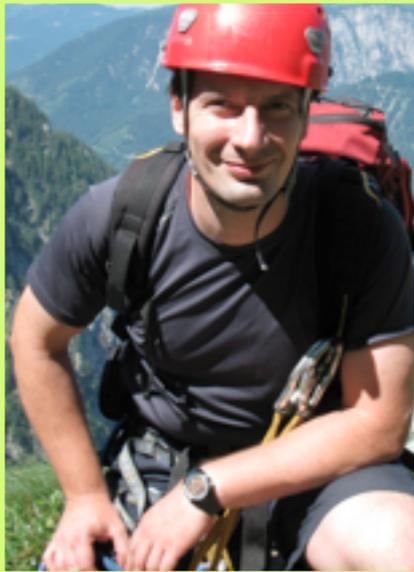


Statisztikus tanulás az idegrendszerben

ORBÁN GERGŐ

<http://golab.wigner.mta.hu>



Somogyvári Zoltán



Bányai Mihály

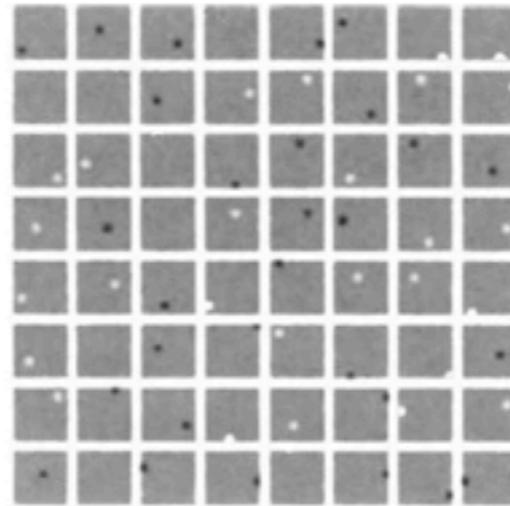
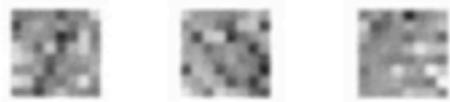


Orbán Gergő

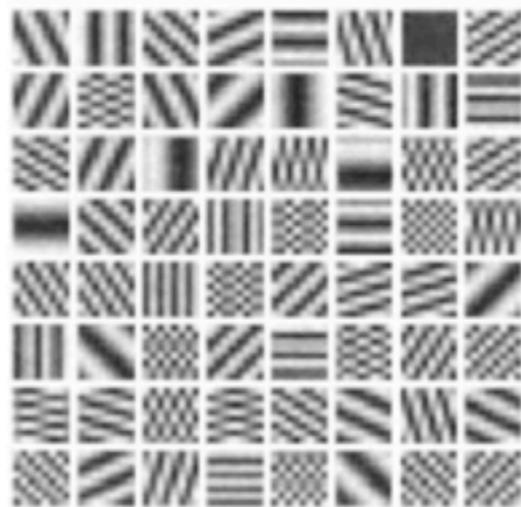
1. Bevezetés - G
2. Perceptron, előrecsatolt hálózatok
3. Rekurrens hálózatok, a Hopfield hálózat
4. Rejtett változós modellek
5. Reprezentációs tanulás
6. Eloszlások tanulása, a Boltzmann-gép
7. MAP paraméterbecslés, bayesi modelösszehasonlítás
8. Az EM-algoritmus, keverékmodellek
9. Az EM speciális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

RECAP: Statisztikai tanulás

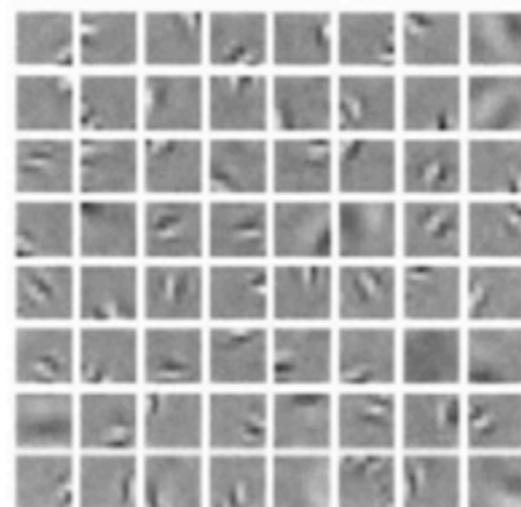
a Sparse pixels



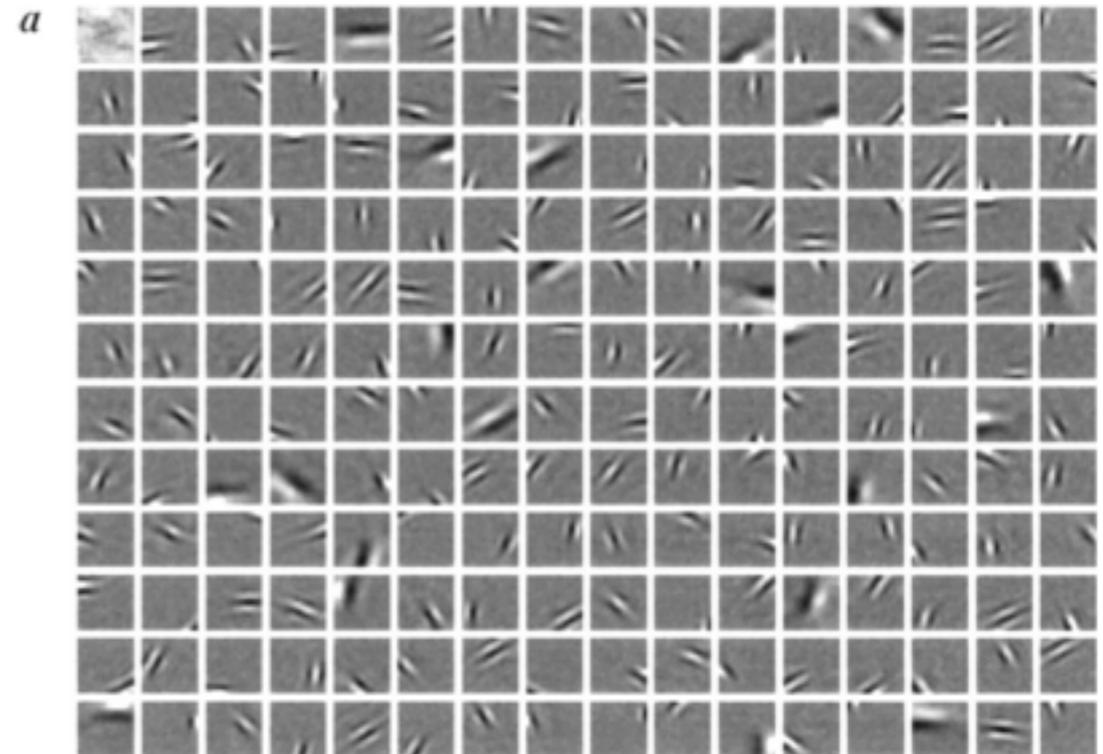
b Sparse gratings



c Sparse gabors



Natural images



Olshausen & Field '96

RECAP: Statisztikai tanulás

RECAP: Statisztikai tanulás

- A filterek/receptív mezok függenek a kepek statisztikájától

RECAP: Statisztikai tanulás

- A filterek/receptív mezok függenek a kepek statisztikájától
- A stasztika és a stílus valamiképpen összefüggenek

RECAP: Statisztikai tanulás

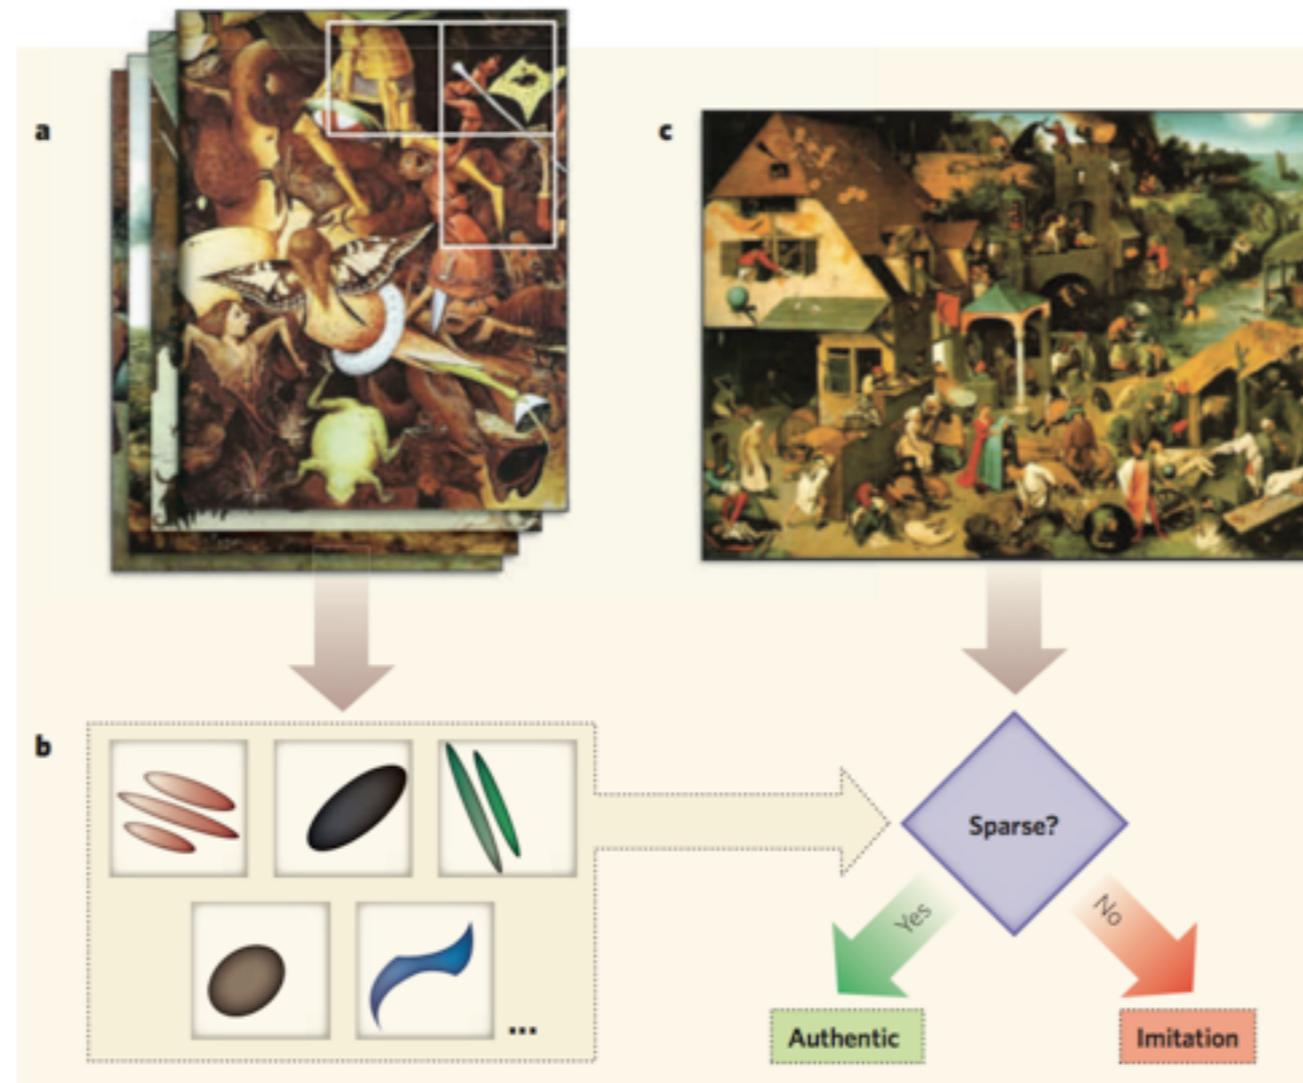
- A filterek/receptív mezok függenek a kepek statisztikájától
- A stasztika és a stílus valamiképpen összefüggenek
- A tréningező adathalmaz stílusa ‘tanulható’

RECAP: Statisztikai tanulás

- A filterek/receptív mezők függenek a képek statisztikájától
- A stasztika és a stílus valamiképpen összefüggenek
- A tréningező adathalmaz stílusa ‘tanulható’
- A tesztadathalmaz stílusa tesztelhető

RECAP: Statisztikai tanulás

- A filterek/receptív mezok függenek a kepek statisztikájától
- A stasztika és a stílus valamiképpen összefüggenek
- A tréningező adathalmaz stílusa ‘tanulható’
- A tesztadathalmaz stílusa tesztelhető



RECAP: Statisztikai tanulás

- 'EM' a lineáris ICA modellben:

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

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

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

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

RECAP: Statisztikai tanulás

- 'EM' a lineáris ICA modellben:

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

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

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

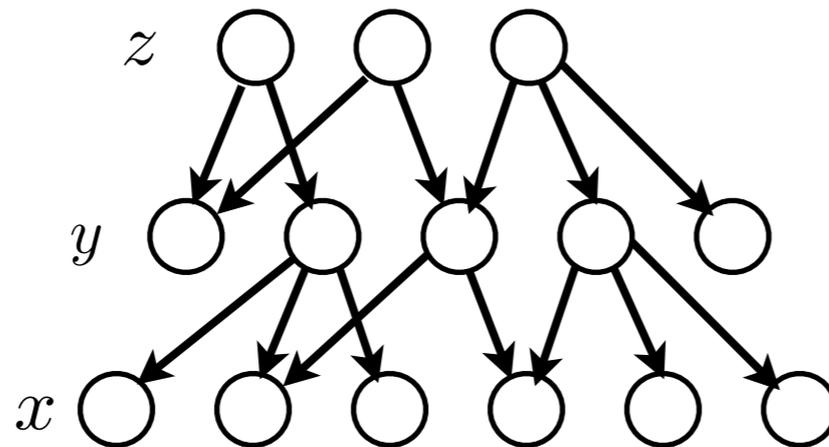
$$\dot{z}_i = \mathbf{A}_i x_t - \sum_j \mathbf{A}'_i \mathbf{A}_j z_j - \frac{\lambda}{\sigma} S' \left(\frac{z_i}{\sigma} \right)$$

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

RECAP: Statisztikai tanulás

Miért tudjuk ezt elvégezni?

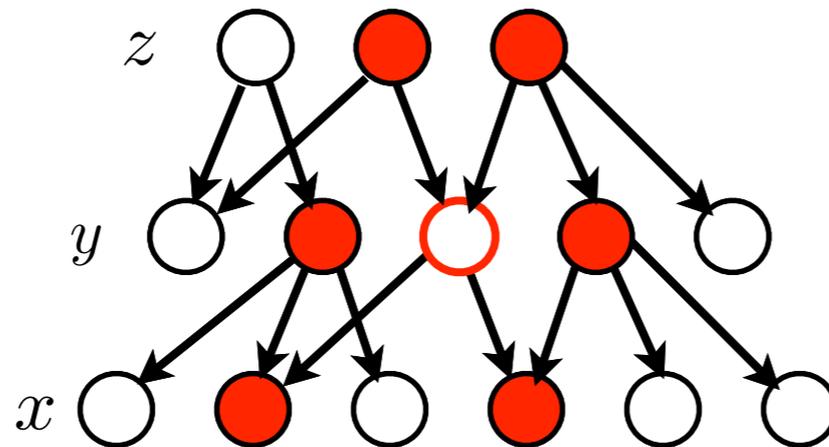
- Linearitás
- Irányított generatív modell



RECAP: Statisztikai tanulás

Miért tudjuk ezt elvégezni?

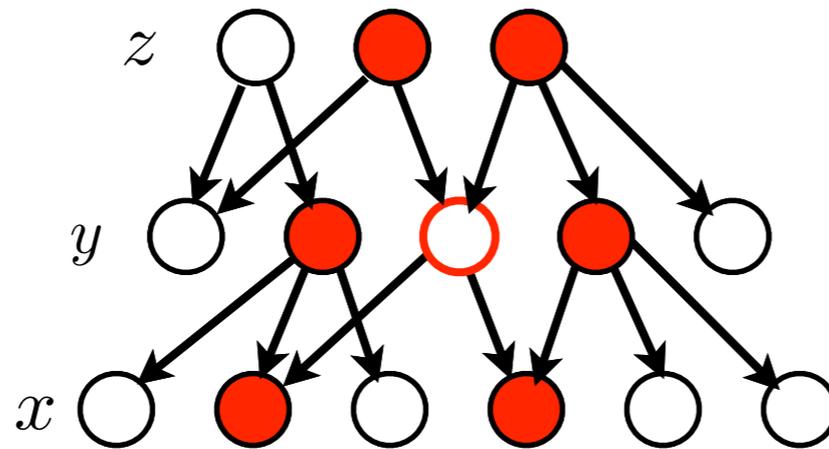
- Linearitás
- Irányított generatív modell



RECAP: Statisztikai tanulás

Miért tudjuk ezt elvégezni?

- Linearitás
- Irányított generatív modell

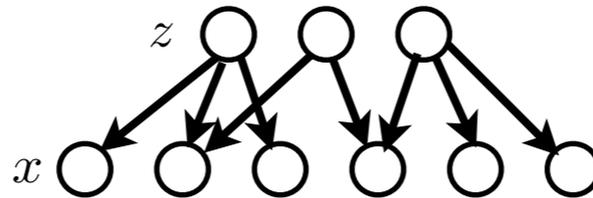


Markov lepedő:

- szülők
- gyermekek
- gyermekek szülei

Helmholtz machine

- Sztochasztikus
- Bináris
- Nemlineáris $P(x | z) = \text{sigmoid}(w \cdot z)$
- Irányított
- Lehetőség szerint többrétegű (hierarchikus)

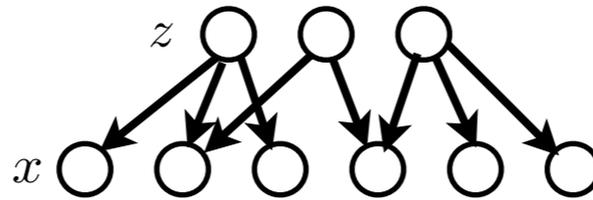


generatív súlyok

rekogníciós súlyok

Helmholtz machine

- Sztochasztikus
- Bináris
- Nemlineáris $P(x | z) = \text{sigmoid}(w \cdot z)$
- Irányított
- Lehetőség szerint többrétegű (hierarchikus)



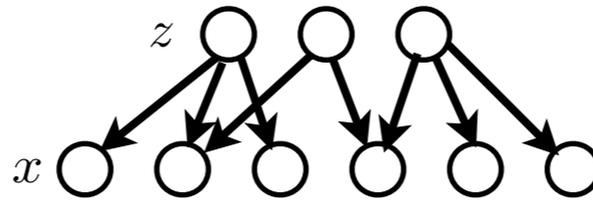
Probléma: tanulni szeretnénk ebben a modellben, de inferencia nehéz

generatív súlyok

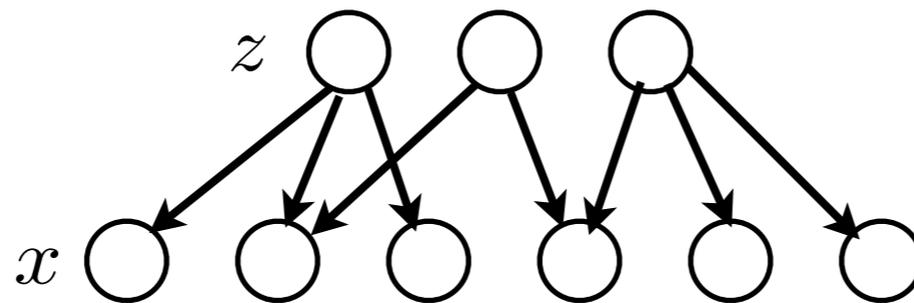
rekogníciós súlyok

Helmholtz machine

- Sztochasztikus
- Bináris
- Nemlineáris $P(x | z) = \text{sigmoid}(w \cdot z)$
- Irányított
- Lehetőség szerint többrétegű (hierarchikus)



Probléma: tanulni szeretnénk ebben a modellben, de inferencia nehéz

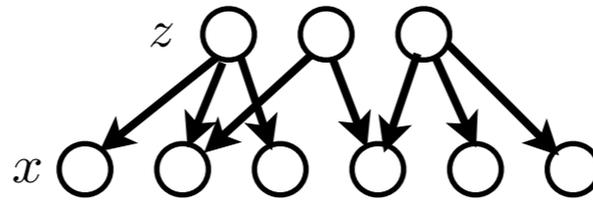


generatív súlyok

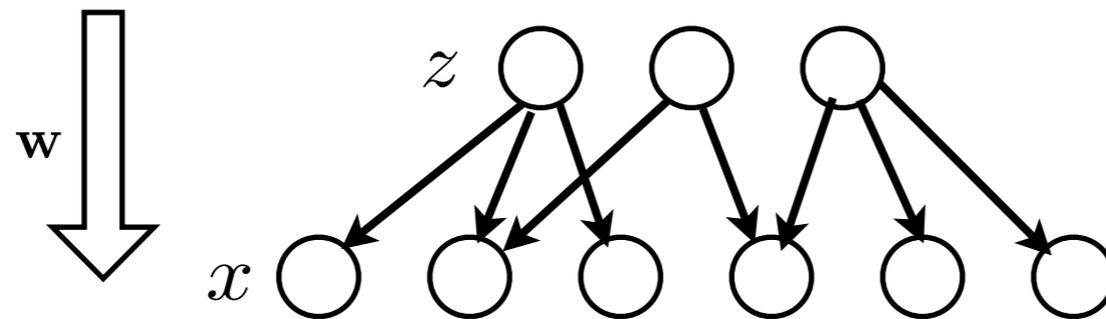
rekogníciós súlyok

Helmholtz machine

- Sztochasztikus
- Bináris
- Nemlineáris $P(x | z) = \text{sigmoid}(w \cdot z)$
- Irányított
- Lehetőség szerint többrétegű (hierarchikus)



Probléma: tanulni szeretnénk ebben a modellben, de inferencia nehéz

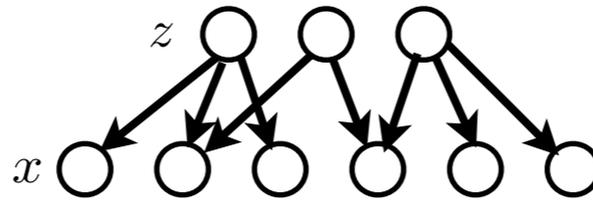


generatív súlyok

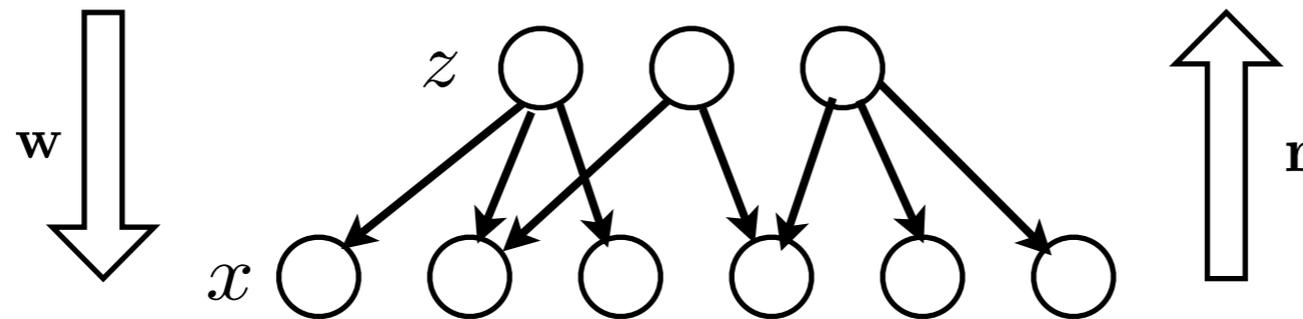
rekogníciós súlyok

Helmholtz machine

- Sztochasztikus
- Bináris
- Nemlineáris $P(x | z) = \text{sigmoid}(w \cdot z)$
- Irányított
- Lehetőség szerint többrétegű (hierarchikus)



Probléma: tanulni szeretnénk ebben a modellben, de inferencia nehéz

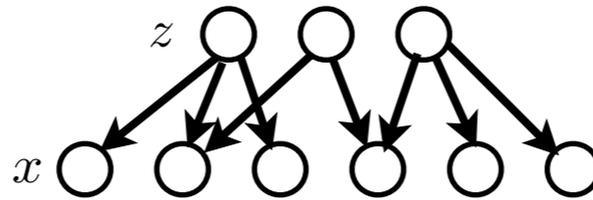


generatív súlyok

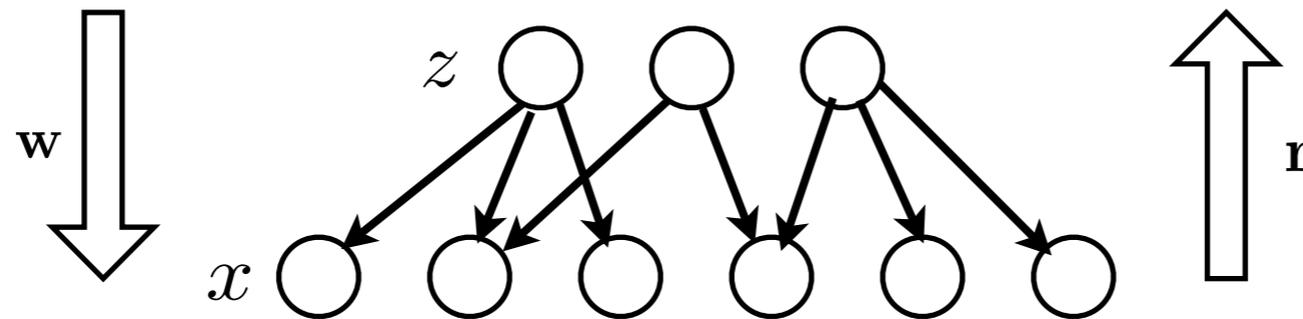
rekogníciós súlyok

Helmholtz machine

- Sztochasztikus
- Bináris
- Nemlineáris $P(x | z) = \text{sigmoid}(w \cdot z)$
- Irányított
- Lehetőség szerint többrétegű (hierarchikus)



Probléma: tanulni szeretnénk ebben a modellben, de inferencia nehéz

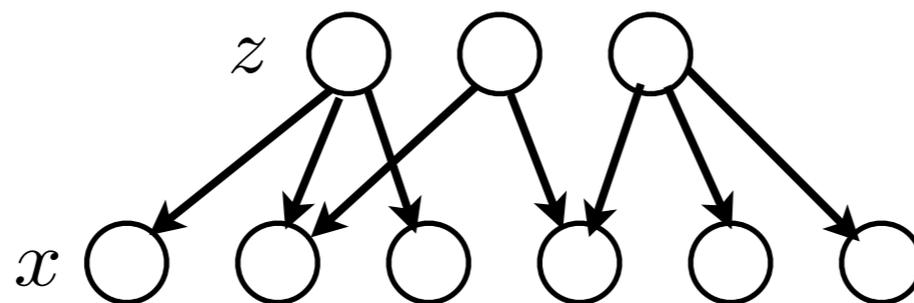


generatív súlyok

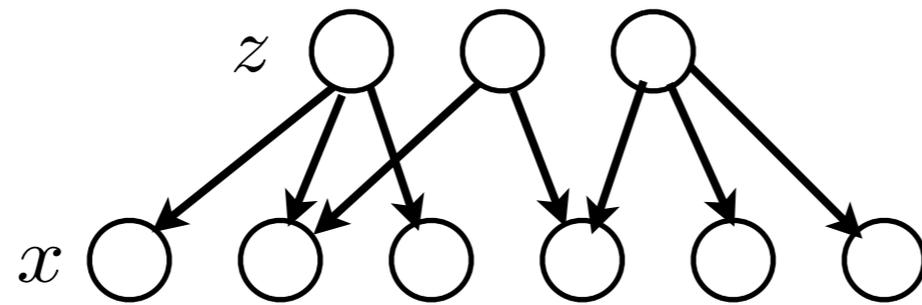
rekogníciós súlyok

generatív modell nem invertálható

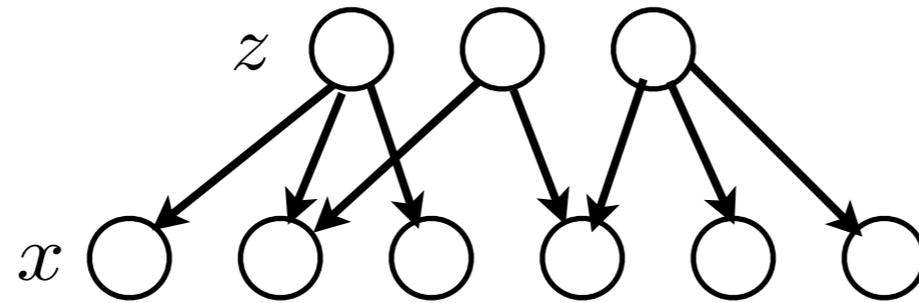
Helmholtz machine



Helmholtz machine

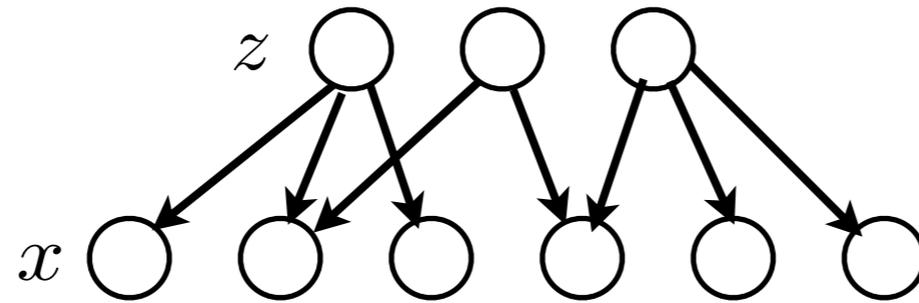


Helmholtz machine

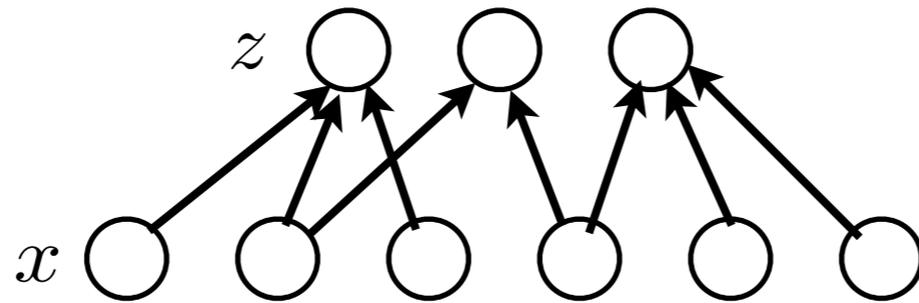


Közelítő rekogníciós modell:

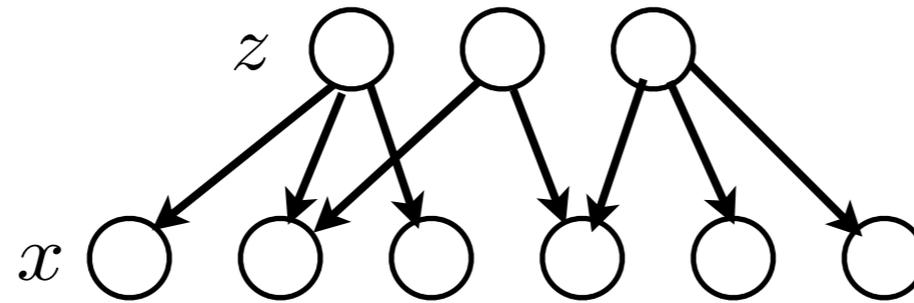
Helmholtz machine



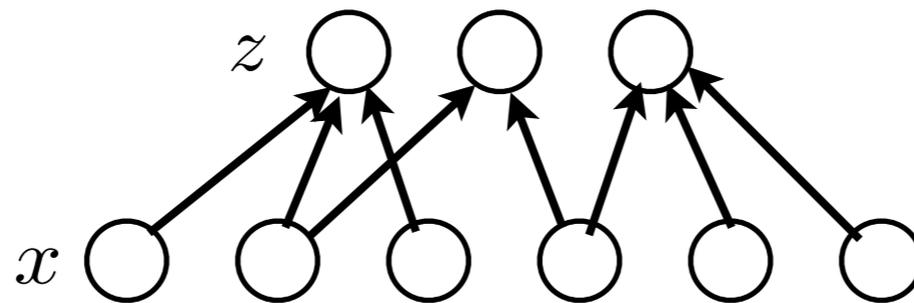
Közelítő rekogníciós modell:



Helmholtz machine

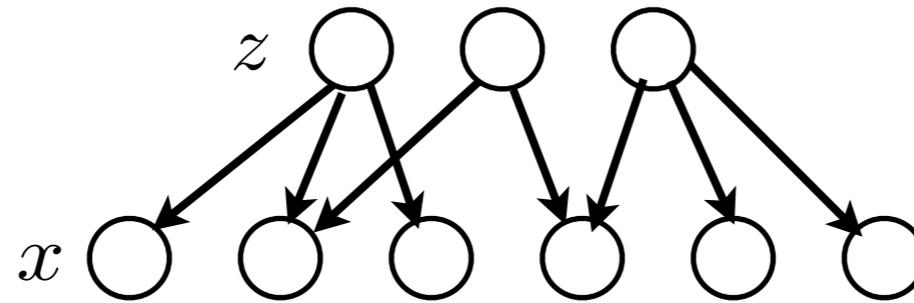


Közelítő rekogníciós modell:

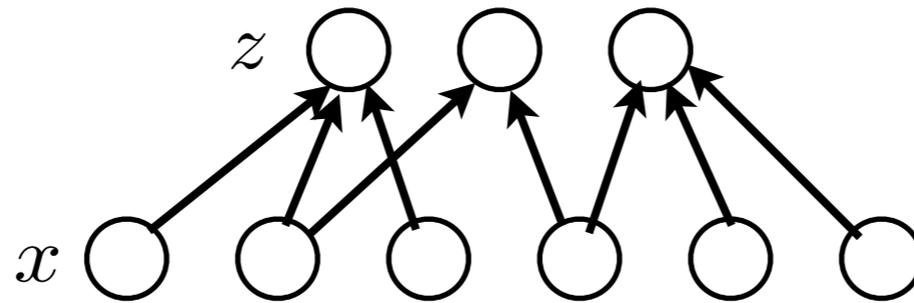


eredeti:
$$P = \prod_i \text{sigmoid}(h_i + w_i \cdot z)^{x_i} (1 - \text{sigmoid}(h_i + w_i \cdot z))^{1-x_i}$$

Helmholtz machine



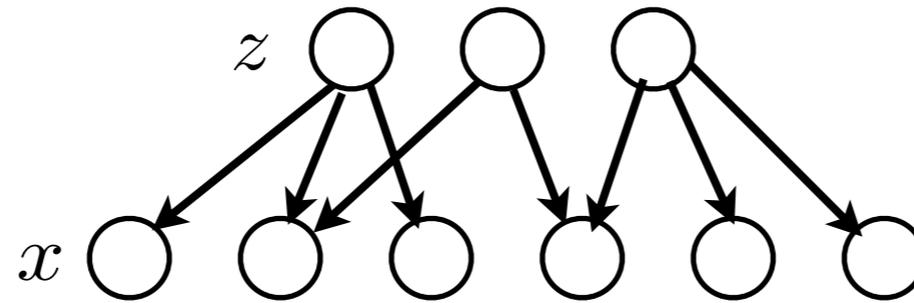
Közelítő rekogníciós modell:



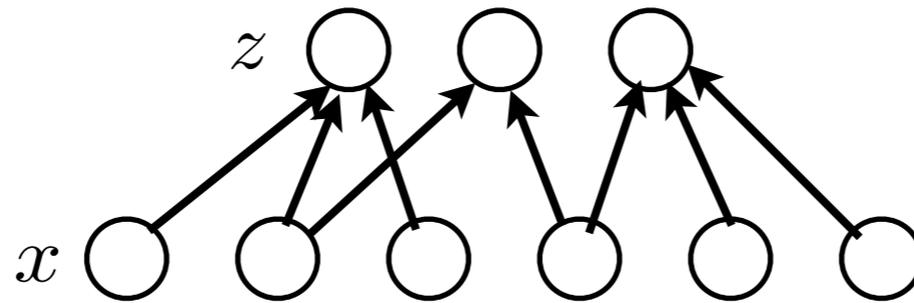
eredeti:
$$P = \prod_i \text{sigmoid}(h_i + w_i \cdot z)^{x_i} (1 - \text{sigmoid}(h_i + w_i \cdot z))^{1-x_i}$$

közelítés:
$$Q = \prod_j \text{sigmoid}(g_j + r_j \cdot x)^{z_j} (1 - \text{sigmoid}(g_j + r_j \cdot x))^{1-z_j}$$

Helmholtz machine



Közelítő rekogníciós modell:



eredeti:
$$P = \prod_i \text{sigmoid}(h_i + w_i \cdot z)^{x_i} (1 - \text{sigmoid}(h_i + w_i \cdot z))^{1-x_i}$$

közelítés:
$$Q = \prod_j \text{sigmoid}(g_j + r_j \cdot x)^{z_j} (1 - \text{sigmoid}(g_j + r_j \cdot x))^{1-z_j}$$

EM-et konstruálunk a tanuláshoz

Helmholtz machine

eredeti: $P = \prod_i \text{sigmoid}(h_i + w_i \cdot z)^{x_i} (1 - \text{sigmoid}(h_i + w_i \cdot z))^{1-x_i}$

közelítés: $Q = \prod_j \text{sigmoid}(g_j + r_j \cdot x)^{x_i} (1 - \text{sigmoid}(g_j + r_j \cdot x))^{1-x_i}$

reguláris EM

$$\mathcal{F}(R, W) = L(W) - \sum P(x) D_{KL}(Q[z; x, R], P[z | x, W])$$

Helmholtz machine

eredeti:
$$P = \prod_i \text{sigmoid}(h_i + w_i \cdot z)^{x_i} (1 - \text{sigmoid}(h_i + w_i \cdot z))^{1-x_i}$$

közelítés:
$$Q = \prod_j \text{sigmoid}(g_j + r_j \cdot x)^{x_i} (1 - \text{sigmoid}(g_j + r_j \cdot x))^{1-x_i}$$

reguláris EM

$$\mathcal{F}(R, W) = L(W) - \sum P(x) D_{KL}(Q[z; x, R], P[z | x, W])$$

közelített EM

$$\tilde{\mathcal{F}}(R, W) = L(W) - \sum P(x, W) D_{KL}(P[z | x, W], Q[z; x, R])$$

Helmholtz machine

eredeti:
$$P = \prod_i \text{sigmoid}(h_i + w_i \cdot z)^{x_i} (1 - \text{sigmoid}(h_i + w_i \cdot z))^{1-x_i}$$

közelítés:
$$Q = \prod_j \text{sigmoid}(g_j + r_j \cdot x)^{x_i} (1 - \text{sigmoid}(g_j + r_j \cdot x))^{1-x_i}$$

reguláris EM

$$\mathcal{F}(R, W) = L(W) - \sum P(x) D_{KL}(Q[z; x, R], P[z | x, W])$$

közelített EM

$$\tilde{\mathcal{F}}(R, W) = L(W) - \sum P(x, W) D_{KL}(P[z | x, W], Q[z; x, R])$$

E lépés:

- mintavételezés z-ből
- generatív súlyok tanulása

M lépés

- mintavételezés x-ből
- rekogníciós súlyok állítása

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: $P(\mathbf{x})$

(Reinforcement 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: $P(\mathbf{x})$

(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?

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

Unsupervised learning

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

Gól: $P(\mathbf{x})$

(Reinforcement learning:

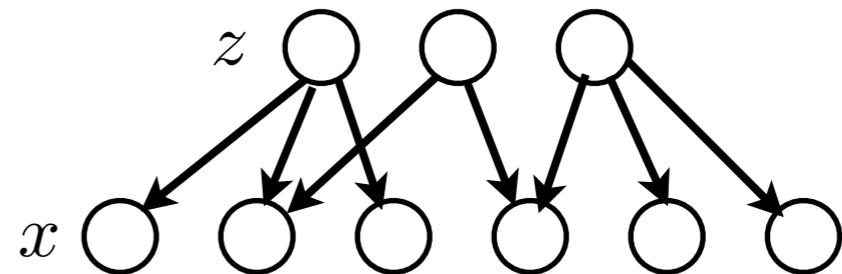
Input: $\{x_1, y_1\}, \{x_2, y_2\}, \dots, \{x_t, y_t\}$

Gól: $P(\mathbf{x} | \mathbf{y})$)

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

Miért is?

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



Unsupervised learning

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

Gól: $P(\mathbf{x})$

(Reinforcement learning:

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

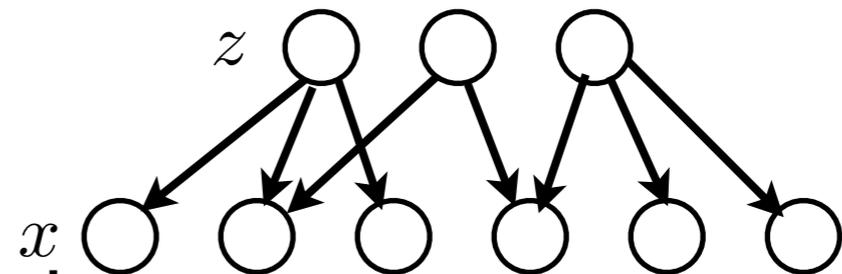
Gól: $P(\mathbf{x} | \mathbf{y})$)

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

Miért is?

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

- az adatot a “z”-k terében reprezentáljuk



Unsupervised learning

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

Gól: $P(\mathbf{x})$

(Reinforcement learning:

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

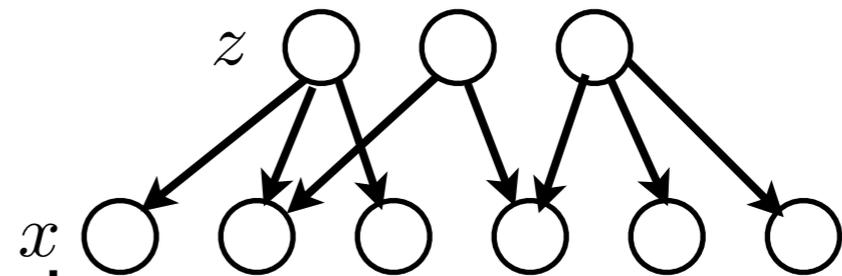
Gól: $P(\mathbf{x} | \mathbf{y})$)

$P(\mathbf{x})$ 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



Unsupervised learning

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

Gól: $P(\mathbf{x})$

(Reinforcement learning:

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

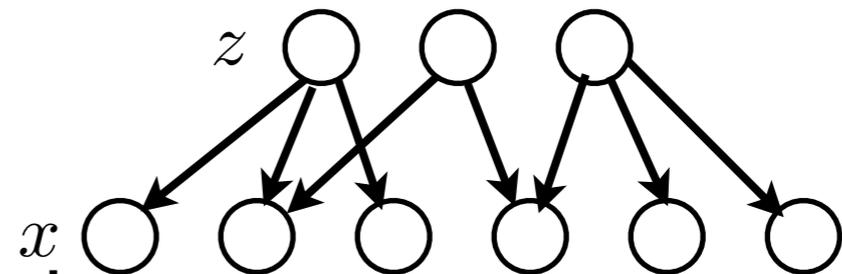
Gól: $P(\mathbf{x} | \mathbf{y})$)

$P(\mathbf{x})$ 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

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

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

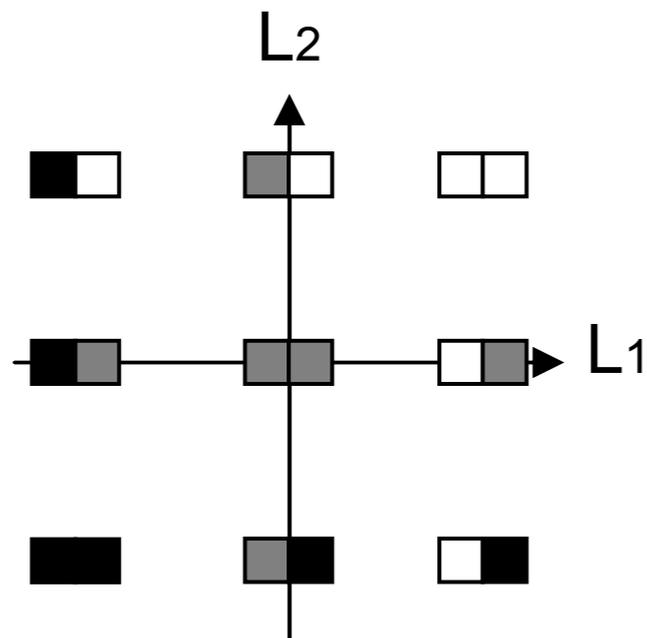
- A oszlopvektorai ortogonálisak
- $D(x) = D(z)$
- Izotróp zaj

Lineáris modellek

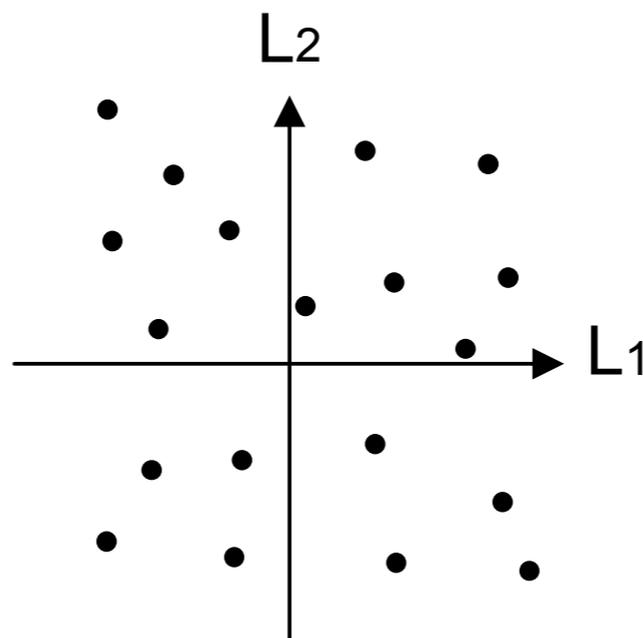
$$P(x | z) = \text{Normal}(x; z, \theta) = C \exp\left(-\frac{1}{2}(x - Az)^T \Sigma^{-1} (x - Az)\right)$$

PCA

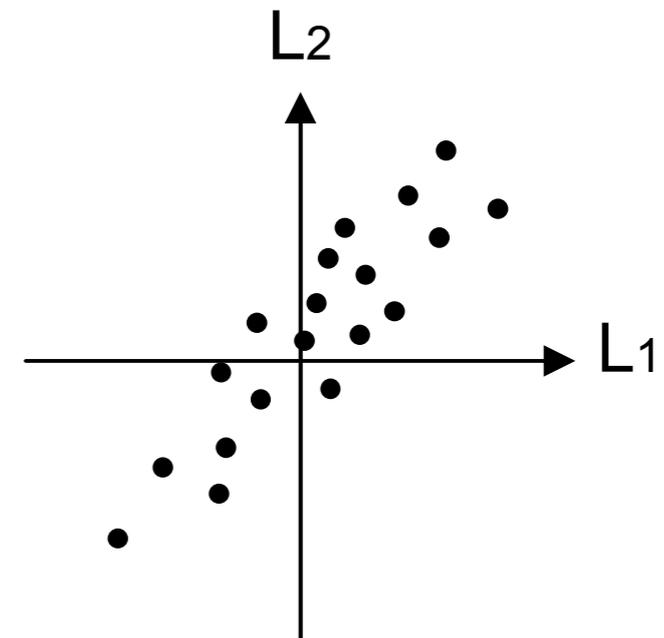
- A oszlopvektorai ortogonálisak
- $D(x) = D(z)$
- Izotróp zaj



State space of two pixel images



Random images



Structured images

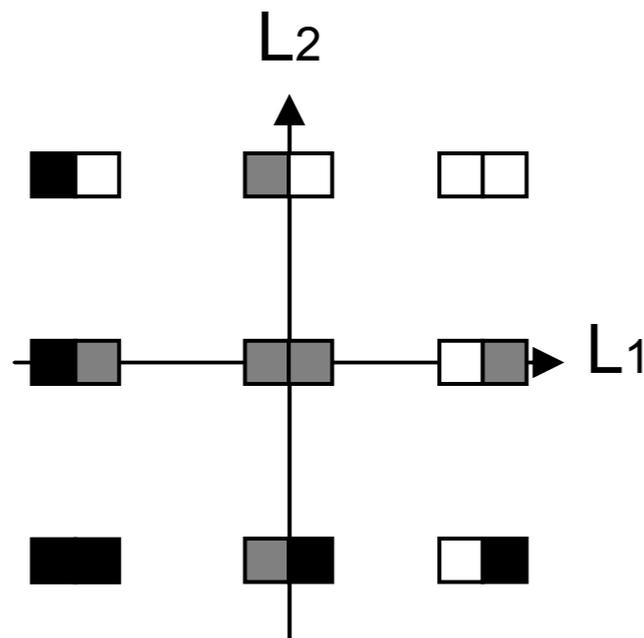
Lineáris modellek

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

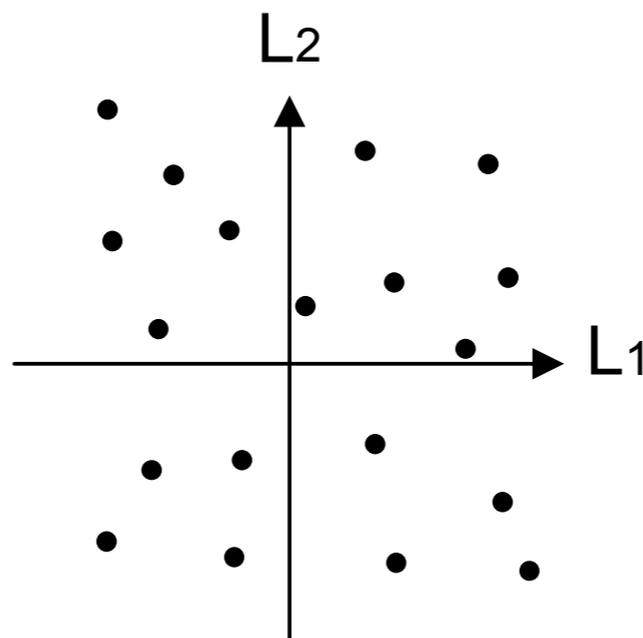
$$x = A \cdot z + \epsilon$$

PCA

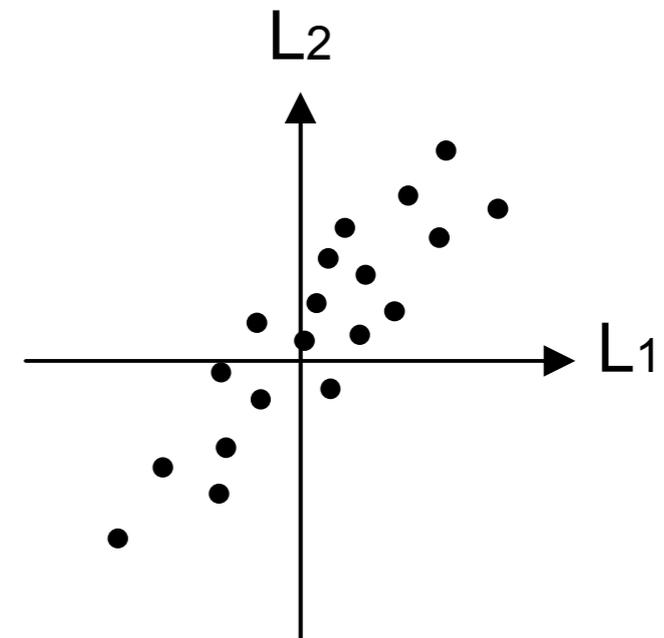
- A oszlopvektorai ortogonálisak
- $D(x) = D(z)$
- Izotróp zaj



State space of two pixel images



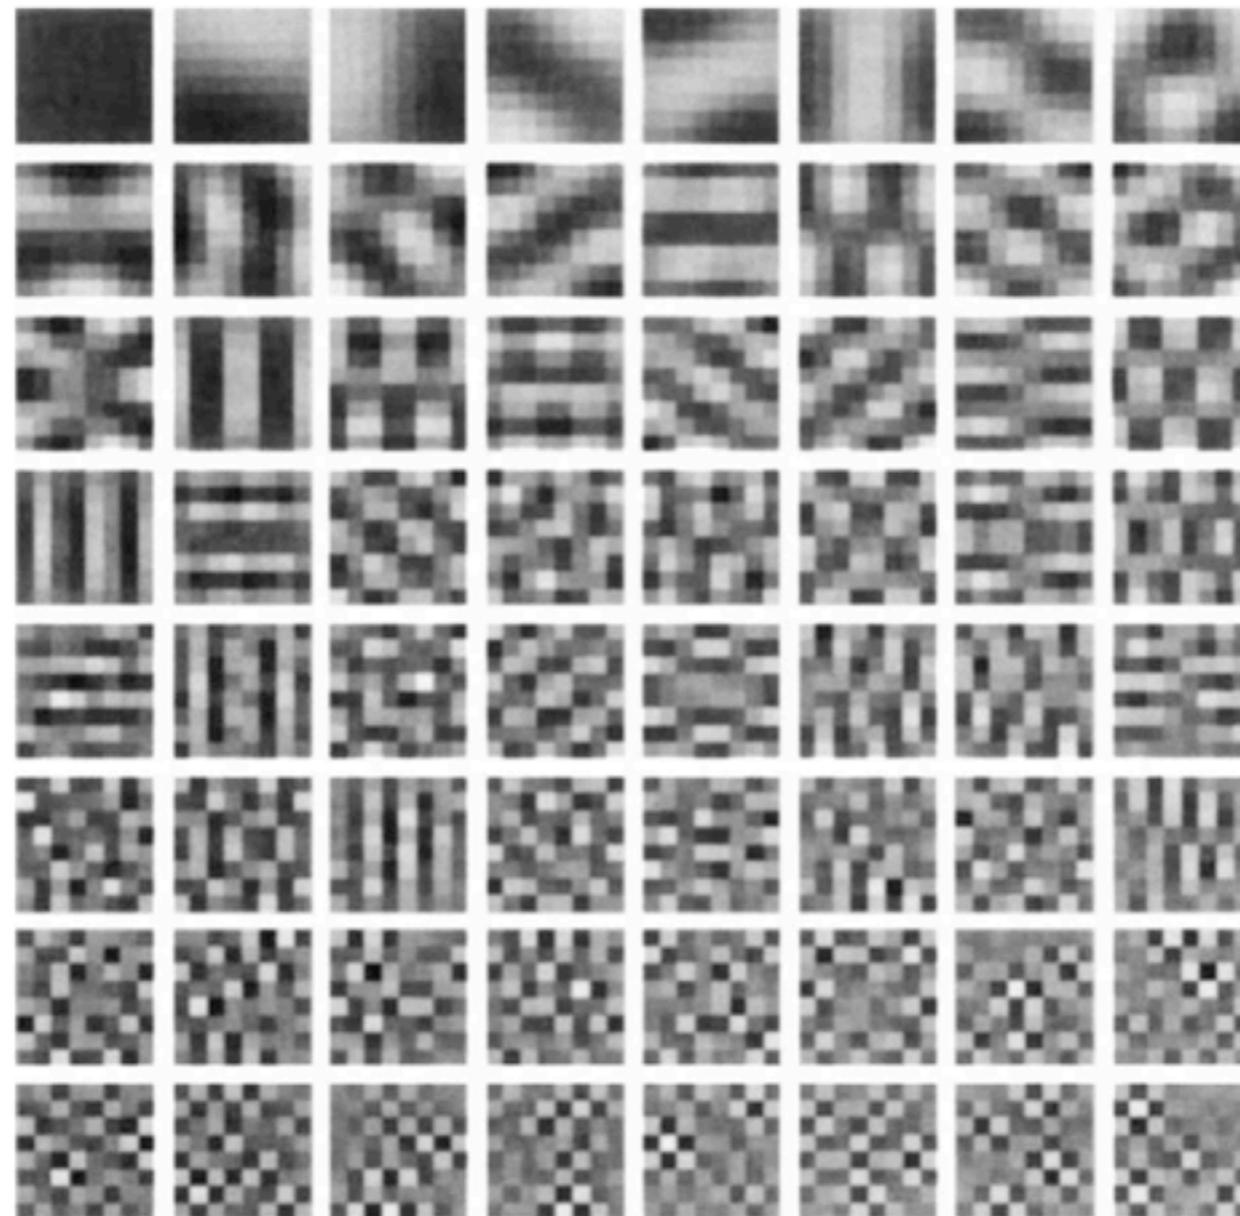
Random images



Structured images

PCA tulajdonságok

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



Sparse kódolás, ICA

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

Sparse kódolás, ICA

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

- “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:

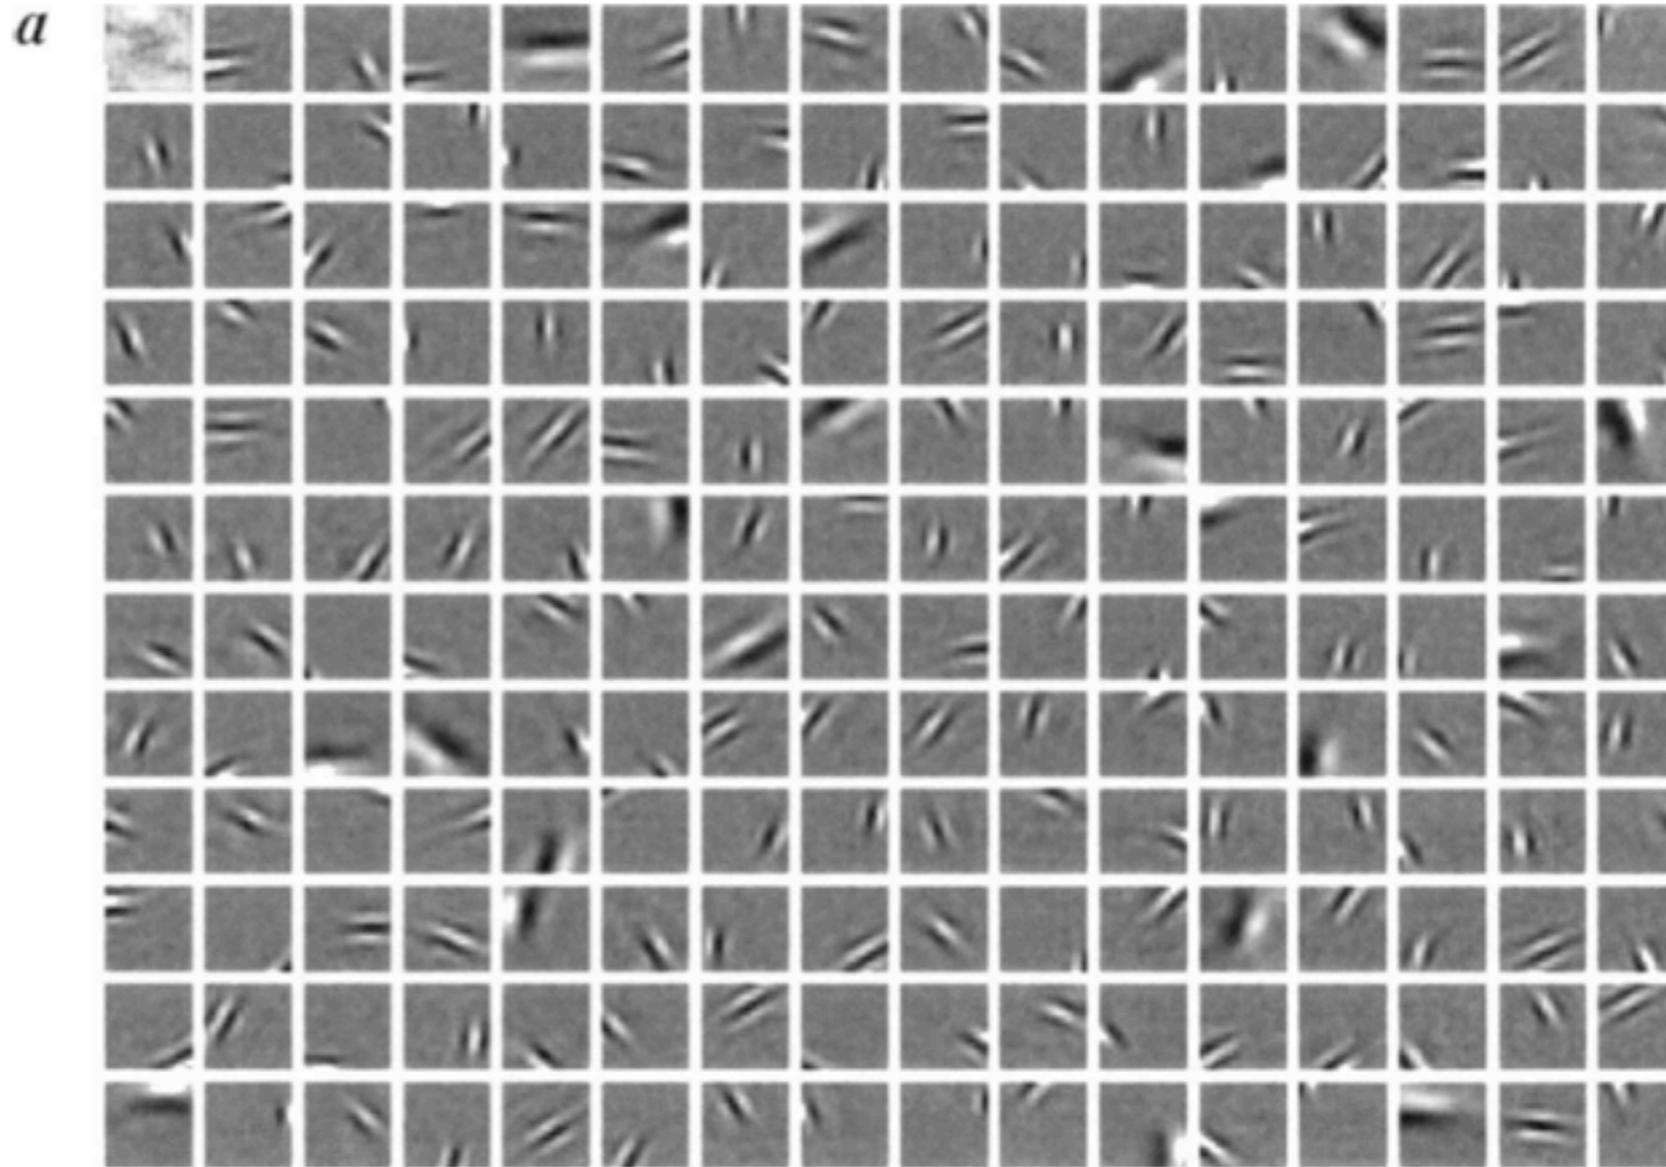
$$\dot{z}_i = \mathbf{A}_i x_t - \sum_j \mathbf{A}'_i \mathbf{A}_j z_j - \frac{\lambda}{\sigma} S' \left(\frac{z_i}{\sigma} \right)$$

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

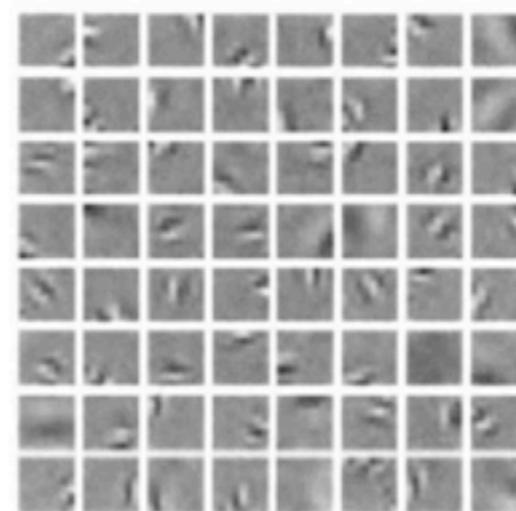
A kialakult bázis:

- irányított
- térbeli sávszűrést valósít meg
- lokalizált

Tanulás és stimulus statisztika

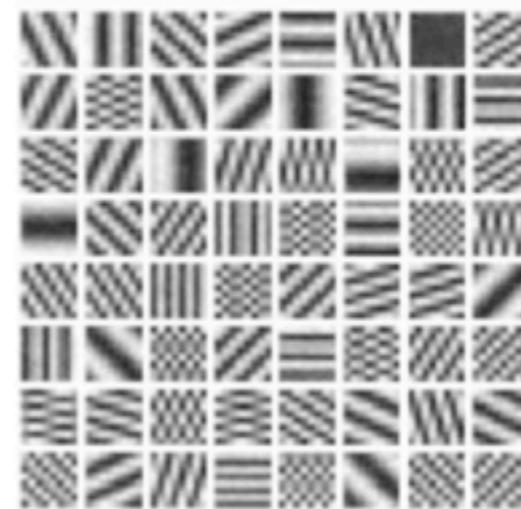
c

Sparse gabors

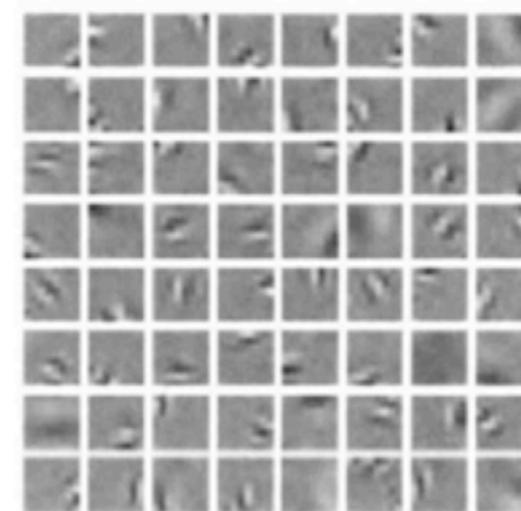


Tanulás és stimulus statisztika

b Sparse gratings

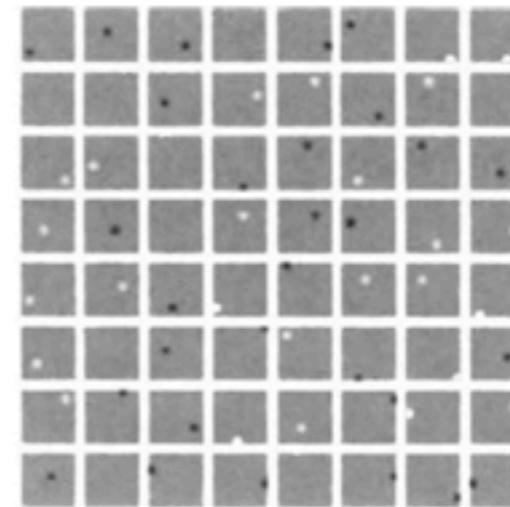
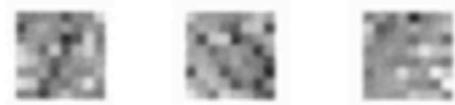


c Sparse gabors

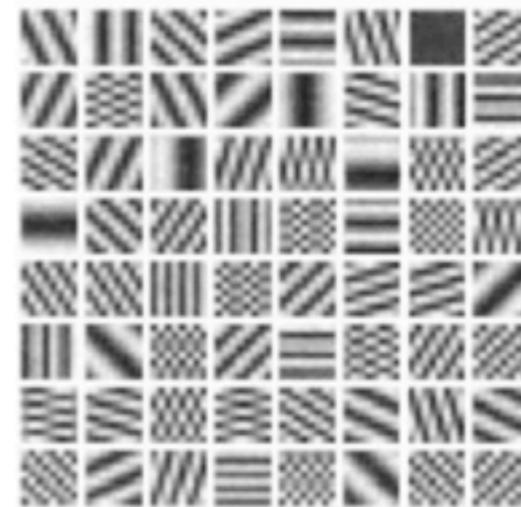


Tanulás és stimulus statisztika

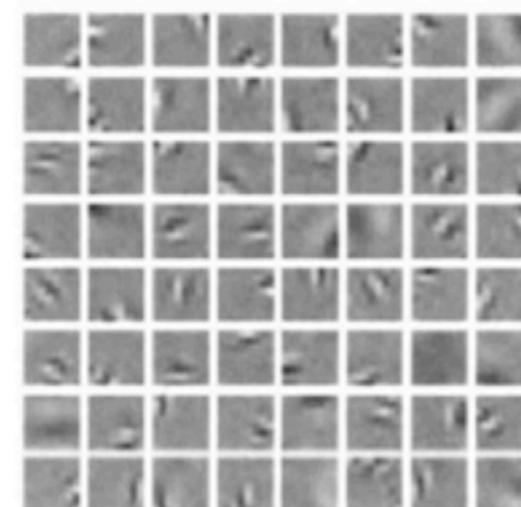
a Sparse pixels



b Sparse gratings



c Sparse gabors

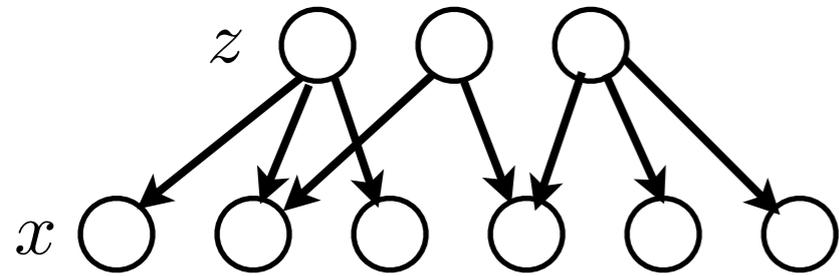


Generatív/rekogníciós modell

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

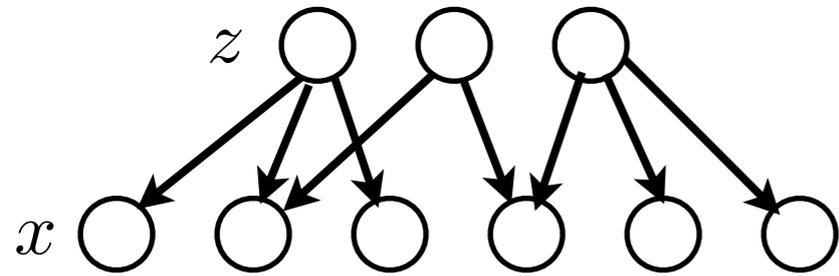
Generatív/rekogníciós modell

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



Generatív/rekogníciós modell

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



szituáció / környezet

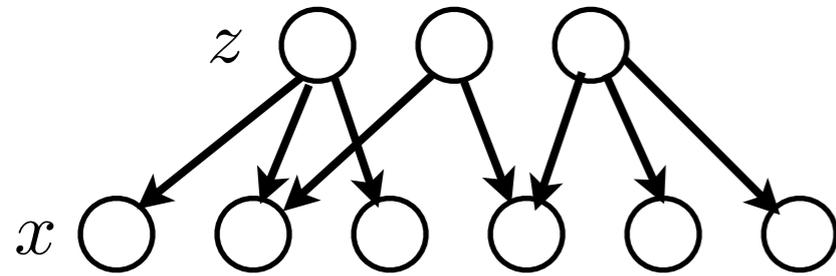
Generatív/rekogníciós modell

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



Generatív/rekogníciós modell

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



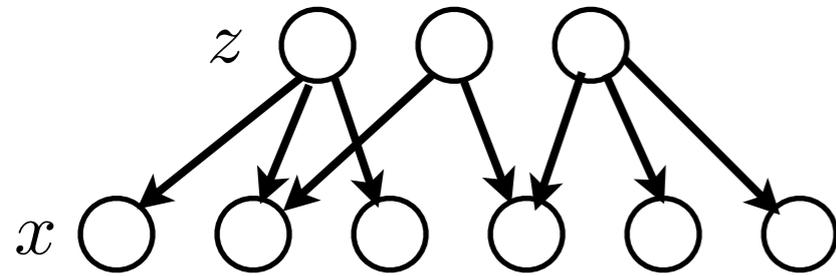
szituáció / környezet

objektumok

objektum elhelyezkedése |
méret, hely, helyzet, világítás

Generatív/rekogníciós modell

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



szituáció / környezet

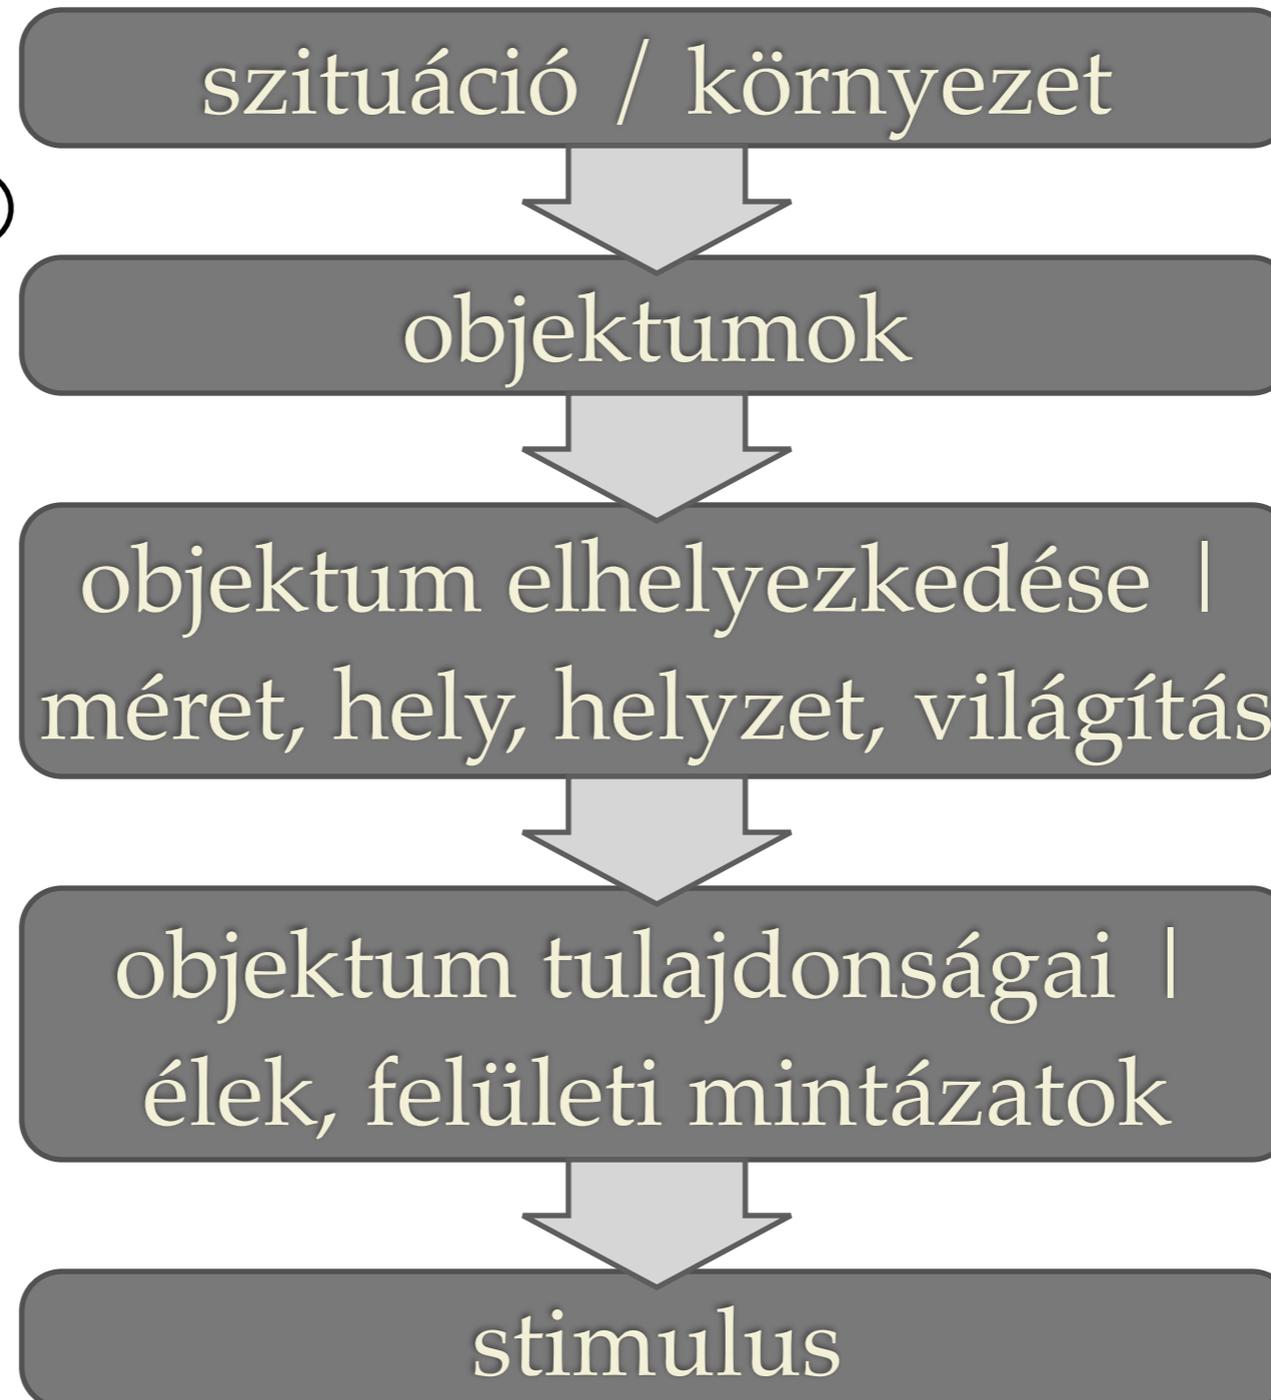
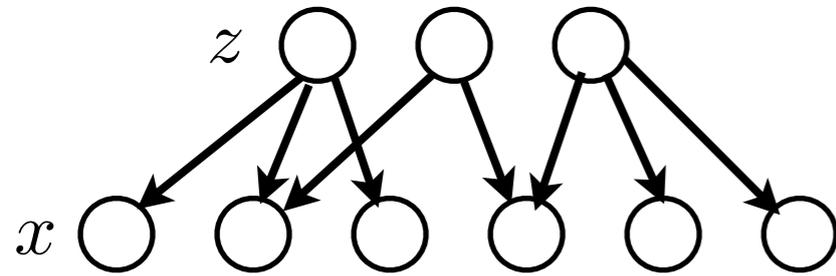
objektumok

objektum elhelyezkedése |
méret, hely, helyzet, világítás

objektum tulajdonságai |
élek, felületi mintázatok

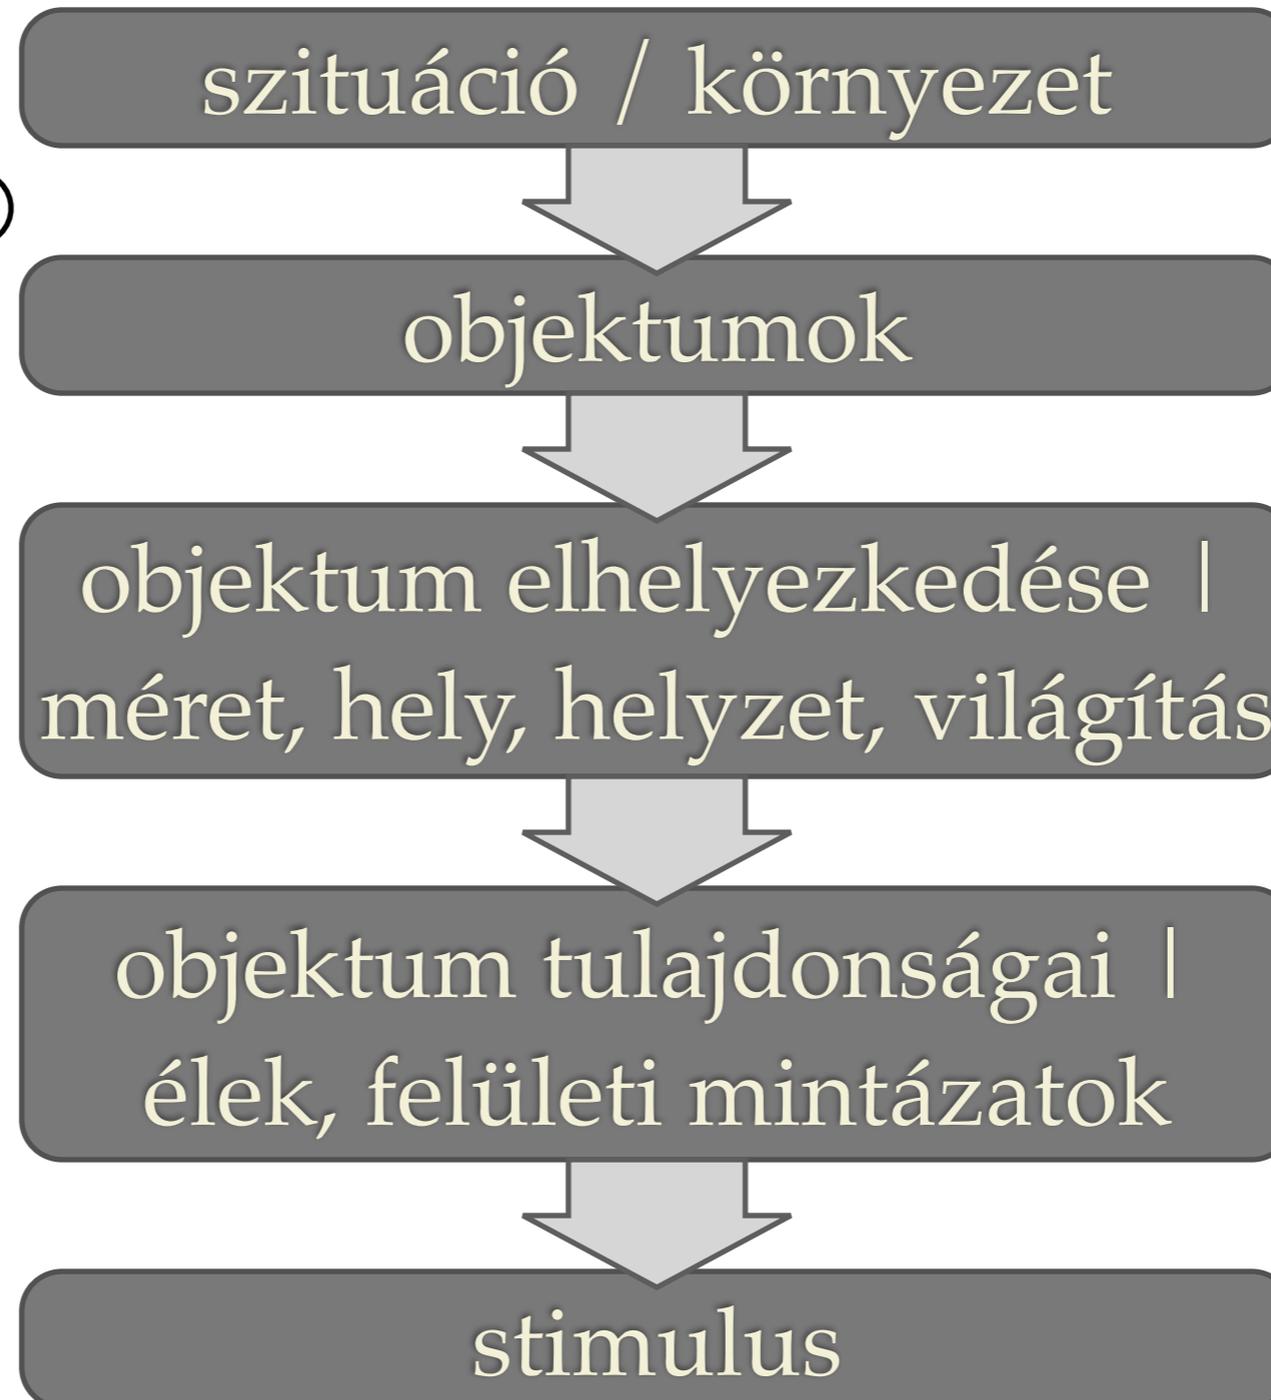
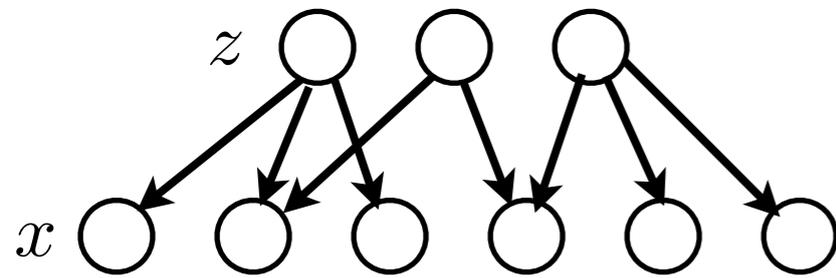
Generatív/rekogníciós modell

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



Generatív/rekogníciós modell

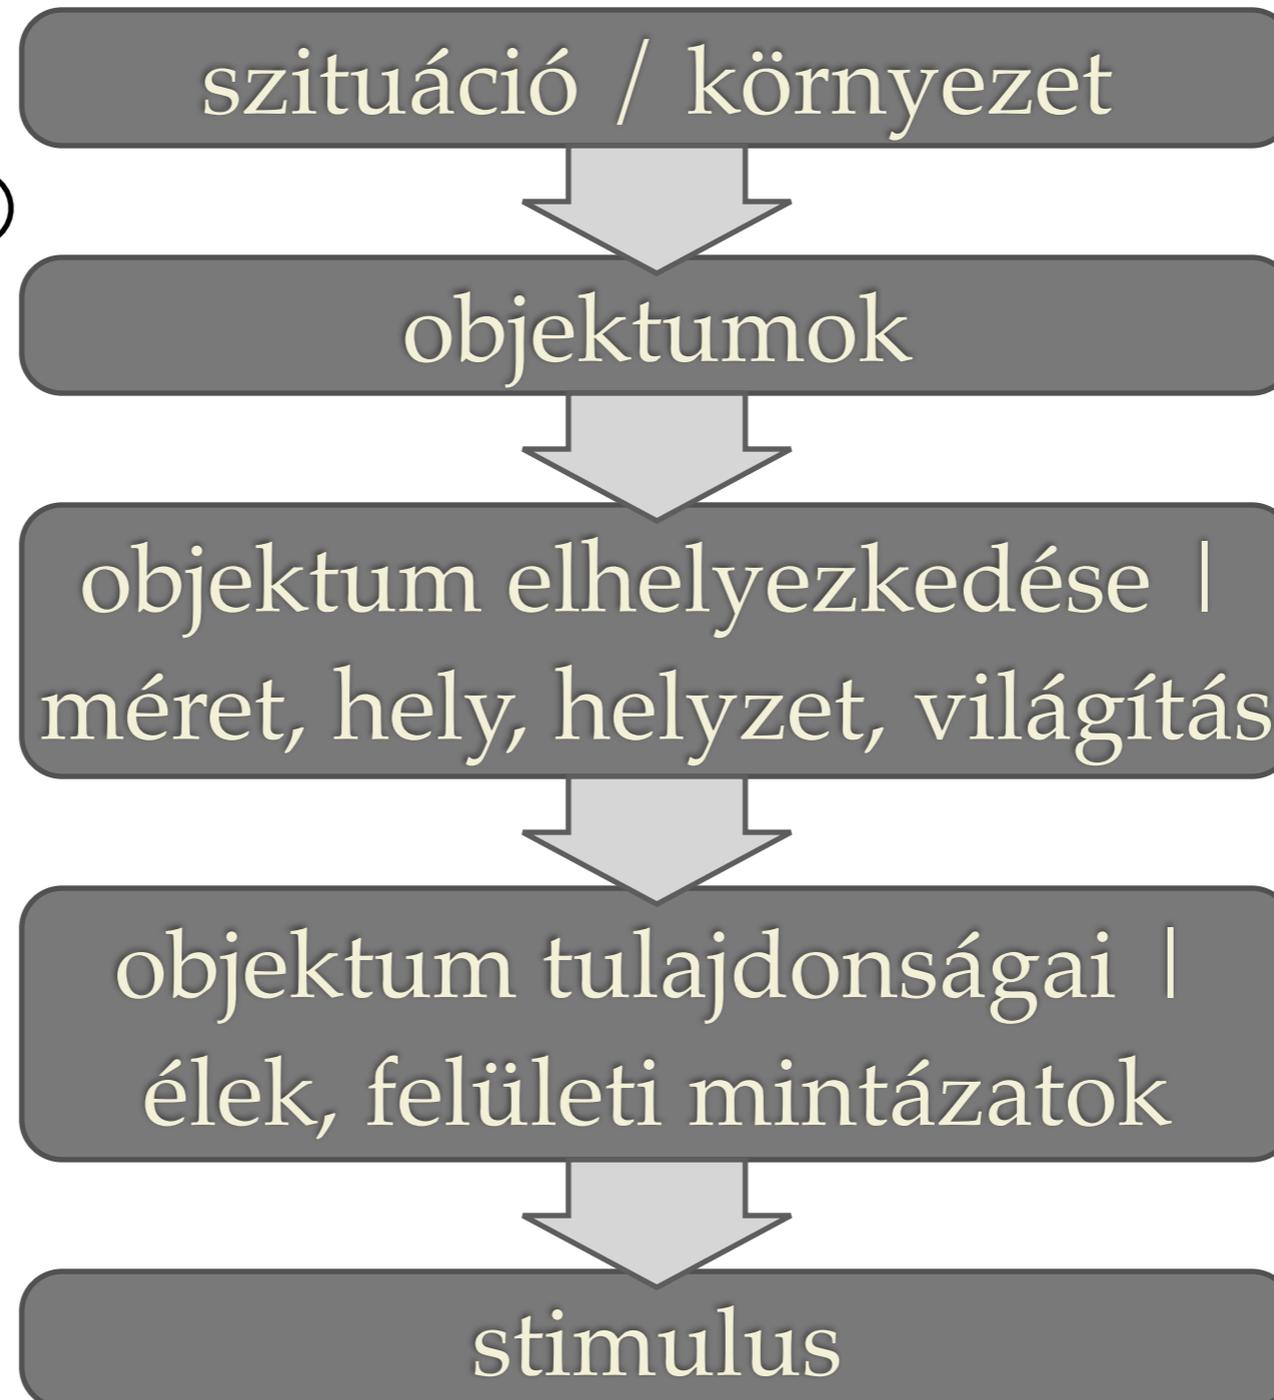
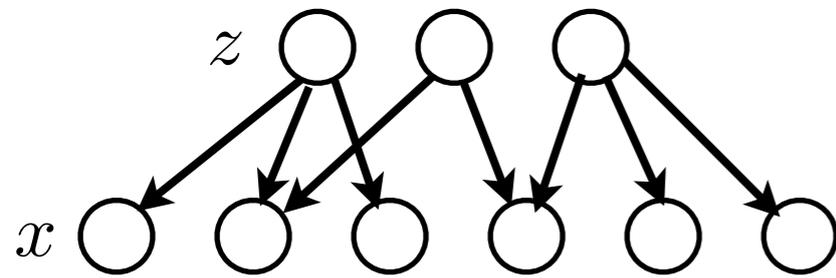
$$P(\mathbf{x}) = P(\mathbf{x} | \mathbf{z}) P(\mathbf{z})$$



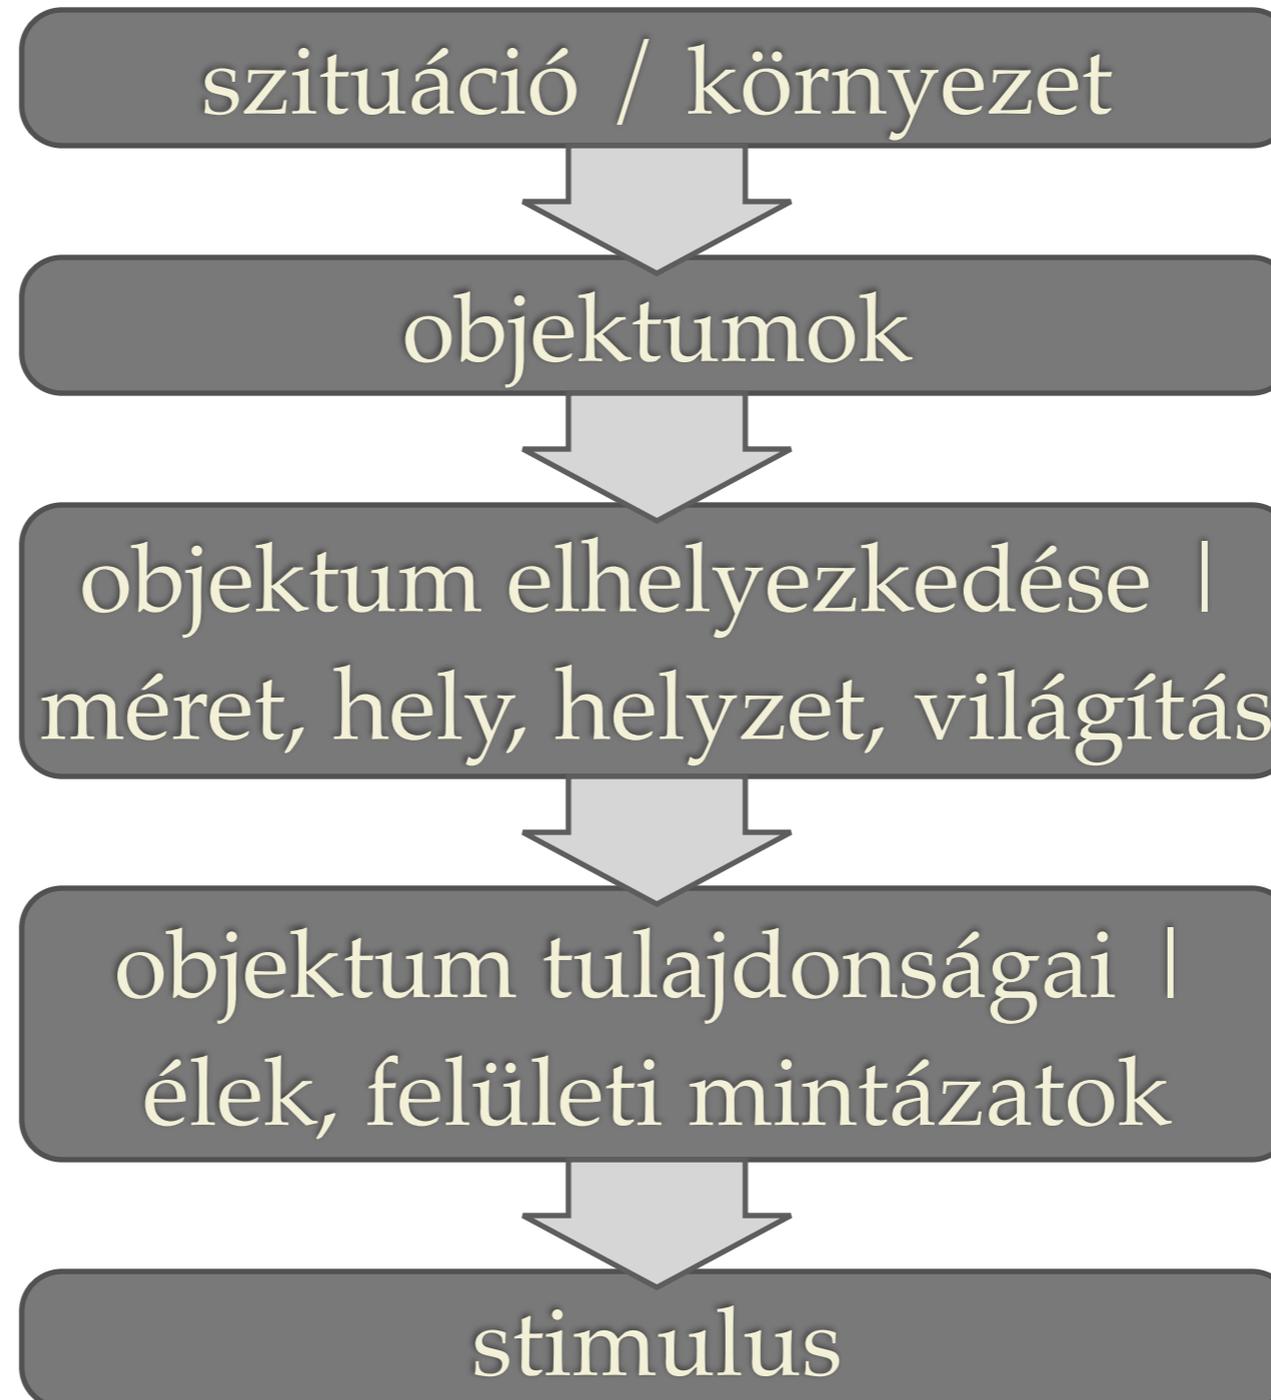
Generatív modell

Generatív/rekogníciós modell

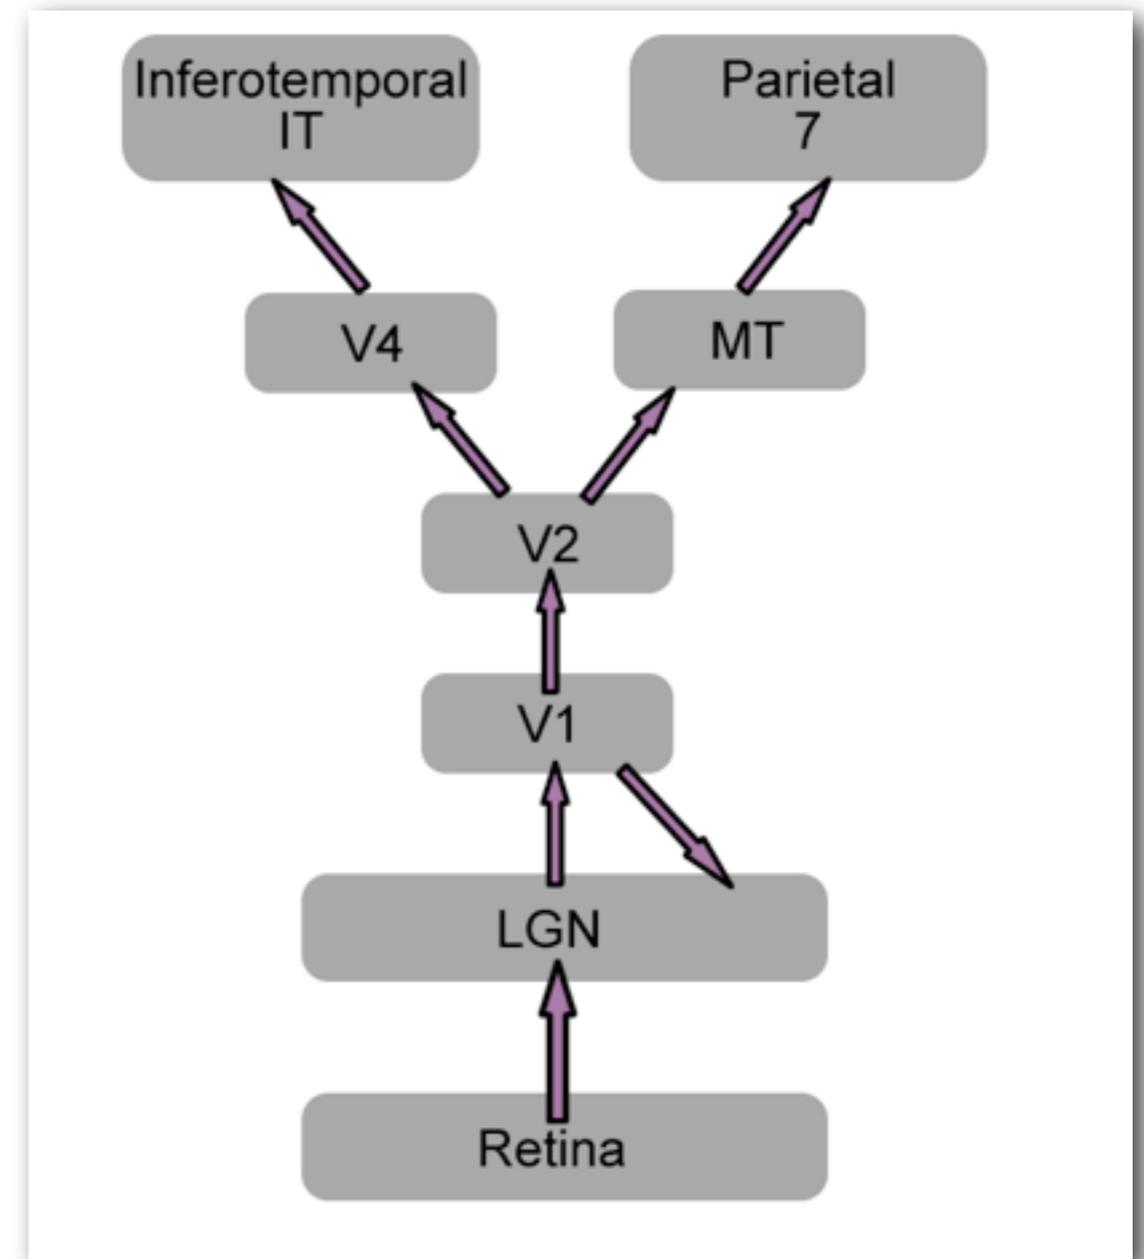
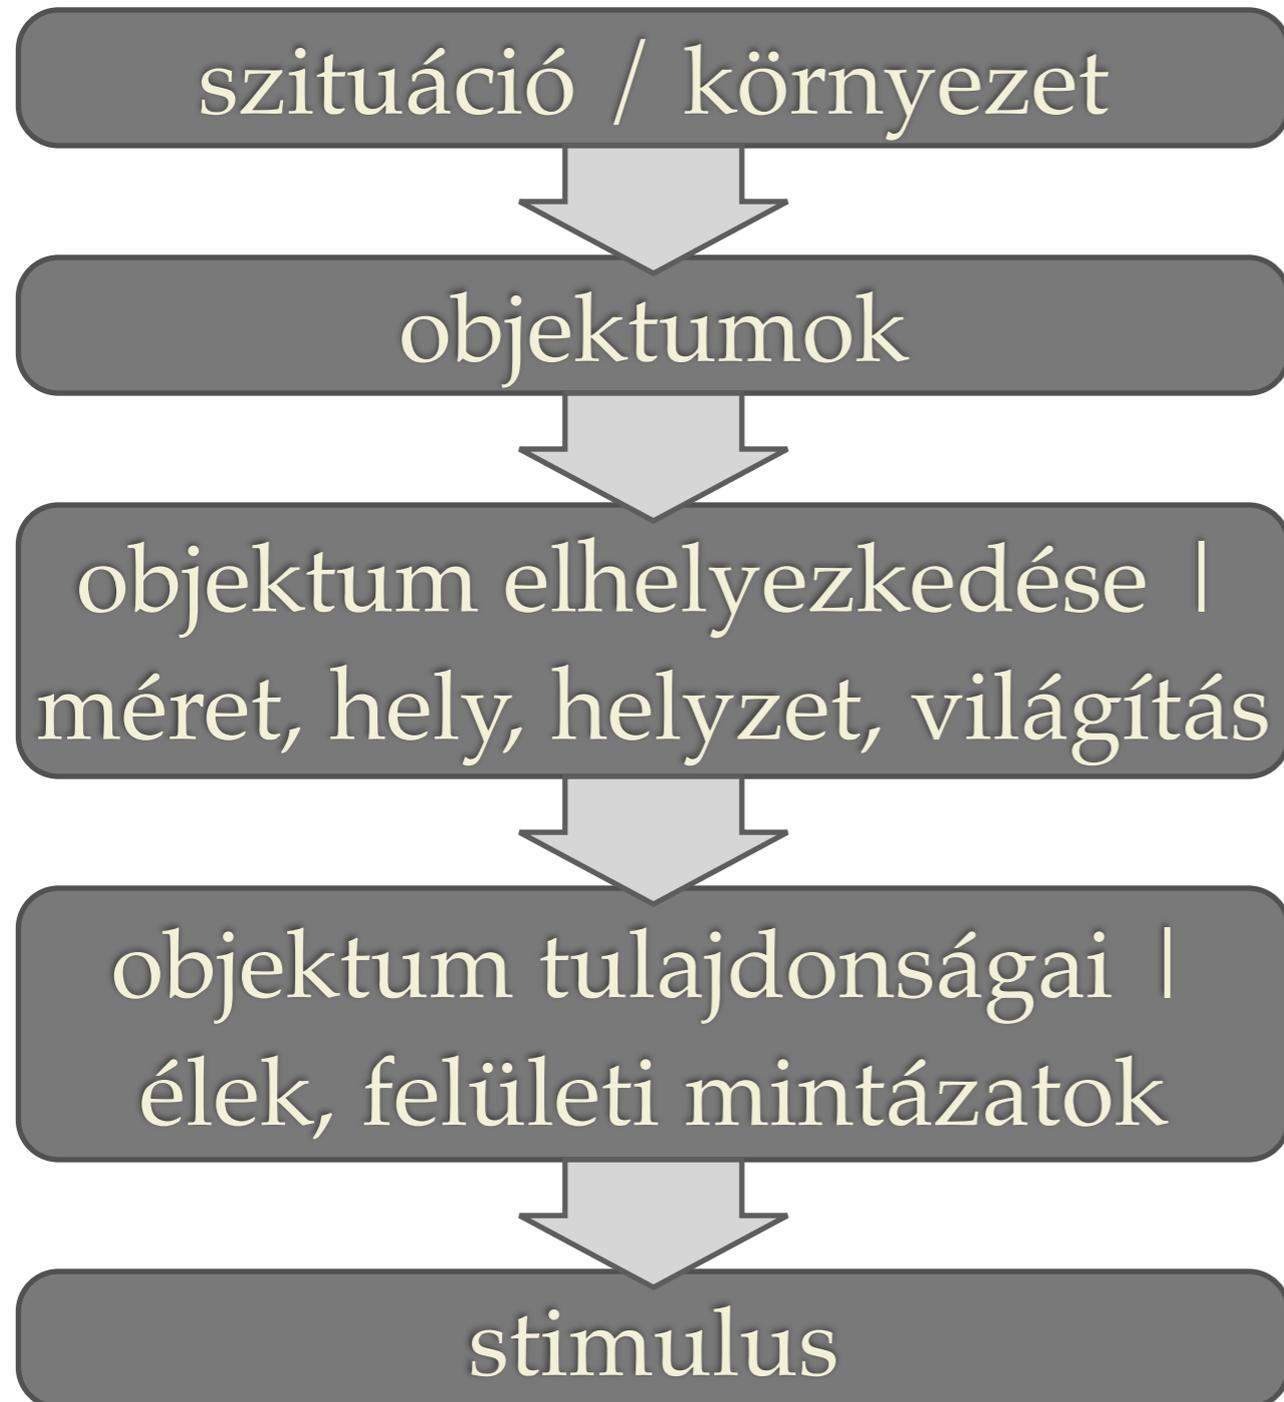
$$P(\mathbf{x}) = P(\mathbf{x} | \mathbf{z}) P(\mathbf{z})$$



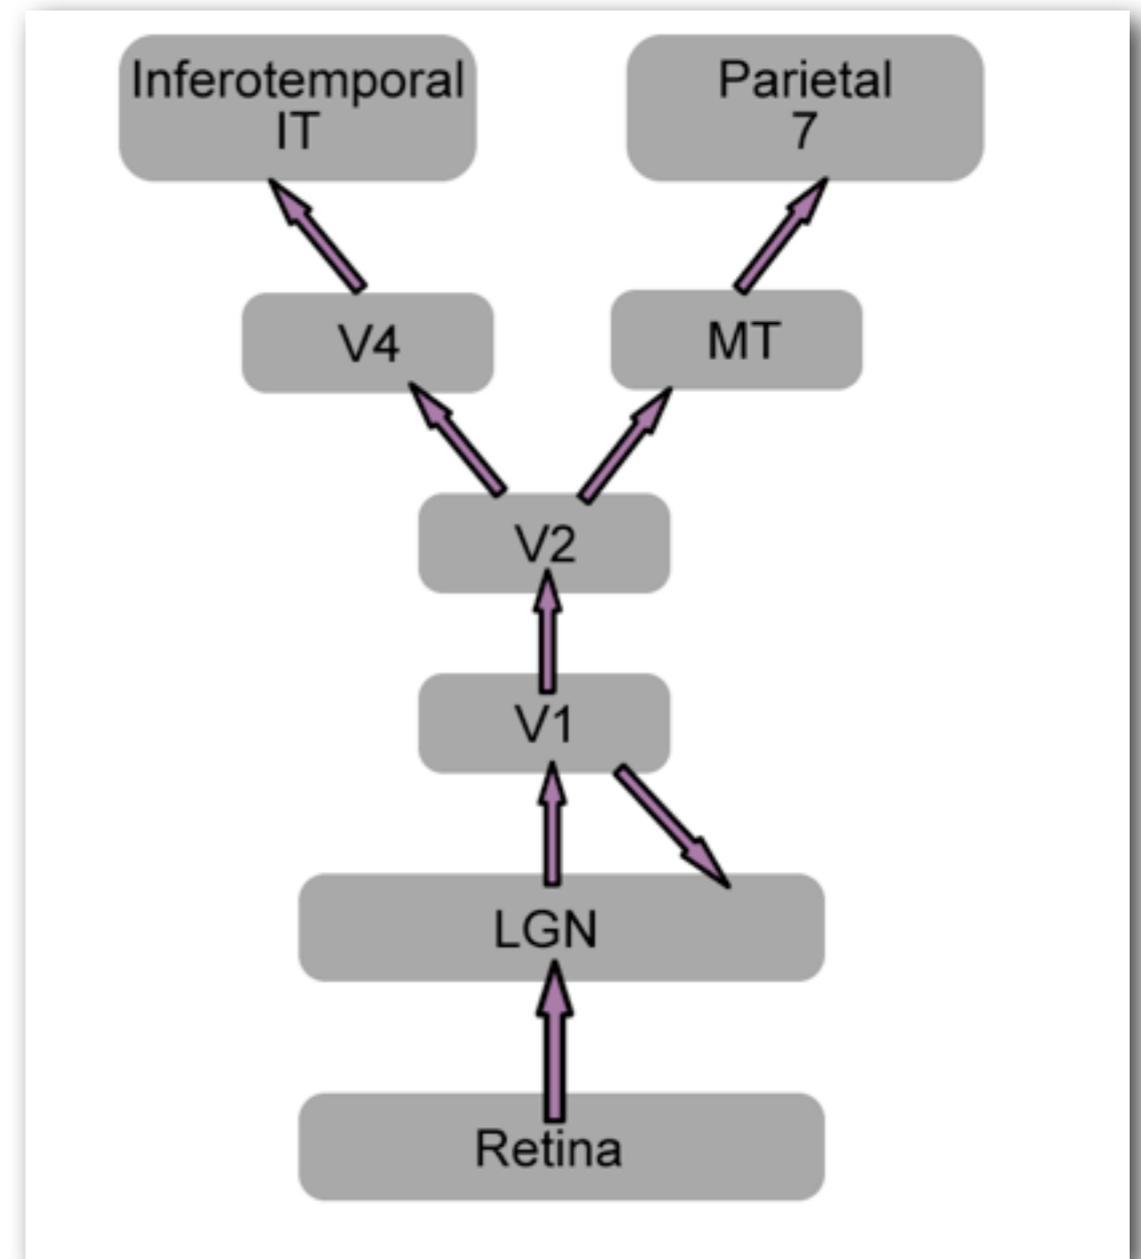
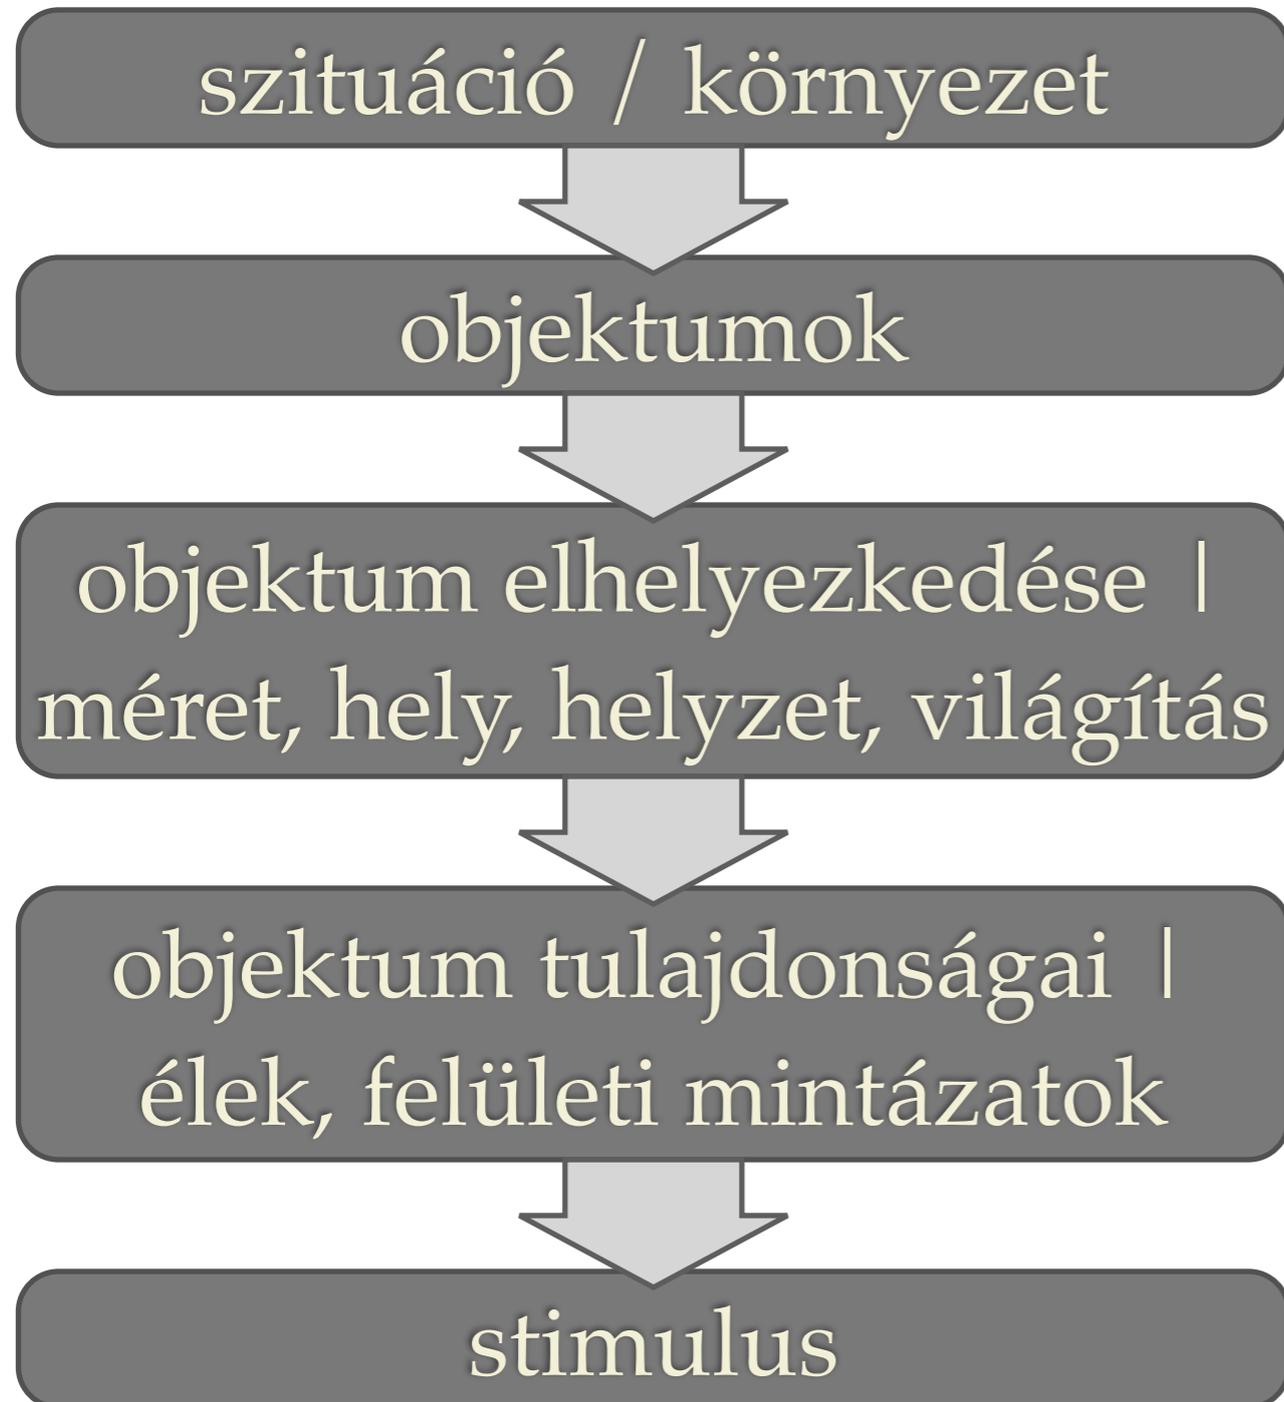
Generatív/rekogníciós modell



Generatív/rekogníciós modell



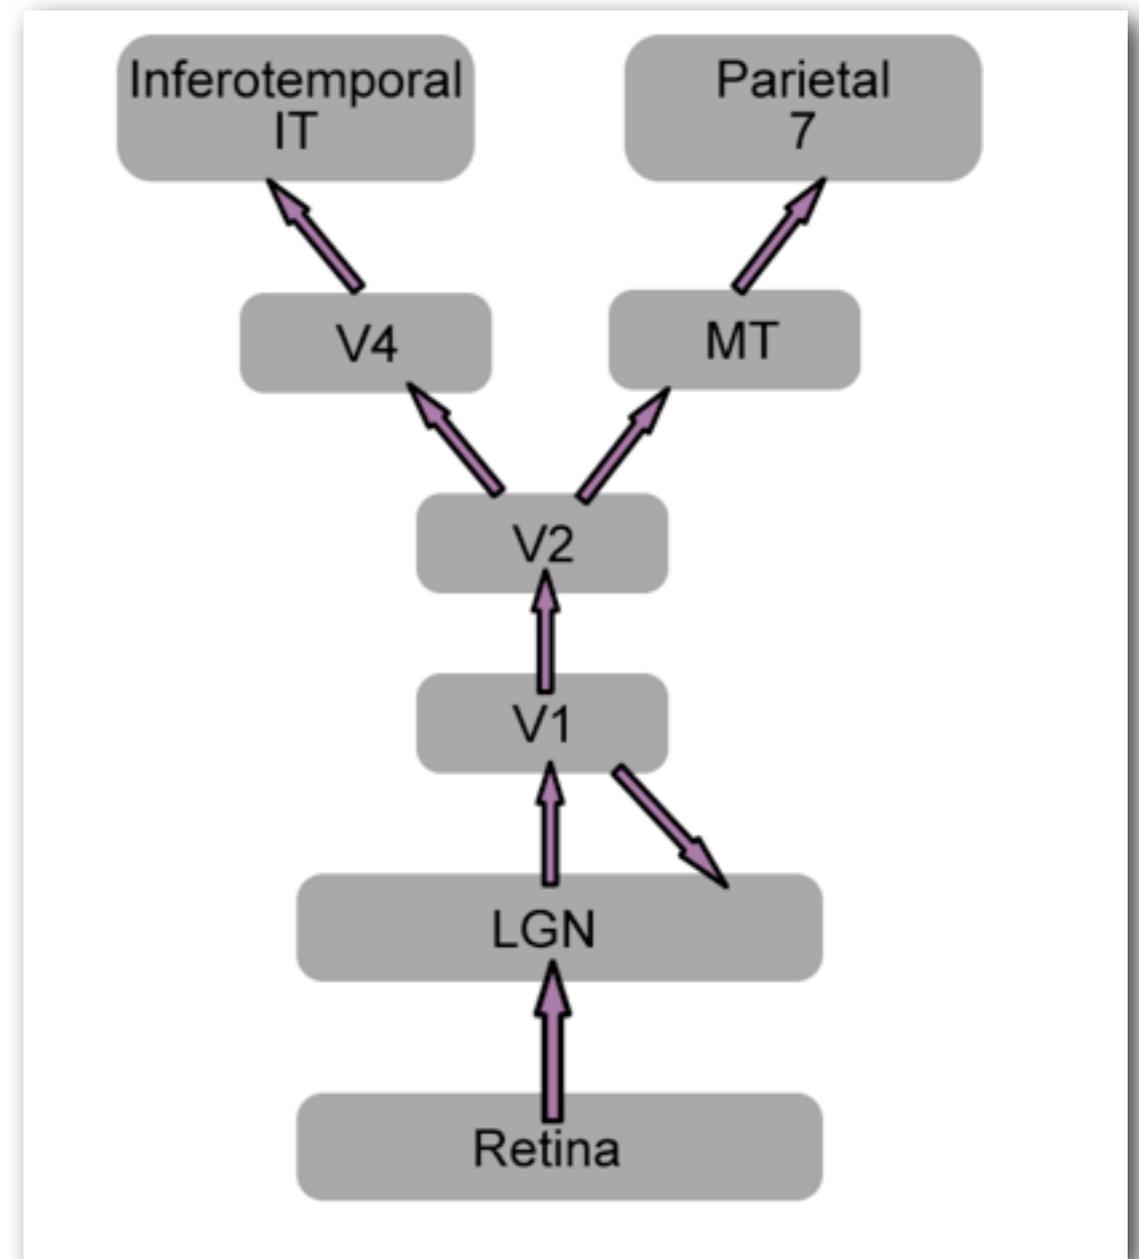
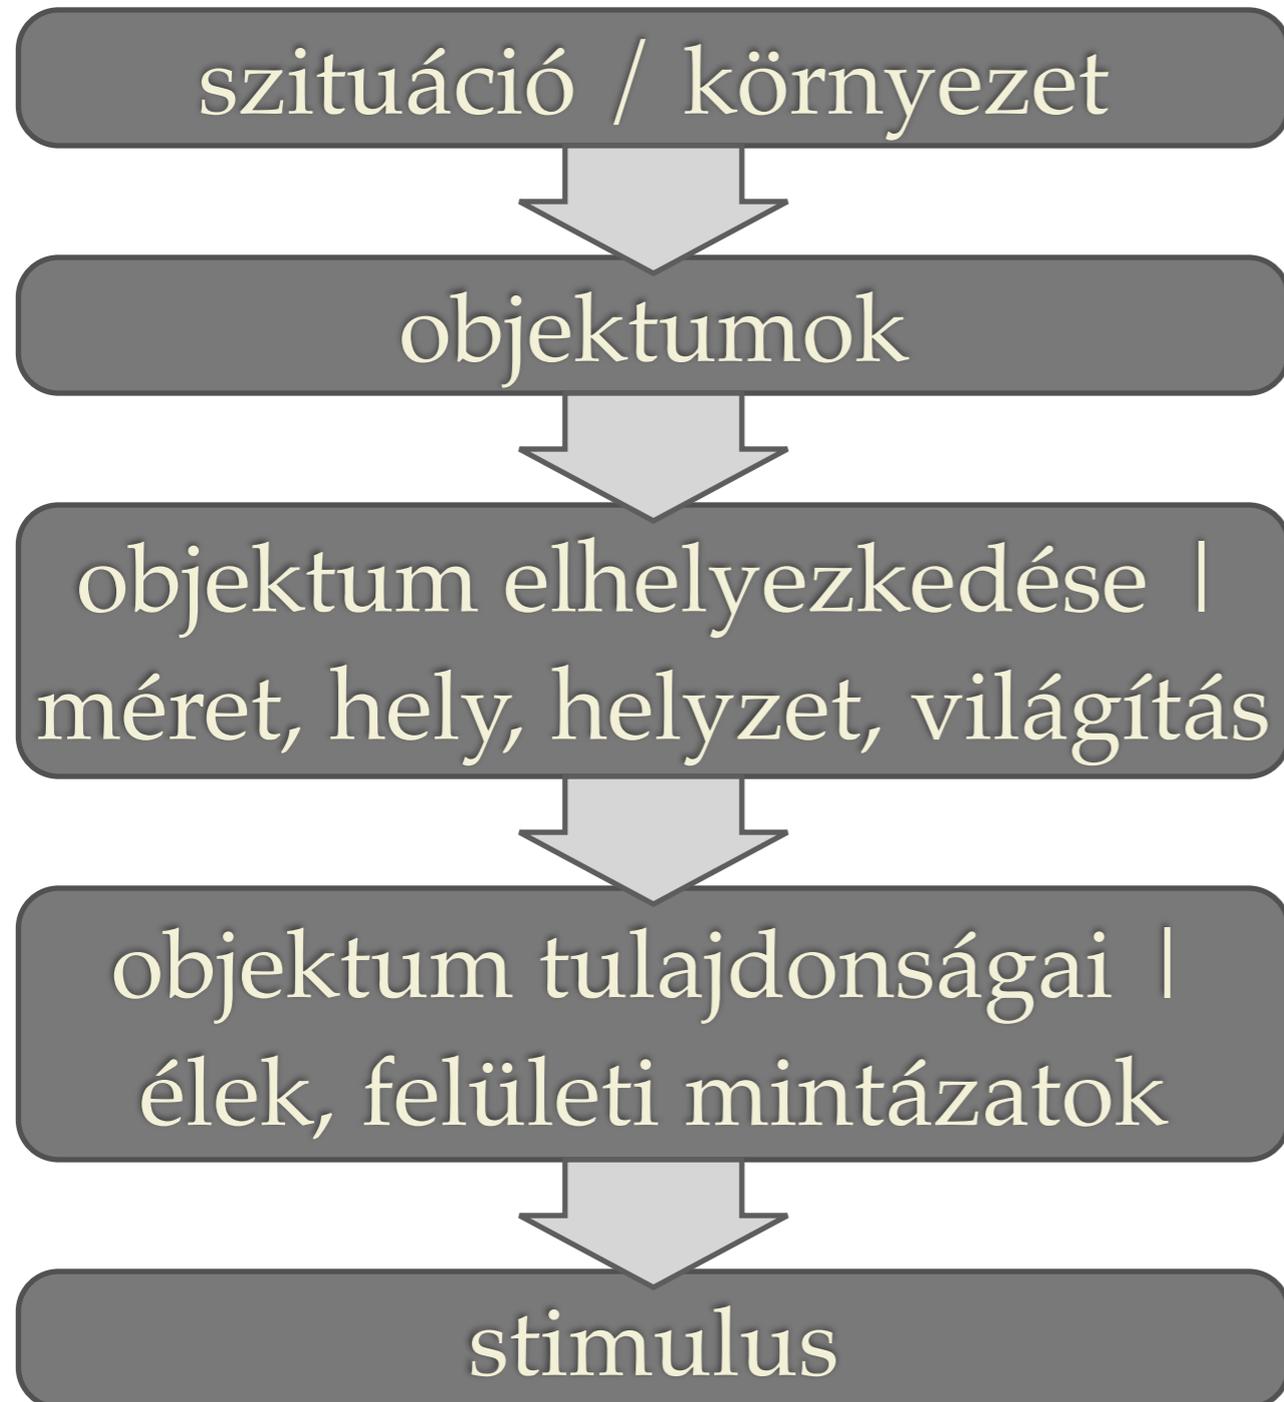
Generatív/rekogníciós modell



Modell definíció -> rekogníció:

$$P(x|z)$$

Generatív/rekogníciós modell

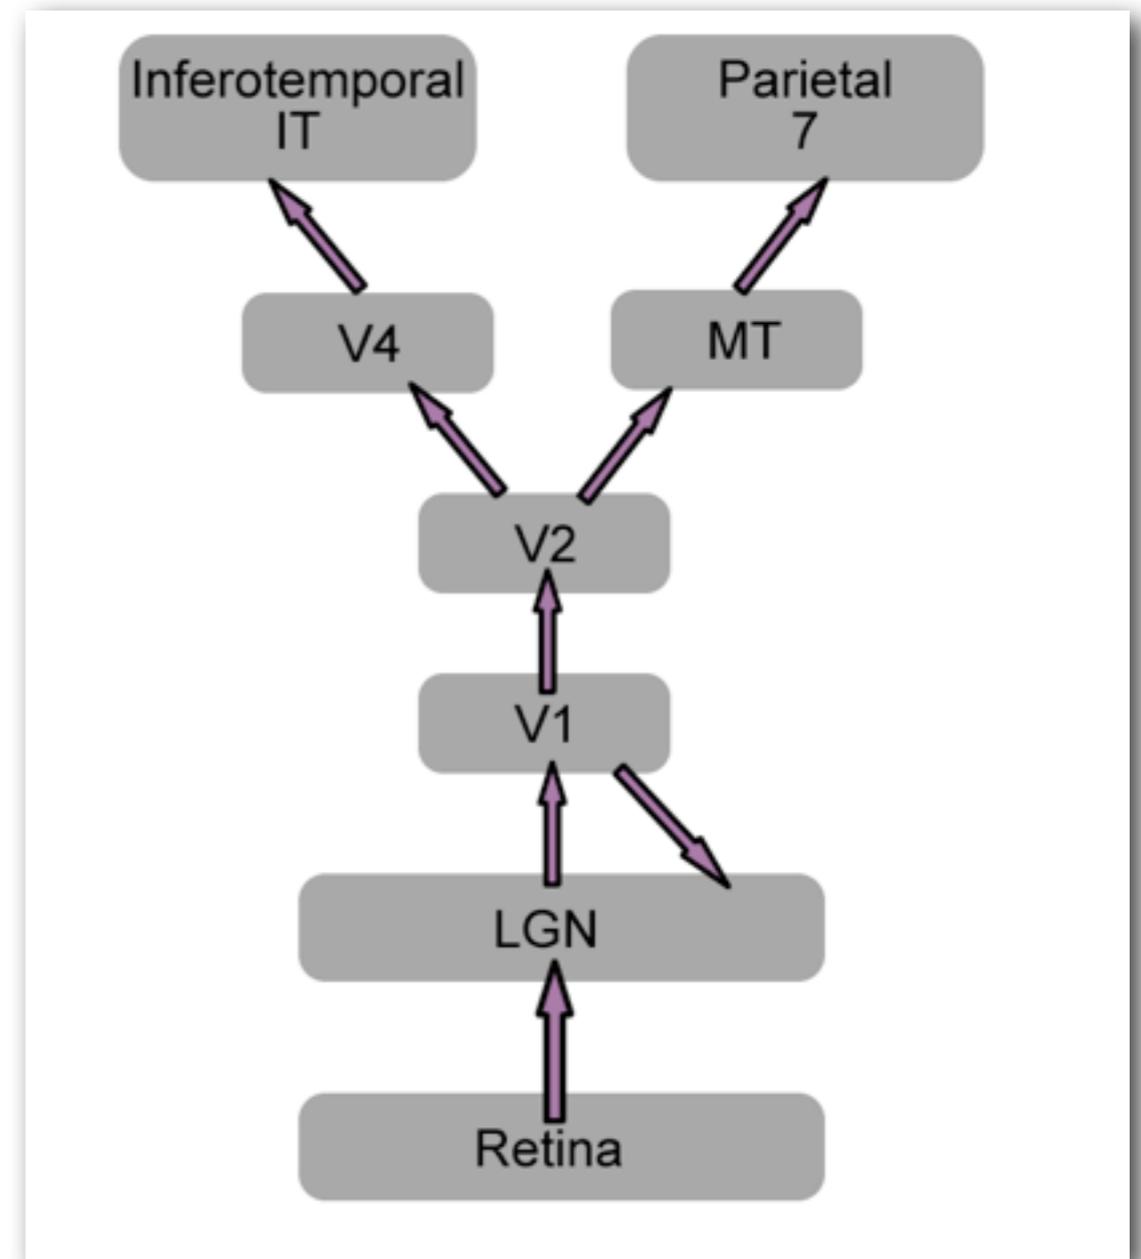
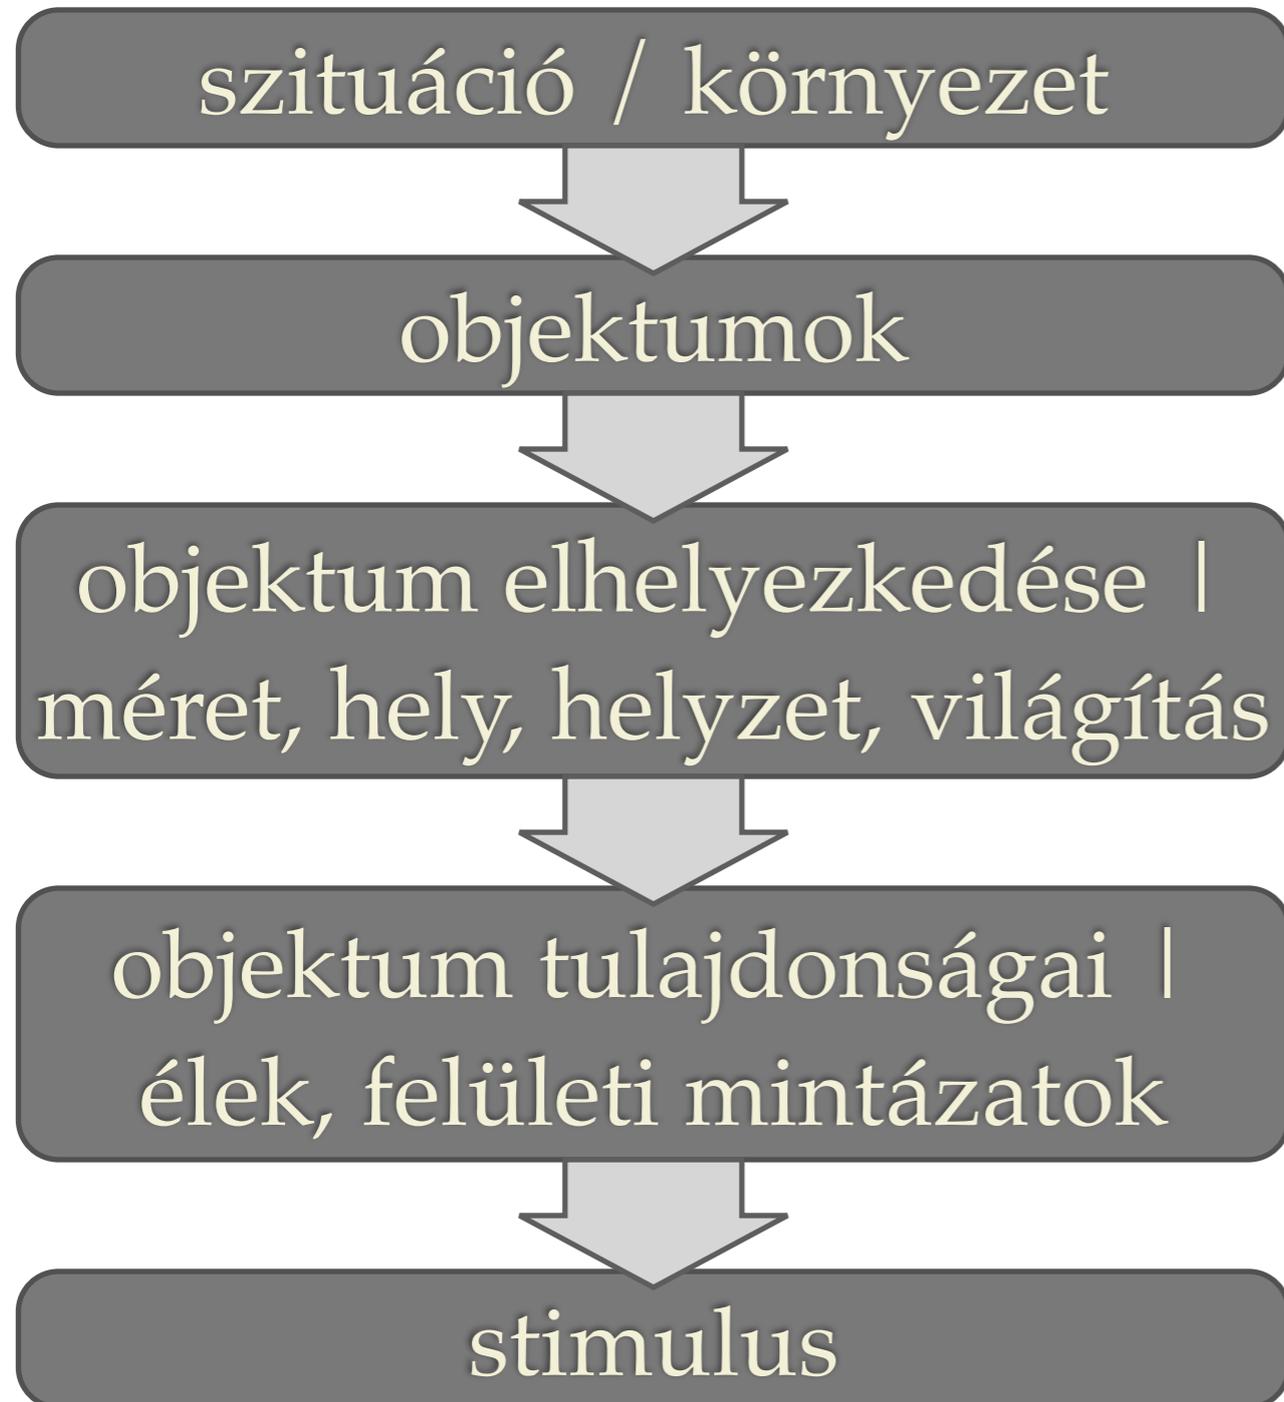


Modell definíció -> rekogníció:

$$P(x|z)$$

$$P(z|x)$$

Generatív/rekogníciós modell



Modell definíció -> rekogníció:

$$P(x|z)$$

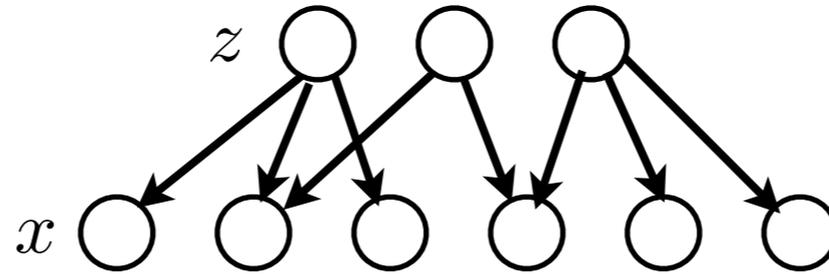
Inferencia igénye -> rekogníció:

$$P(z|x)$$

Independens komponensek

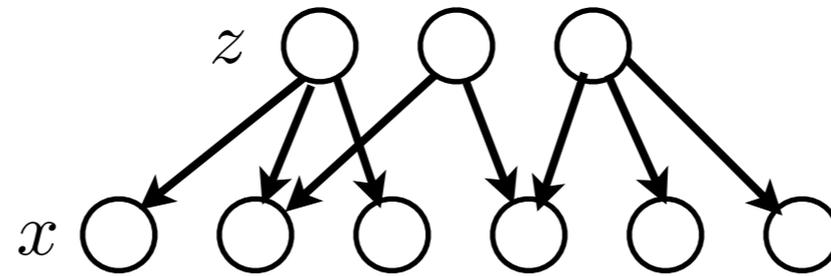
Schwartz & Simoncelli, 2001

Independens komponensek

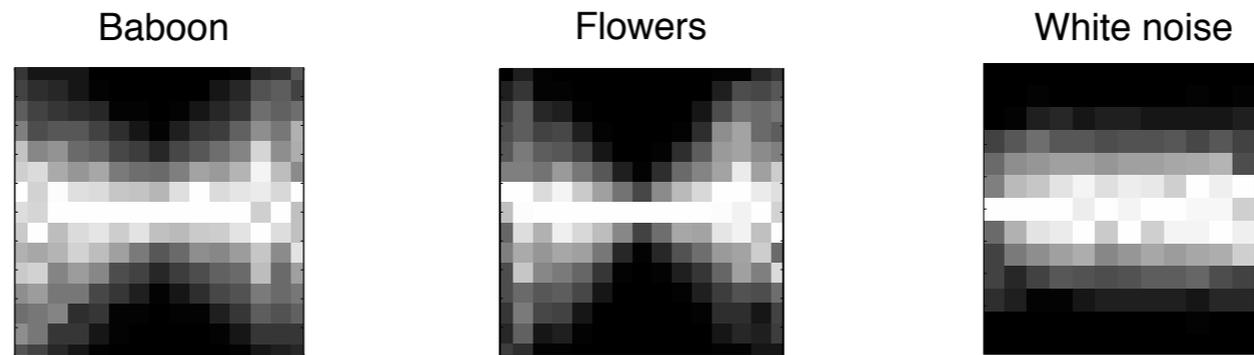


Schwartz & Simoncelli, 2001

Independens komponensek

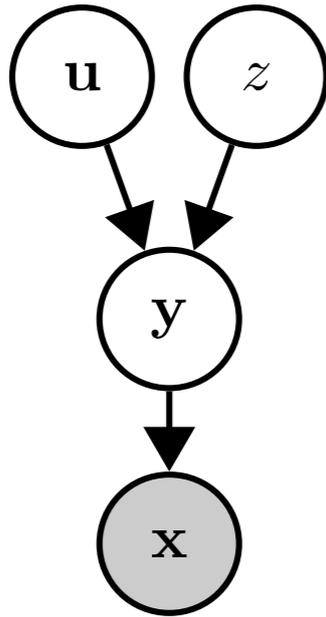


a



Schwartz & Simoncelli, 2001

Gaussian Scale Mixtures



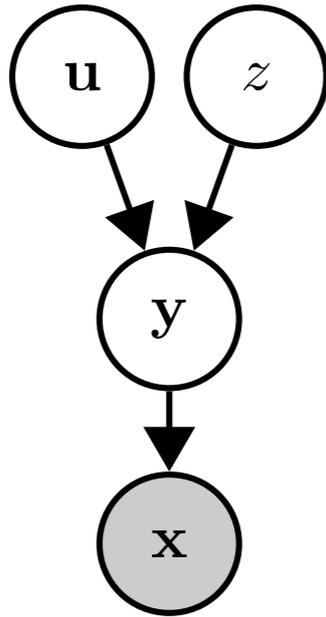
$$P(\mathbf{x}|\mathbf{y}) = \mathcal{N}(\mathbf{x}; \mathbf{A}\mathbf{y}, \sigma_x^2 \mathbf{I})$$

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

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

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

Gaussian Scale Mixtures



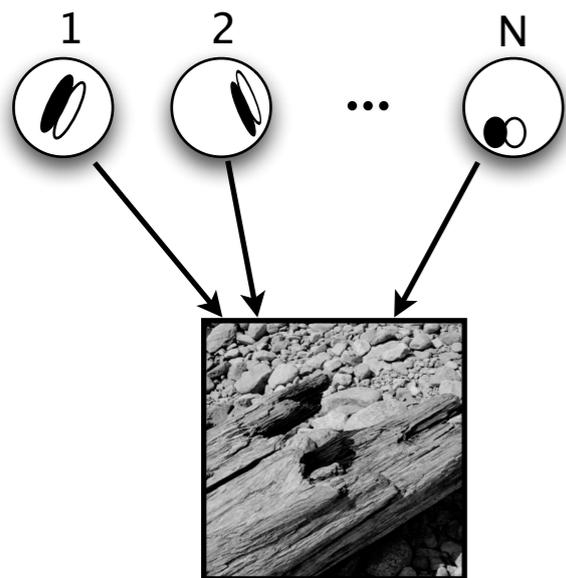
$$P(\mathbf{x}|\mathbf{y}) = \mathcal{N}(\mathbf{x}; \mathbf{A}\mathbf{y}, \sigma_x^2 \mathbf{I})$$

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

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

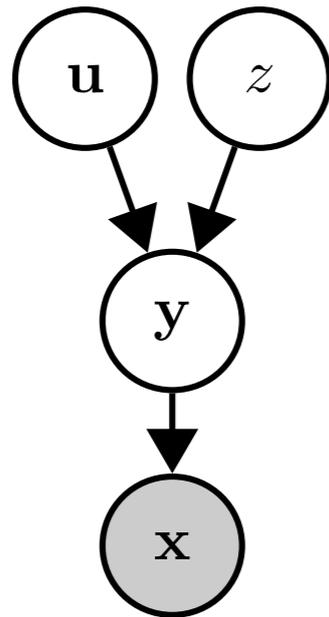
$$P(z) = \text{Gamma}(z; k, \theta)$$

linear features



image

Gaussian Scale Mixtures



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

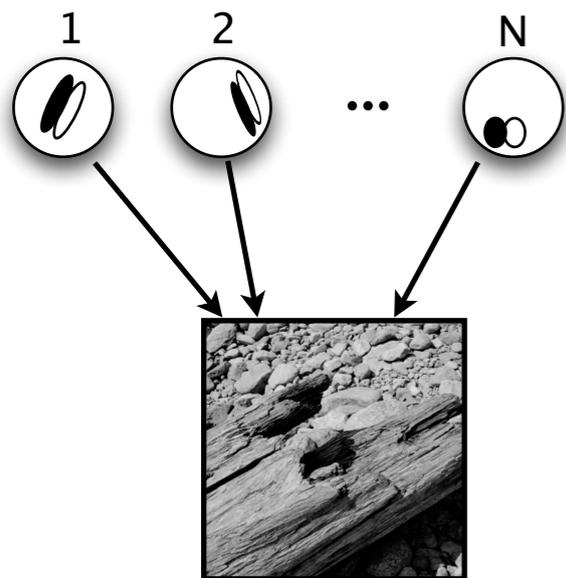
$$\mathbf{y} = z \mathbf{u}$$

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

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

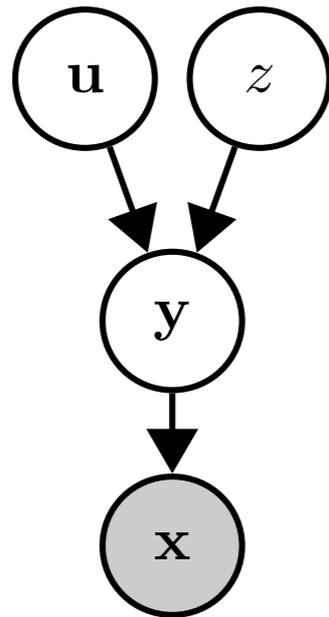
linear features

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



image

Gaussian Scale Mixtures



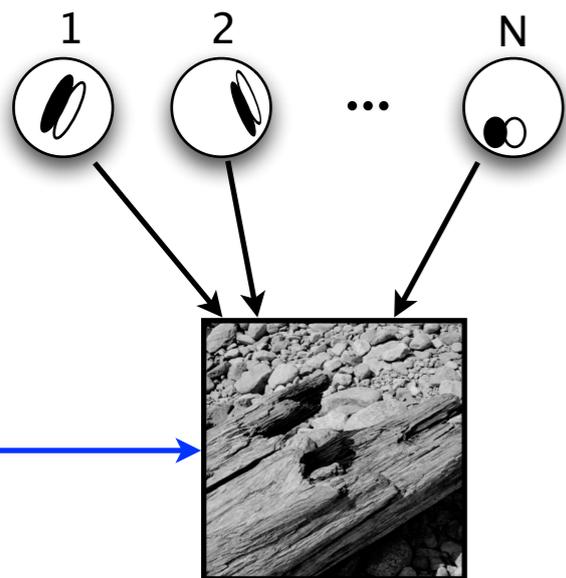
$$P(\mathbf{x}|\mathbf{y}) = \mathcal{N}(\mathbf{x}; \mathbf{A}\mathbf{y}, \sigma_x^2 \mathbf{I})$$

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

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

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

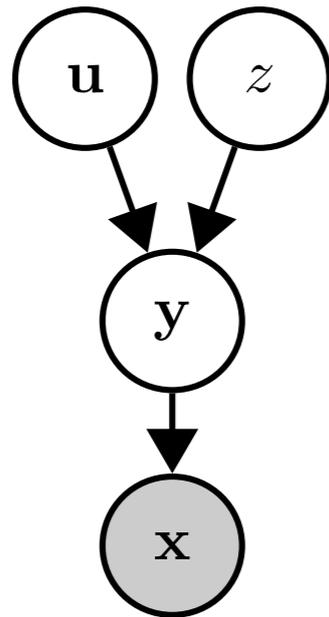
linear features



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

image

Gaussian Scale Mixtures



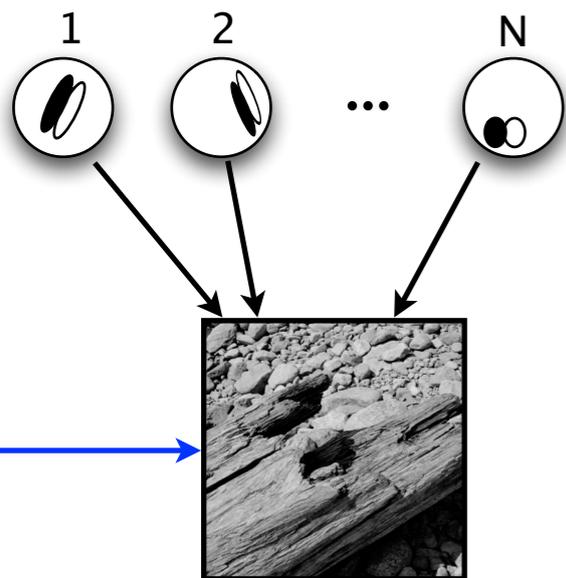
$$P(\mathbf{x}|\mathbf{y}) = \mathcal{N}(\mathbf{x}; \mathbf{A}\mathbf{y}, \sigma_x^2 \mathbf{I})$$

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

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

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

linear features



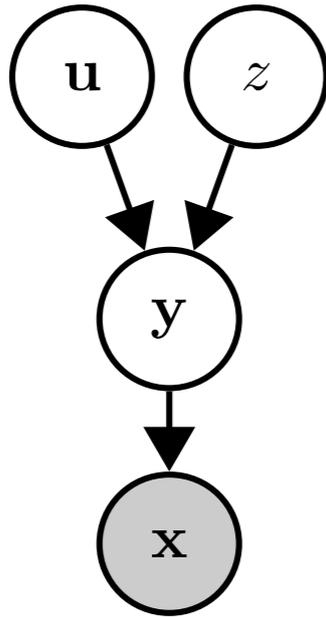
image

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

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

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

Gaussian Scale Mixtures



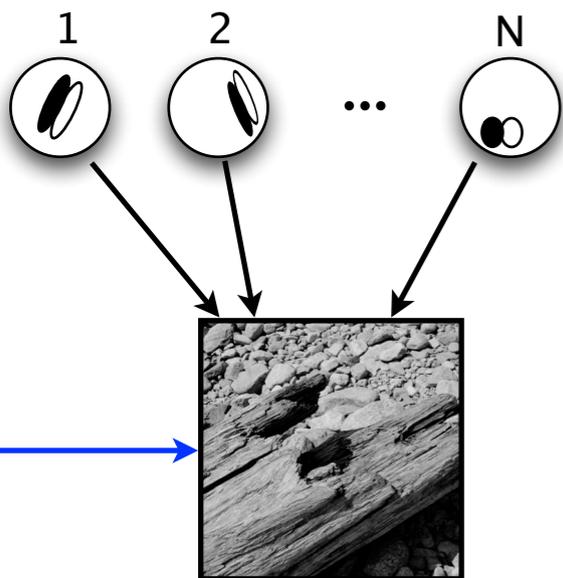
$$P(\mathbf{x}|\mathbf{y}) = \mathcal{N}(\mathbf{x}; \mathbf{A}\mathbf{y}, \sigma_x^2 \mathbf{I})$$

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

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

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

linear features



image

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

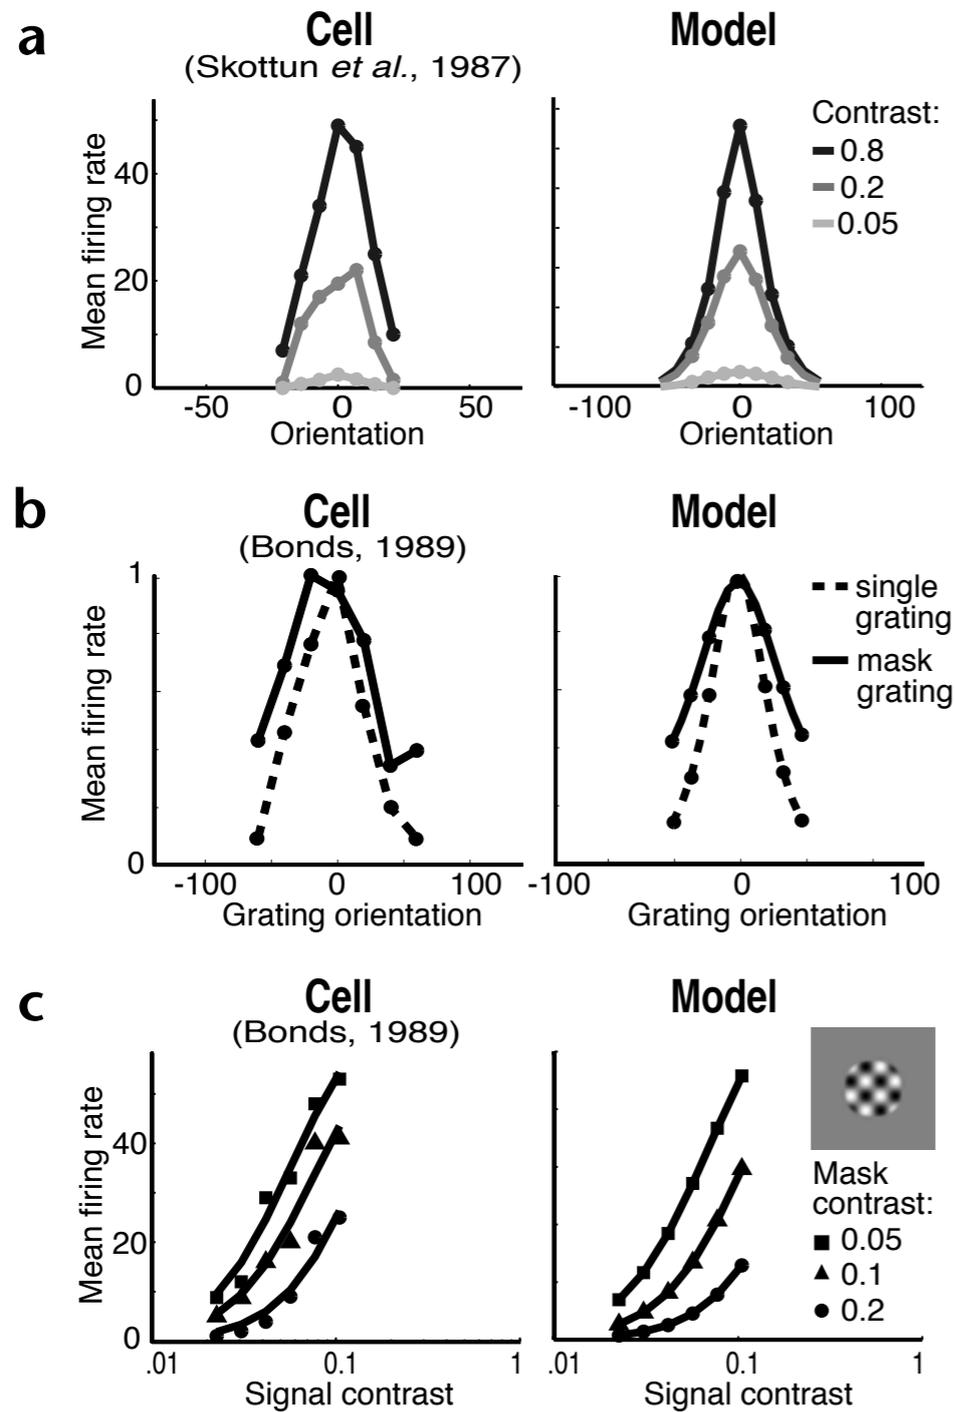
$$\text{var}(L_1|L_2) = wL_2^2 + \sigma^2$$

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

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

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

Neurális adatok és GSM



Schwartz & Simoncelli, 2001

