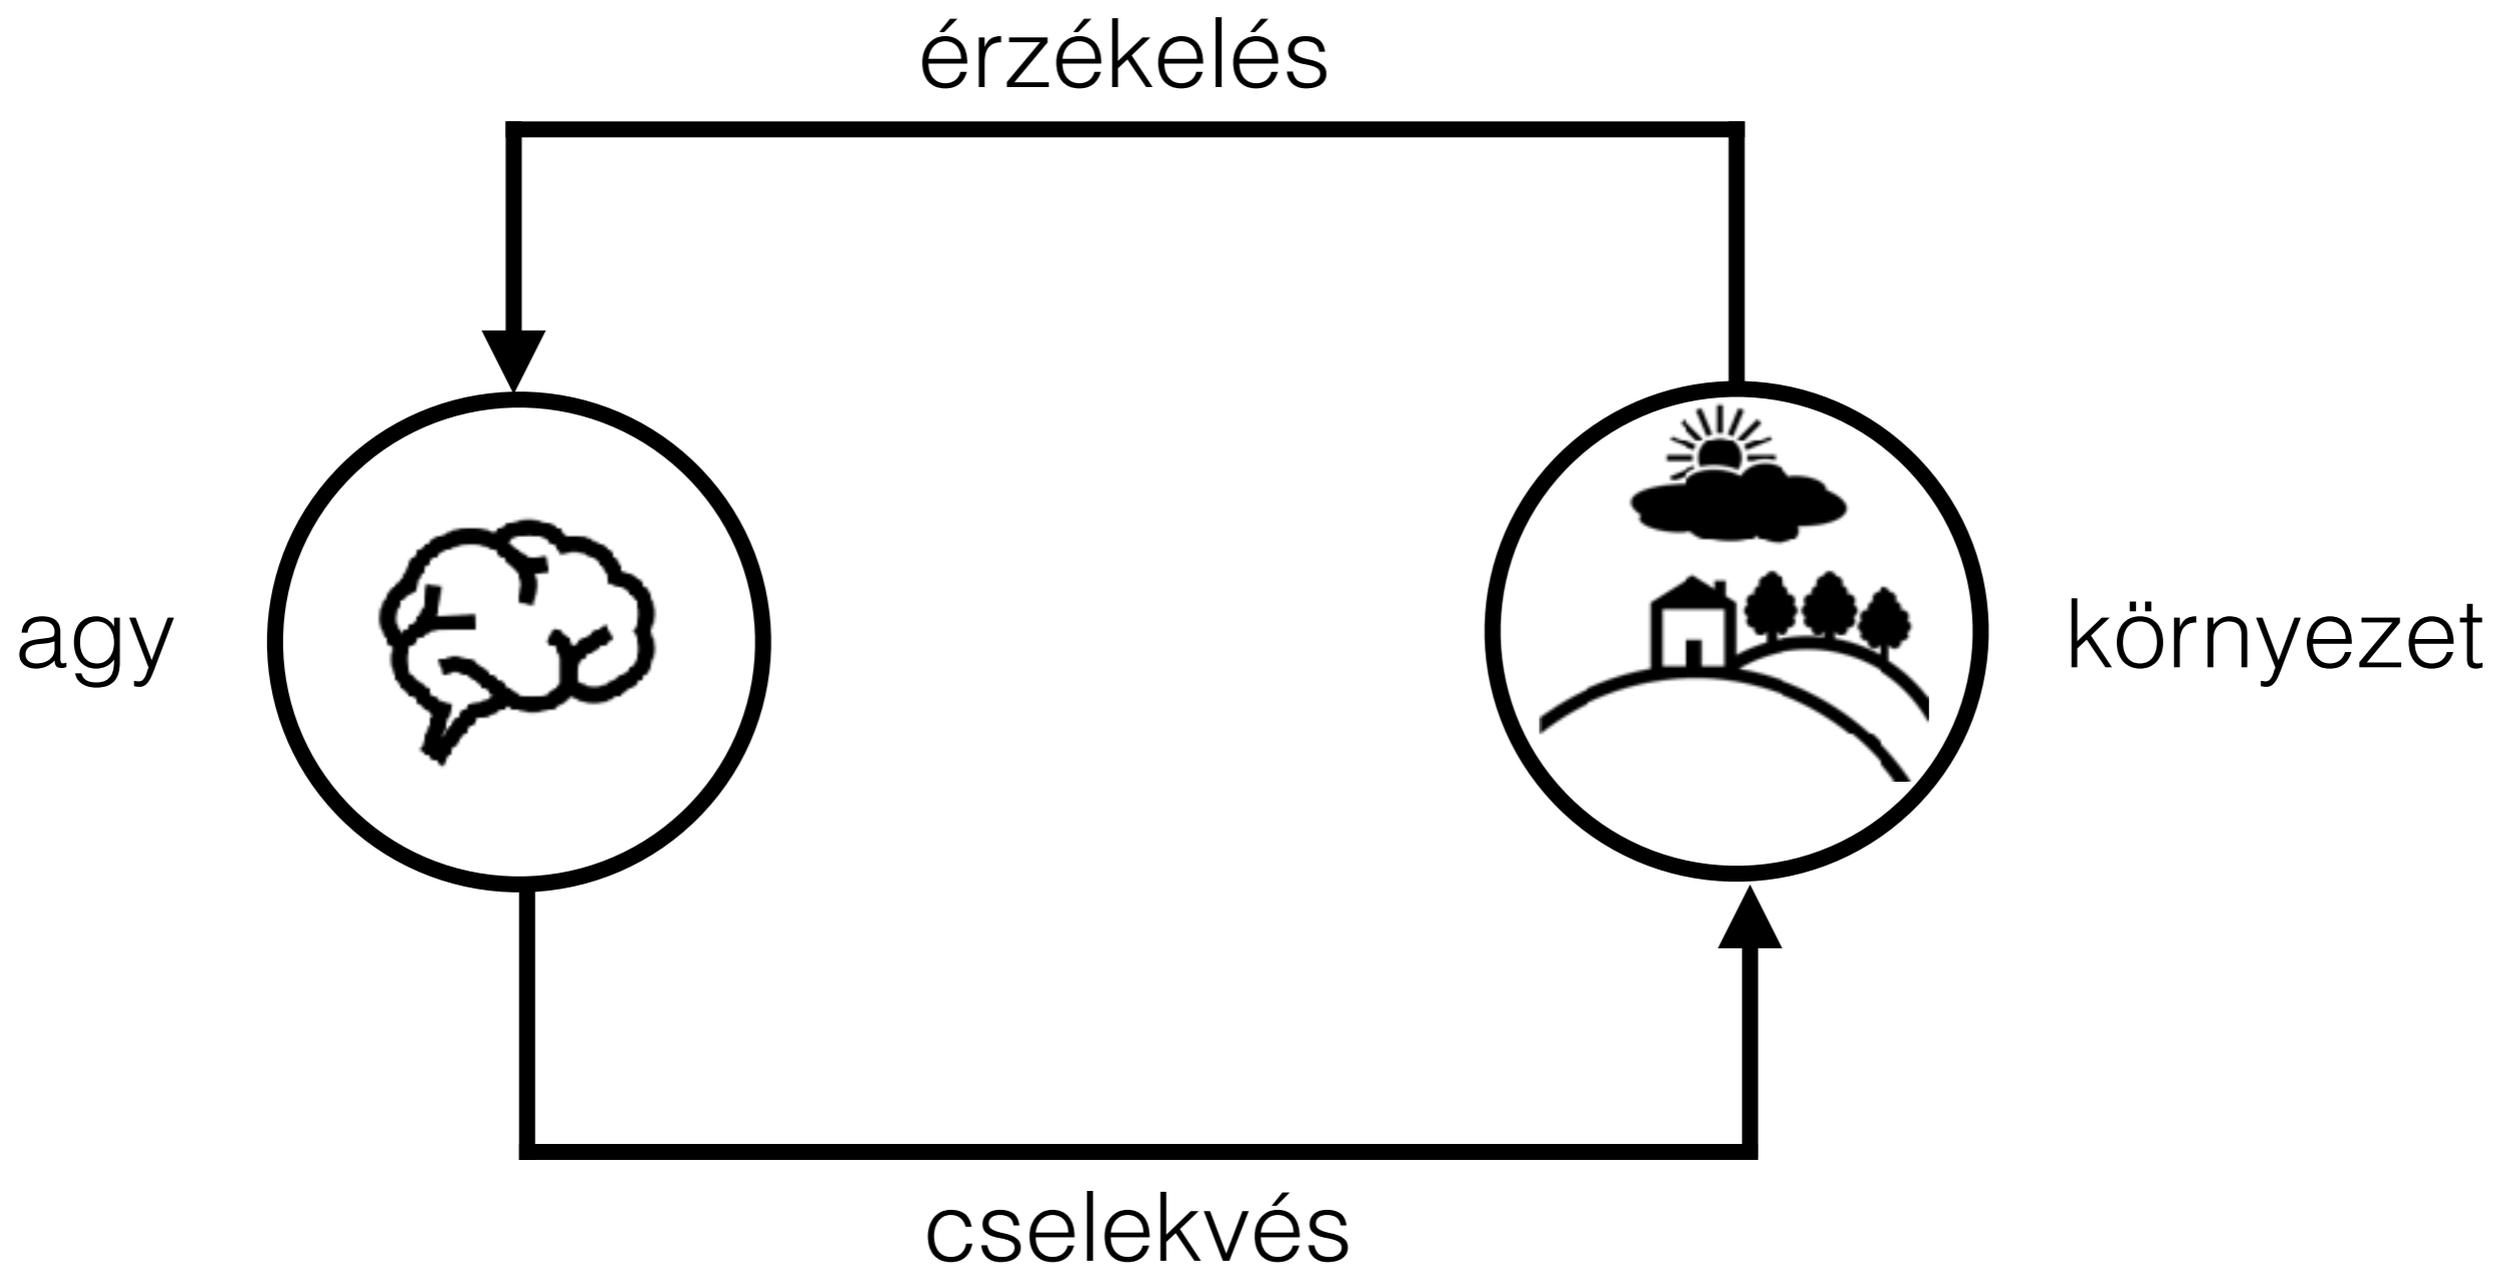


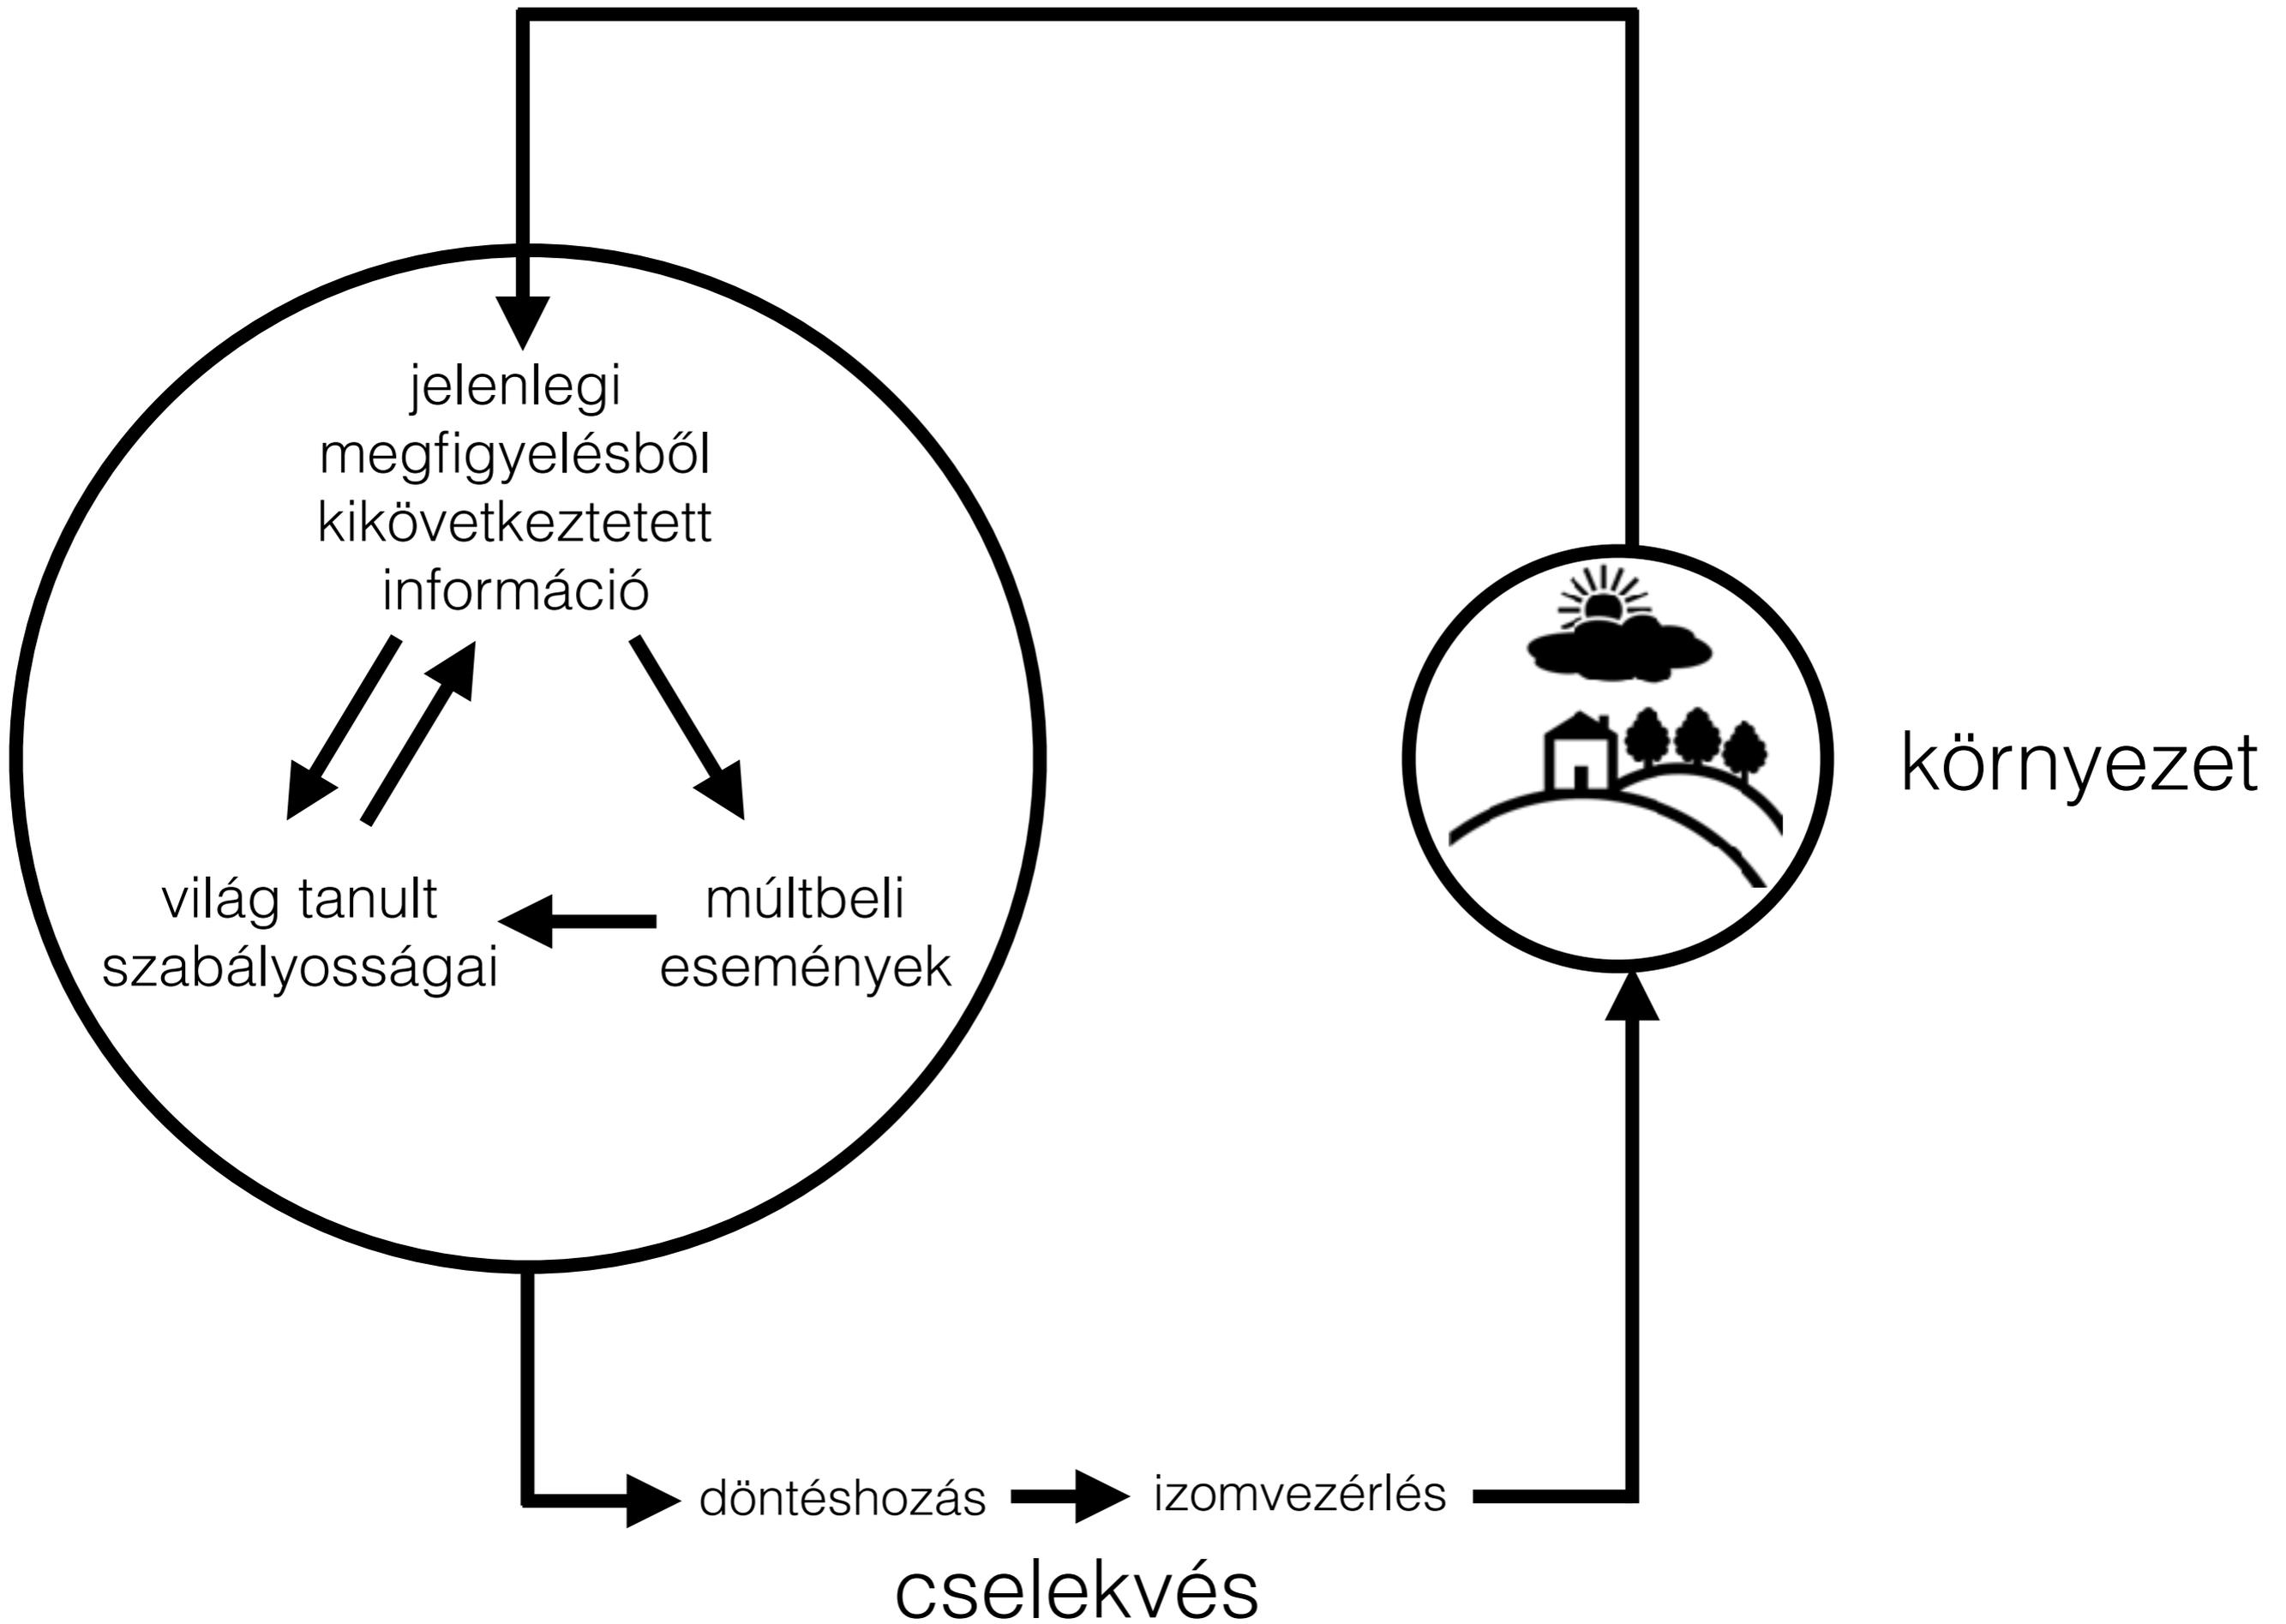
Statisztikus tanulás az idegrendszerben

ORBÁN GERGŐ

golab.wigner.mta.hu



érzékelés



érzékelés

**percepció
(észlelés)**

jelenlegi
megfigyelésből
kikövetkeztetett
információ

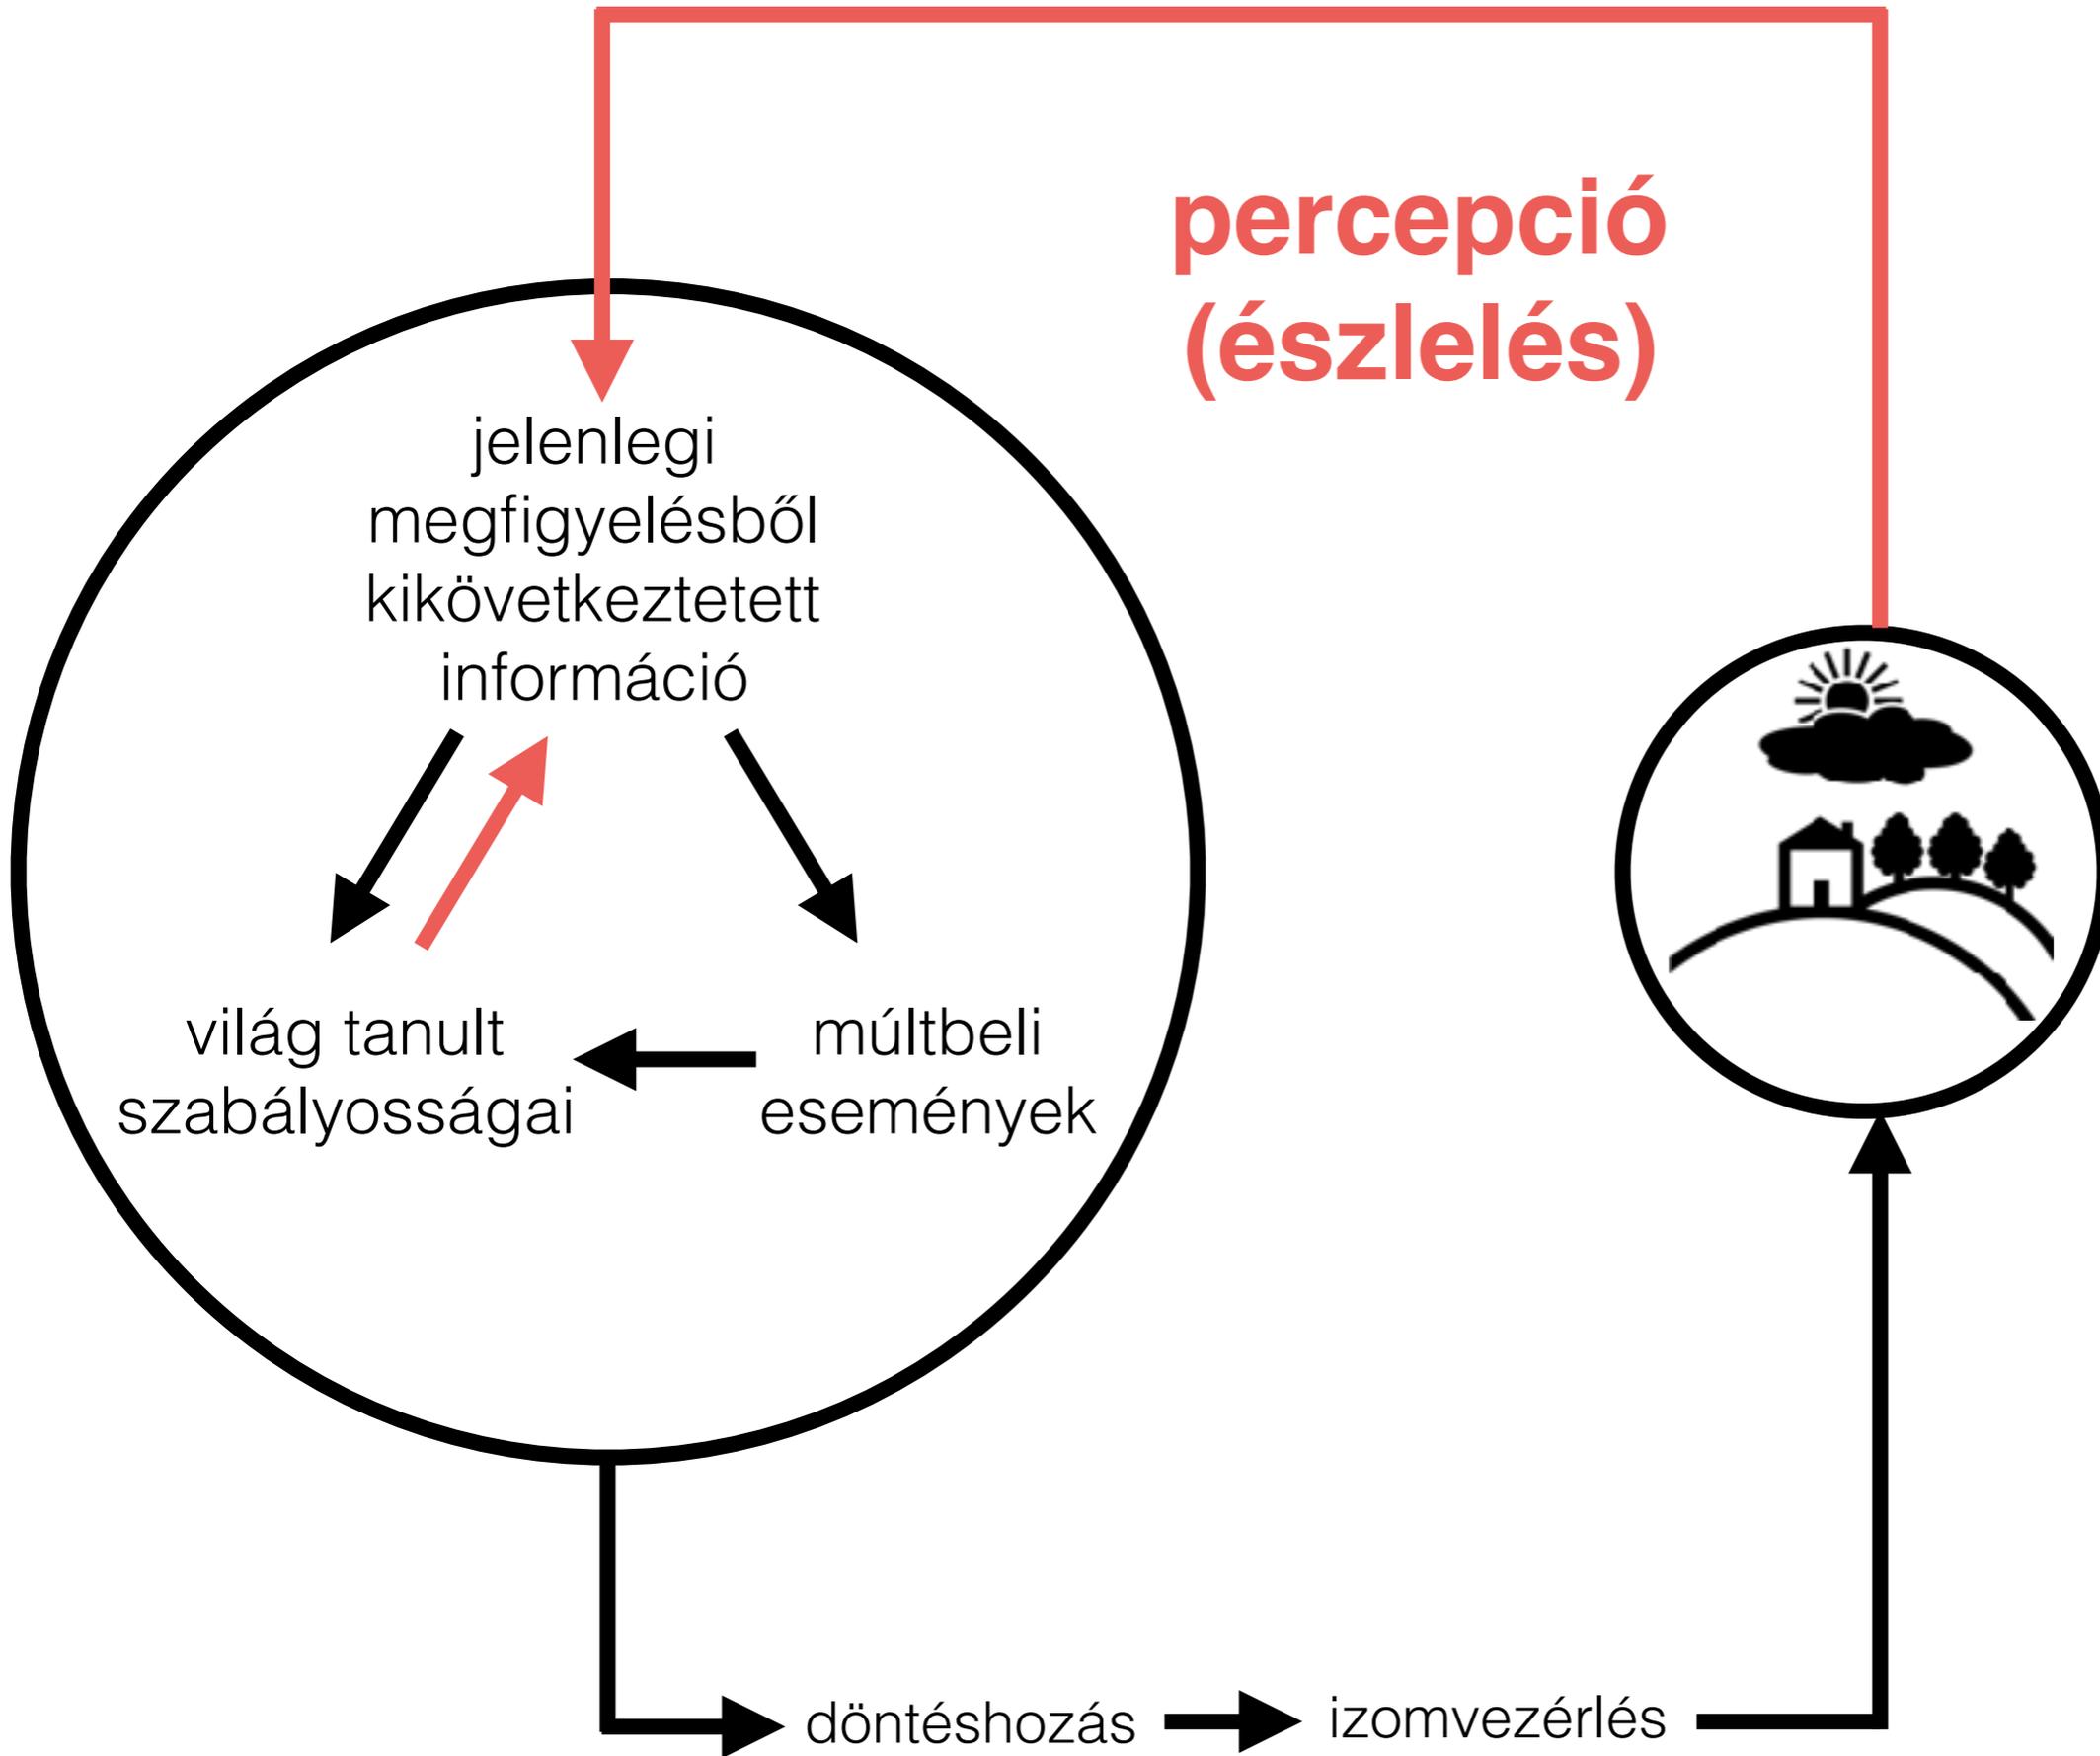
világ tanult
szabályosságai

múltbeli
események

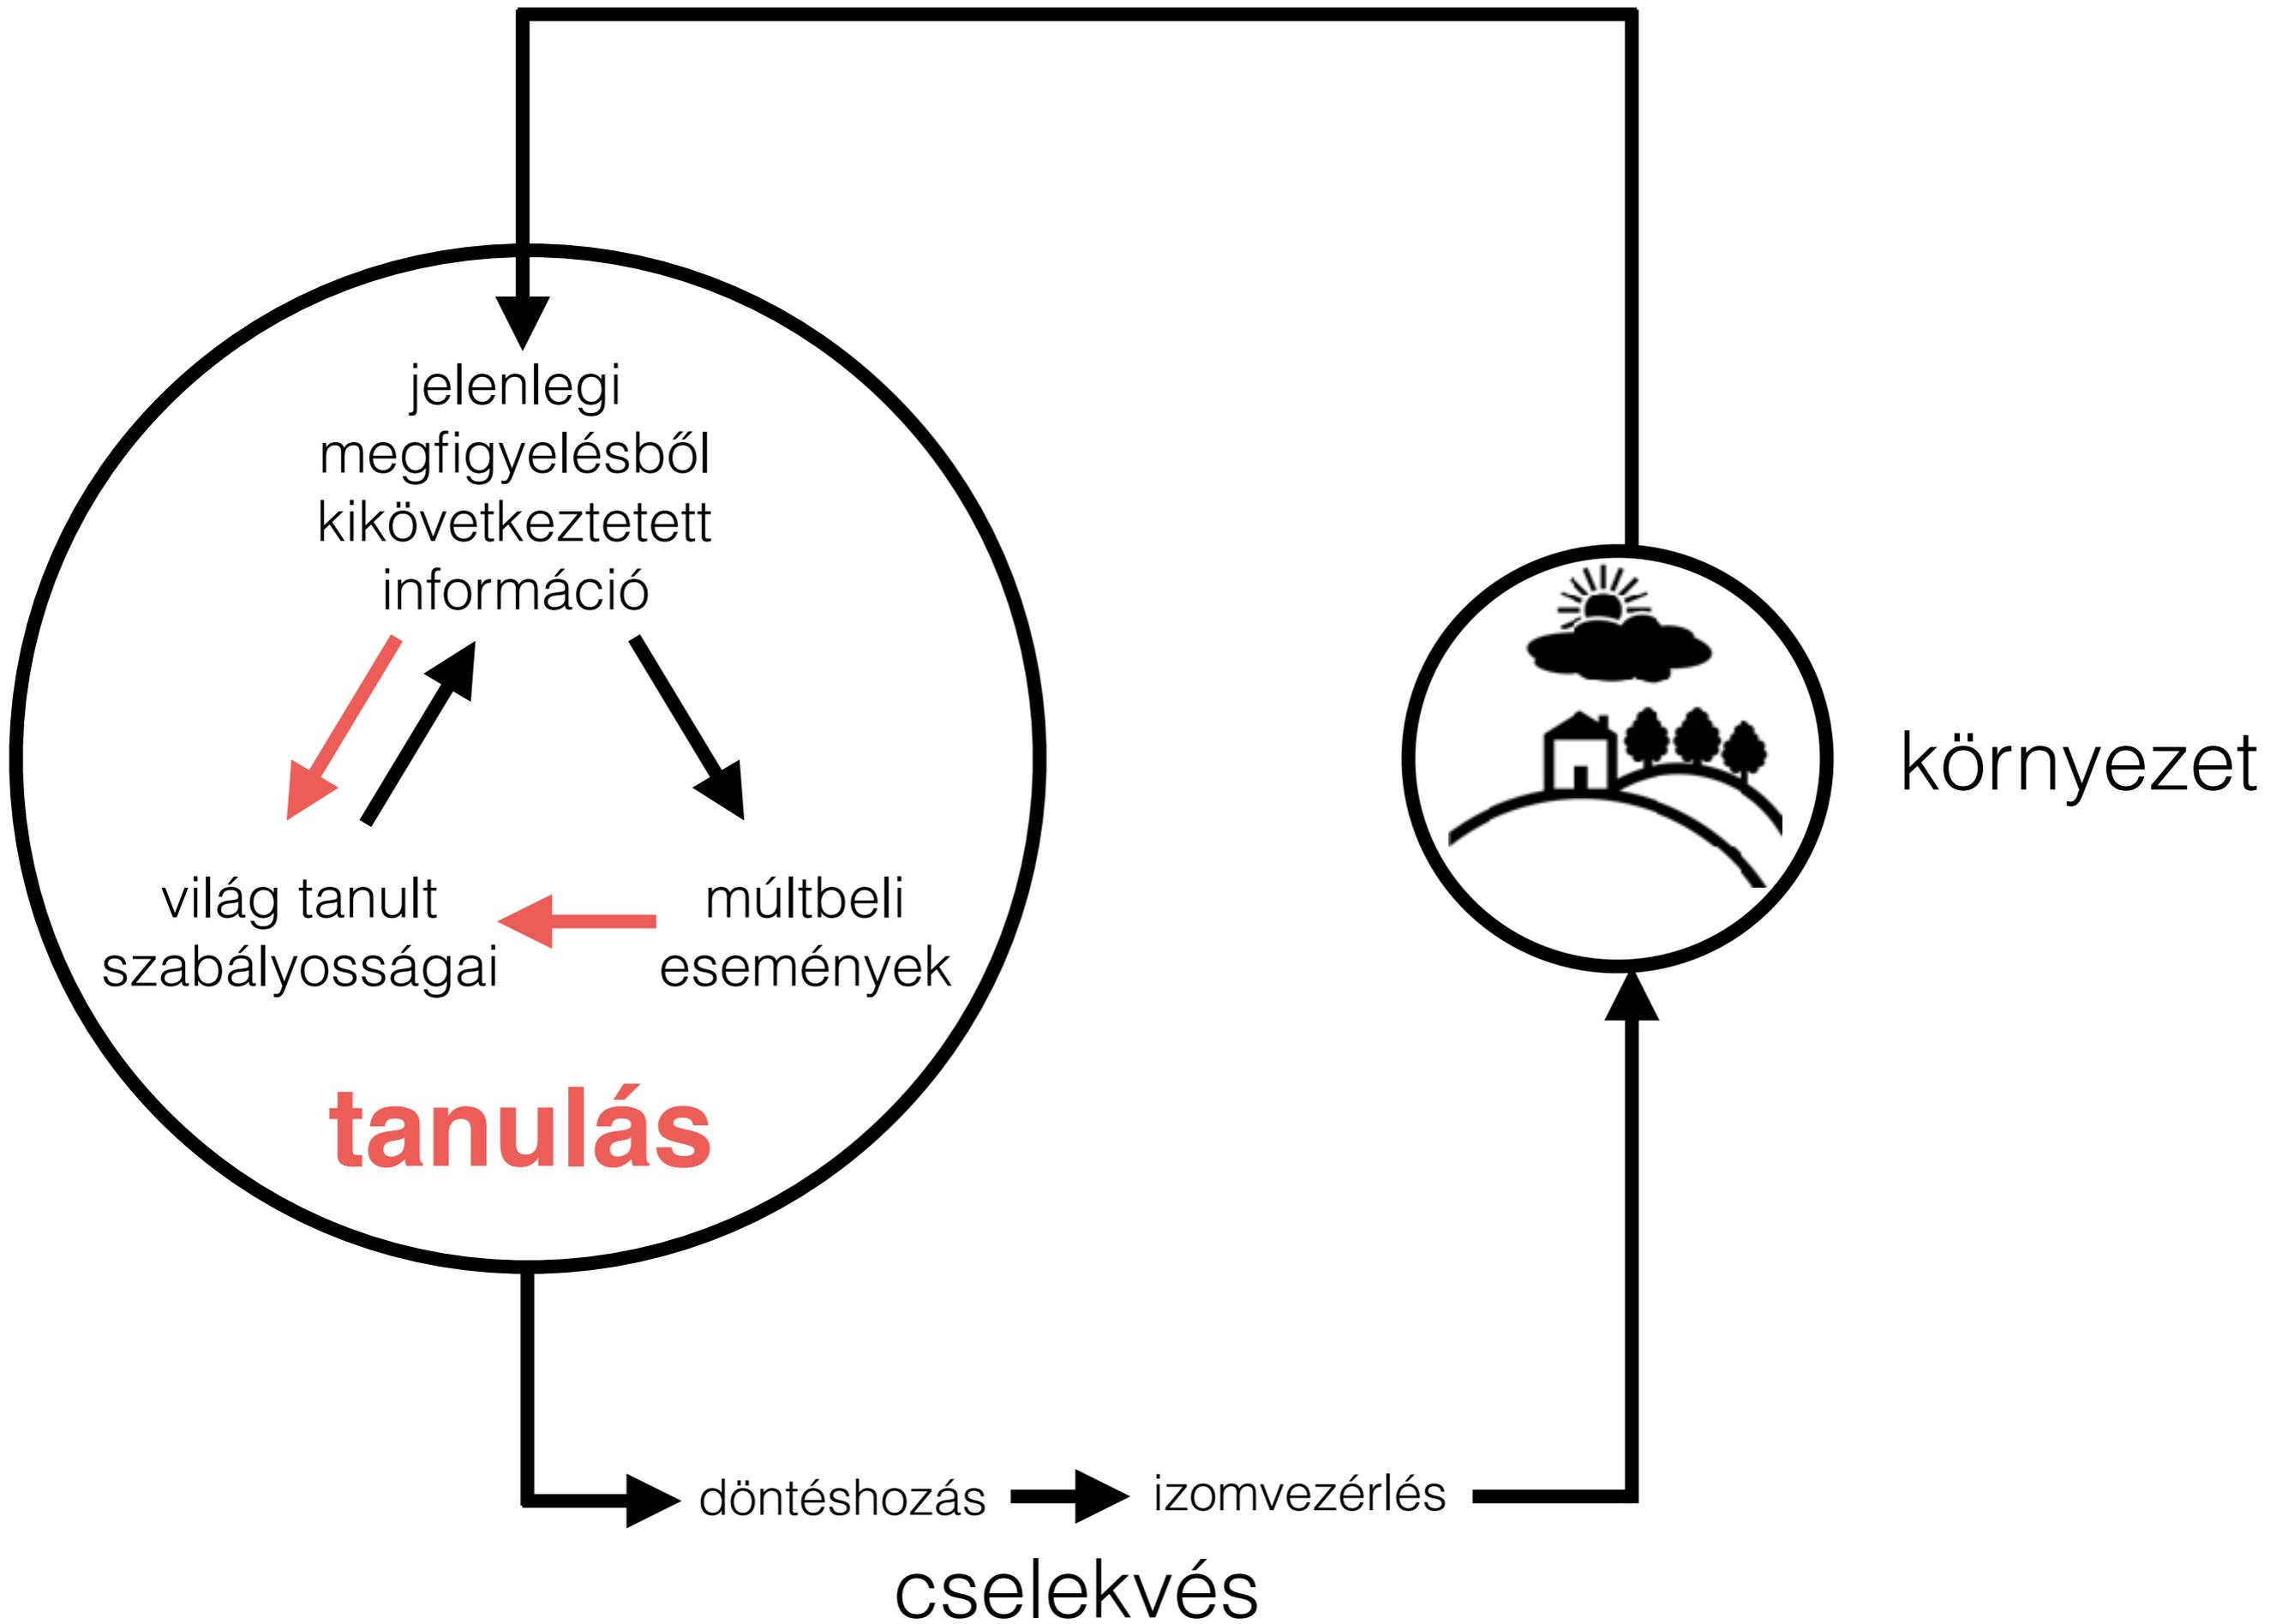
környezet

döntéshozás → izomvezérlés

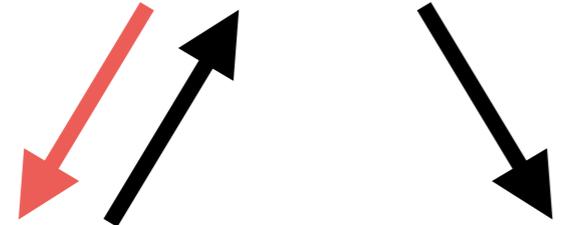
cselekvés



érzékelés



jelenlegi
megfigyelésből
kikövetkeztetett
információ



világ tanult
szabályosságai

múltbeli
események

tanulás

döntéshozás → izomvezérlés

cselekvés



környezet

érzékelés

jelenlegi
megfigyelésből
kikövetkeztetett
információ

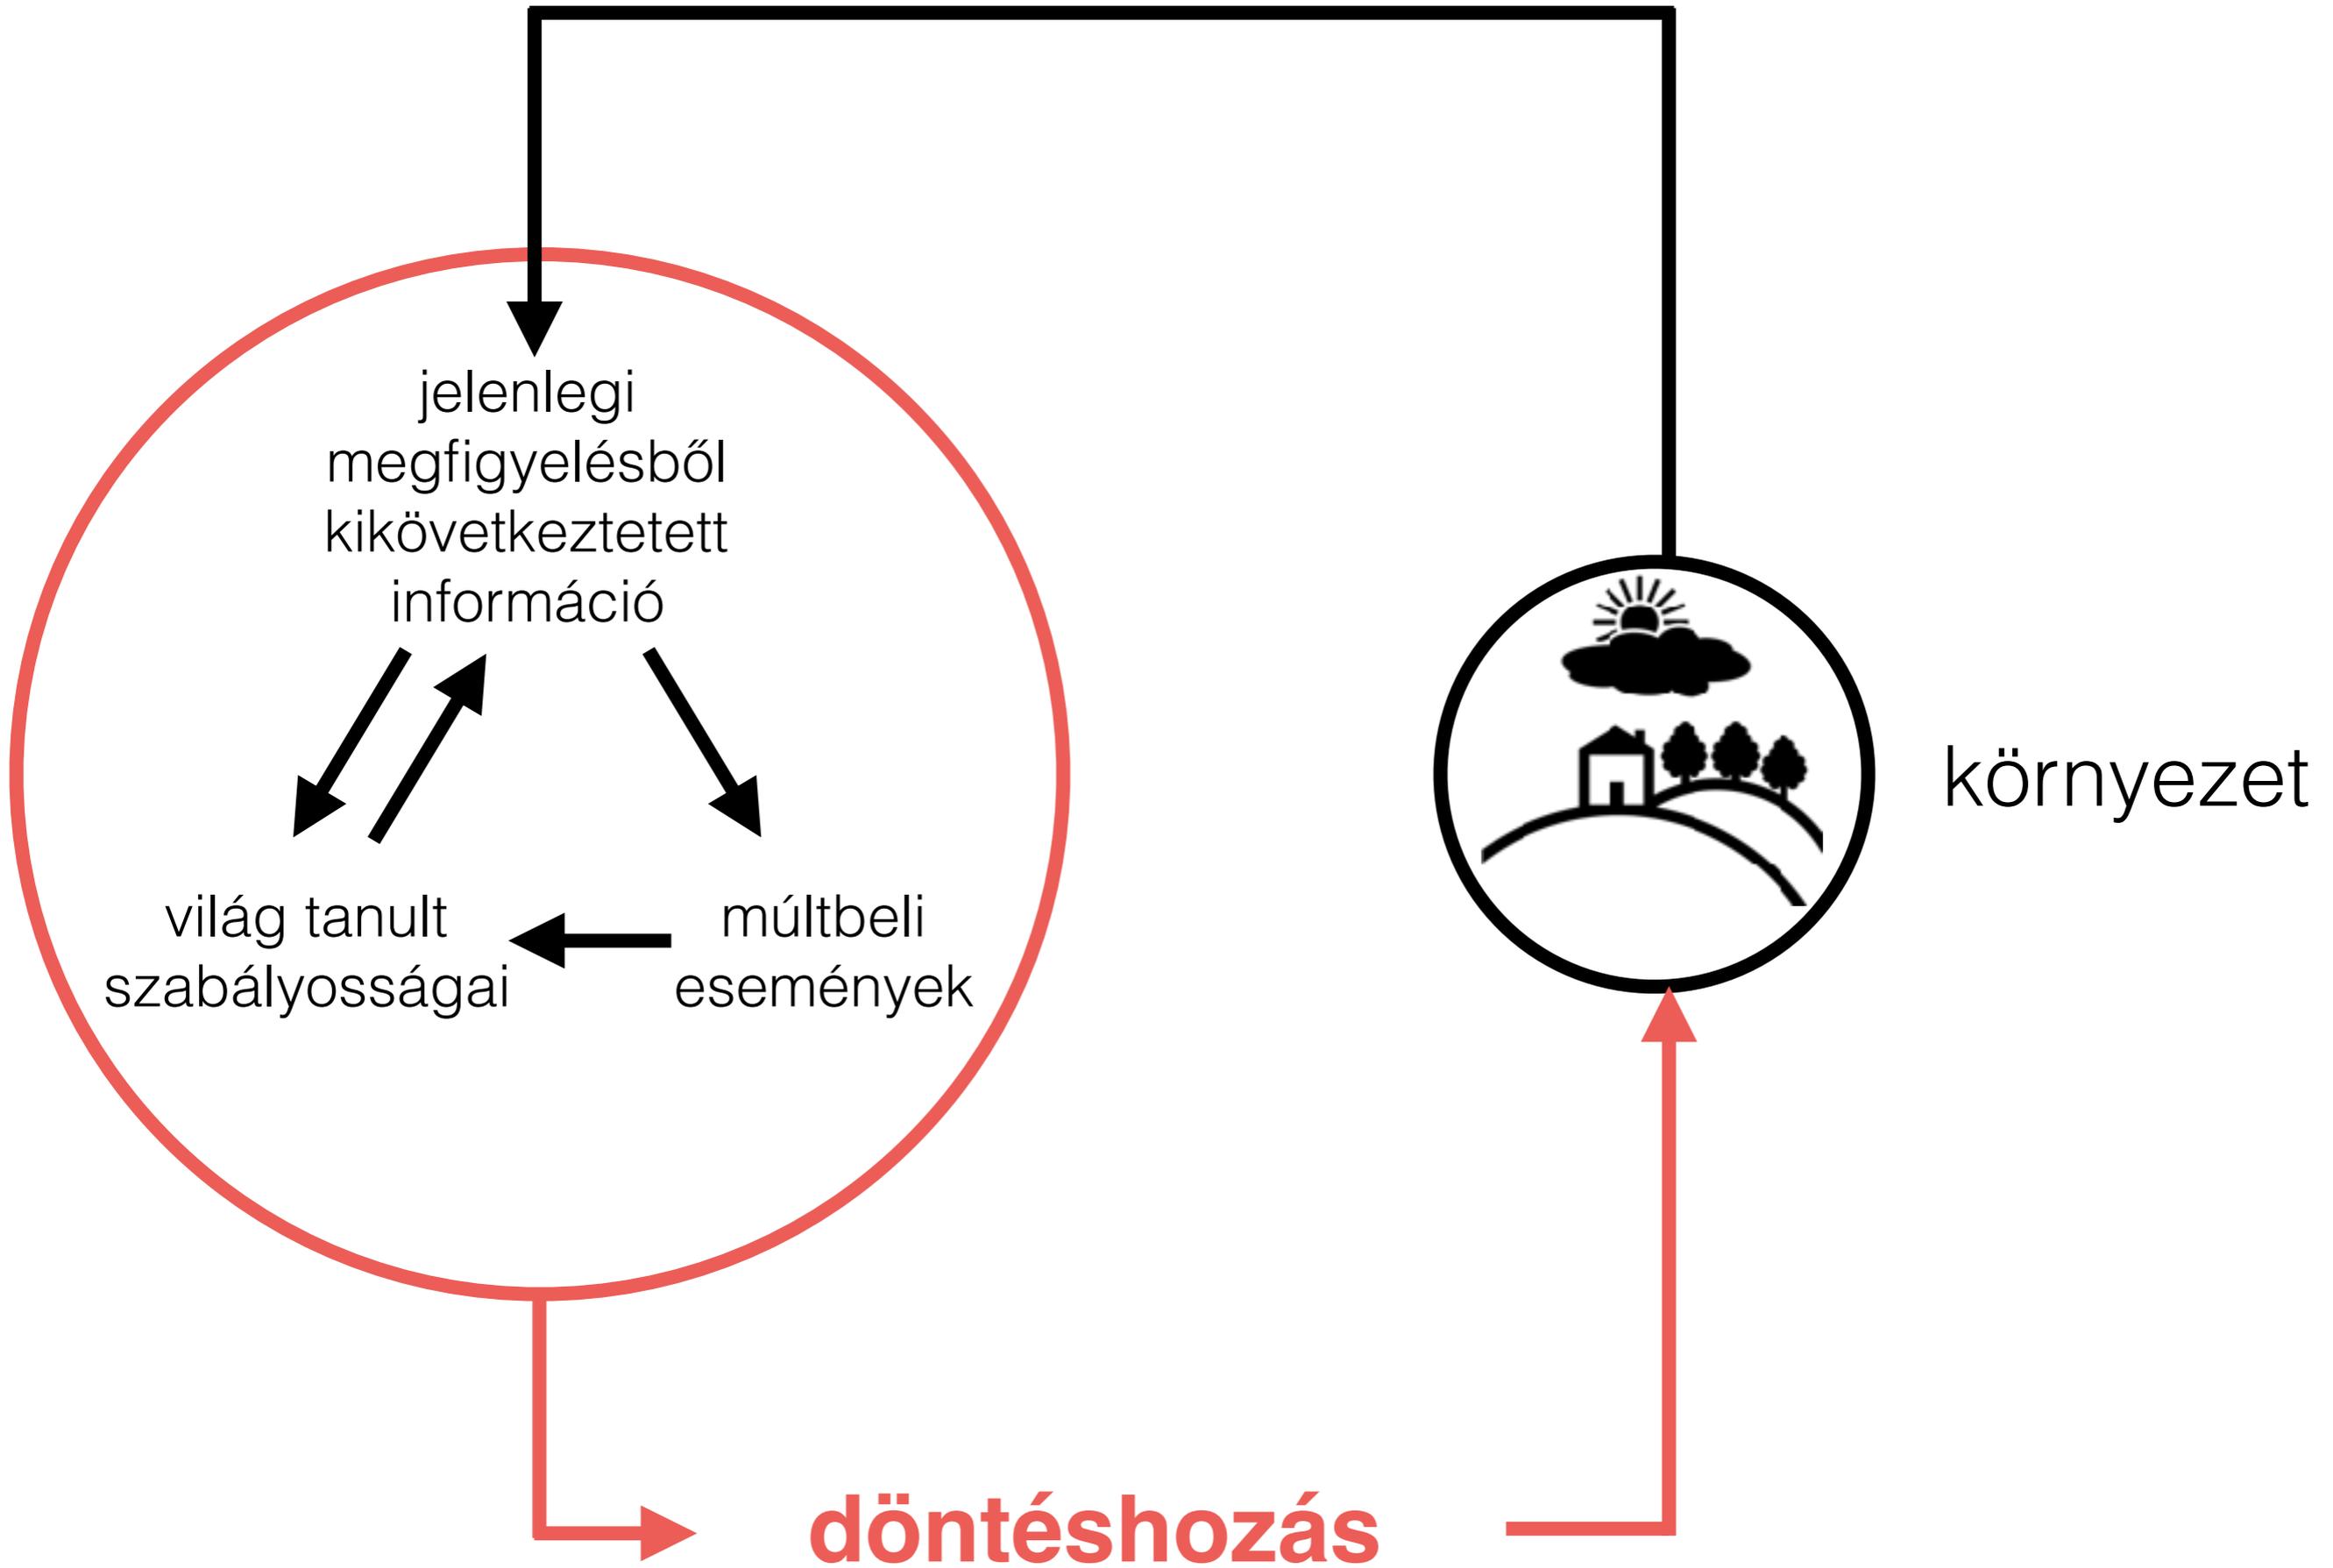
világ tanult
szabályosságai

múltbeli
események



környezet

döntéshozás



Introduction

Knowledge representation

Probabilistic models

Bayesian behaviour

Approximate inference I (computer lab)

Vision I

Approximate inference II: Sampling

Measuring priors

Neural representation of probabilities

Structure learning

Vision II

Decision making and reinforcement learning

elméleti

Introduction

Knowledge representation

Probabilistic models

Bayesian behaviour

Approximate inference I (computer lab)

Vision I

Approximate inference II: Sampling

Measuring priors

Neural representation of probabilities

Structure learning

Vision II

Decision making and reinforcement learning

Introduction

Knowledge representation

Probabilistic models

elméleti

Bayesian behaviour

Approximate inference I (computer lab)

Vision I

kognitív

Approximate inference II: Sampling

Measuring priors

Neural representation of probabilities

Structure learning

Vision II

Decision making and reinforcement learning

Introduction

Knowledge representation

Probabilistic models

elméleti

Bayesian behaviour

Approximate inference I (computer lab)

Vision I

kognitív

Approximate inference II: Sampling

Measuring priors

Neural representation of probabilities

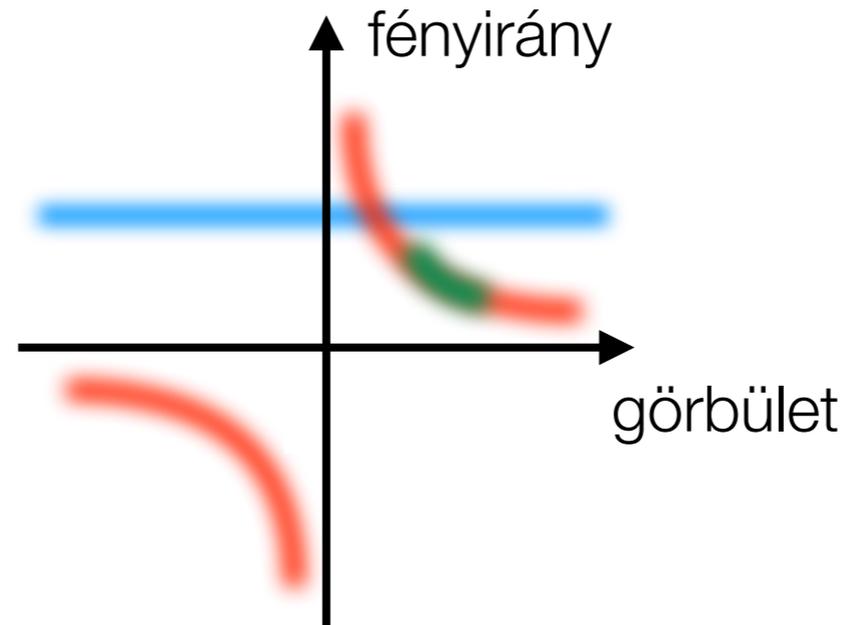
neurális

Structure learning

Vision II

Decision making and reinforcement learning

RECAP: role of priors



evidence

expectation

inference

$$P(\text{feature} \mid \text{stimulus}) \propto P(\text{stimulus} \mid \text{feature}) \times P(\text{feature})$$

posterior: inference

likelihood: evidence

prior : expectations

features \rightsquigarrow neurons

Bayes inferencia

Miért érdekes a poszterior eloszlás?

Bayes inferencia

Miért érdekes a poszterior eloszlás?

stimulus

perception

action

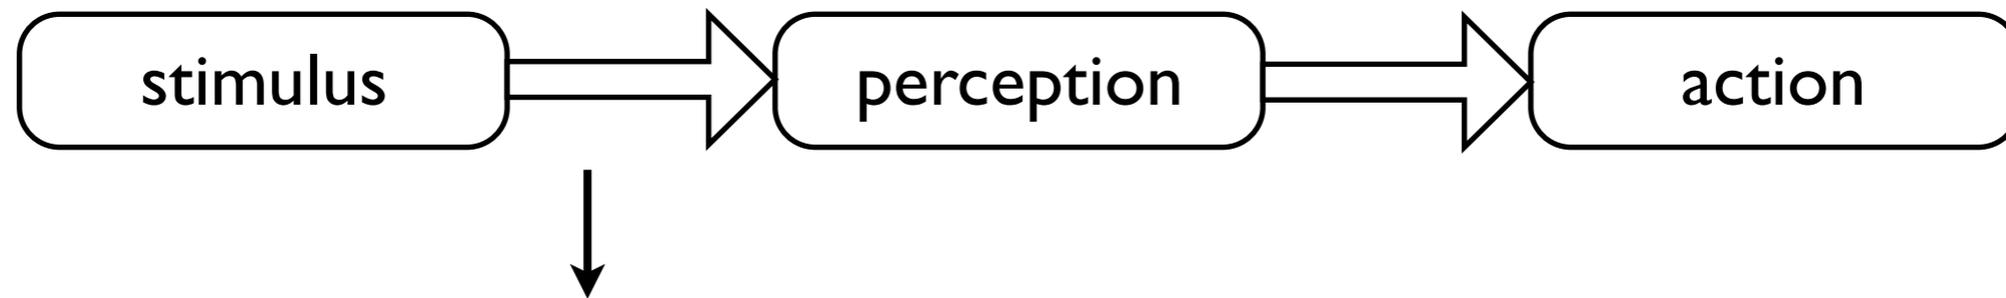
Bayes inferencia

Miért érdekes a poszterior eloszlás?



Bayes inferencia

Miért érdekes a poszterior eloszlás?

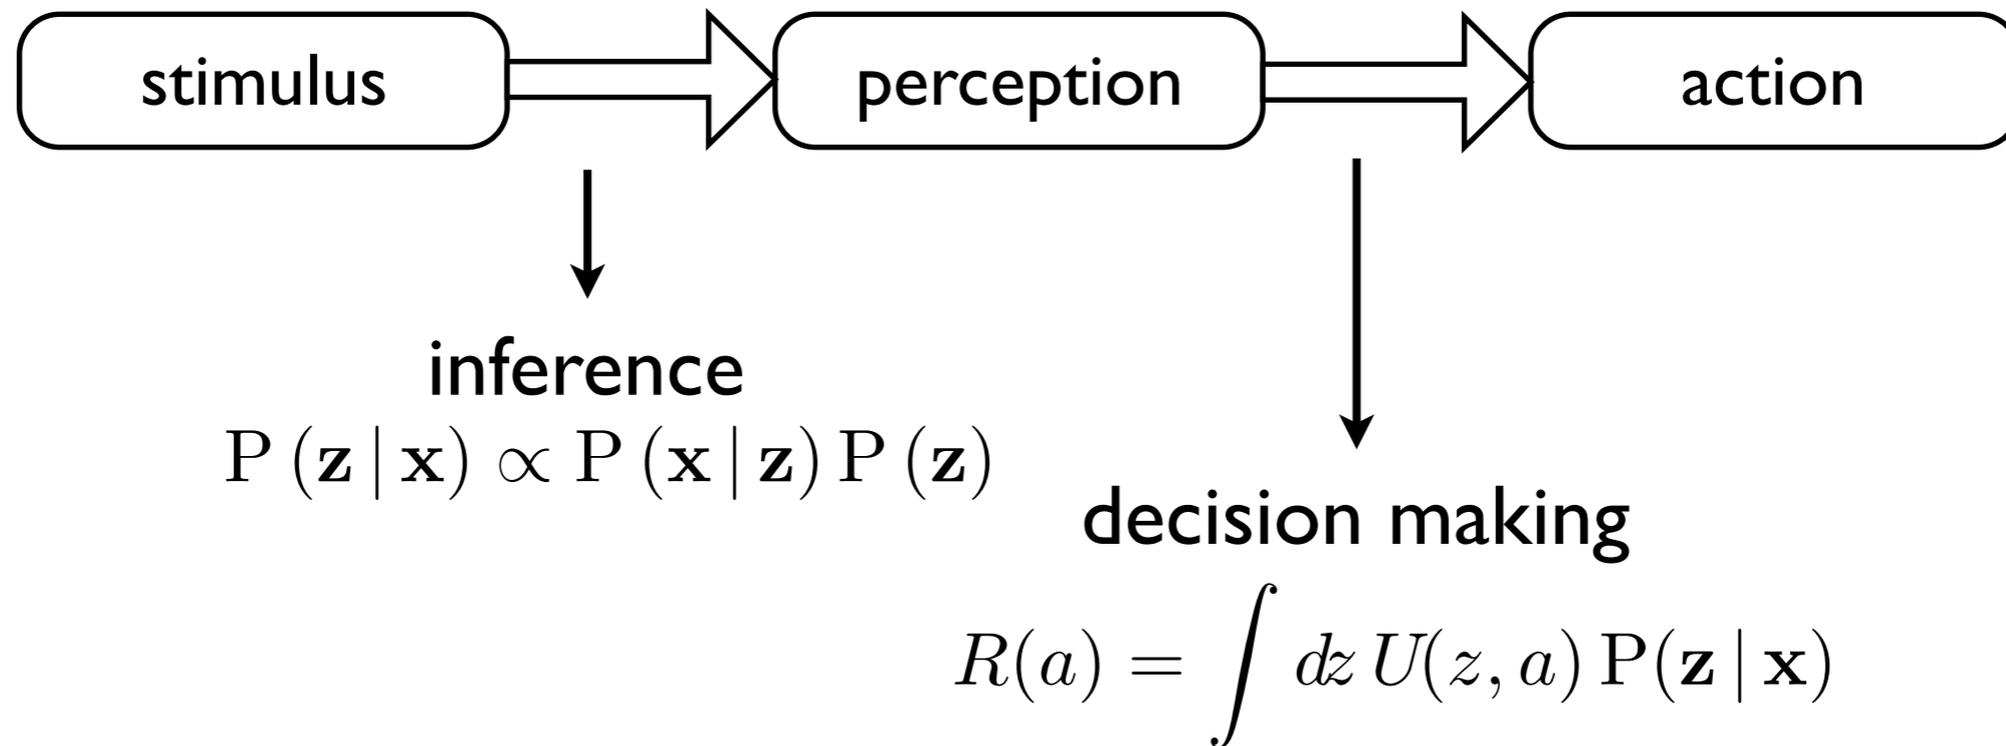


inference

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

Bayes inferencia

Miért érdekes a poszterior eloszlás?



Neurális válaszok



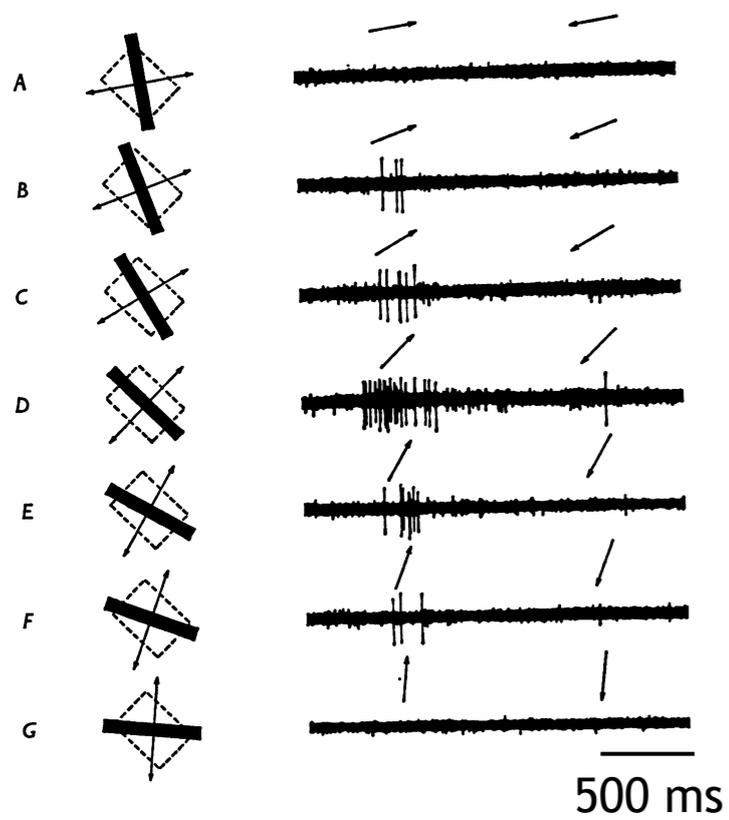
Neurális válaszok



Simple Cell

Neurális válaszok

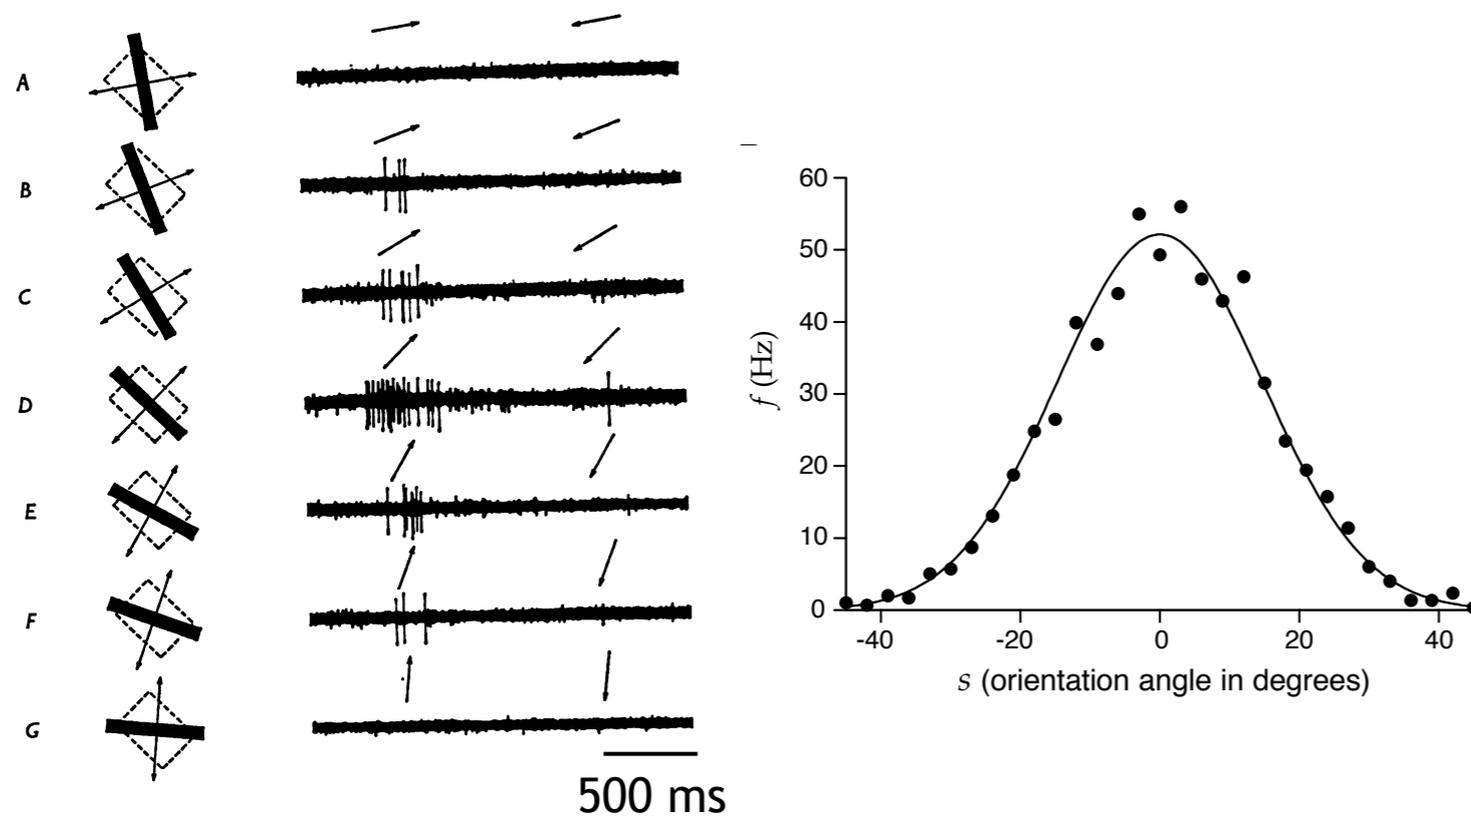
V1 characteristic response



Hubel & Wiesel, J Physiol 1968

Neurális válaszok

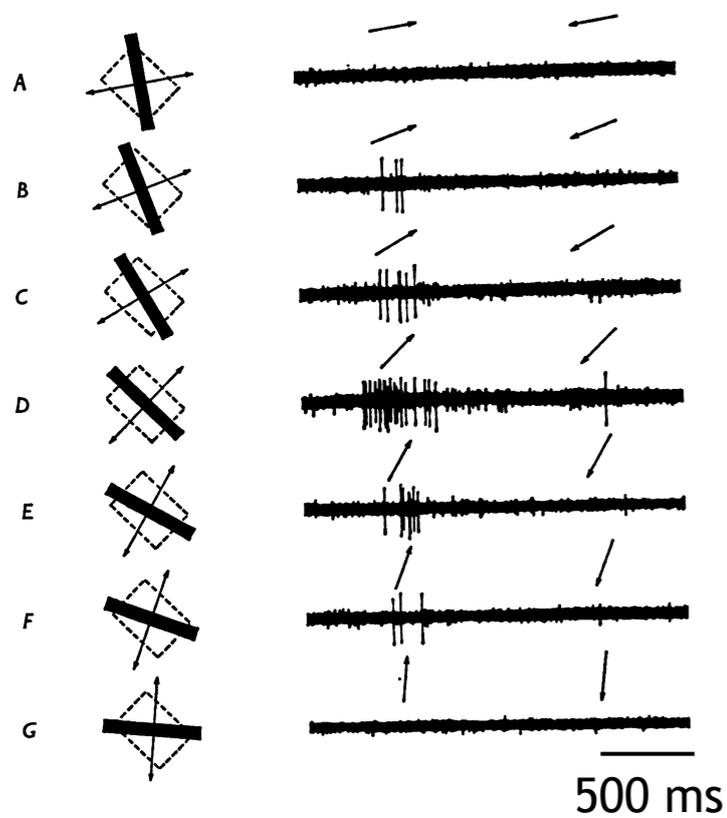
V1 characteristic response



Hubel & Wiesel, *J Physiol* 1968

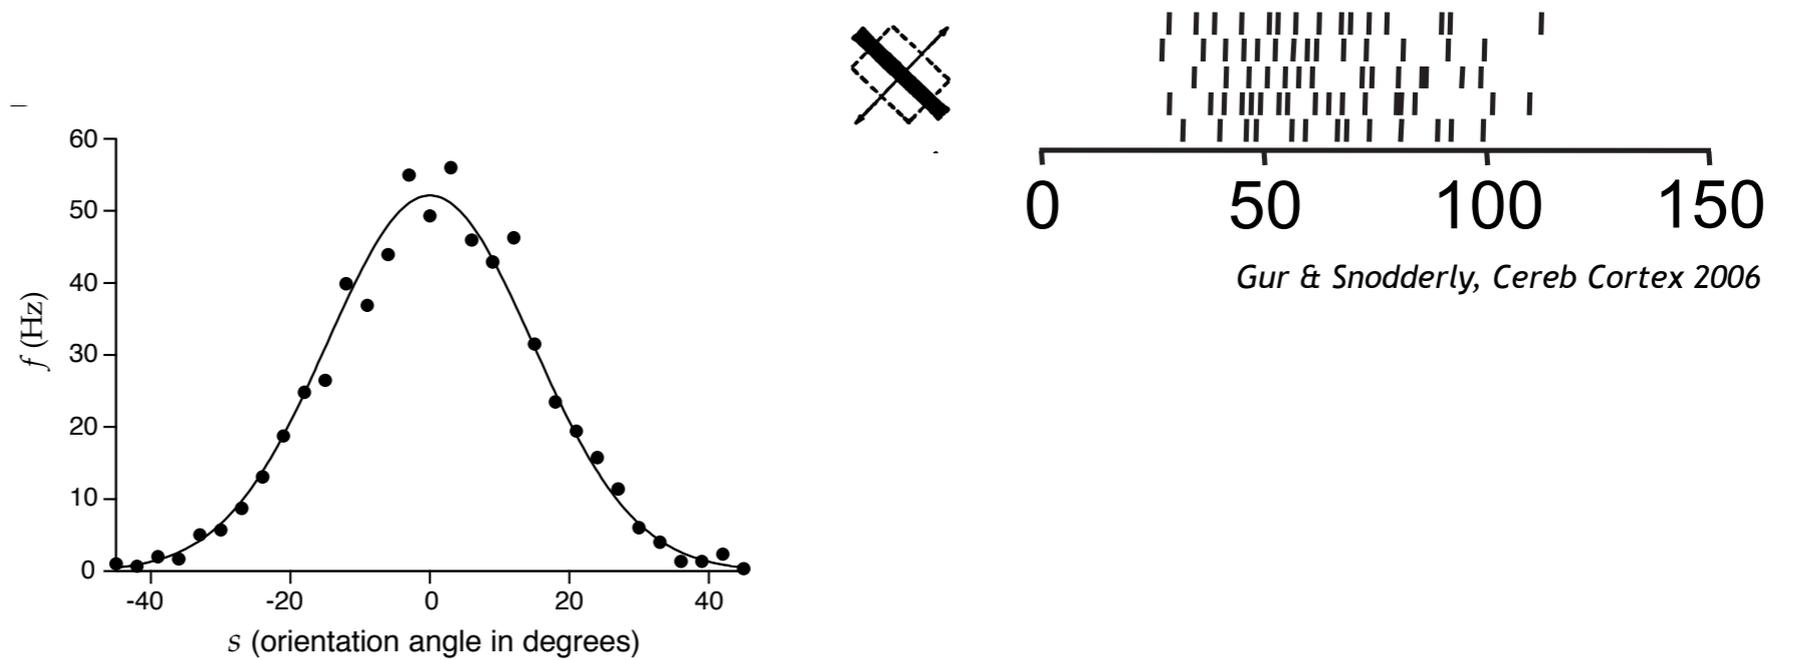
Neurális válaszok

V1 characteristic response



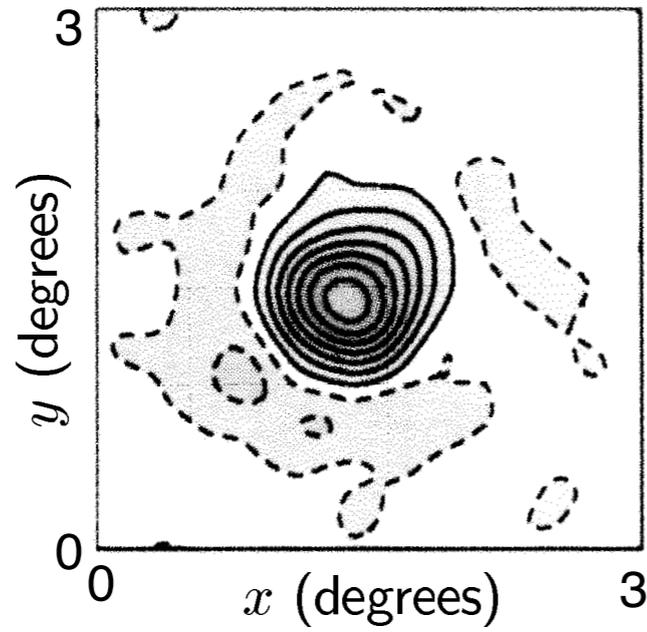
Hubel & Wiesel, *J Physiol* 1968

V1 spike train variability

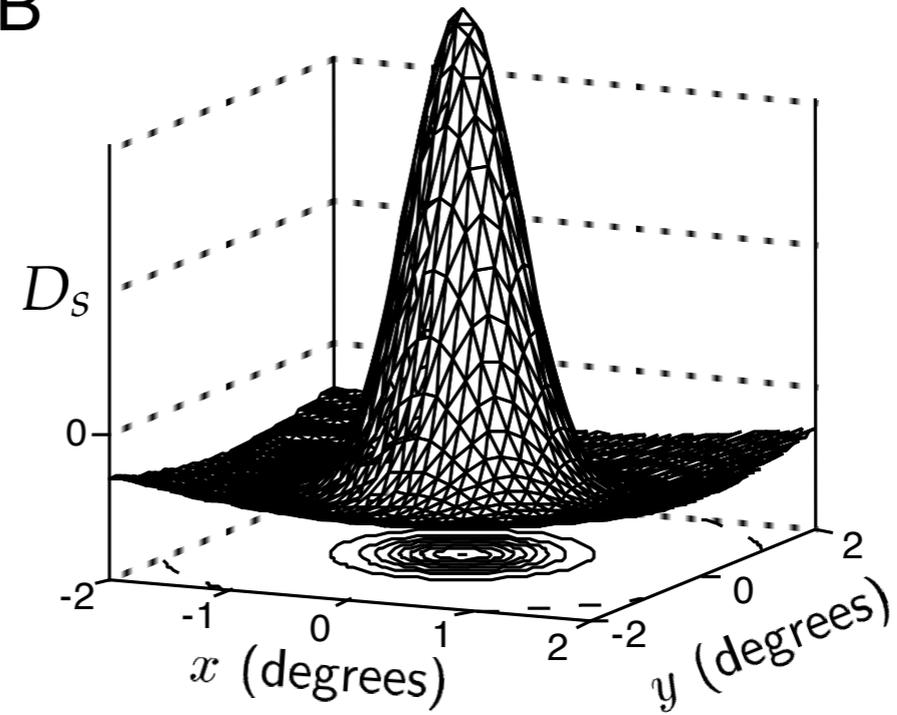


Receptív mező

A

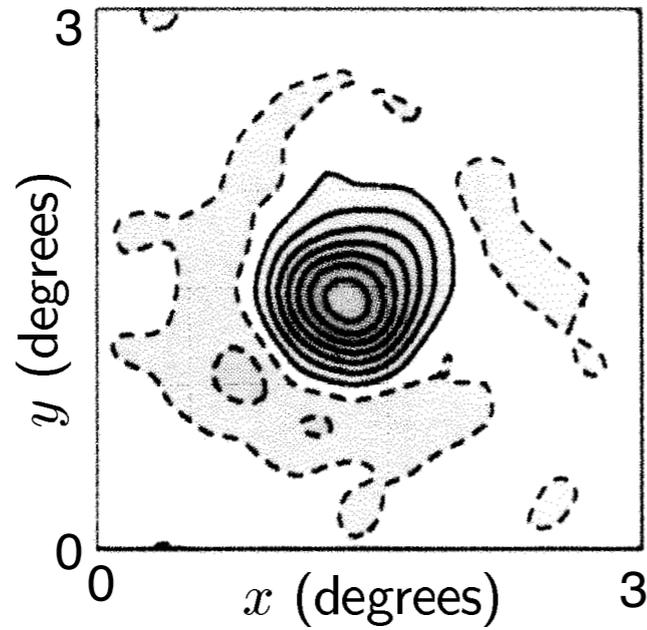


B

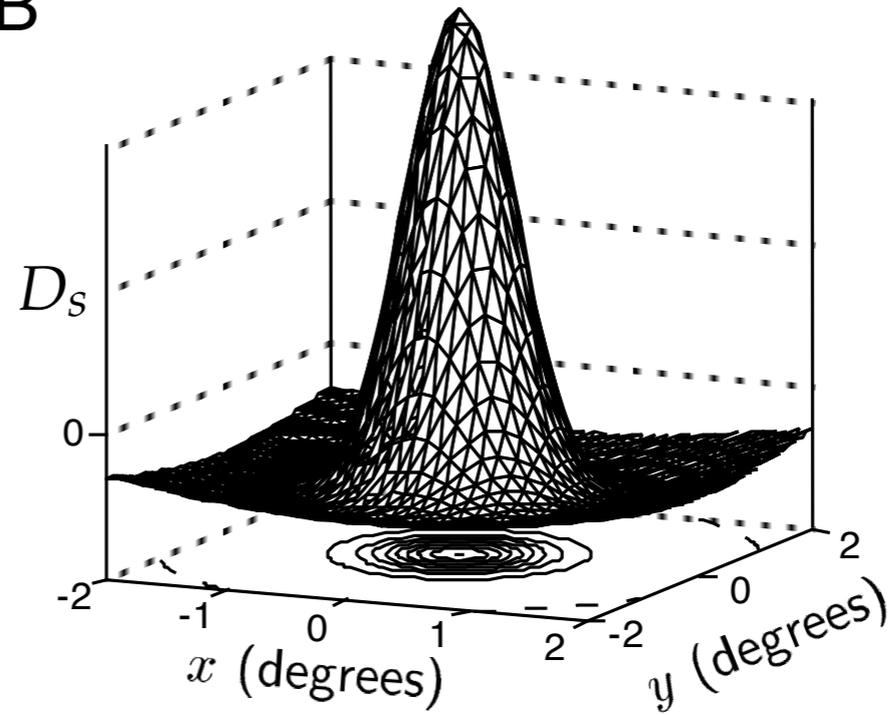


Receptív mező

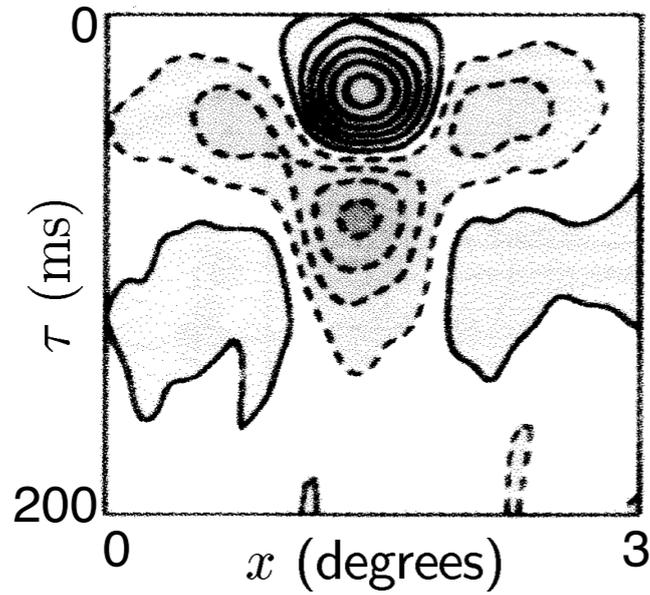
A



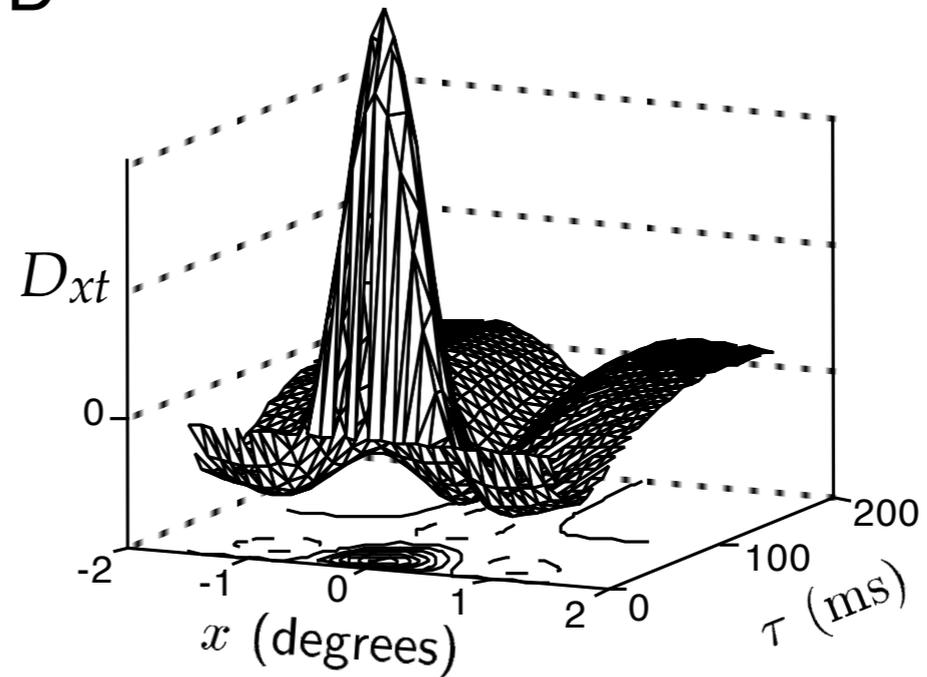
B



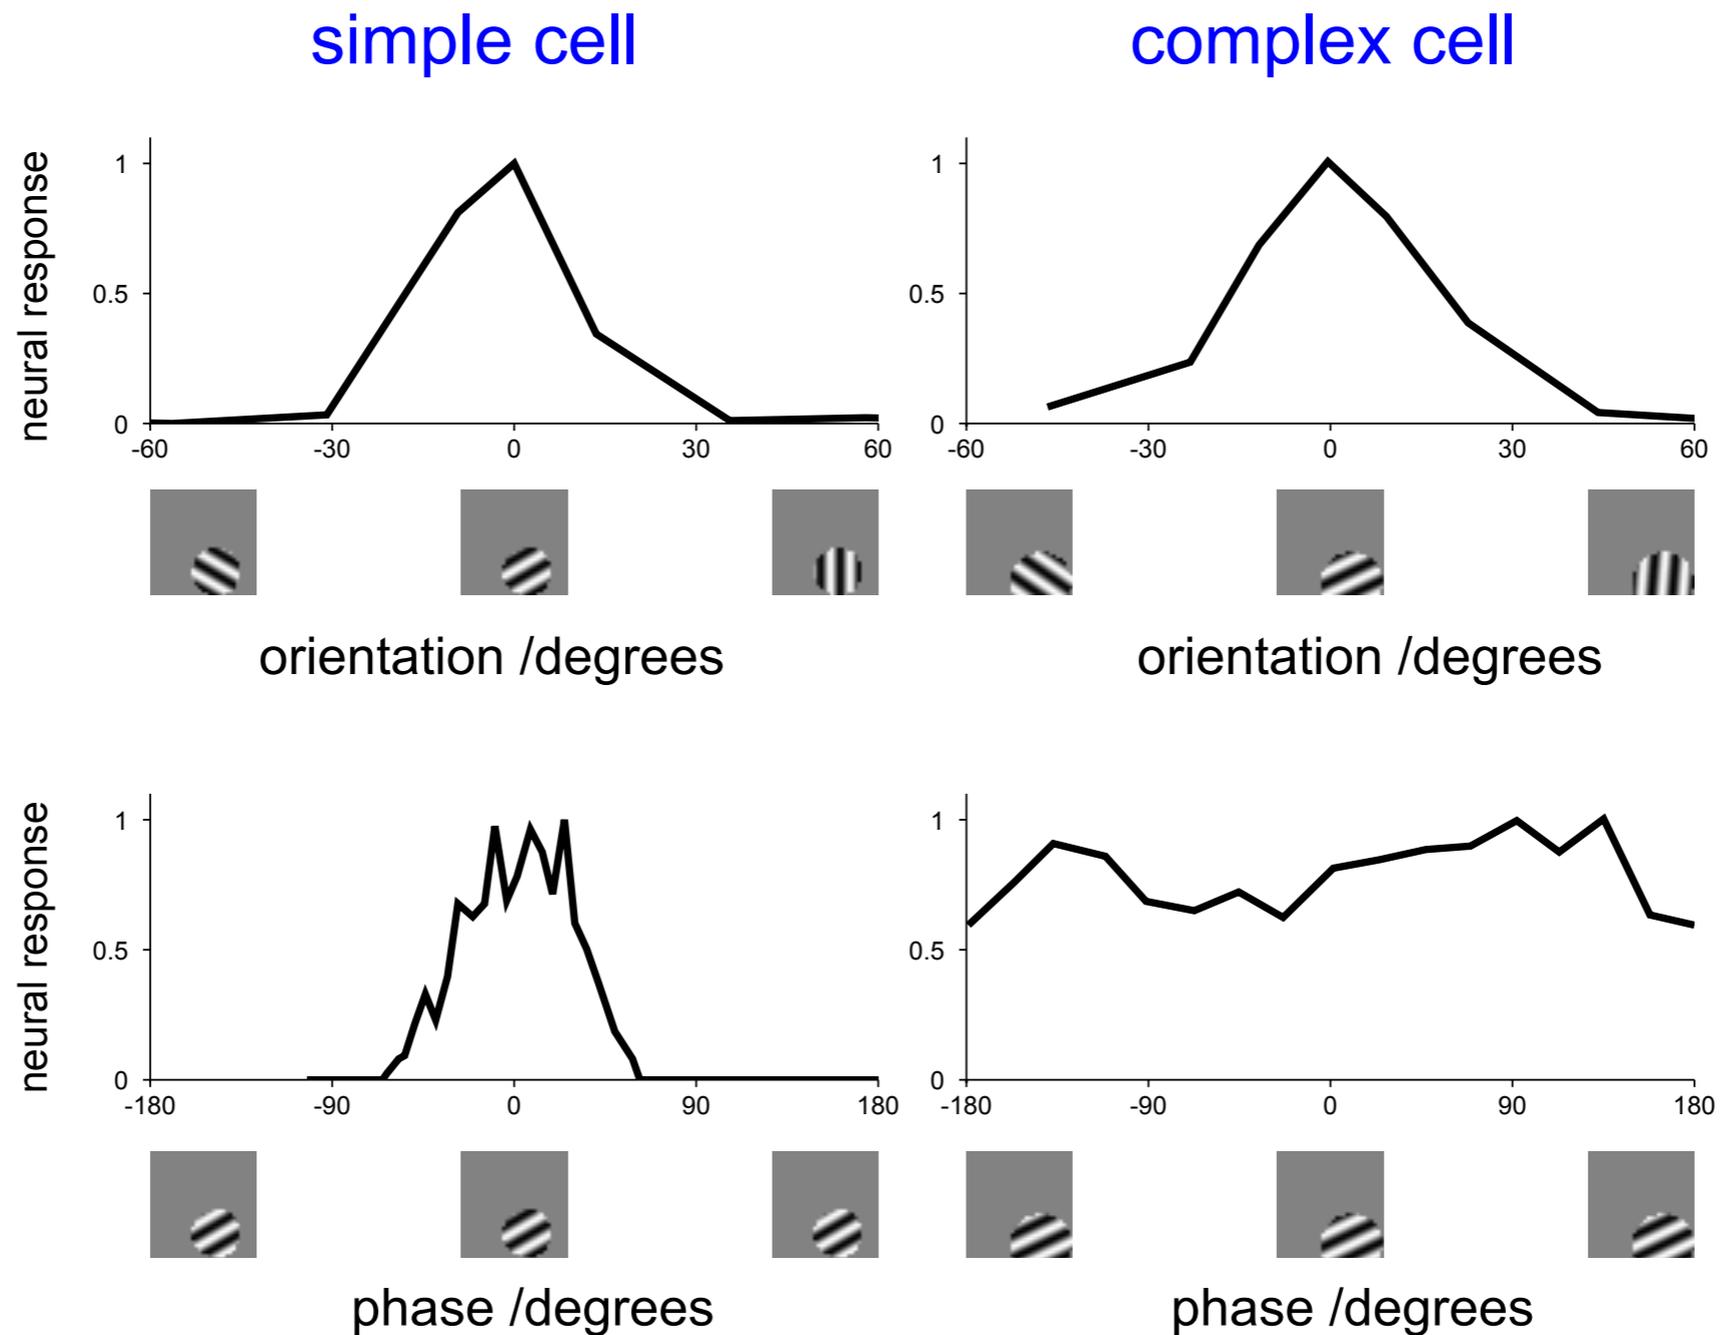
C



D

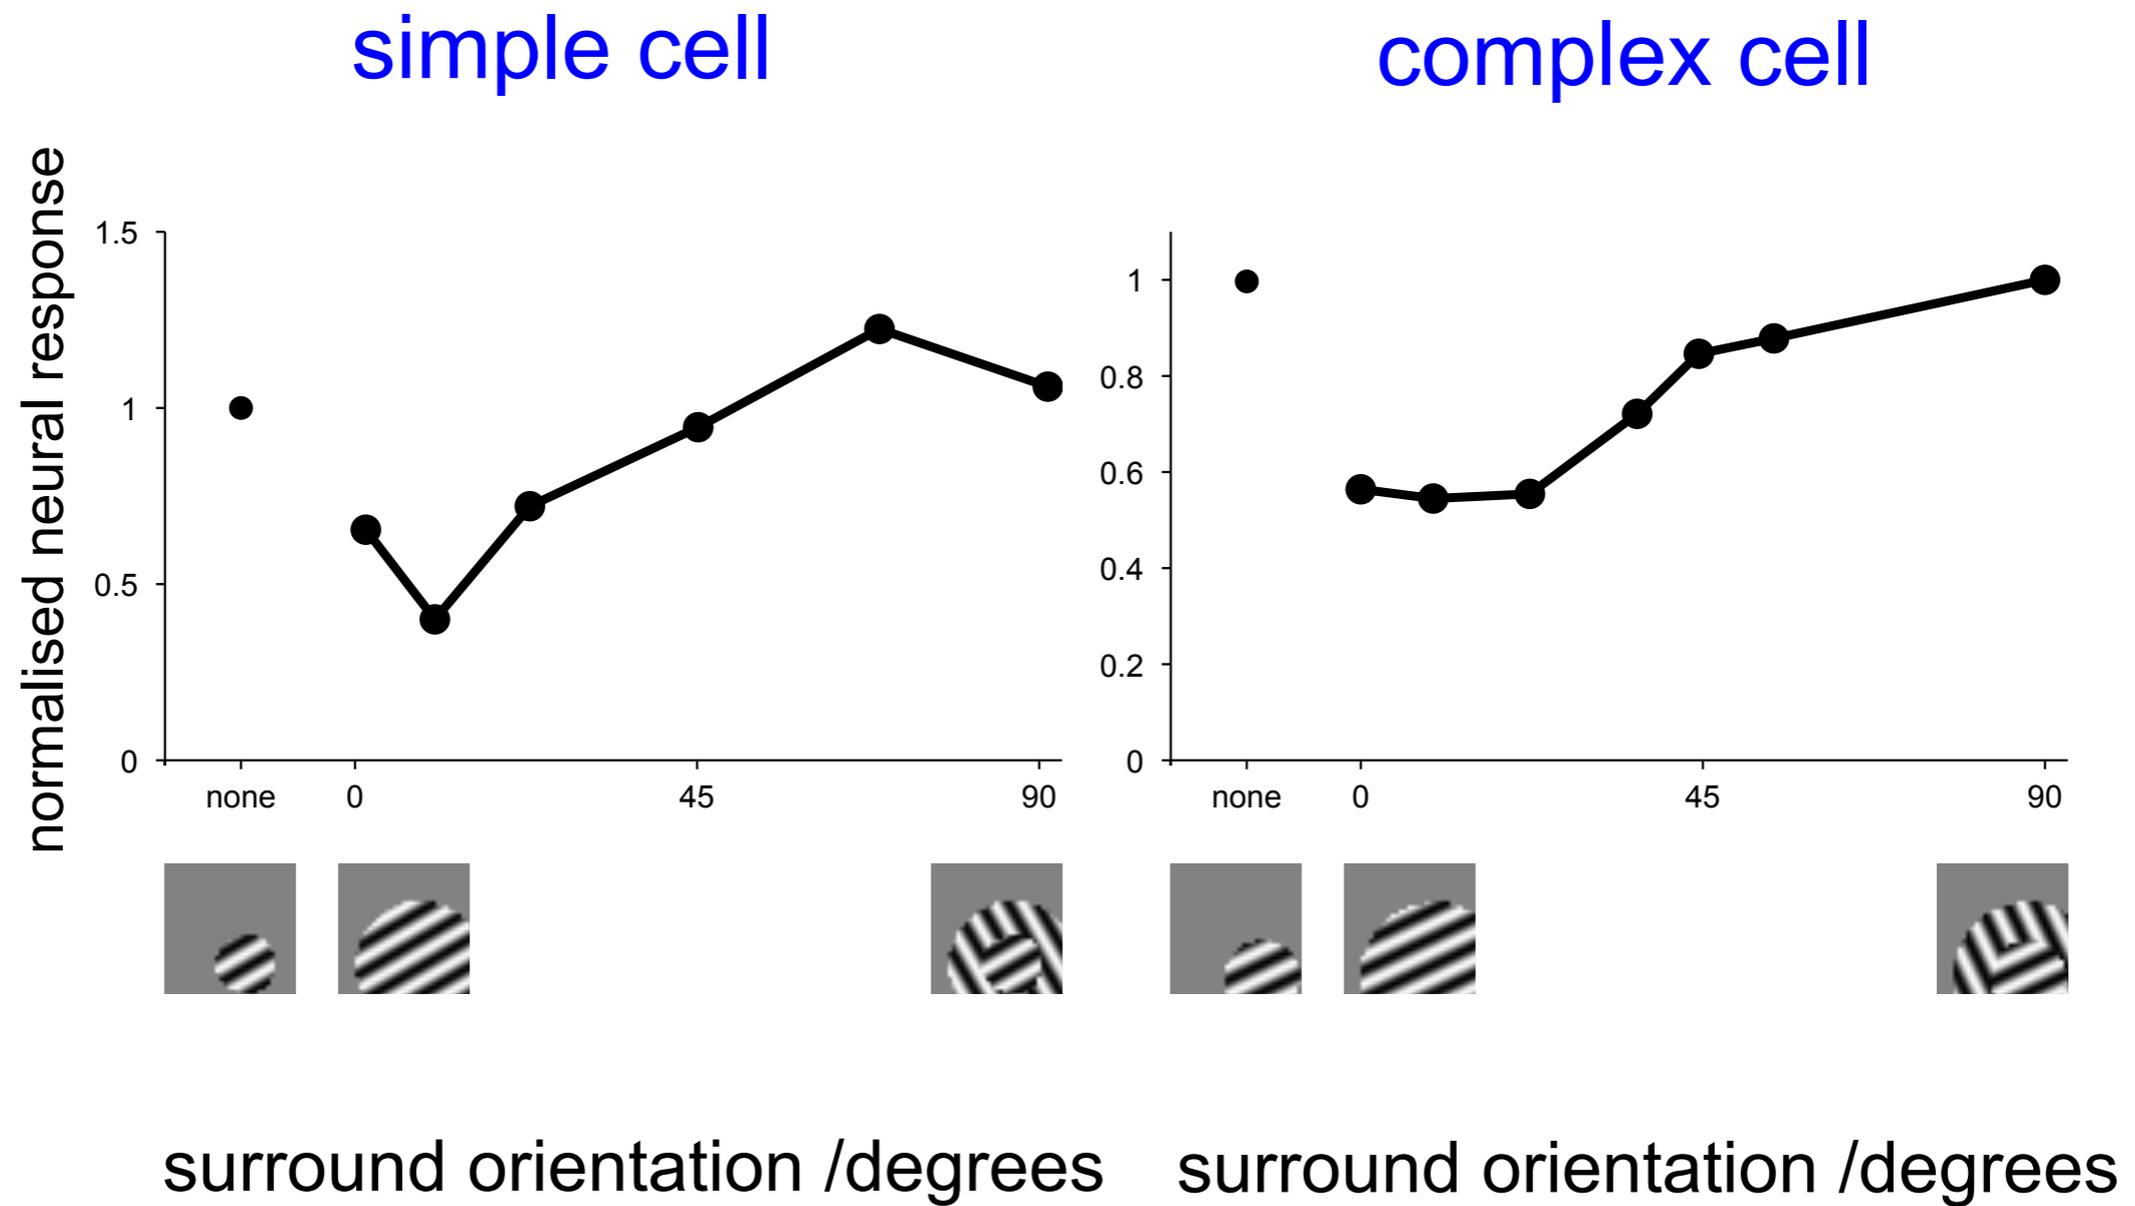


Receptív mező tulajdonságok



Movshon et al. 1978a, 1978b and Jones et al. 2001

Receptív mező tulajdonságok



Unsupervised learning

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

Gól: $P(\mathbf{x})$

Unsupervised learning

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

Gól: $P(\mathbf{x})$

(Supervised learning:

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

Gól: $P(\mathbf{x} | \mathbf{y})$)

Unsupervised learning

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

Gól: $P(\mathbf{x})$

(Supervised 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?

Unsupervised learning

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

Gól: $P(\mathbf{x})$

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

Unsupervised learning

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

Gól: $P(\mathbf{x})$

(Supervised learning:

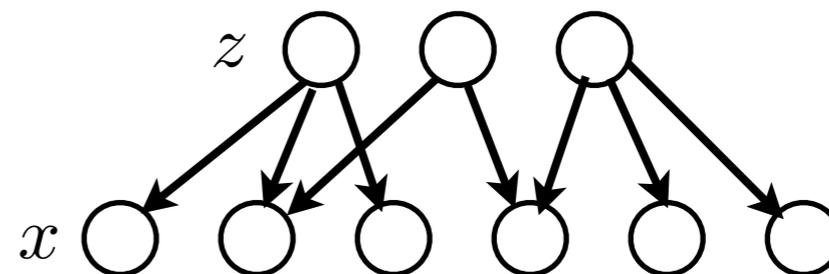
Input: $\{x_1, y_1\}, \{x_2, y_2\}, \dots, \{x_t, y_t\}$

Gól: $P(\mathbf{x} | \mathbf{y})$)

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

Miért is?

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



Unsupervised learning

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

Gól: $P(\mathbf{x})$

(Supervised learning:

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

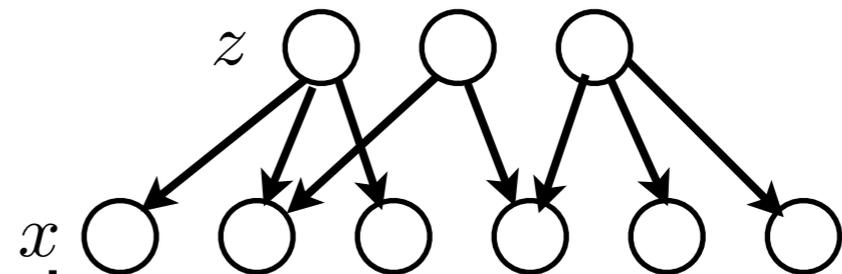
Gól: $P(\mathbf{x} | \mathbf{y})$)

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

Miért is?

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

- az adatot a “z”-k terében reprezentáljuk



Unsupervised learning

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

Gól: $P(\mathbf{x})$

(Supervised learning:

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

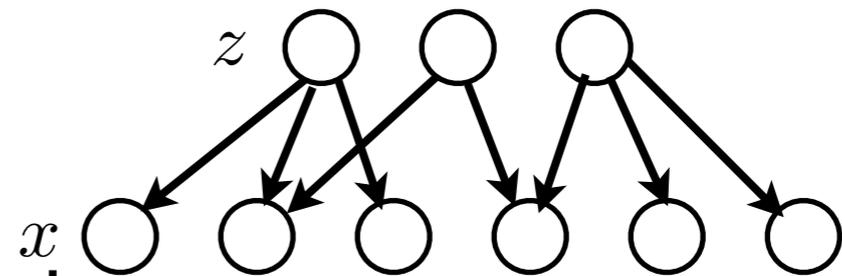
Gól: $P(\mathbf{x} | \mathbf{y})$)

$P(\mathbf{x})$ 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



Unsupervised learning

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

Gól: $P(\mathbf{x})$

(Supervised learning:

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

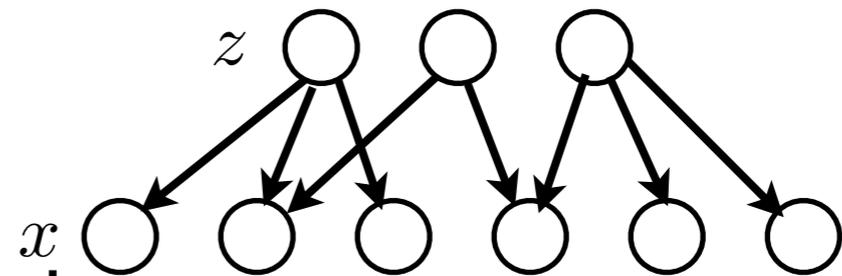
Gól: $P(\mathbf{x} | \mathbf{y})$)

$P(\mathbf{x})$ 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

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

Lineáris modellek

$$P(x | z) = \text{Normal}(x; z, \theta) = C \exp\left(-\frac{1}{2}(x - Az)^T \Sigma^{-1} (x - Az)\right)$$

PCA

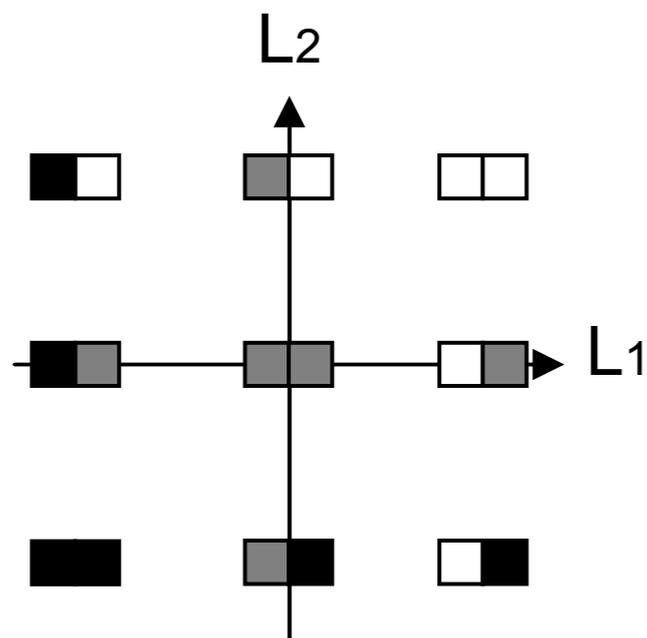
- A oszlopvektorai ortogonálisak
- $D(x) = D(z)$
- Izotróp zaj

Lineáris modellek

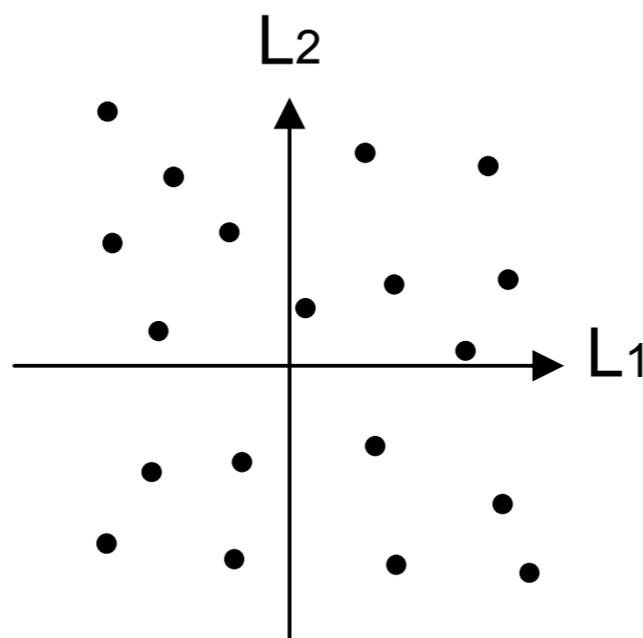
$$P(x | z) = \text{Normal}(x; z, \theta) = C \exp\left(-\frac{1}{2}(x - Az)^T \Sigma^{-1} (x - Az)\right)$$

PCA

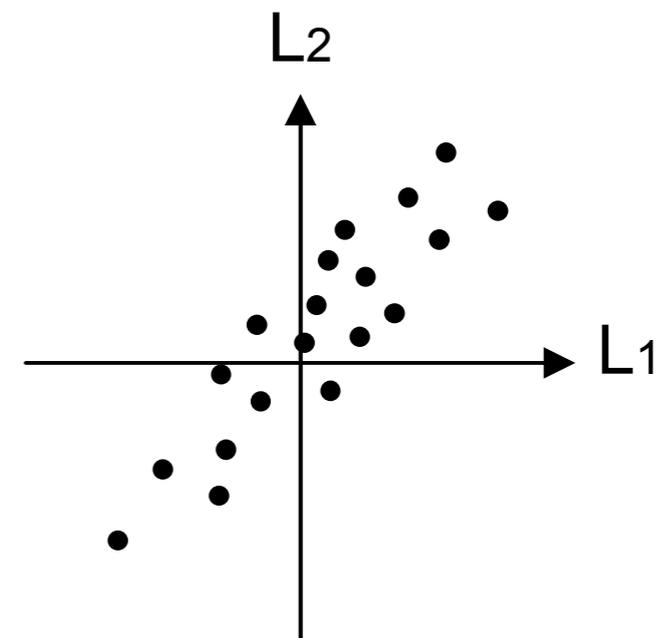
- A oszlopvektorai ortogonálisak
- $D(x) = D(z)$
- Izotróp zaj



State space of two pixel images



Random images



Structured images

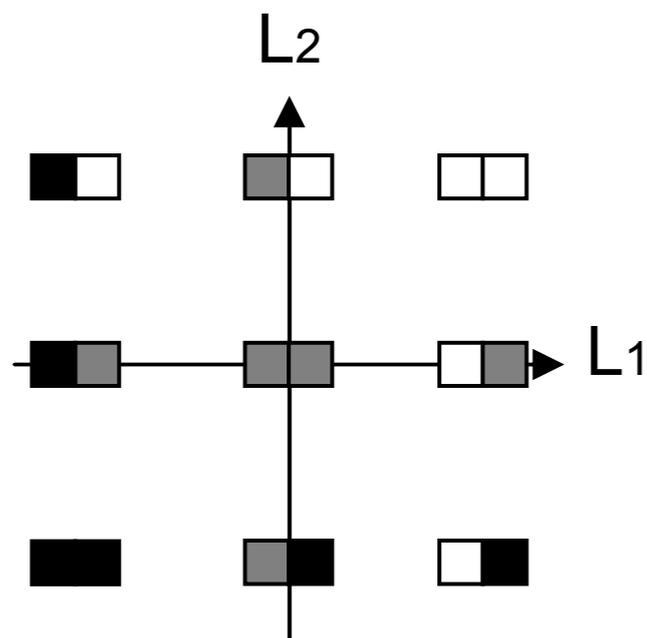
Lineáris modellek

$$P(x | z) = \text{Normal}(x; z, \theta) = C \exp\left(-\frac{1}{2}(x - Az)^T \Sigma^{-1} (x - Az)\right)$$

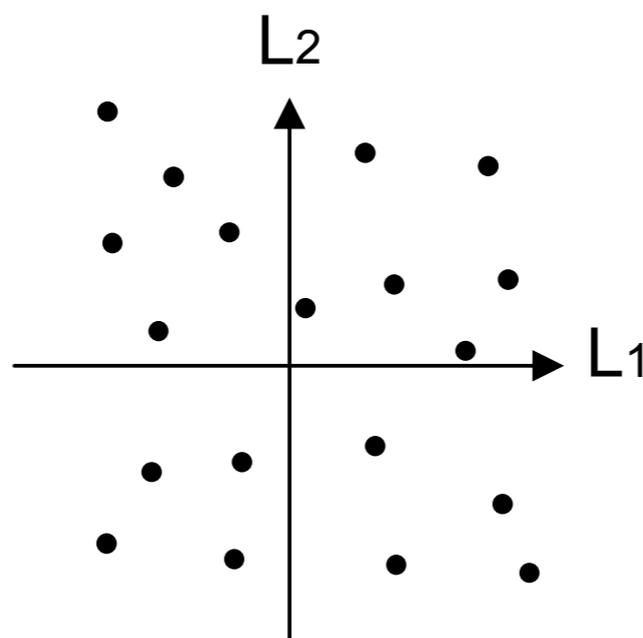
$$x = A \cdot z + \epsilon$$

PCA

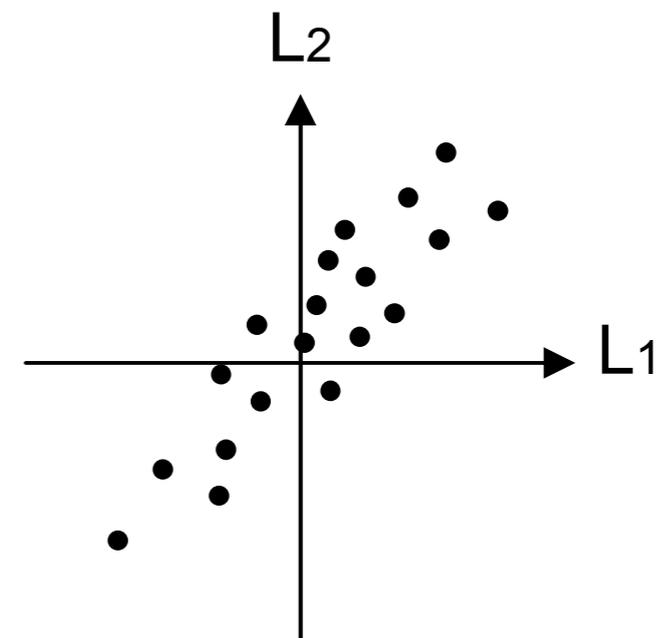
- A oszlopvektorai ortogonálisak
- $D(x) = D(z)$
- Izotróp zaj



State space of two pixel images



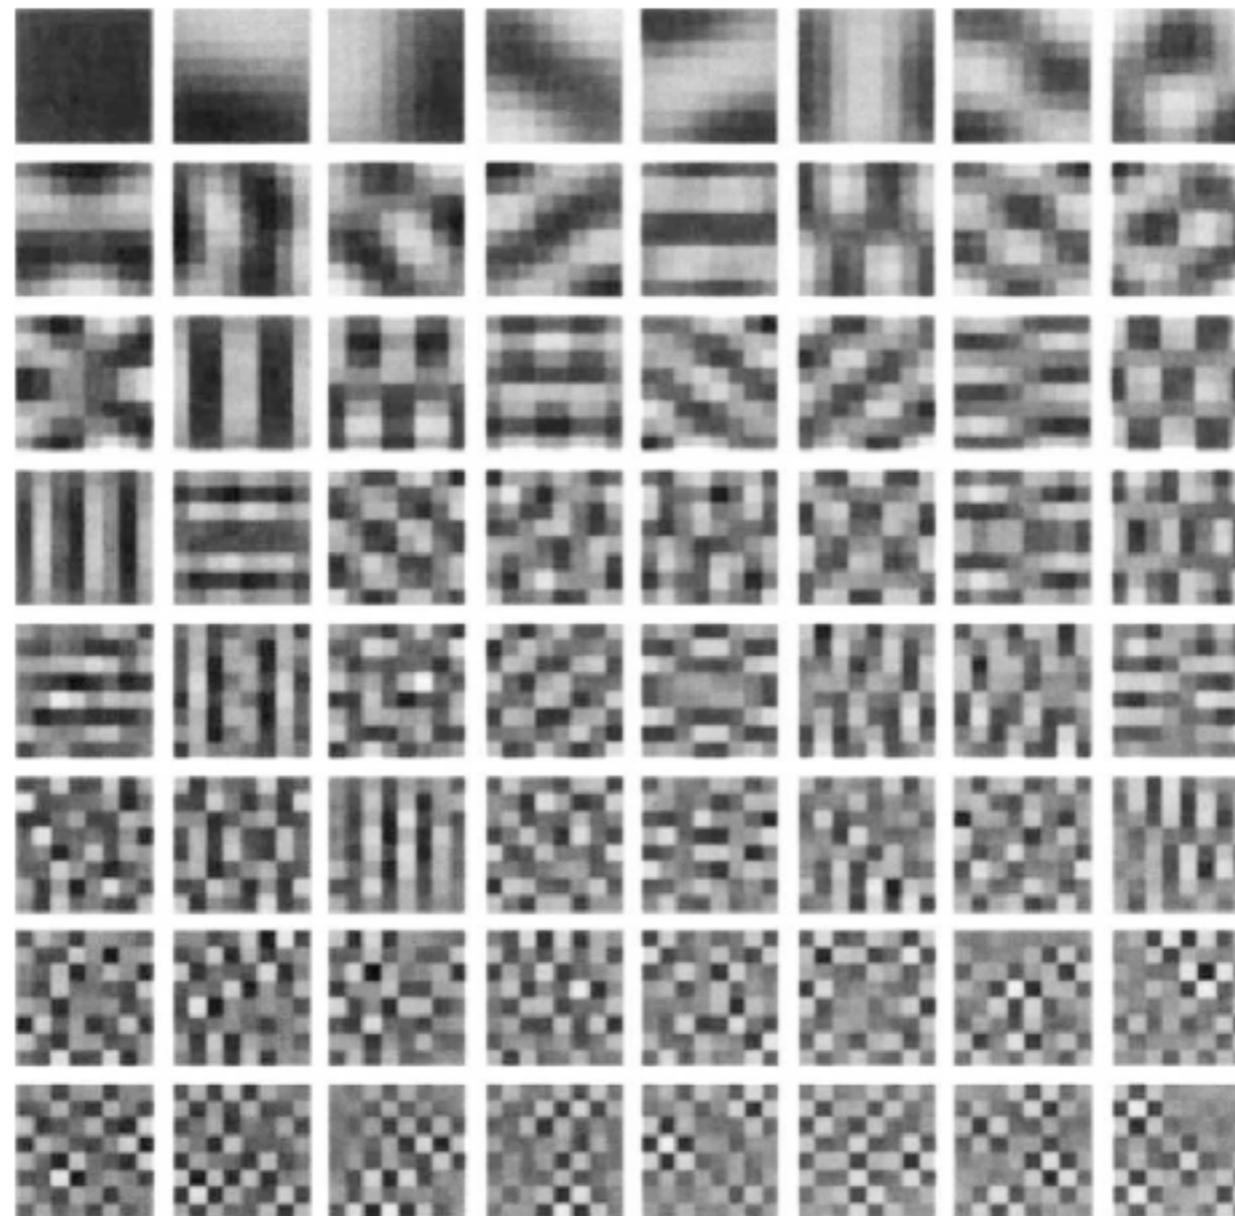
Random images



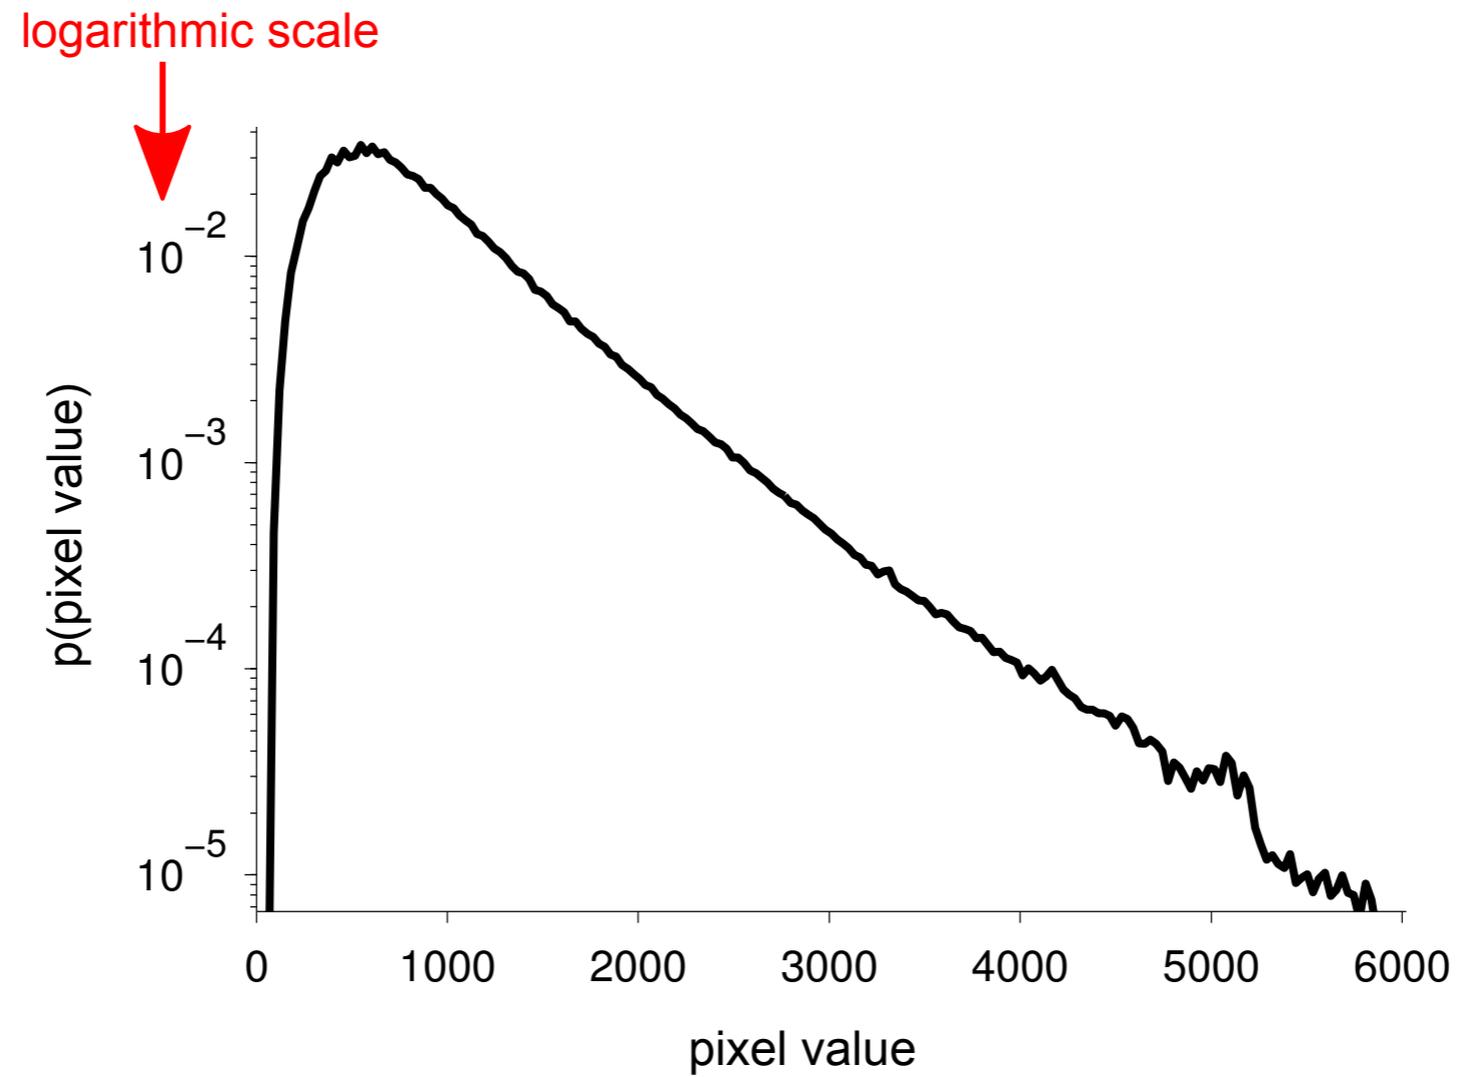
Structured images

PCA tulajdonságok

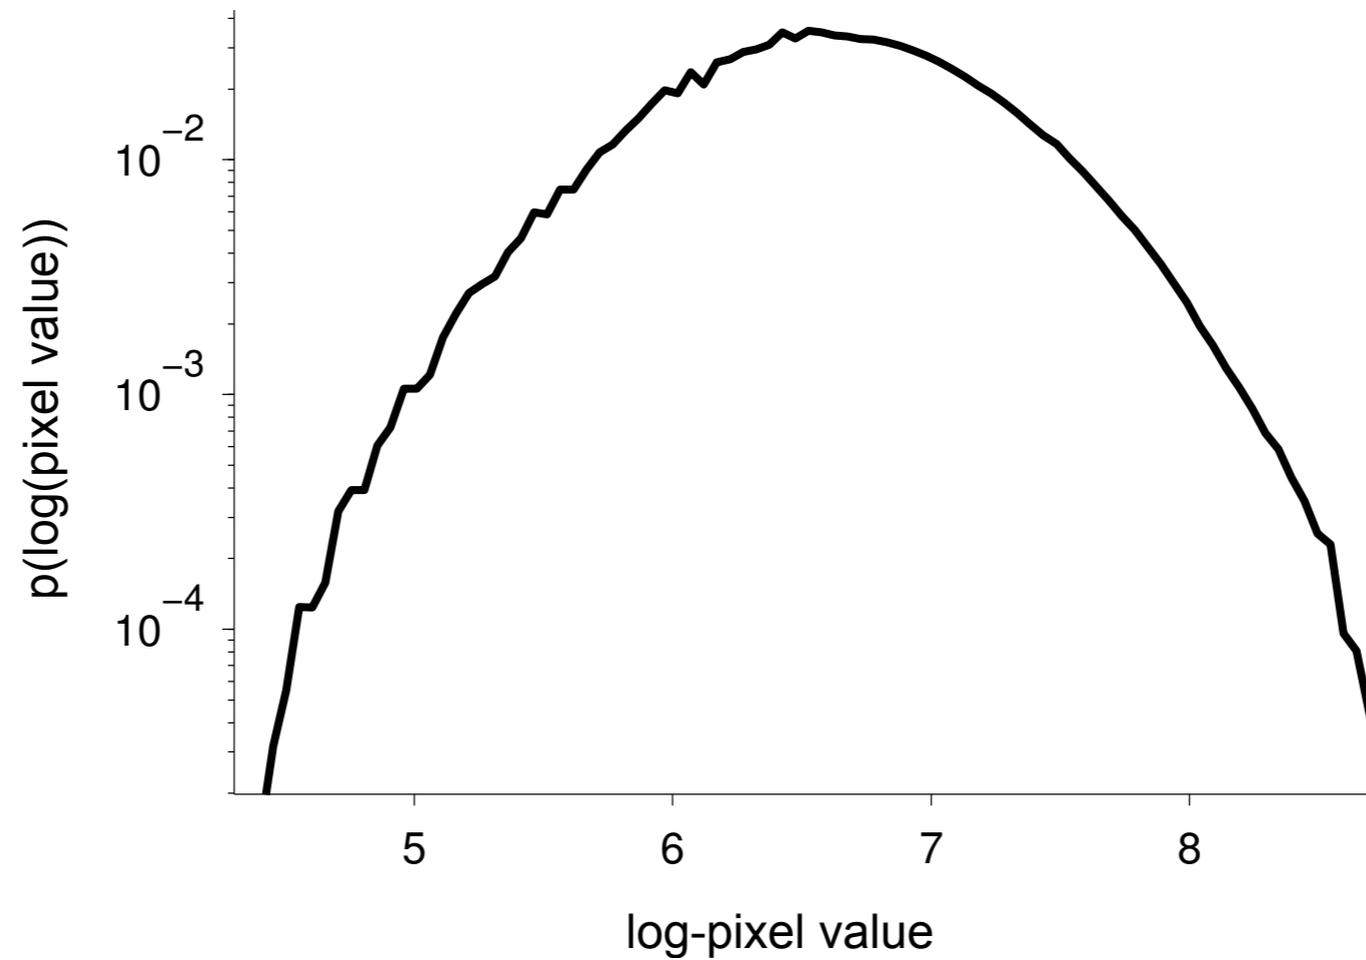
- Kompakt kódot eredményez
- Egy adatpont (kép) leírásáért általában a teljes hálózat felel



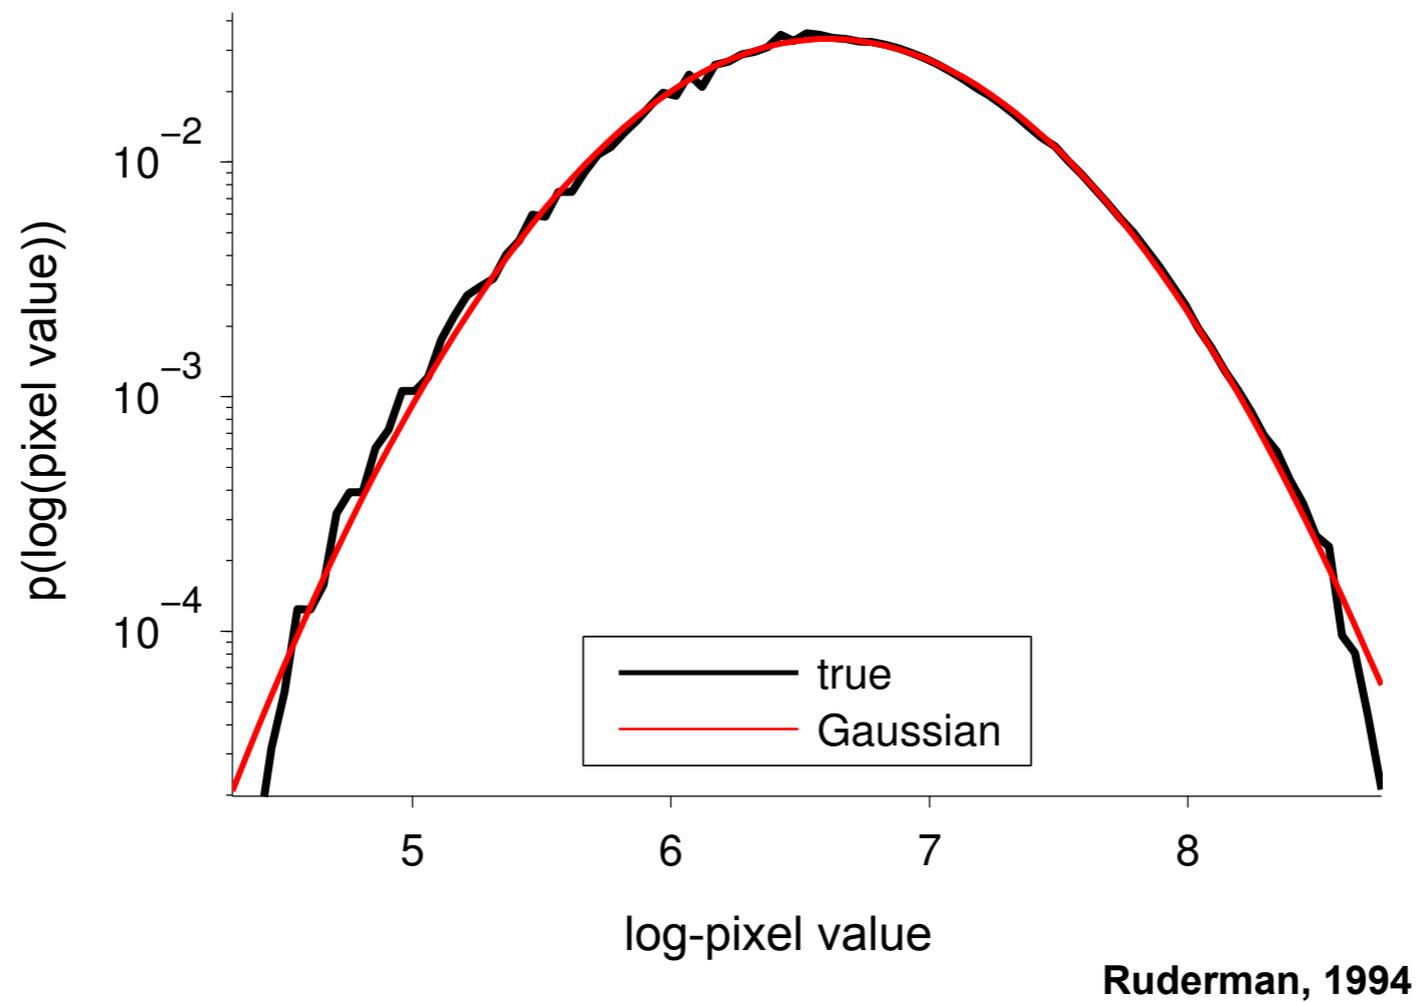
Marginális statisztika



Marginális statisztika



Marginális statisztika



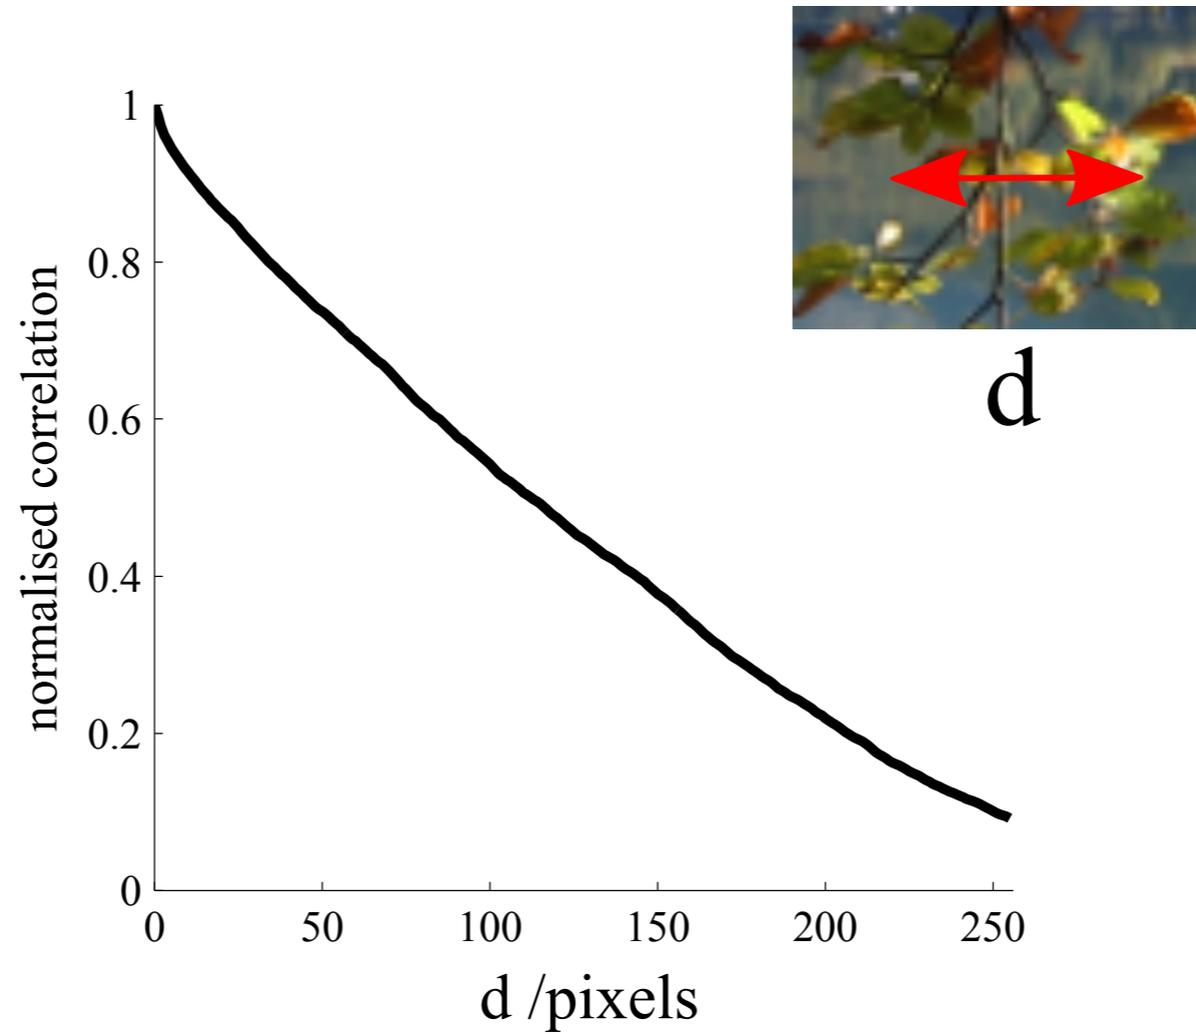
Ruderman, 1994

Pixel korrelációk

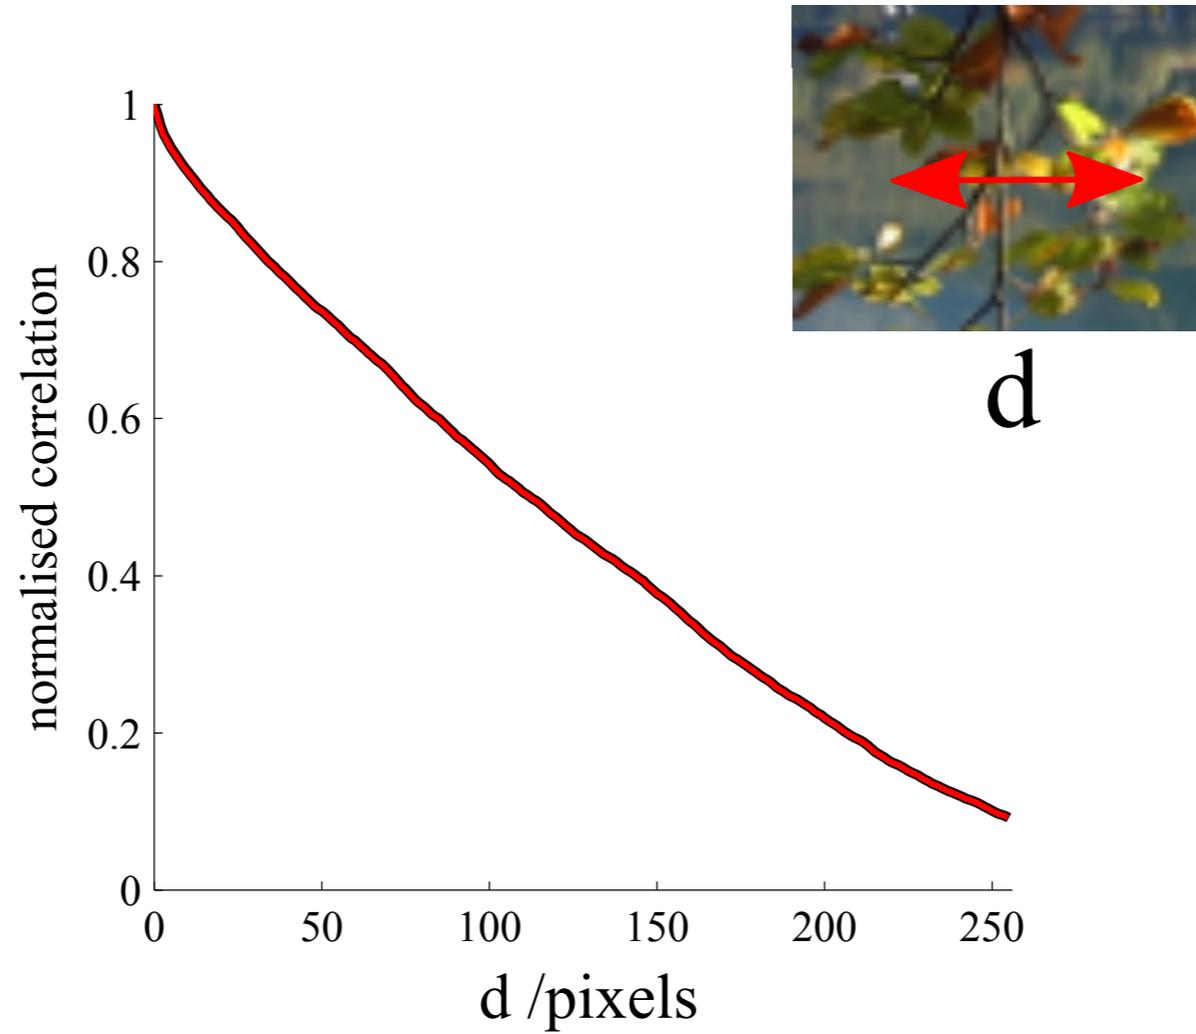


d

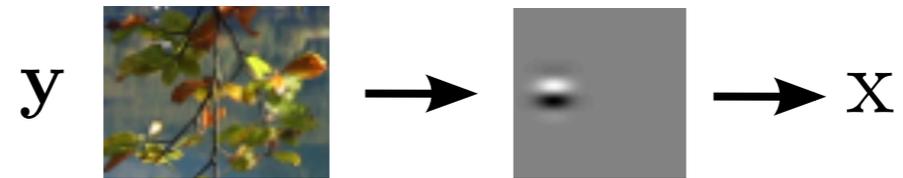
Pixel korrelációk



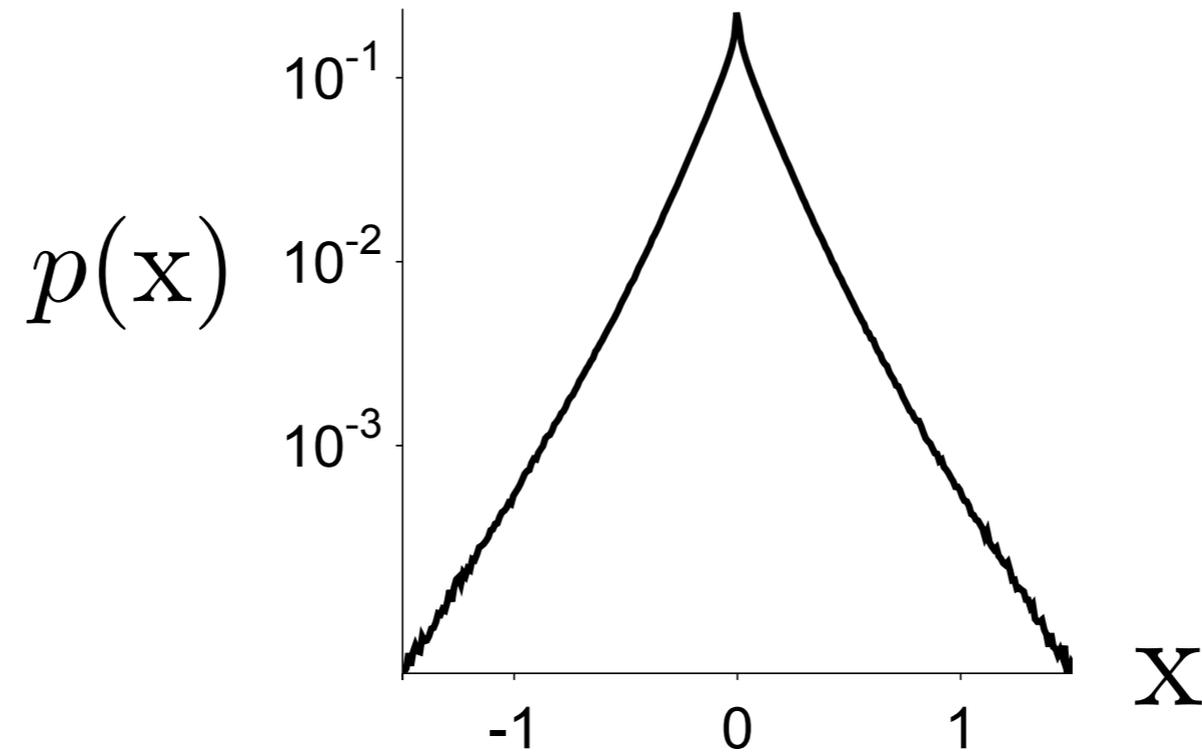
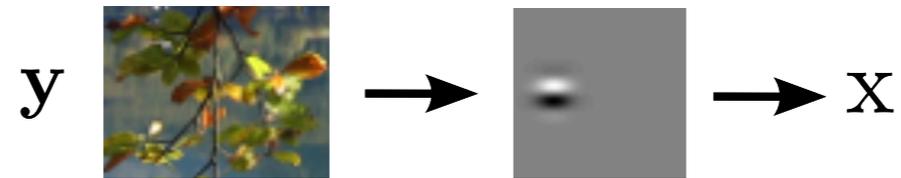
Pixel korrelációk



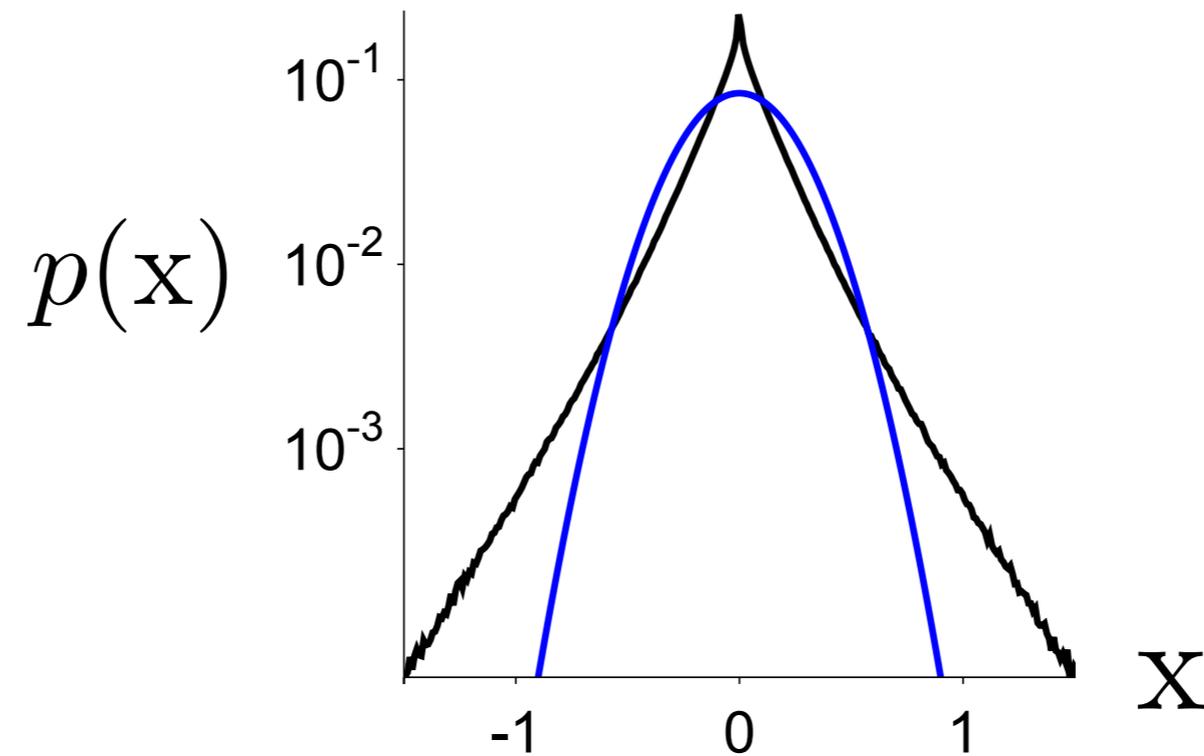
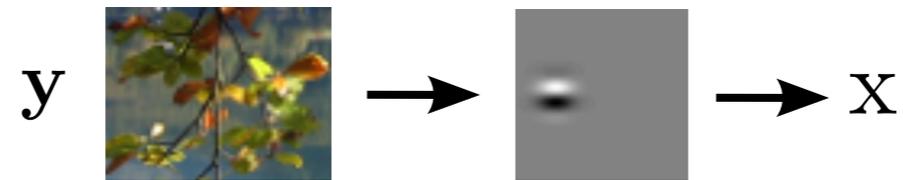
Magasabb rendű korrelációk: ritkaság



Magasabb rendű korrelációk: ritkaság



Magasabb rendű korrelációk: ritkaság



Sparse kódolás, ICA

- “z”-k függetlenek
- y priorja “ritka” ($P(z)$)

Sparse kódolás, ICA

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

- “z”-k függetlenek
- y priorja “ritka” ($P(z)$)

Sparse kódolás, ICA

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

- “z”-k függetlenek
- y priorja “ritka” ($P(z)$)

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:

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

Sparse kód tanulása: E-M

Algoritmus:

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

Adott konnektivitási mátrix esetén a legjobb aktivitások megtalálása:

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

Sparse kód tanulása: E-M

Algoritmus:

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

Adott konnektivitási mátrix esetén a legjobb aktivitások 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:

Sparse kód tanulása: E-M

Algoritmus:

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

Adott konnektivitási mátrix esetén a legjobb aktivitások megtalálása:

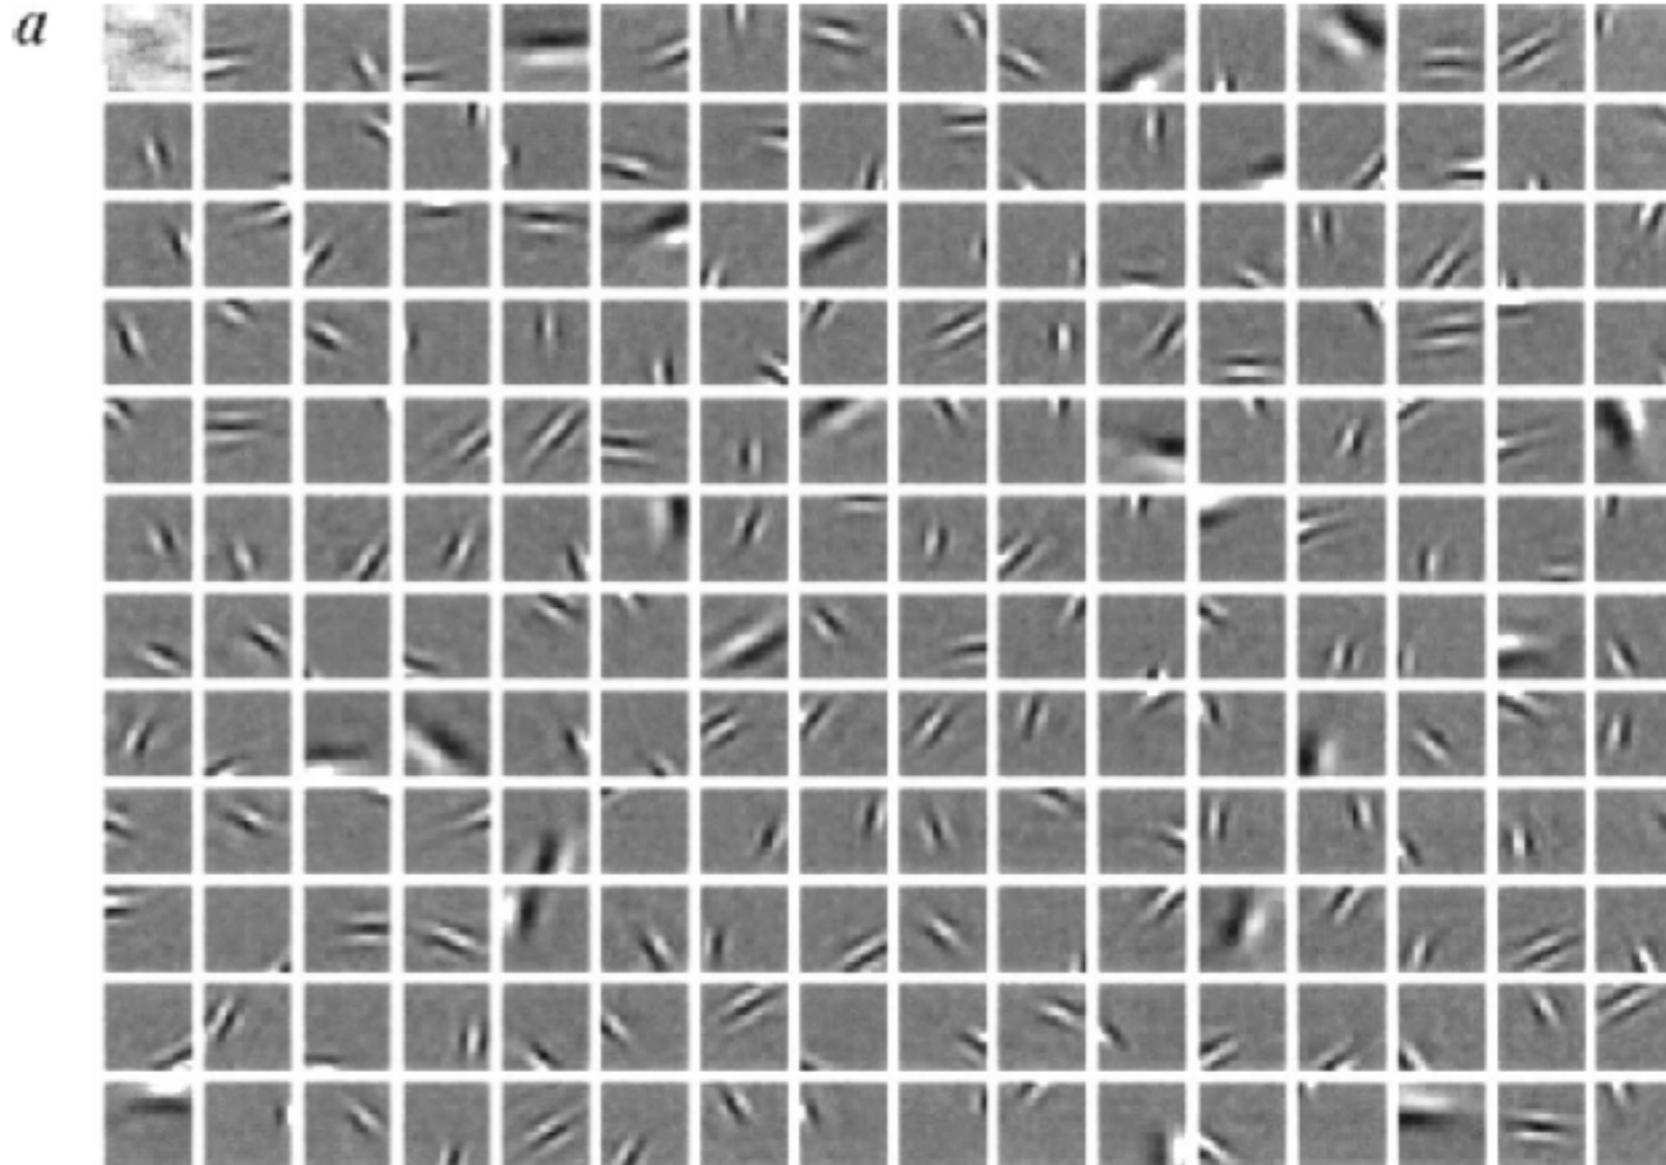
$$\dot{z}_i = \mathbf{A}_i x_t - \sum_j \mathbf{A}'_i \mathbf{A}_j z_j - \frac{\lambda}{\sigma} S' \left(\frac{z_i}{\sigma} \right)$$

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

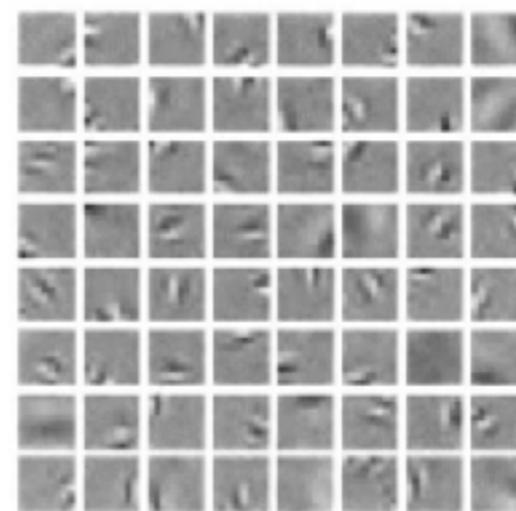
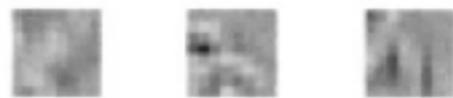
A kialakult bázis:

- irányított
- térbeli sávszűrést valósít meg
- lokalizált

Tanulás és stimulus statisztika

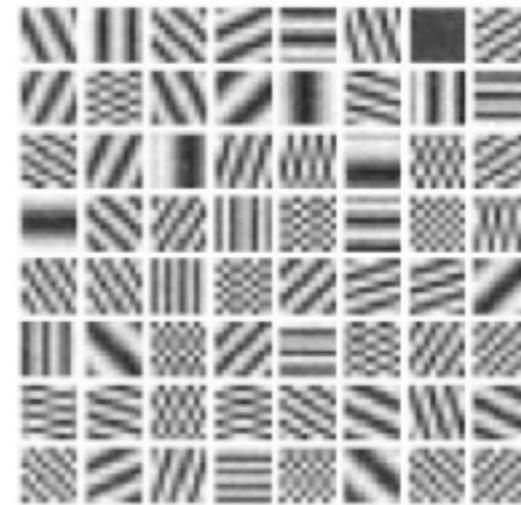
c

Sparse gabors

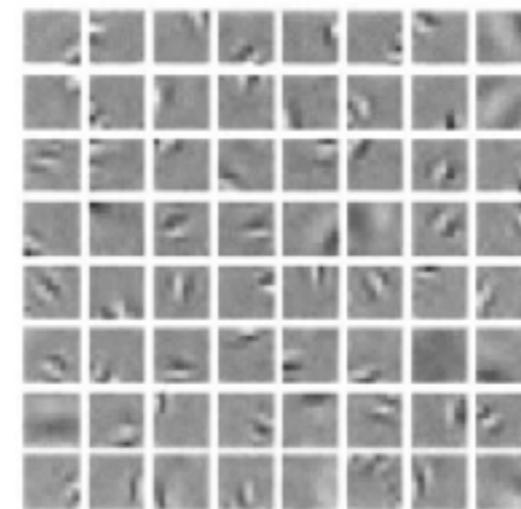


Tanulás és stimulus statisztika

b Sparse gratings

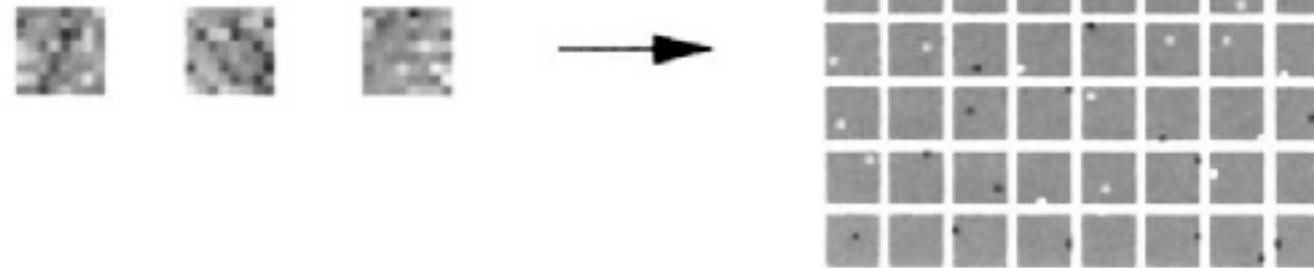


c Sparse gabors



Tanulás és stimulus statisztika

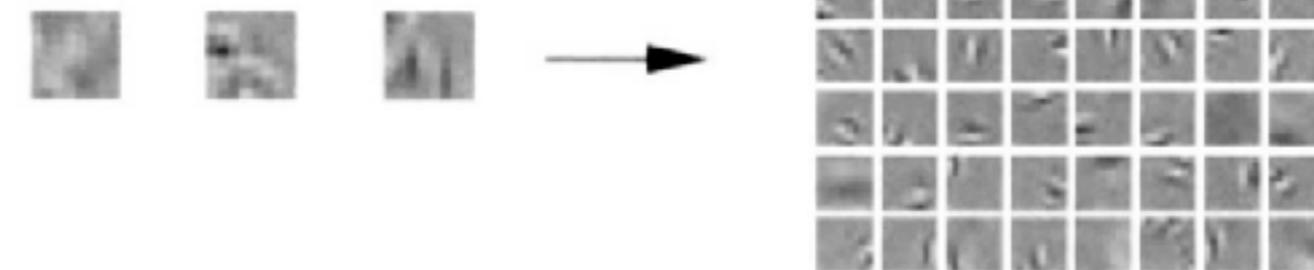
a Sparse pixels



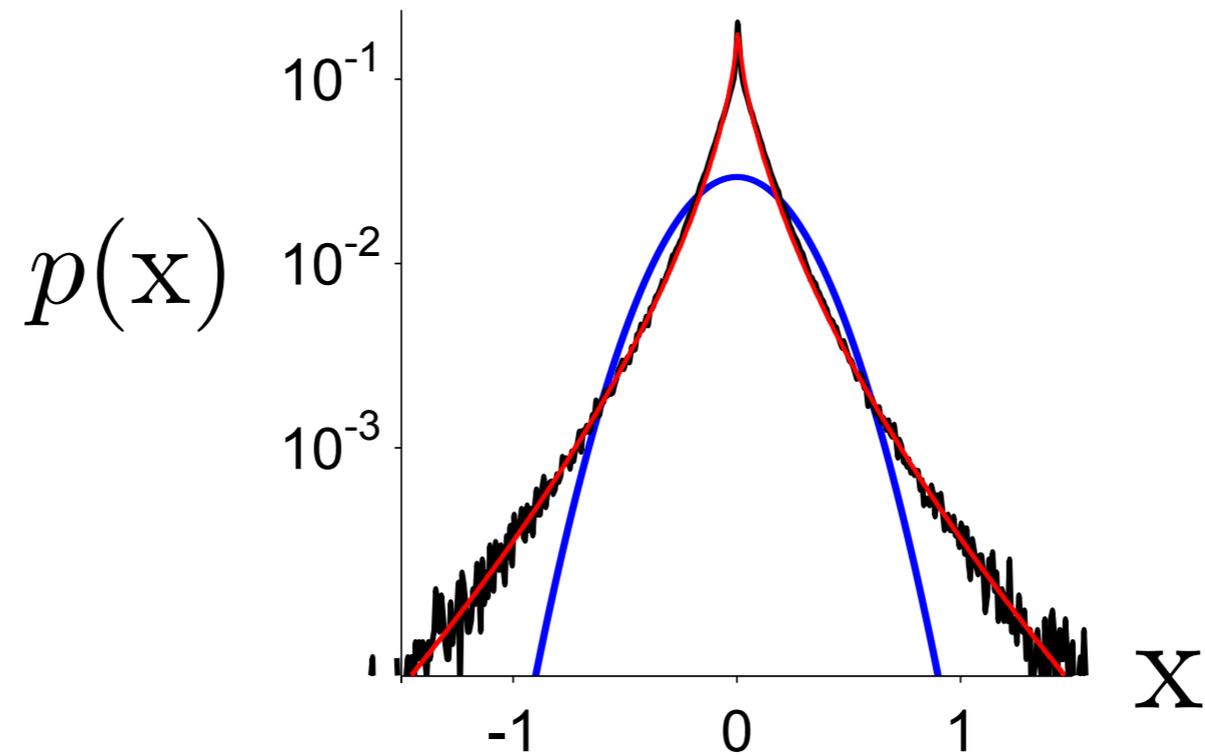
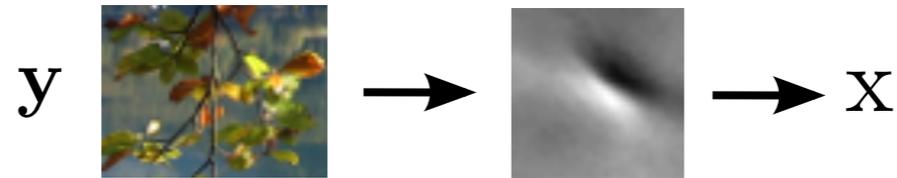
b Sparse gratings



c Sparse gabors



Magasabb rendű korrelációk: ritkaság

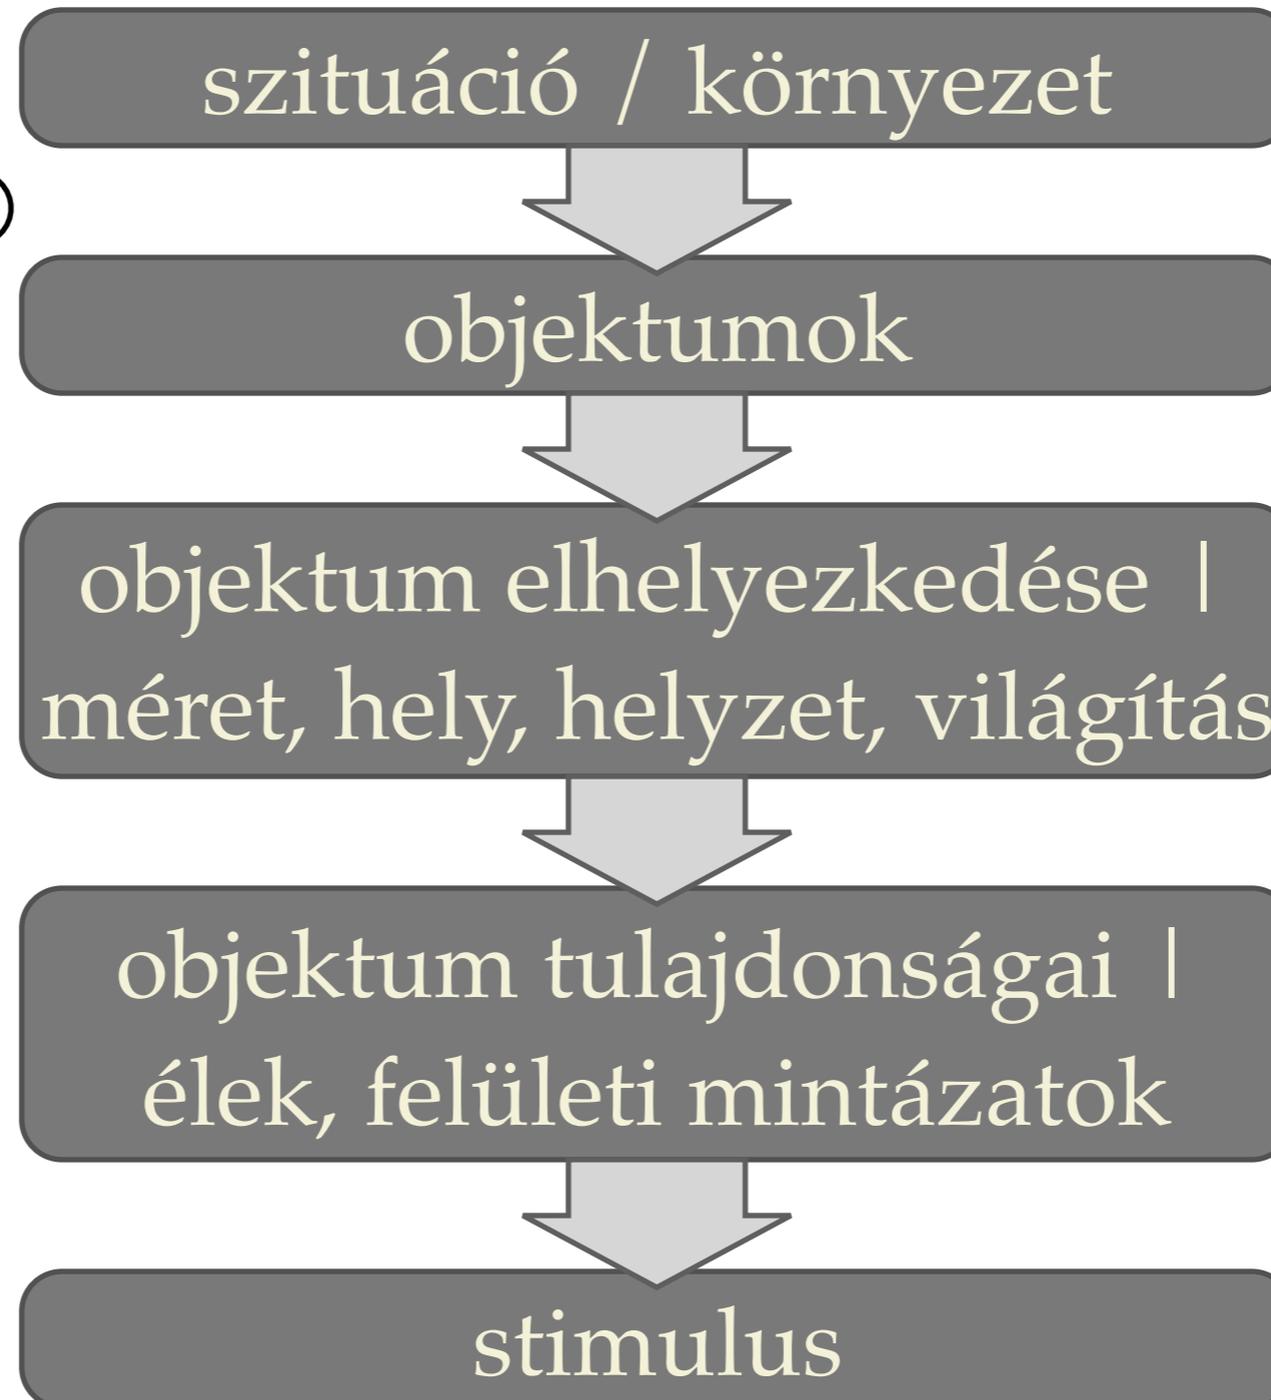
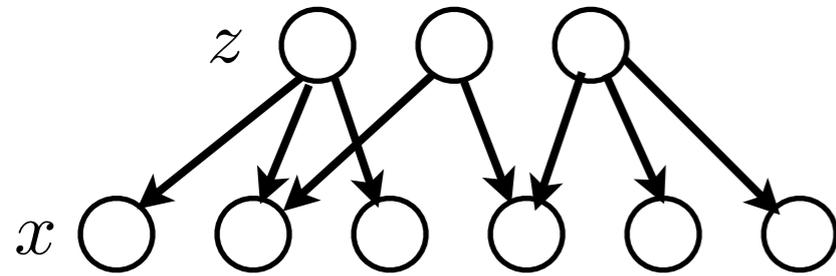


Generatív/rekogníciós modell

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

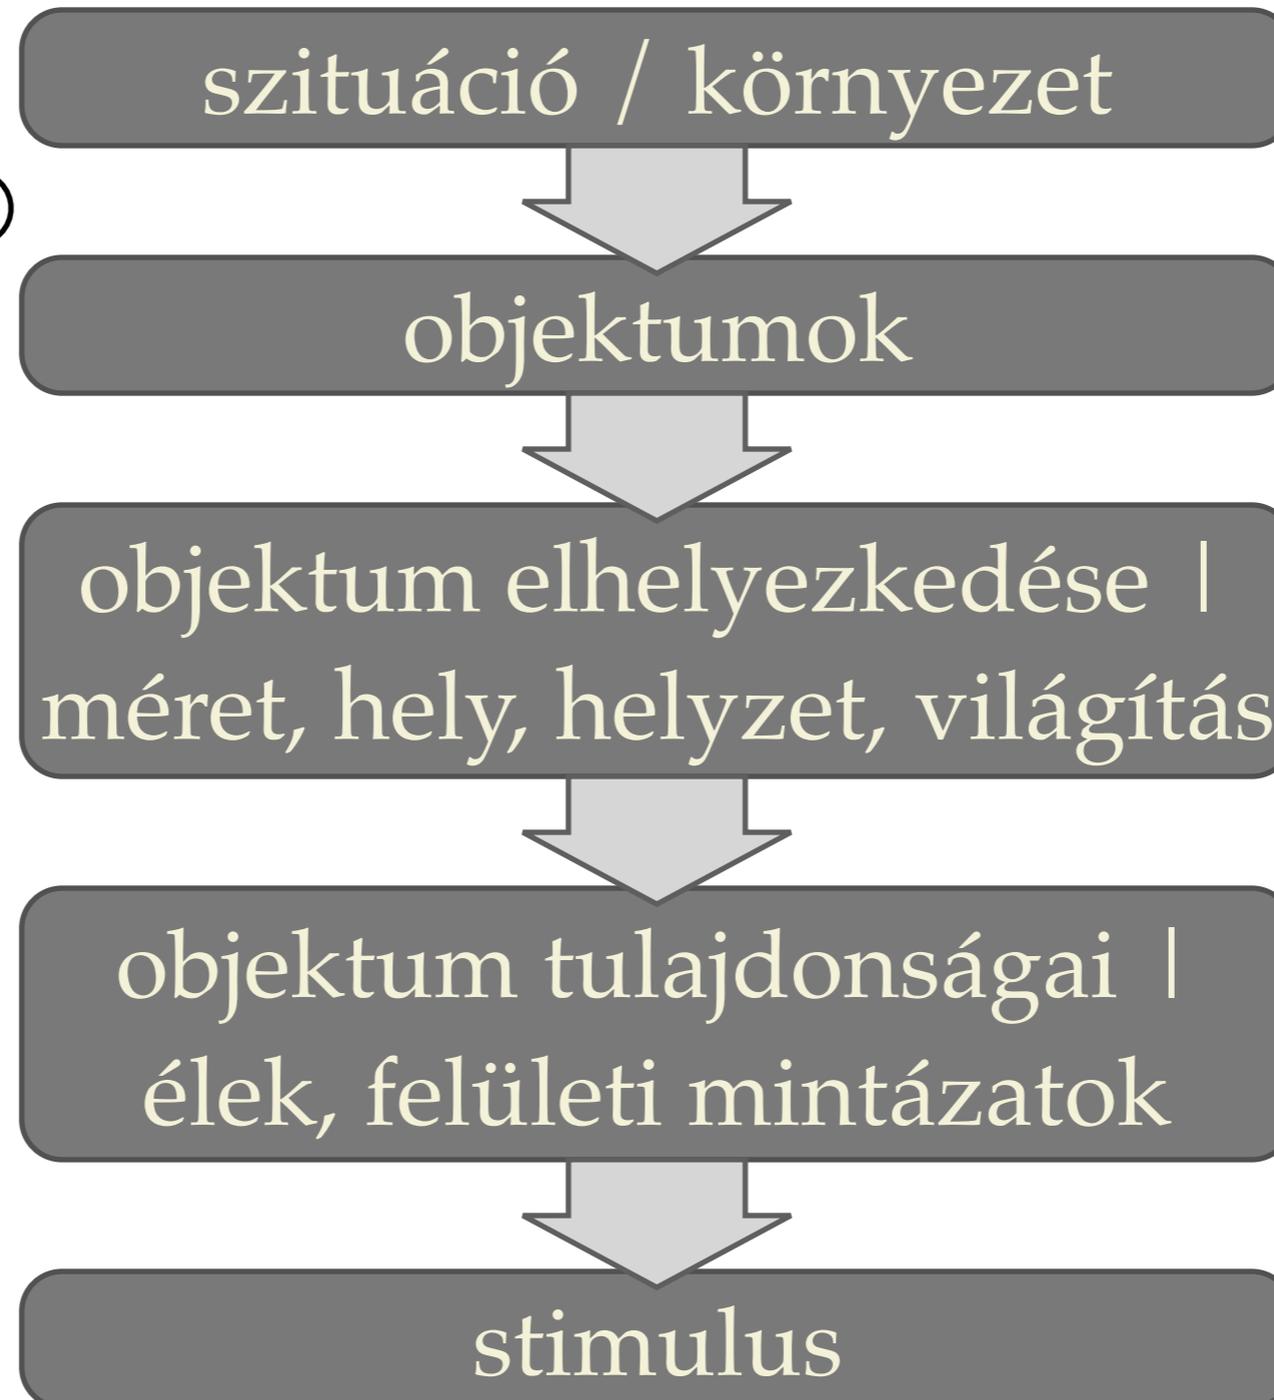
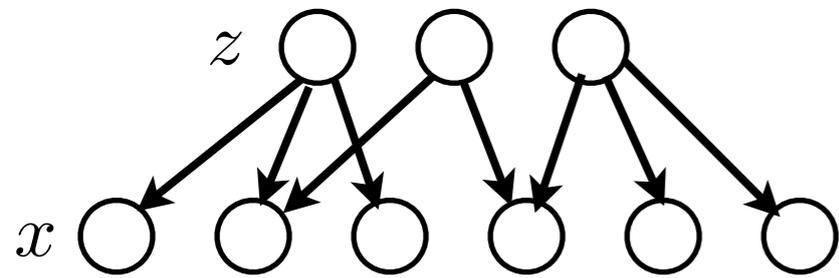
Generatív/rekogníciós modell

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



Generatív/rekogníciós modell

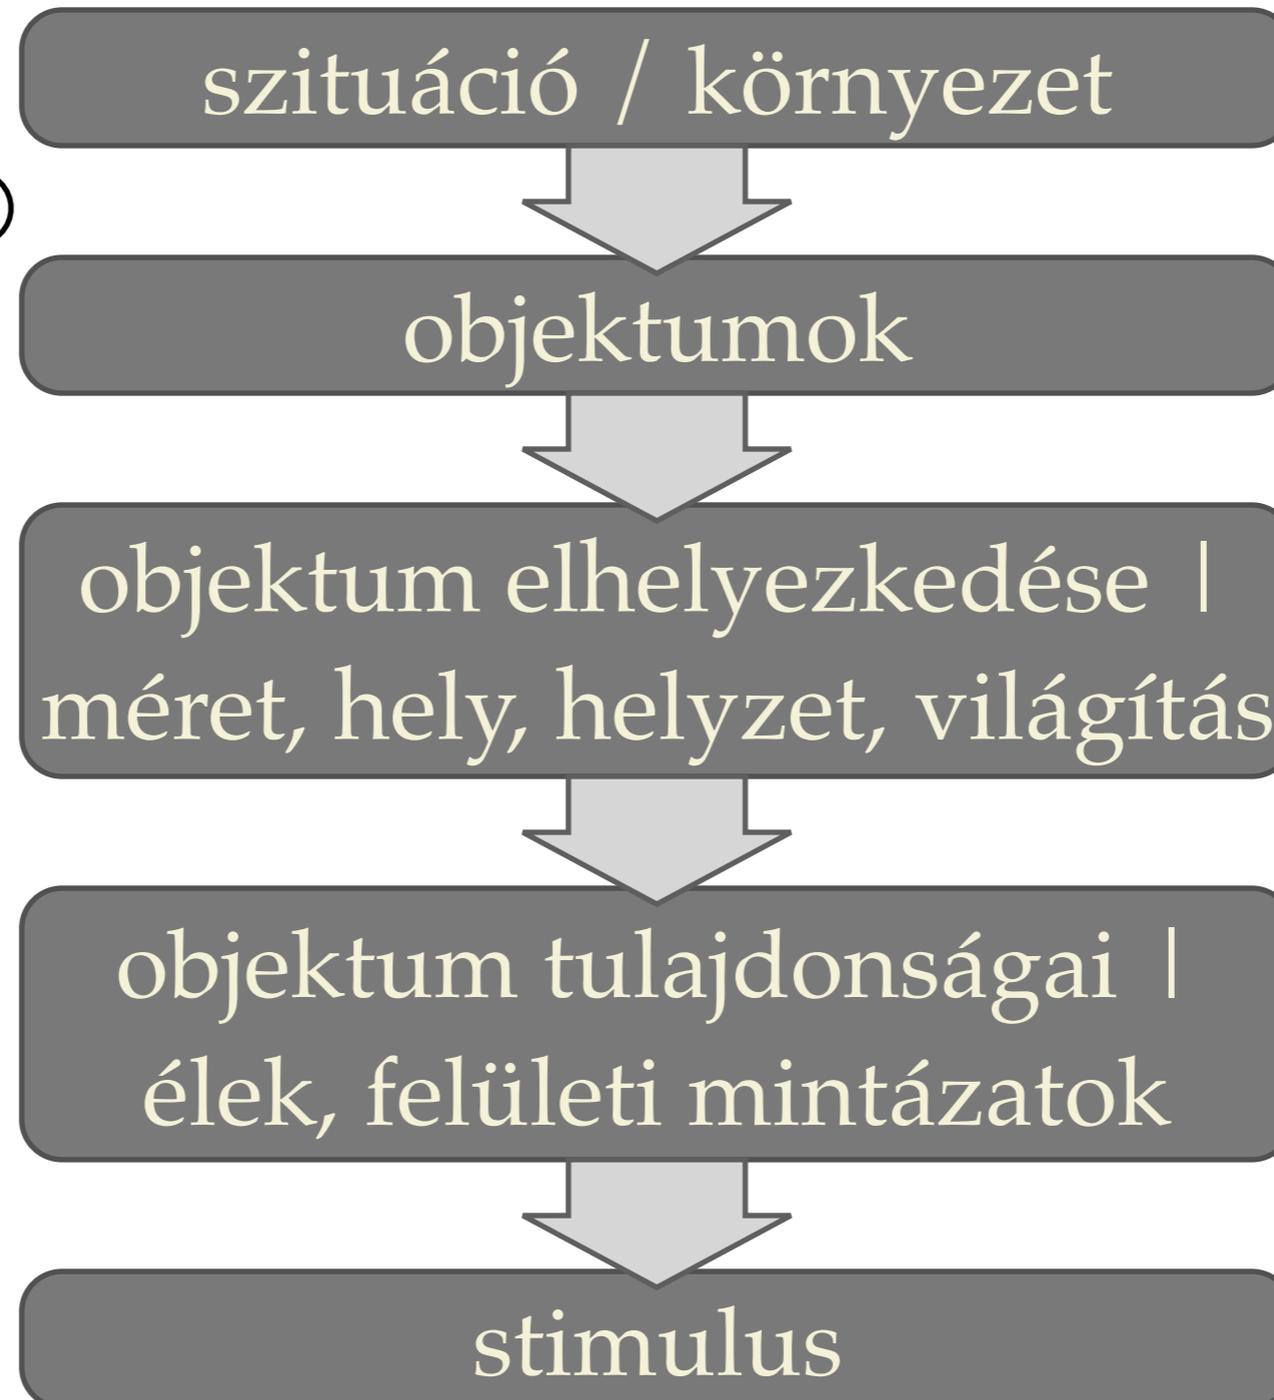
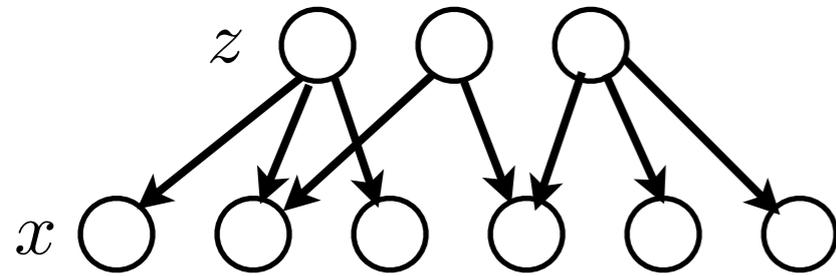
$$P(\mathbf{x}) = P(\mathbf{x} | \mathbf{z}) P(\mathbf{z})$$



generatív modell

Generatív/rekogníciós modell

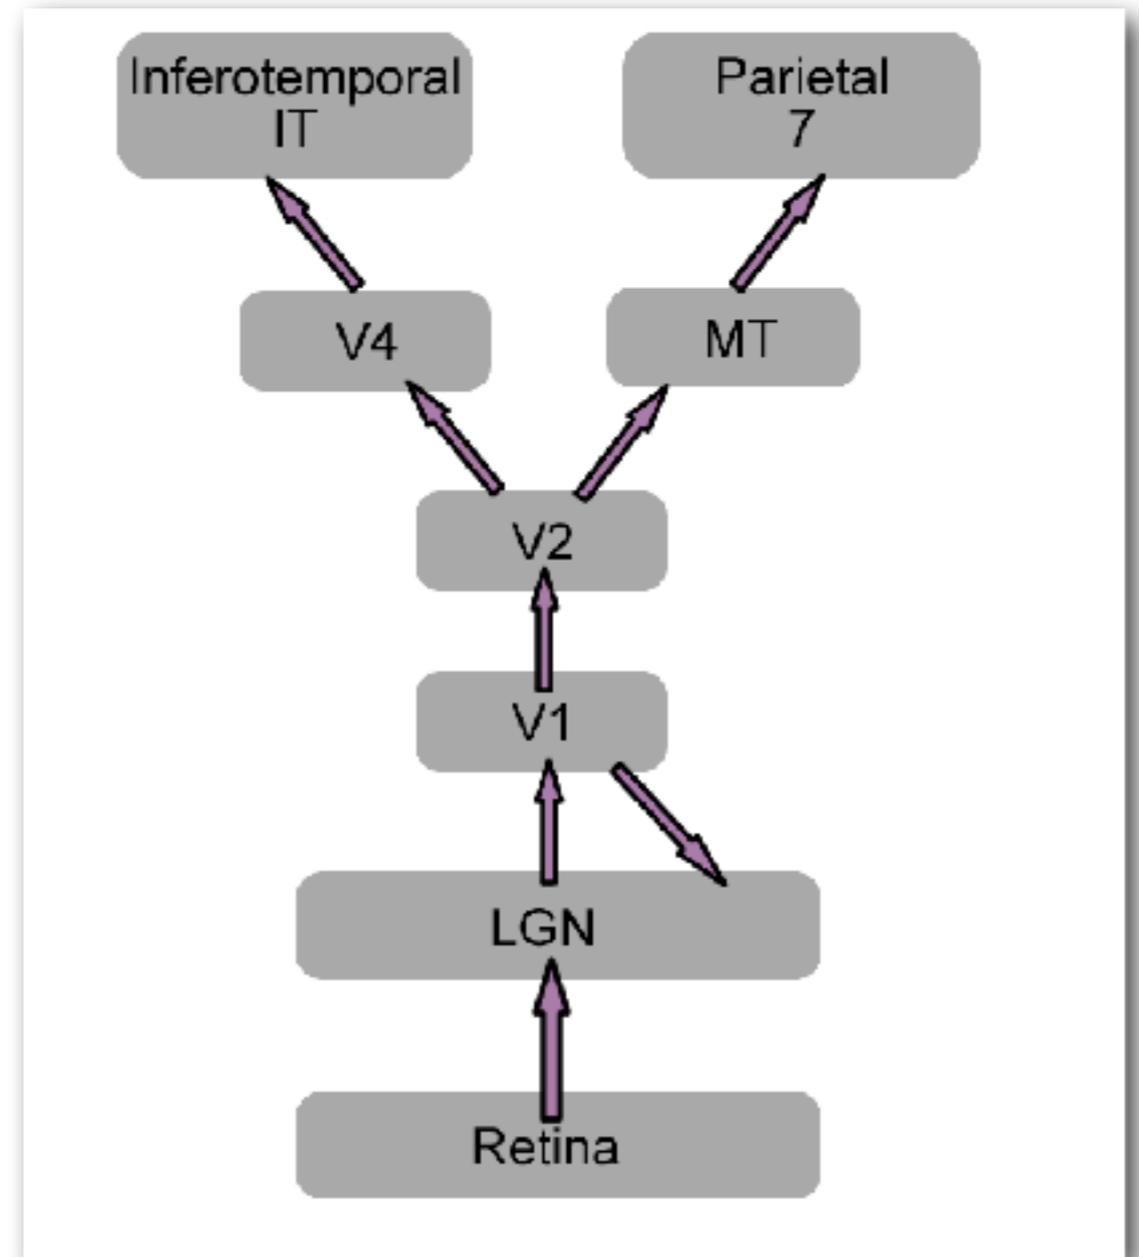
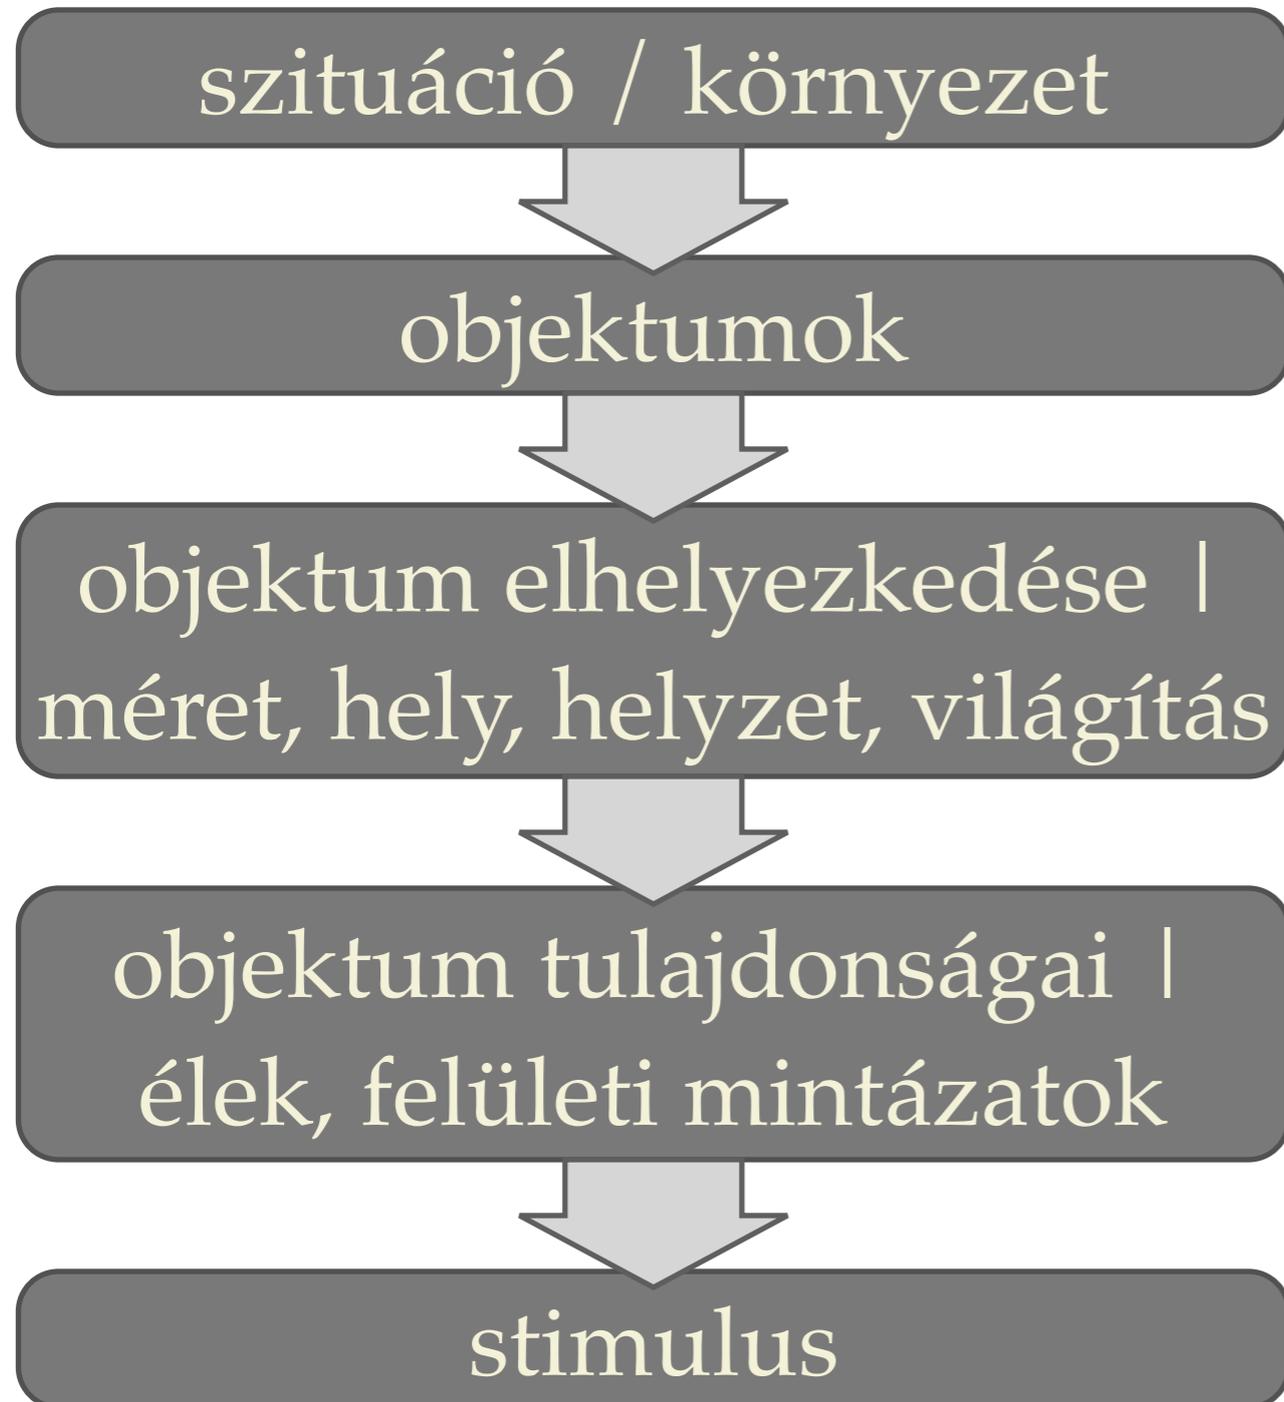
$$P(\mathbf{x}) = P(\mathbf{x} | \mathbf{z}) P(\mathbf{z})$$



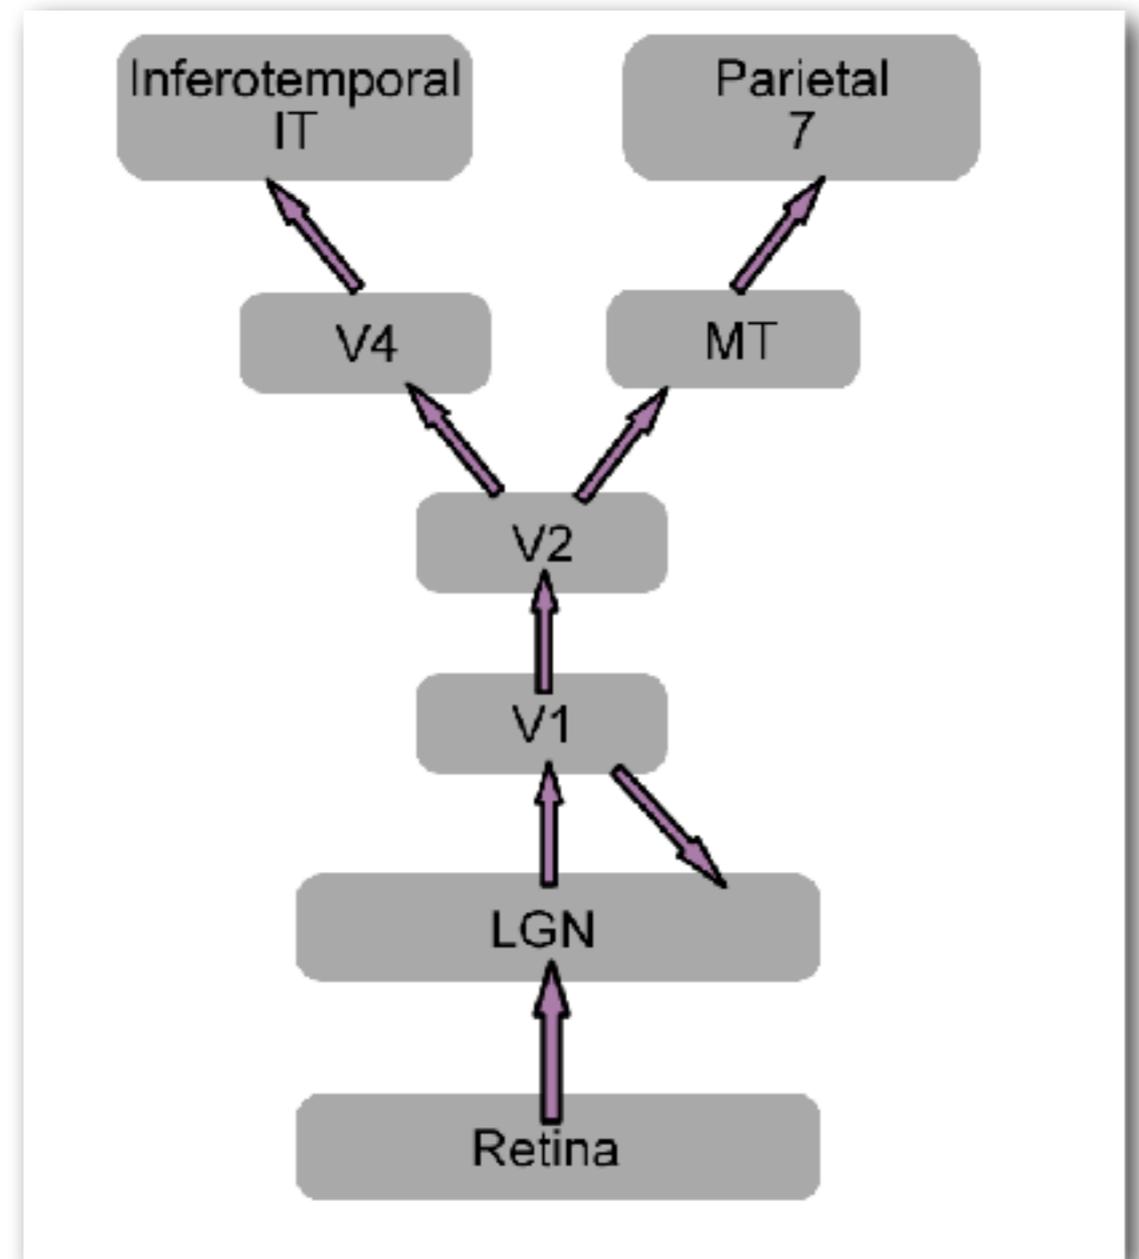
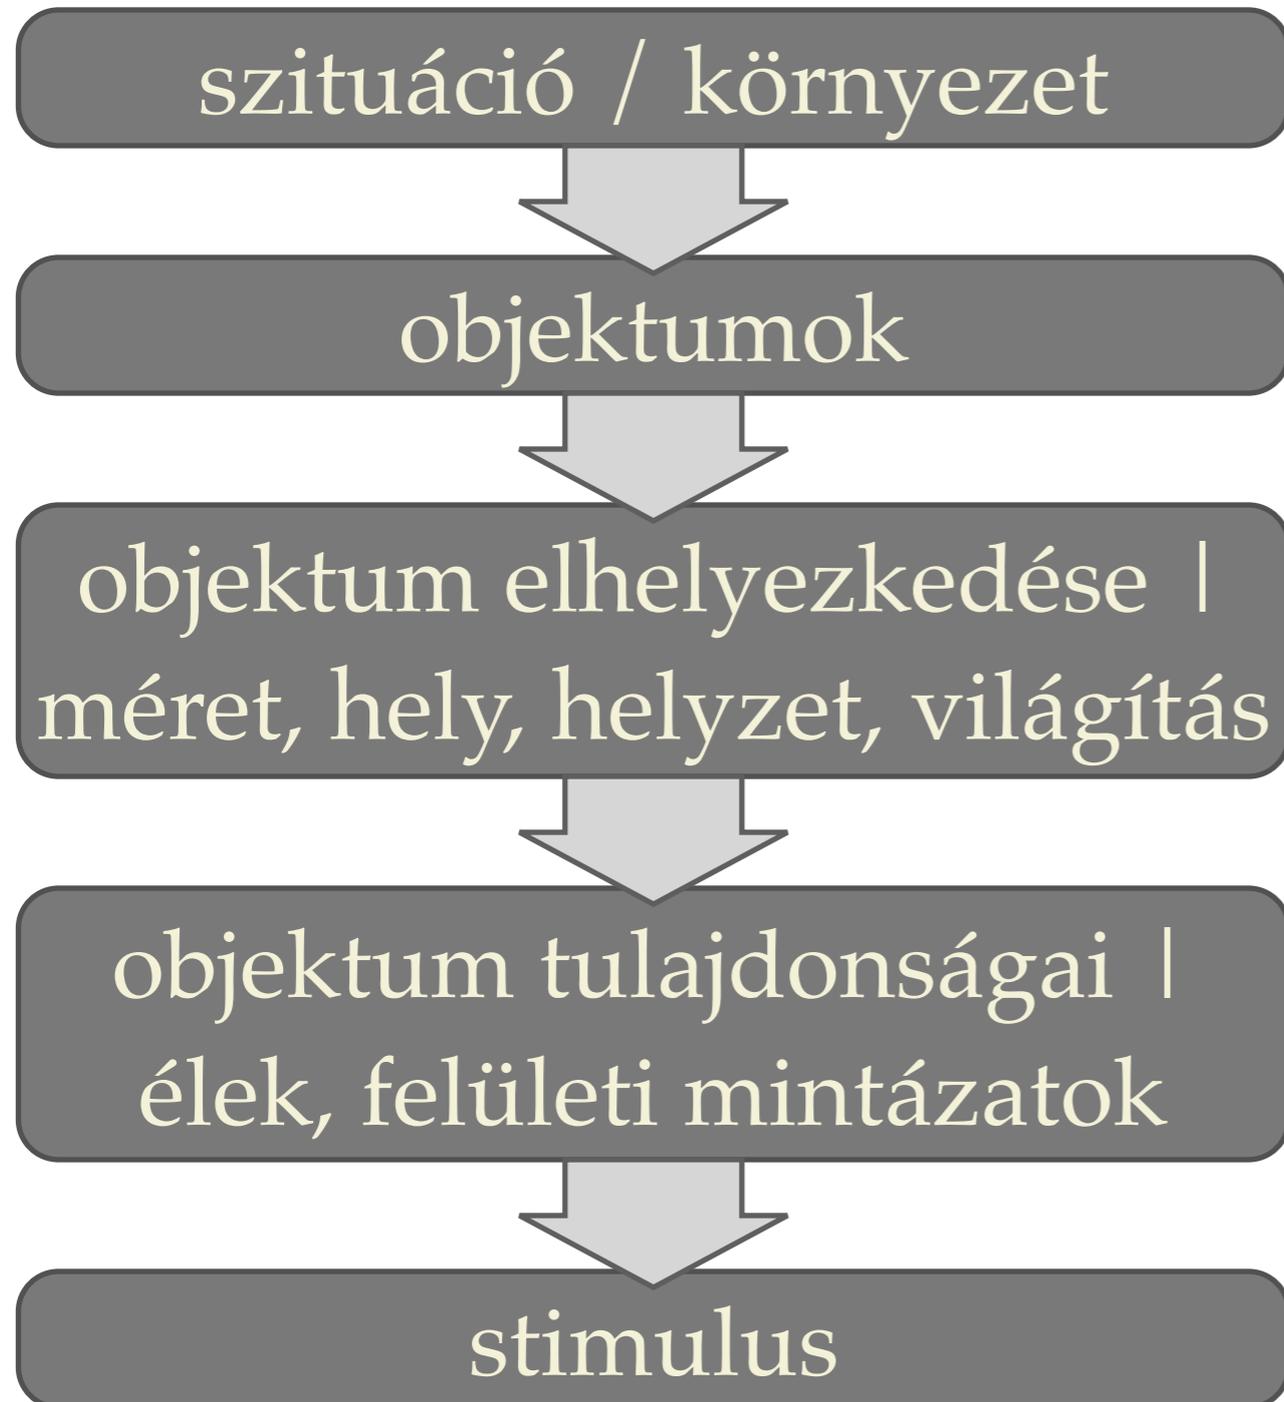
generatív modell

inferencia/felismerés

Generatív/rekogníciós modell



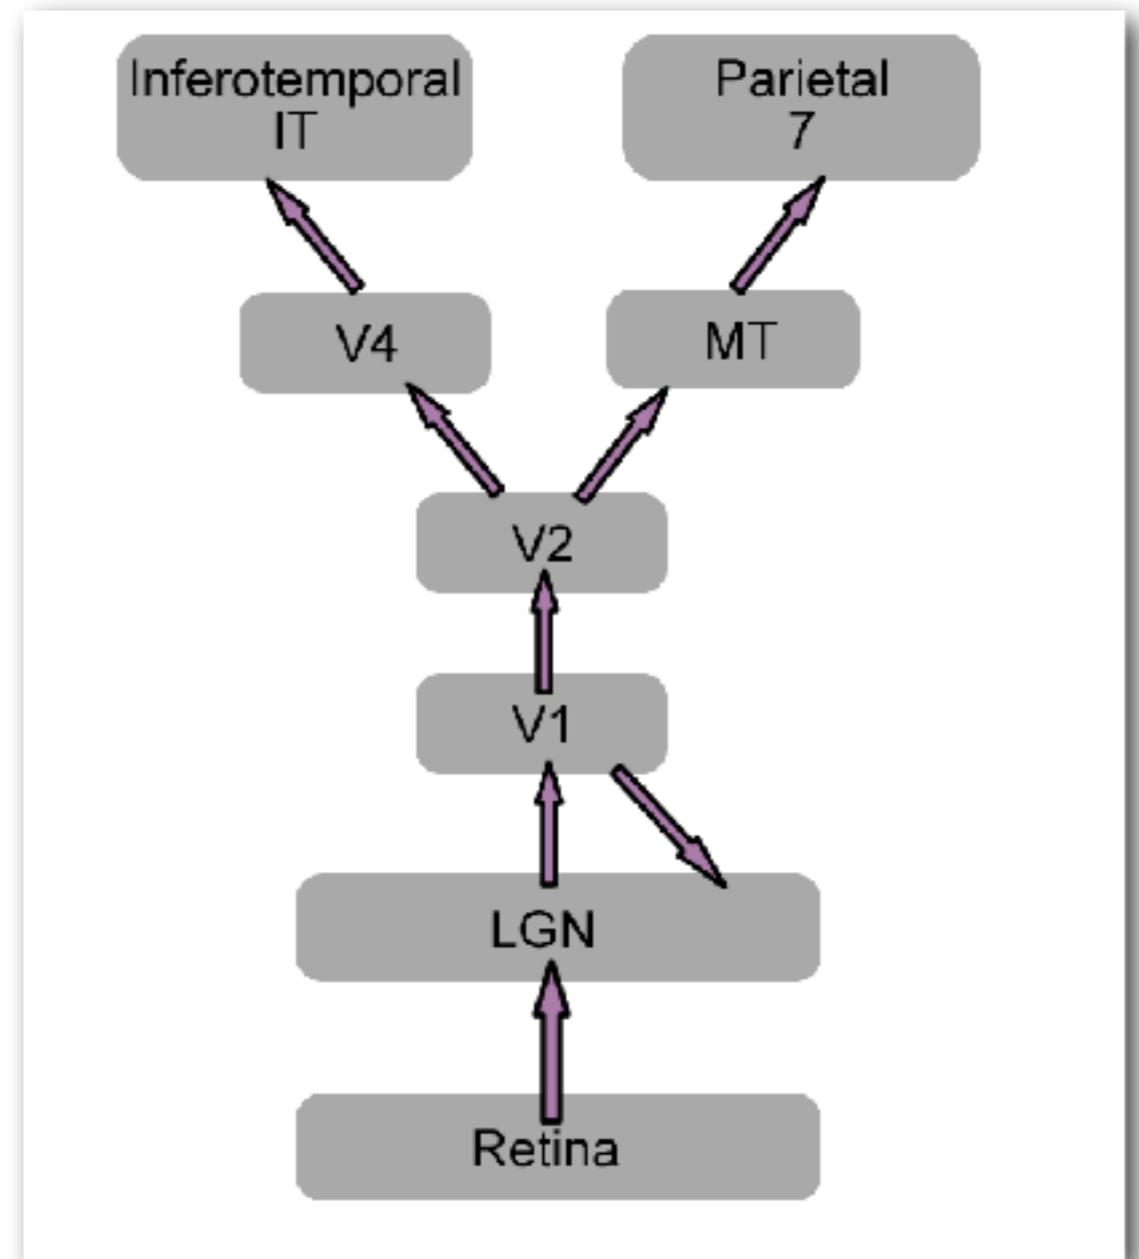
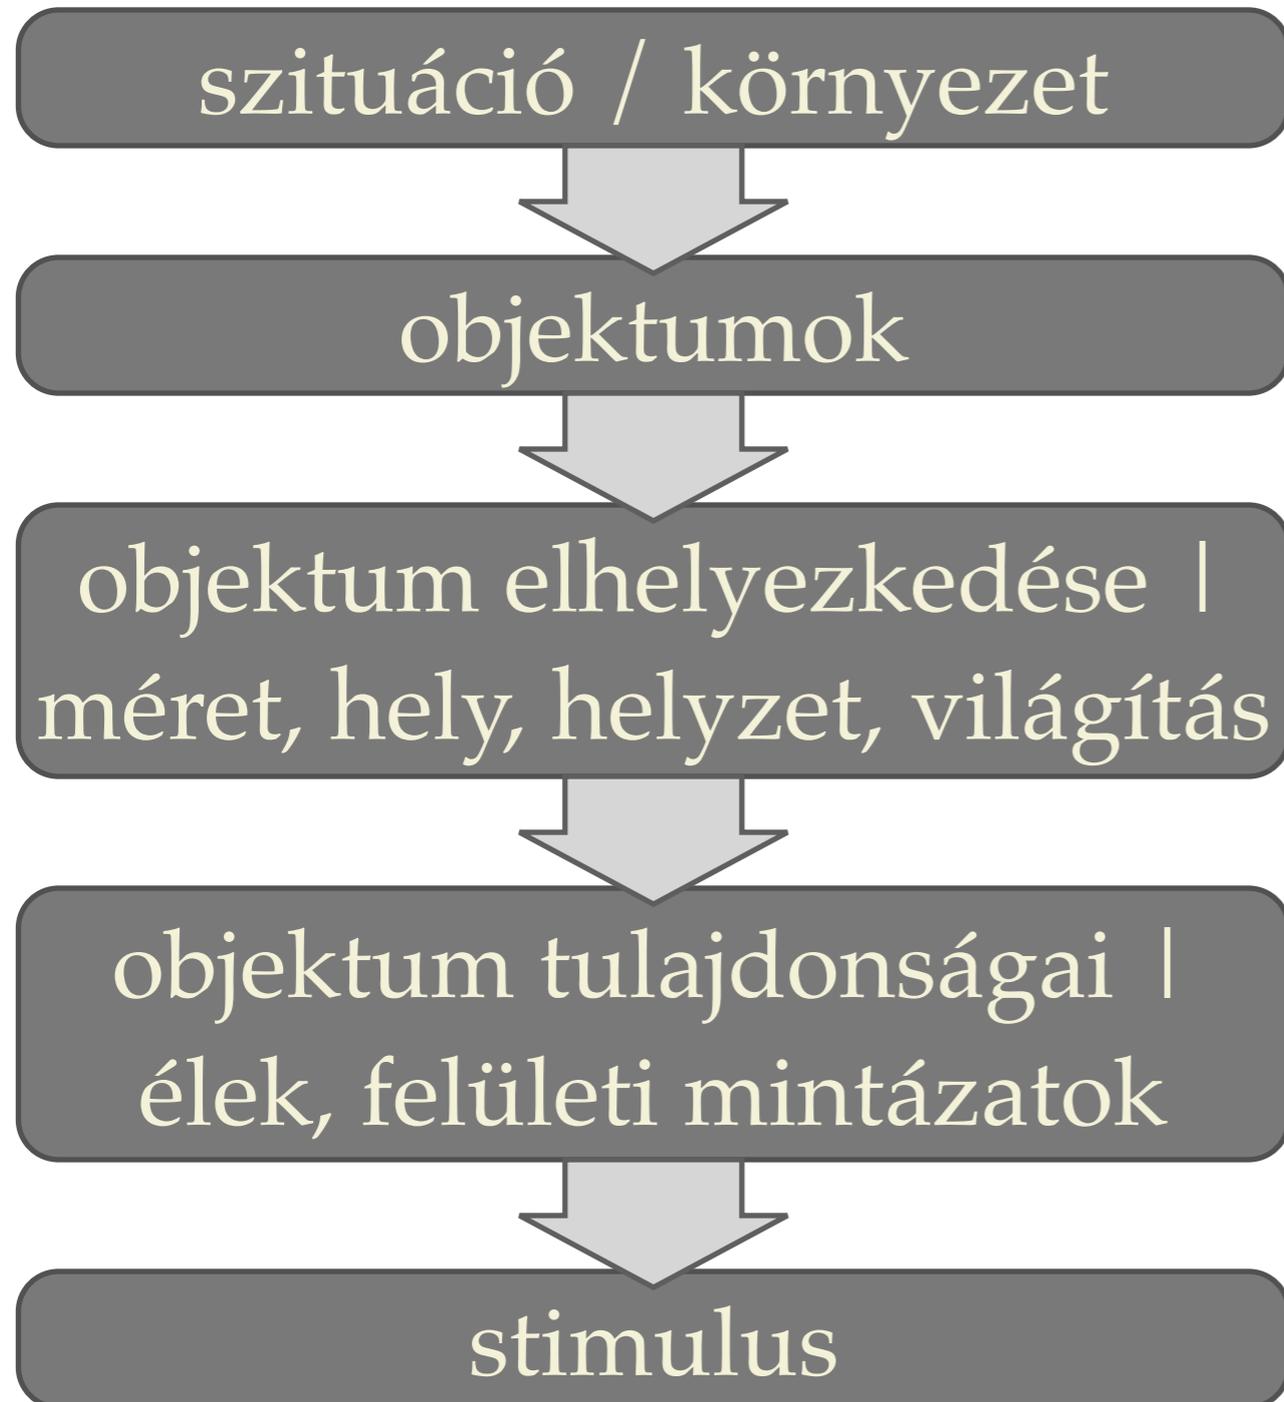
Generatív/rekogníciós modell



Modell definíció -> rekogníció:

$$P(x|z)$$

Generatív/rekogníciós modell



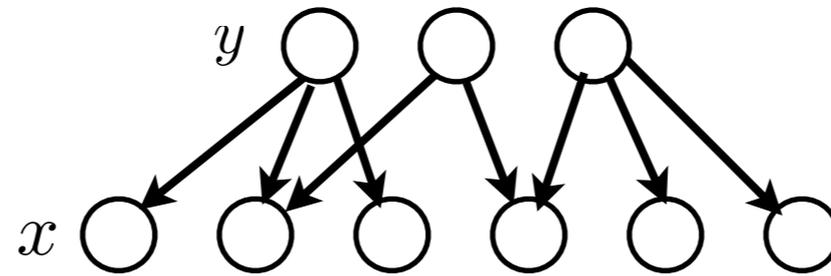
Modell definíció -> rekogníció:

$$P(x|z)$$

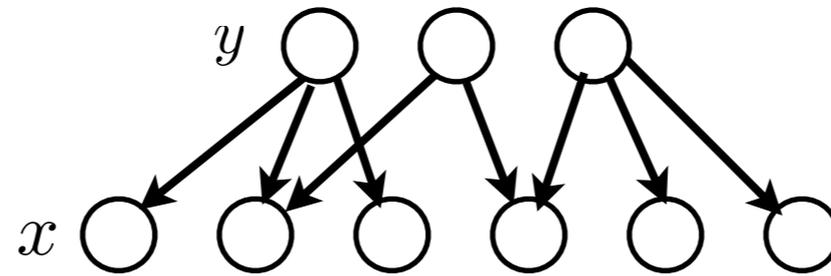
Inferencia igénye -> rekogníció:

$$P(z|x)$$

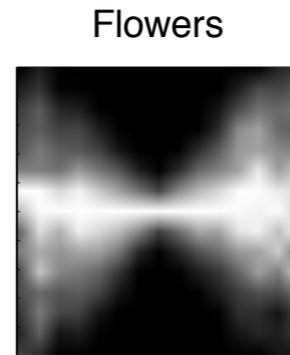
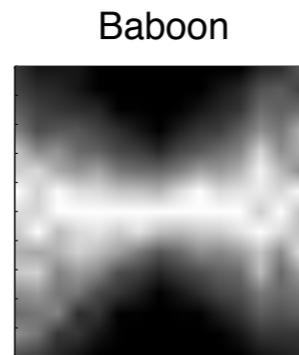
Independens komponensek



Independens komponensek

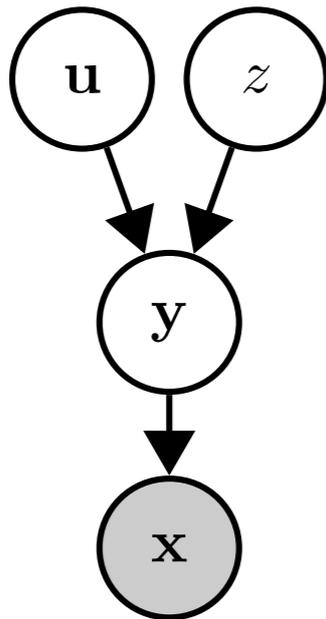


a



Schwartz & Simoncelli, 2001

Gaussian Scale Mixtures



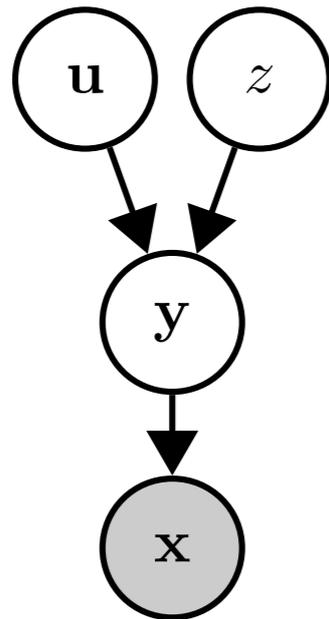
$$P(\mathbf{x}|\mathbf{y}) = \mathcal{N}(\mathbf{x}; \mathbf{A}\mathbf{y}, \sigma_{\mathbf{x}}^2 \mathbf{I})$$

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

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

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

Gaussian Scale Mixtures



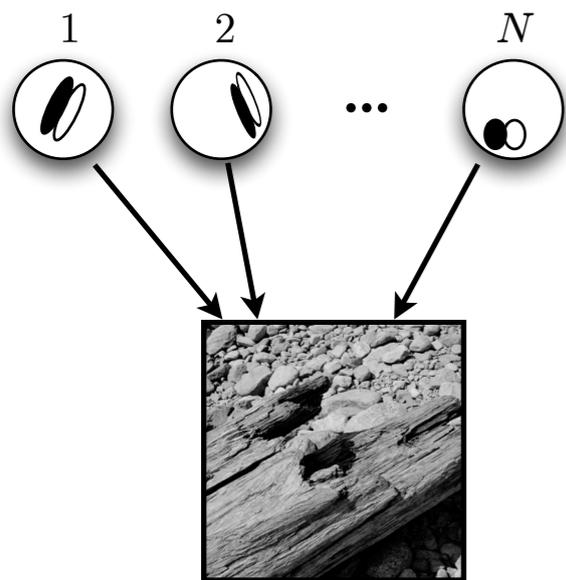
$$P(\mathbf{x}|\mathbf{y}) = \mathcal{N}(\mathbf{x}; \mathbf{A}\mathbf{y}, \sigma_x^2 \mathbf{I})$$

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

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

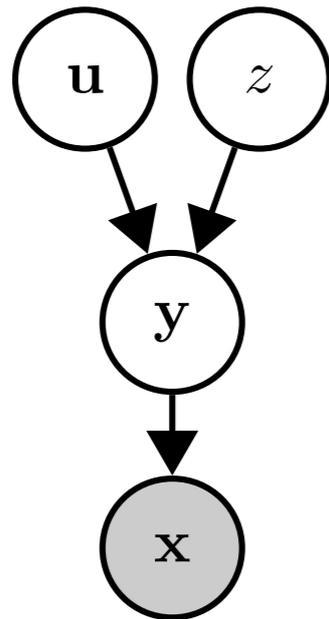
$$P(z) = \text{Gamma}(z; k, \theta)$$

linear features



image

Gaussian Scale Mixtures



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

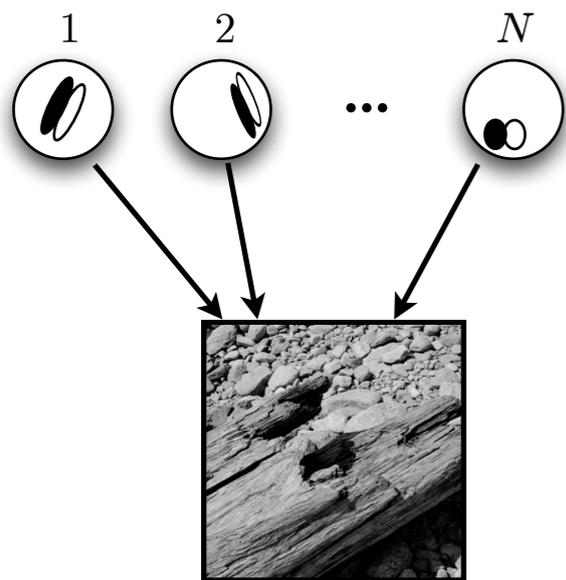
$$\mathbf{y} = z \mathbf{u}$$

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

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

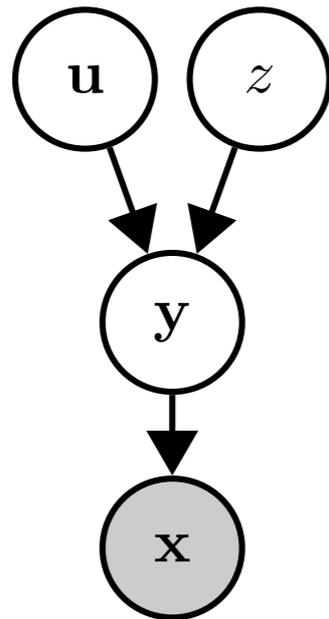
linear features

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



image

Gaussian Scale Mixtures



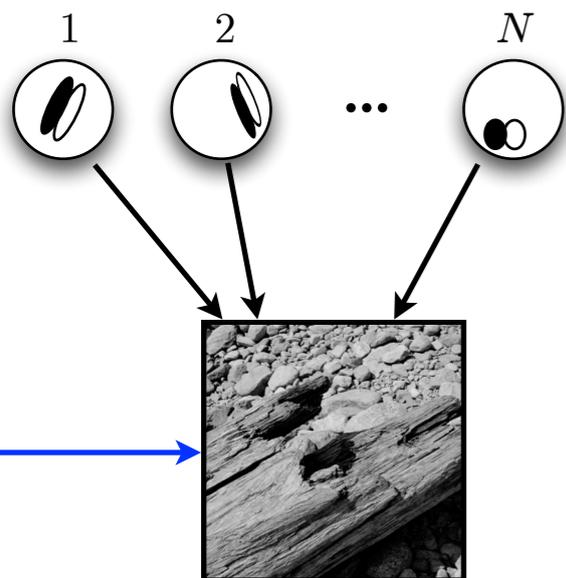
$$P(\mathbf{x}|\mathbf{y}) = \mathcal{N}(\mathbf{x}; \mathbf{A}\mathbf{y}, \sigma_x^2 \mathbf{I})$$

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

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

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

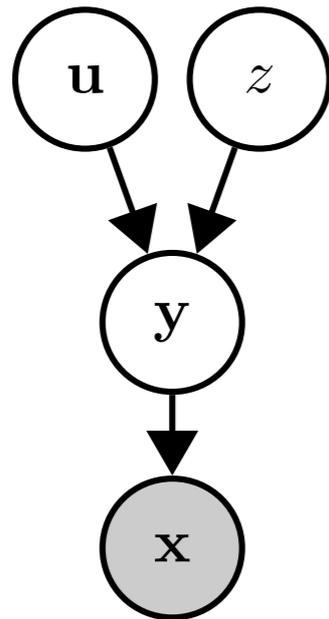
linear features



image

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

Gaussian Scale Mixtures



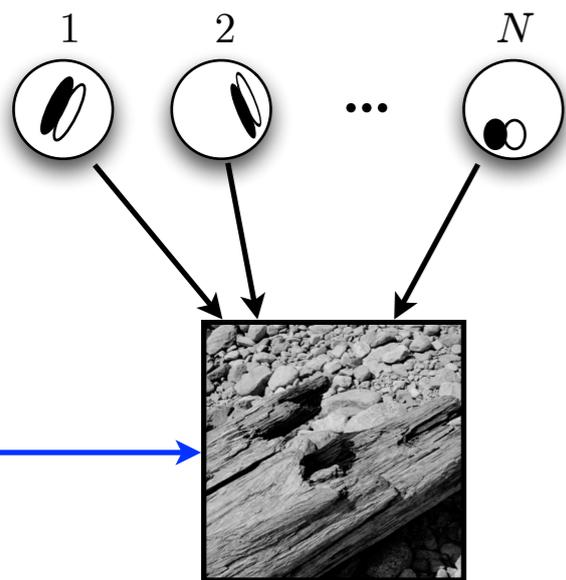
$$P(\mathbf{x}|\mathbf{y}) = \mathcal{N}(\mathbf{x}; \mathbf{A}\mathbf{y}, \sigma_x^2 \mathbf{I})$$

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

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

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

linear features



image

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

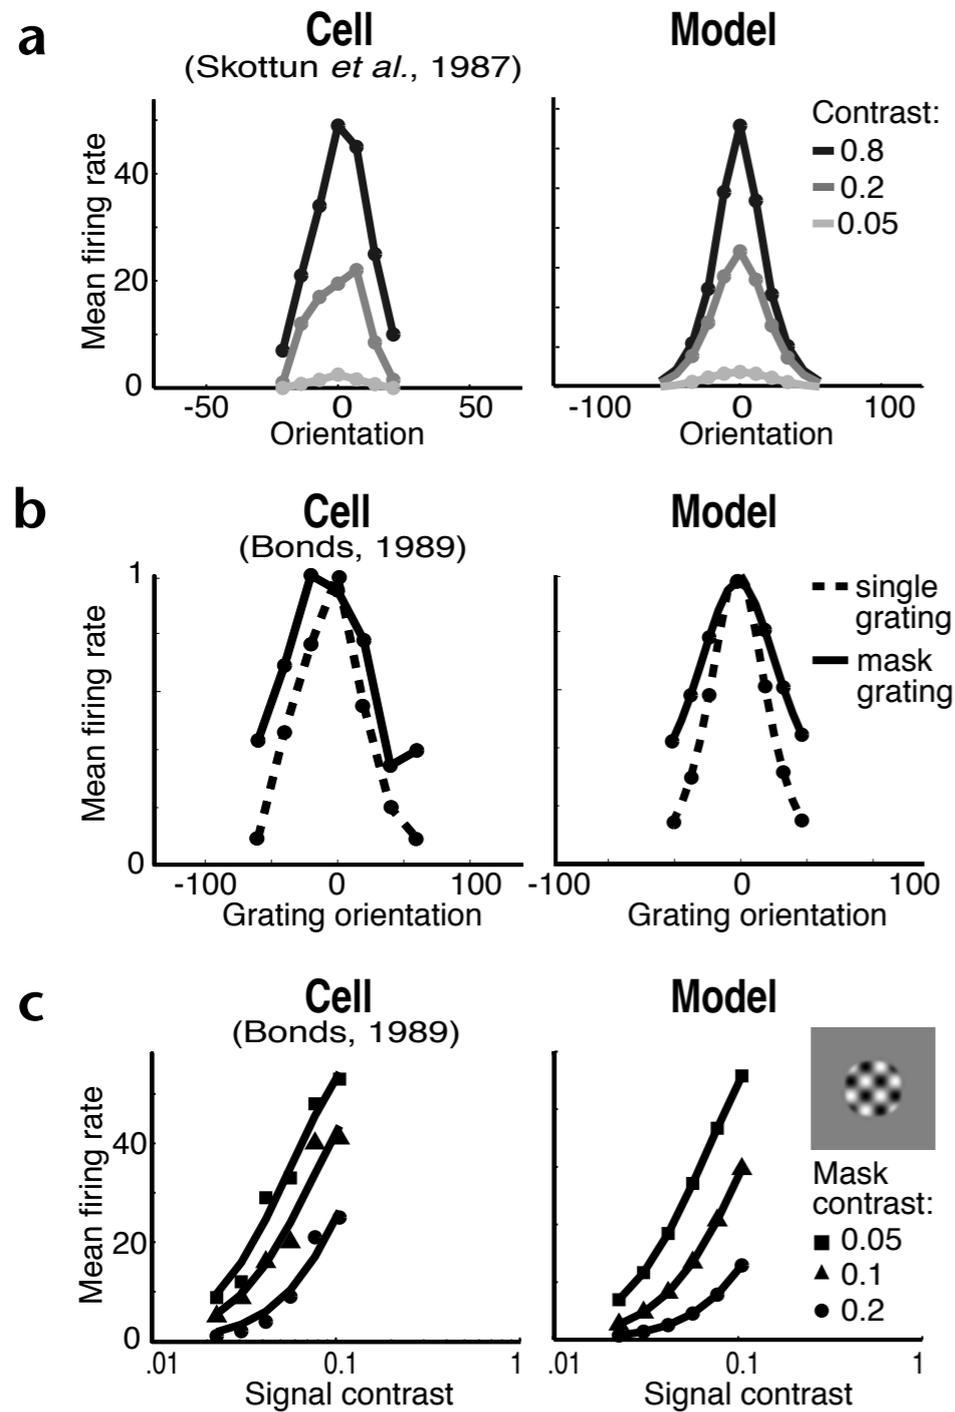
$$\text{var}(L_1|L_2) = wL_2^2 + \sigma^2$$

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

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

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

Neurális adatok és GSM



Schwartz & Simoncelli, 2001

