

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

Unsupervised learning

Input: x_1, x_2, \dots, x_t összefoglaló néven: adat -
vizuális, auditoros, szöveg

Gól: $P(\mathbf{x})$

(Reinforcement learning:

Input: $\{x_1, y_1\}, \{x_2, y_2\}, \dots, \{x_t, y_t\}$


Gól: $P(\mathbf{x} | \mathbf{y})$

$P(\mathbf{x})$ Bonyolult!

Miért is?

Egyszerűsítés: $P(\mathbf{x}) = P(\mathbf{x} | \mathbf{z}) P(\mathbf{z})$

- az adatot a “z”-k terében reprezentáljuk
- kategorizáció, dimenzió redukció
- általánosabban a feladat: predikció, döntéshozatal, kommunikáció




Lineáris modellek

$$P(x | z) = \text{Normal}(x; z, \theta) = C \exp \left((x - Az)^T \Sigma^{-1} (x - Az) \right)$$


$$x = A \cdot z + \epsilon$$

PCA


- A oszlopvektorai ortogonálisak
- $D(x) = D(z)$
- Izotróp zaj



State space of two pixel images




Random images



Structured images

PCA tulajdonságok

- Kompakt kódot eredményez
- Egy adatponért leírásáért általában a teljes hálózat felel



Sparse kódolás, ICA

$$x = \mathbf{A} \cdot \mathbf{z} + \epsilon$$

- “z”-k függetlenek
- y priorja “ritka” ($P(\mathbf{z})$)

Komputációs kritériumok:

- Hiteles rekonstrukció
költség egy adatpontra (képre):

$$\text{cost}_1 = \left(x - \sum_i A'_i \cdot z_i \right)^2$$

- Kis “energiafelhasználás (kevés szimultán aktív neuron)
további költség a kód “ritkasága”:

$$\text{cost}_2 = - \sum_i S \left(\frac{z_i}{\sigma} \right)$$

S a Gauss-nál nagyobb kurtózissal bíró eloszlás

- teljes költség (~energia):

$$E = -\text{cost}_1 - \lambda \text{cost}_2$$

Sparse kód tanulása: E-M

Algoritmus:

- Itéráció EM lépésekkel
- Random kezdeti feltételek
- Adott konnektivitási mátrixnál az aktivítások segítségével a költség minimalizálása
- Adott aktivitásokkal a költség minimalizálása a súlyok adaptálásával

Adott konnektivitási mátrix esetén a legjobb aktivítások megtalálása:


$$\dot{z}_i = \mathbf{A}_i x_t - \sum_j \mathbf{A}'_i \mathbf{A}_j z_j - \frac{\lambda}{\sigma} S' \left(\frac{z_i}{\sigma} \right)$$

Adott konnektivitási aktivációk esetén a legjobb súlyok megtalálása:

$$\Delta A_i = \eta \langle a_i [x - \hat{x}] \rangle_t$$

Sparse kódolás: eredmény

tréningezés természetes képekkel



Olshausen & Field '96


A kialakult bázis:

- irányított
- térbeli sávszűrést valósít meg
- lokalizált

Tanulás és stimulus statisztika


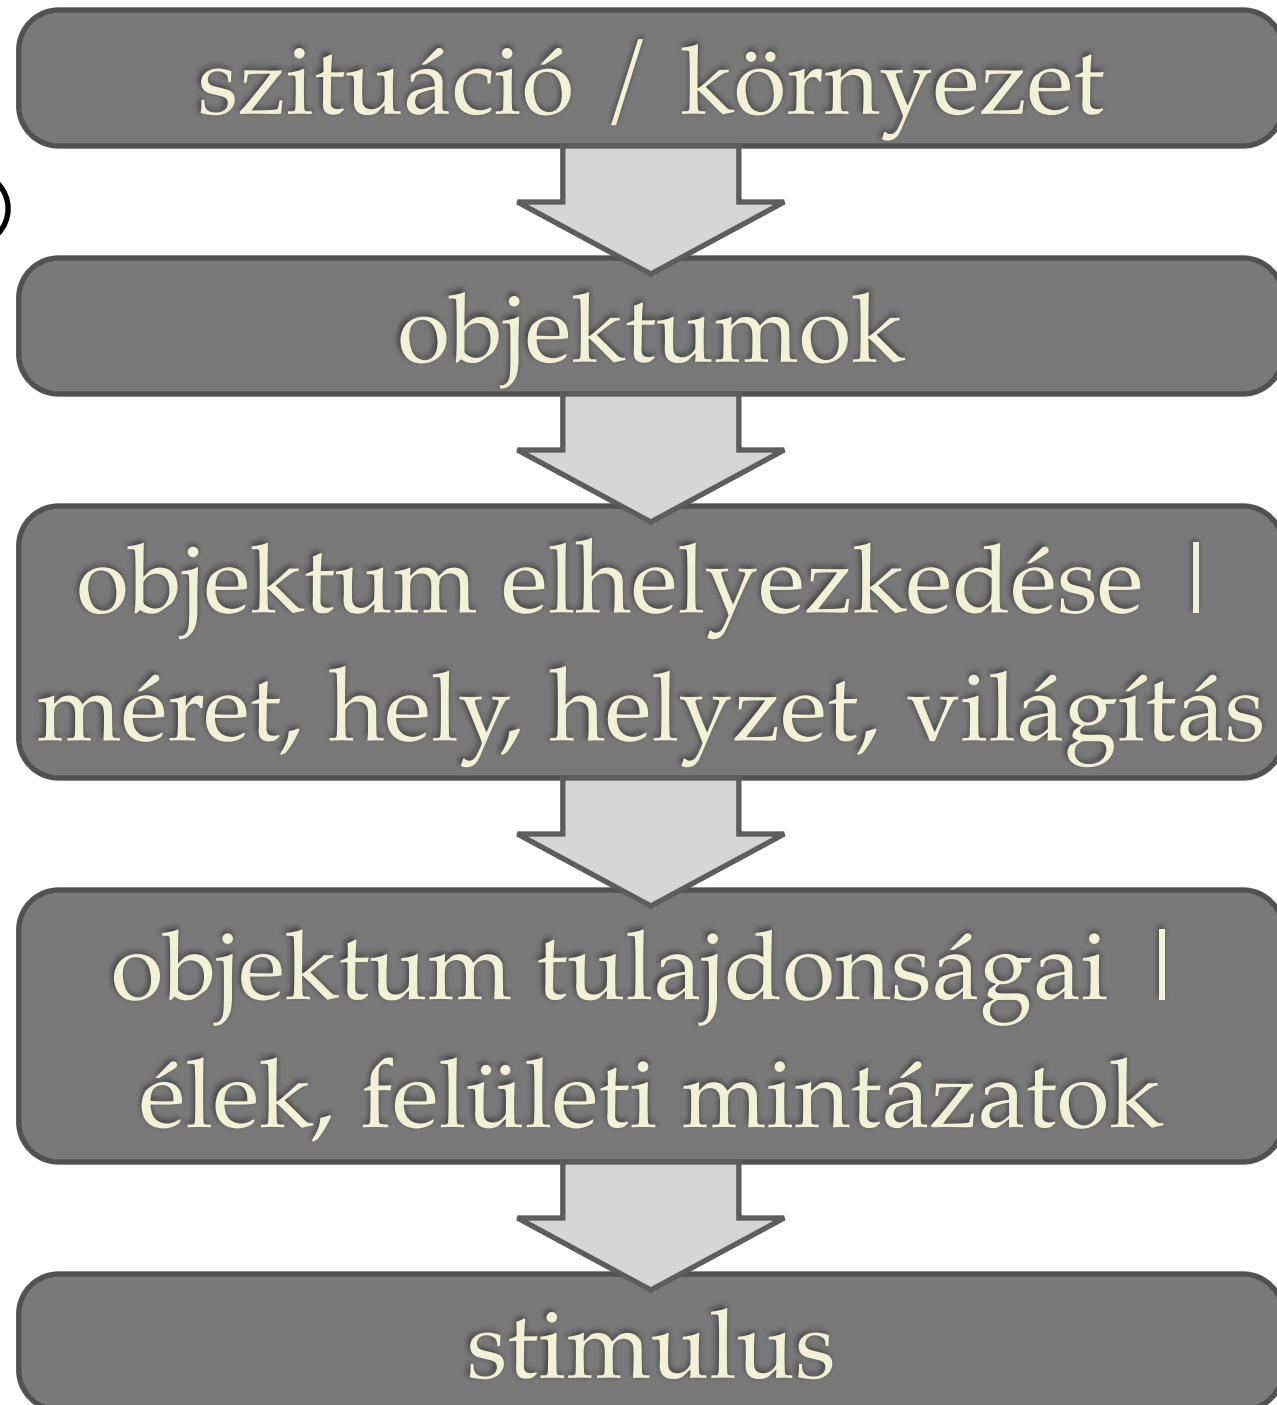

c

Sparse gabors

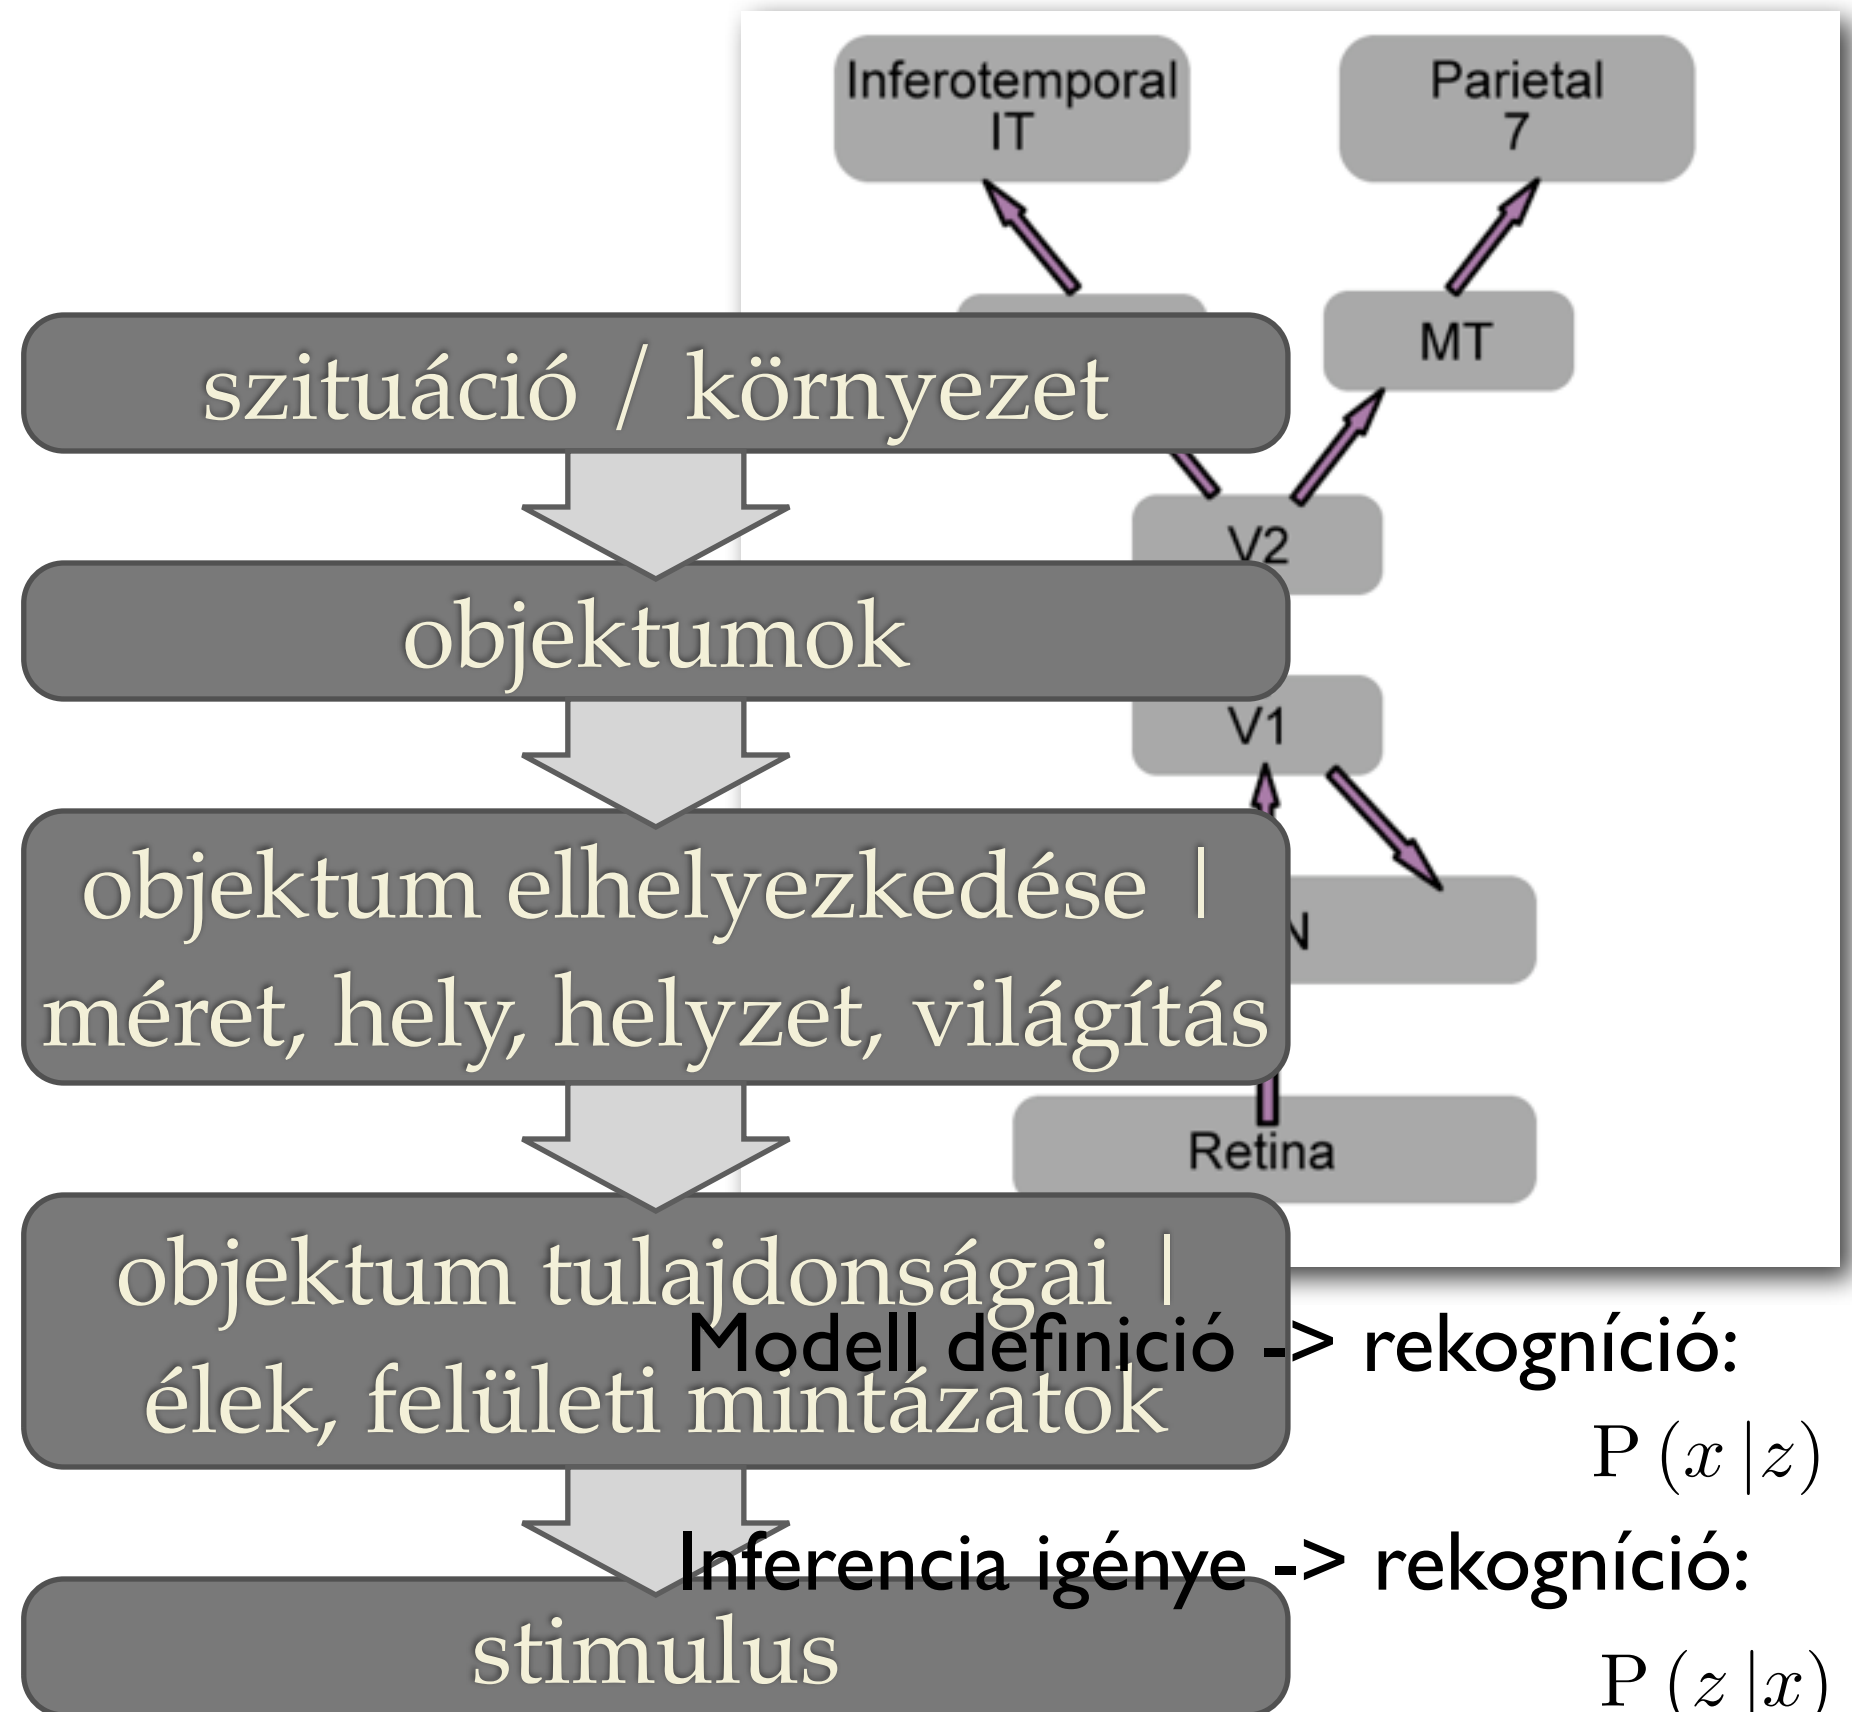


Generatív/rekogníciós modell


$$P(\mathbf{x}) = P(\mathbf{x} | \mathbf{z}) P(\mathbf{z})$$



Generatív/rekogníciós modell




Independens komponensek




a




Baboon



Flowers




White noise



Schwartz & Simoncelli, 2001

Gaussian Scale Mixtures




$$P(\mathbf{x}|\mathbf{y}) = \mathcal{N}(\mathbf{x}; \mathbf{A}\mathbf{y}, \sigma_x^2 \mathbf{I})$$

$$\mathbf{y} = z \mathbf{u}$$

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

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



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

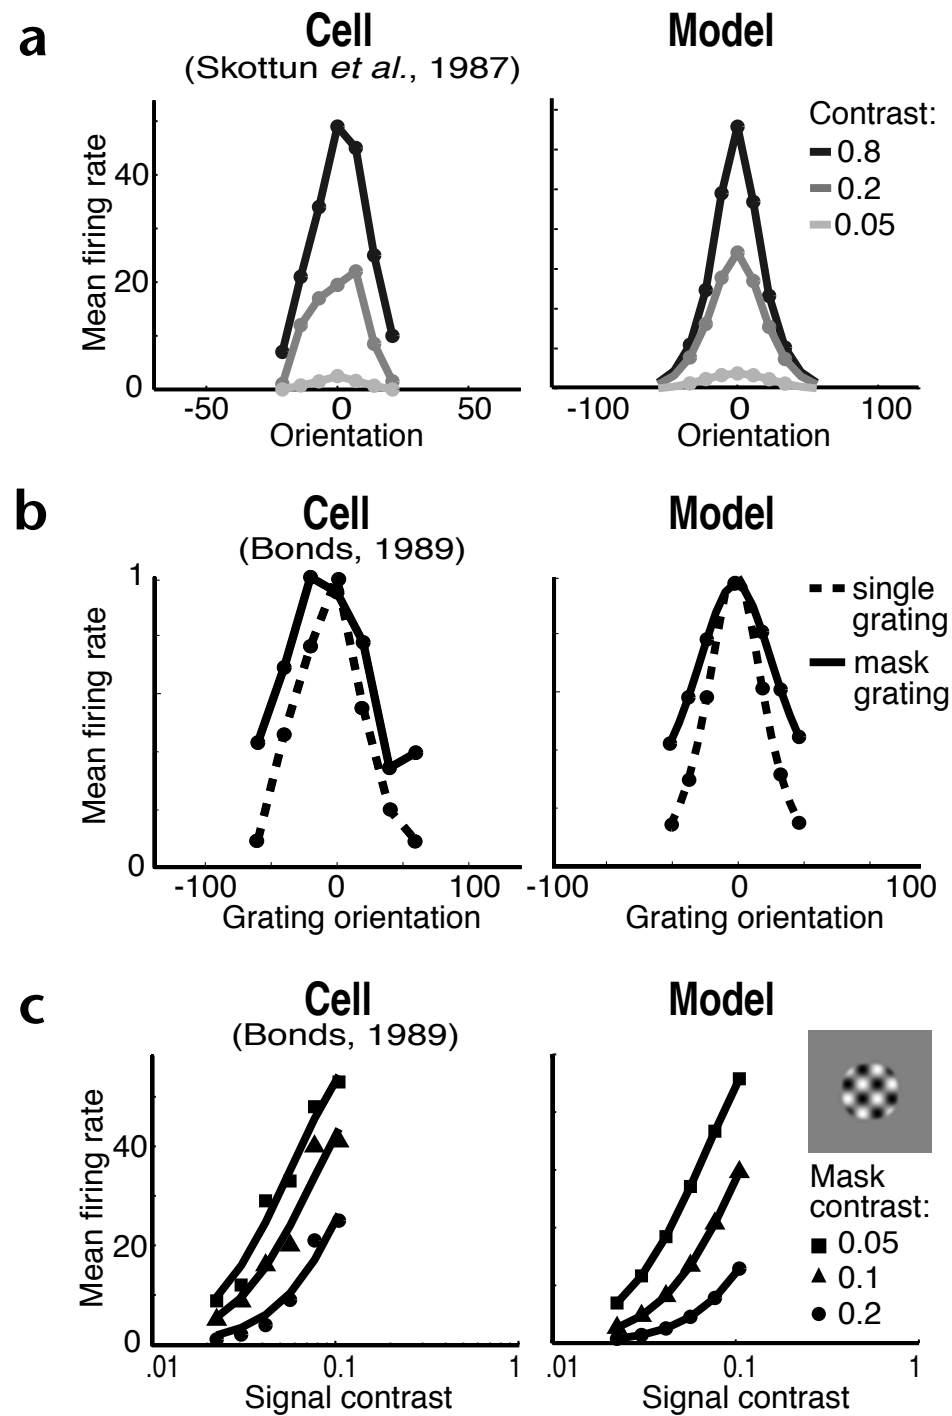
$$\text{var}(L_1|L_2) = wL_2^2 + \sigma^2$$

$$R_1 = \frac{L_1^2}{wL_2^2 + \sigma^2}$$

$$\text{var}(L_i|\{L_j, j \in N_i\}) = \sum w_{ji} L_j^2 + \sigma^2$$

$$R_i = \frac{L_i^2}{\sum_j w_{ji} L_j^2 + \sigma^2}$$

Neurális adatok és GSM



Schwartz & Simoncelli, 2001

