




# 7. Előadás: Diffúziós Modellek

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



Dr. Vaitkus Márton

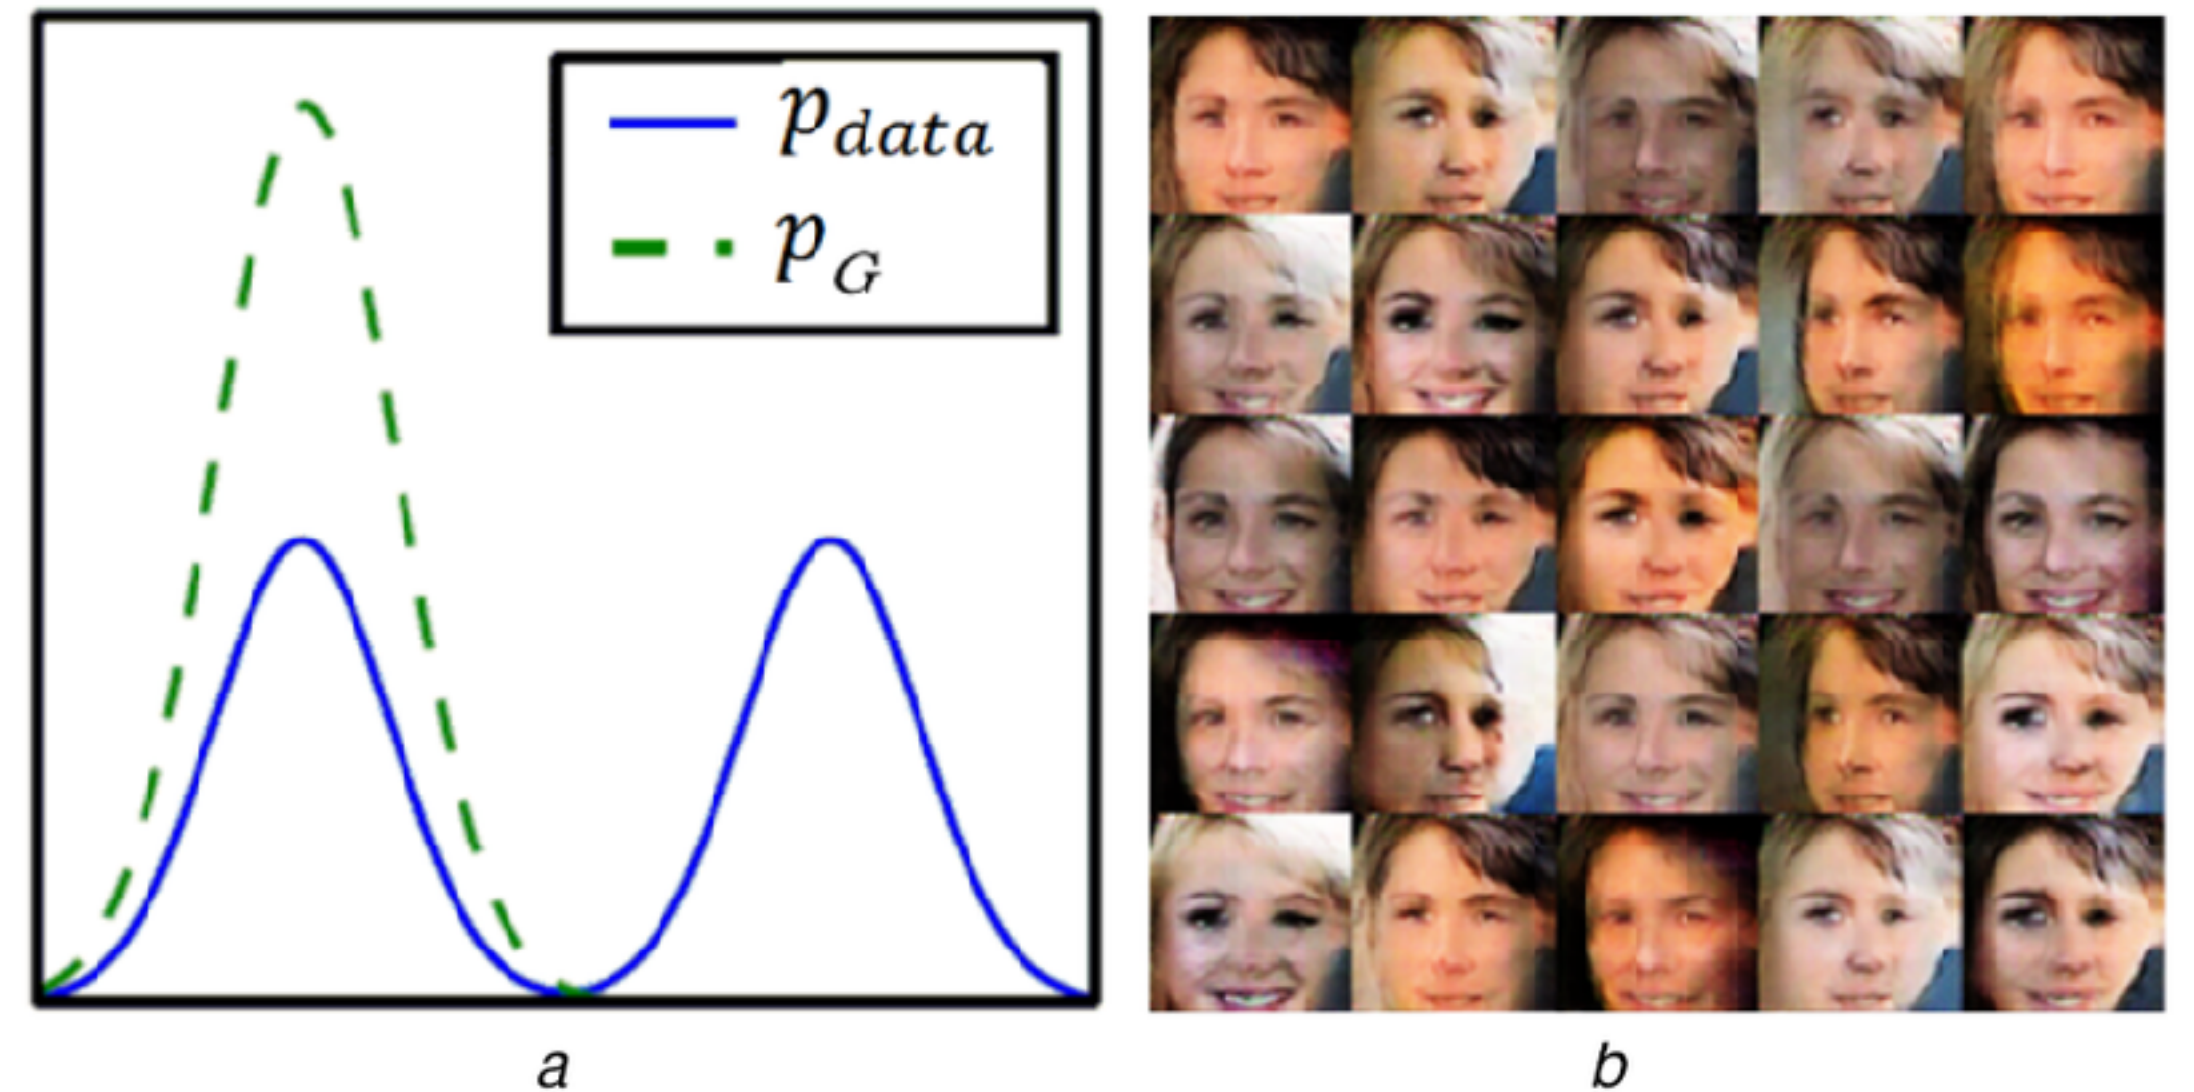
# Generatív Modellezés

## Korábbi módszerek



### Autóenkóder:

Változatos, de homályos/“átlagos” képek



### GAN:

Részletes, de egyhangú képek (“mode collapse”)  
Nehéz tanítani


Nem várunk túl sokat egy neurális hálótól?

# Diffúziós Modellek

Mi lenne, ha a képet nem egy lépésben generálnánk, hanem fokozatosan?



Diffúzió




Autoregresszió

# Diffúziós Modellek

Mi lenne, ha a képet nem egy lépésben generálnánk, hanem fokozatosan?



Diffúzió



Autoregresszió

# Diffúziós Modellek


## Denoizer hálók

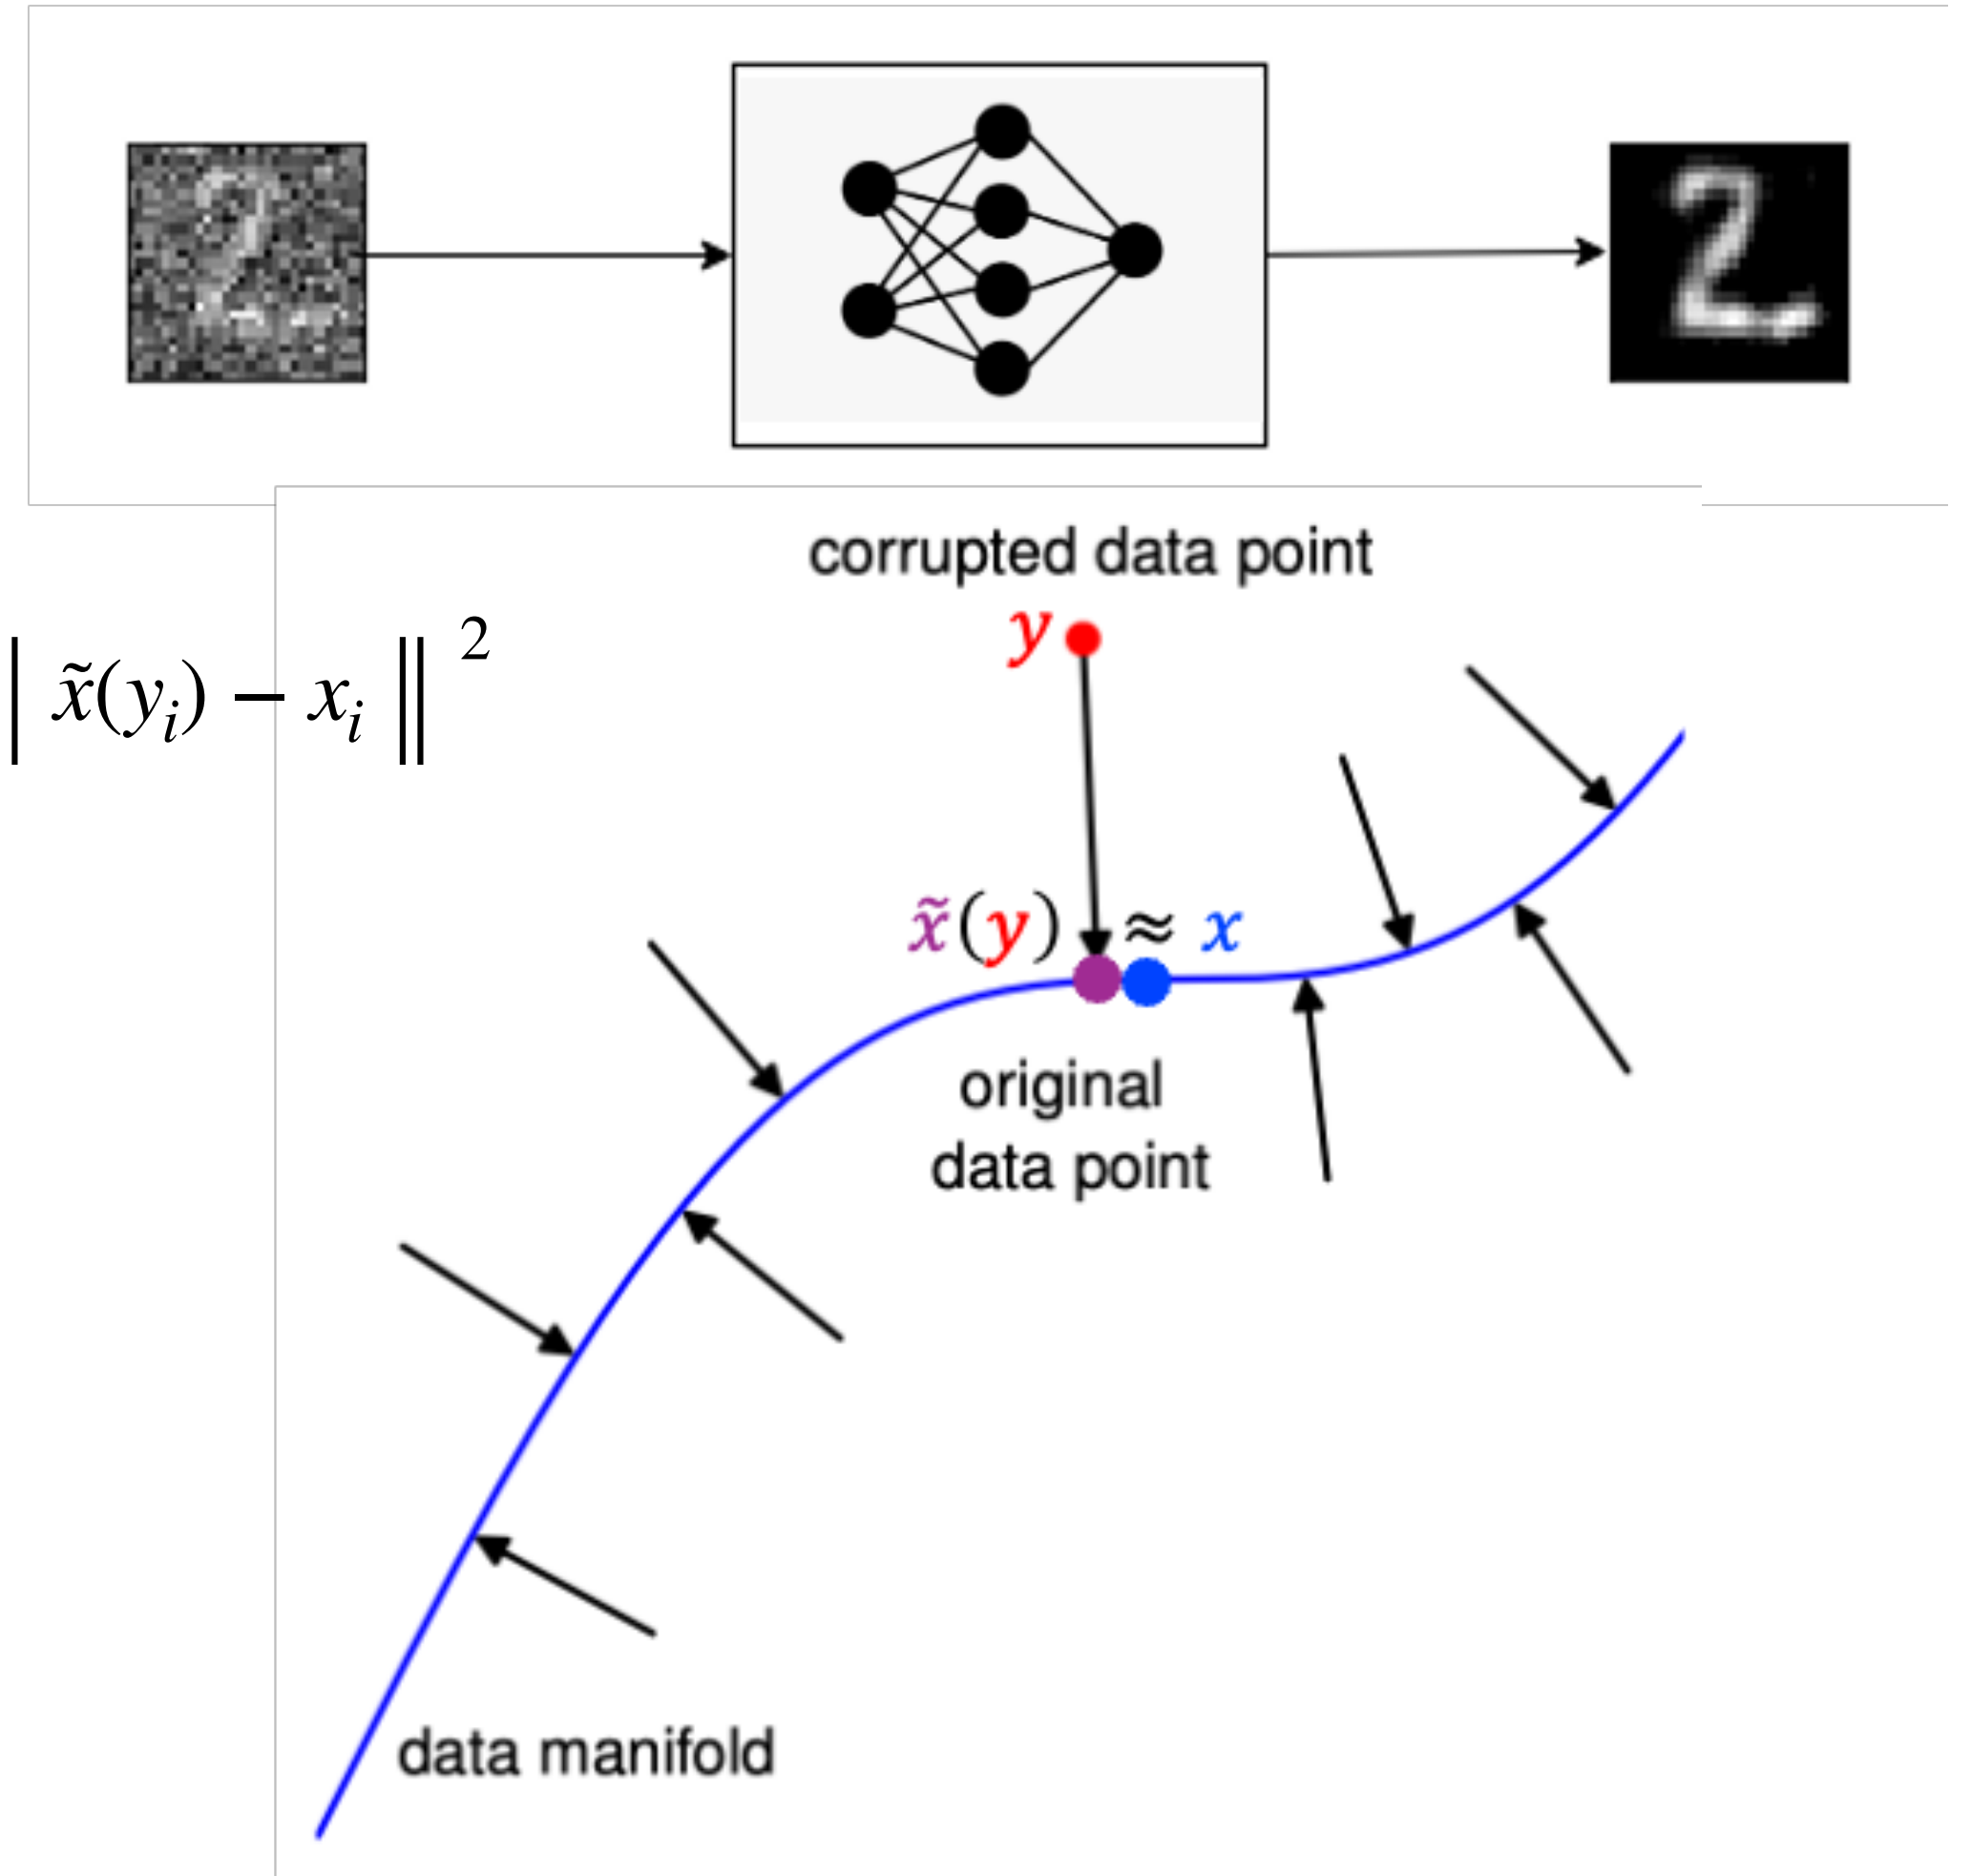
- Tekintsünk egy  $x \sim p(x)$  képet, adjunk hozzá Gaussi zajt  $\sigma_t$  szórással:

$$y = x + \epsilon, \quad \epsilon \sim p_\sigma(y | x) = \mathcal{N}(0, \sigma)$$

- Tanítsunk hálót a tiszta kép MSE rekonstrukciójára:  $\min_{\tilde{x}} \sum_i \|\tilde{x}(y_i) - x_i\|^2$
- MSE szerint legjobb becslés a tiszta képre (**MMSE**):

$$\tilde{x}(y) = \int x \cdot \underbrace{p(x | y)}_{\frac{p(y | x) \cdot p(x)}{p(y)}} dx = \frac{1}{p(y)} \int x \cdot p(y | x) p(x) dx$$

- **Formulával:**  $\tilde{x}(y) = \sum_i \frac{e^{-\frac{(x_i - y)^2}{2\sigma^2}} \cdot x_i}{\sum_j e^{-\frac{(x_j - y)^2}{2\sigma^2}}}$  Sok adatpontra:  A hálóval csak közelítjük...



# Diffúziós Modellek

## Denoizer hálók

- Tekintsünk egy zajos és eredeti pontok közötti *különbségvektort* (becsült zajt):

$$\begin{aligned}\tilde{x}(y, \sigma) - y &= \int x \cdot p_\sigma(x | y) dx - y \cdot \underbrace{\int p_\sigma(x | y) dx}_1 = \int (x - y) \cdot p_\sigma(x | y) dx \\ &= \frac{1}{p_\sigma(y)} \int (x - y) p_\sigma(y | x) p(x) dx = \sigma^2 \frac{\nabla p_\sigma(y)}{p_\sigma(y)} = \sigma^2 \boxed{\nabla \log p_\sigma(y)}\end{aligned}$$

- **Ideális denoizer = zajos eloszlás score-függvénye!**

Zajos adatpontok eloszlásfüggvénye és gradiense:

“Gaussian blur” (az eloszlásra!!)

$$p_\sigma(y) = \int p_\sigma(y | x) p(x) dx \propto \int e^{-\frac{\|y-x\|^2}{2\sigma^2}} p(x) dx$$

$$\nabla p_\sigma(y) = \frac{1}{\sigma^2} \int (x - y) p_\sigma(y | x) p(x) \quad \underline{\underline{\text{DEMÓ!}}}$$

*Tweedie  
formula*



M. Tweedie  
(1919–1996)

**Score  
függvény!**

# Diffúziós Modellek


## Denoizer hálók

- Több lehetséges paraméterezés a denoizer hálókra

- Tiszta kép becslése:  $\tilde{x}_\theta(y, \sigma) \approx x$

- Zaj becslése:  $\tilde{\epsilon}_\theta(y, \sigma) \approx y - x$  (a leggyakoribb!)

- Score matching:  $\tilde{s}_\theta(y, \sigma) \approx \nabla \log p_\sigma(y)$





Elméletileg ekvivalensek, de mindig ellenőrizzük az implementáció melyiket használja!

# Diffúziós Modellek

## Score matching – Langevin mintavételezés

- Hogyan kapunk denoizer modellből generatív modellt?
- A denoizer becslést ad a score függvényről (**score matching**) – alkalmazzunk **Langevin mintavételezést!**

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





# Diffúziós Modellek

## Score matching – Langevin mintavételezés


- Hogyan kapunk denoizer modellből generatív modellt?
- A denoizer becslést ad a score függvényről (**score matching**) – alkalmazzunk **Langevin mintavételezést!**

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



# Diffúziós Modellek

## Score matching – Zajszint megválasztása

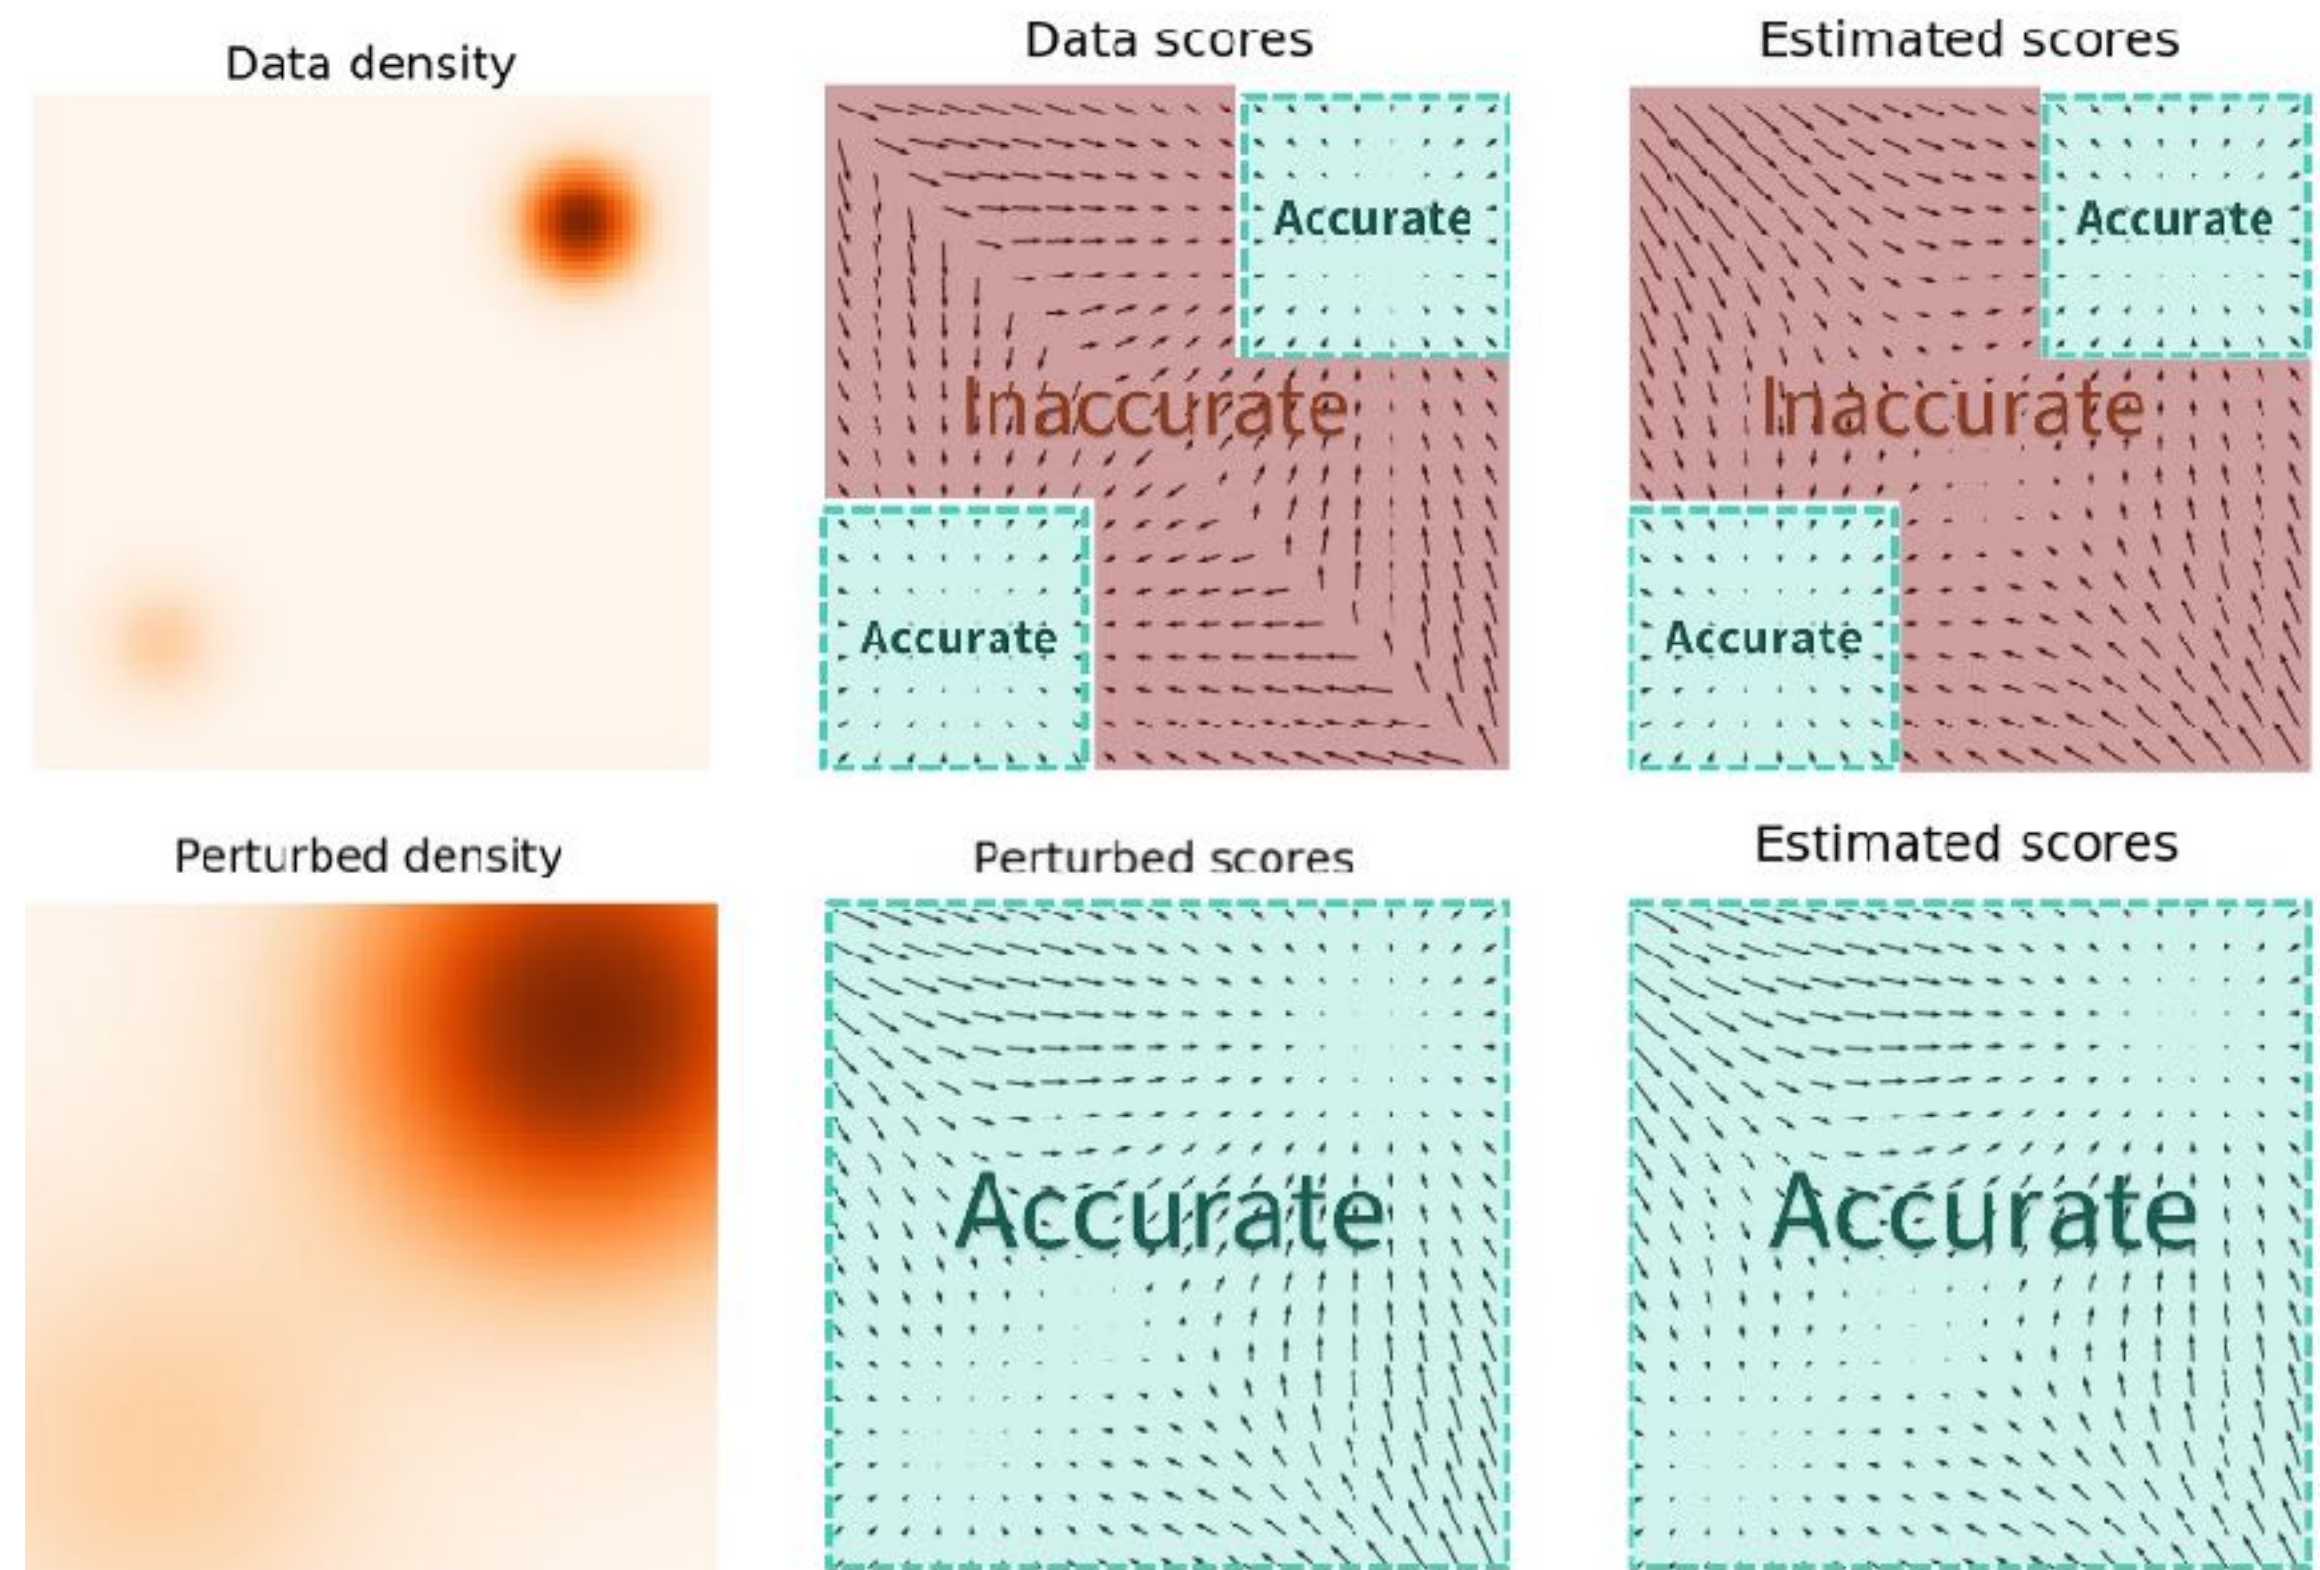



Score függvény különböző zajszintekre – DEMO

# Diffúziós Modellek

## Score matching – Zajszint megválasztása

- Mennyi zajt adjunk az adatokhoz?
- Túl kevés zaj: pontatlanul becsüljük az eloszlást
- Túl sok zaj: a denoizer homályos/“átlagos” mintákat generál



# Diffúziós Modellek

## Score matching

- Ötlet: fokozatosan növeljük a zaj szintjét valamilyen  $\sigma(t)$ ,  $t \in [0,1]$  ütemezés szerint és fokozatosan távolítsuk el!

- Tanítsunk egy közös denoizer hálót a különböző zajszintekre!

$$\min_{\theta} \mathbb{E}_{\sigma} \mathbb{E}_{x, \epsilon \sim \mathcal{N}(0, I)} \left[ \left\| \epsilon_{\theta}(x + \sigma \cdot \epsilon, \sigma) - \epsilon \right\|^2 \right]$$

- Mintavételezés: “lágyított” Langevin módszerrel

- Induláskor  $\sigma(t) \approx 1$ , aztán minden lépésben fokozatosan kisebb zajszint szerint lépünk

- Diffúziós modellek egy példája




---

### Generative Modeling by Estimating Gradients of the Data Distribution

---

Yang Song  
Stanford University

Stefano Ermon  
Stanford University



# Diffúziós Modellek

## Score matching

- Ötlet: fokozatosan növeljük a zaj szintjét valamilyen  $\sigma(t)$ ,  $t \in [0,1]$  ütemezés szerint és fokozatosan távolítsuk el!

- Tanítsunk egy közös denoizer hálót a különböző zajszintekre!

$$\min_{\theta} \mathbb{E}_{\sigma} \mathbb{E}_{x, \epsilon \sim \mathcal{N}(0, I)} \left[ \left\| \epsilon_{\theta}(x + \sigma \cdot \epsilon, \sigma) - \epsilon \right\|^2 \right]$$

- Mintavételezés: “lágyított” Langevin módszerrel

- Induláskor  $\sigma(t) \approx 1$ , aztán minden lépésben fokozatosan kisebb zajszint szerint lépünk

- Diffúziós modellek egy példája




---

## Generative Modeling by Estimating Gradients of the Data Distribution

---


Yang Song  
Stanford University

Stefano Ermon  
Stanford University



# Diffúziós Modellek


## Neurális architektúra



A diffúziós modellek architektúráira (U-Net, Transformer) még visszatérünk...

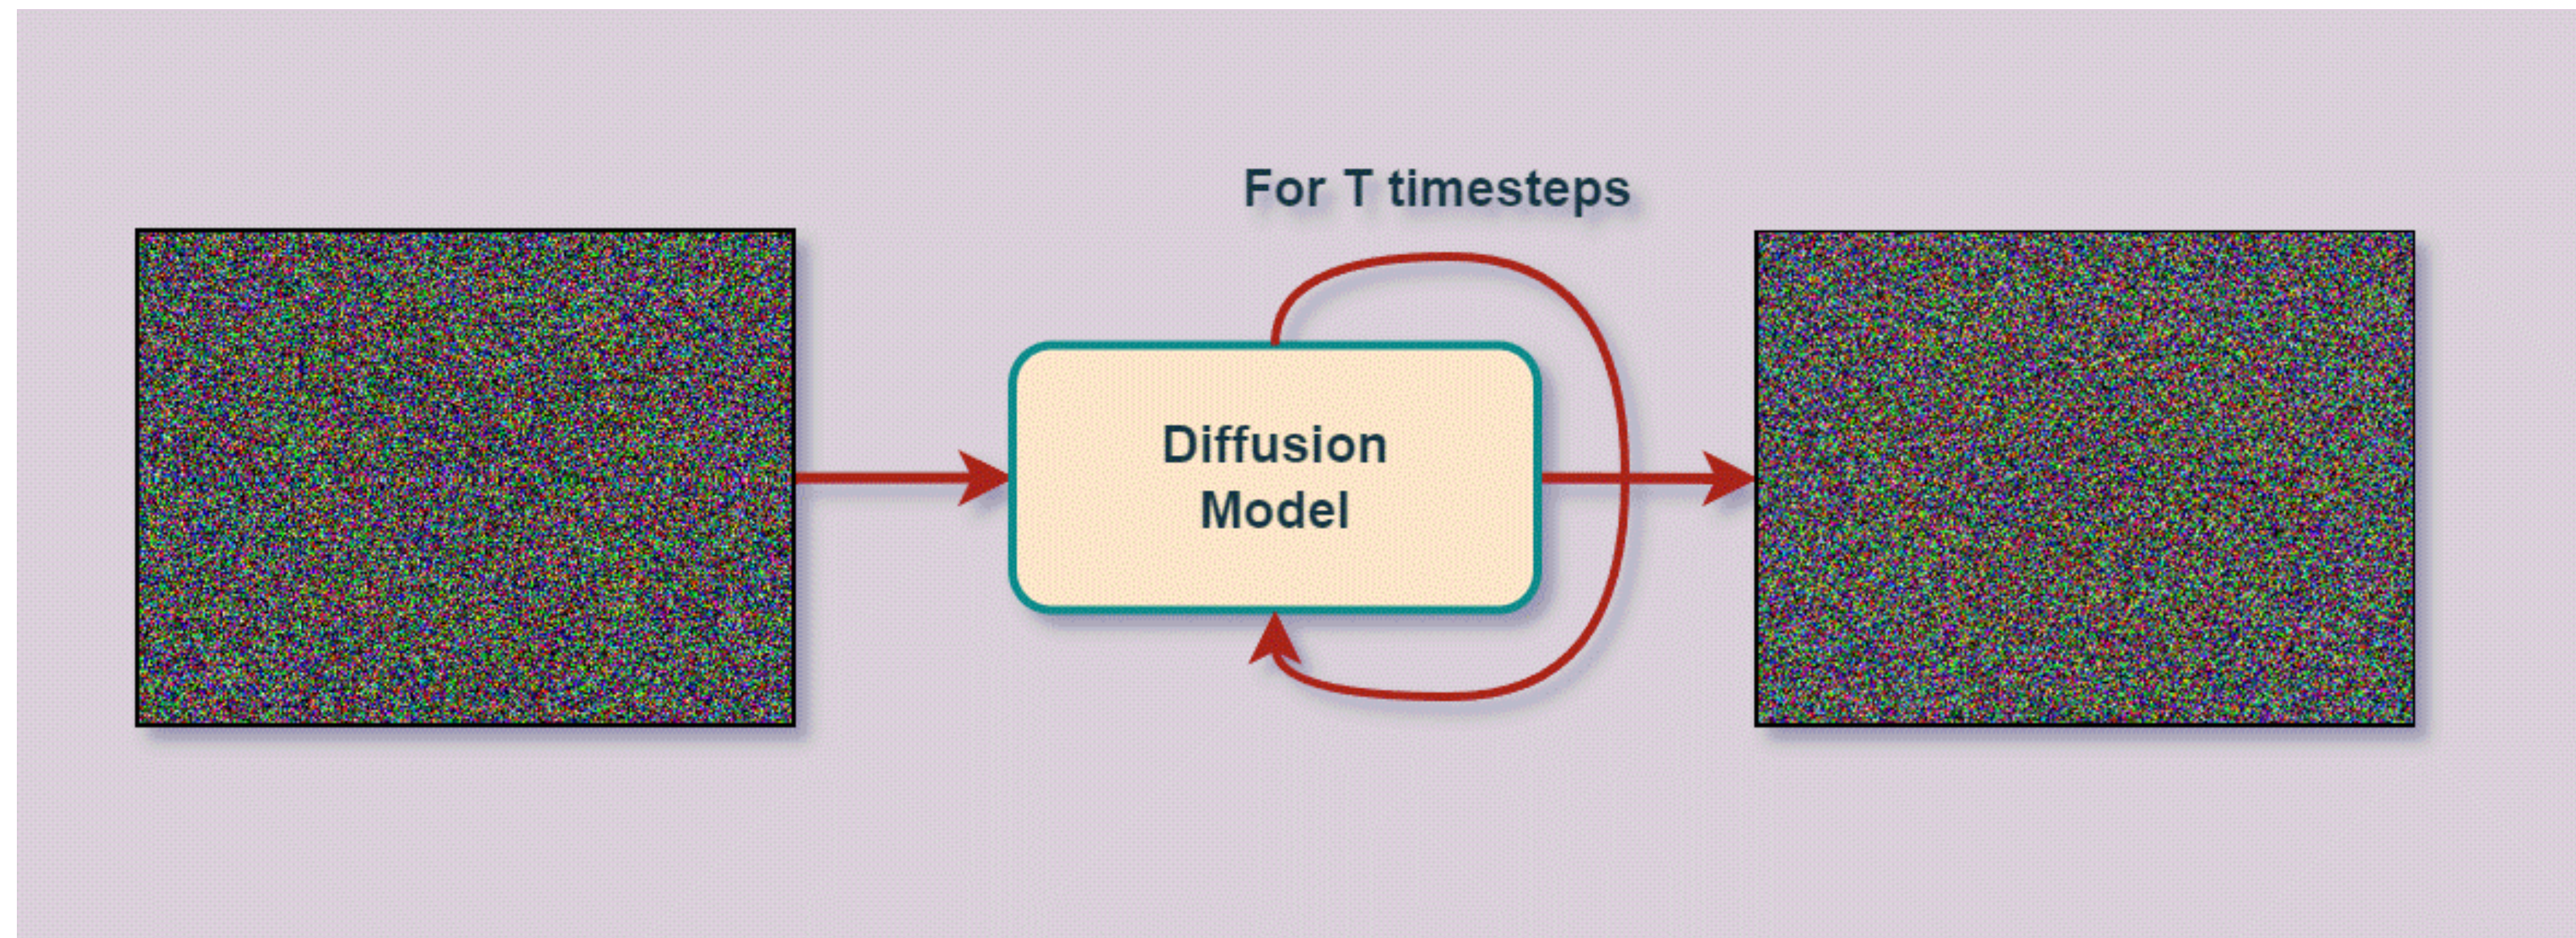


# Diffúziós Modellek



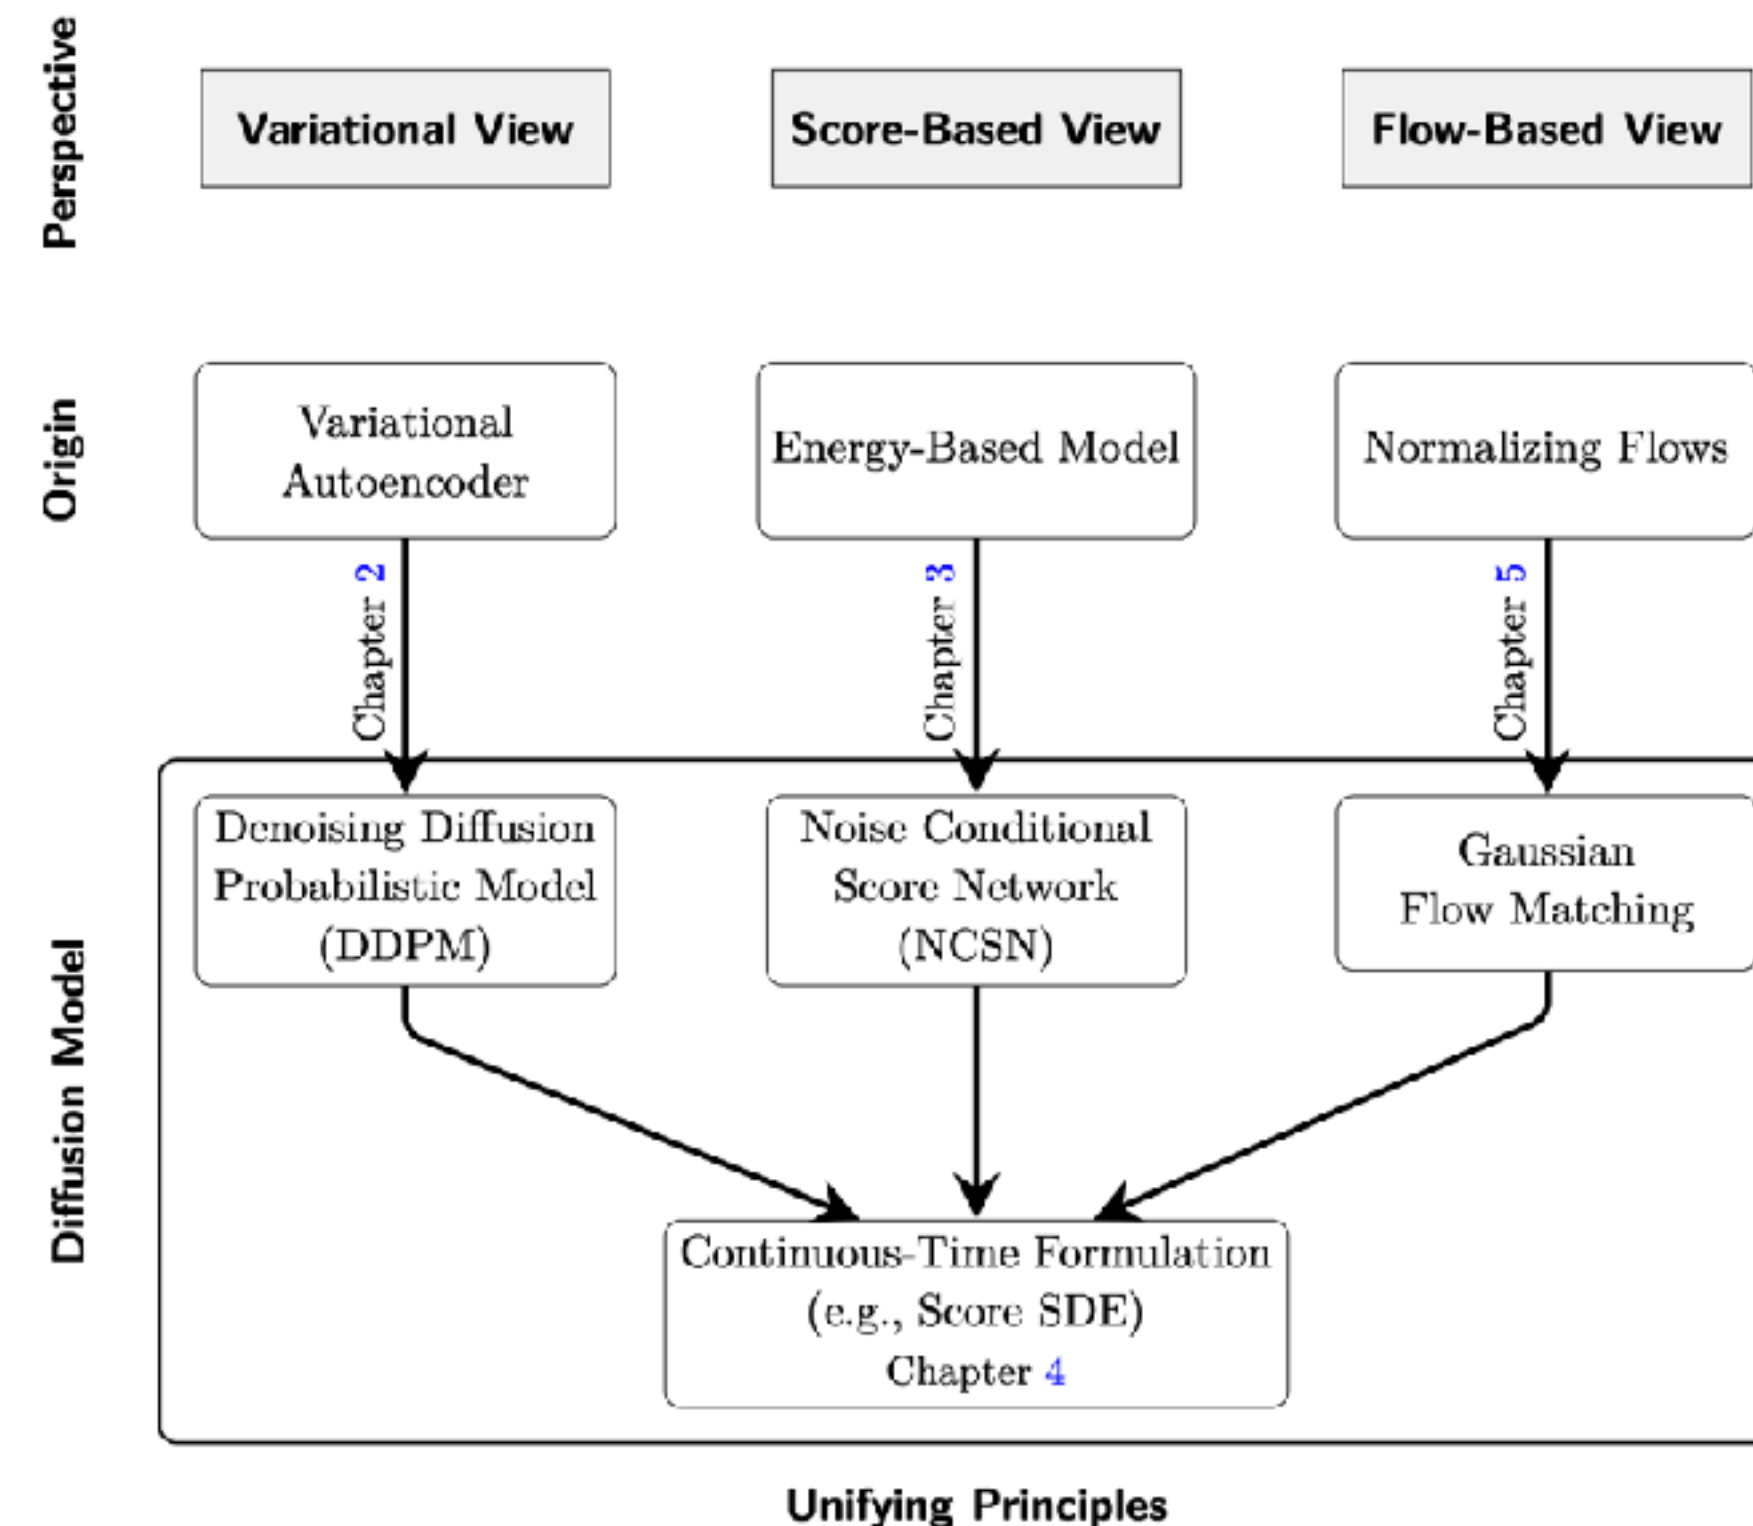
**Diffúziós modellek**: iteratív generatív modellek egy általános családja

# Diffúziós Modellek



**Diffúziós modellek**: iteratív generatív modellek egy általános családja

# Diffúziós Modellek



A score matching a diffúziós modellek egy lehetséges felfogása...  
De nem az egyetlen, számos különböző perspektíva létezik!

# Diffúziós Modellek

## Forward folyamat

- Forward diffúziós folyamat (fix!):

$$q(x_t | x_0) \sim \mathcal{N}(\sqrt{\bar{\alpha}_t} \cdot x_0, (1 - \bar{\alpha}_t) \cdot I)$$

$$\bar{\alpha}_t = \prod_{s=1}^t (1 - \beta_s) \quad \beta_t \in (0,1), t \in [1, T-1] :$$

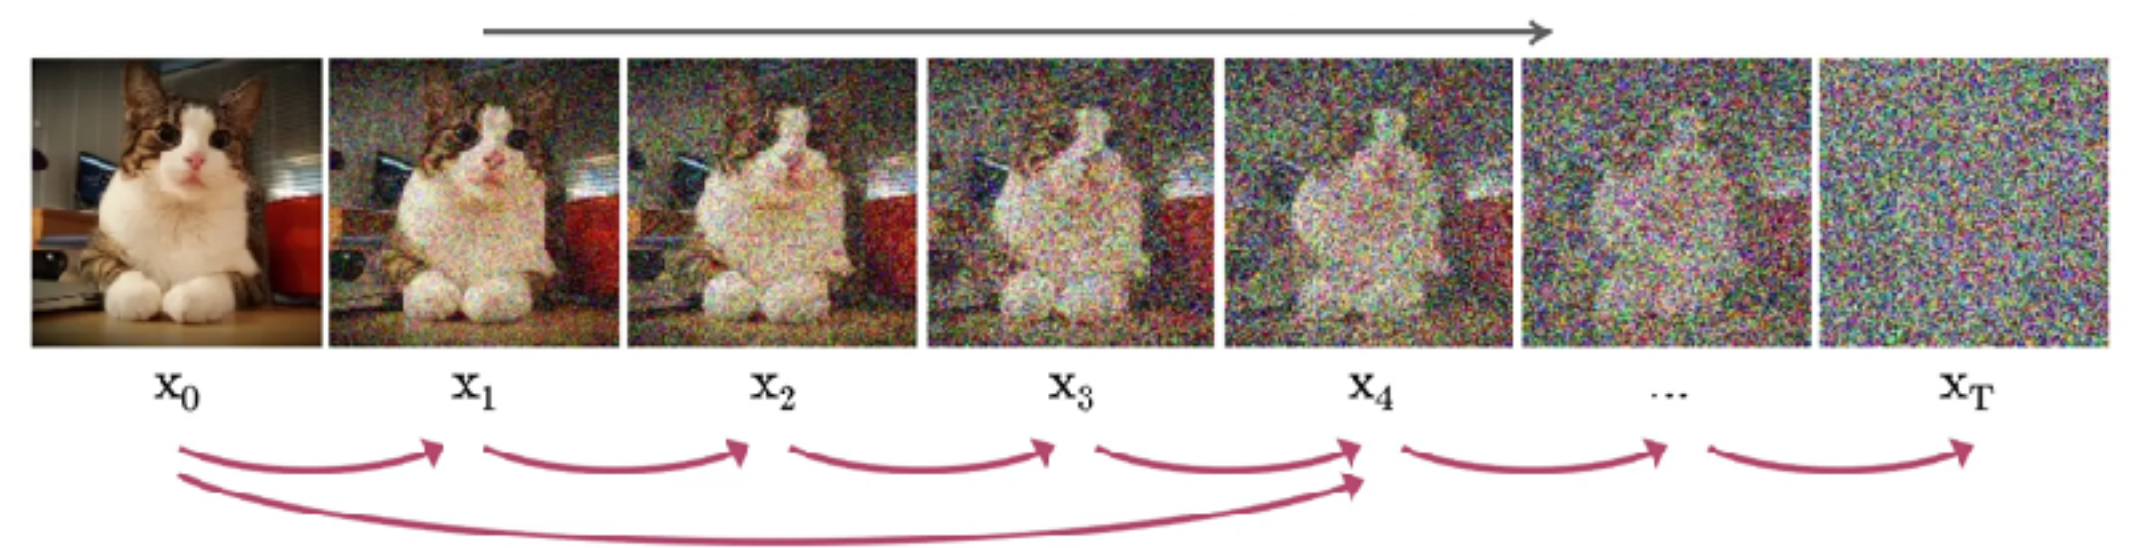

**zaj ütemezés**  
(interpoláció az adat ( $T = 0$ ) és  $\mathcal{N}(0, I)$  zaj ( $T = 1$ ) között)

- Mintavétel:

$$q(x_t | x_0) = \sqrt{\bar{\alpha}_t} \cdot x_0 + \sqrt{1 - \bar{\alpha}_t} \cdot \epsilon \quad \epsilon \sim \mathcal{N}(0, I)$$

*Emlékezzünk:*

$$\text{Var}(A \cdot x + B \cdot y) = A^2 \cdot \text{Var}(x) + B^2 \cdot \text{Var}(y) + 2AB \cdot \text{Cov}(A, B)$$



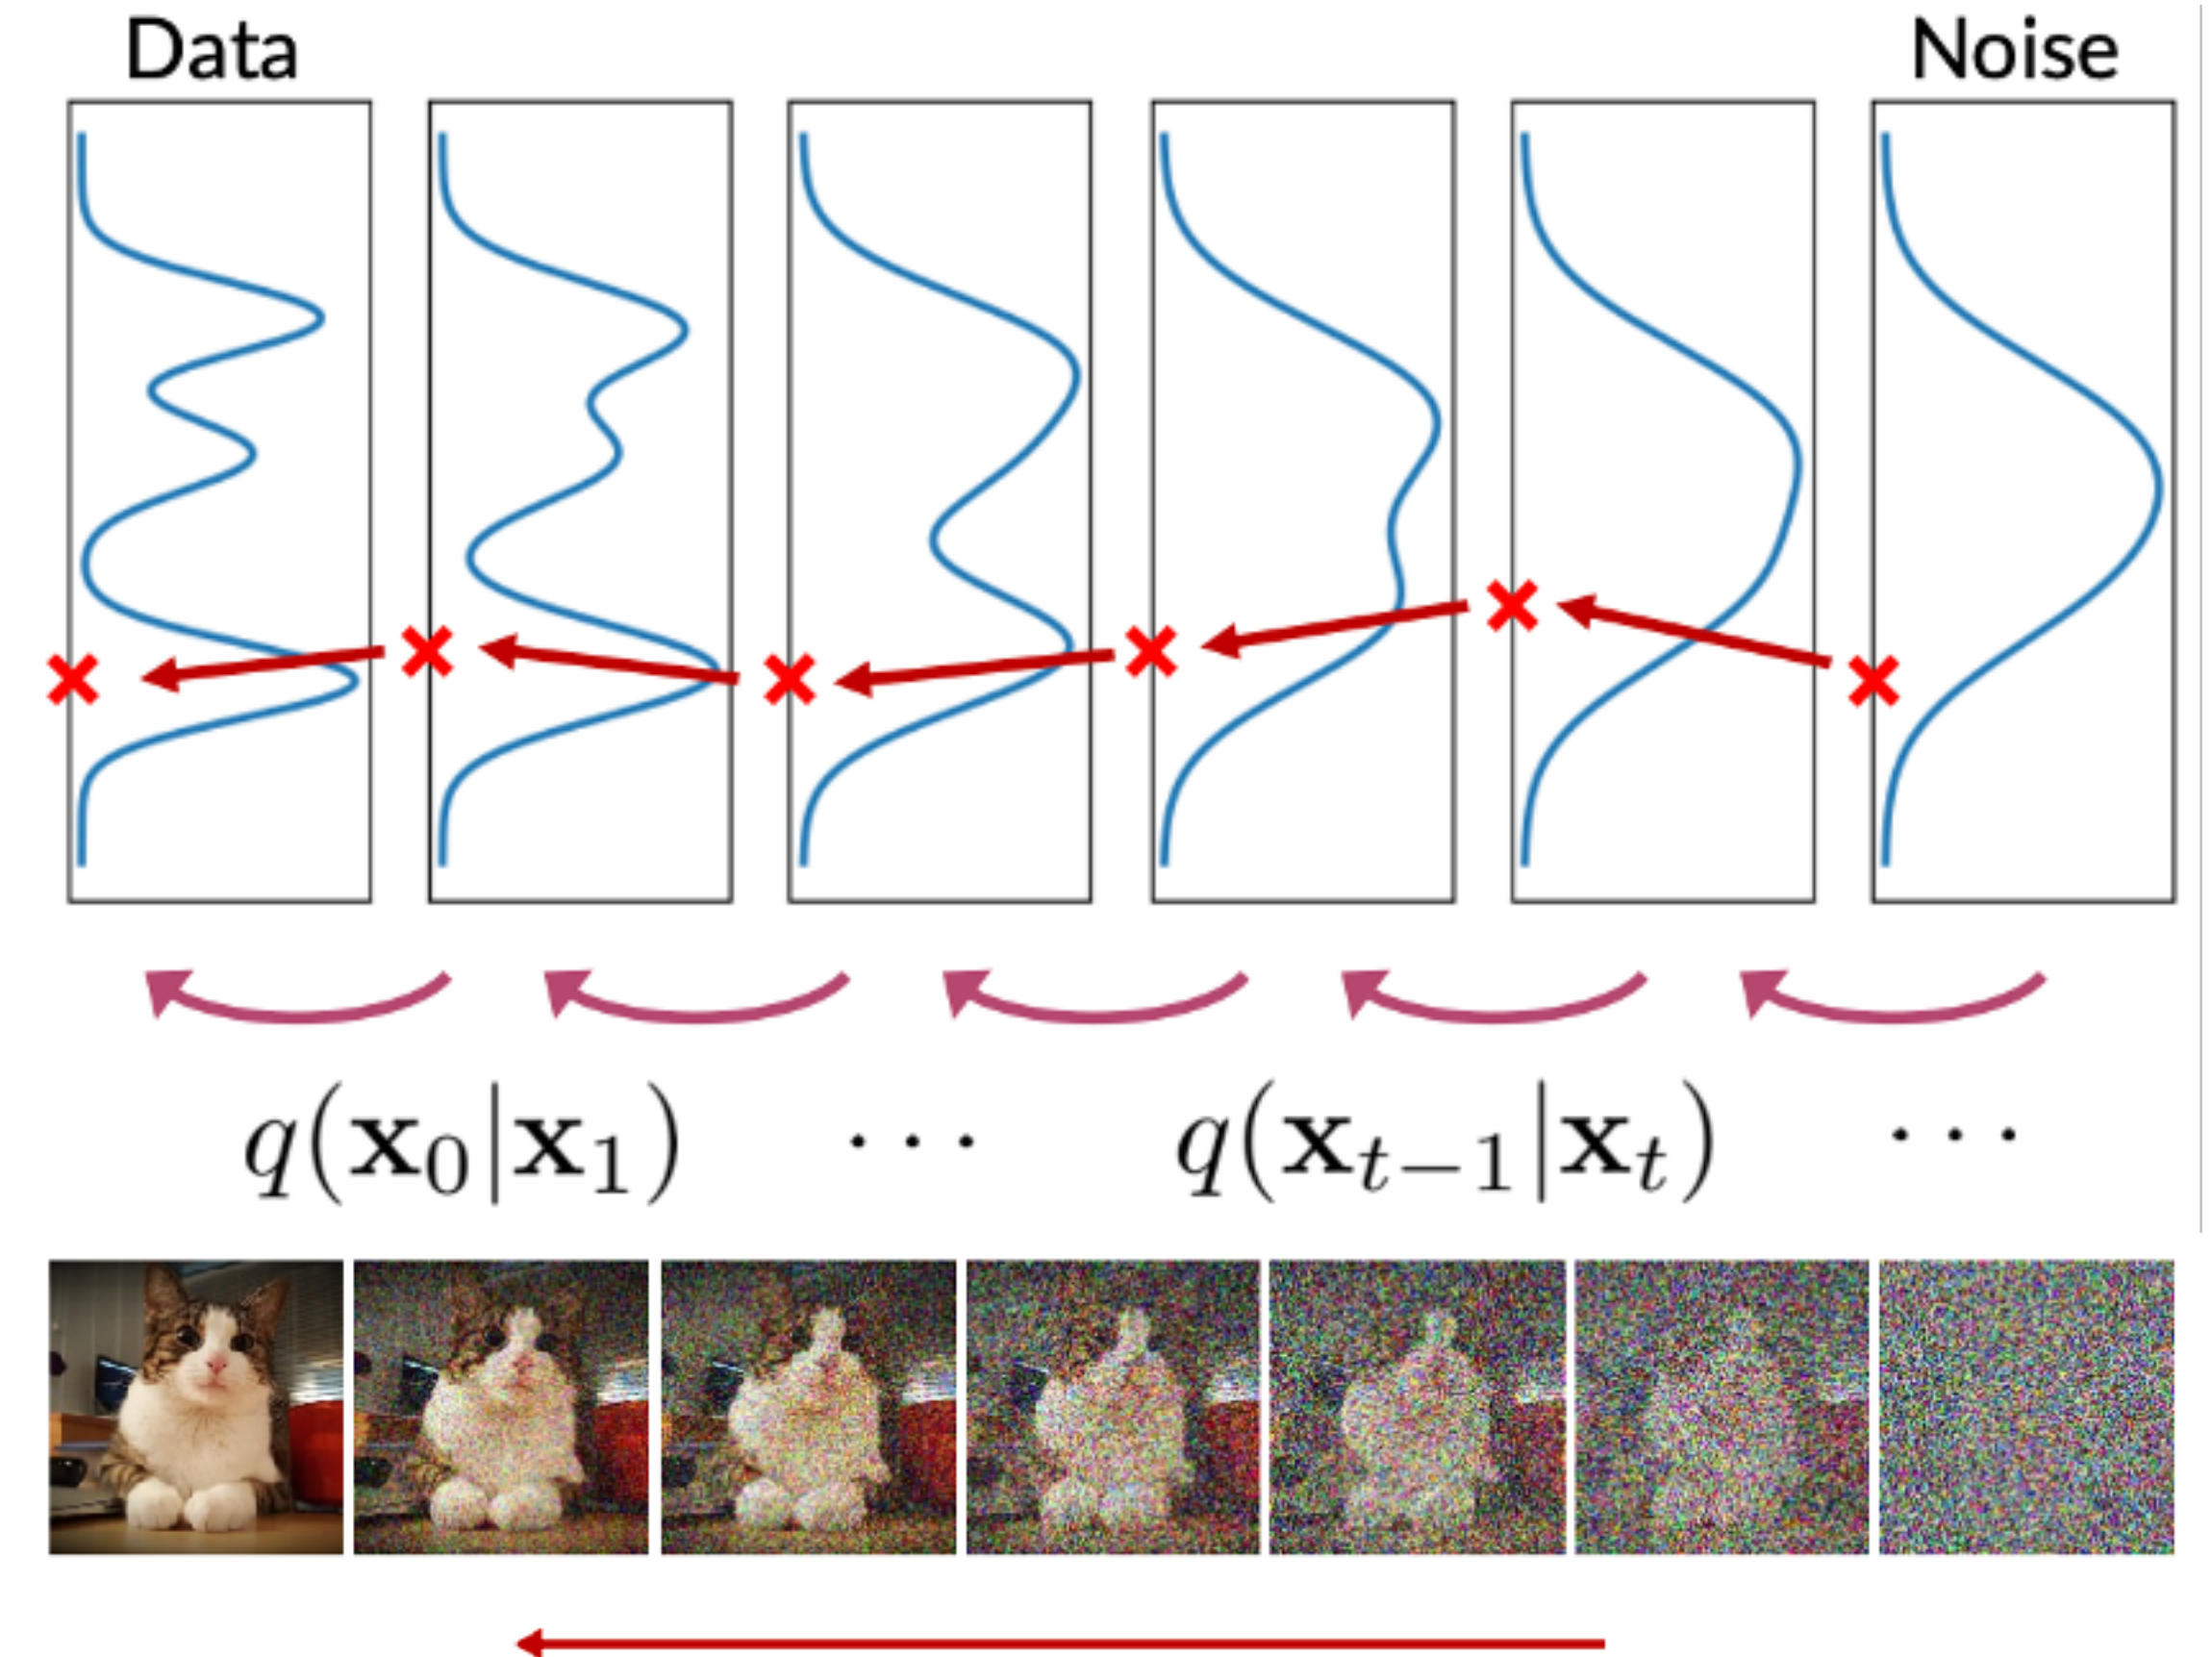
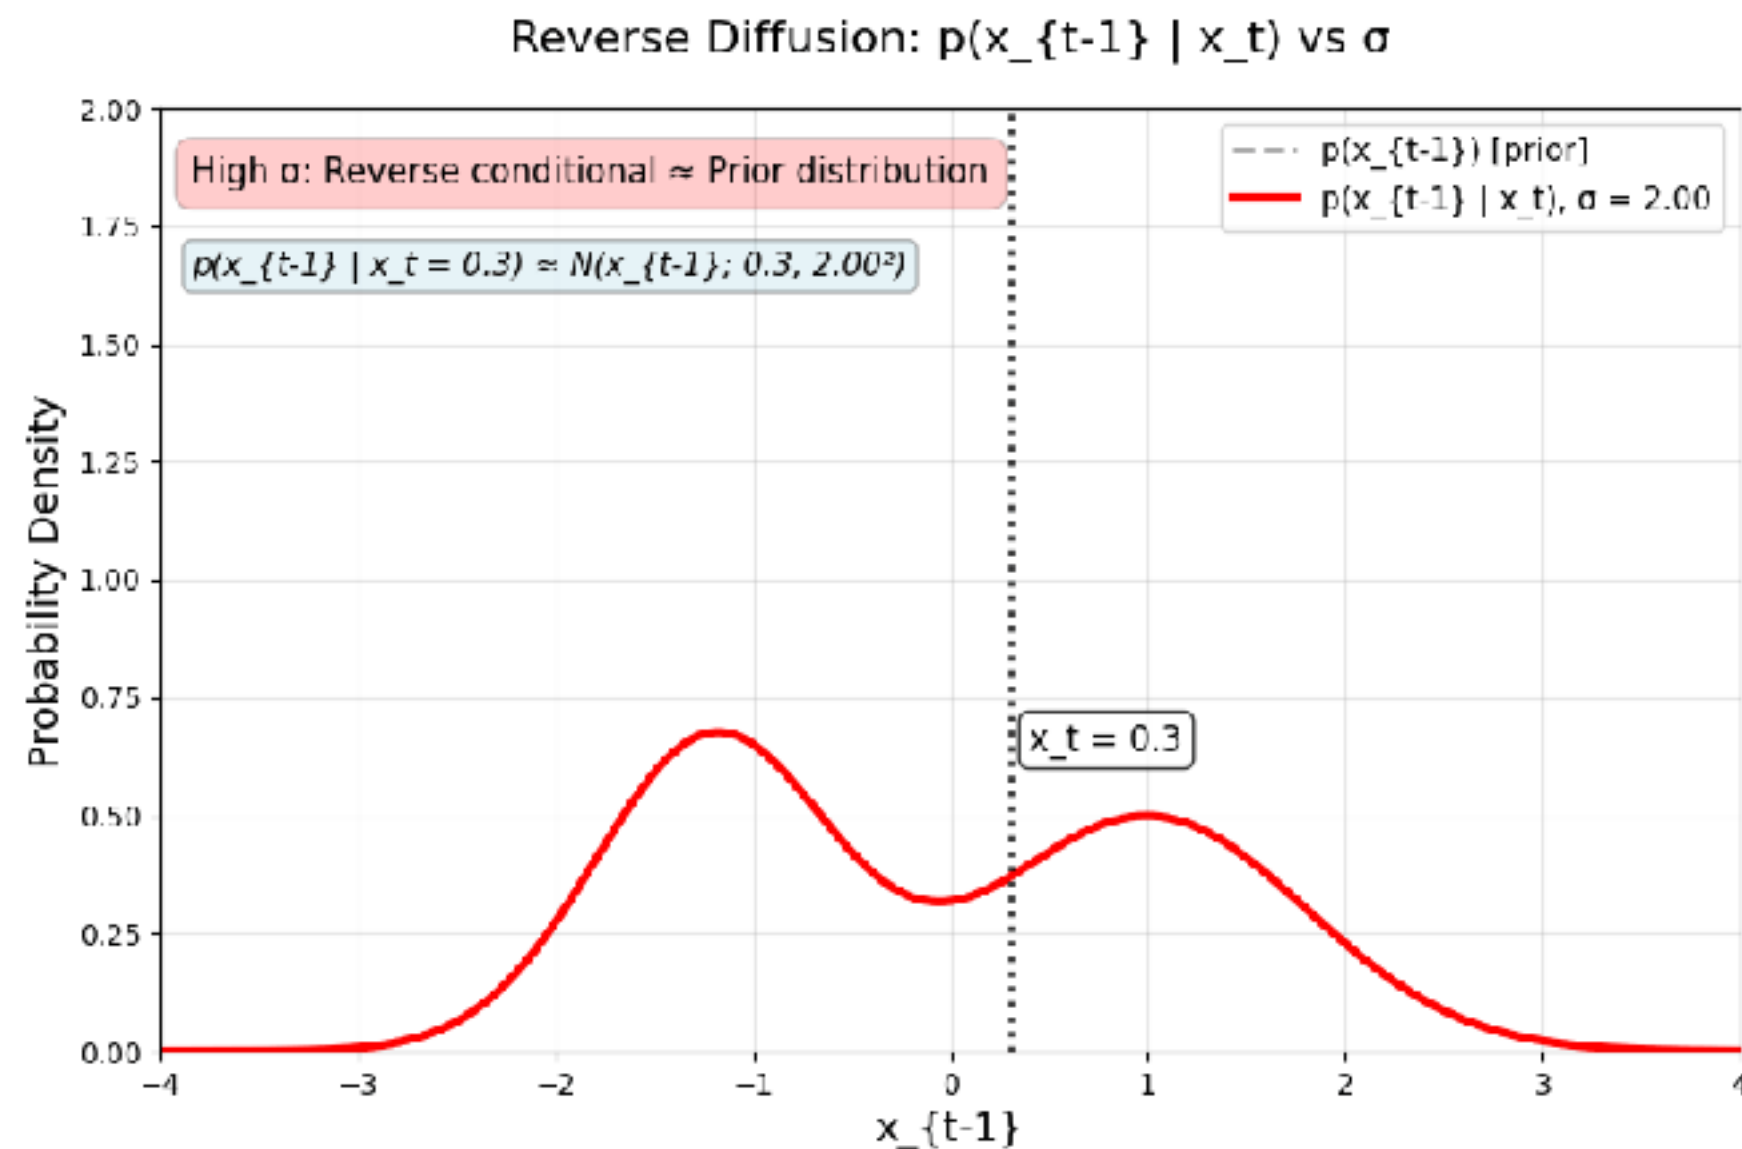
# Diffúziós Modellek

## Reverse folyamat

- Reverse diffúziós folyamat:

$$p(x_{t-1} | x_t) \underset{\text{Bayes}}{\propto} p(x_t | x_{t-1}) \cdot p(x_{t-1}) \quad \text{☠}$$

- Kis lépésre közelíthető normális eloszlással!



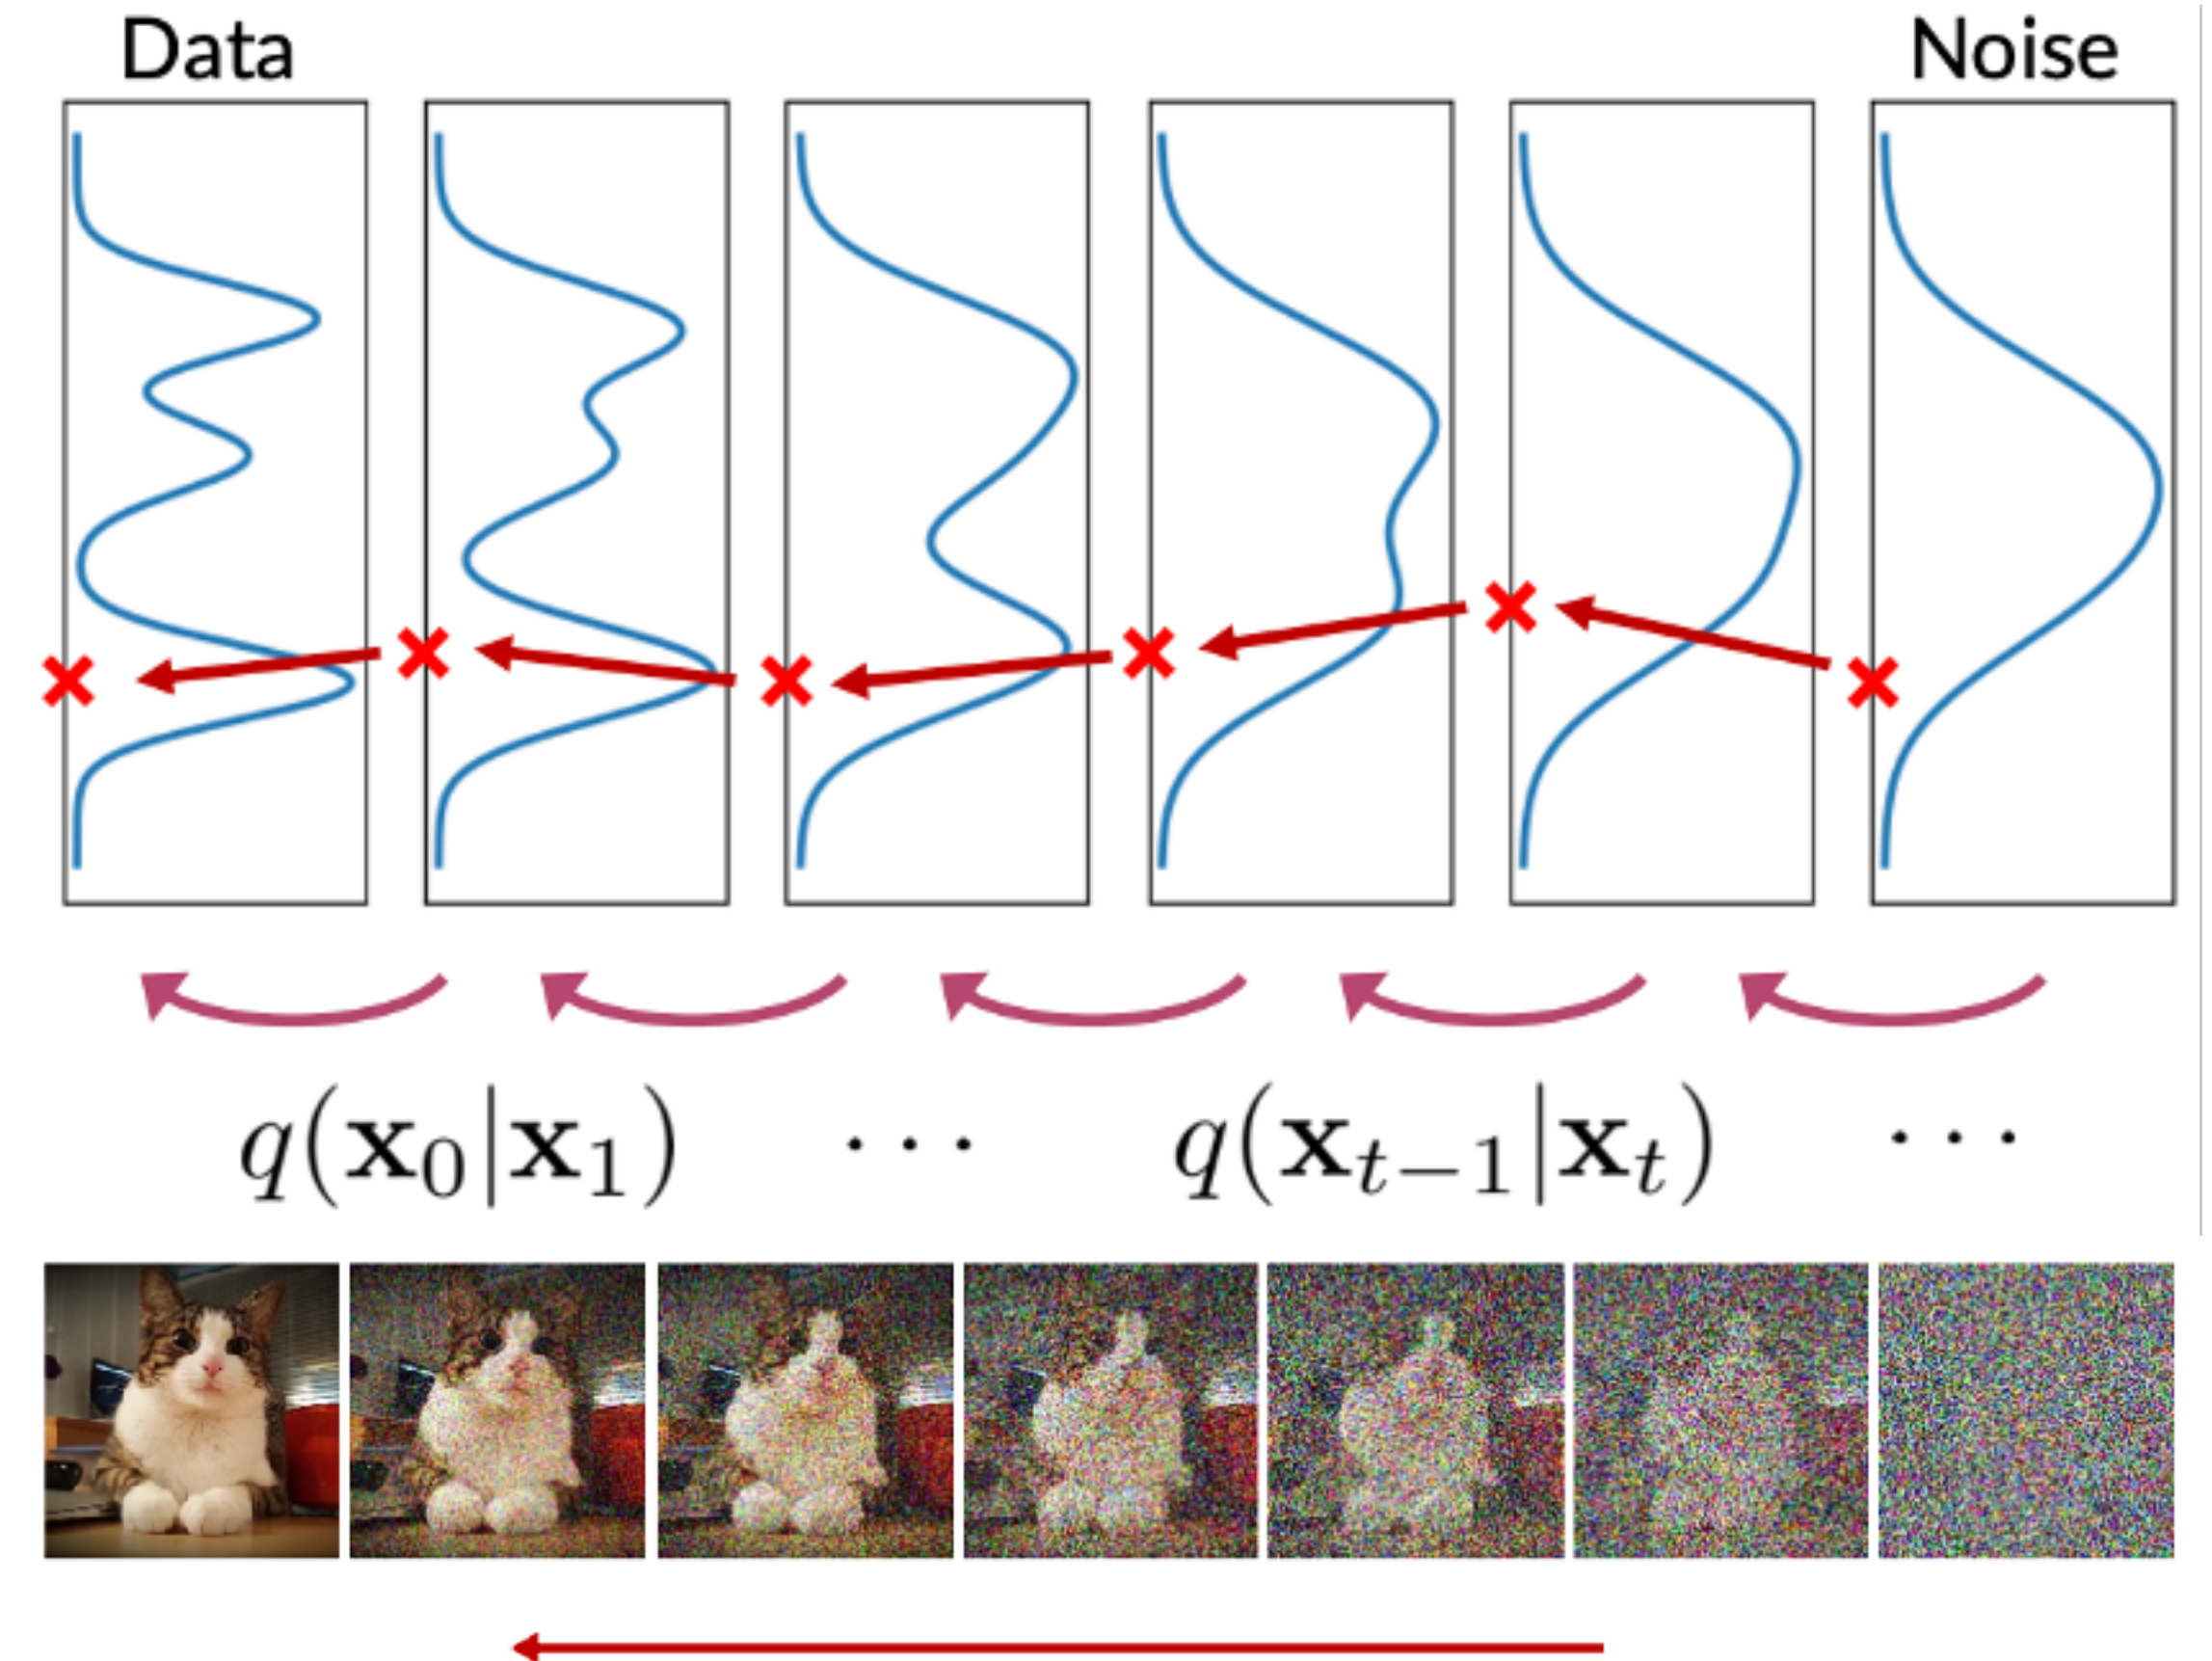

# Diffúziós Modellek

## Reverse folyamat

- Reverse diffúziós folyamat:

$$p(x_{t-1} | x_t) \underset{\text{Bayes}}{\propto} p(x_t | x_{t-1}) \cdot p(x_{t-1}) \quad \text{☠}$$

- Kis lépésre közelíthető normális eloszlással!



# Diffúziós Modellek

## Reverse folyamat

- Reverse posterior eloszlása kezelhetőbb, ha ismerjük a zajmentes képet:

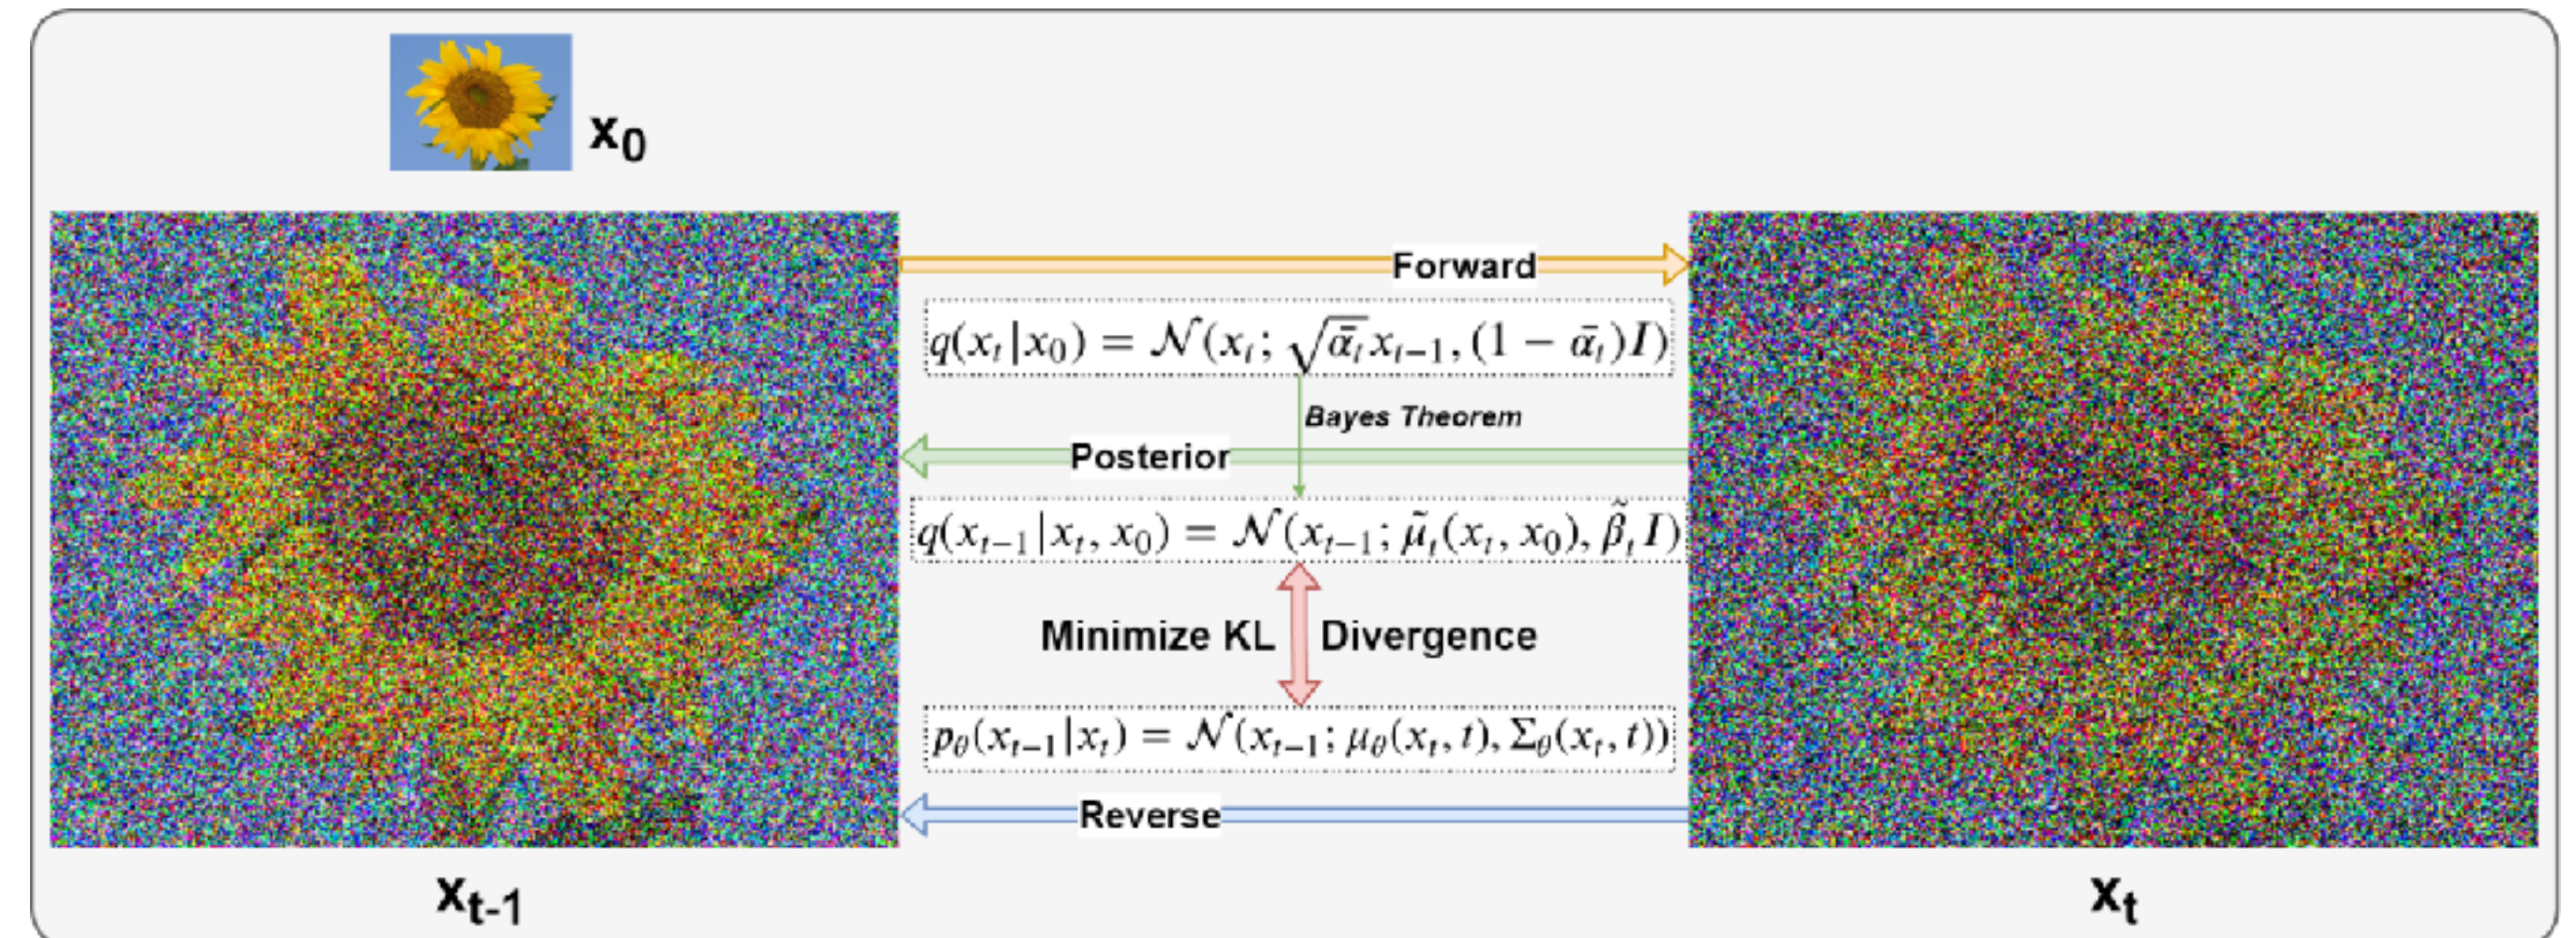
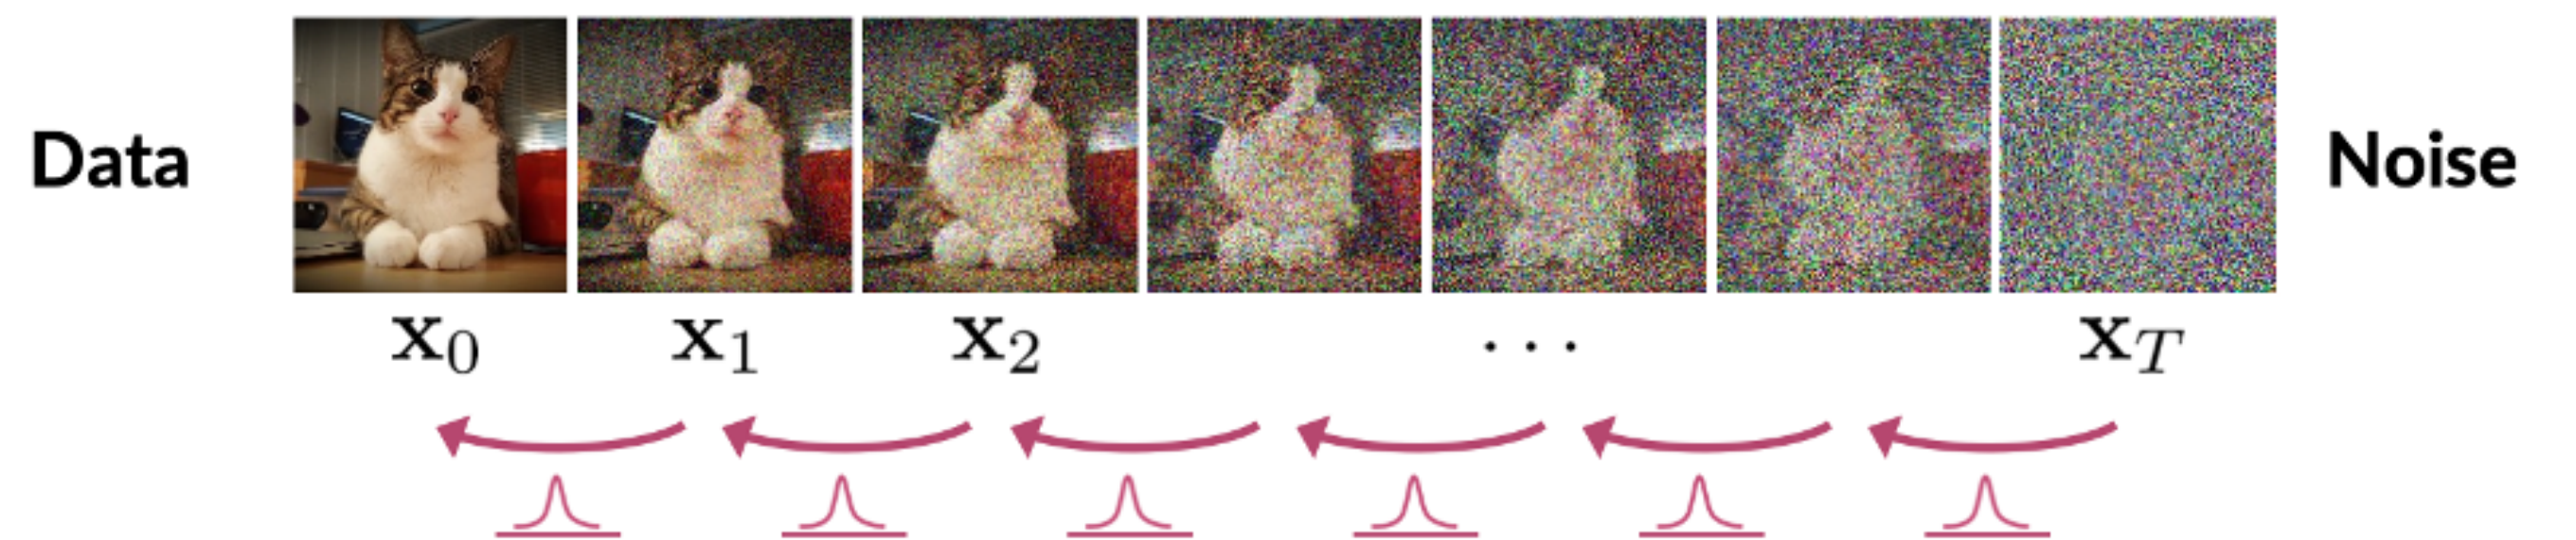
$$q(x_{t-1} | x_t, x_0) \propto \underbrace{q(x_t | x_{t-1}, x_0)}_{q(x_t | x_{t-1})} \cdot q(x_{t-1} | x_0)$$

Minden normális eloszlású!

- Közelítsük neurális hálóval:

$$p_\theta(x_{t-1} | x_t) = \mathcal{N}(\mu_\theta(x_t, t), \beta_t \cdot I)$$

Azonos háló minden lépésre!




# Diffúziós Modellek

## Denoising Diffusion Probabilistic Model (DDPM)

- Tanítás log-likelihood alapján — közelítő ELBO (a la VAE)

↓

Gauss eloszlásokra szimpla négyzetes hiba!



- **DDPM**  $\approx$  score matching!



- A legtöbb diffúziós modell hasonló loss-t minimalizál, csak a generálás (mintavételezés) módszerében különbözik!

---

### Algorithm 1 Training

---

```
1: repeat  
2:  $\mathbf{x}_0 \sim q(\mathbf{x}_0)$   
3:  $t \sim \text{Uniform}(\{1, \dots, T\})$   
4:  $\epsilon \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$   
5: Take gradient descent step on  
    $\nabla_{\theta} \|\epsilon - \epsilon_{\theta}(\sqrt{\bar{\alpha}_t} \mathbf{x}_0 + \sqrt{1 - \bar{\alpha}_t} \epsilon, t)\|^2$   
6: until converged
```

---

---

### Algorithm 2 Sampling

---

```
1:  $\mathbf{x}_T \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$   
2: for  $t = T, \dots, 1$  do  
3:  $\mathbf{z} \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$   
4:  $\mathbf{x}_{t-1} = \frac{1}{\sqrt{\alpha_t}} \left( \mathbf{x}_t - \frac{1 - \alpha_t}{\sqrt{1 - \bar{\alpha}_t}} \epsilon_{\theta}(\mathbf{x}_t, t) \right) + \sigma_t \mathbf{z}$   
5: end for  
6: return  $\mathbf{x}_0$ 
```

---


# Diffúziós Modellek

## Denoising Diffusion Probabilistic Model (DDPM)

- Tanítás log-likelihood alapján — közelítő ELBO (a la VAE)

↓

Gauss eloszlásokra szimpla négyzetes hiba!



- **DDPM**  $\approx$  score matching!



- A legtöbb diffúziós modell hasonló loss-t minimalizál, csak a generálás (mintavételezés) módszerében különbözik!

---

### Algorithm 1 Training

---

```
1: repeat  
2:  $\mathbf{x}_0 \sim q(\mathbf{x}_0)$   
3:  $t \sim \text{Uniform}(\{1, \dots, T\})$   
4:  $\epsilon \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$   
5: Take gradient descent step on  
    $\nabla_{\theta} \|\epsilon - \epsilon_{\theta}(\sqrt{\alpha_t}\mathbf{x}_0 + \sqrt{1 - \alpha_t}\epsilon, t)\|^2$   
6: until converged
```

---

---

### Algorithm 2 Sampling

---

```
1:  $\mathbf{x}_T \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$   
2: for  $t = T, \dots, 1$  do  
3:  $\mathbf{z} \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$   
4:  $\mathbf{x}_{t-1} = \frac{1}{\sqrt{\alpha_t}} \left( \mathbf{x}_t - \frac{1 - \alpha_t}{\sqrt{1 - \alpha_t}} \epsilon_{\theta}(\mathbf{x}_t, t) \right) + \sigma_t \mathbf{z}$   
5: end for  
6: return  $\mathbf{x}_0$ 
```

---

# Diffúziós Modellek

## Zaj ütemezési stratégiák

- A zajos kép paraméterezése:

$$x_t = \alpha_t \cdot x_0 + \sigma_t \cdot \epsilon$$

Tiszta kép                  Gaussi zaj  $\sim \mathcal{N}(0, I)$

- Variance-Preserving (VP):**

$$\alpha(t) = \sqrt{1 - \sigma^2(t)}$$

- Variance-Exploding:**

$$\alpha(t) = 1$$

$$\sigma(t) = t \text{ ("EDM")}$$

- Sub-VP** (folyamillesztés):

$$\alpha(t) = t$$

$$\sigma(t) = 1 - t$$


Akár különbözhet tanítás és mintavételezés közben!

Ami valójában számít:  $SNR_t = \frac{\alpha_t^2}{\sigma_t^2}$

**DDPM:**  $\sigma(t) = \sqrt{1 - \prod (1 - \beta_i)}$  – ma már kevésbé használatos

**Cosine scheduling:**  $\sigma(t) = \sin\left(\frac{t/T + s}{s} \cdot \frac{\pi}{2}\right)$  – zajos képekre gyorsabb, tisztábbakra lassabb, gyakran használt!

**DEMO!**



<https://sander.ai/2024/06/14/noise-schedules.html>

# Diffúziós Modellek

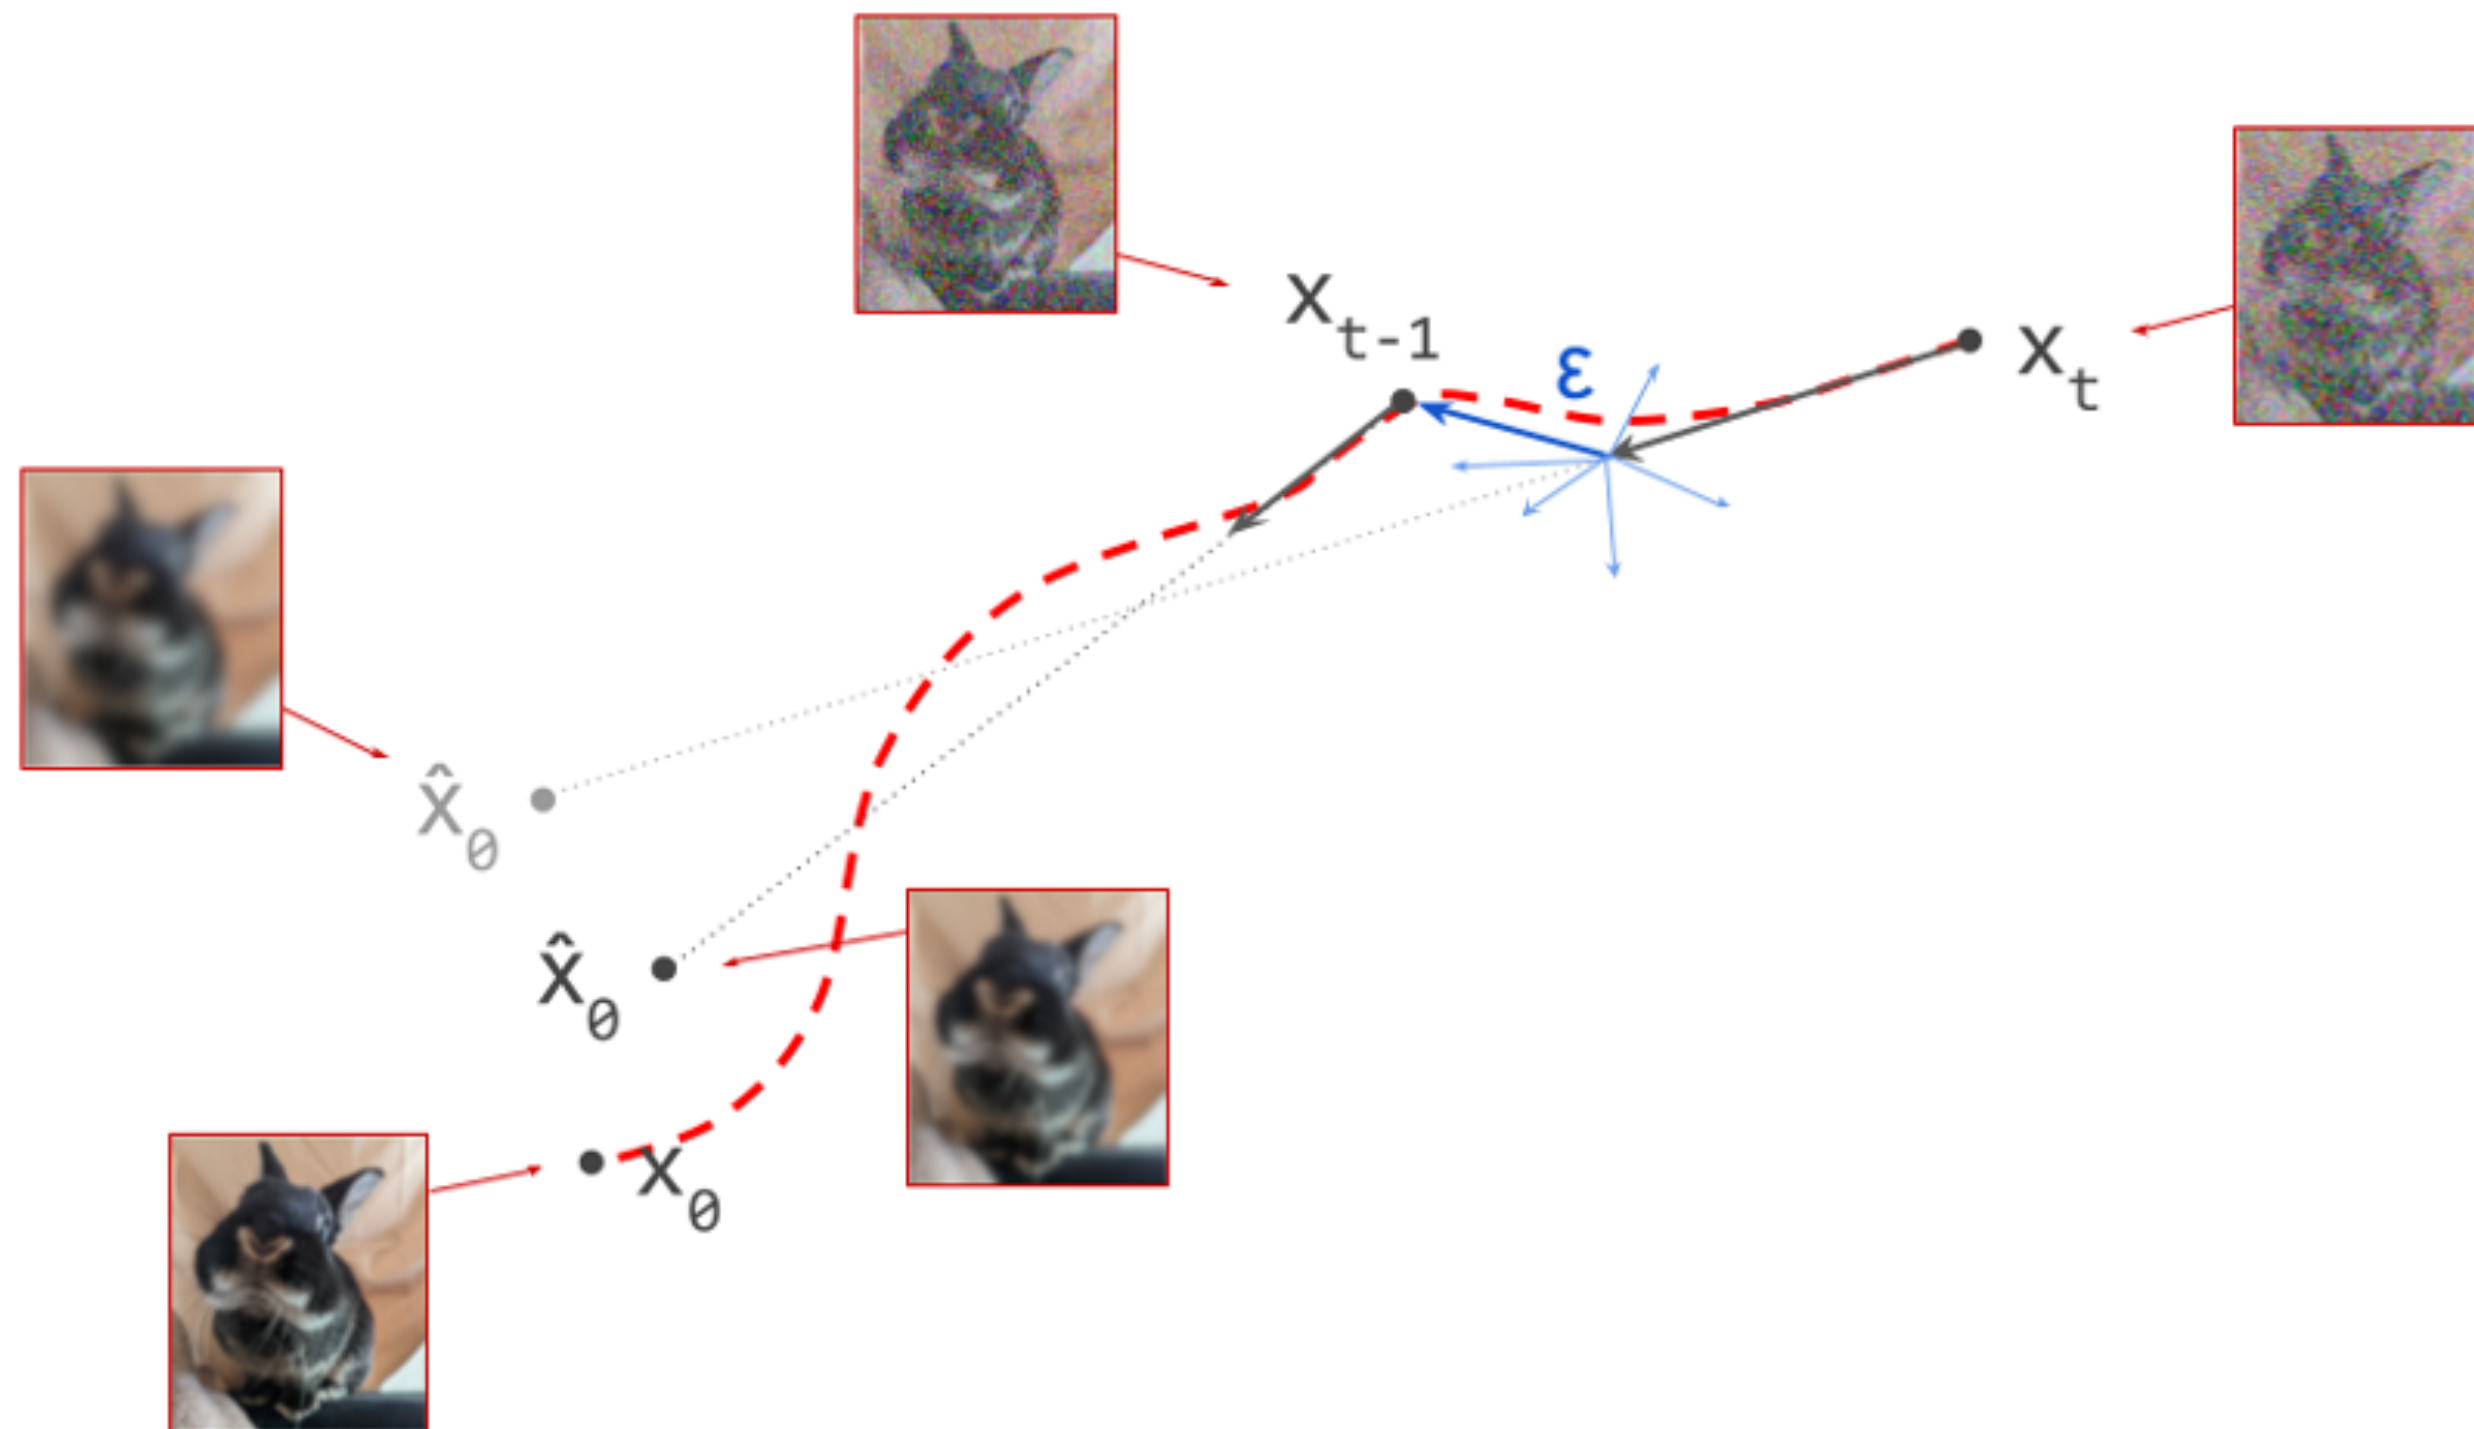
**!FIGYELEM!**



A diffúziós szakirodalom (ezen fóliákat beleértve)  
nem következetes a jelölések tekintetében.  
Legyünk óvatosak!

# Diffúziós Modellek

## A DDPM-en túl?



A DDPM mintavételezés elég lassú (1000+ lépés is szükséges lehet)  
Minden lépéssel a tiszta képre adott jelenlegi becslést “követjük”.  
A sok kicsi lépés folytonos pályát ír le — Be tudjuk futni másként is?

# Diffúziós Modellek

## Denoising Diffusion Implicit Model (DDIM)

- Minden denoizer lépés becslést ad a tiszta képre:

$$x_{0,k} = \frac{x_k - \epsilon_{\theta}(x_k)}{\alpha_k}$$

- **DDIM** mintavételezés – általános lineáris kombináció:

$$x_{k-1} = A \cdot x_{0,k} + B \cdot x_k + C \cdot \epsilon$$

- Lehet  $C = 0$  – **determinisztikus mintavételezés!**
- DDPM-nél sokkal gyorsabb mintavétel: 20-100 lépés a több 1000 helyett!
- A modern ODE és folyam-alapú mintavételezés speciális esete


### DENOISING DIFFUSION IMPLICIT MODELS

Jiaming Song, Chenlin Meng & Stefano Ermon  
Stanford University

$A + B = 1$  (egyenes interpoláció zaj és kép között)

$A^2 \cdot \sigma_k + C^2 = \sigma_{k-1}$  (forward folyamat megőrzése)

$A, B, C$  közül egy szabadon választható!



# Diffúziós Modellek

## Denoising Diffusion Implicit Model (DDIM)

- Minden denoizer lépés becslést ad a tiszta képre:

$$x_{0,k} = \frac{x_k - \epsilon_{\theta}(x_k)}{\alpha_k}$$

- **DDIM** mintavételezés – általános lineáris kombináció:

$$x_{k-1} = A \cdot x_{0,k} + B \cdot x_k + C \cdot \epsilon$$

- Lehet  $C = 0$  – **determinisztikus mintavételezés!**
- DDPM-nél sokkal gyorsabb mintavétel: 20-100 lépés a több 1000 helyett!
- A modern ODE és folyam-alapú mintavételezés speciális esete


### DENOISING DIFFUSION IMPLICIT MODELS

Jiaming Song, Chenlin Meng & Stefano Ermon  
Stanford University

$A + B = 1$  (egyenes interpoláció zaj és kép között)


$A^2 \cdot \sigma_k + C^2 = \sigma_{k-1}$  (forward folyamat megőrzése)

$A, B, C$  közül egy szabadon választható!



# Diffúziós Modellek

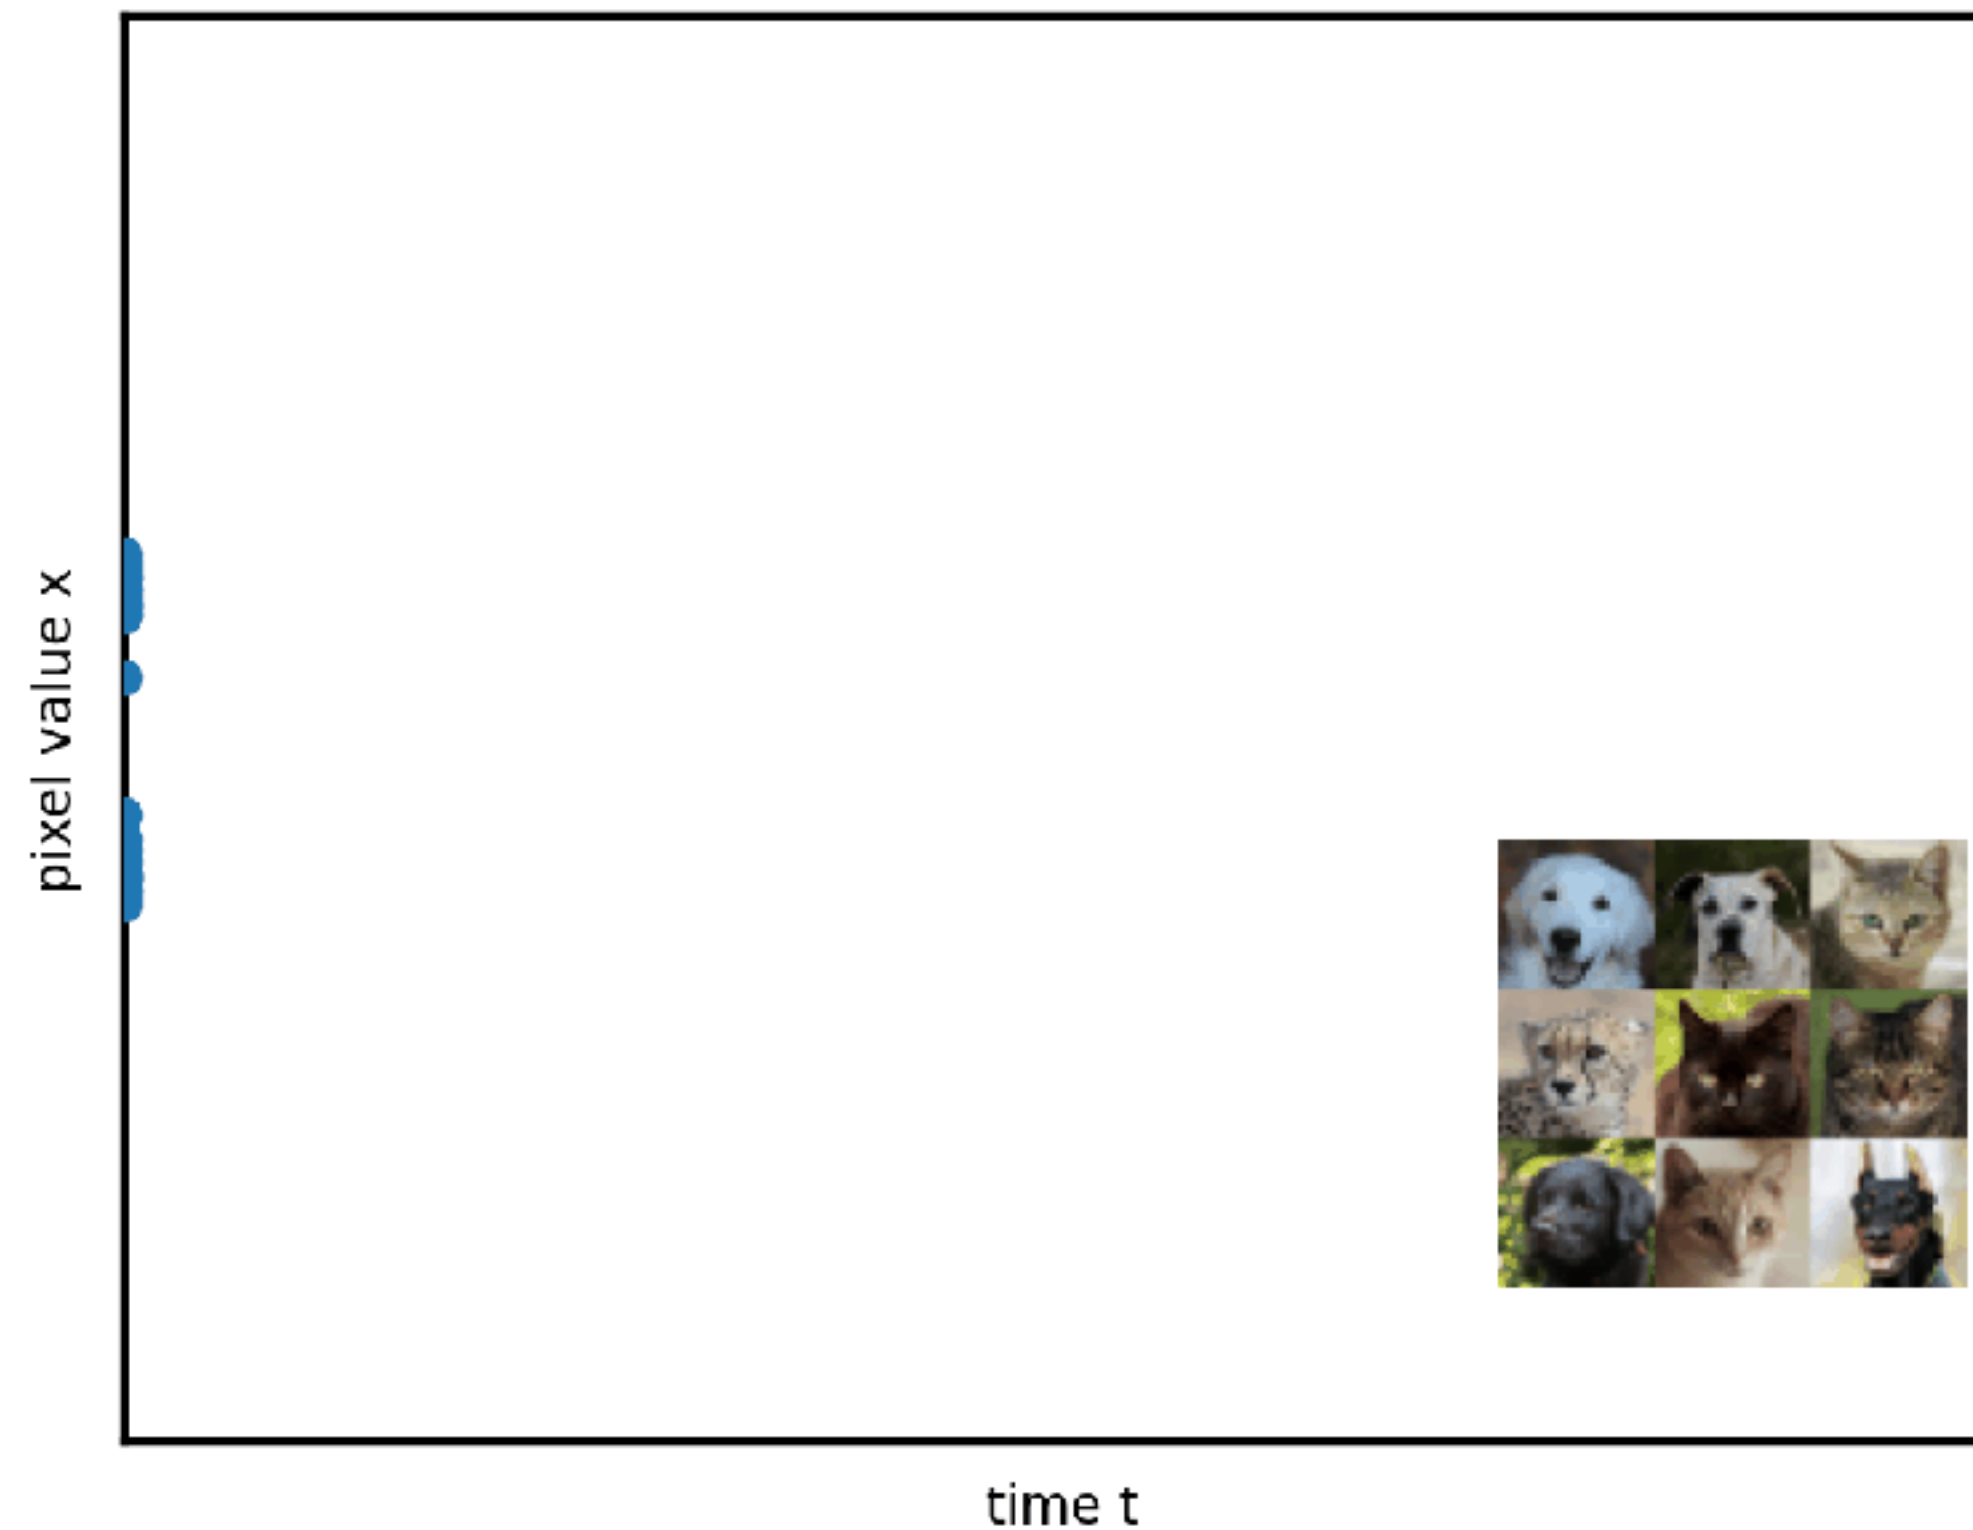
A folyam-alapú modellek felé...



Új nézőpont: egy diffúziós modell folytonos átmenetet képez eloszlások között

# Diffúziós Modellek

A folyam-alapú modellek felé...



Új nézőpont: egy diffúziós modell folytonos átmenetet képez eloszlások között


# Diffúziós Modellek

## SDE értelmezés

- Végtelen finom zajskálákra a forward folyamat megfelel egy sztochasztikus differenciálegyenletnek (SDE):

$$dx = \sigma(t)dW_t$$

$\sigma(t)$ : zaj ütemezés




# Diffúziós Modellek

## SDE értelmezés

- Végtelen finom zajskálákra a forward folyamat megfelel egy sztochasztikus differenciálegyenletnek (SDE):

$$dx = \sigma(t)dW_t$$

$\sigma(t)$ : zaj ütemezés



# Diffúziós Modellek

## SDE értelmezés

### SCORE-BASED GENERATIVE MODELING THROUGH STOCHASTIC DIFFERENTIAL EQUATIONS

Yang Song\*  
Stanford University  
yangsong@cs.stanford.edu

Jascha Sohl-Dickstein  
Google Brain  
jaschasd@google.com

Diederik P. Kingma  
Google Brain  
durk@google.com

Abhishek Kumar  
Google Brain  
abhishk@google.com


Stefano Ermon  
Stanford University  
ermon@cs.stanford.edu

Ben Poole  
Google Brain  
pooleb@google.com

- A reverse folyamat is megfelel egy SDE-nek:

$$dx = -\sigma(t)\dot{\sigma}(t) \nabla \log p_{\sigma(t)}(x) dt + \sigma(t)dW_t$$

Score-függvény!



# Diffúziós Modellek

## SDE értelmezés

### SCORE-BASED GENERATIVE MODELING THROUGH STOCHASTIC DIFFERENTIAL EQUATIONS

Yang Song\*  
Stanford University  
yangsong@cs.stanford.edu

Jascha Sohl-Dickstein  
Google Brain  
jaschasd@google.com

Diederik P. Kingma  
Google Brain  
durk@google.com

Abhishek Kumar  
Google Brain  
abhishk@google.com


Stefano Ermon  
Stanford University  
ermon@cs.stanford.edu

Ben Poole  
Google Brain  
pooleb@google.com

- A reverse folyamat is megfelel egy SDE-nek:

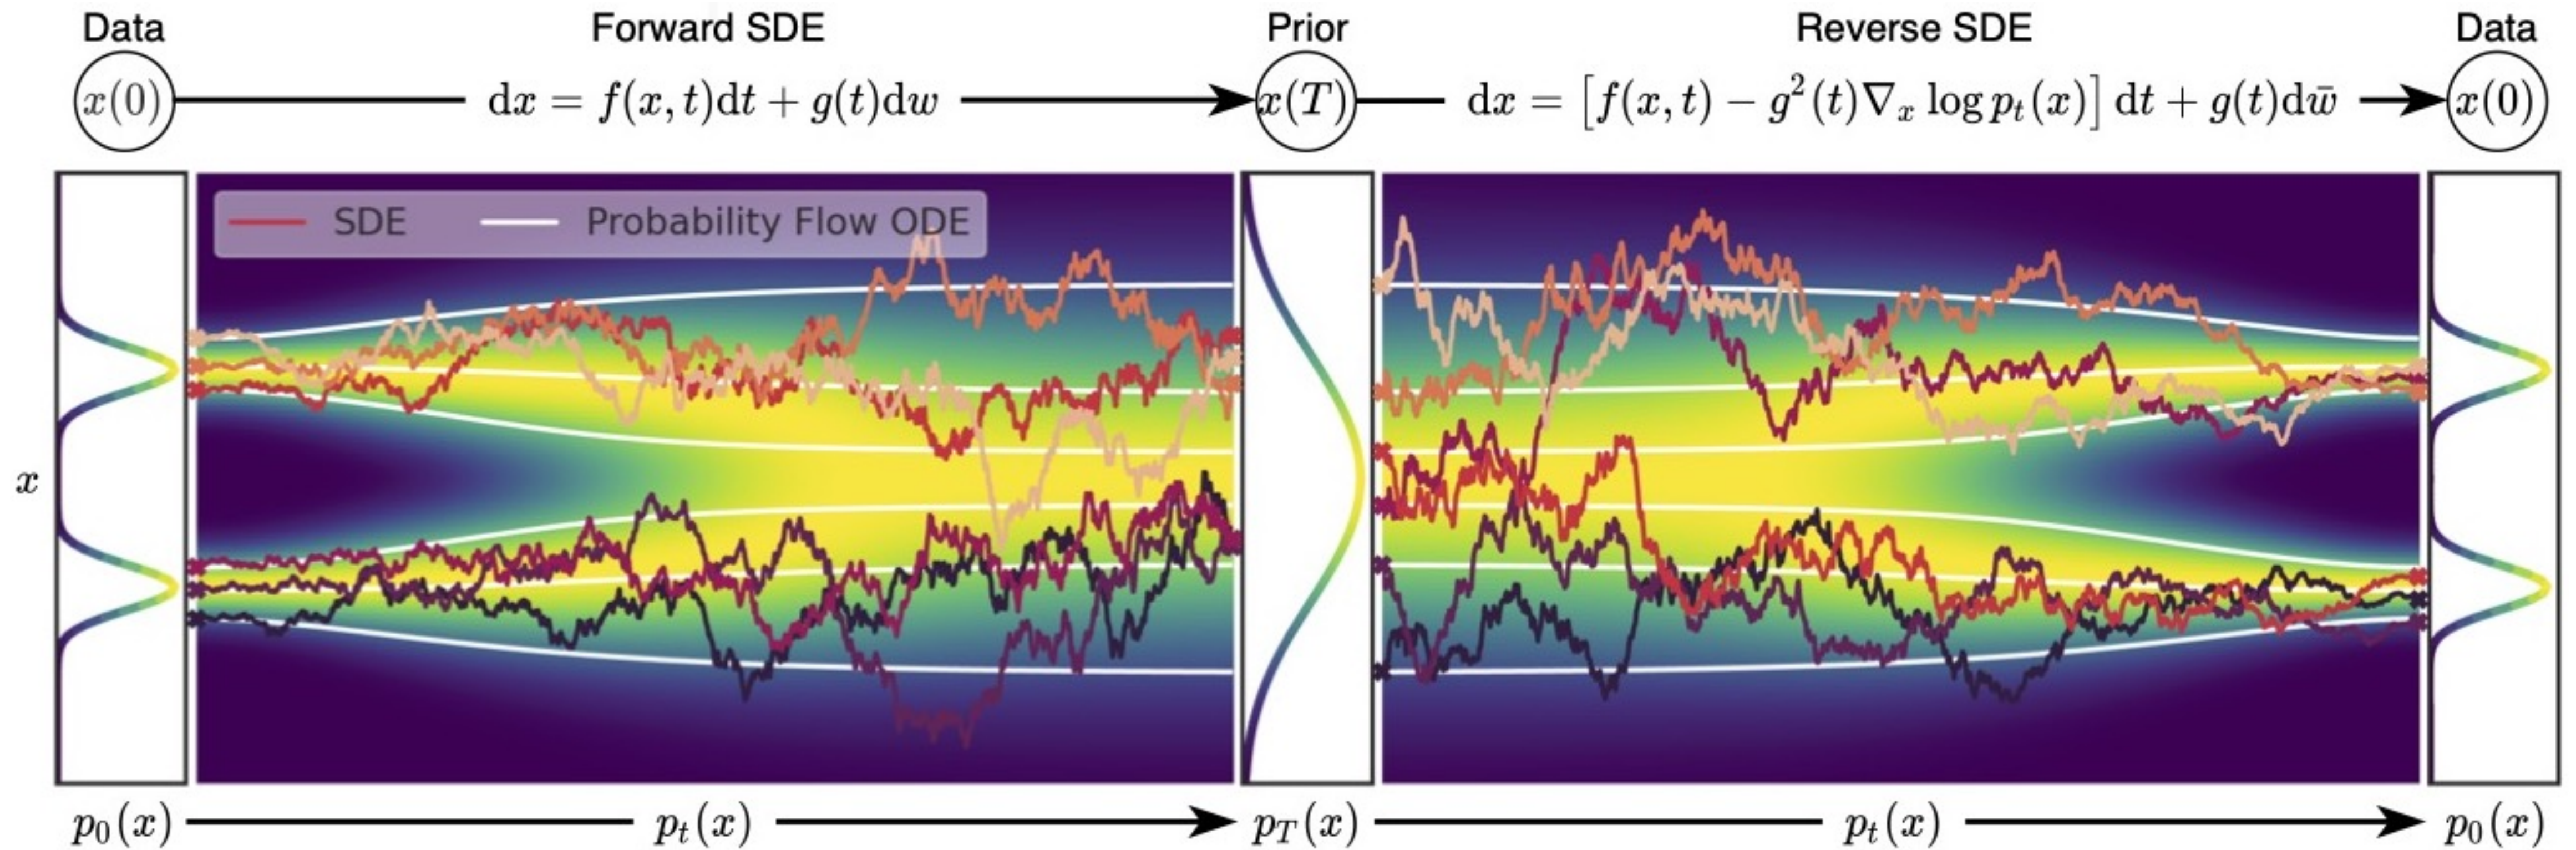
$$dx = -\sigma(t)\dot{\sigma}(t) \nabla \log p_{\sigma(t)}(x) dt + \sigma(t)dW_t$$

Score-függvény!



# Diffúziós Modellek

## SDE értelmezés



# Diffúziós Modellek

## ODE értelmezés

- Vehetjük az SDE-nek megfelelő (Neural) **ODE**-t:

$$\frac{dx}{dt} = -\sigma(t)\dot{\sigma}(t) \nabla \log p_{\sigma(t)}(x)$$

- Numerikus integrálás — **determinisztikus generálás!**

- Sok lehetséges ODE solver /  $\sigma(t)$  kombináció:

	VP [49]	VE [49]	iDDPM [37] + DDIM [47]	Ours (“EDM”)
<b>Sampling (Section 3)</b>				
ODE solver	Euler	Euler	Euler	2 <sup>nd</sup> order Heun
Time steps	$t_i < N$ $1 + \frac{i}{N-1}(\epsilon_s - 1)$	$\sigma_{\max}^2 (\sigma_{\min}^2 / \sigma_{\max}^2)^{\frac{i}{N-1}}$	$u_{\lfloor j_0 + \frac{M-1-j_0}{N-1} i + \frac{1}{2} \rfloor}$ , where $u_M = 0$ $u_{j-1} = \sqrt{\frac{u_j^2 + 1}{\max(\bar{\alpha}_{j-1}/\bar{\alpha}_j, C_1)}} - 1$	$(\sigma_{\max}^{\frac{1}{\rho}} + \frac{i}{N-1}(\sigma_{\min}^{\frac{1}{\rho}} - \sigma_{\max}^{\frac{1}{\rho}}))^{\rho}$
Schedule	$\sigma(t)$	$\sqrt{t}$	$t$	$t$
Scaling	$s(t)$	1	1	1



### Elucidating the Design Space of Diffusion-Based Generative Models

Tero Karras  
NVIDIA

Miika Aittala  
NVIDIA

Timo Aila  
NVIDIA

Samuli Laine  
NVIDIA



# Diffúziós Modellek

## ODE értelmezés

- Vehetjük az SDE-nek megfelelő (Neural) **ODE**-t:

$$\frac{dx}{dt} = -\sigma(t)\dot{\sigma}(t) \nabla \log p_{\sigma(t)}(x)$$

- Numerikus integrálás — **determinisztikus generálás!**

- Sok lehetséges ODE solver /  $\sigma(t)$  kombináció:

	VP [49]	VE [49]	iDDPM [37] + DDIM [47]	Ours (“EDM”)
<b>Sampling (Section 3)</b>				
ODE solver	Euler	Euler	Euler	2 <sup>nd</sup> order Heun
Time steps	$t_i < N$ $1 + \frac{i}{N-1}(\epsilon_s - 1)$	$\sigma_{\max}^2 (\sigma_{\min}^2 / \sigma_{\max}^2)^{\frac{i}{N-1}}$	$u_{\lfloor j_0 + \frac{M-1-j_0}{N-1} i + \frac{1}{2} \rfloor}$ , where $u_M = 0$ $u_{j-1} = \sqrt{\frac{u_j^2 + 1}{\max(\bar{\alpha}_{j-1}/\bar{\alpha}_j, C_1)}} - 1$	$(\sigma_{\max}^{\frac{1}{\rho}} + \frac{i}{N-1}(\sigma_{\min}^{\frac{1}{\rho}} - \sigma_{\max}^{\frac{1}{\rho}}))^{\rho}$
Schedule	$\sigma(t)$	$\sqrt{t}$	$t$	$t$
Scaling	$s(t)$	1	1	1



### Elucidating the Design Space of Diffusion-Based Generative Models

Tero Karras  
NVIDIA

Miika Aittala  
NVIDIA

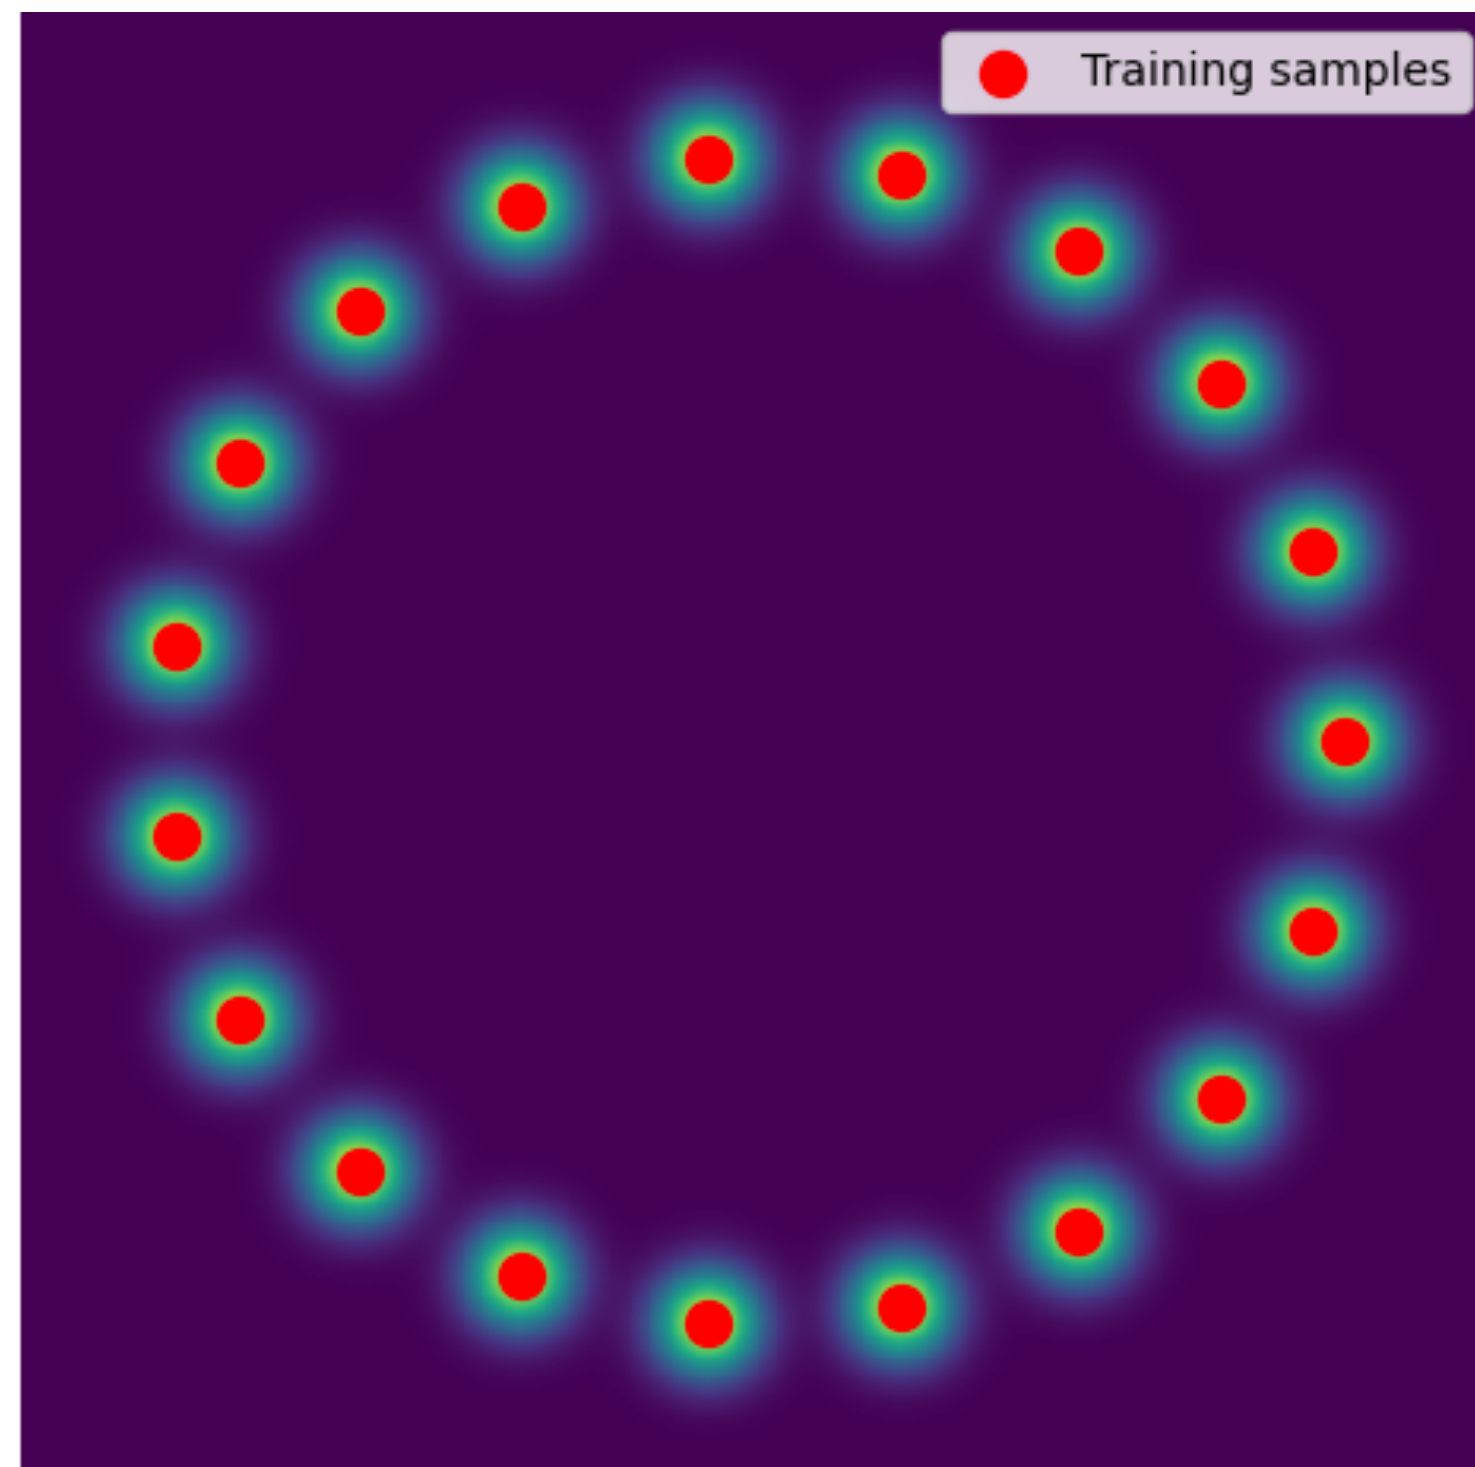
Timo Aila  
NVIDIA

Samuli Laine  
NVIDIA




# Diffúziós Modellek

## Általánosító képesség



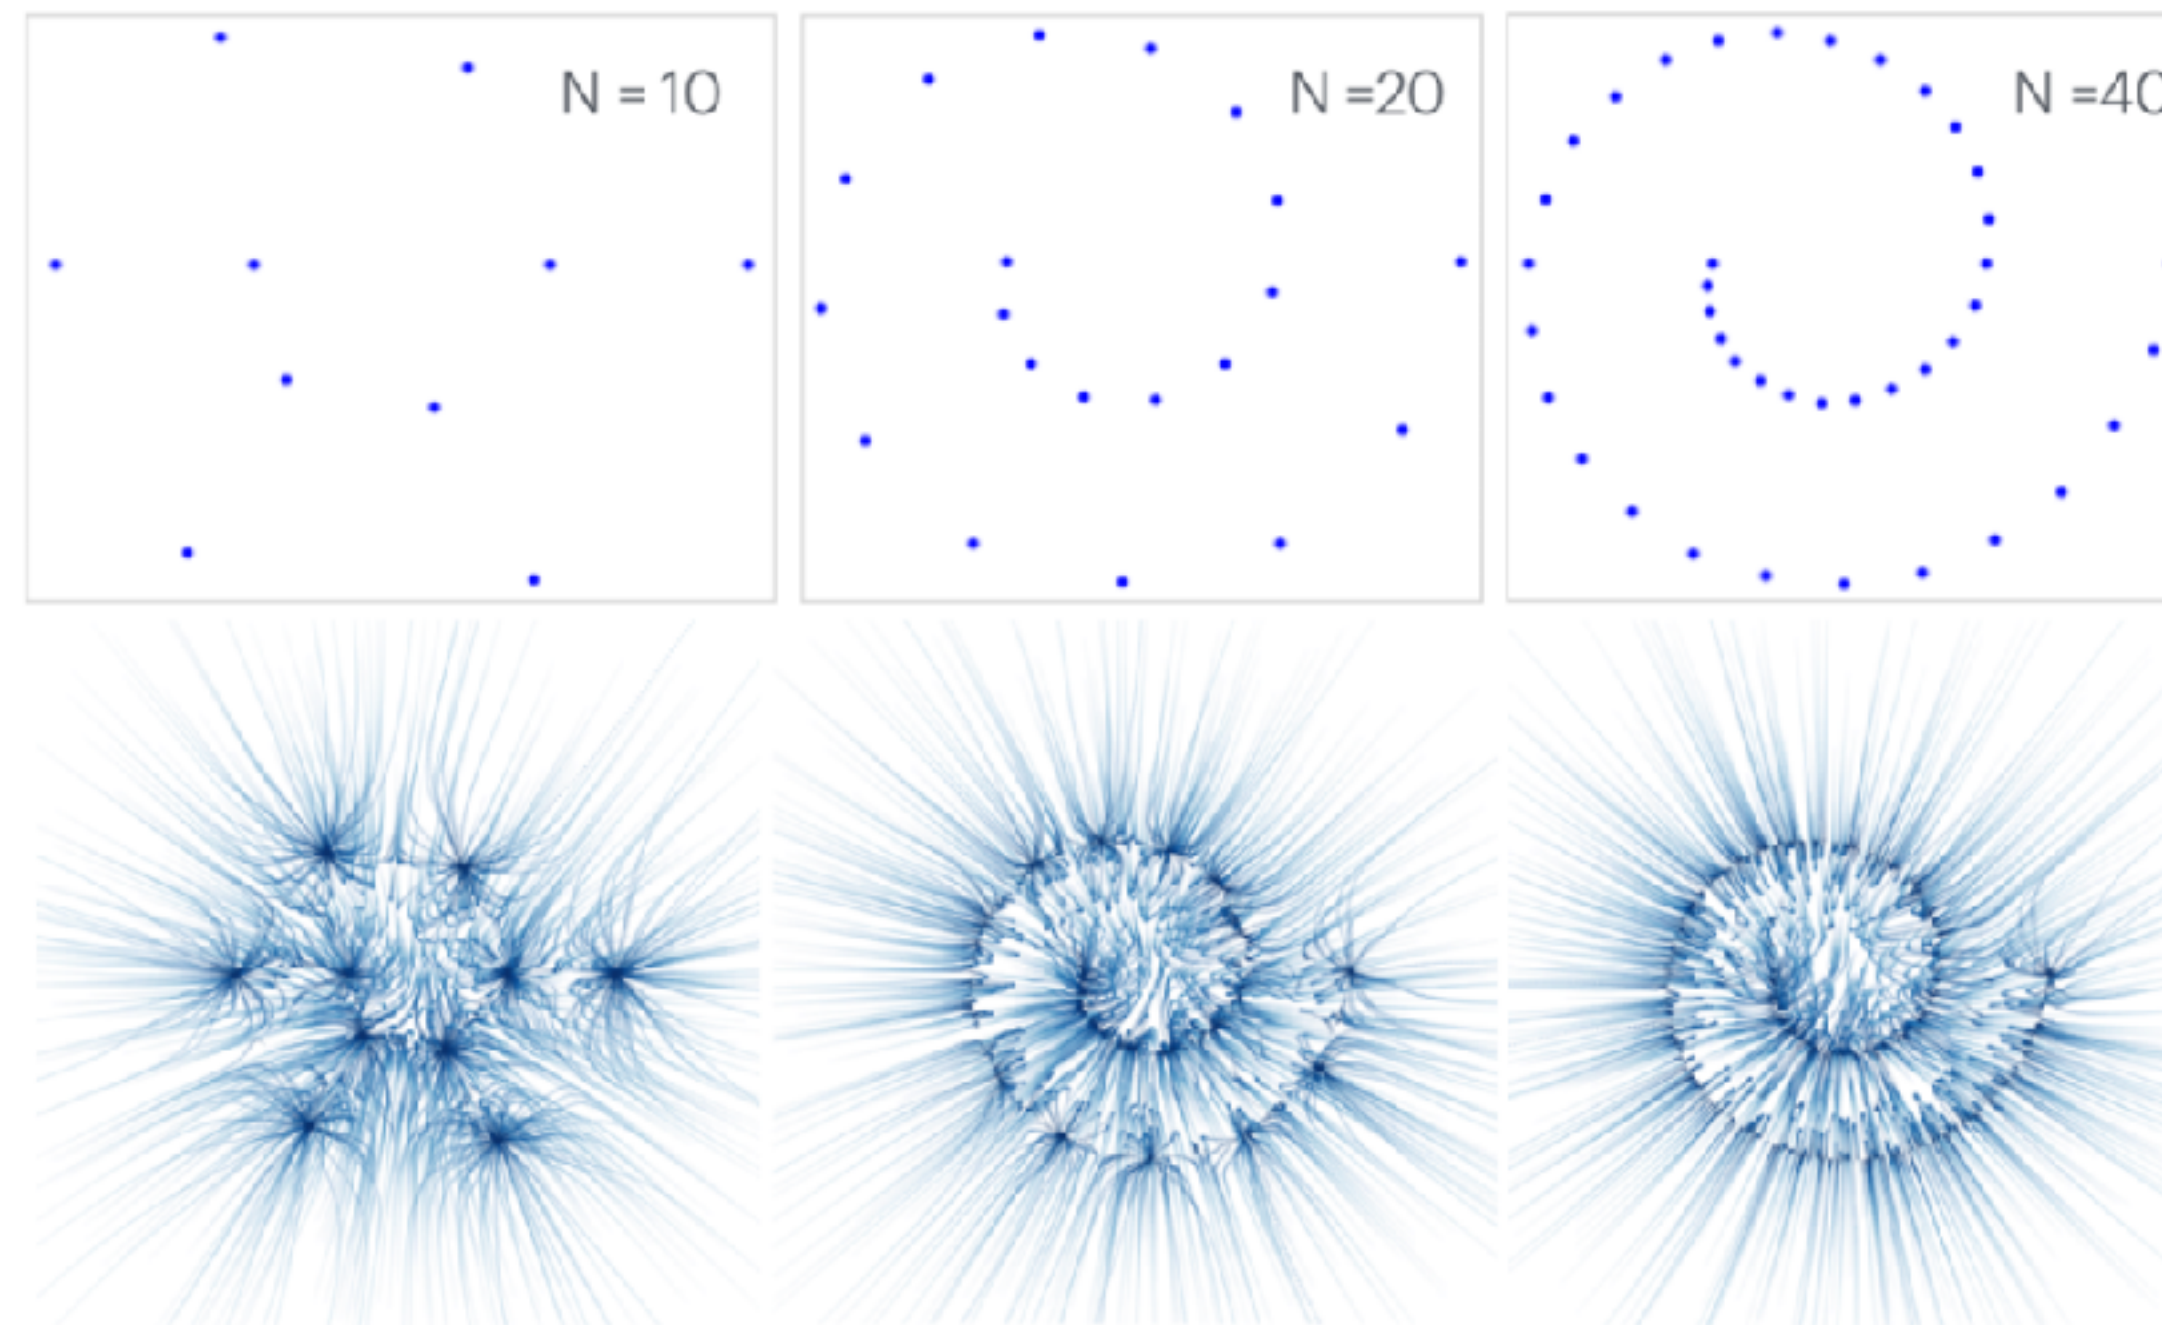
Rossz általánosító képesség (memorizálás)



Jó általánosító képesség

# Diffúziós Modellek


## Általánosító képesség




Kevés adatra a determinisztikus mintavétel memorizálja az adathalmazt!  
Több adatpontra javul az általánosító képesség...

# Diffúziós Modellek

## Általánosító képesség



Ideális denoizer



Közelítő (neurális) denoizer

Az általánosítás kulcsa(?): a tökéletlen közelítés elsimítja az adateloszlást!


# Diffúziós Modellek

## Geometriai értelmezés


Interpreting and Improving Diffusion Models from an Optimization Perspective

Frank Permenter<sup>\*1</sup> Chenyang Yuan<sup>\*1</sup>

<https://www.chenyang.co/diffusion.html>




Score függvény  $\approx$  simított távolság(négyzet)  
az adatsokaságtól




Diffúziós generálás (pl. DDIM)  $\approx$   
gradient descent a simított távolságfüggvényre

# Folyamillesztés





**Diffúzió (SDE)**



**Folyam (ODE)**



# Folyamillesztés



<https://alechelbling.com/Diffusion-Explorer/>

A diffúziós modellek valójában egy ODE/folyam, azaz egy *vektormező* alapján generálnak  
Ötlet: definiáljuk a feladatot egy vektormező illesztéseként!

# Folyamillesztés



<https://alechelbling.com/Diffusion-Explorer/>

A diffúziós modellek valójában egy ODE/folyam, azaz egy *vektormező* alapján generálnak  
Ötlet: definiáljuk a feladatot egy vektormező illesztéseként!

# Folyamillesztés

## Valószínűségi folyam

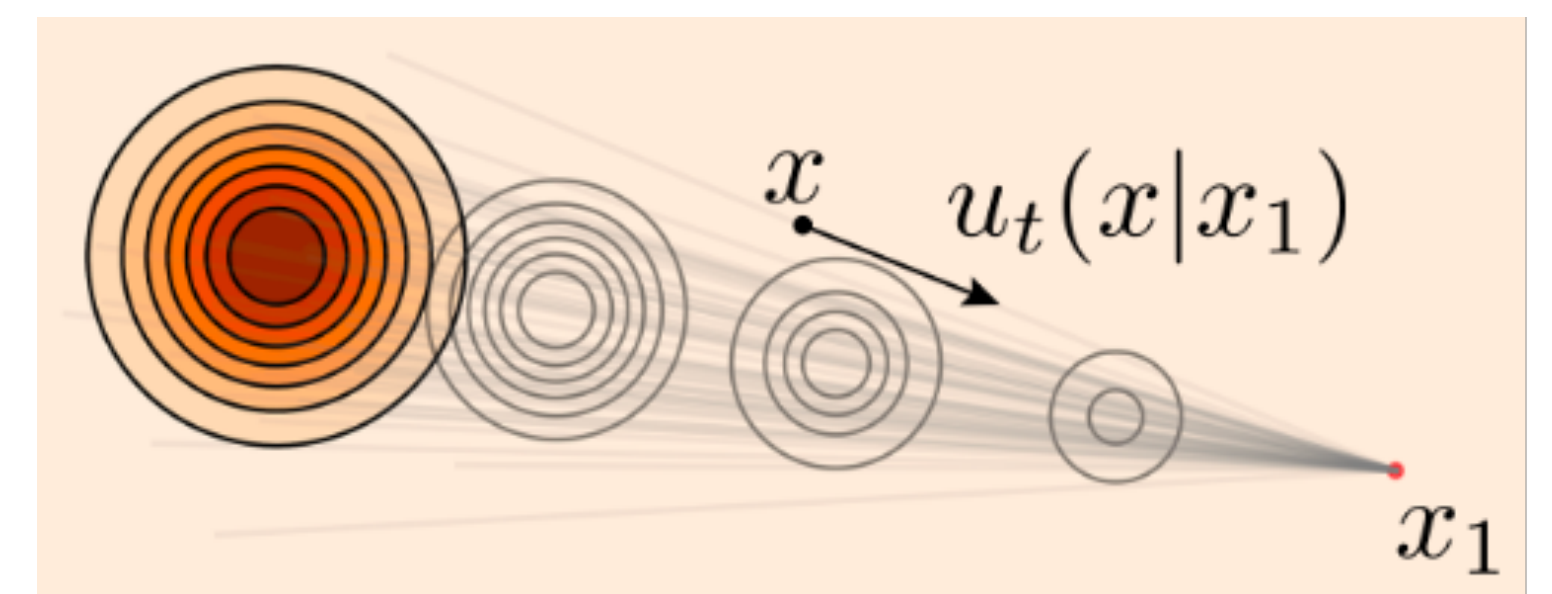

- Cél: interpolálni a  $p_0$  Gaussi eloszlás (zaj) és a  $p_1$  adat eloszlás között —  $p_t$  eloszlás-család ( $0 \leq t \leq 1$ )

- Adott  $x_0 \sim p_0$ ,  $x_1 \sim p_1$  mintákra:

$$(1 - t)x_0 + tx_1 \sim p_t$$

- Tegyük fel, hogy egyetlen  $x_1$  adatpontunk van — haladjon minden  $x_t$  pont egyenletes sebességgel  $x_1$  irányába (**feltételes vektormező**):

$$v(x_t | x_1) = \frac{dx_t}{dt} = x_1 - x_0$$



# Folyamillesztés

## Marginális és feltételes folyamillesztés

- Komplexebb  $p_1$  adateloszlásra a marginális folyamat kapjuk:

$$v(x_t) = \int v(x_t | x) \cdot p_1(x) dx$$


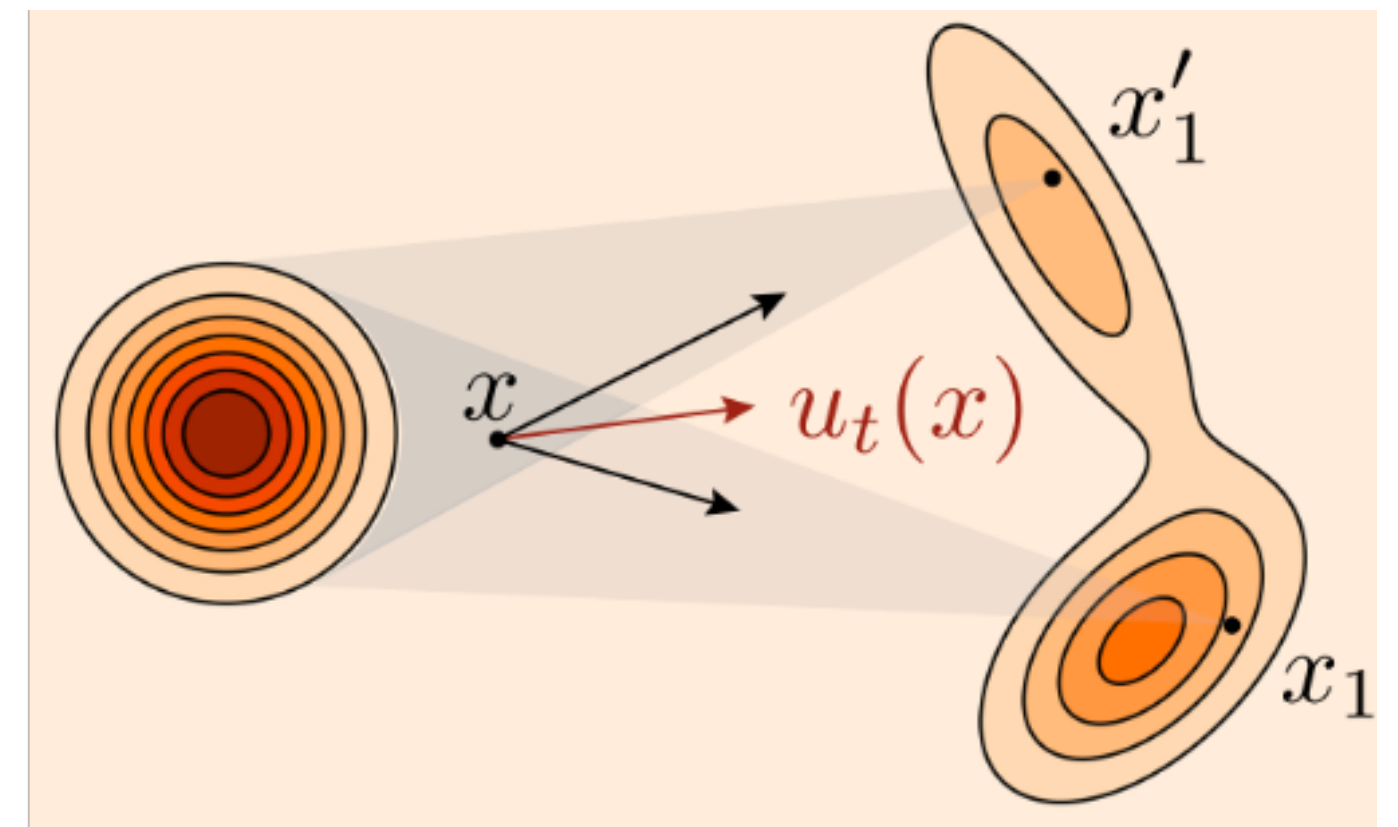
- Közelítése neurális hálóval – folyamillesztés (flow matching):

$$L_{FM}(\theta) = \mathbb{E}_{x_0 \sim p_0, x_1 \sim p_1, t \sim U(0,1)} [ \| v_\theta(x_t, t) - v(x_t) \|^2 ] \quad \text{☠}$$

- A marginális folyam helyettesíthető a feltételes folyammal!

$$\begin{aligned} L_{CFM}(\theta) &= \mathbb{E}_{x_0 \sim p_0, x_1 \sim p_1, t \sim U(0,1)} [ \| v_\theta(x_t, t) - v(x_t | x_1) \|^2 ] \\ &= \mathbb{E}_{x_0 \sim p_0, x_1 \sim p_1, t \sim U(0,1)} [ \| v_\theta((1-t)x_0 + tx_1, t) - (x_1 - x_0) \|^2 ] \end{aligned}$$

- A két loss lényegében ekvivalens:  $L_{CFM} = L_{FM} + \text{const}$ .




# Folyamillesztés

## Tanítás

- Folyamillesztés (flow matching) előnyei:
  - Nagyon egyszerű tanítás (regresszió)!
  - Determinisztikus generálás (ODE)!
  - Rugalmasság! (Tetszőleges összerendelés, cél/forrás eloszlás, interpoláció, stb.)

```
for _ in range(10000):  
    x_1 = Tensor(make_moons(256, noise=0.05)[0])  
    x_0 = torch.randn_like(x_1)  
    t = torch.rand(len(x_1), 1)  
    x_t = (1 - t) * x_0 + t * x_1  
    dx_t = x_1 - x_0  
    optimizer.zero_grad()  
    loss_fn(flow(x_t, t), dx_t).backward()  
    optimizer.step()
```

*Igazi Pytorch, nem pseudokód!*

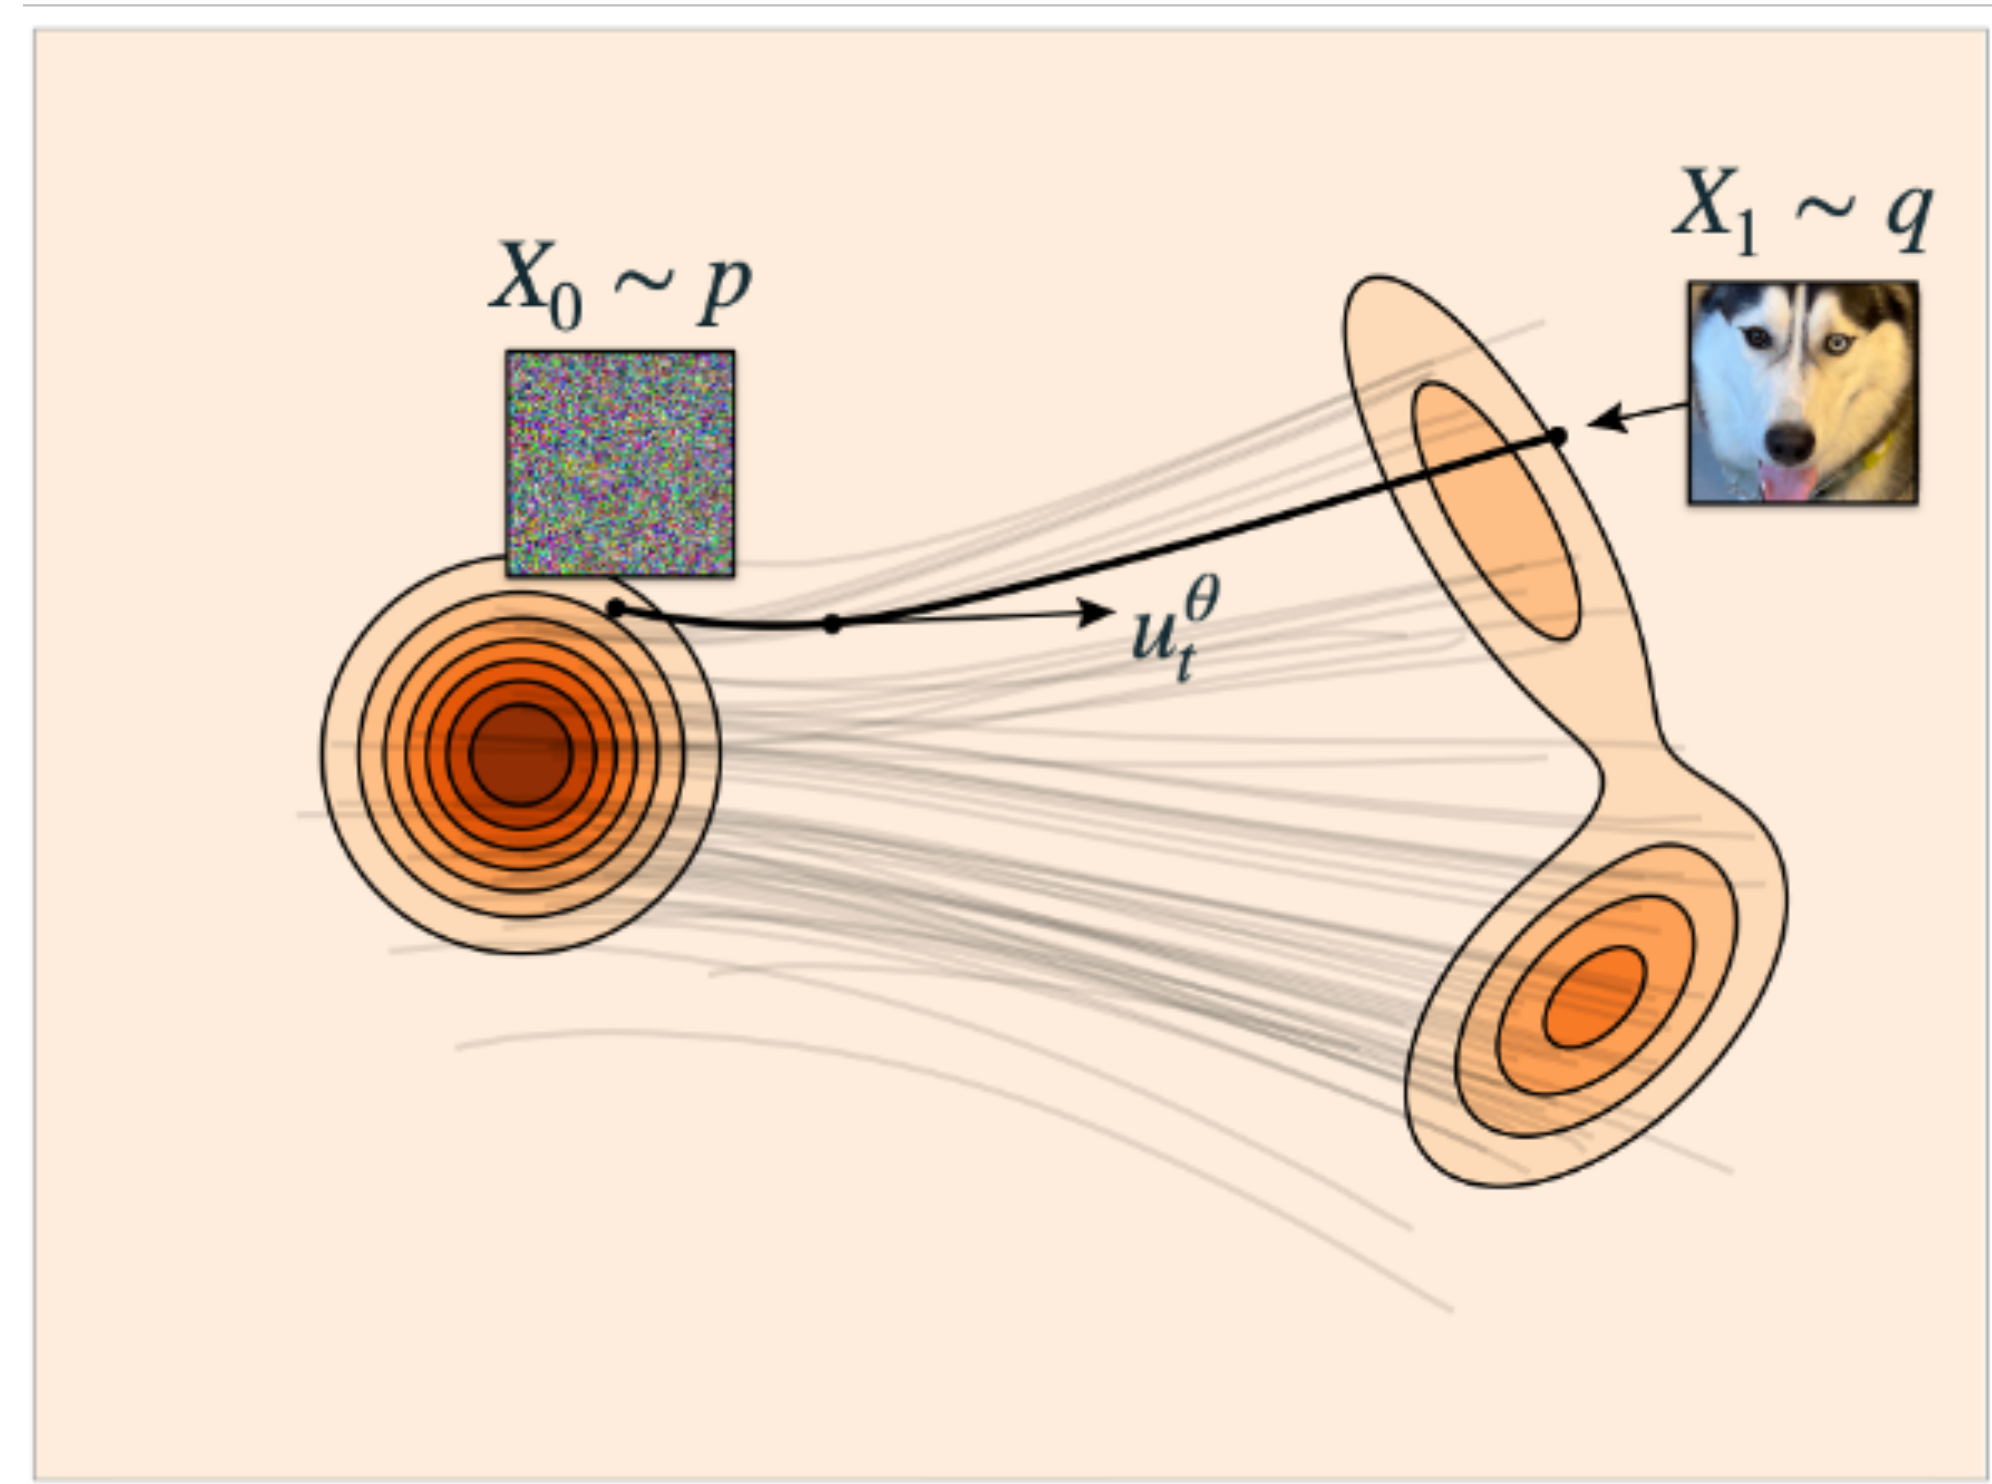


$$\mathbb{E}_{t, X_0, X_1} \left\| u_t^\theta(X_t) - (X_1 - X_0) \right\|^2$$

# Folyamillesztés

## Generálás

- Folyamillesztés (flow matching) előnyei:
  - Nagyon egyszerű tanítás (regresszió)!
  - **Determinisztikus generálás (ODE)!**
  - Rugalmasság!  
(Tetszőleges összerendelés, cél/forrás eloszlás, interpoláció, stb.)



**Bármilyen ODE solver (integrátor) használható!**

# Folyamillesztés


## Rugalmasság

- Folyamillesztés (flow matching) előnyei:

- Nagyon egyszerű tanítás (regresszió)!

- Determinisztikus generálás (ODE)!

- **Rugalmasság!**  
(Tetszőleges összerendelés, cél/forrás eloszlás, interpoláció, stb. )



Bridging arbitrary distributions - Example

Videos without audio → videos with audio

Low resolution images → high resolution images

Unperturbed cells → perturbed cells

etc.




Figure credit: Michael Albergo

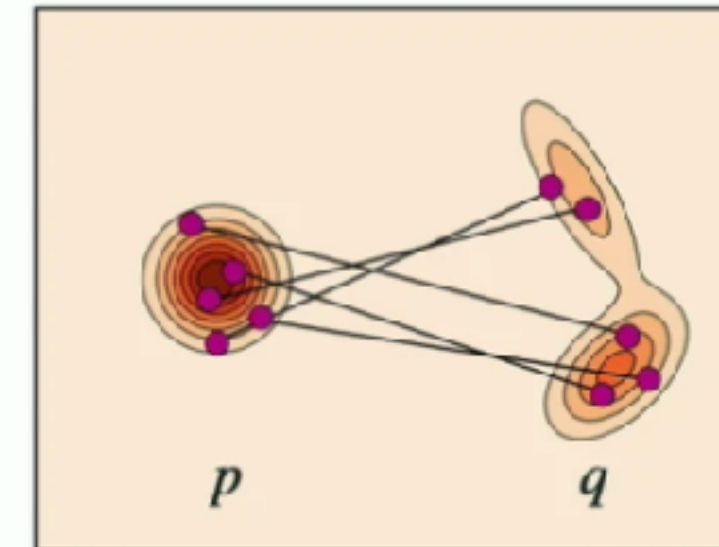
**Tetszőleges eloszlások között interpolálhatunk!**

# Folyamillesztés

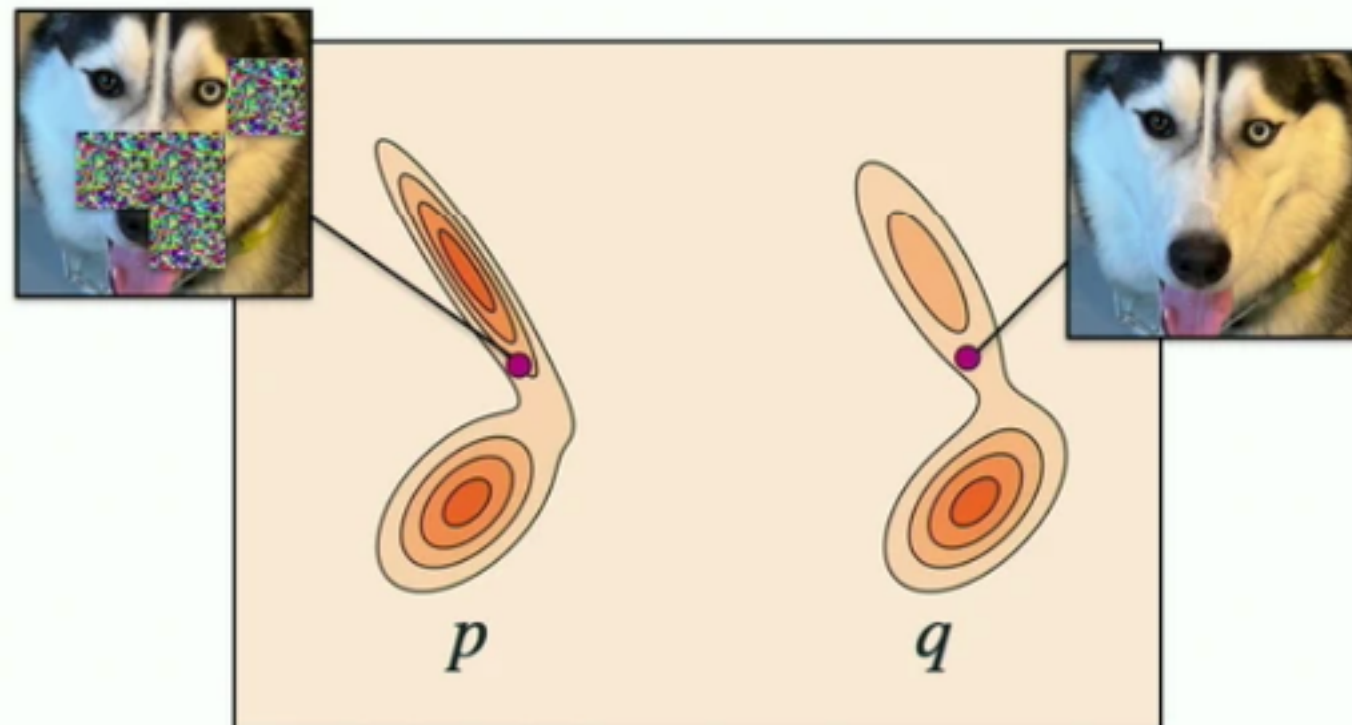
## Adatok összerendelése

$$\mathcal{L}_{\text{CFM}}(\theta) = \mathbb{E}_{t, X_0, X_1} \|u_t(X_t | X_1) - u_t^\theta(X_t)\|^2$$

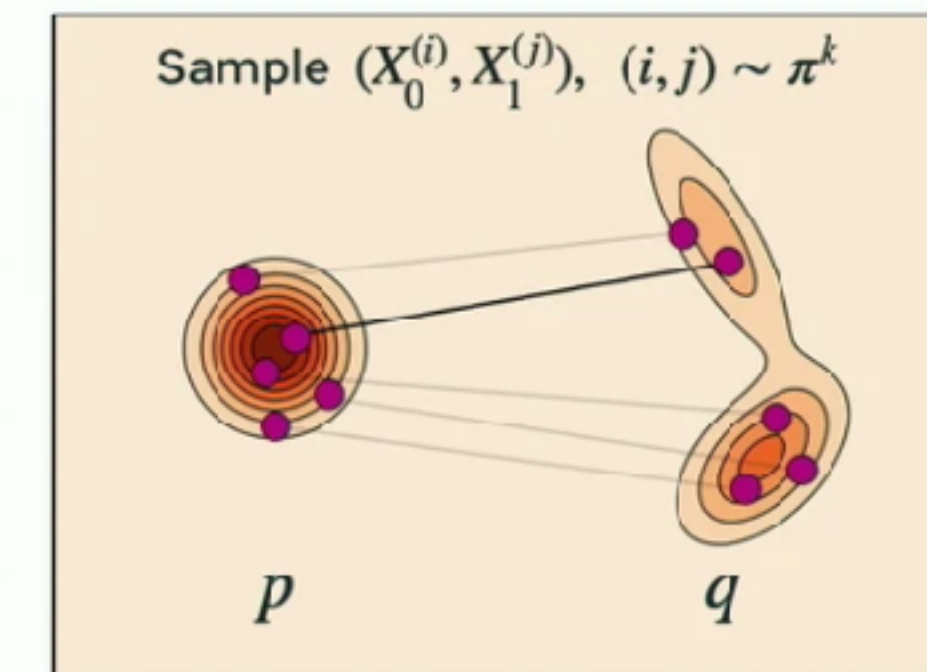
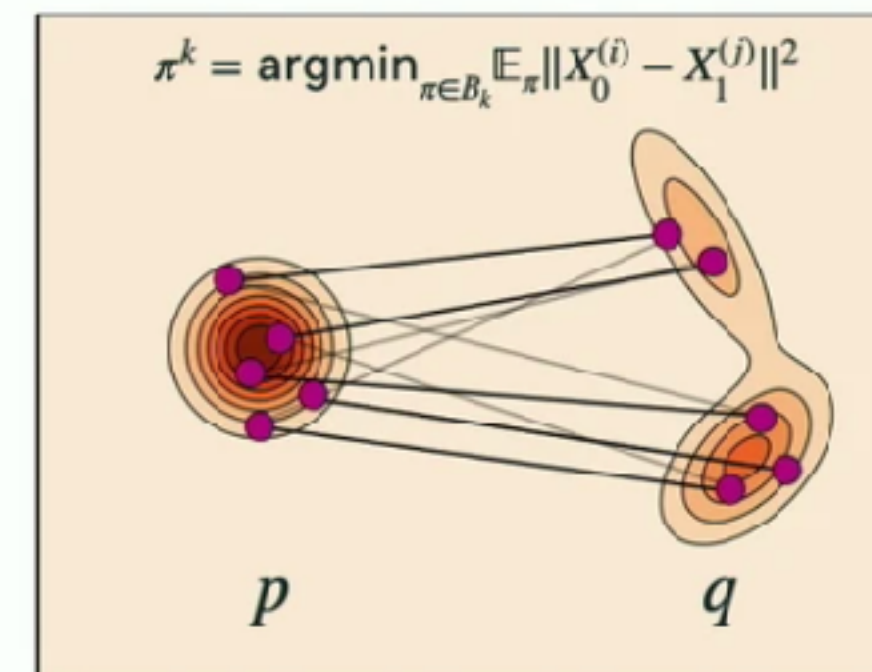
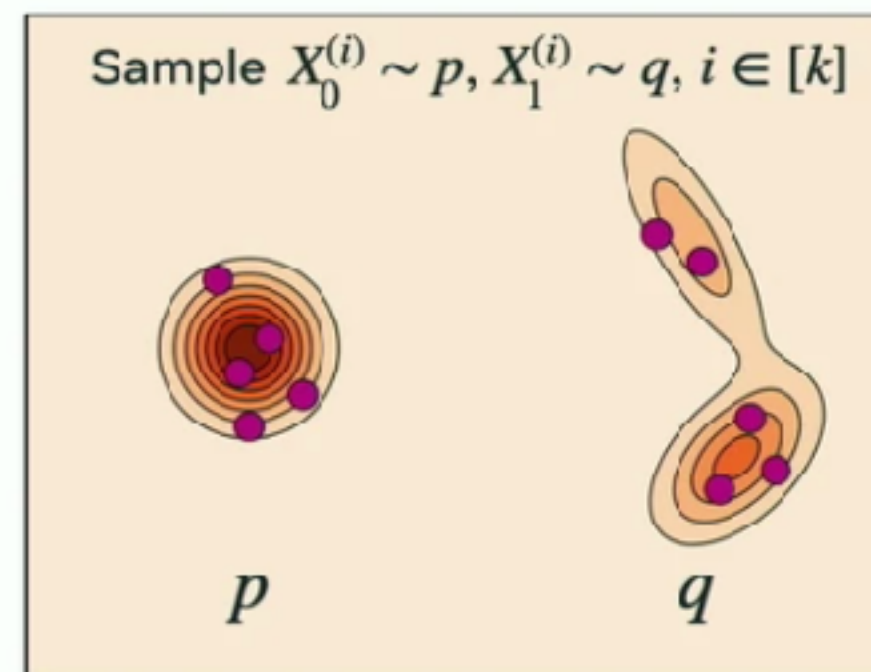
$$(X_0, X_1) \sim \pi_{0,1} = p(X_0)q(X_1)$$



Független összerendelés



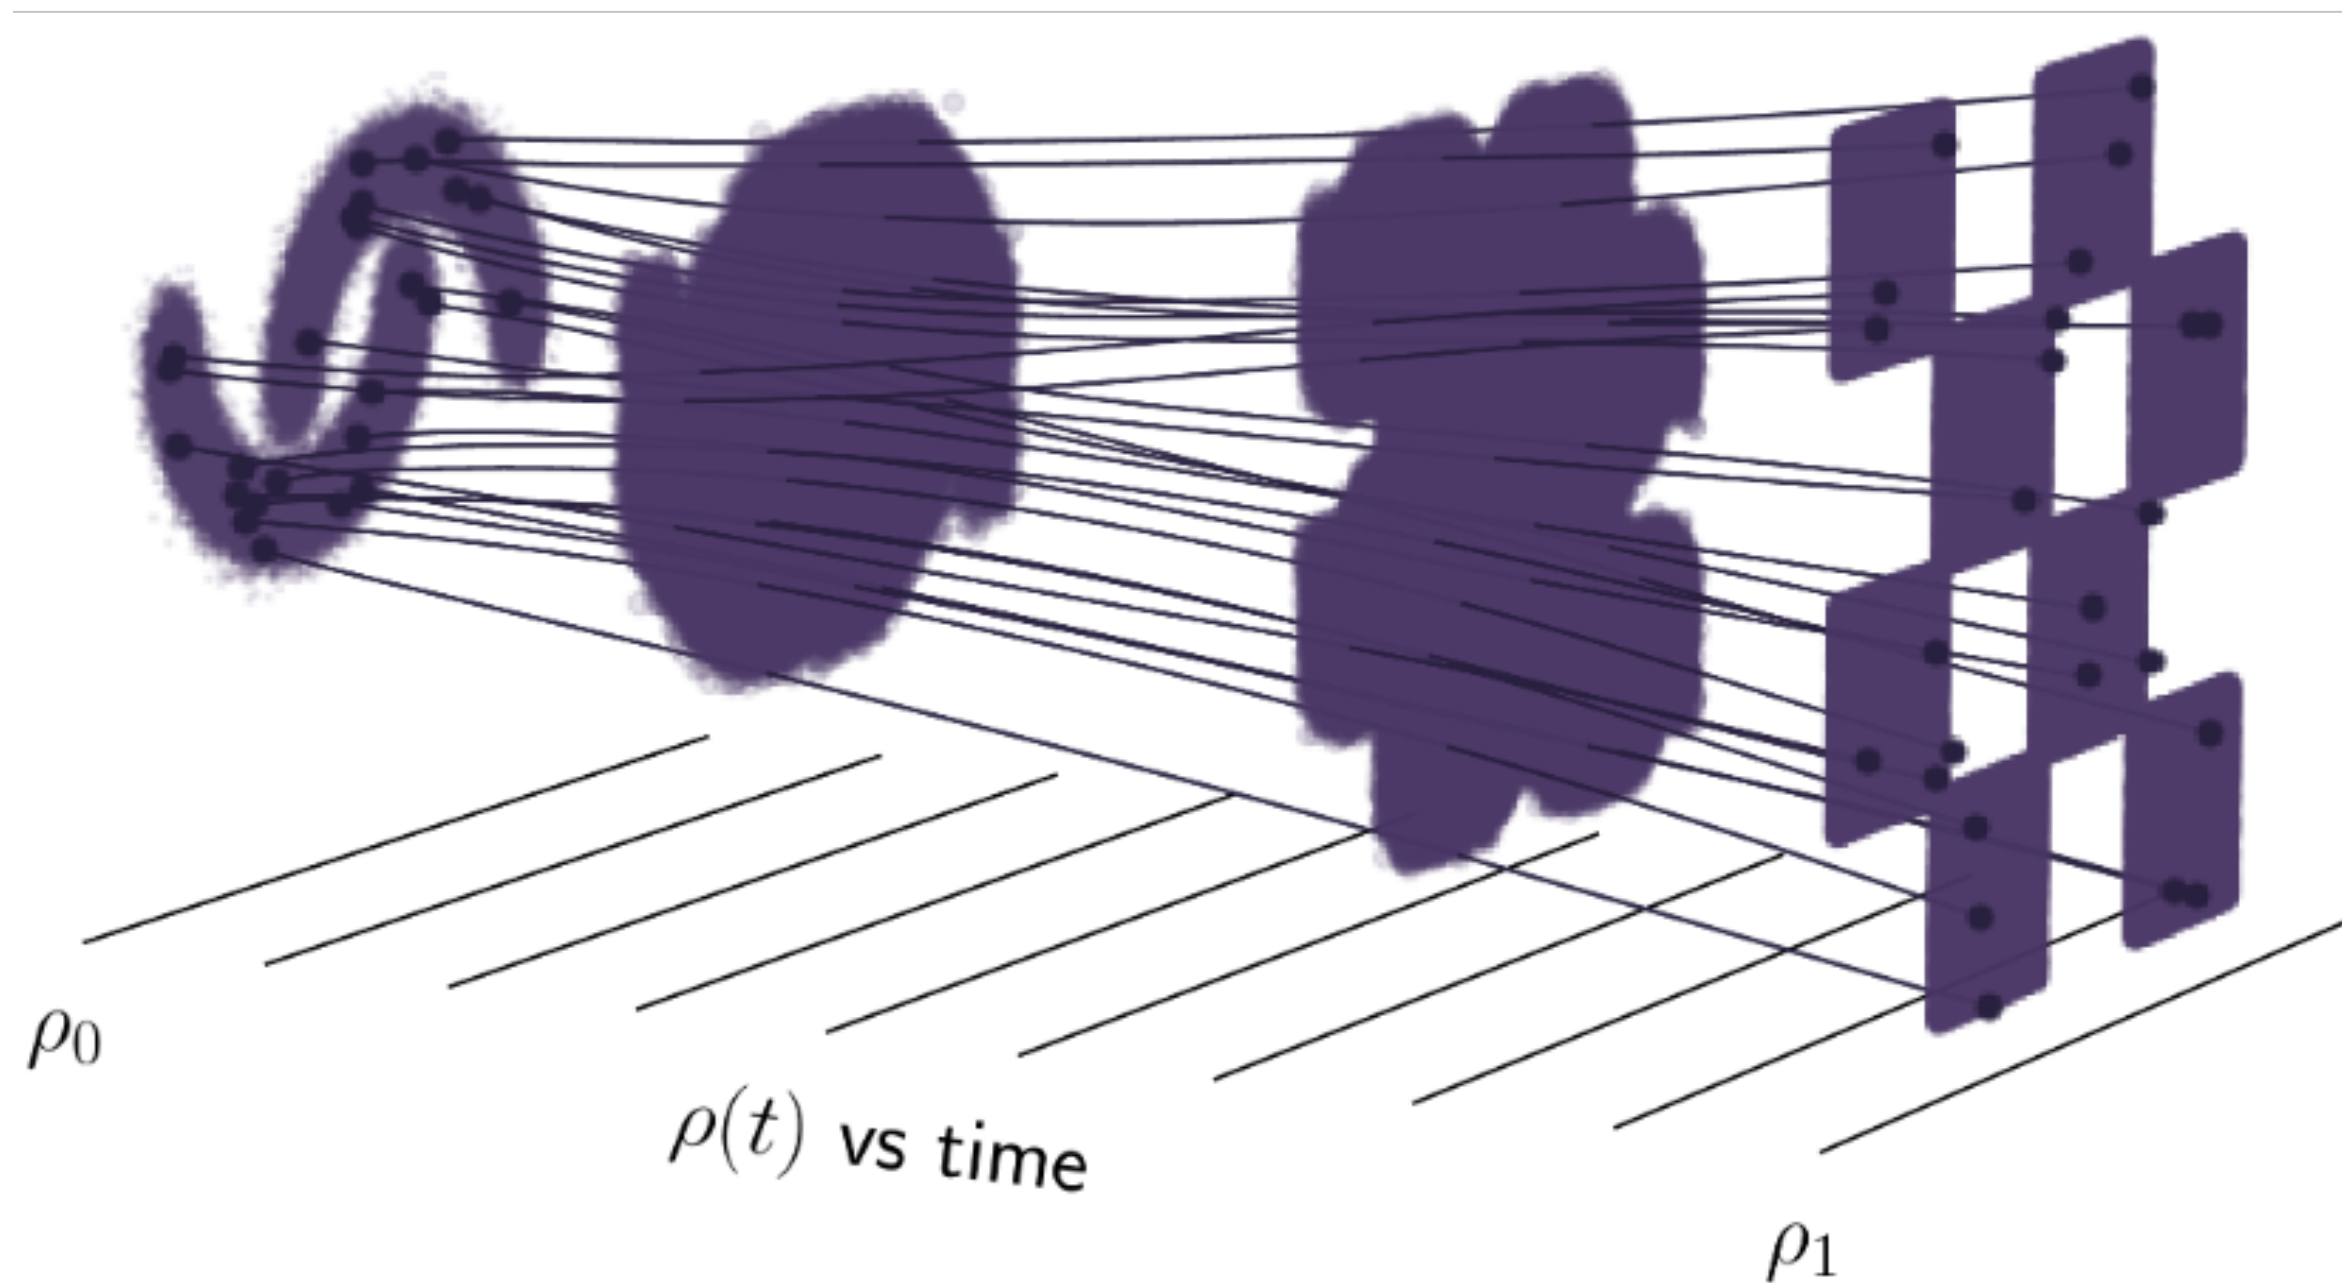
Párosított adatok




(Mini-Batch) Optimal Transport

# Folyamillesztés

## Kapcsolódó formalizmusok



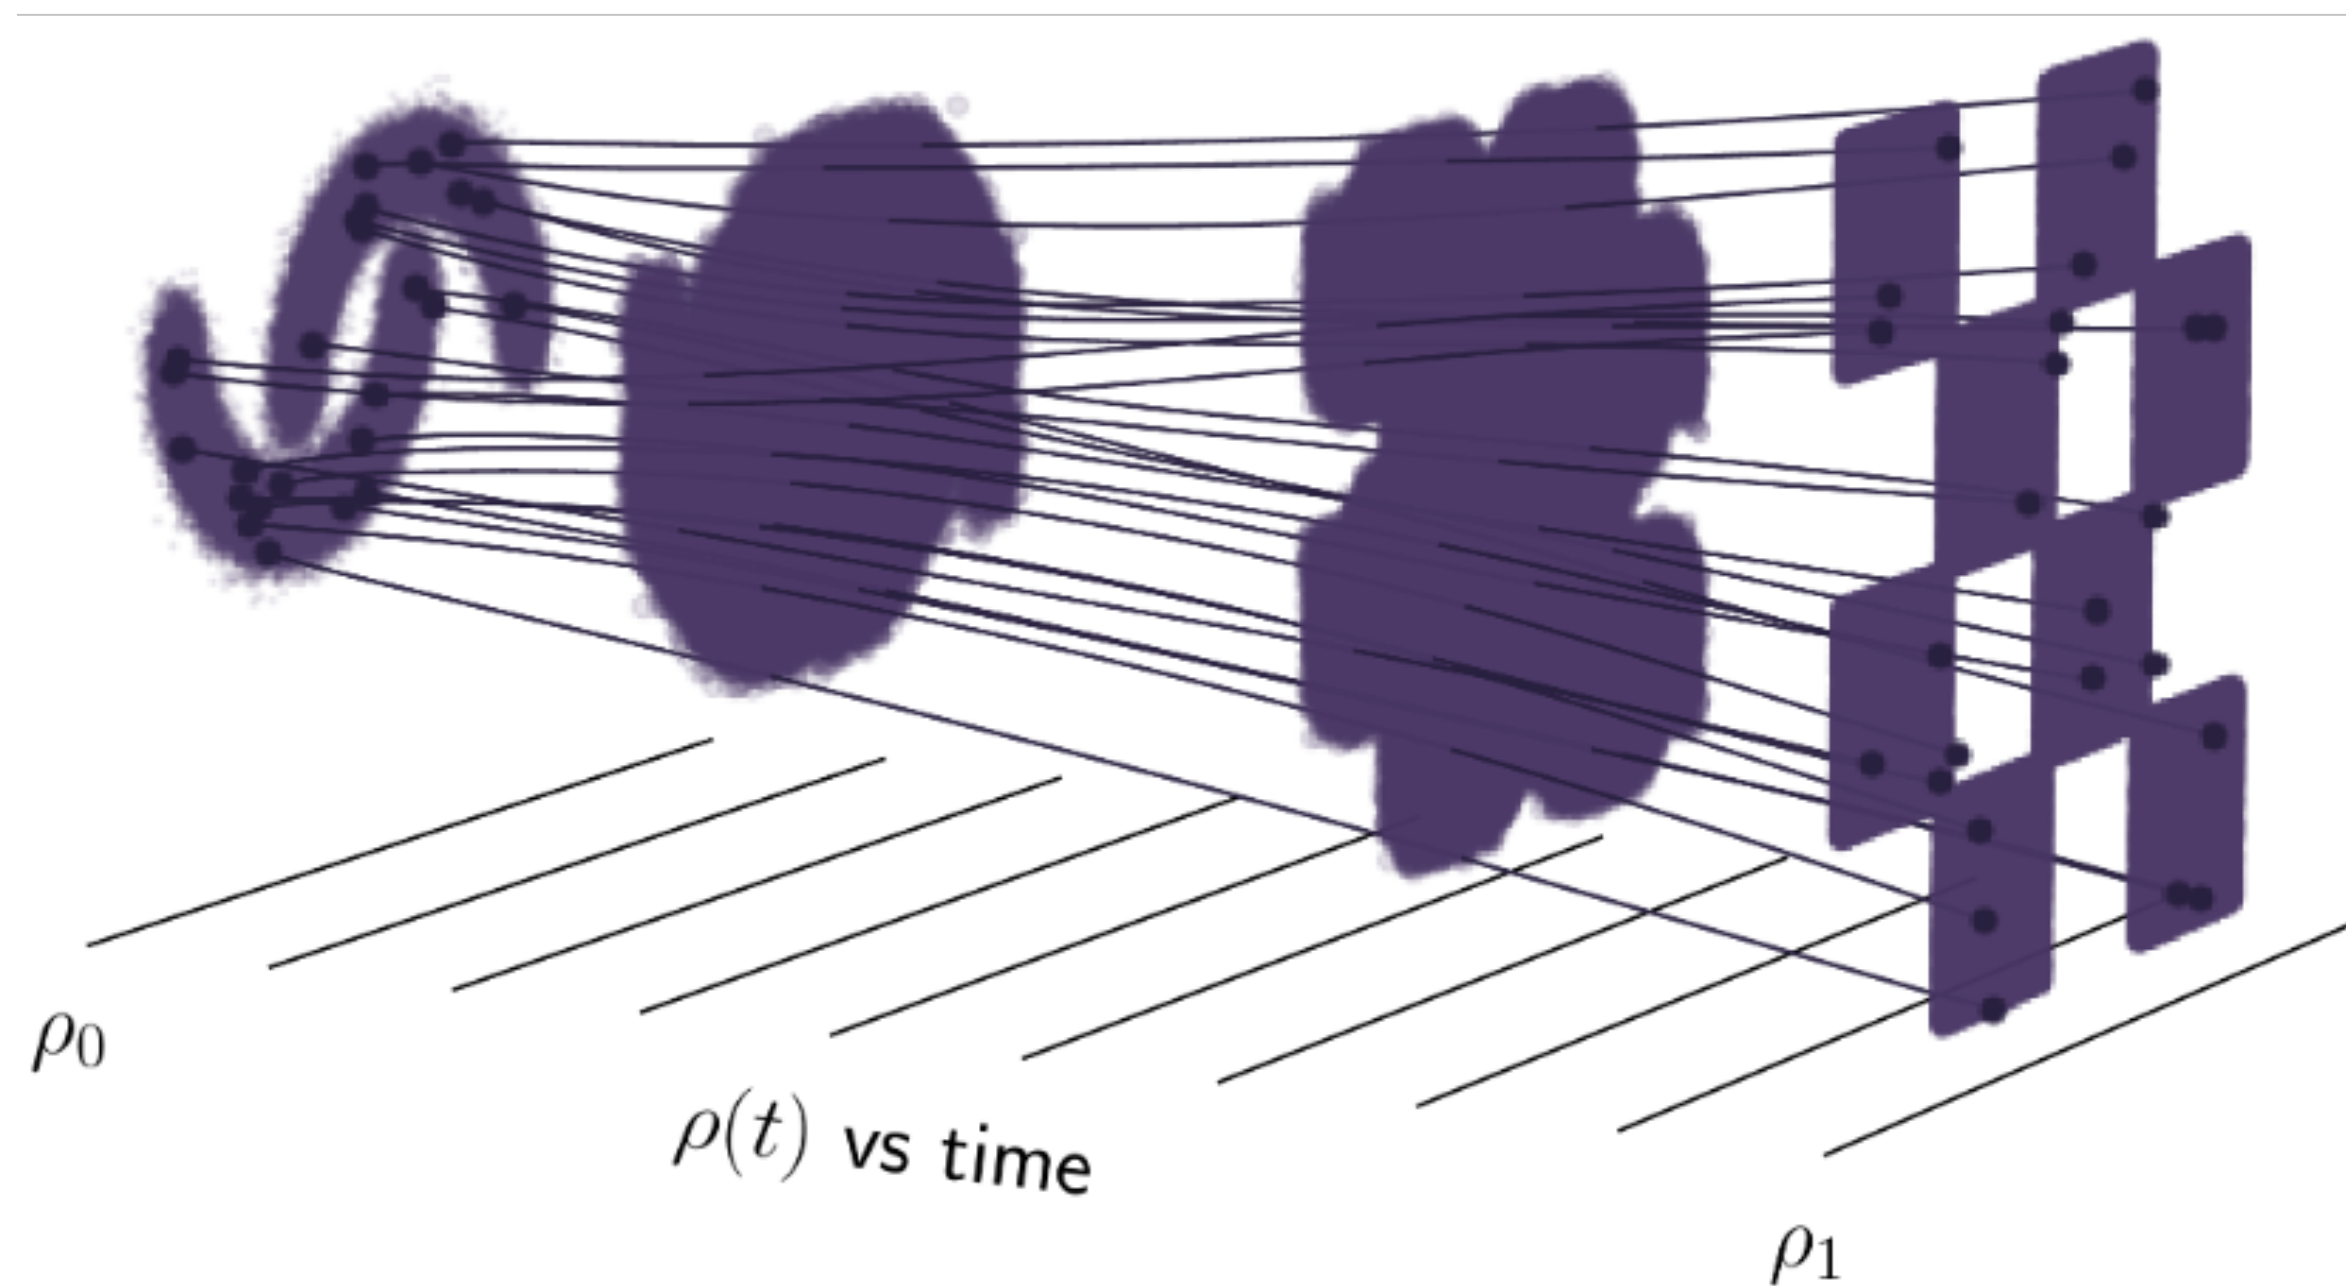
Sztochasztikus Interpolánsok




Rektifikált folyamatok

# Folyamillesztés

## Kapcsolódó formalizmusok




Sztochasztikus Interpolánsok



Rektifikált folyamatok

# Diffúziós Modellek

## Történelem



### Deep Unsupervised Learning using Nonequilibrium Thermodynamics

**Jascha Sohl-Dickstein**

Stanford University

**Eric A. Weiss**

University of California, Berkeley

**Niru Maheswaranathan**

Stanford University

**Surya Ganguli**

Stanford University



2015: még csak egy generatív módszer a sok közül...

# Diffúziós Modellek

## Történelem

---

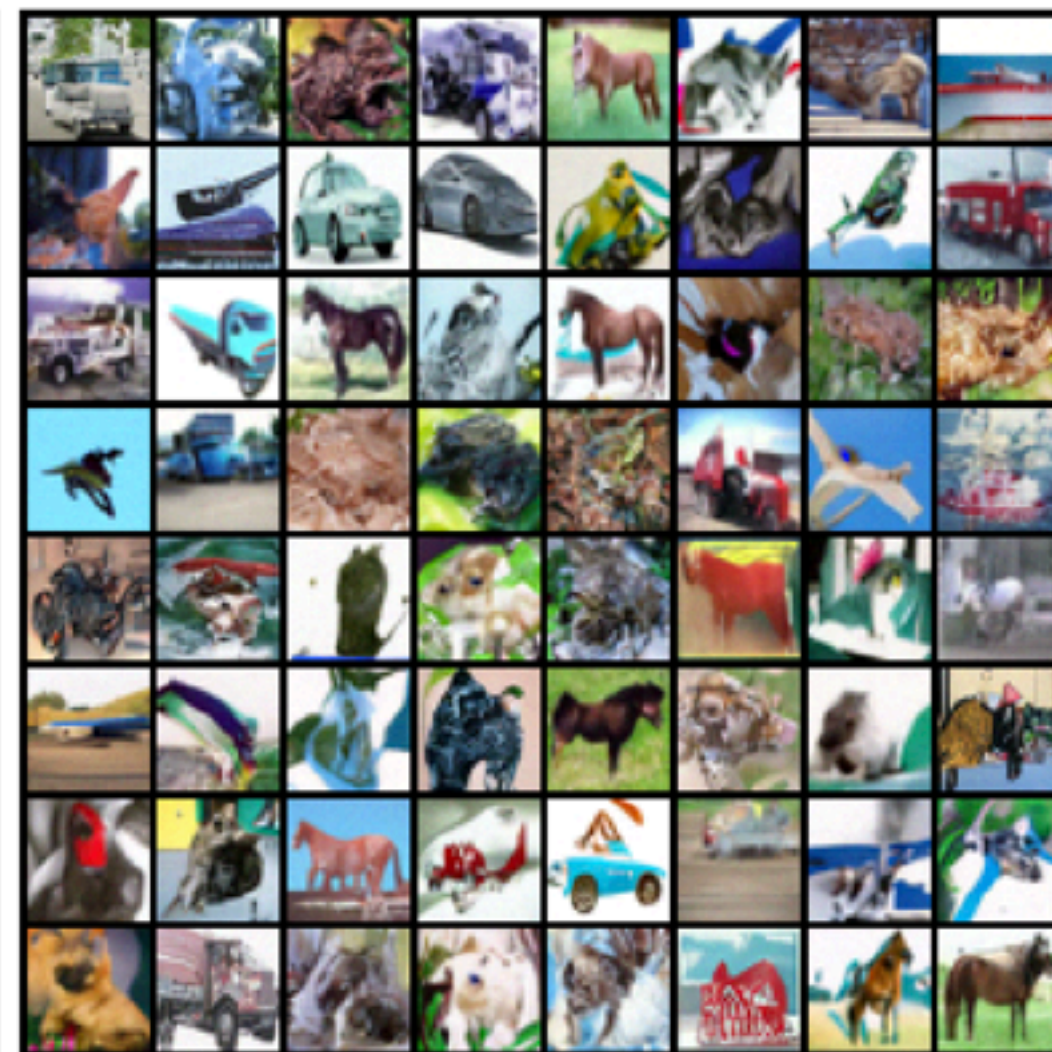
### Generative Modeling by Estimating Gradients of the Data Distribution

---

Yang Song  
Stanford University



Stefano Ermon  
Stanford University



---


### Denoising Diffusion Probabilistic Models

---

Jonathan Ho  
UC Berkeley

Ajay Jain  
UC Berkeley

Pieter Abbeel  
UC Berkeley



2019-2020: a diffúziós modellek újjáéledése

# Diffúziós Modellek

## Történelem

---

### Diffusion Models Beat GANs on Image Synthesis

---

Prafulla Dhariwal<sup>\*</sup>  
OpenAI  
prafulla@openai.com

Alex Nichol<sup>\*</sup>  
OpenAI  
alex@openai.com



### High-Resolution Image Synthesis with Latent Diffusion Models

Robin Rombach<sup>1</sup> \*    Andreas Blattmann<sup>1</sup> \*    Dominik Lorenz<sup>1</sup>    Patrick Esser<sup>RS</sup>    Björn Ommer<sup>1</sup>

<sup>1</sup>Ludwig Maximilian University of Munich & IWR, Heidelberg University, Germany    <sup>RS</sup>Runway ML

<https://github.com/CompVis/latent-diffusion>



2021-22: növekvő felbontás és modell méretek

# Diffúziós Modellek

## Történelem



2022-: a diffúziós modelleket az ébredő nagy nyelvi modellekkel vezérelve megszületnek az első igazán általános képgenerátorok!

# Diffúziós Modellek

## Történelem

### SCORE-BASED GENERATIVE MODELING THROUGH STOCHASTIC DIFFERENTIAL EQUATIONS

**Yang Song\***  
Stanford University  
yangsong@cs.stanford.edu


**Jascha Sohl-Dickstein**  
Google Brain  
jaschasd@google.com

**Diederik P. Kingma**  
Google Brain  
durk@google.com

**Abhishek Kumar**  
Google Brain  
abhishk@google.com

**Stefano Ermon**  
Stanford University  
ermon@cs.stanford.edu

**Ben Poole**  
Google Brain  
pooleb@google.com




### Elucidating the Design Space of Diffusion-Based Generative Models

**Tero Karras**  
NVIDIA

**Miika Aittala**  
NVIDIA

**Timo Aila**  
NVIDIA

**Samuli Laine**  
NVIDIA



2022-: SDE/ODE értelmezések,  
fokozatos áttérés hatékonyabb *determinisztikus* generálási módszerekre

# Diffúziós Modellek

## Történelem

### SCORE-BASED GENERATIVE MODELING THROUGH STOCHASTIC DIFFERENTIAL EQUATIONS

**Yang Song\***  
Stanford University  
yangsong@cs.stanford.edu


**Jascha Sohl-Dickstein**  
Google Brain  
jaschasd@google.com

**Diederik P. Kingma**  
Google Brain  
durk@google.com

**Abhishek Kumar**  
Google Brain  
abhishk@google.com

**Stefano Ermon**  
Stanford University  
ermon@cs.stanford.edu

**Ben Poole**  
Google Brain  
pooleb@google.com




### Elucidating the Design Space of Diffusion-Based Generative Models

**Tero Karras**  
NVIDIA

**Miika Aittala**  
NVIDIA

**Timo Aila**  
NVIDIA

**Samuli Laine**  
NVIDIA




2022-: SDE/ODE értelmezések,  
fokozatos áttérés hatékonyabb *determinisztikus* generálási módszerekre

# Diffúziós Modellek

## Történelem

### FLOW MATCHING FOR GENERATIVE MODELING

Yaron Lipman<sup>1,2</sup> Ricky T. Q. Chen<sup>1</sup> Heli Ben-Hamu<sup>2</sup> Maximilian Nickel<sup>1</sup> Matt Le<sup>1</sup>  
<sup>1</sup>Meta AI (FAIR) <sup>2</sup>Weizmann Institute of Science



### Stochastic Interpolants: A Unifying Framework for Flows and Diffusions

Michael S. Albergo\*  
Center for Cosmology and Particle Physics  
New York University  
New York, NY 10012, USA


ALBERGO@NYU.EDU

Nicholas M. Boffi\*  
Courant Institute of Mathematical Sciences  
New York University  
New York, NY 10012, USA

BOFFI@CIMS.NYU.EDU

Eric Vanden-Eijnden  
Courant Institute of Mathematical Sciences  
New York University  
New York, NY 10012, USA

EVE2@CIMS.NYU.EDU




### Flow Straight and Fast: Learning to Generate and Transfer Data with Rectified Flow

Xingchao Liu\*  
University of Texas at Austin  
xcliu@utexas.edu

Chengyue Gong\*  
University of Texas at Austin  
cygong@cs.utexas.edu

Qiang Liu  
University of Texas at Austin  
liqiang@cs.utexas.edu




2022-23: ODE központú megközelítések, folyamillesztés

# Diffúziós Modellek

## Történelem

### FLOW MATCHING FOR GENERATIVE MODELING

Yaron Lipman<sup>1,2</sup> Ricky T. Q. Chen<sup>1</sup> Heli Ben-Hamu<sup>2</sup> Maximilian Nickel<sup>1</sup> Matt Le<sup>1</sup>  
<sup>1</sup>Meta AI (FAIR) <sup>2</sup>Weizmann Institute of Science



### Stochastic Interpolants: A Unifying Framework for Flows and Diffusions

Michael S. Albergo\*  
Center for Cosmology and Particle Physics  
New York University  
New York, NY 10012, USA


ALBERGO@NYU.EDU

Nicholas M. Boffi\*  
Courant Institute of Mathematical Sciences  
New York University  
New York, NY 10012, USA

BOFFI@CIMS.NYU.EDU

Eric Vanden-Eijnden  
Courant Institute of Mathematical Sciences  
New York University  
New York, NY 10012, USA

EVE2@CIMS.NYU.EDU




### Flow Straight and Fast: Learning to Generate and Transfer Data with Rectified Flow

Xingchao Liu\*  
University of Texas at Austin  
xcliu@utexas.edu

Chengyue Gong\*  
University of Texas at Austin  
cygong@cs.utexas.edu

Qiang Liu  
University of Texas at Austin  
liqiang@cs.utexas.edu



2022-23: ODE központú megközelítések, folyamillesztés

# Diffúziós Modellek

## Történelem



FLUX.1 Kontext



腾讯混元-Video



Isaac GROOT

Hunyuan3D 2.0

$\pi_0$ : A Vision-Language-Action Flow Model for  
General Robot Control

Physical Intelligence



SimpleFold: Folding Proteins is  
Simpler than You Think

Yuyang Wang, Jiarui Lu\*, Navdeep Jaitly, Josh Susskind, Miguel Angel Bautista

A jelenlegi trend: folyamillesztés mindenhol, mindenre!

# Diffúziós Modellek

## Történelem



**Midjourney**

**FLUX.1**  
A new era of creation



Napjainkra már komoly ökoszisztéma épült a diffúziós modellek köré!

# Diffúziós Modellek

## Jegyzetajánló

### The Principles of Diffusion Models

From Origins to Advances

---

**Chieh-Hsin Lai**  
Sony AI

**Yang Song**  
OpenAI

**Dongjun Kim**  
Stanford University

**Yuki Mitsufuji**  
Sony Corporation, Sony AI

**Stefano Ermon**  
Stanford University

<https://arxiv.org/abs/2510.21890>

<https://the-principles-of-diffusion-models.github.io/#/blog>

### An Introduction to Flow Matching and Diffusion Models

Peter Holderrieth and Ezra Erives

Website: <https://diffusion.csail.mit.edu/>

### STEP-BY-STEP DIFFUSION: AN ELEMENTARY TUTORIAL

*Preetum Nakkiran<sup>1</sup>, Arwen Bradley<sup>1</sup>, Hattie Zhou<sup>1,2</sup>, Madhu Advani<sup>1</sup>*

<sup>1</sup>Apple, <sup>2</sup>Mila, Université de Montréal

<https://arxiv.org/abs/2406.08929>



### Generative Modeling by Estimating Gradients of the Data Distribution

AUTHORS  
Yang Song

<https://yang-song.net/blog/2021/score/>

# Következő előadás: Autoregresszív Generálás

- Transformer architektúra / figyelem
- Nagy nyelvi modellek alapjai
- Multimodalitás



# Következő előadás: Autoregresszív Generálás

- Transformer architektúra / figyelem
- Nagy nyelvi modellek alapjai
- Multimodalitás

