
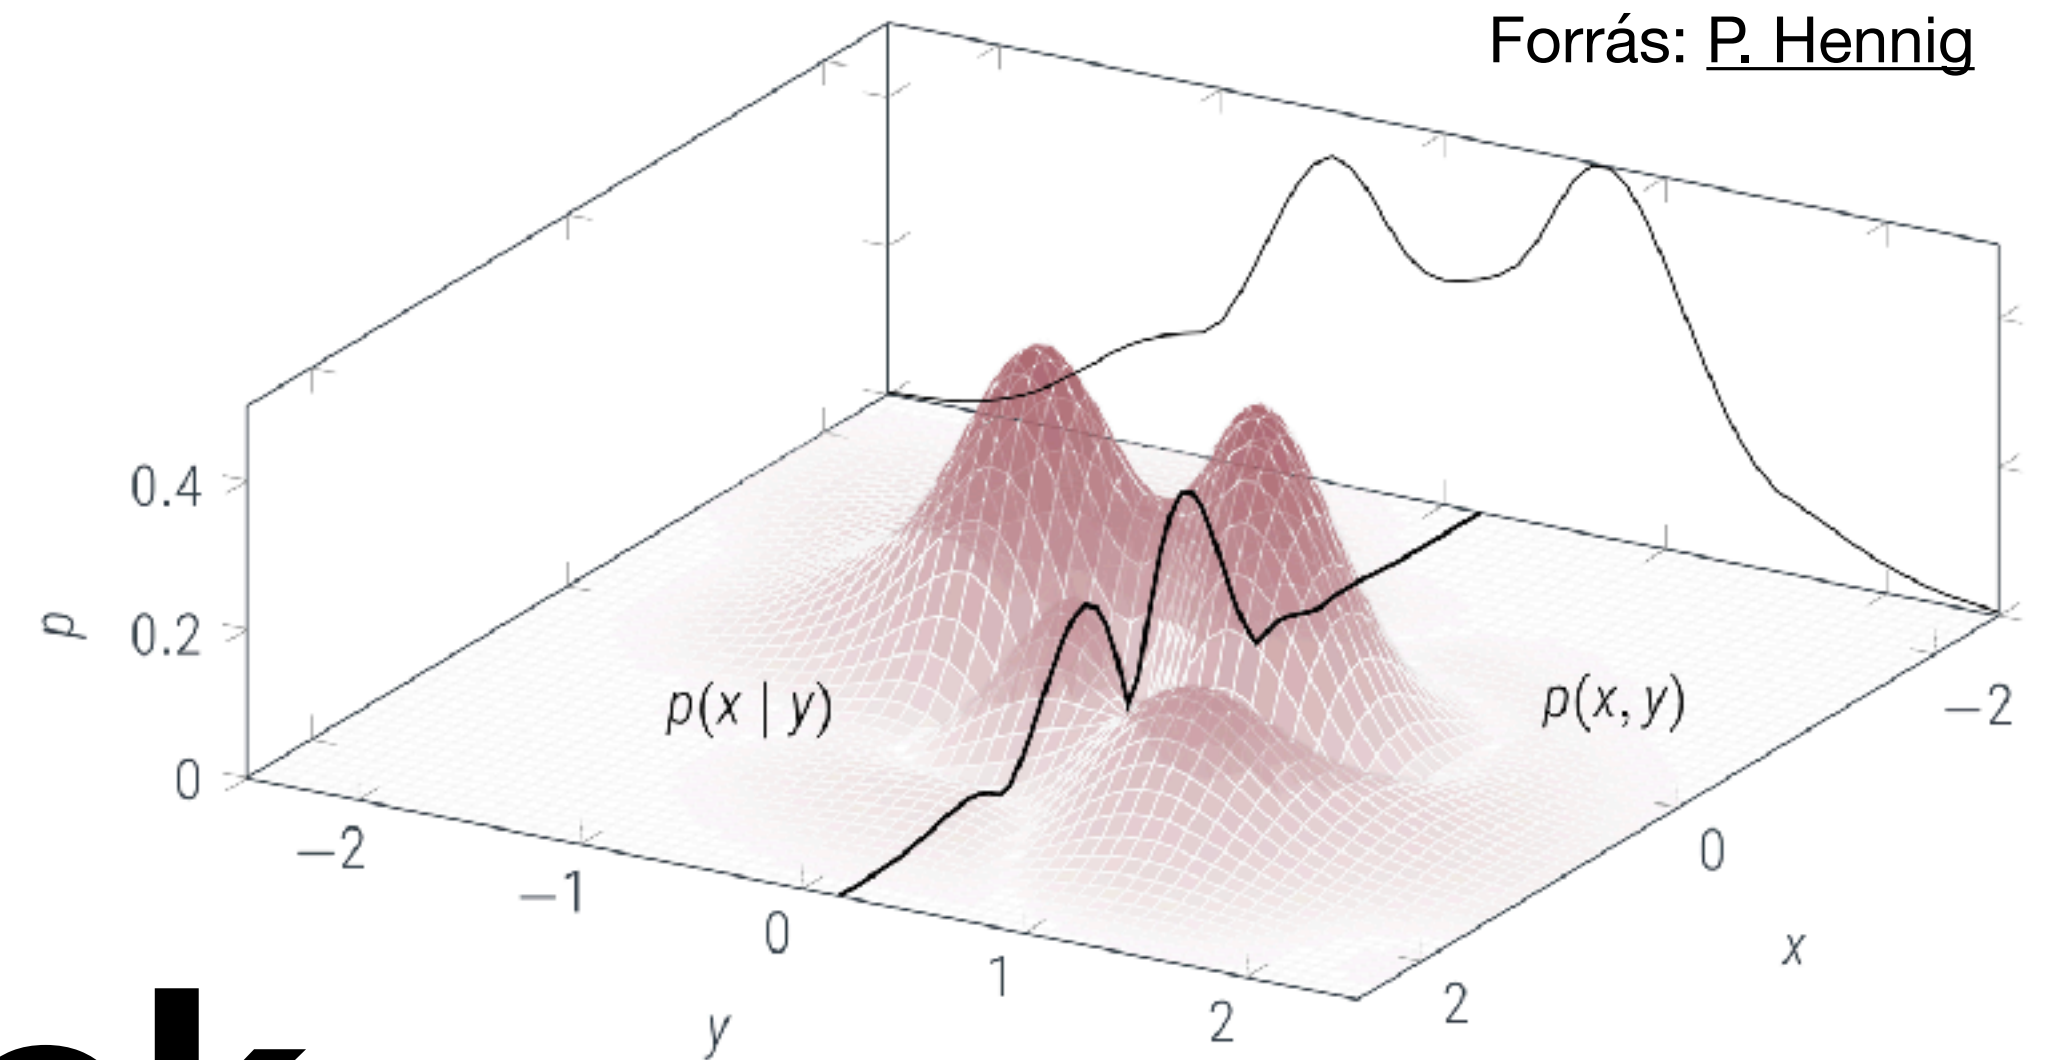


# 5. Előadás: Matematikai Alapok

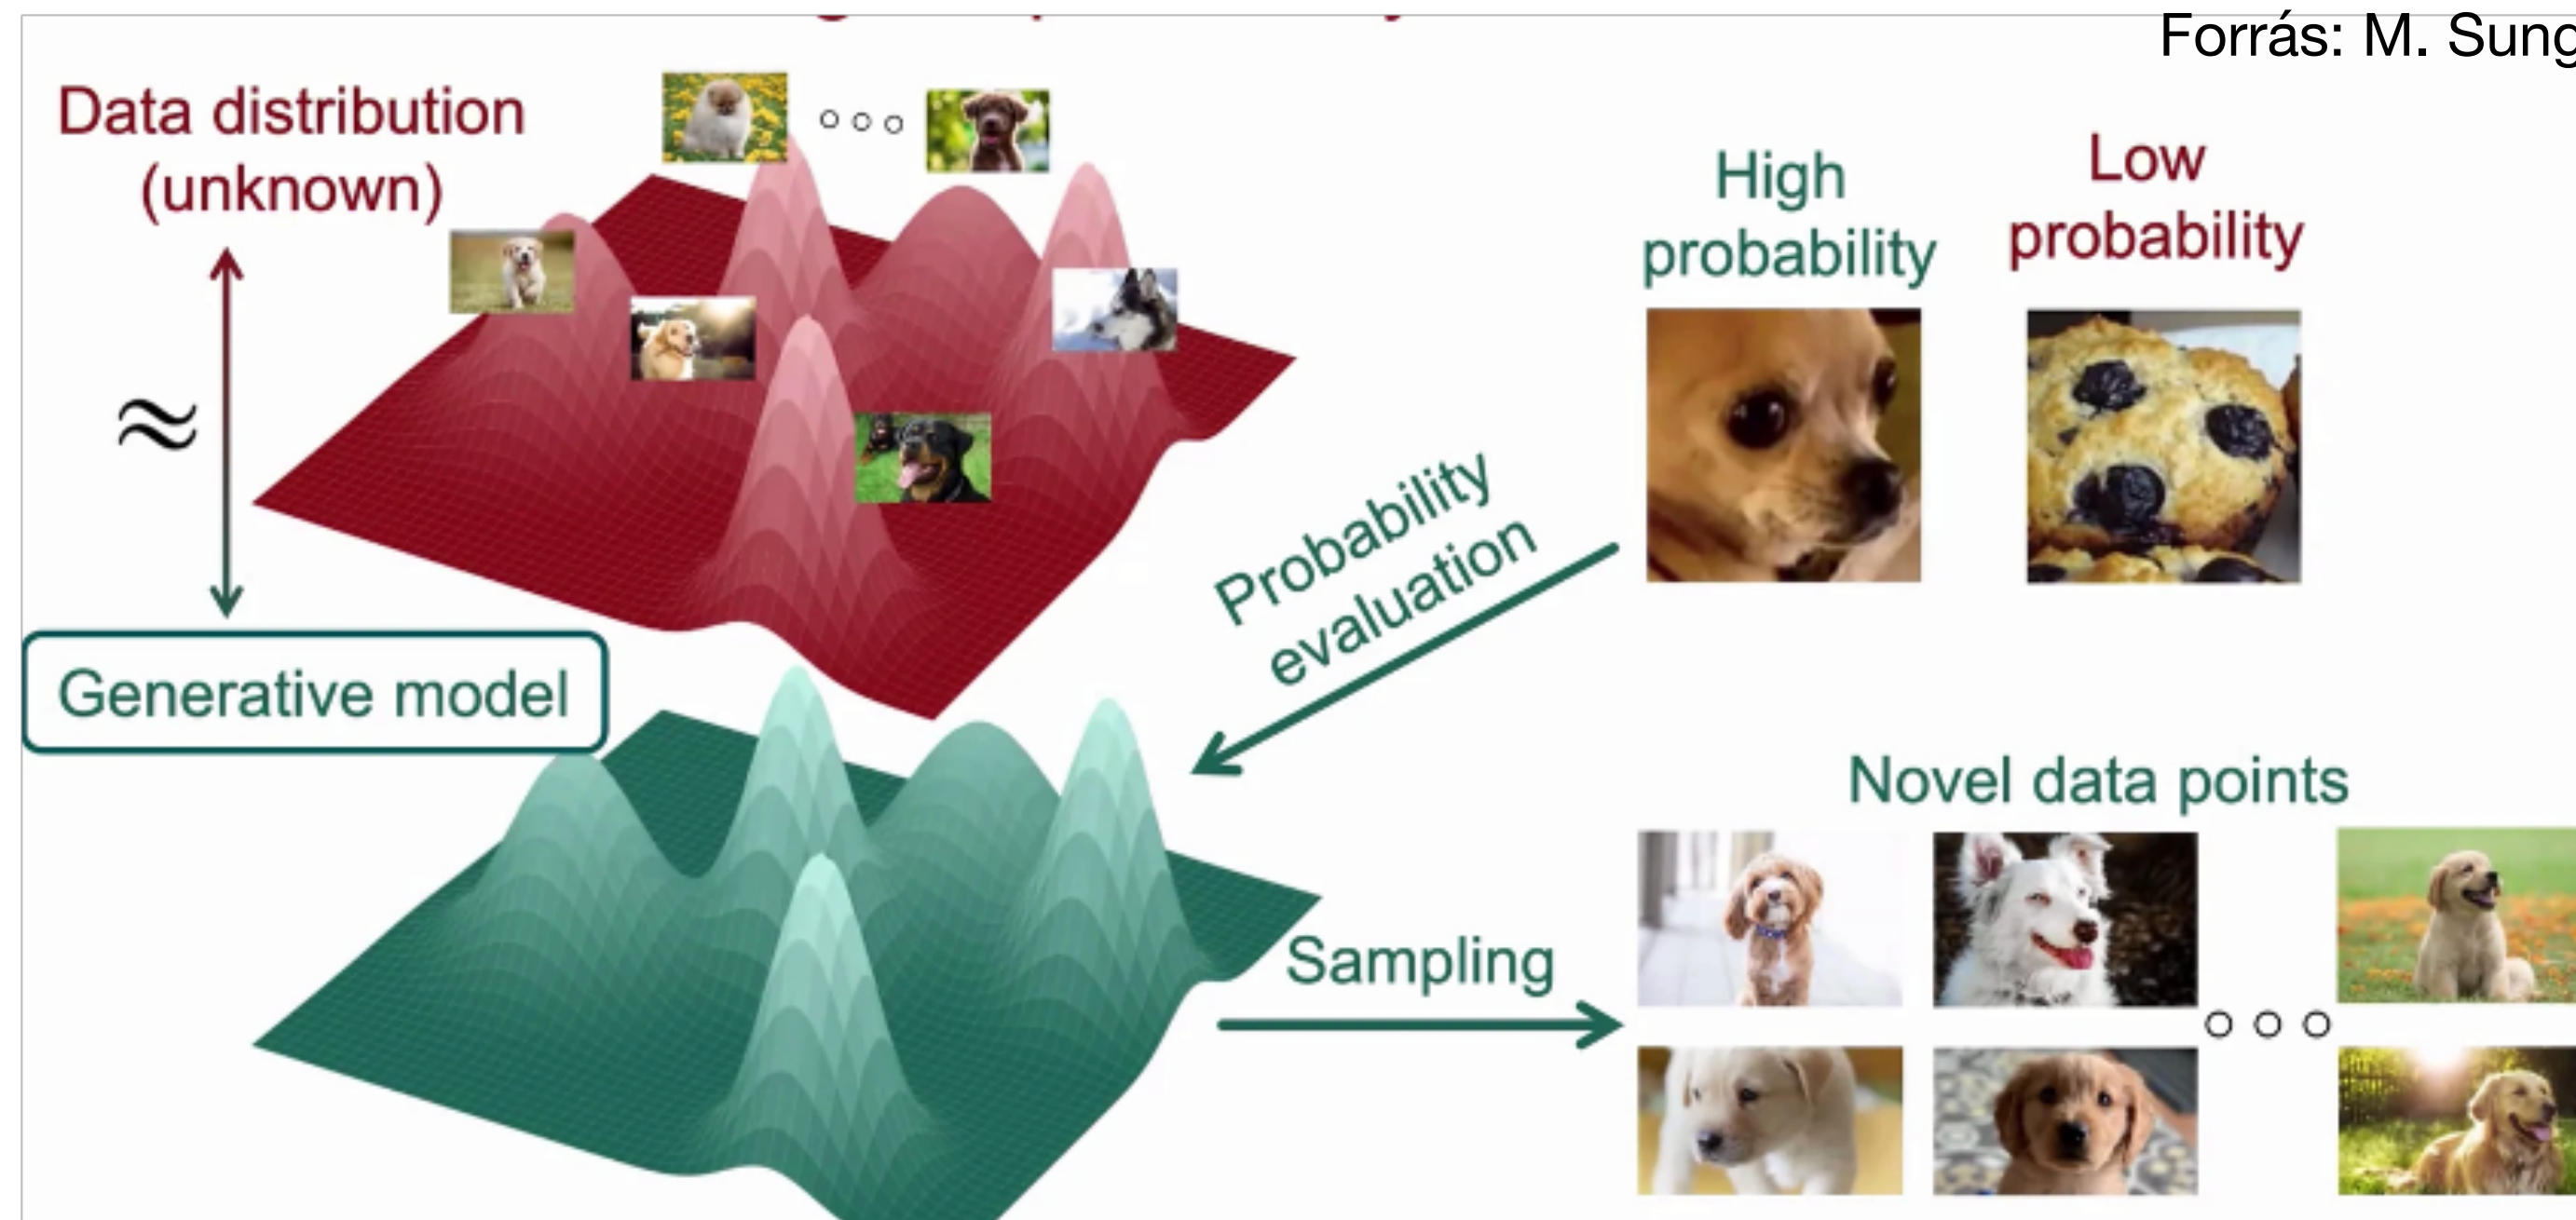
Generatív AI és Inverz Módszerek a Képszintézisben  
*BME-VIK IIT, 2026*



Dr. Vaitkus Márton



# A Generatív Modellezés Felé...



**Generatív modell**: adathalmazok eloszlását modellezi & új mintákat generál  
Hogyan modellezünk és mintavételezünk általános eloszlásokat?

# Valószínűségi eloszlások

## Alapok

- Valószínűségi eloszlás (PDF):

- $0 \leq p(x) \leq 1, \forall x \in \Omega$

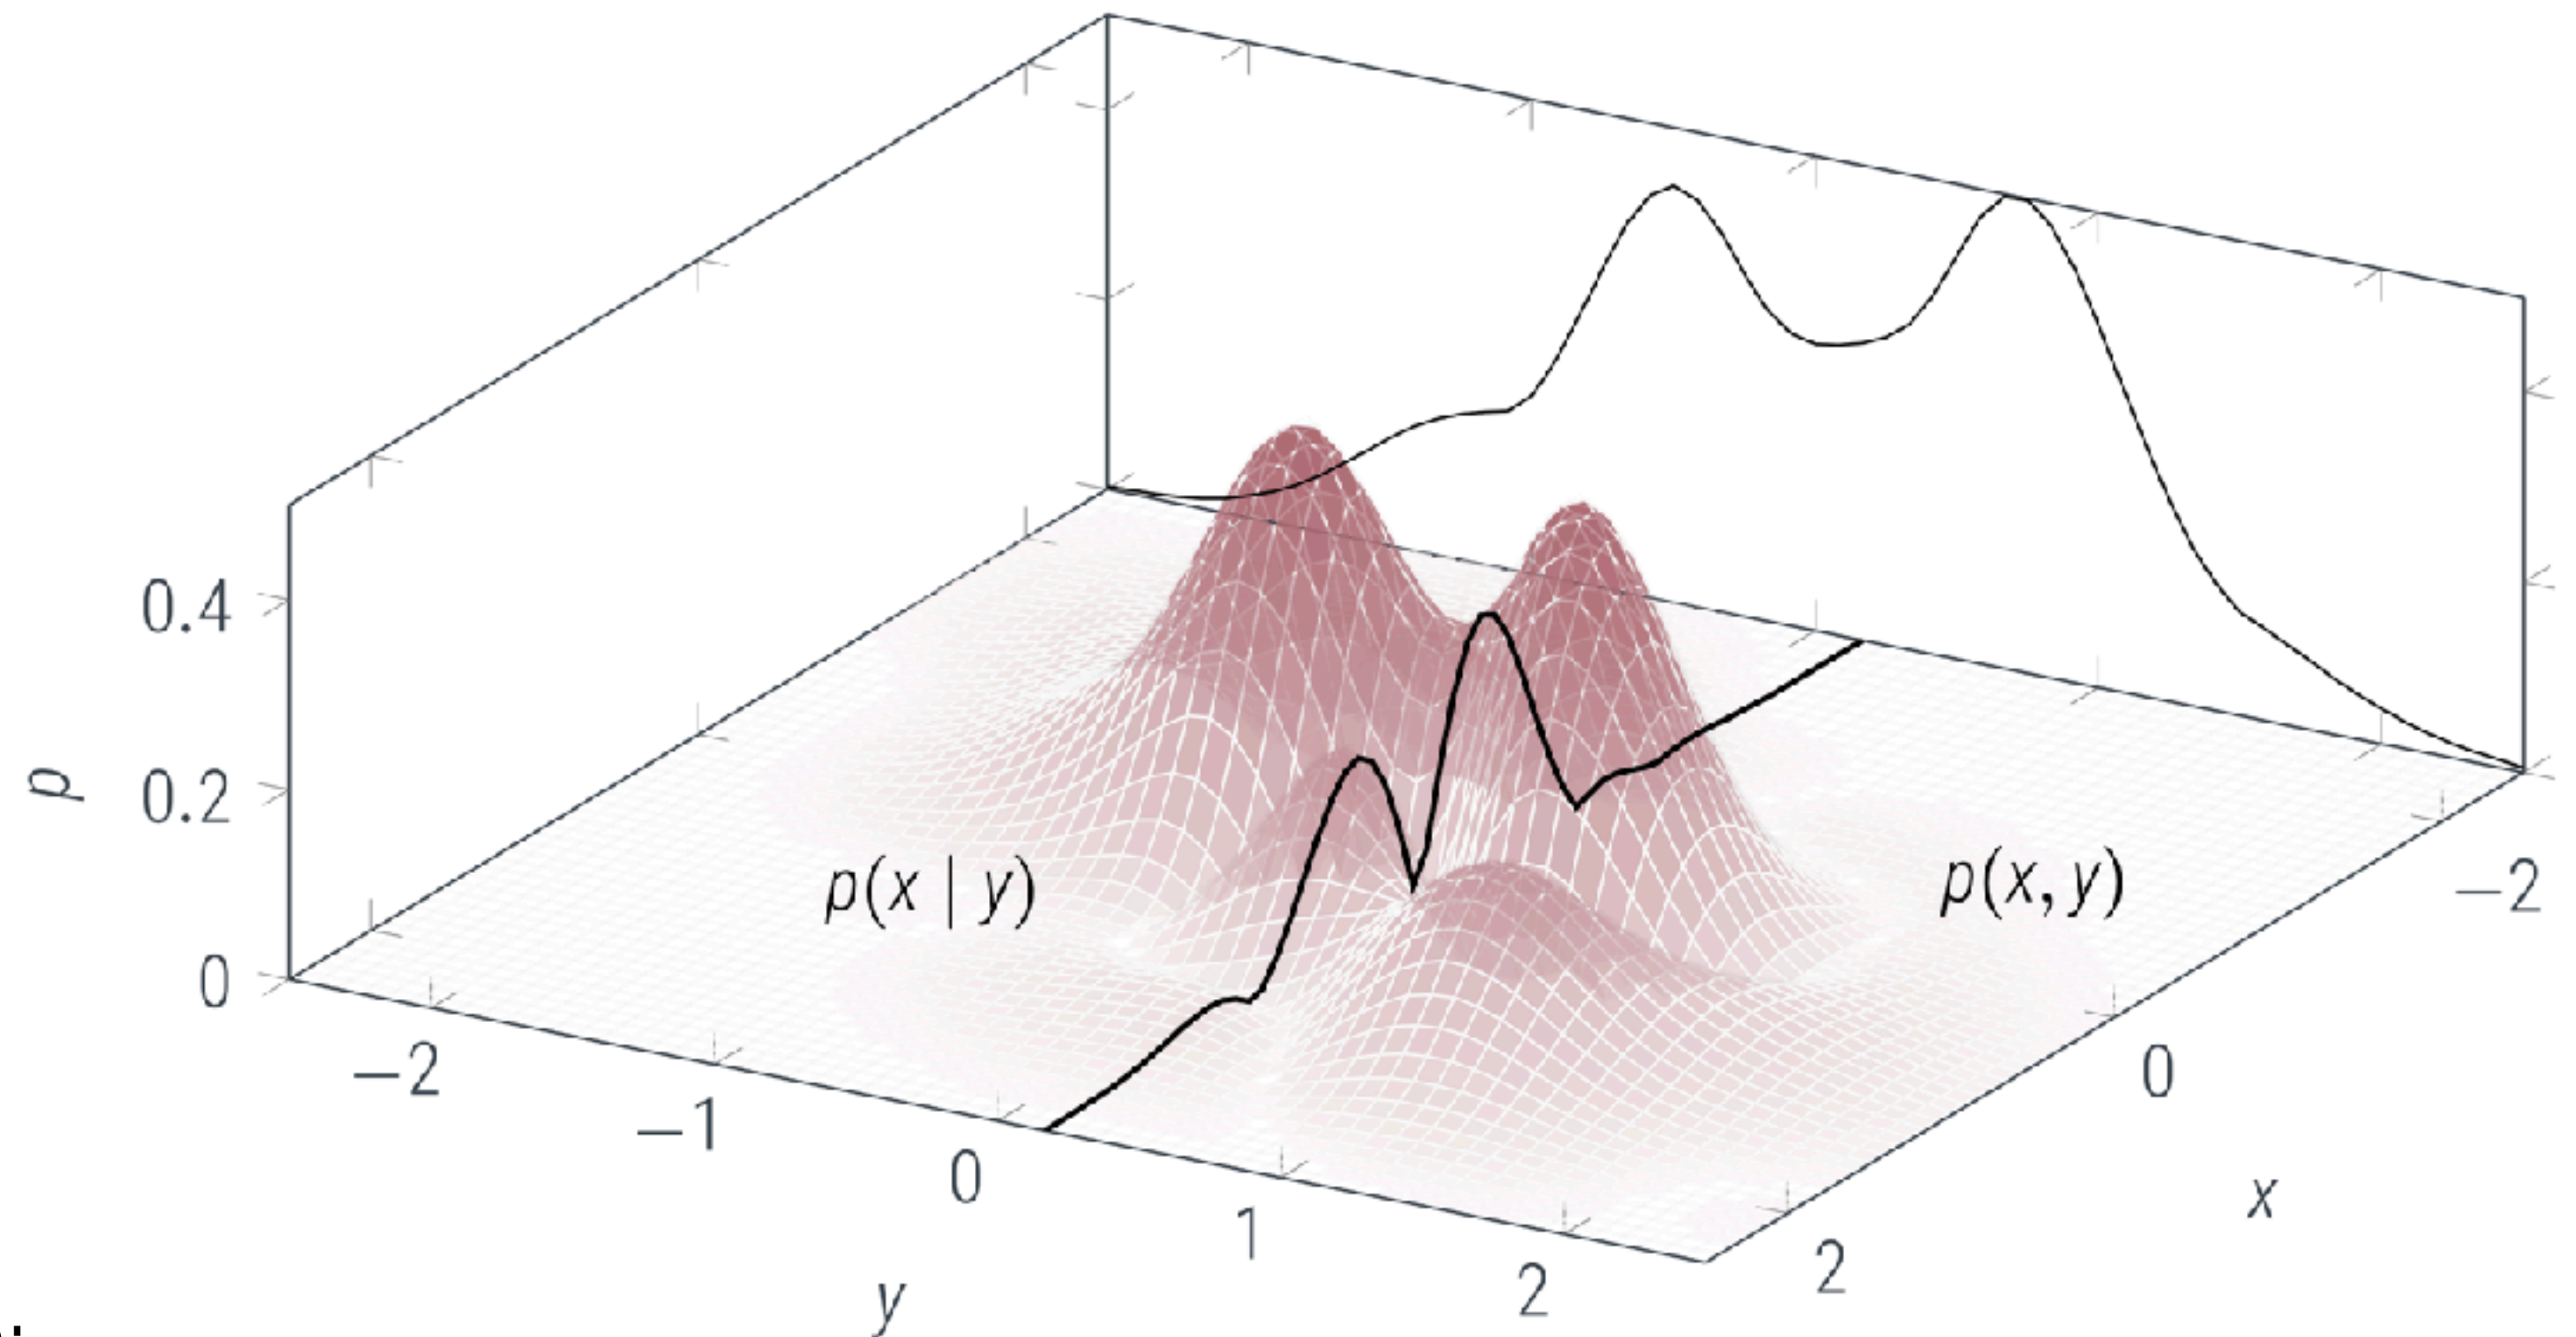
- $\int_{\Omega} p(x) dx = 1$  ☠

- Marginális valószínűség:

- $p(x) = \int p(x, y) dy$  ☠

- Feltételes valószínűség (láncszabály):

- $p(x, y) = p(y | x) \cdot p(x) = p(x | y) \cdot p(y)$



Forrás: [P. Hennig](#)

# Valószínűségi eloszlások

## Bayes formula

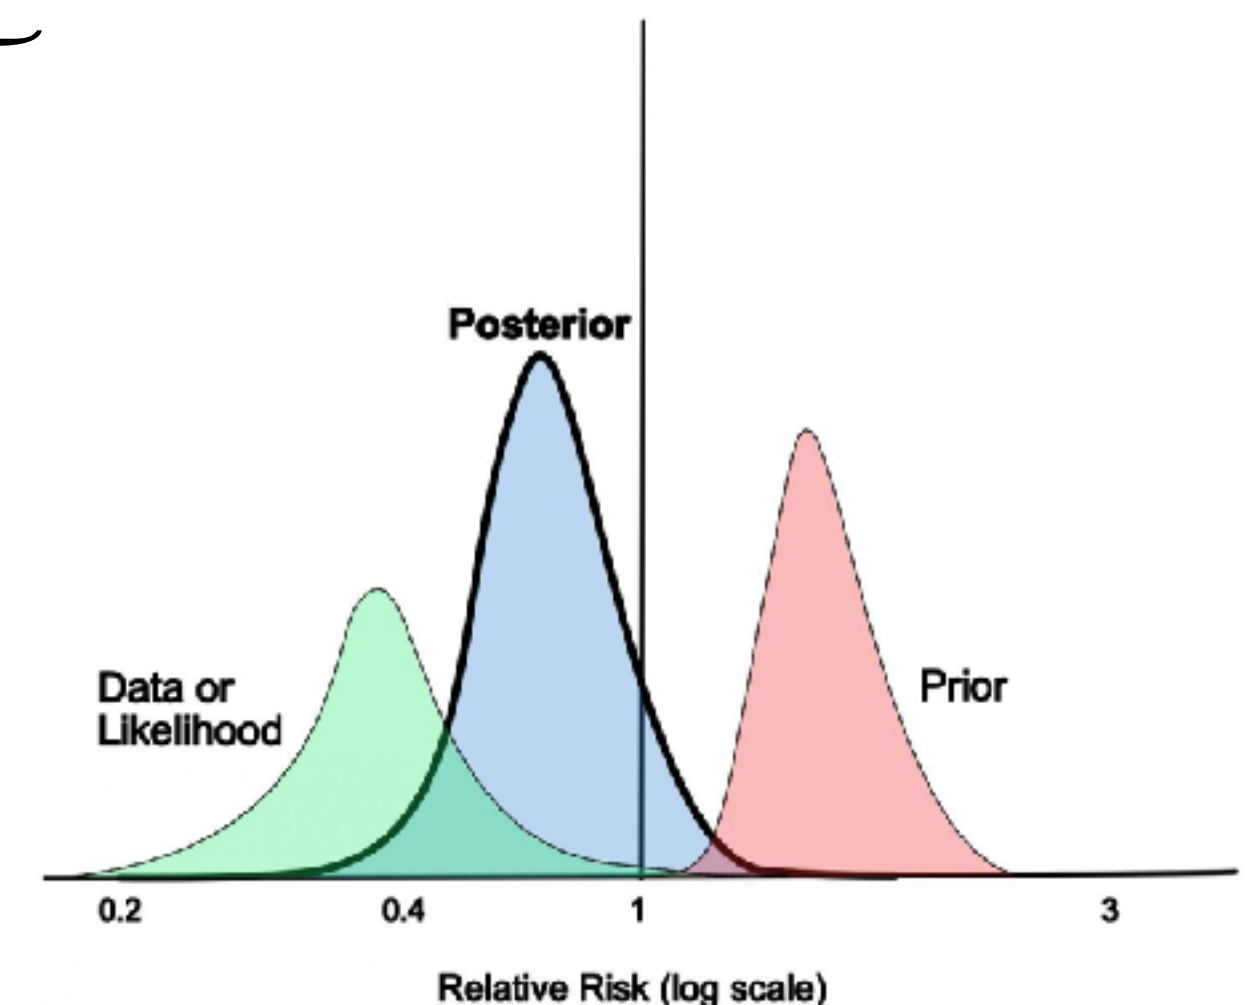
- A feltételes valószínűségek megfordíthatóak — **Bayes formula:**

$$\underbrace{p(y | x)}_{\text{Posterior}} = \frac{p(x | y) \overbrace{p(y)}^{\text{Prior}}}{p(x)} = \frac{p(x | y)p(y)}{\underbrace{\int p(x | Y)p(Y)dY}_{\text{Skull and Crossbones}}}$$

**Bayes  
következtetés /  
inferencia**



$P(A|B) = [P(A)*P(B|A)]/P(B)$ , all the rest is commentary.

De legyünk óvatosak:  
nem biztos, hogy ki is tudjuk számolni!





# Valószínűségi eloszlások

## Bayes formula – Video ajánló



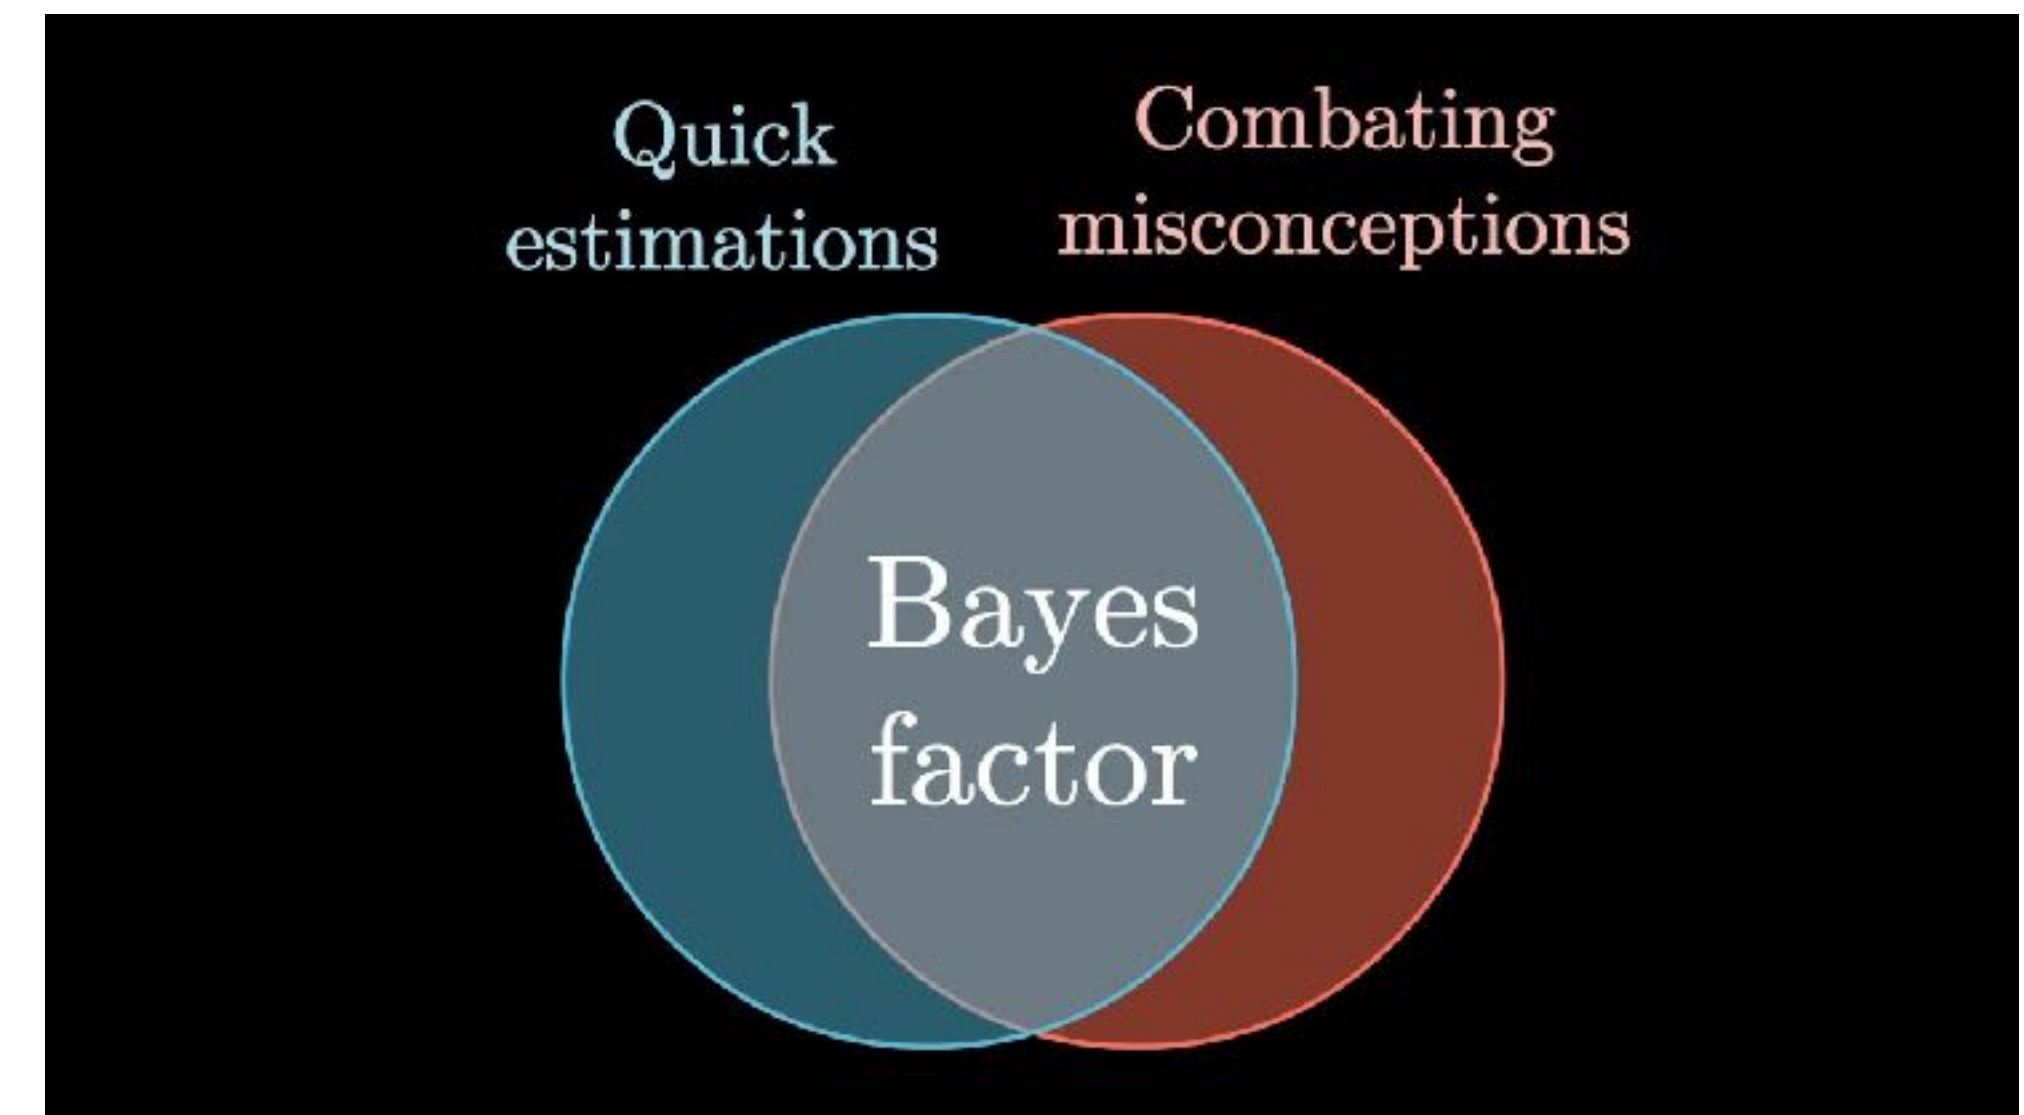
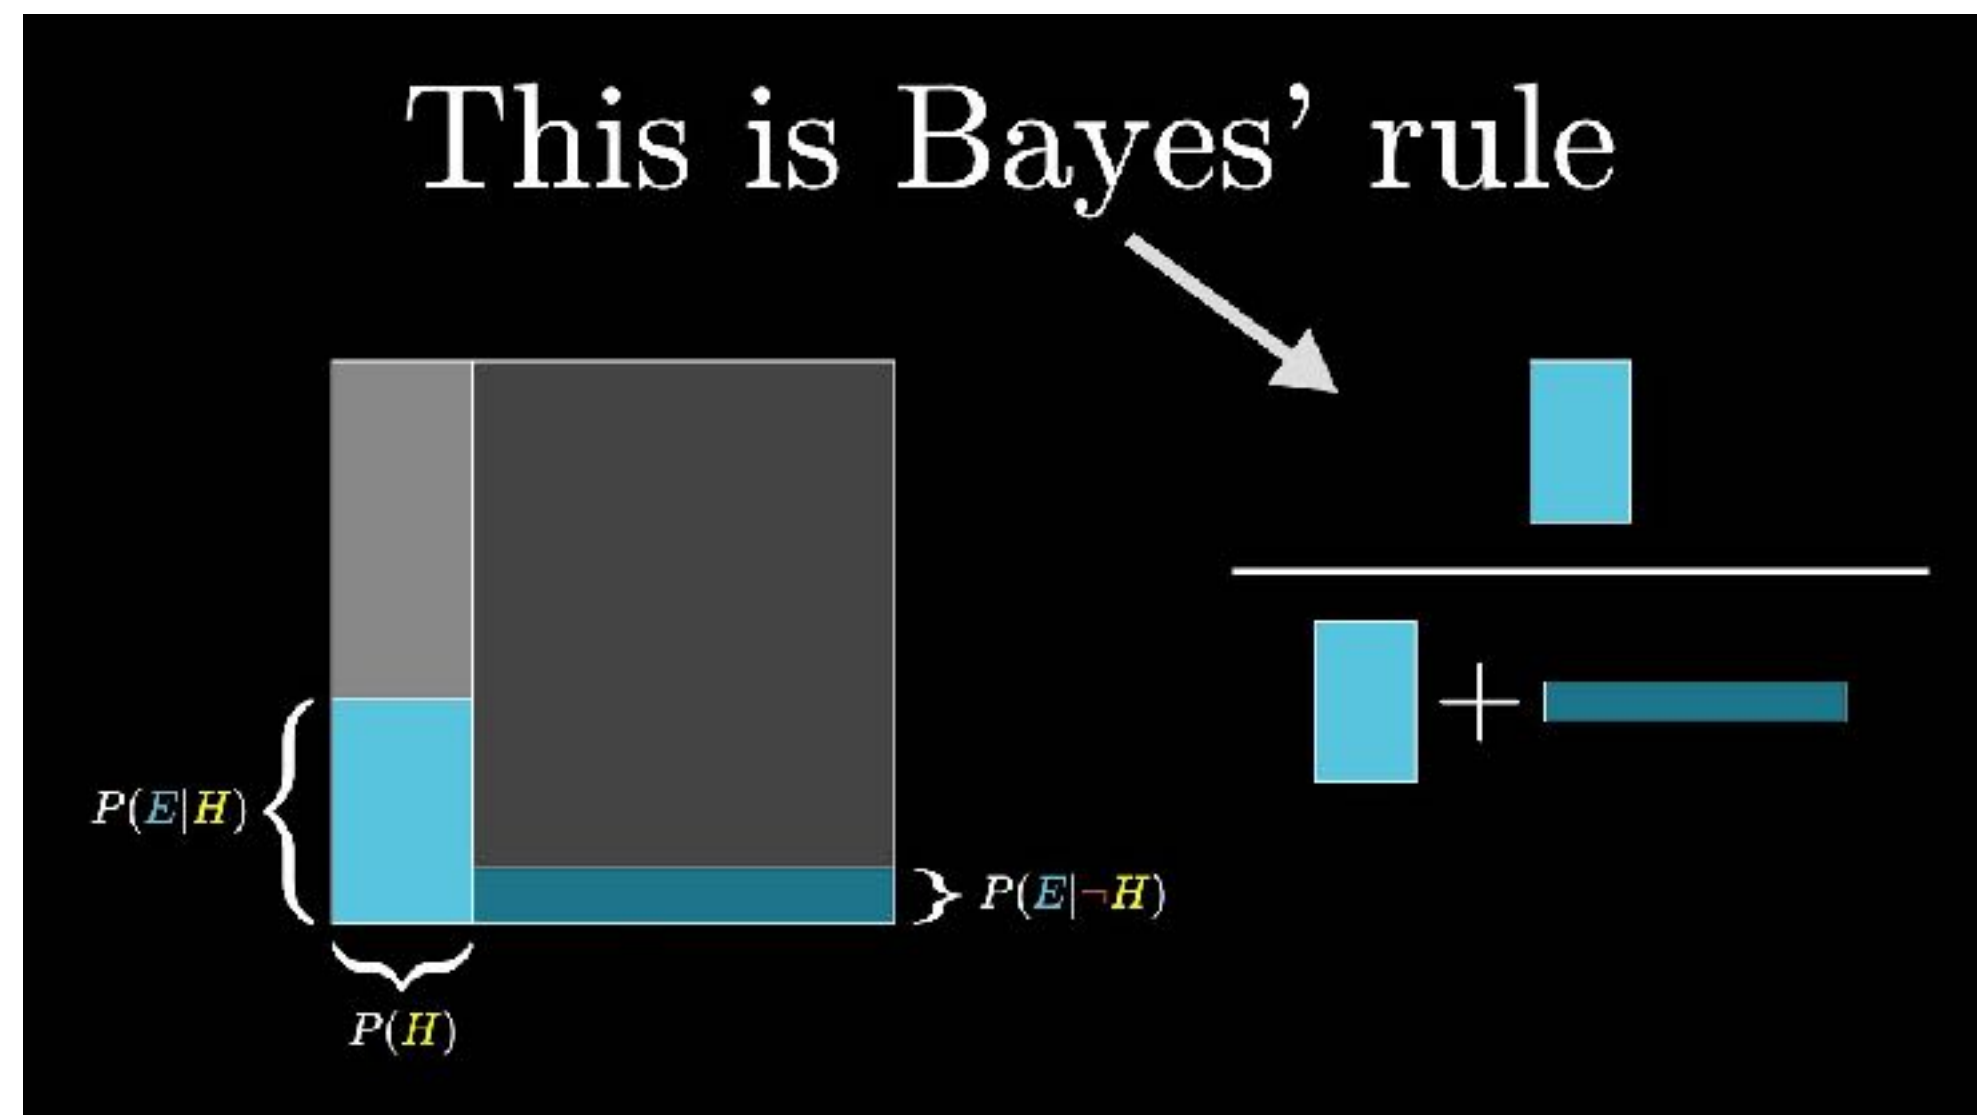
# Valószínűségi eloszlások

## Bayes formula – Video ajánló



# Valószínűségi eloszlások

## Bayes formula – Video ajánló



# Valószínűségi Eloszlások

## Statisztikák

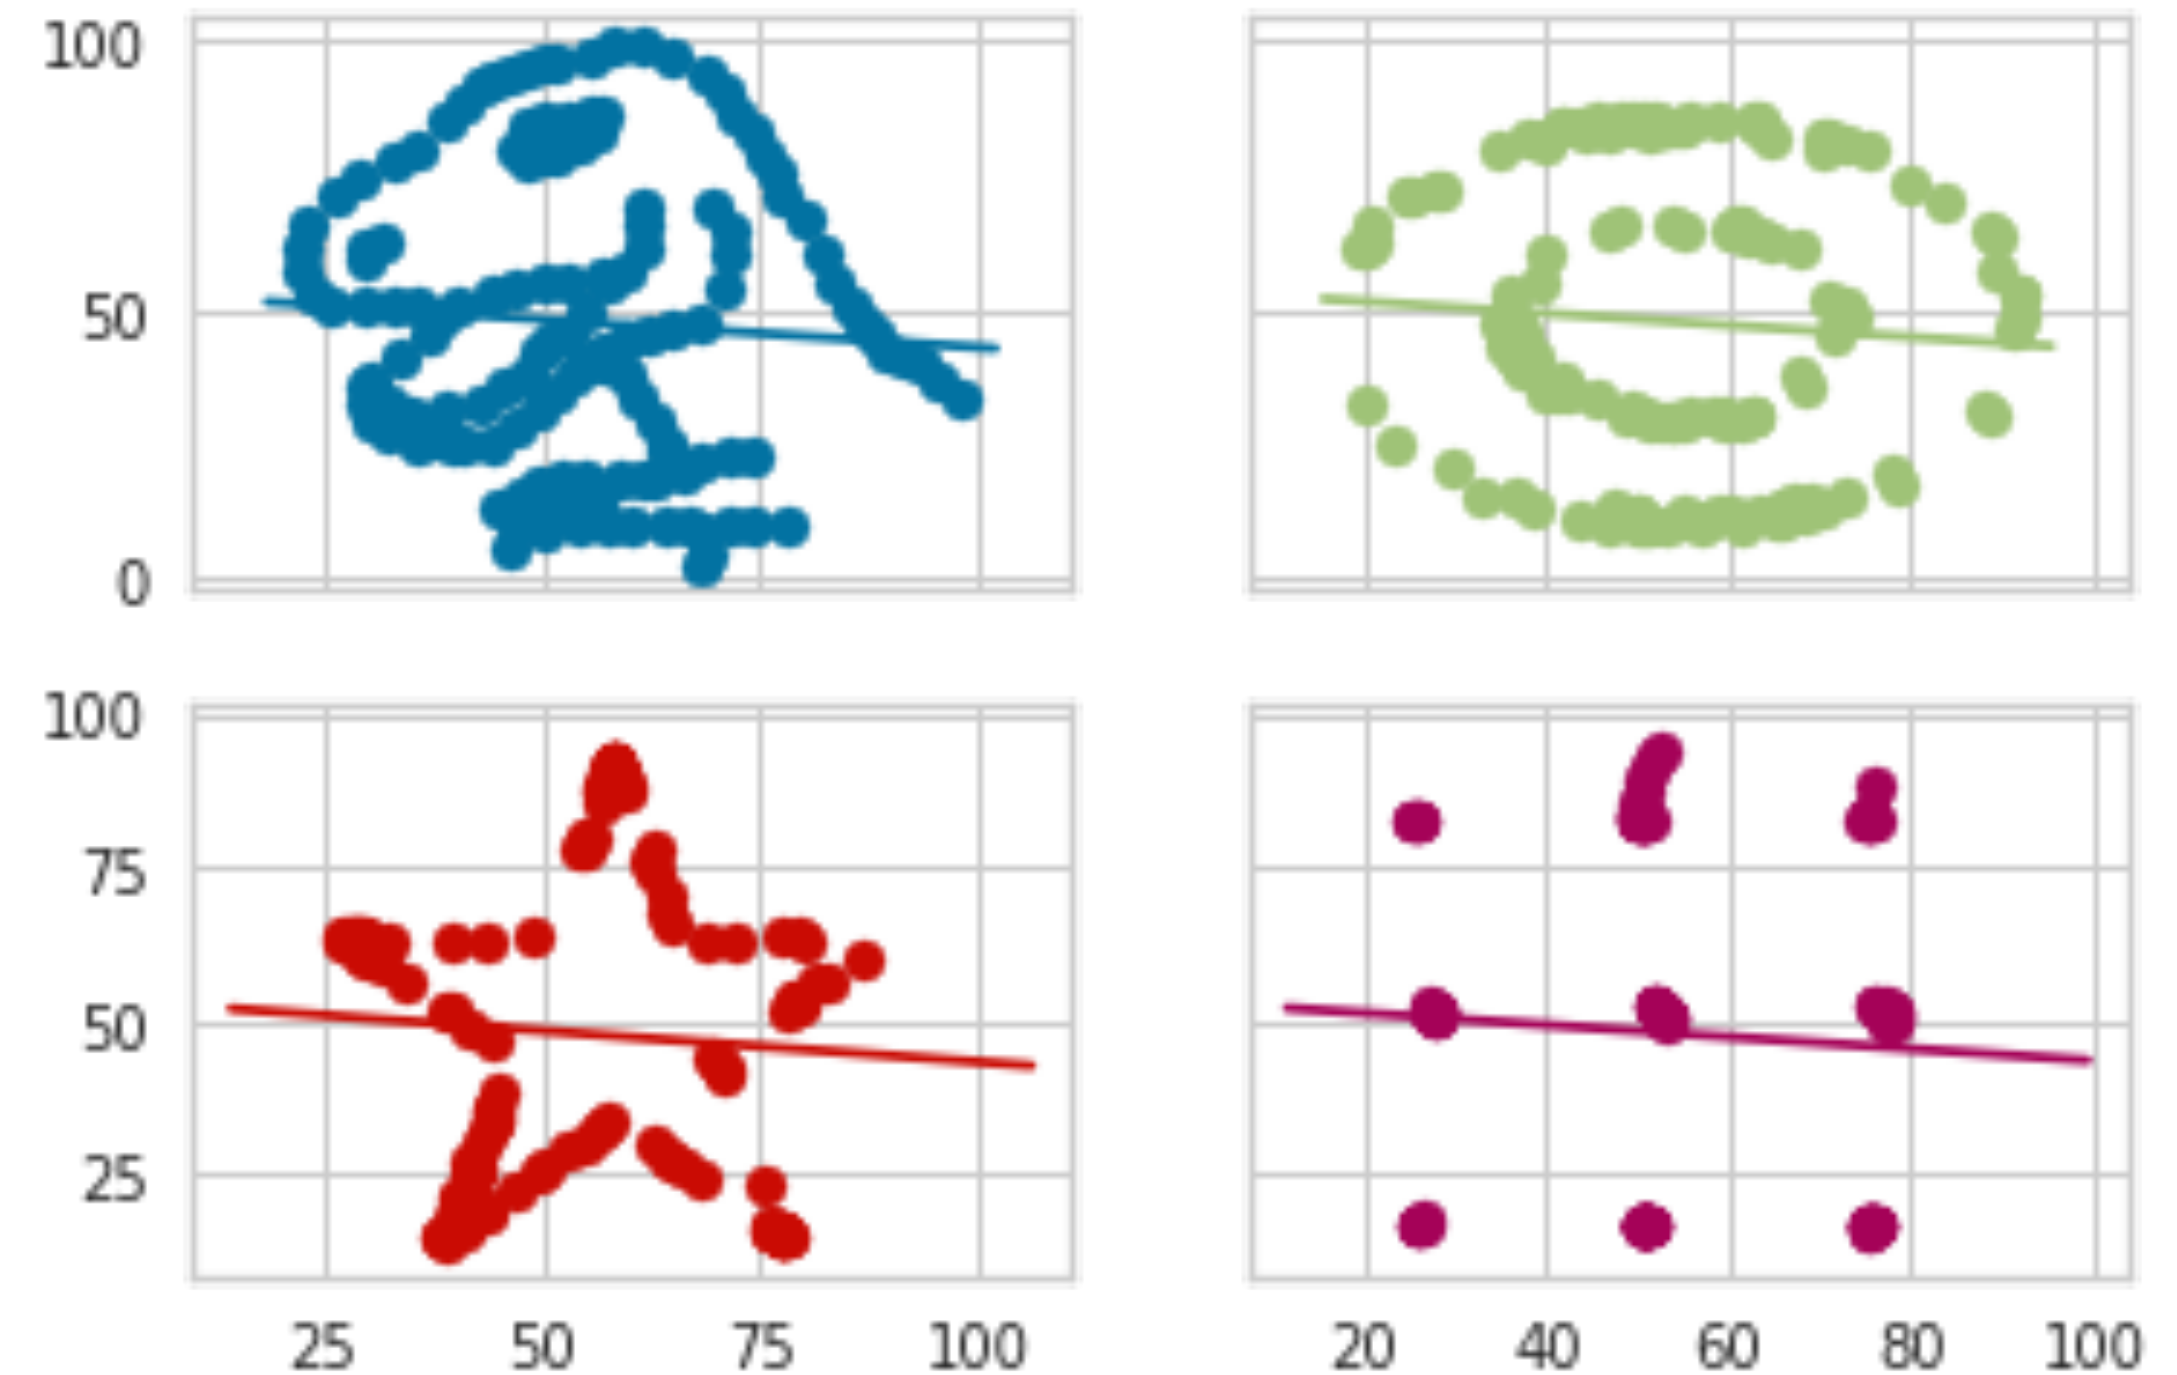
- Várható érték:

$$\mathbb{E}_{p(x)}(f(x)) = \int_{\Omega} f(x)p(x)dx$$

Konvex kombináció!

- Szórás (2. momentum):


$$\text{Var}(x) = \mathbb{E}_{p(x)}[(x - \mathbb{E}_{p(x)}[x])^2]$$



Egyforma átlag és szórás!  
Ugyanolyan illeszkedő egyenes!

# Valószínűségi Eloszlások

## Gauss / Normális eloszlások – 1-D




- $\mu$  Várható érték / Átlag
- $\sigma^2$  Variancia / Szórásnégyzet
- $\sigma$  Szórás / Standard deviancia

Forrás: [P. Hennig](#)

# Valószínűségi Eloszlások

## Gauss / Normális eloszlások – N-D



Forrás: [P. Hennig](#)

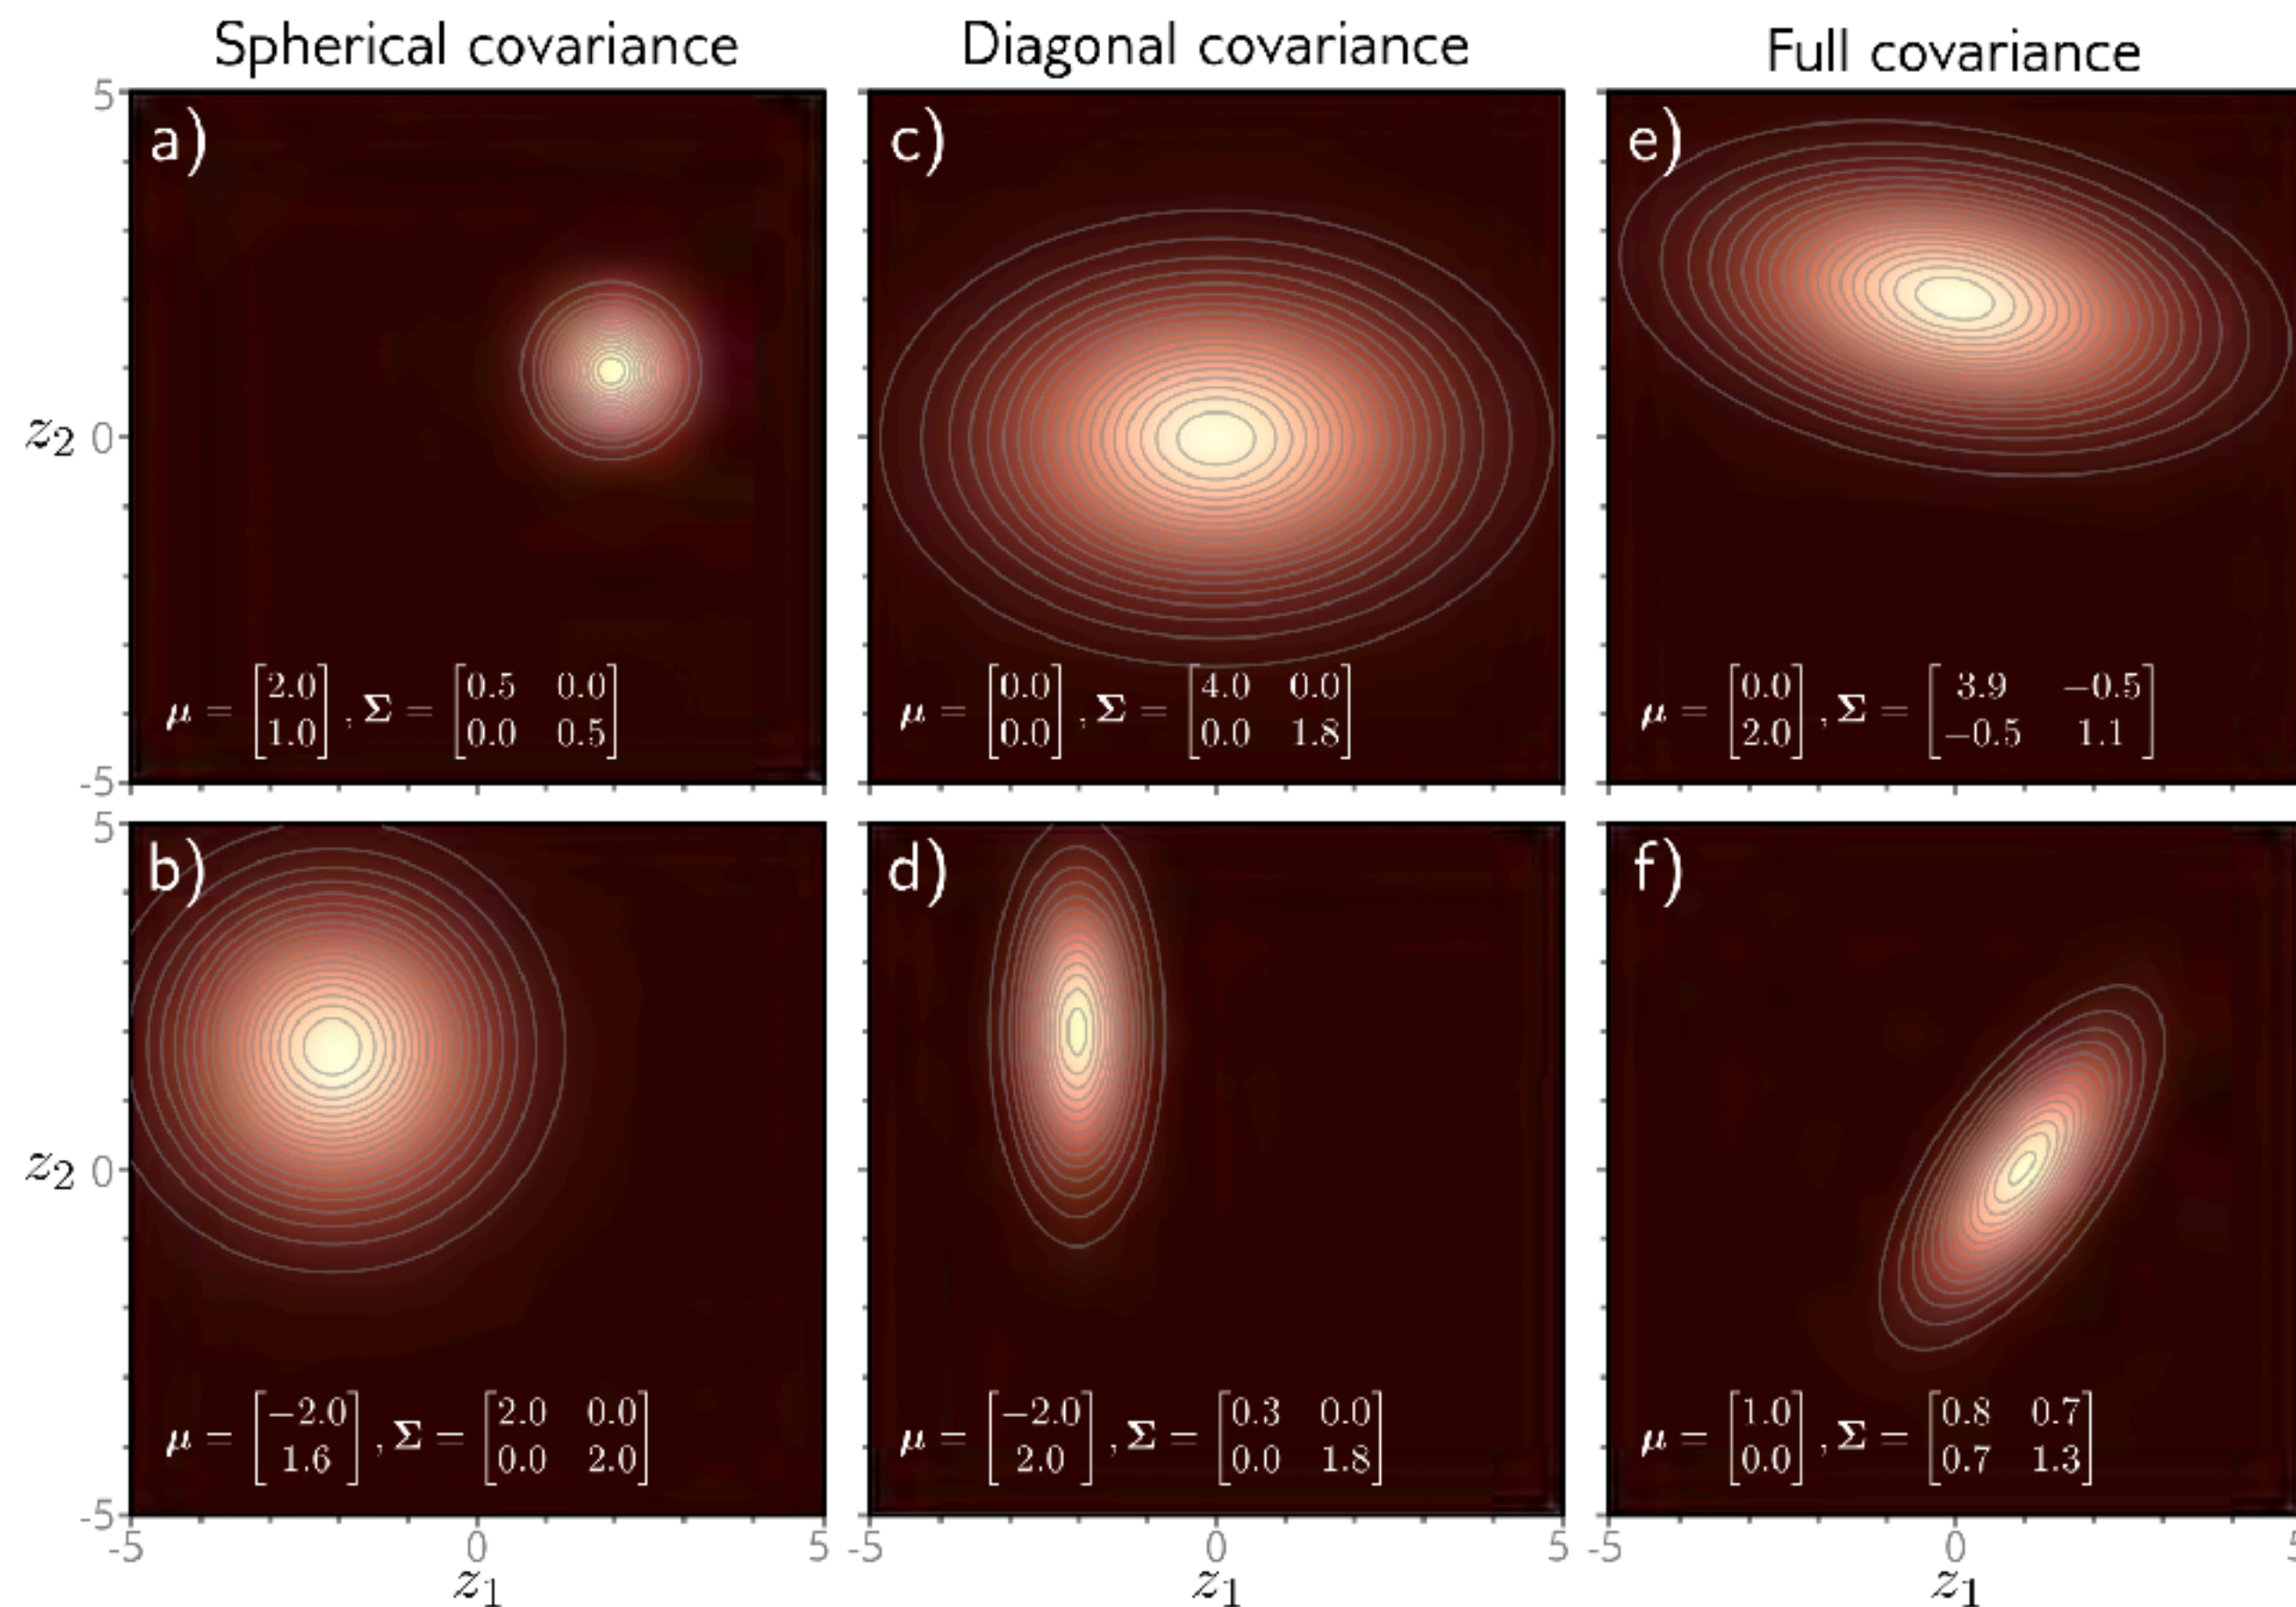
$$\mathcal{N}(x; \mu, \Sigma) = \frac{1}{(2\pi)^{n/2} |\Sigma|^{1/2}} \exp \left( -\frac{1}{2} \underbrace{(x - \mu)^\top \Sigma^{-1} (x - \mu)}_{\text{Kvadratisches függvény!}} \right)$$

$\mu \in \mathbb{R}^N$       Várható érték / Átlag

$\Sigma \in \mathbb{R}^{N \times N}$       Kovarianciamátrix  
(Szimmetrikus, + definit)

# Valószínűségi Eloszlások

## Gauss / Normális eloszlások – N-D



Forrás: [S.J.D. Prince](#)


Konstans szintfelületek:

N-dim. **ellipszoidok**

Főtengelyek:  $\Sigma$  sajátértékei/vektorai

# Valószínűségi Eloszlások

## Gauss kalkulus




Let

$$p(x) = \mathcal{N}(x; \mu, \sigma^2)$$
$$p(y|x) = \mathcal{N}(y; x, \nu^2)$$

Then

$$p(x|y) = \frac{p(x)p(y|x)}{\int p(x)p(y|x) dx}$$
$$= \mathcal{N}(x; m, s^2), \text{ with}$$
$$s^2 := \frac{1}{\sigma^{-2} + \nu^{-2}}$$
$$m := \frac{\sigma^{-2}\mu + \nu^{-2}y}{\sigma^{-2} + \nu^{-2}}$$

Forrás: [P. Hennig](#)



Gauss eloszlások szorzata Gauss eloszlású!

# Valószínűségi Eloszlások

## Gauss kalkulus

Forrás: [P. Hennig](#)

- ▶ products of Gaussians are Gaussians

$$\begin{aligned} & \mathcal{N}(x; a, A) \mathcal{N}(x; b, B) \\ &= \mathcal{N}(x; c, C) \mathcal{N}(a; b, A + B) \end{aligned}$$

$$C := (A^{-1} + B^{-1})^{-1} \quad c := C(A^{-1}a + B^{-1}b)$$

- ▶ linear projections of Gaussians are Gaussians

$$\begin{aligned} & p(z) = \mathcal{N}(z; \mu, \Sigma) \\ \Rightarrow & p(Az) = \mathcal{N}(Az, A\mu, A\Sigma A^T) \end{aligned}$$

- ▶ marginals of Gaussians are Gaussians

$$\int \mathcal{N} \left[ \begin{pmatrix} x \\ y \end{pmatrix}; \begin{pmatrix} \mu_x \\ \mu_y \end{pmatrix}, \begin{pmatrix} \Sigma_{xx} & \Sigma_{xy} \\ \Sigma_{yx} & \Sigma_{yy} \end{pmatrix} \right] dy = \mathcal{N}(x; \mu_x, \Sigma_{xx})$$

- ▶ (linear) conditionals of Gaussians are Gaussians

$$\begin{aligned} p(x | y) &= \frac{p(x, y)}{p(y)} \\ &= \mathcal{N} \left( x; \mu_x + \Sigma_{xy} \Sigma_{yy}^{-1} (y - \mu_y), \Sigma_{xx} - \Sigma_{xy} \Sigma_{yy}^{-1} \Sigma_{yx} \right) \end{aligned}$$

Bayesian inference becomes linear algebra

If  $p(x) = \mathcal{N}(x; \mu, \Sigma)$  and  $p(y | x) = \mathcal{N}(y; A^T x + b, \Lambda)$ , then


$$p(B^T x + c | y) = \mathcal{N}[B^T x + c; B^T \mu + c + B^T \Sigma A (A^T \Sigma A + \Lambda)^{-1} (y - A^T \mu - b), B^T \Sigma B - B^T \Sigma A (A^T \Sigma A + \Lambda)^{-1} A^T \Sigma B]$$

**Gauss kalkulus = lineáris algebra!**


# Valószínűségi Eloszlások

## Egy kis intuíció

- Hol található egy  $N$ -dimenziós (pl. Normális) eloszlás “tömegének” legnagyobb része?
- Nem az eloszlás maximuma körül, hanem attól kb.  $\sqrt{N}$  szórásnyi távolságra!
- $N$ -D térfogat exponenciálisan nő!
- Hogy néz ki egy  $N$ -dimenziós Gaussi eloszlásból vett minta?







Forrás: [M. Betancourt](#)




# Valószínűségi Eloszlások

## Entrópia

- Meglepetés/ optimális bitszám:  $b_{p_i} = \log \frac{1}{p_i} = -\log p_i$  *Belátható, hogy csak a log függvény lehet!*
- **Entrópia** – várható bitszám:  $H(p) = \sum_i p_i b_{p_i} = -\sum_i p_i \log p_i$



“Maximum Entrópia” elve  
[Jaynes, 1957]



# Valószínűségi Eloszlások


## Eloszlások összehasonlítása

- Kereszt-entrópia:  $H(p, q) = - \sum_i p_i \log q_i$

- Relatív entrópia / Kullback-Leibler divergencia:

$$D_{KL}(p||q) = H(p, q) - H(p) = - \sum_i p_i \log \frac{p_i}{q_i} \quad \text{Nem szimmetrikus "távolság"}$$

- $D_{KL}(p||q) \geq 0$
- $D_{KL}(p||q) \neq D_{KL}(q||p)!!!$



# Valószínűségi Eloszlások

## Mintavételezés

- Egyenletes (uniform) eloszlásokból “könnyű” mintavételezni (véletlenszám generátor, **RNG**)
- Hogyan tudunk mintavételezni általános eloszlásokból?

$$x \sim p(x)$$

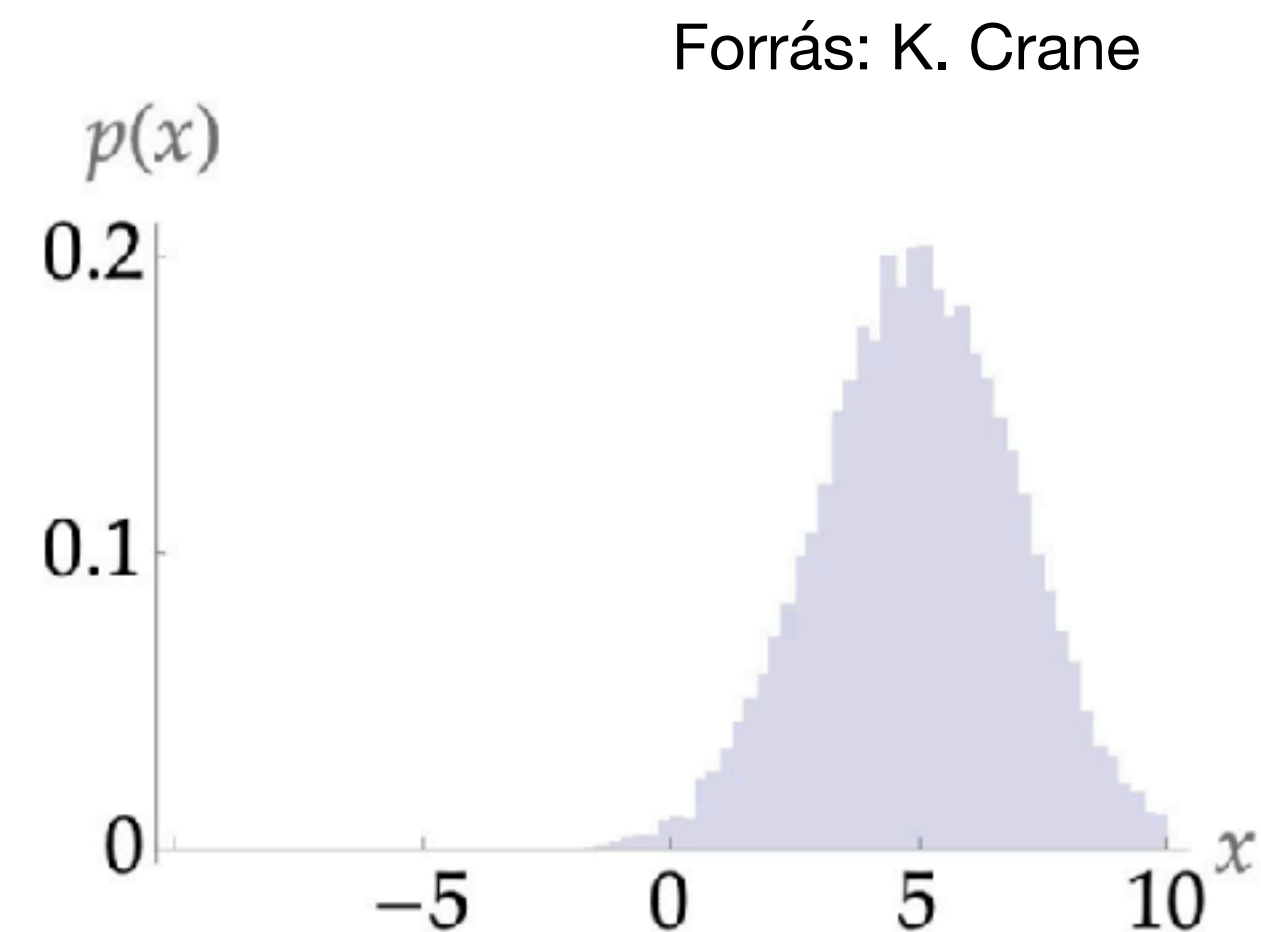


# Valószínűség eloszlások

## Mintavételezés – Normális eloszlás

- 1-D Gauss eloszlás: Box-Müller transzformáció
- N-D Gauss: N db 1D mintából

```
def SampleNormal(  $\mu$ ,  $\sigma$  ):  
    u = uniform(0,1) * 2*pi  
    v = uniform(0,1)  
    return  $\sigma$ *sqrt(v)*cos(u) +  $\mu$ 
```



# Valószínűségi eloszlások

## Mintavételezés – Inverzió


- 1. Uniform eloszlással mintavételezünk  $[0,1]$ -ből ( $y \sim \mathcal{U}([0,1])$ )
- 2. Kiszámítjuk az eloszlás kumulatív eloszlás függvényét (CDF):

$$P(x) = \int_a^x p(X)dX$$

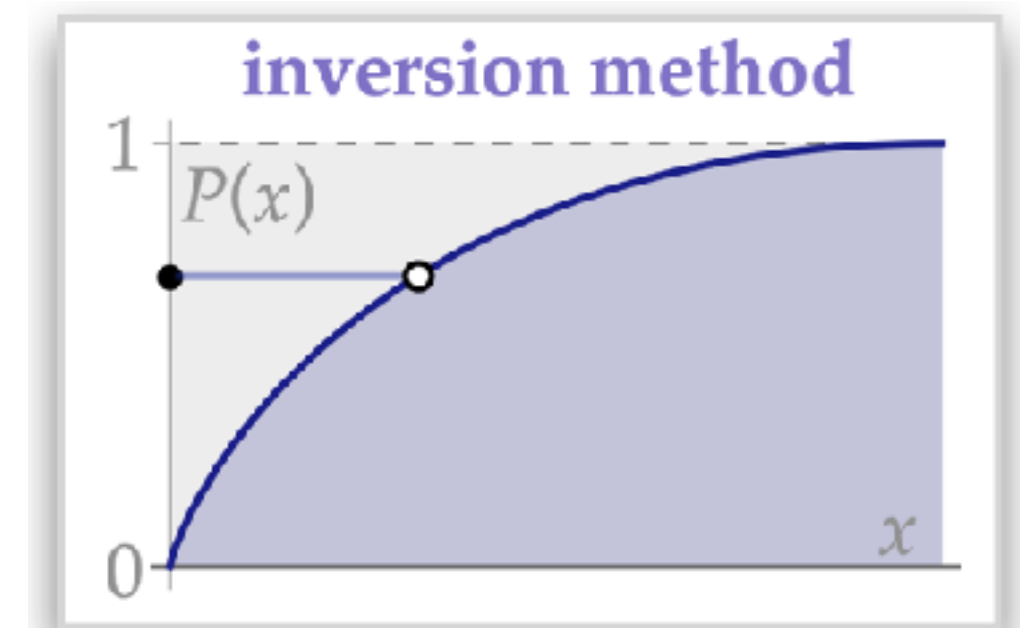
- 3. Invertáljuk a CDF-et (kvantilis)

$$Q(y) = P^{-1}(y) \sim p(x)$$

- Nem mindig alkalmazható, pláne magasabb dimenziókban...



Forrás: K. Crane

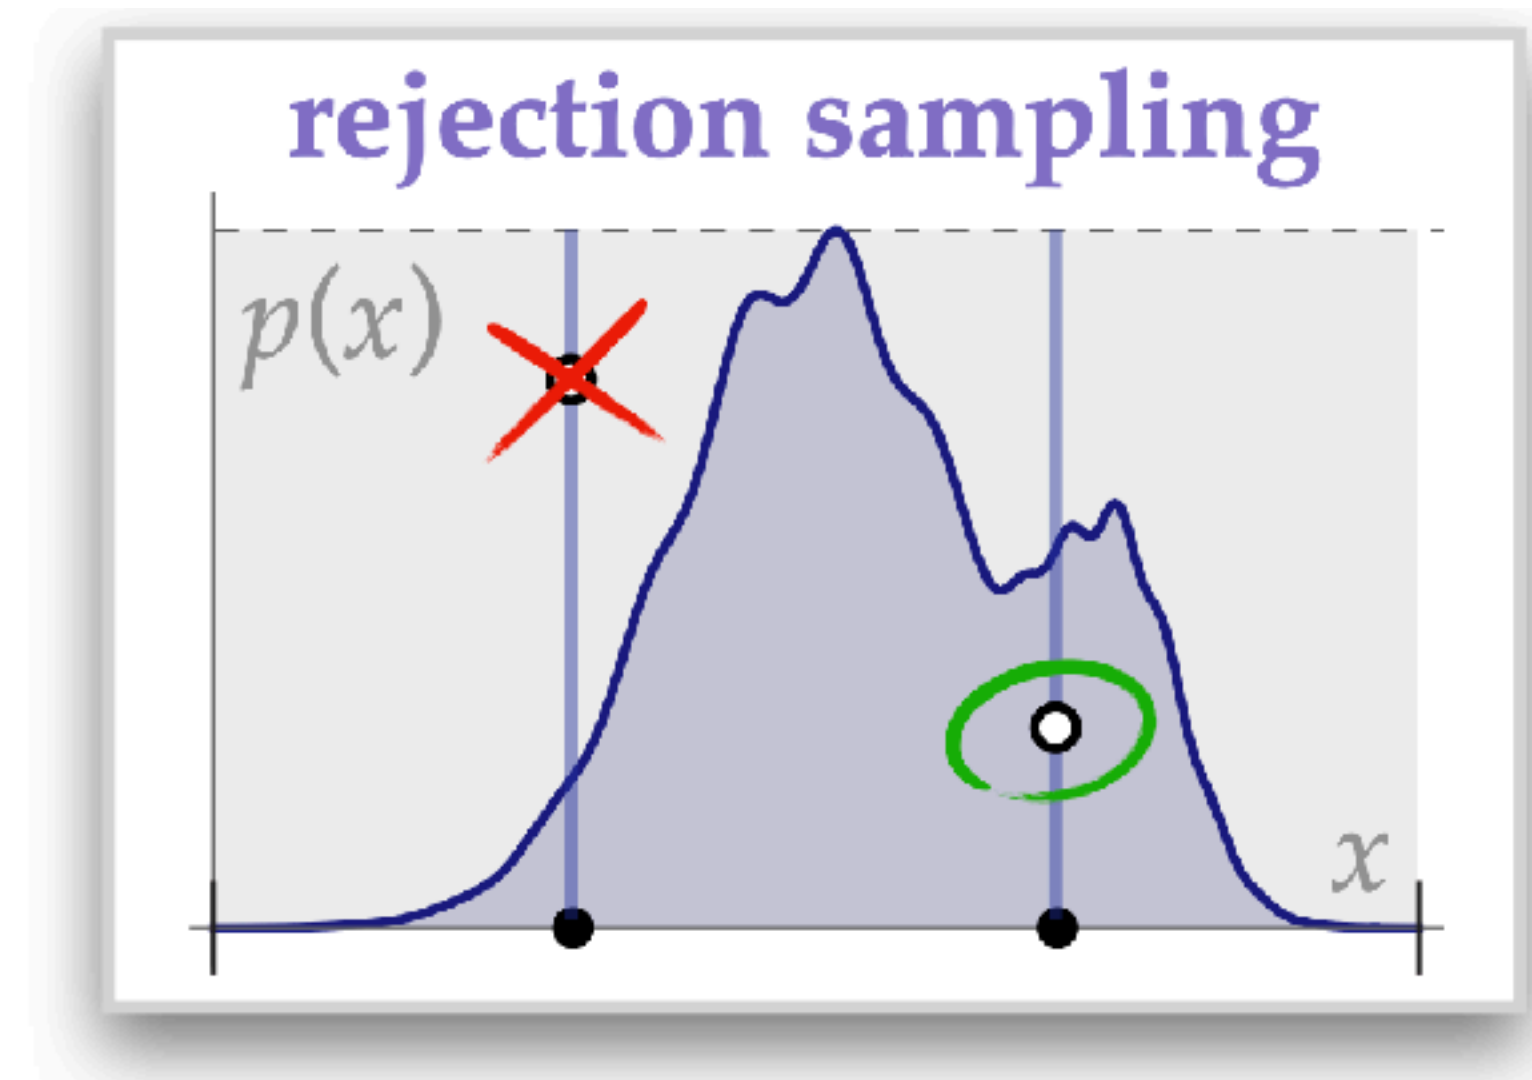


# Valószínűségi eloszlások

## Mintavételezés – Rejection sampling

- 1. Uniform mintavételezzük az értelmezési tartományt ( $x \sim \mathcal{U}(\Omega)$ )
- 2. Uniform mintavételezzük a PDF értékkészletét ( $y \sim [0, \max p(x)]$ )
- 3. Ha  $y < p(x)$ , elfogadjuk a mintát, egyébként elutasítjuk

Forrás: K. Crane



# Differenciálegyenletek




## ODE

- **Közönséges differenciálegyenlet (ODE):**

$$\frac{d\mathbf{x}}{dt} = \mathbf{f}(x(t), t) \quad \begin{array}{l} x(t) \in \mathbb{R}^n \text{ – függő változó (állapotvektor)} \\ t \in \mathbb{R} \text{ – független változó ("idő")} \end{array}$$

- Aka “dinamikai rendszer”
- Geometriai értelmezés: vektormező
  - Akár explicit függhet az időtől is!
- Formális megoldás (integrálgörbe / **folyam**):

$$x(t) = x(0) + \int_0^t f(x(\tau), \tau) d\tau$$



Forrás: M. Gemoll

# Differenciálegyenletek


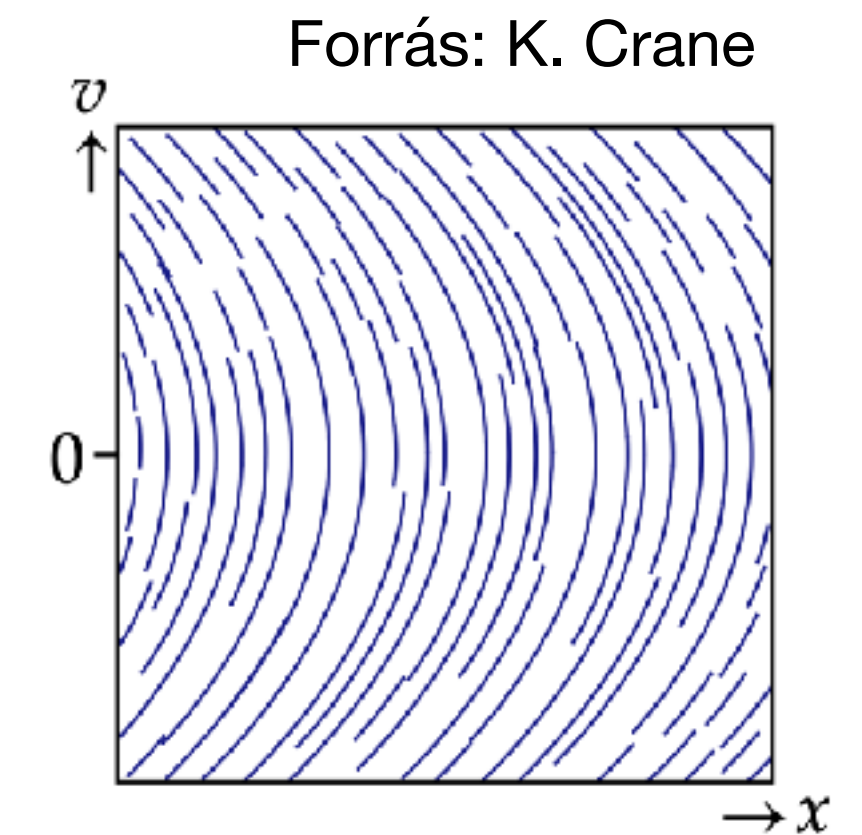

## ODE

- **Közönséges differenciálegyenlet (ODE):**

$$\frac{d\mathbf{x}}{dt} = \mathbf{f}(x(t), t) \quad \begin{array}{l} x(t) \in \mathbb{R}^n \text{ — függő változó (állapotvektor)} \\ t \in \mathbb{R} \text{ — független változó ("idő")} \end{array}$$

- Aka “dinamikai rendszer”
- Geometriai értelmezés: vektormező
  - Akár explicit függhet az időtől is!
- Formális megoldás (integrálgörbe / **folyam**):

$$x(t) = x(0) + \int_0^t f(x(\tau), \tau) d\tau$$



Forrás: M. Gemoll


# Differenciálegyenletek

## ODE – Példa


- Gradiens folyam (gradient flow):

$$\frac{d\mathbf{x}}{dt} = -\nabla F(\mathbf{x})$$

- Az integrálgörbék a függvény kritikus pontjaiba ( $\nabla F(x) = 0$ ) futnak be!
- Gradient descent “folytonos idejű” megfelelője



Forrás: Wikipedia




# Differenciálegyenletek

## ODE – Példa


- Gradiens folyam (gradient flow):

$$\frac{d\mathbf{x}}{dt} = -\nabla F(\mathbf{x})$$

- Az integrálgörbék a függvény kritikus pontjaiba ( $\nabla F(x) = 0$ ) futnak be!
- Gradient descent “folytonos idejű” megfelelője



Forrás: Wikipedia



# Differenciálegyenletek

## ODE – Numerikus módszerek


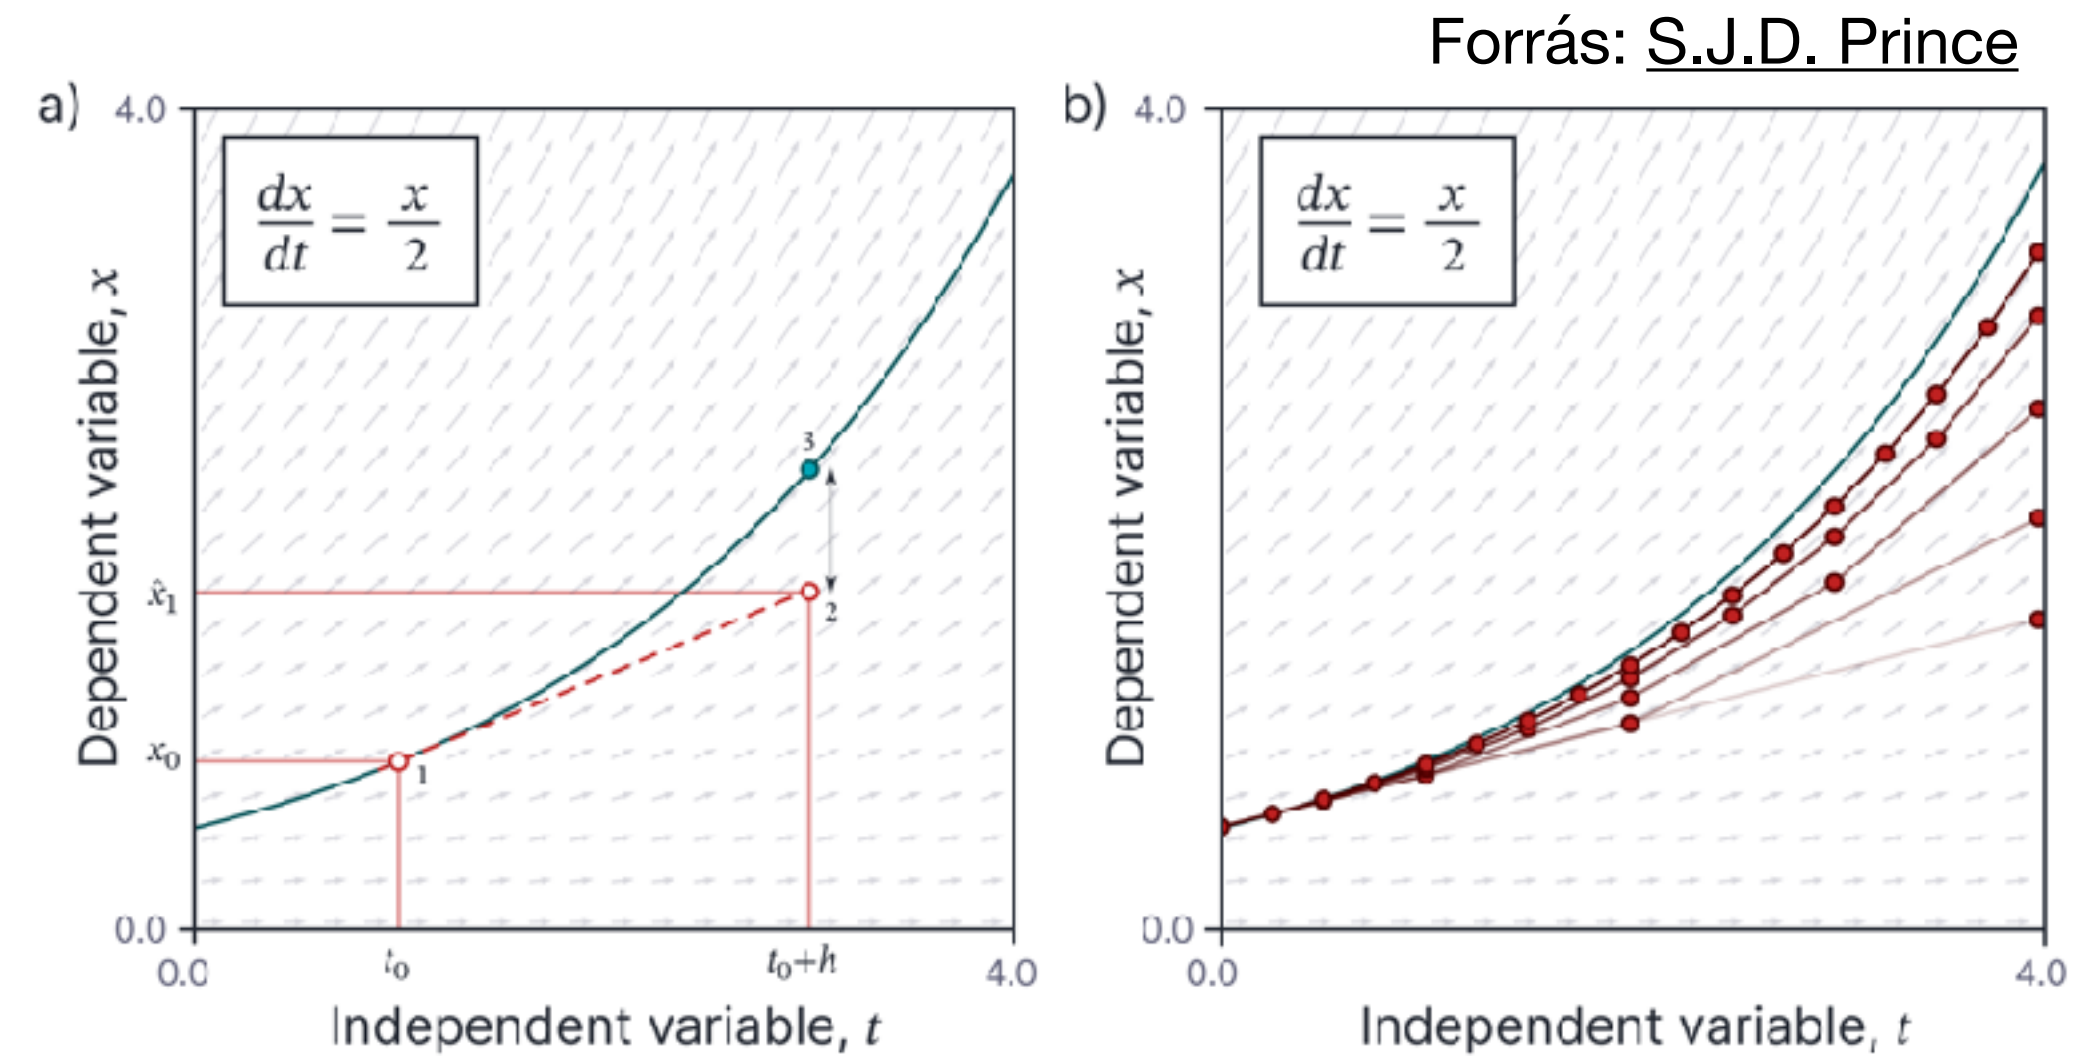
- Diszkretizáljuk az időt:

$$\frac{dx}{dt} \approx \frac{x(t + \Delta t) - x(t)}{\Delta t} = f(x(t), t)$$

- Explicit / Forward Euler** módszer:

$$x(t_{k+1}) = x(t_k) + \Delta t \cdot f(x(t_k), t_k)$$

- Gradient Descent =  
Gradiens folyam + Forward Euler!



Forrás: F. Bach

# Differenciálegyenletek

## ODE – Numerikus módszerek



- Diszkretizáljuk az időt:

$$\frac{dx}{dt} \approx \frac{x(t + \Delta t) - x(t)}{\Delta t} = f(x(t), t)$$

- Explicit / Forward Euler** módszer:

$$x(t_{k+1}) = x(t_k) + \Delta t \cdot f(x(t_k), t_k)$$

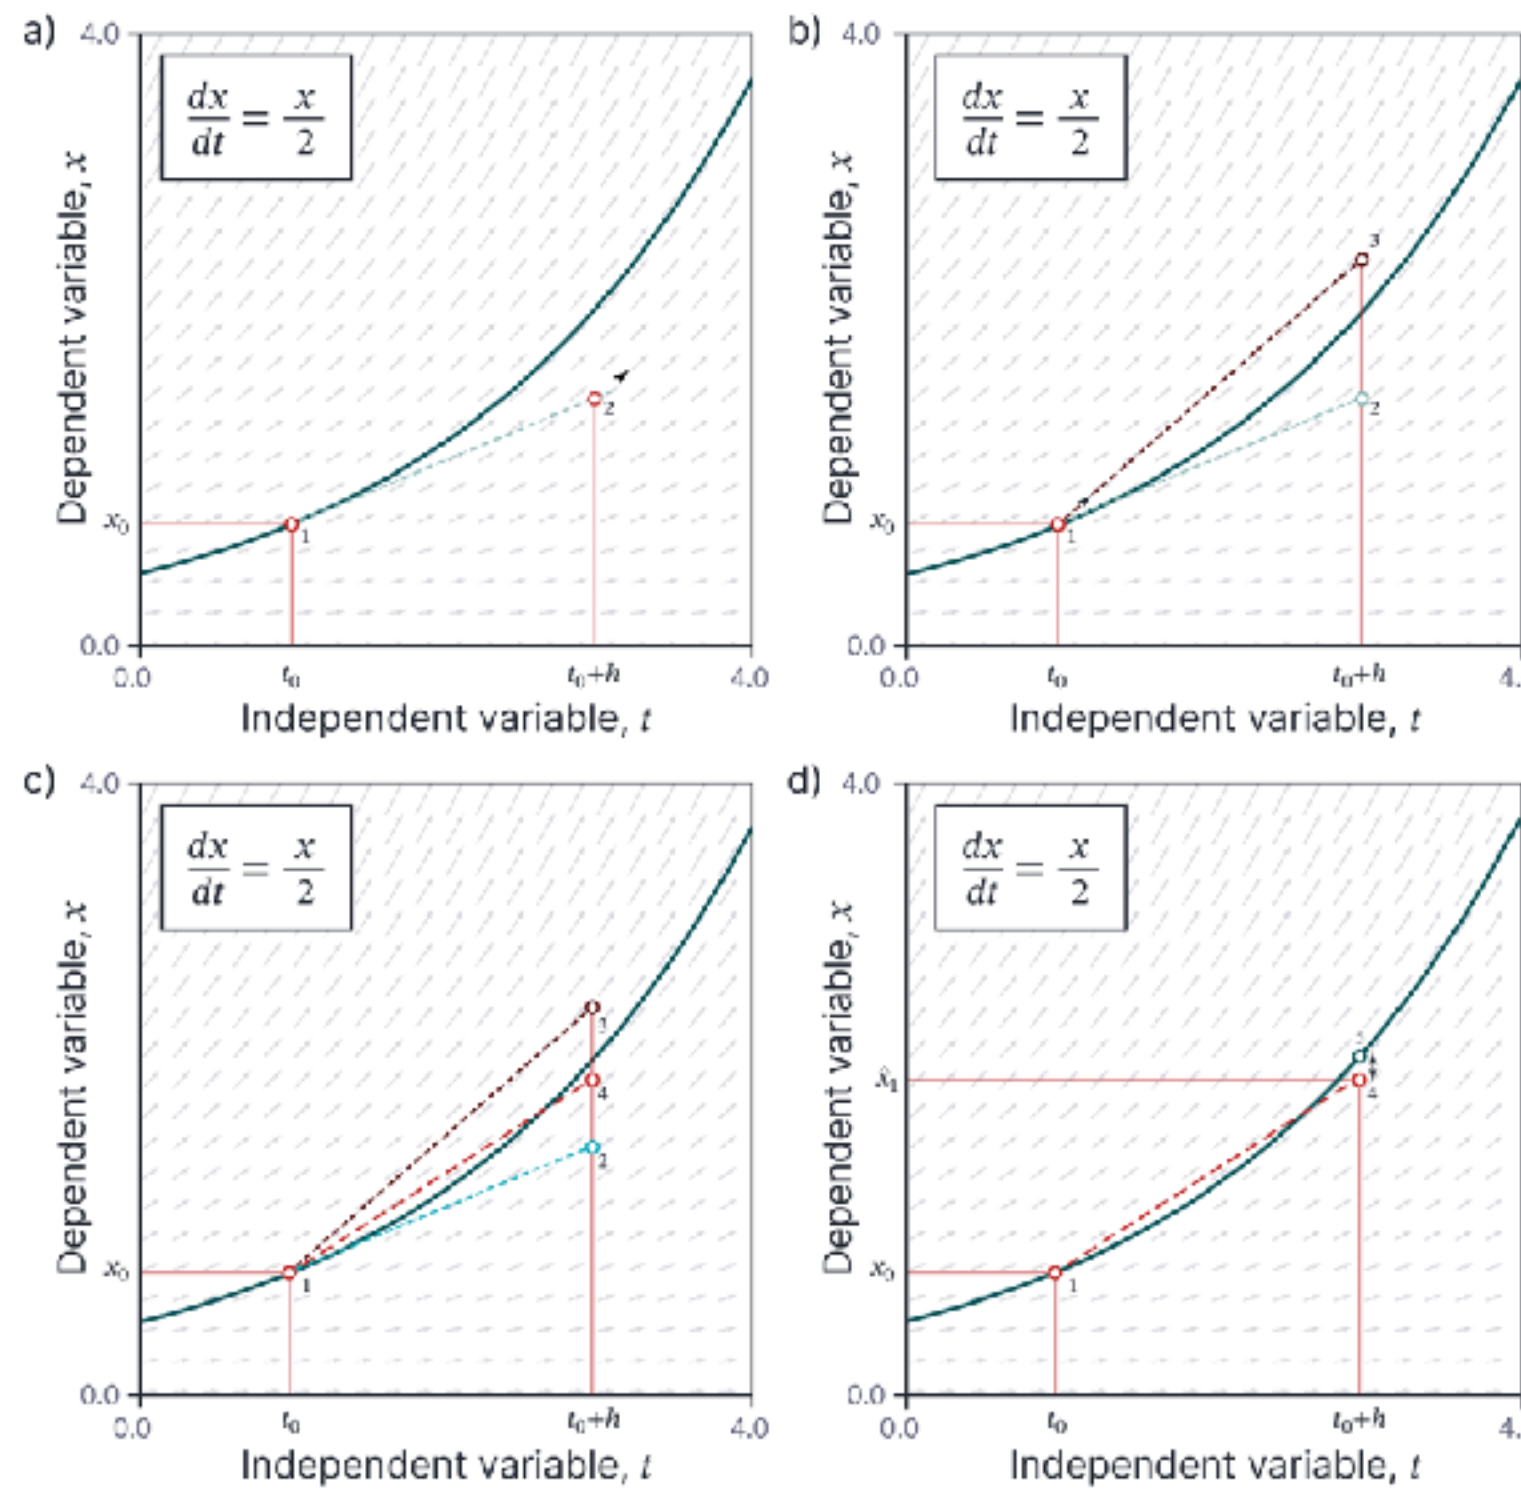
- Gradient Descent =  
Gradiens folyam + Forward Euler!



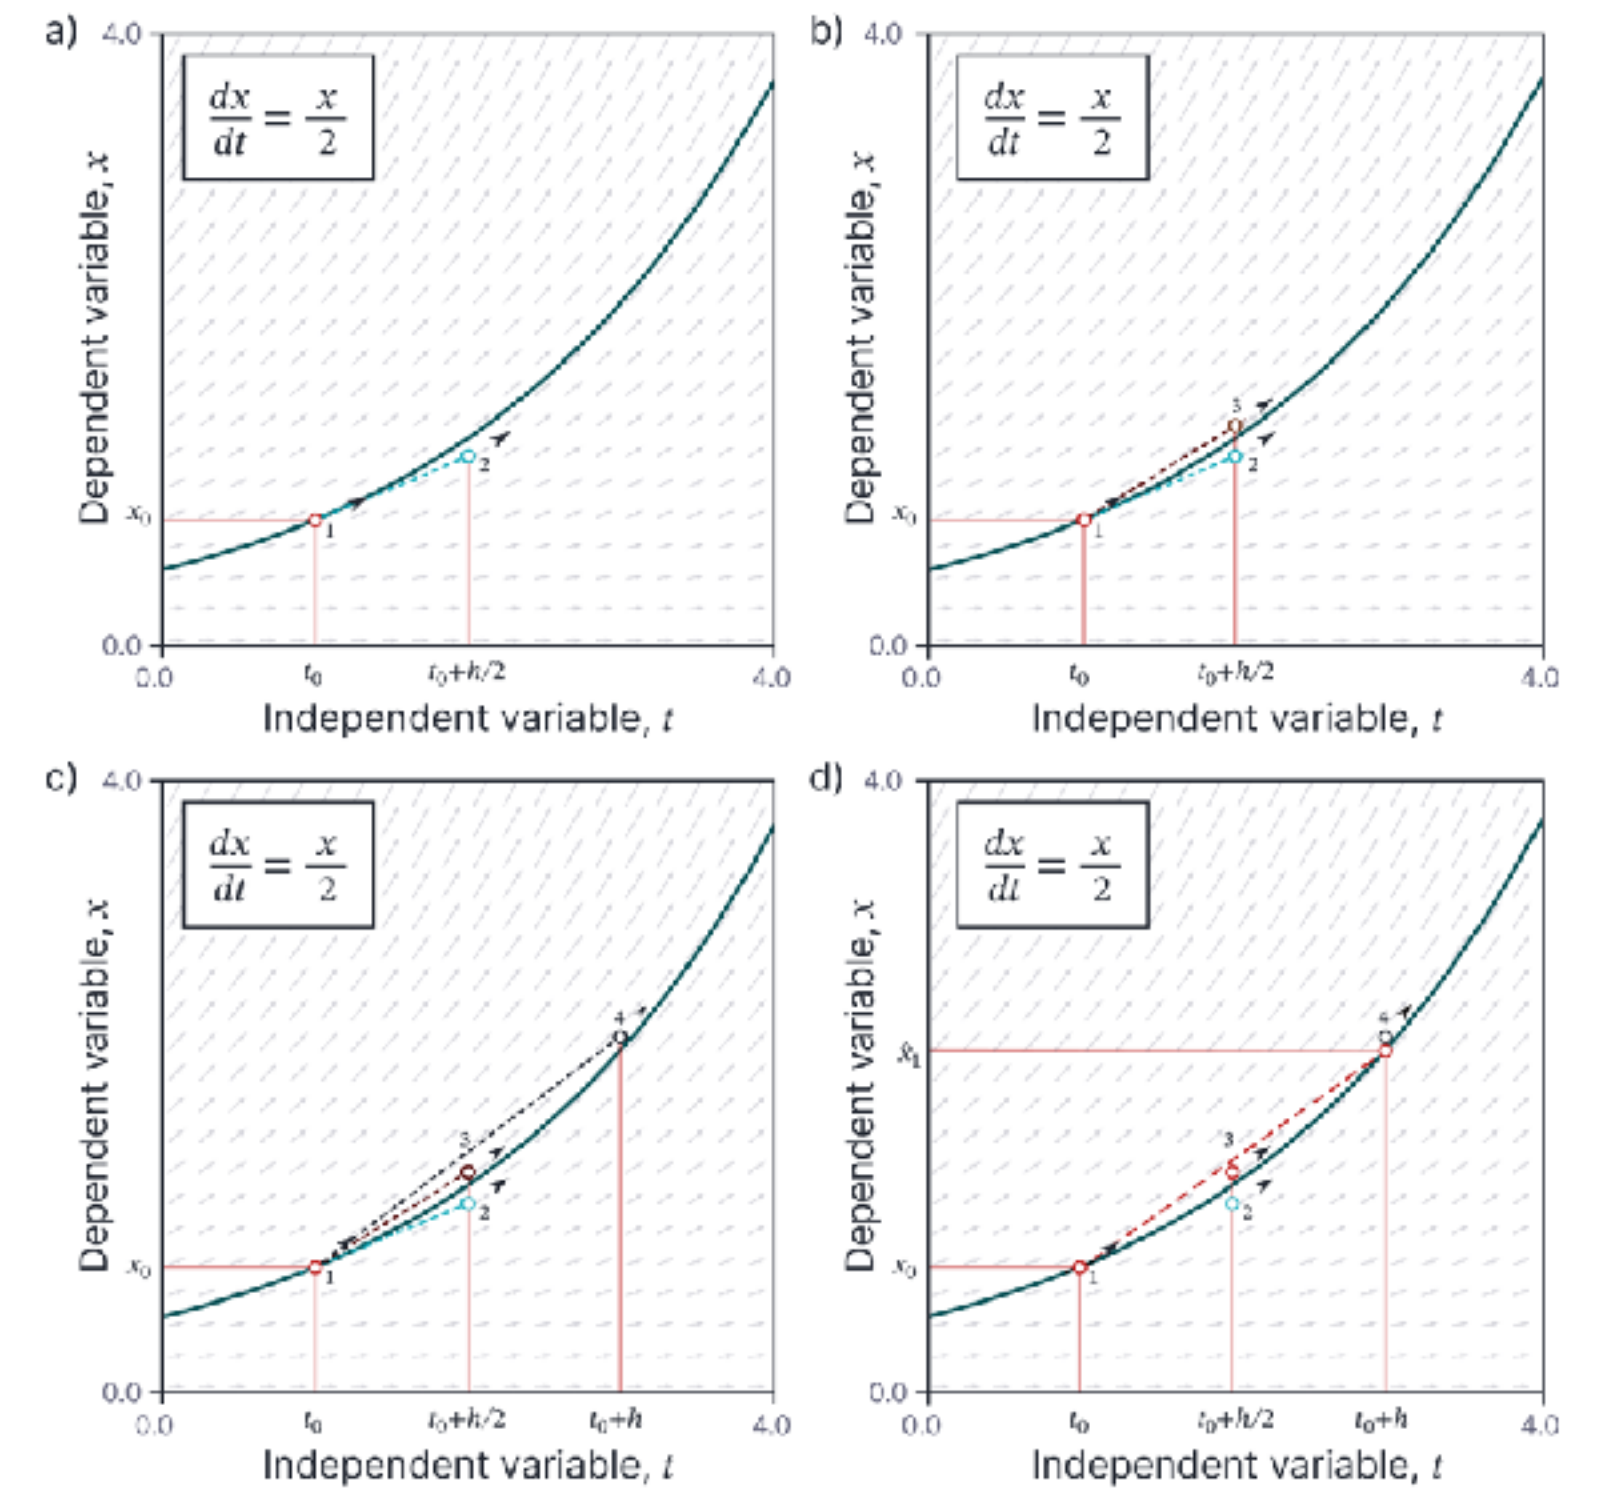
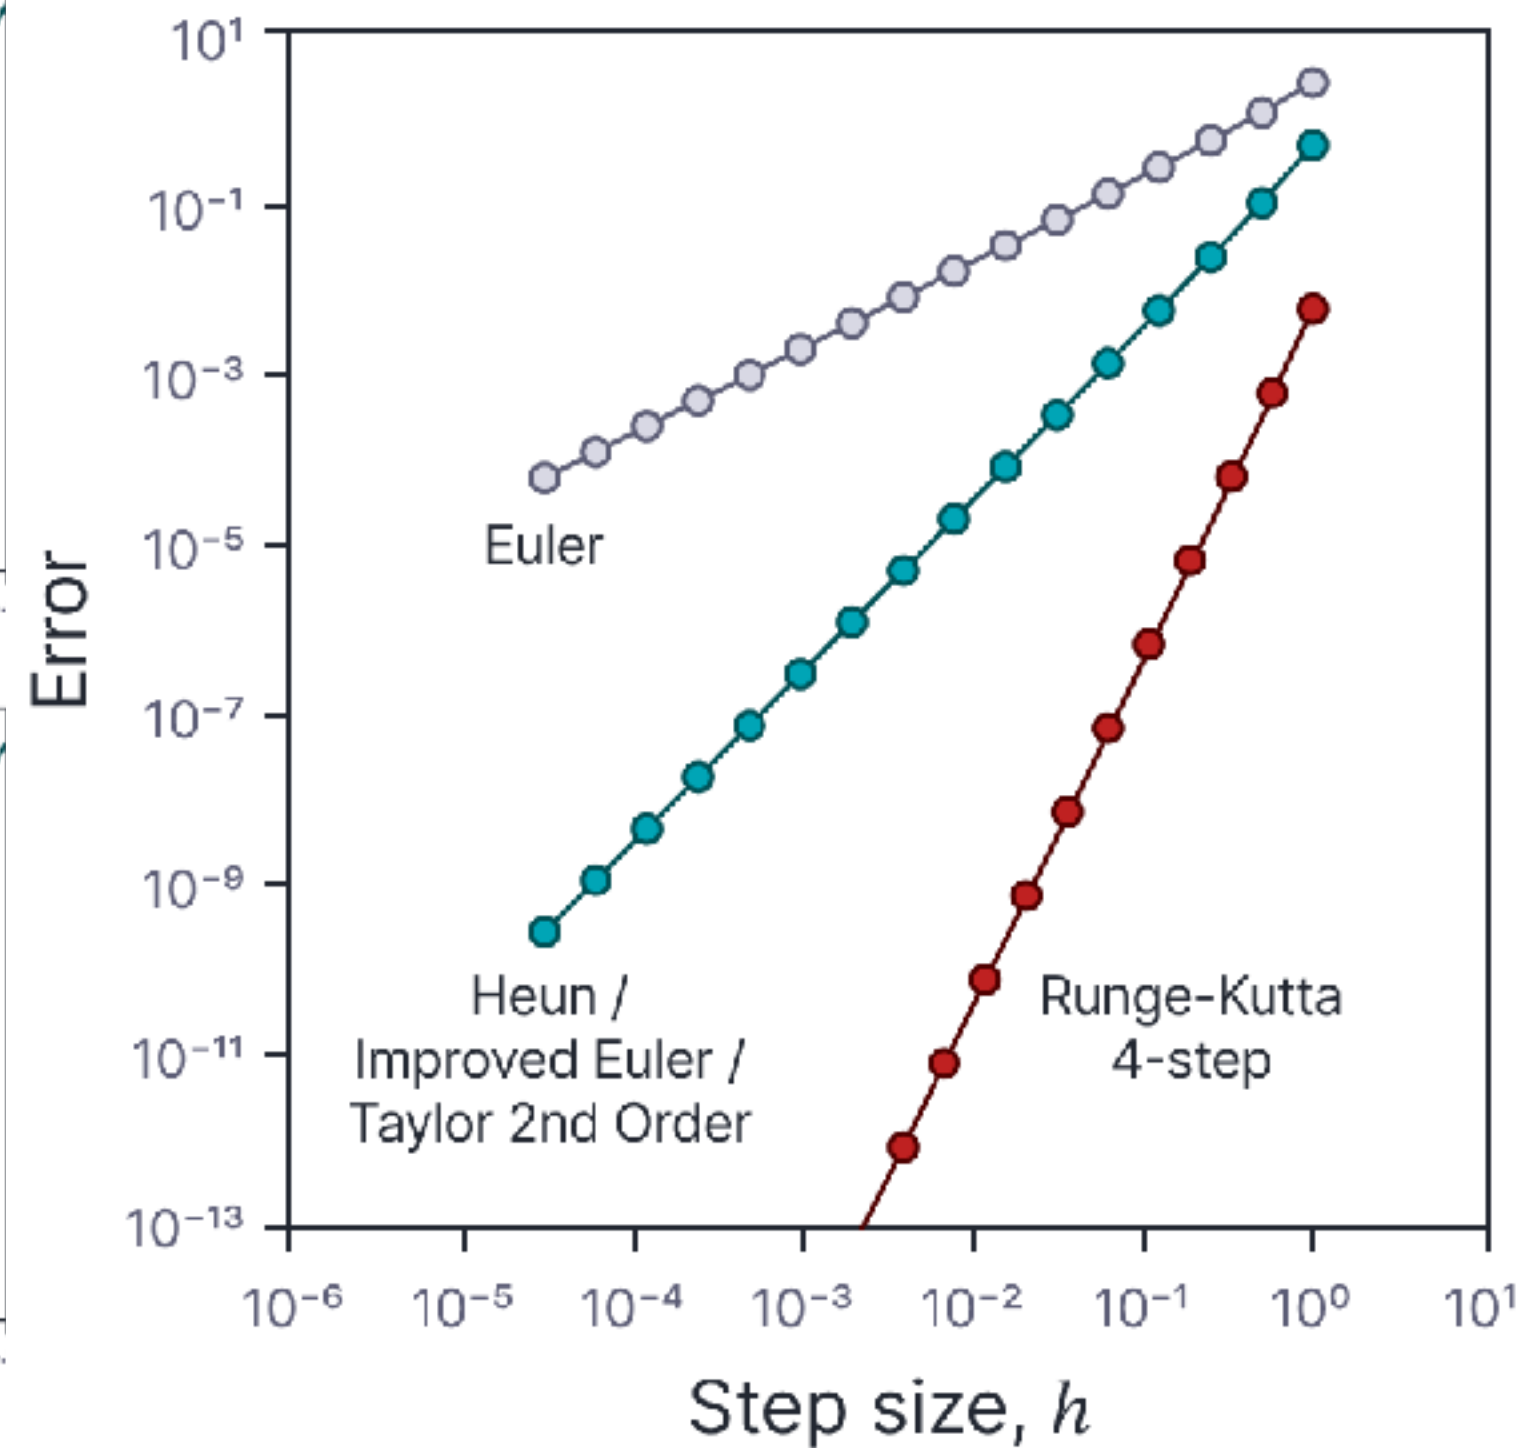
Forrás: F. Bach

# Differenciálegyenletek

## ODE – Numerikus módszerek – Integrátorok



**Heun (2. rendű)**



**Runge-Kutta (4. rendű)**

Forrás: S.J.D. Prince

# Differenciálegyenletek

## ODE – Numerikus módszerek – Integrátorok

- Implicit / backward Euler:

$$x(t_{k+1}) = x(t_k) + \Delta t \cdot f(x(t_{k+1}), t_{k+1})$$

$$G(x(t_{k+1})) = x(t_{k+1}) - \Delta t \cdot f(x(t_{k+1}), t_{k+1}) - x(t_k) = 0 \quad \text{Implicit egyenlet!}$$

- Nemlineáris egyenletrendszer  $x(t_{k+1})$ -re
  - Megoldható iteratív módszerekkel (pl. Newton-Raphson)
- Stabil kb. bármilyen  $\Delta t$  választása esetén!
- Gradiens dinamikára ( $f(x) = -\nabla F(x)$ ) ekvivalens *optimalizáció-alapú* interpretáció (“inkrementális potenciál”):

$$x(t_{k+1}) = \operatorname{argmin} \left( \frac{1}{2\Delta T} \|x - x(t_k)\|^2 + F(x) \right)$$

Megoldás:  
pl. Newton(-Raphson)!

# Differenciálegyenletek


## Neural ODE

- Várjunk csak...

$$x_{L+1} = x_L + f_{W_L}(x_L) \quad \text{🤔} \quad x_{T+1} = x_T + f(x_T)$$

Reziduális réteg

Forward Euler





- Mi lesz egy ResNet-ből, ha  $L \rightarrow \infty$  és a rétegek egyformák?

$$\frac{dx}{dt} = f_W(x, t)$$

Neural ODE

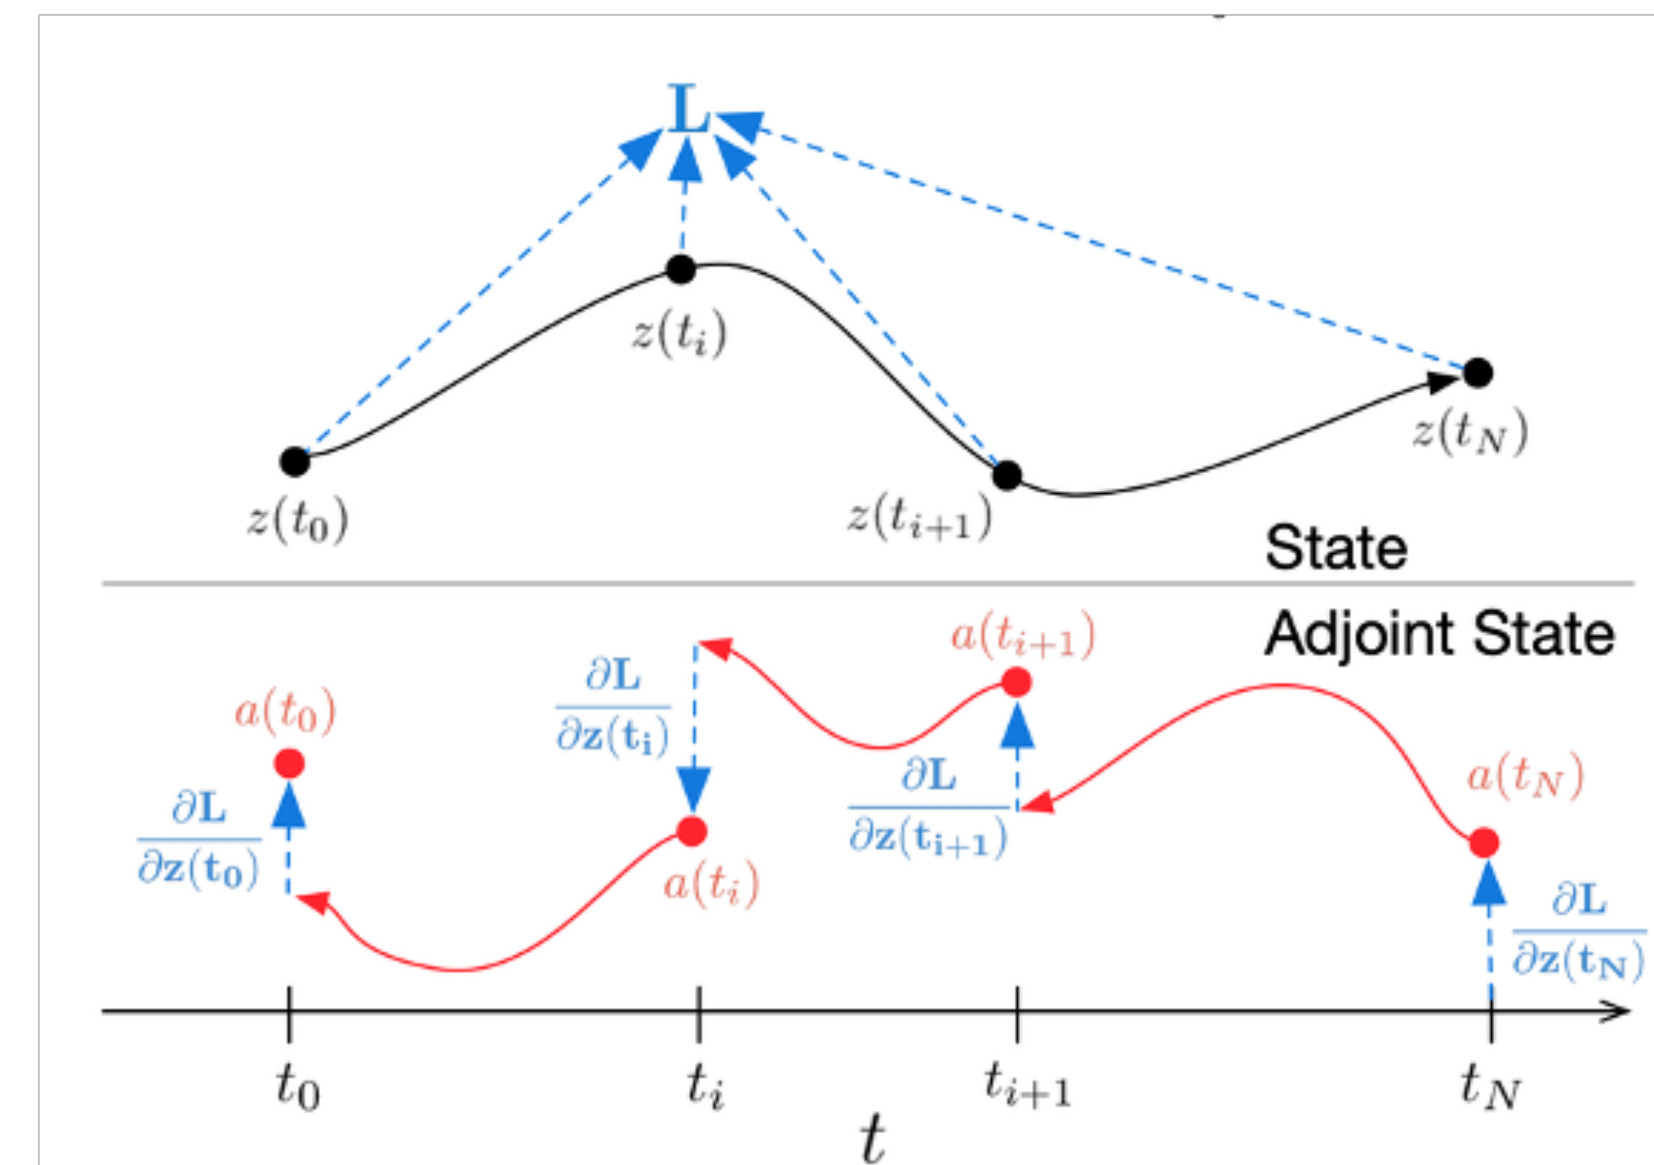
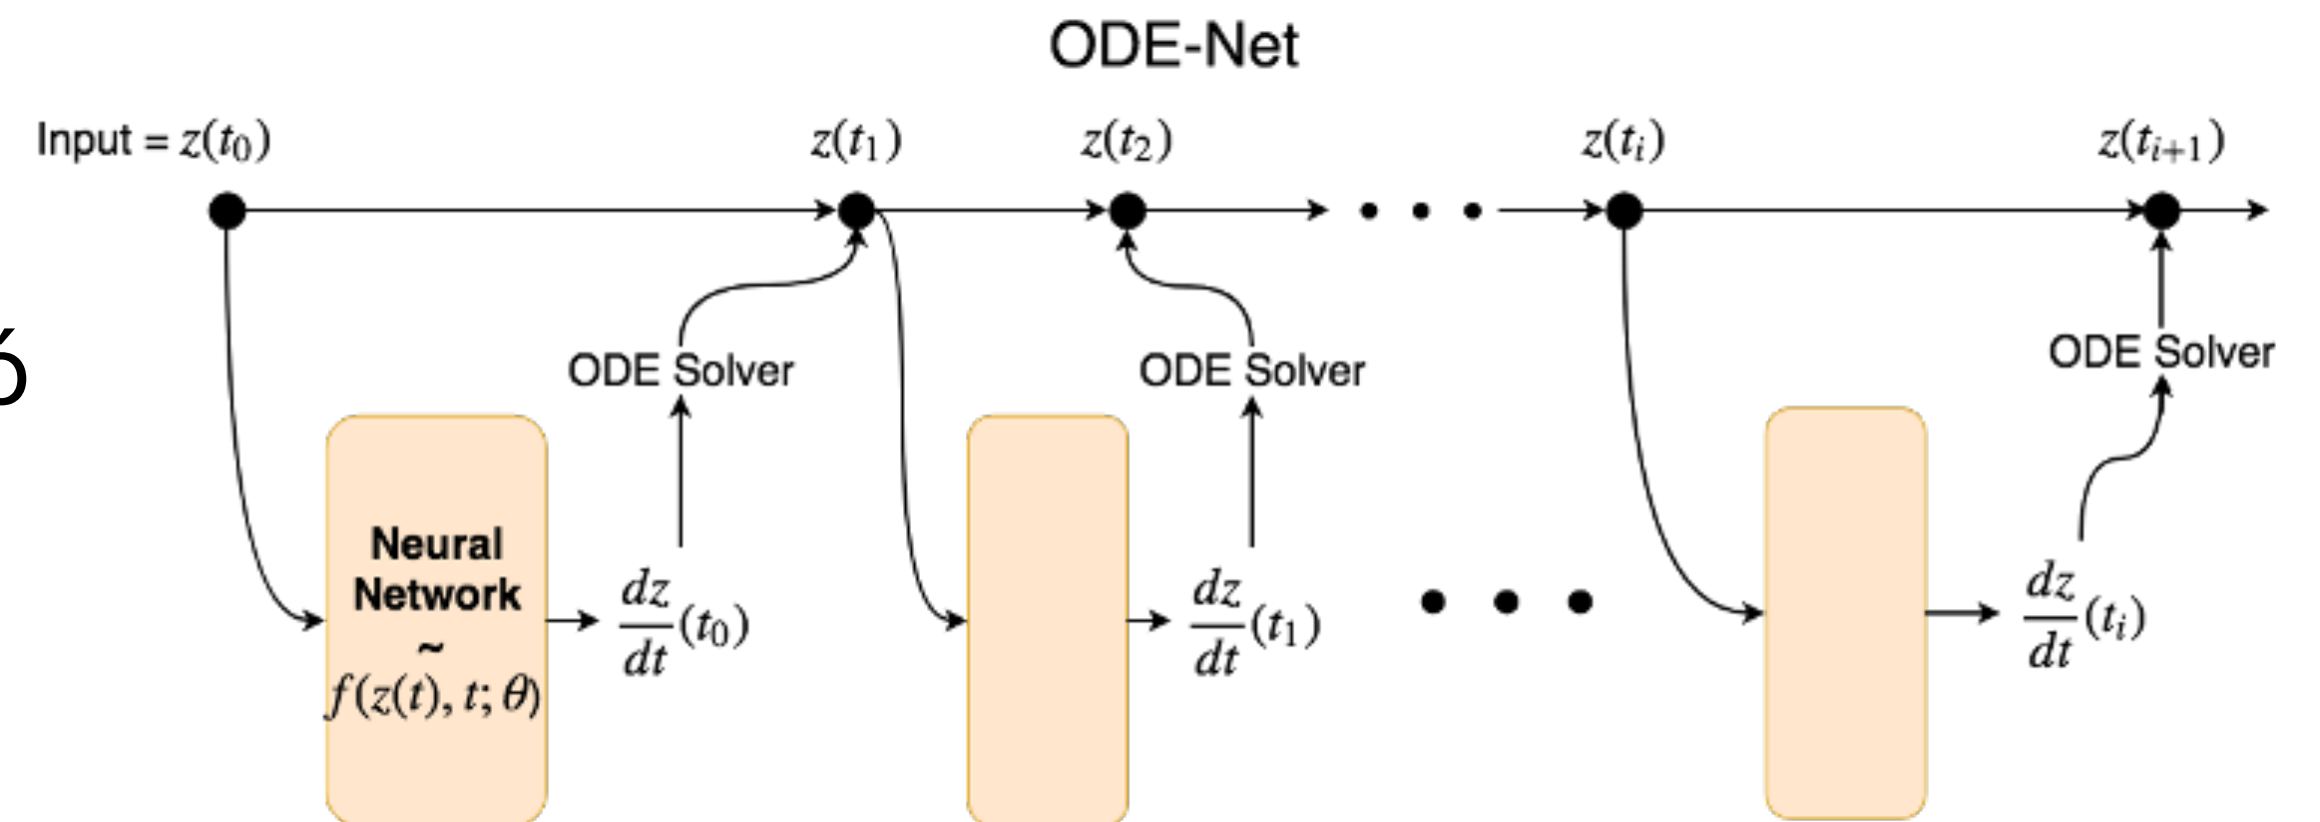
Neurális háló — a bemenet változási sebességét definiálja!



# Differenciálegyenletek

## Neural ODE



- ResNet = Neural ODE + Forward Euler diszkretizáció
- De *bármilyen* integrátort (ODE megoldót) használhatunk a kiértékelésre!
  - Pl. Runge-Kutta, backward Euler, adaptív lépésköz stb.
- Neural ODE tanítása:
  - 1. ötlet: backprop. az ODE megoldó iterációin keresztül (“unrolling”)
  - 2. ötlet: “**adjoint ODE**” integrálása időben visszafelé (aka “folytonos backprop”, “adjoint method”) — hatékonyabb!



# Differenciálegyenletek

## Neural ODE

- Neural ODE alkalmazásai:
  - Idősor analízis
  - Fizikai / dinamikai modellezés
  - Irányítástechnika / robotika
  - Generatív modellezés (diffúzió & flow módszerek)
- Érdeklődőknek: Implicit Rétegek





Forrás: Y. Lipman

# Differenciálegyenletek


## Neural ODE

- Neural ODE alkalmazásai:
  - Idősor analízis
  - Fizikai / dinamikai modellezés
  - Irányítástechnika / robotika
  - Generatív modellezés (diffúzió & flow módszerek)
- Érdeklődőknek: Implicit Rétegek



# Differenciálegyenletek


## SDE – Véletlen séta, Wiener folyamat




**Brown-mozgás / véletlen séta** — sztochasztikus folyamat  
 Sok lépés esetén az egyes lépések eloszlása nem számít!  
 (ld. centrális határeloszlás tétel)

**Wiener folyamat** — független, *normális eloszlású* inkremensek:

$$dW_t \approx W_{t_2} - W_{t_1} \sim \mathcal{N}(0, t_2 - t_1)$$




$$\zeta_1 + \dots + \zeta_n$$



Forrás: K. Crane

# Differenciálegyenletek



## SDE – Véletlen séta, Wiener folyamat



**Brown-mozgás / véletlen séta** — sztochasztikus folyamat  
 Sok lépés esetén az egyes lépések eloszlása nem számít!  
 (ld. centrális határeloszlás tétel)

**Wiener folyamat** — független, *normális eloszlású* inkremensek:

$$dW_t \approx W_{t_2} - W_{t_1} \sim \mathcal{N}(0, t_2 - t_1)$$



Forrás: K. Crane

# Differenciálegyenletek

## Sztocasztikus Differenciálegyenletek (SDE)

- Sztocasztikus Differenciálegyenlet (SDE):

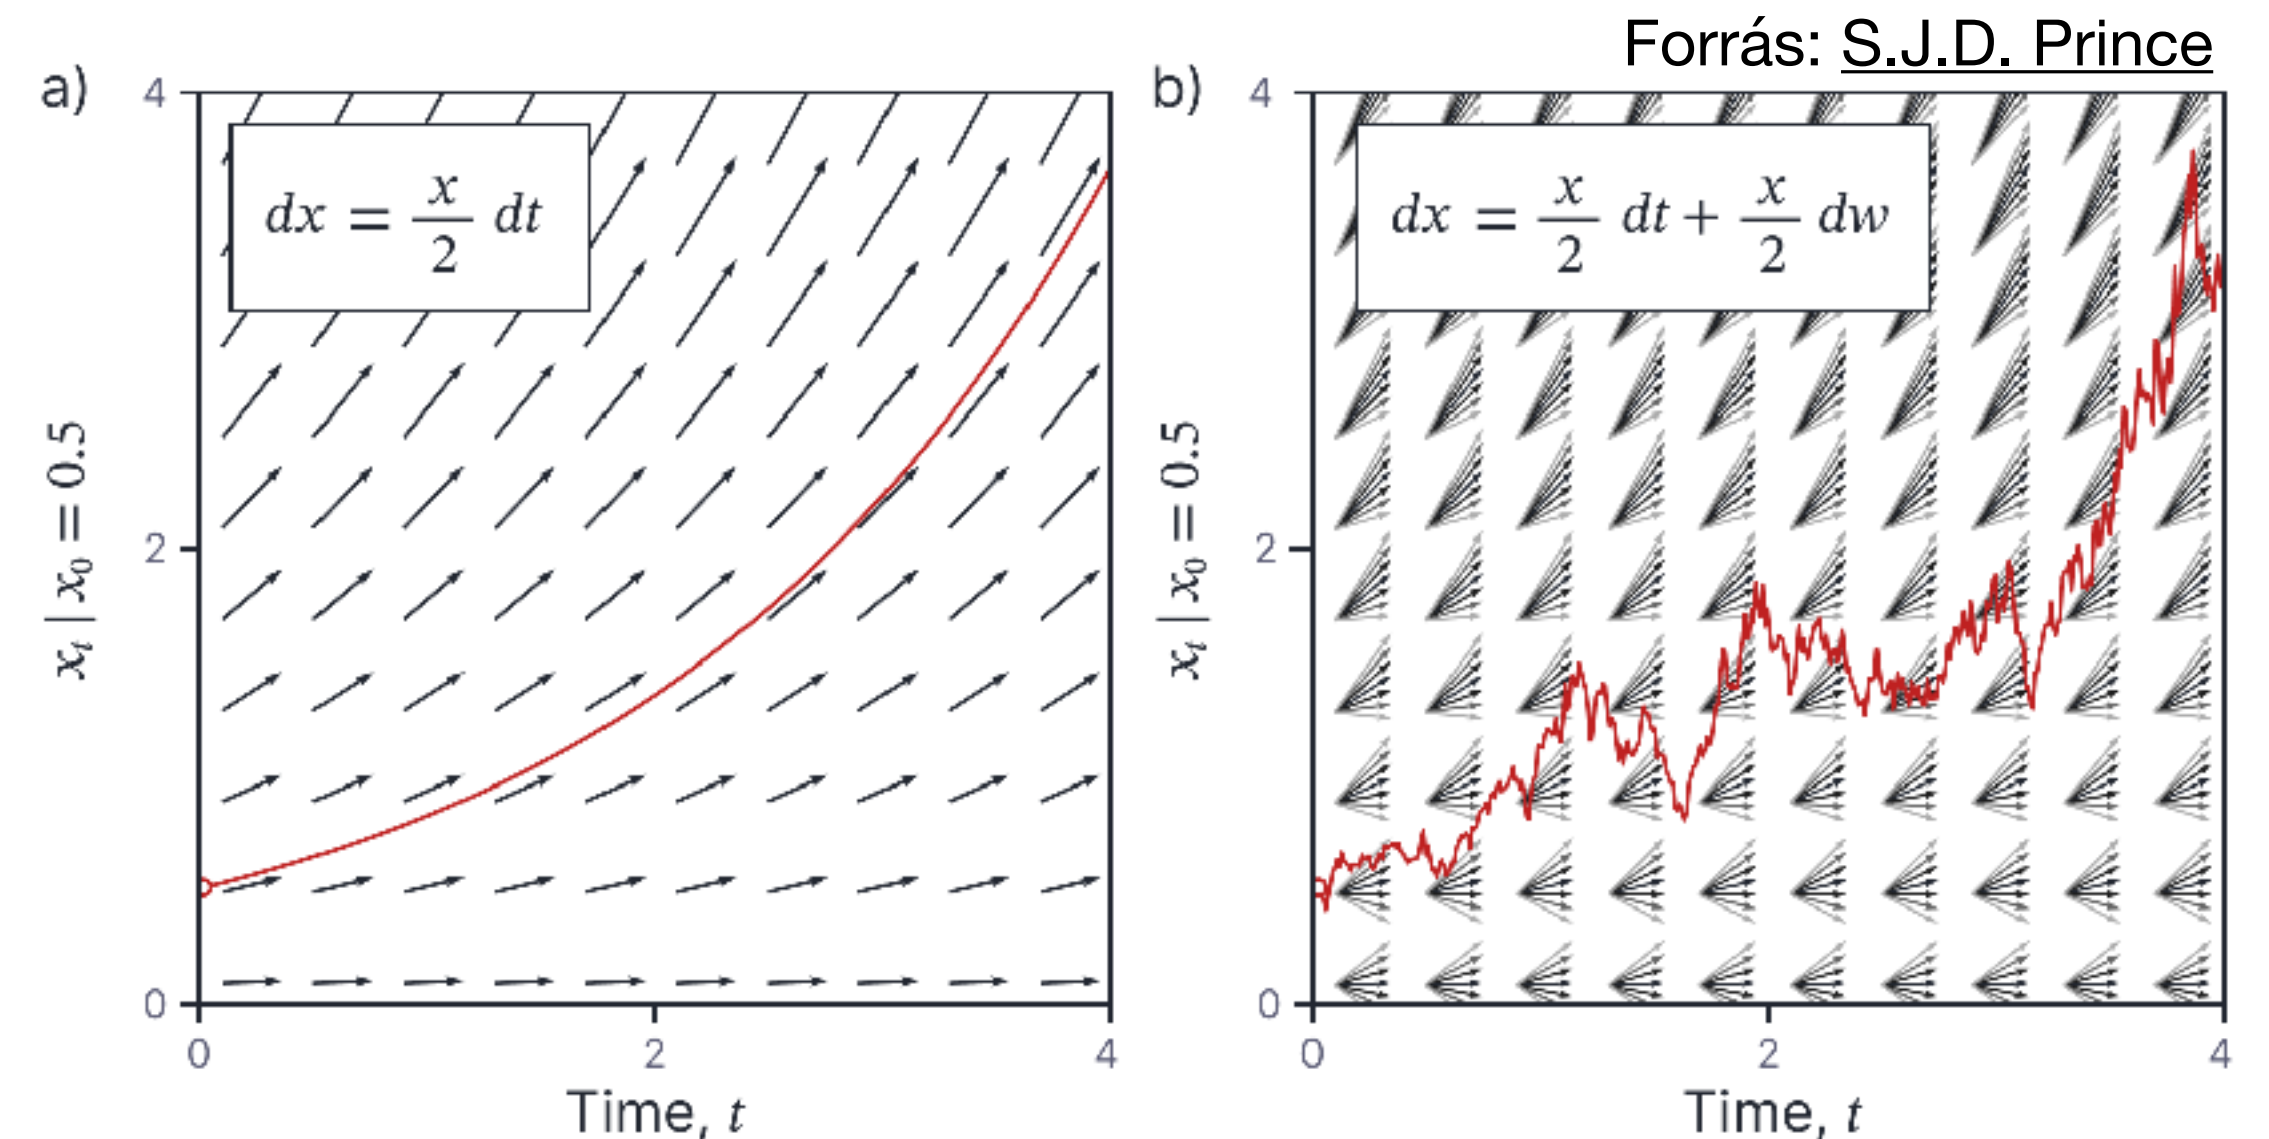
Brown-mozgás  
(stochasztikus folyamat)

$$dX_t = \underbrace{f(X_t)dt}_{\text{Drift (determinisztikus ODE)}} + g(\widehat{dW}_t)$$

Drift  
(determinisztikus ODE)

- Euler–Maruyama módszer: Euler lépés + (std. normális) zaj

$$x_{T+1} = x_T + \Delta T \cdot (f(x_T) + \epsilon), \quad \epsilon \sim \mathcal{N}(0,1)$$



# Valószínűségi eloszlások

## Log-likelihood

- Gyakran valószínűségek logaritmusát manipuláljuk (**log-likelihood**):  $\log P(x)$

- Linearizálja valószínűségek szorzatát és hányadosát:

$$\log \frac{p(x)q(x)}{r(x)} = \log p(x) + \log q(x) - \log r(x)$$



- Sok valószínűségeloszlás log-konkáv függvény!

- **Boltzmann eloszlás:**

$$E(x): \text{“energiafv.”} \quad p(x) = \frac{e^{-E(x)}}{\int e^{-E(y)} dy} = \frac{e^{-E(x)}}{Z}$$

$$\log p(x) = -E(x) - \underbrace{\log Z}_{\text{konstans!}}$$

Partíció  
függvény



# Valószínűségi eloszlások

## Score függvény

- **“Score” függvény** — log-likelihood gradiense:


$$\nabla_x \log p(x)$$

- **Vektormező** — az eloszlás maximumai felé “áramlik”!


- Boltzmann eloszlásra:

$$\nabla_x \log p(x) = \nabla_x E(x) - \underbrace{\nabla_x \int E(x) dx}_{\text{const}} = \nabla_x E(x)$$

**A normalizáció érdektelen!!!**



Forrás: Y. Song



# Differenciálegyenletek


## SDE – Langevin dinamika

- Langevin dinamikai rendszer:  
gradient descent a log-eloszlásra  
(score függvény) + zaj



$$x_{k+1} = x_k + \Delta T \cdot \nabla \log p(x_k) + \sqrt{2 \cdot \Delta T} \cdot \epsilon_k$$
$$\epsilon_k \in \mathcal{N}(0, \mathbf{I})$$

- Belátható, hogy a generált minták az eredeti eloszláshoz konvergálnak!

$$x_k \sim p(x), k \rightarrow \infty$$



Forrás: [Y. Song](#)



t = 0/1500

Forrás: [M. Yi](#)

# Differenciálegyenletek


## SDE – Langevin dinamika

- Langevin dinamikai rendszer:  
gradient descent a log-eloszlásra  
(score függvény) + zaj


$$x_{k+1} = x_k + \Delta T \cdot \nabla \log p(x_k) + \sqrt{2 \cdot \Delta T} \cdot \epsilon_k$$
$$\epsilon_k \in \mathcal{N}(0, \mathbf{I})$$

- Belátható, hogy a generált minták az eredeti eloszláshoz konvergálnak!

$$x_k \sim p(x), k \rightarrow \infty$$



Forrás: [Y. Song](#)




$t = 0/1500$

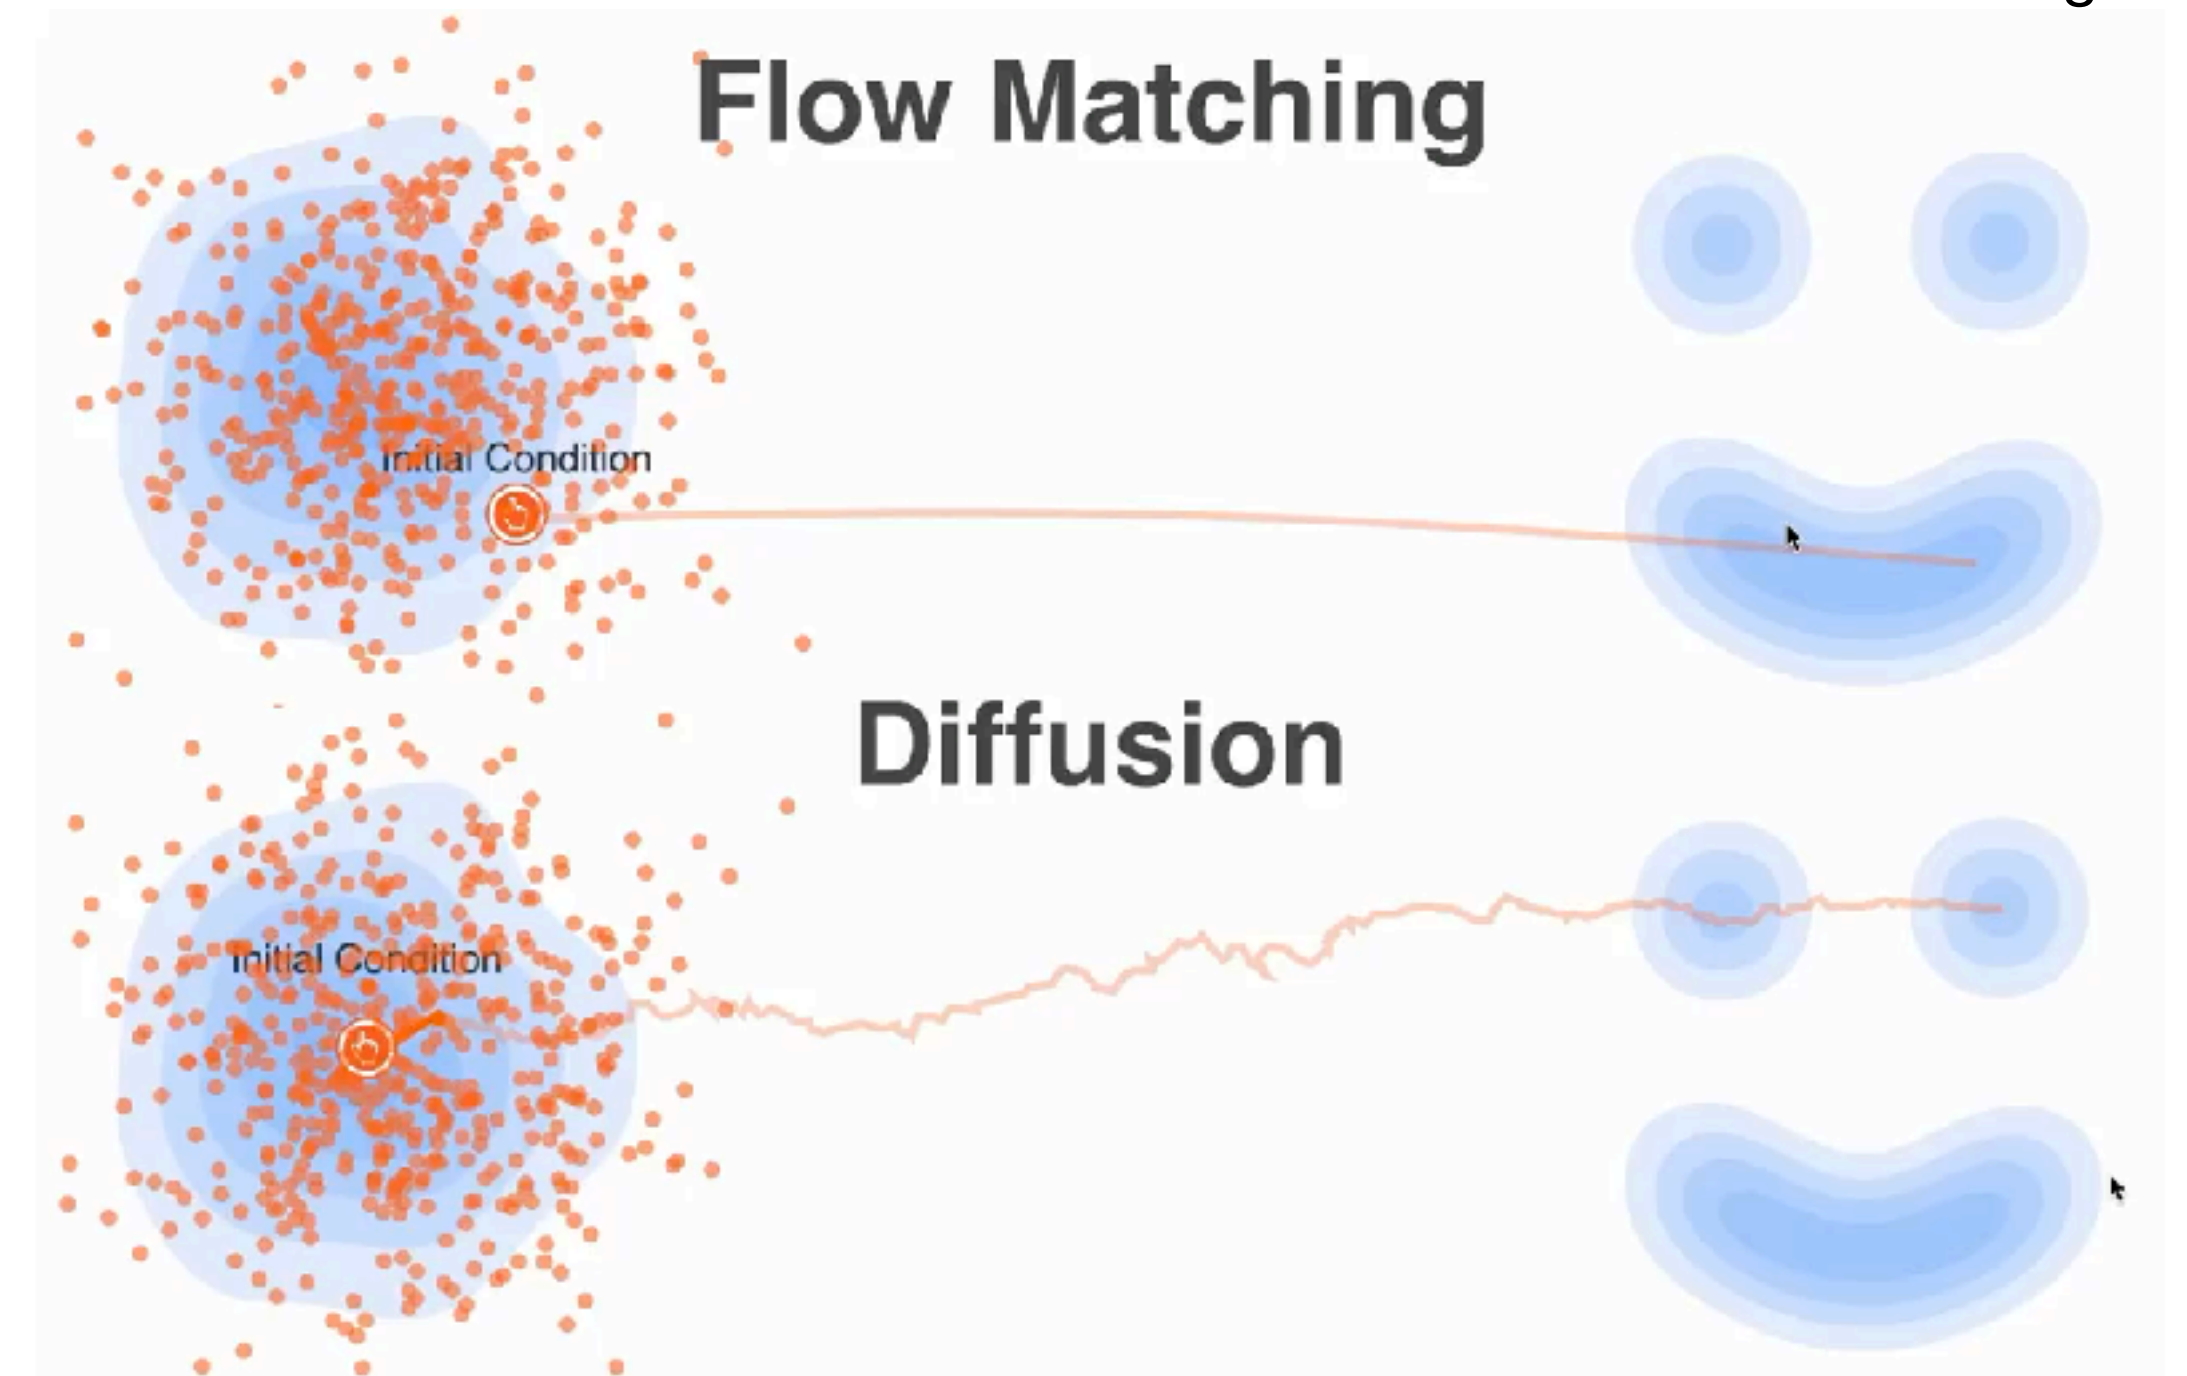
Forrás: [M. Yi](#)

# Differenciálegyenletek

## Előrettekintés



Forrás: [Y. Song](#)




Forrás: [A. Helbling](#)


A kurrens diffúziós & folyam-alapú generatív modellek ODE / SDE technikákra épülnek!

# Differenciálegyenletek

## Előrettekintés



Forrás: [Y. Song](#)



Forrás: [A. Helbling](#)

A kurrens diffúziós & folyam-alapú generatív modellek ODE / SDE technikákra épülnek!

# Következő előadás: Generatív modellezés alapjai

- Generatív modell fogalma
- Generatív modellek kiértékelése
- AE, VAE, GAN

