\sigma_x) + \frac{1}{\sigma_x} (x - zAv)^T (x - zAv) \right] + \log p(z)$$

A paraméterek tanulása

- Iterative stochastic generalised expectation maximisation
- Collecting L samples with Gibbs sampling as E-step
- Reparametrise with Cholesky components to ensure validity of covariance matrices

$$C_v = \sum_{k=1}^K g_k U_k^T U_k$$

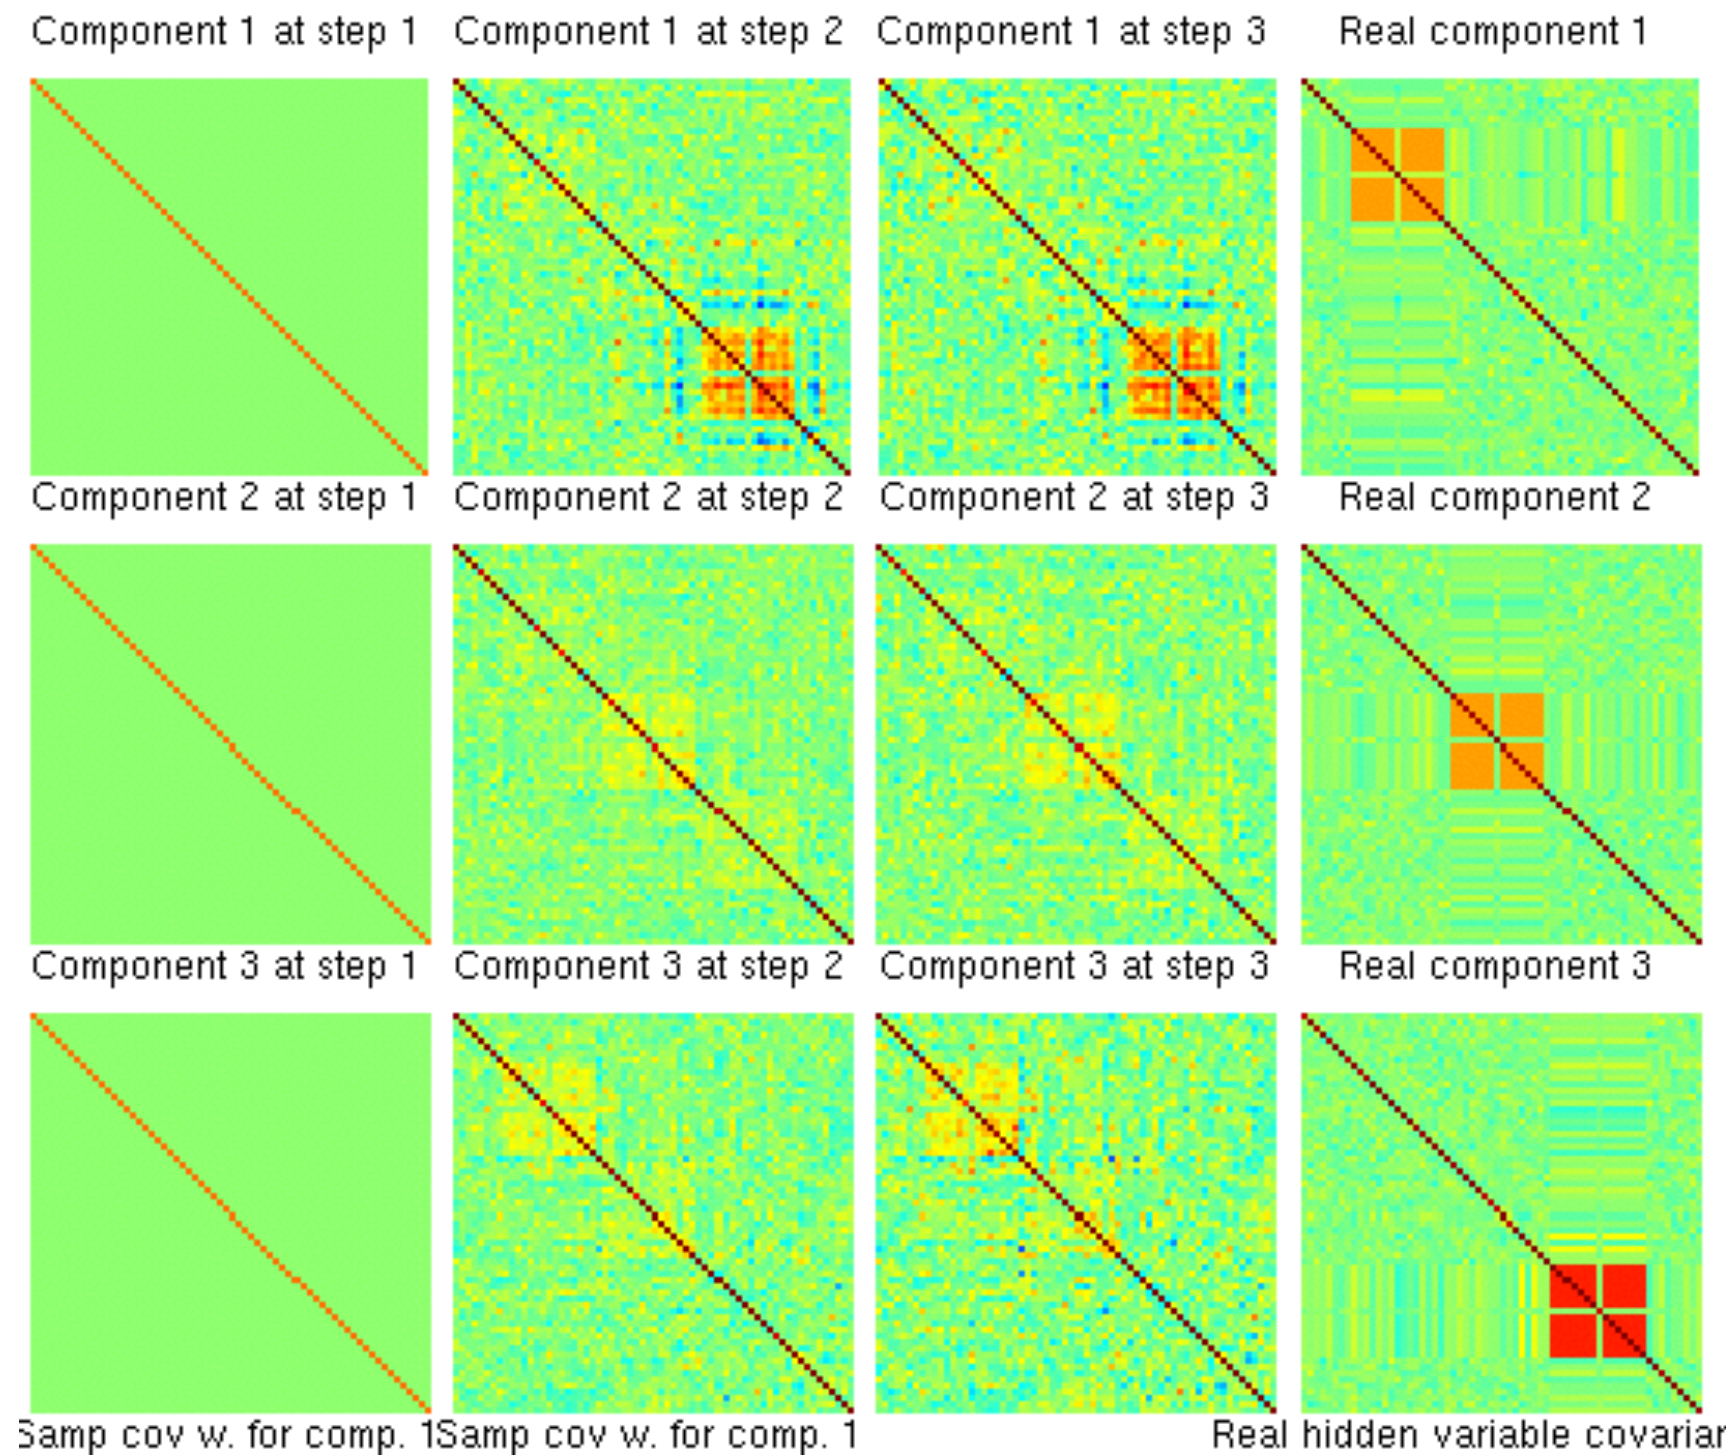
- Gradient of the complete-data log-likelihood over N observations

$$\frac{\partial \mathcal{L}}{\partial [U_k]_{i,j}} = \sum_{l=1}^{NL} \text{Tr} \left[\frac{\partial \log p(x^l, v^l, g^l \mid U_{1\dots K})}{\partial C_v^l} \frac{\partial C_v^l}{\partial [U_k]_{i,j}} \right]$$

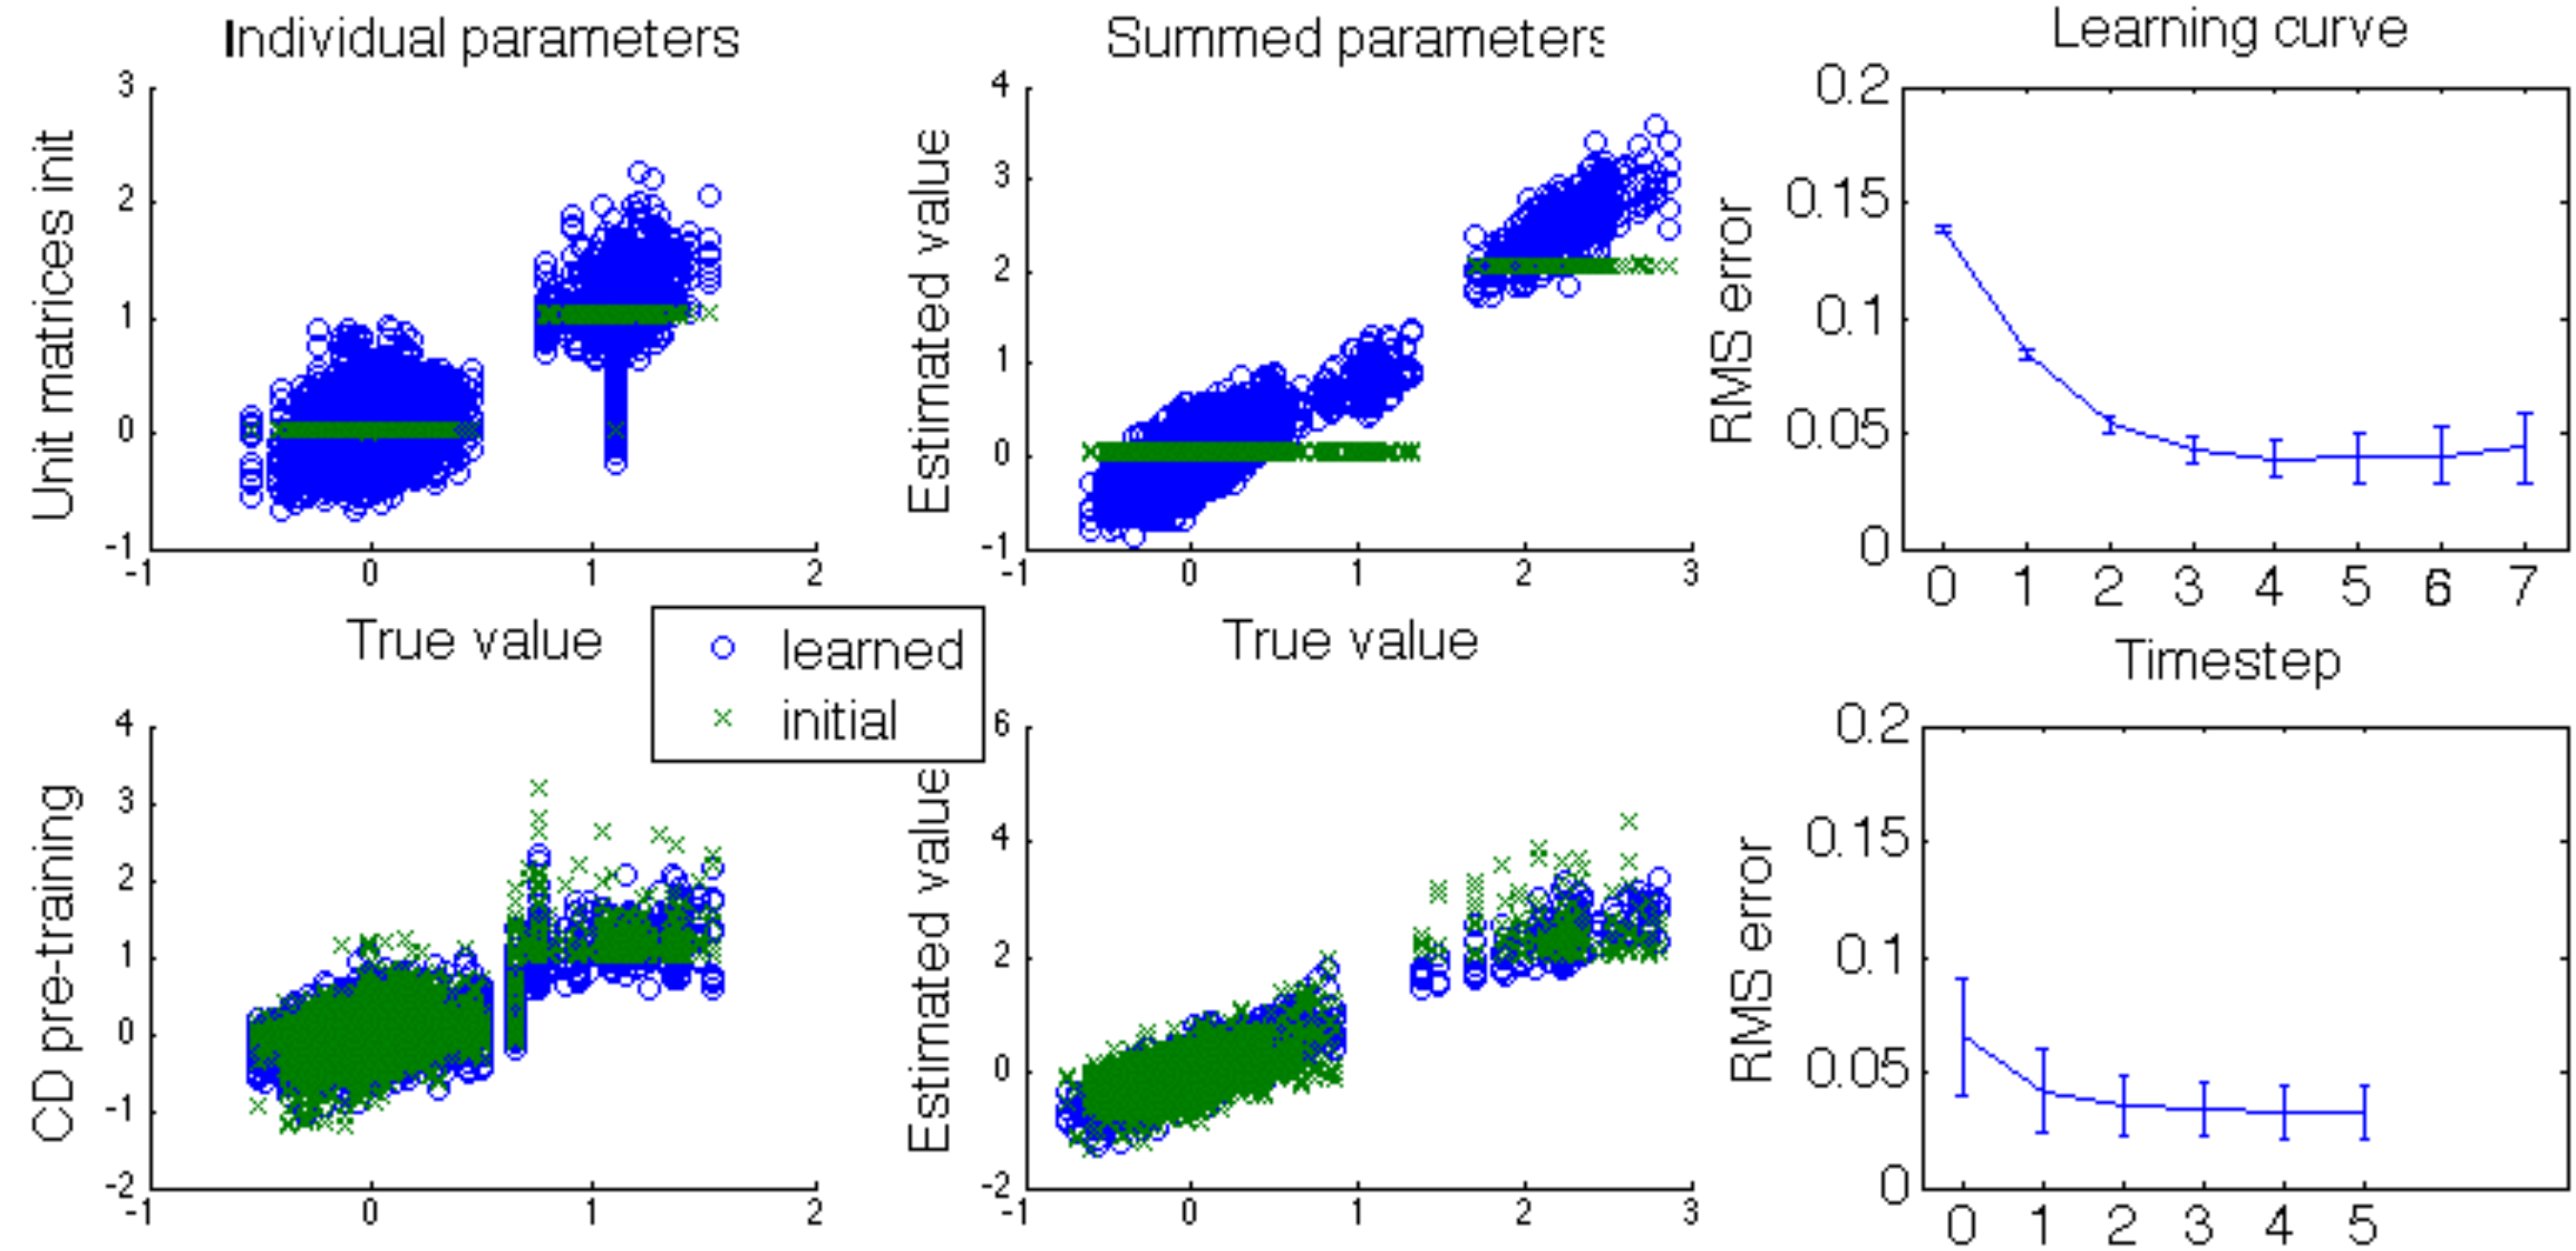
- Gradient descent as generalised M-step

$$[U_k]_{i,j}^{new} = [U_k]_{i,j}^{old} + \epsilon \frac{\partial \mathcal{L}}{\partial [U_k]_{i,j}}$$

Tanulás szintetikus adatokon - példa





Tanulás szintetikus adatokon




Jobb kiindulóállapot keresése

- Közelítő modell
 - restricted boltzmann machine a rejtett rétegekből
 - contrastive divergence tanulás
 - kovarianciakomponensek a tanult súlyokból
 - sokkal gyorsabb



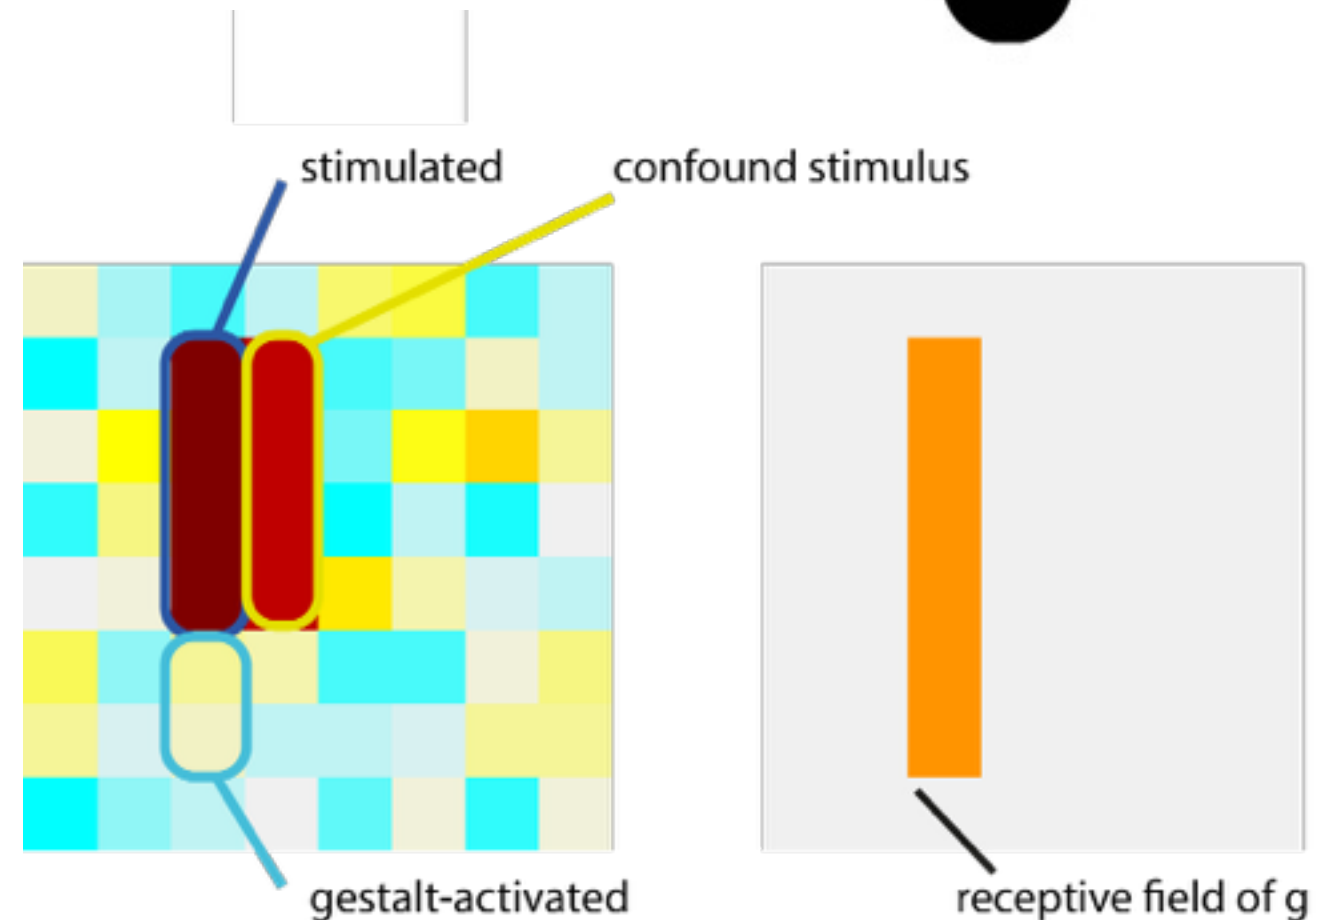
A modell tesztelése illuzórikus kontúrokkal

- Stimuláljuk egy kovarianciakomponens receptív mezejének egy részét
- A nem közvetlenül aktivált, de ahhoz egy komponensen keresztül kapcsolódó rész felel meg az illuzórikus kontúrnak





Stimulus

- To compare model responses to experimental results with IC a test stimulus is constructed
- Left: mean stimulus in the \mathbf{v} space
- Right: receptive field of one of the covariance components in the \mathbf{v} space

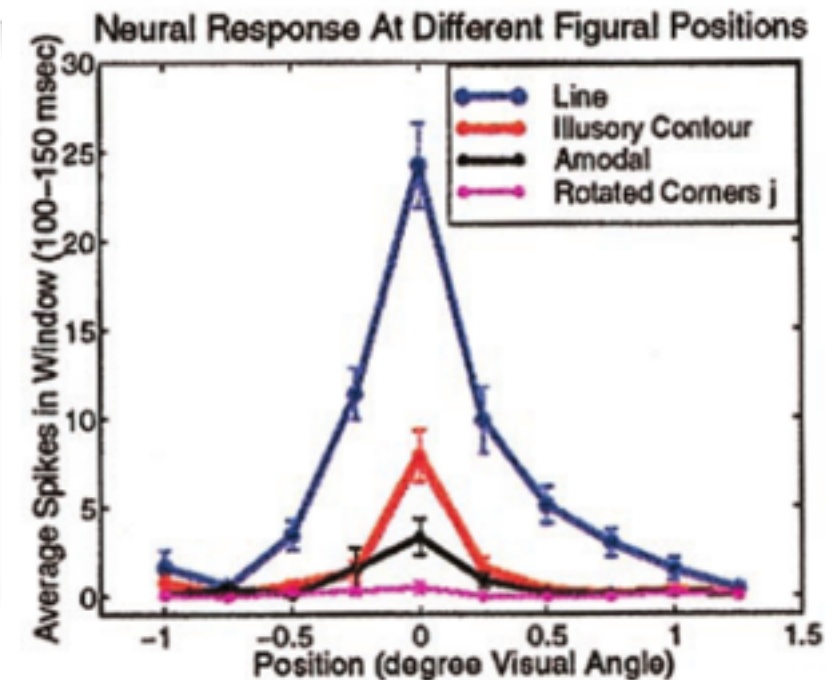



Tüzelési ráták

- Alternating sampling from \mathbf{v} and \mathbf{g} conditioned on the observation, starting with \mathbf{v}
- Non-stimulus-evoked activity in \mathbf{v} follows the activation of higher-level areas

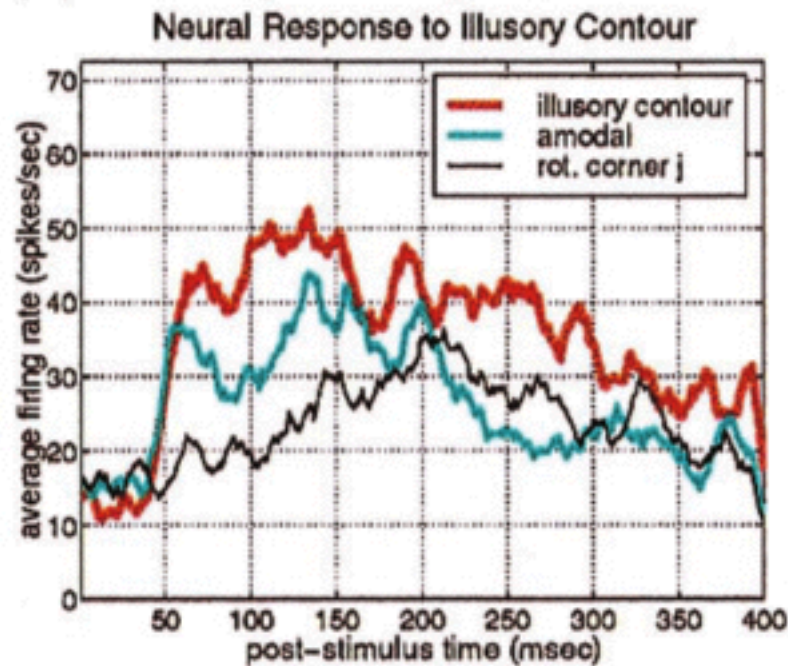


- The model reproduces the magnitude ratio of response rates to real contours, ICs and background
- Mean spike count in V1 as a response to different stimuli in receptive field from **Lee & Nguyen, PNAS, 2001.**

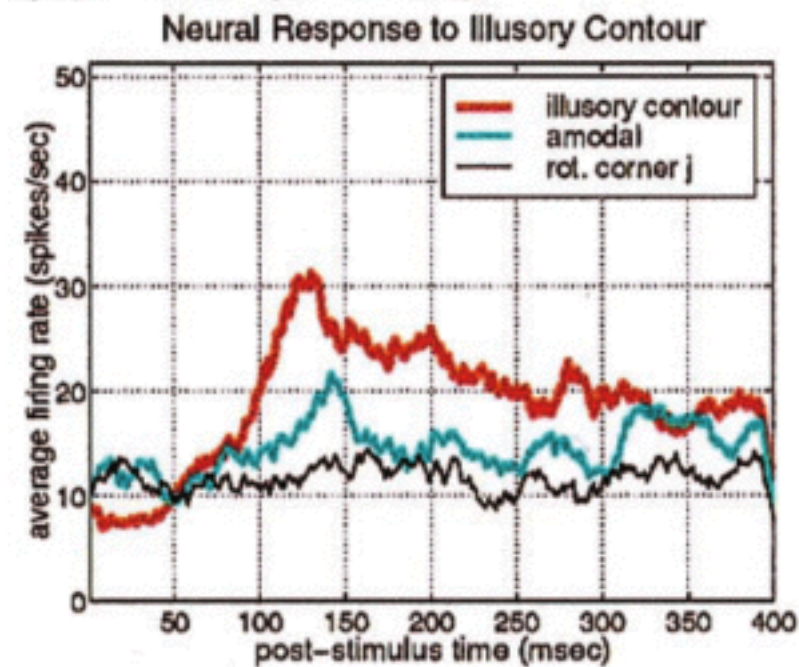


Aktiváció sorrendje

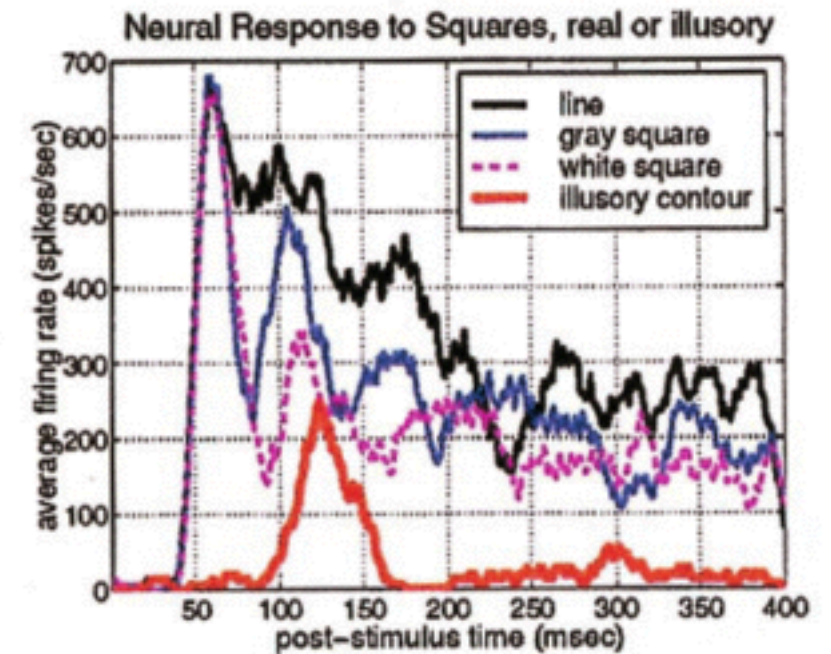
(c). V2S (n = 39)




(a). V1S (n = 49)



(d)




- Lee & Nguyen (2001) report that the response to ICs arrives with an additional latency of 55 ms compared to real contours
- In the model, rates of Gestalt-activated v units increase 2-3 Gibbs steps later
- Membrane potential autocorrelation typically diminishes after 20 ms, taking this as the duration of a sampling step, the model predicts 40-60 ms latency





Variância

- Within-trial variance of stimulated and Gestalt-activated v units decrease in the model as the g activation of the covariance component that has them in its receptive field increases



- **Haider et al. Neuron, 2010.**

report that the spike train reliability of V1 cells increase with non-classical RF activation when added to classical RF stimuli.





Következő lépések

- Mintavételezés sok komponenssel
- Tanítás természetes képeken
- Összevetés további adatokkal

Predicted correlations

- The model predicts that noise correlations increase with g activations
- Correlations appear between only congruently activated cells too



Összefoglalás

- A vizuális reprezentáció felsőbb szintjeiről nagyon keveset tudunk
- A komponensmodell a Gestalt-elveket formalizálja generatív probabilisztikus modellben
- Inferencia megvalósítható Gibbs sampling segítségével
- A komponensek adatból tanulása lehetséges EM-mel
- Illuzórikus kontúrokra adott átlagos válaszok tulajdonságai reprodukálhatók
- Válaszvariabilitás egyes tulajdonságai reprodukálhatók