



# 14. Előadás: Neurális Implicit Reprezentációk

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

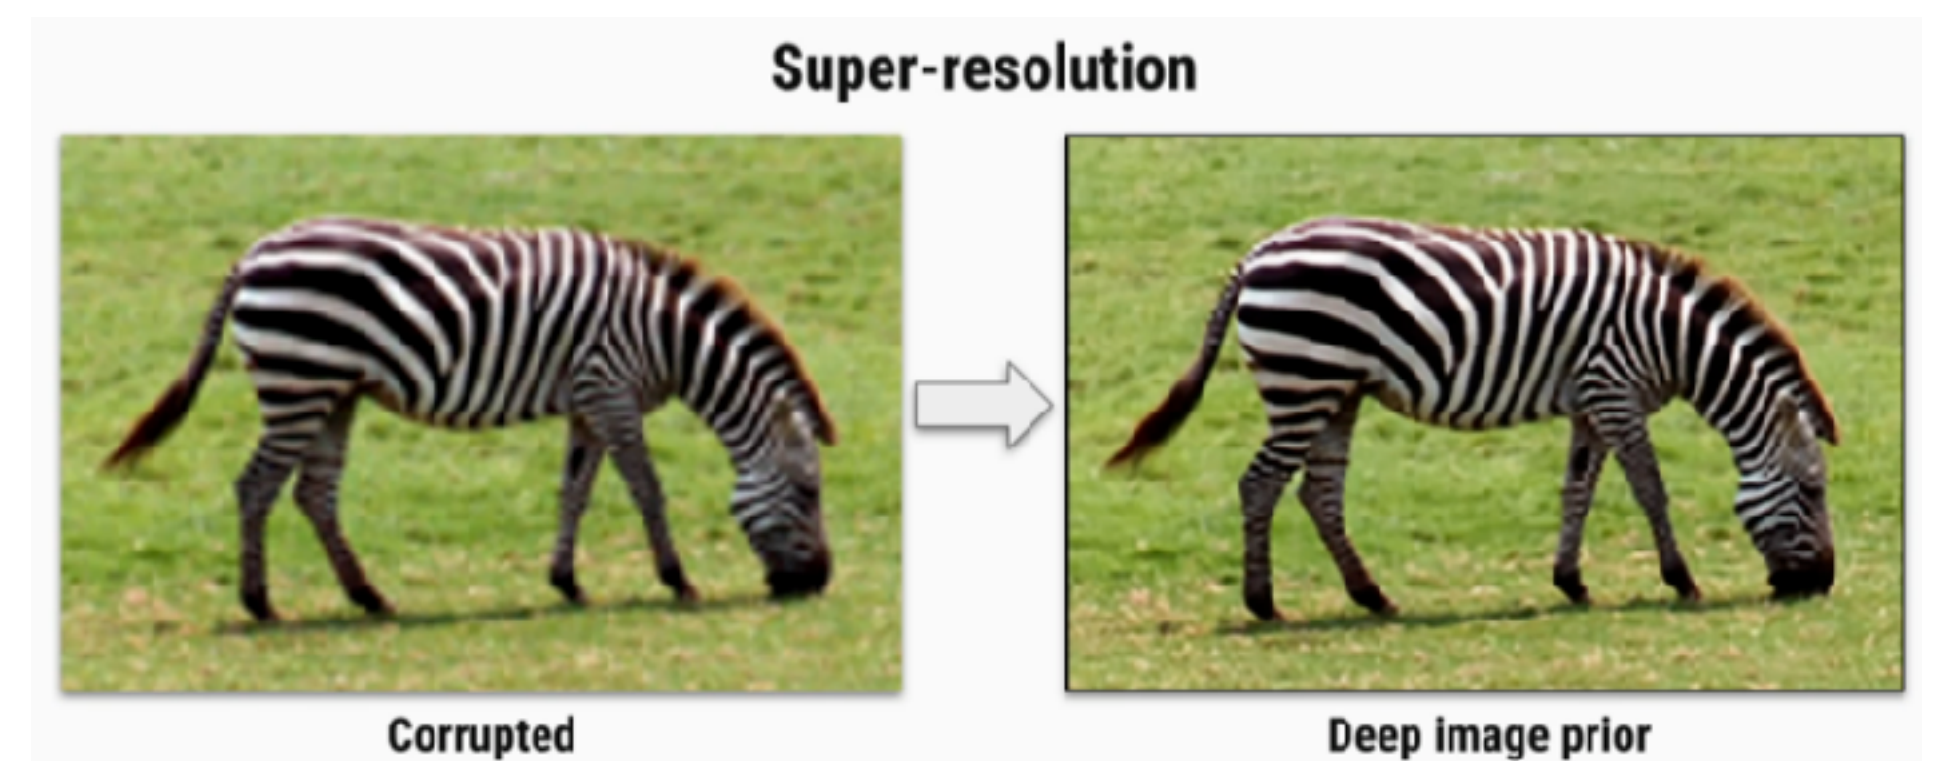
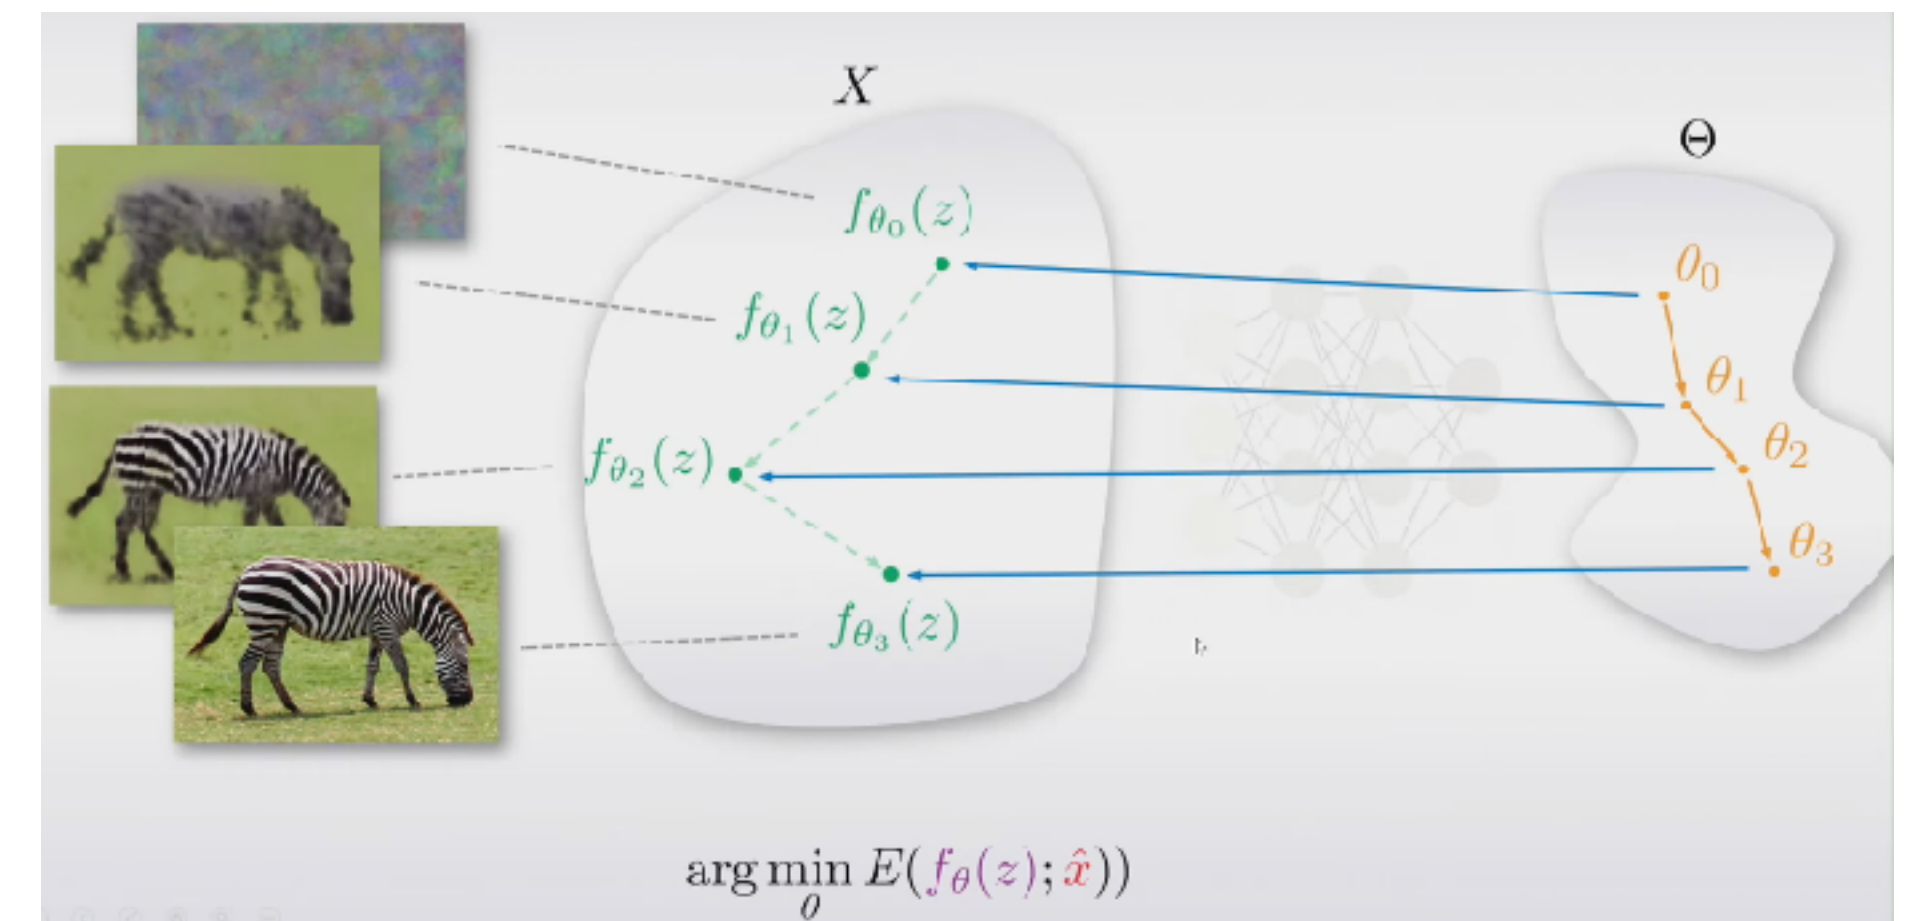


Dr. Vaitkus Márton

# Motiváció

## Deep Image Prior

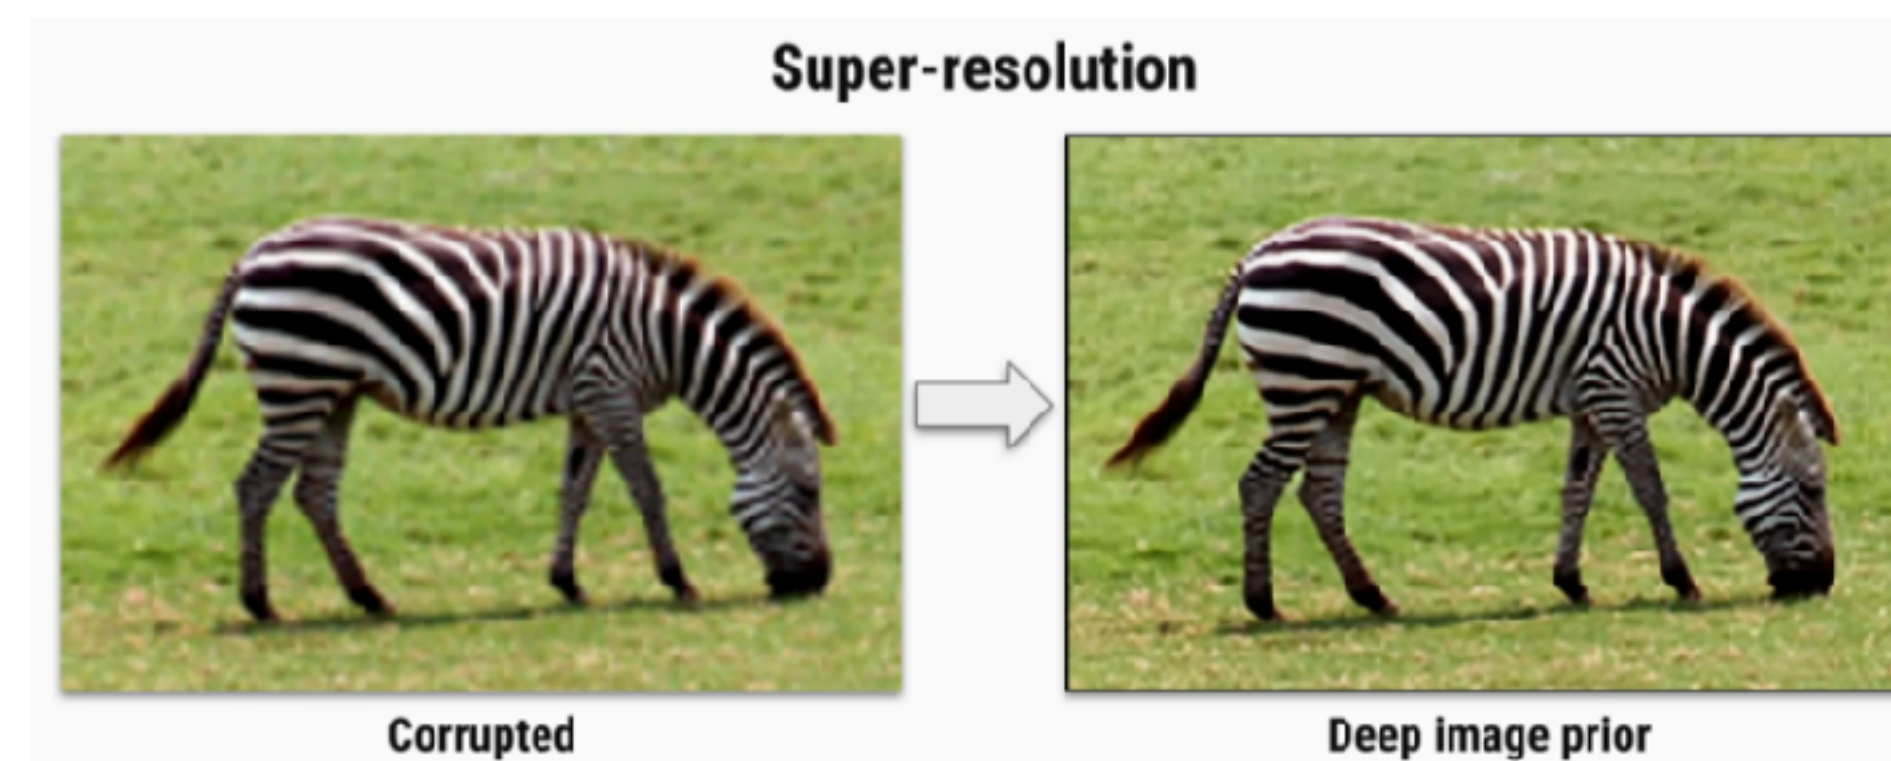

- Ötlet: tanítsunk egy neurális hálót reprodukálni egy *fix képet* (zaj bemenetből)!
- Tapasztalati tény: ha a tanítást korábban leállítjuk (early stopping) gyakran javul a kép minősége (nagyfrekvenciás zaj, artifactok csökkennek, lyukak kitöltődnek)
- **Deep Image Prior**: a neurális háló architektúrája egy bizonyos “prior” kényszerít a rekonstruált képre!



# Motiváció




## Deep Image Prior

- Ötlet: tanítsunk egy neurális hálót reprodukálni egy *fix képet* (zaj bemenetből)!
- Tapasztalati tény: ha a tanítást korábban leállítjuk (early stopping) gyakran javul a kép minősége (nagyfrekvenciás zaj, artifactok csökkennek, lyukak kitöltődnek)
- **Deep Image Prior**: a neurális háló architektúrája egy bizonyos “prior” kényszerít a rekonstruált képre!



# Neurális Reprezentációk

## Diszkretizációs módszerek

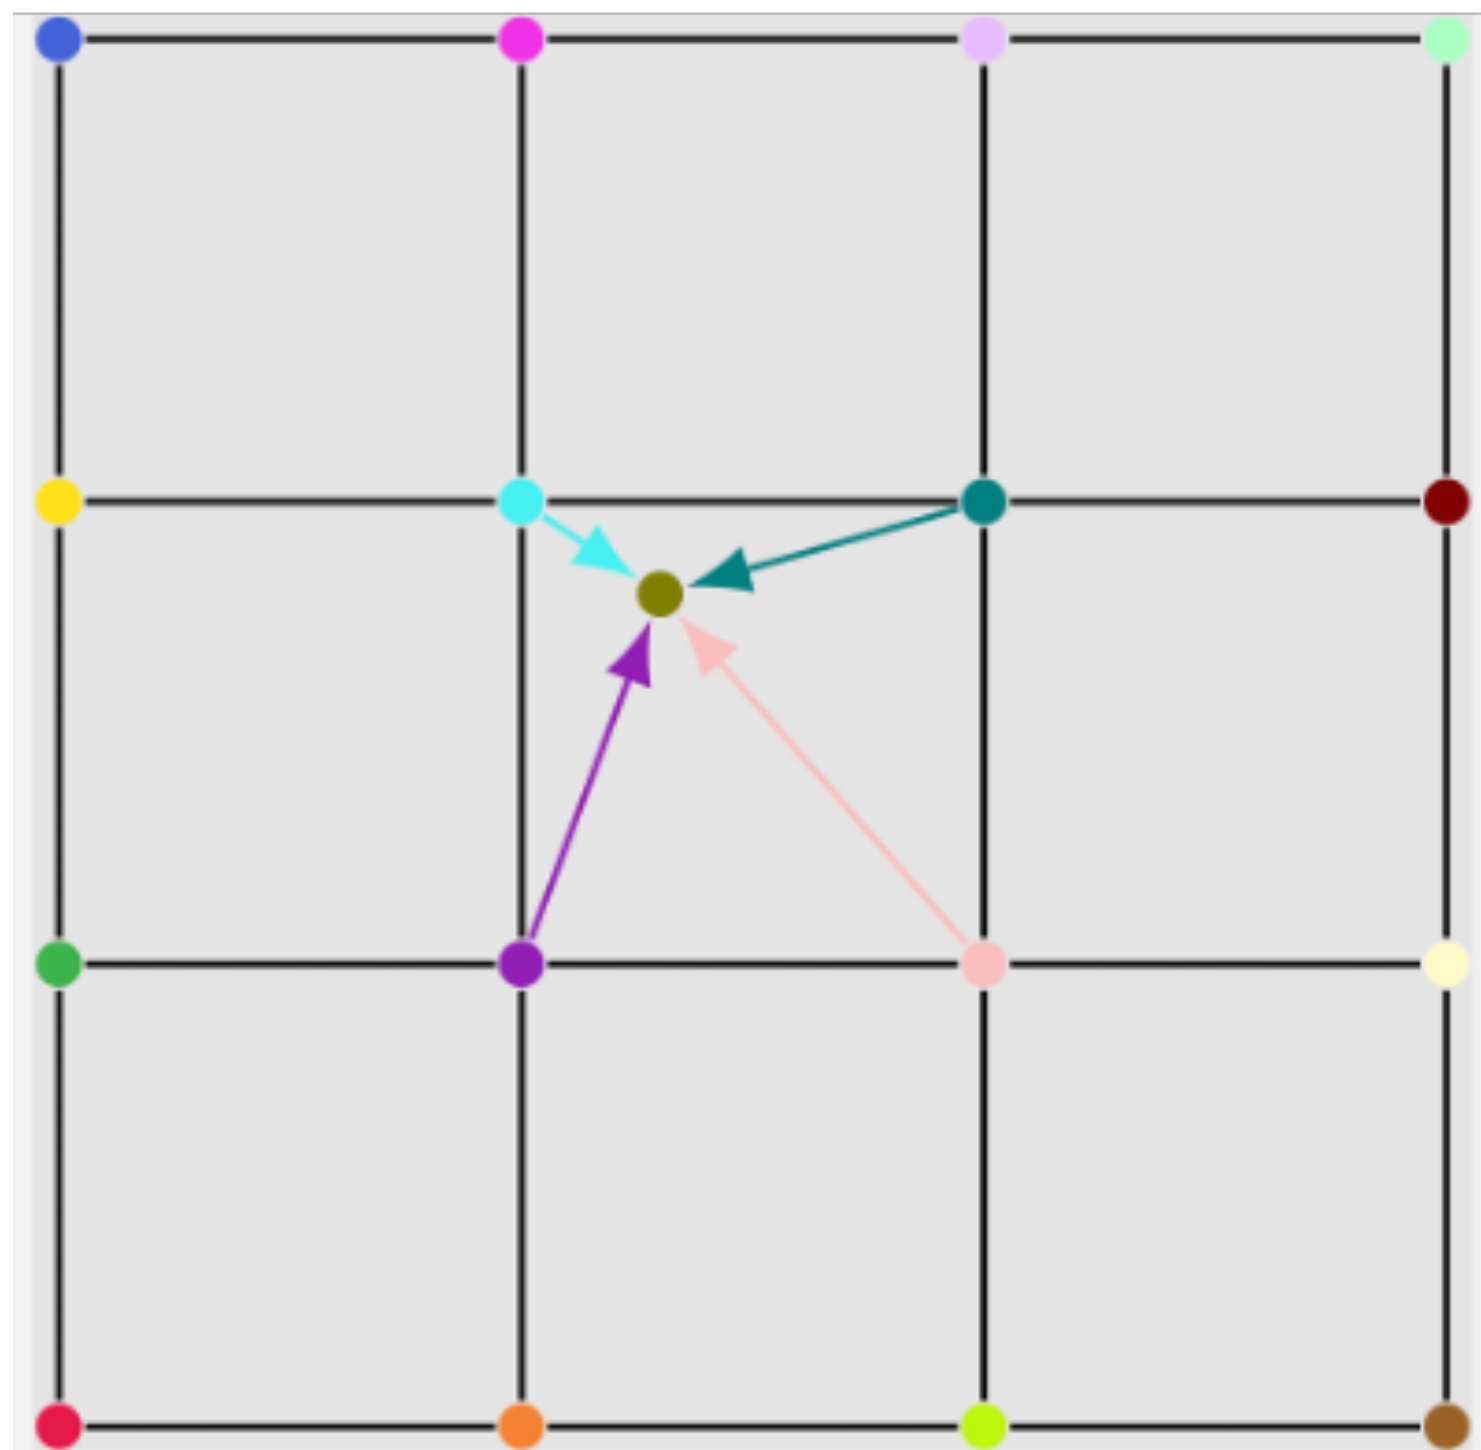


# Neurális Reprezentációk

Diszkretizáció helyett – Neurális reprezentáció?

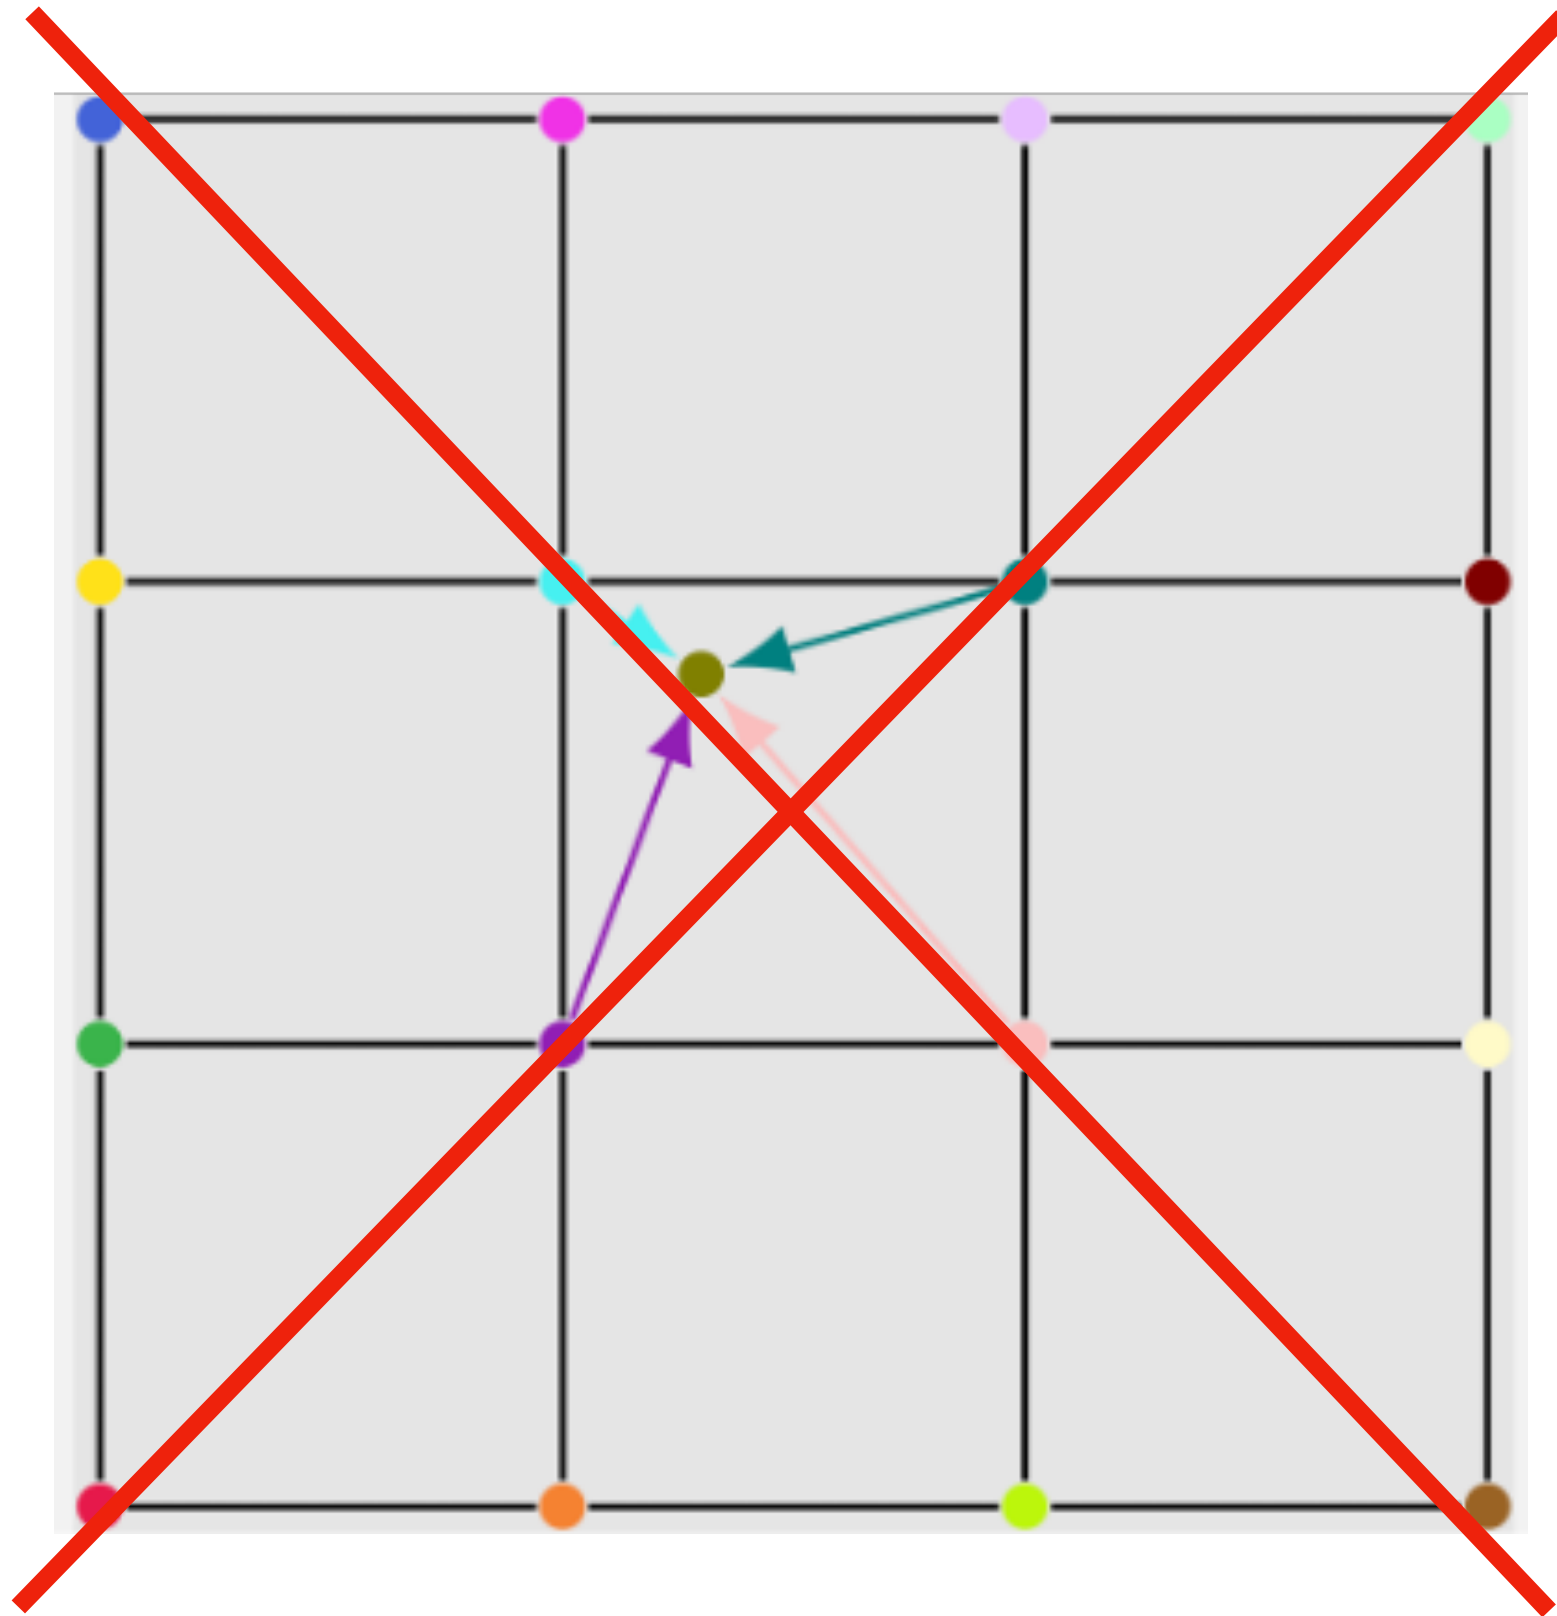
# Neurális Reprezentációk

Diszkretizáció helyett – Neurális reprezentáció?



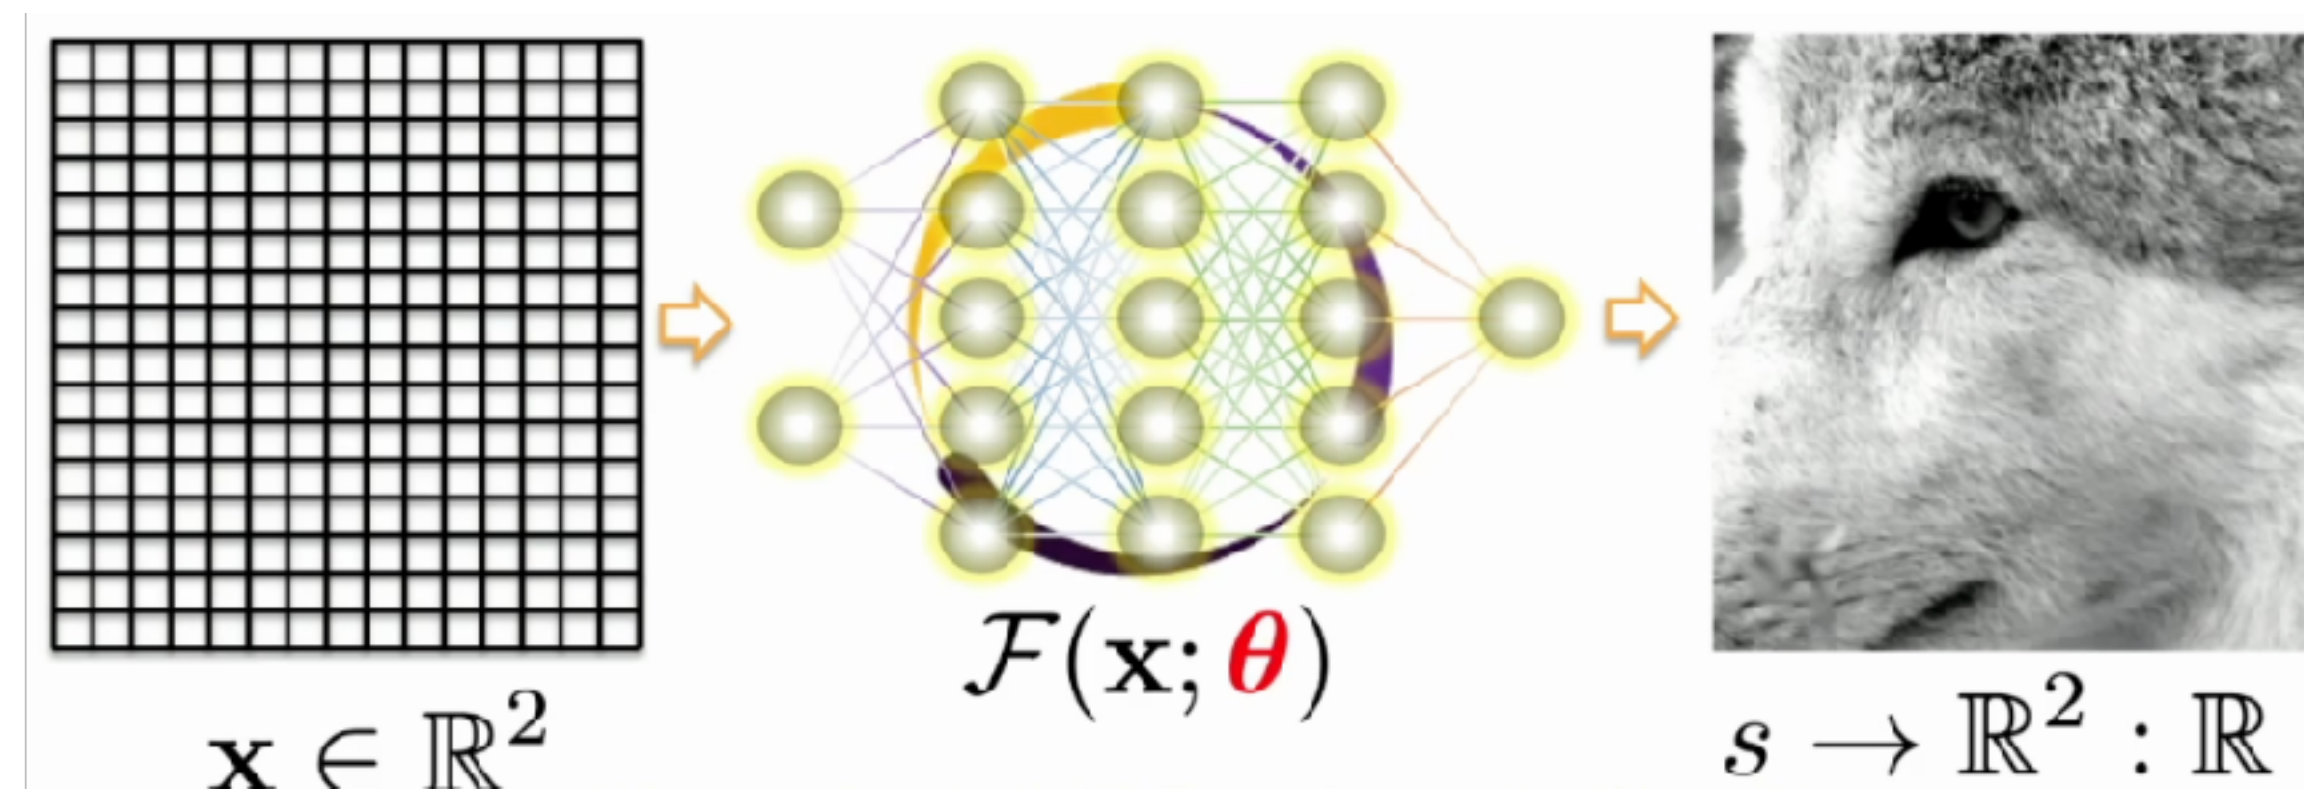
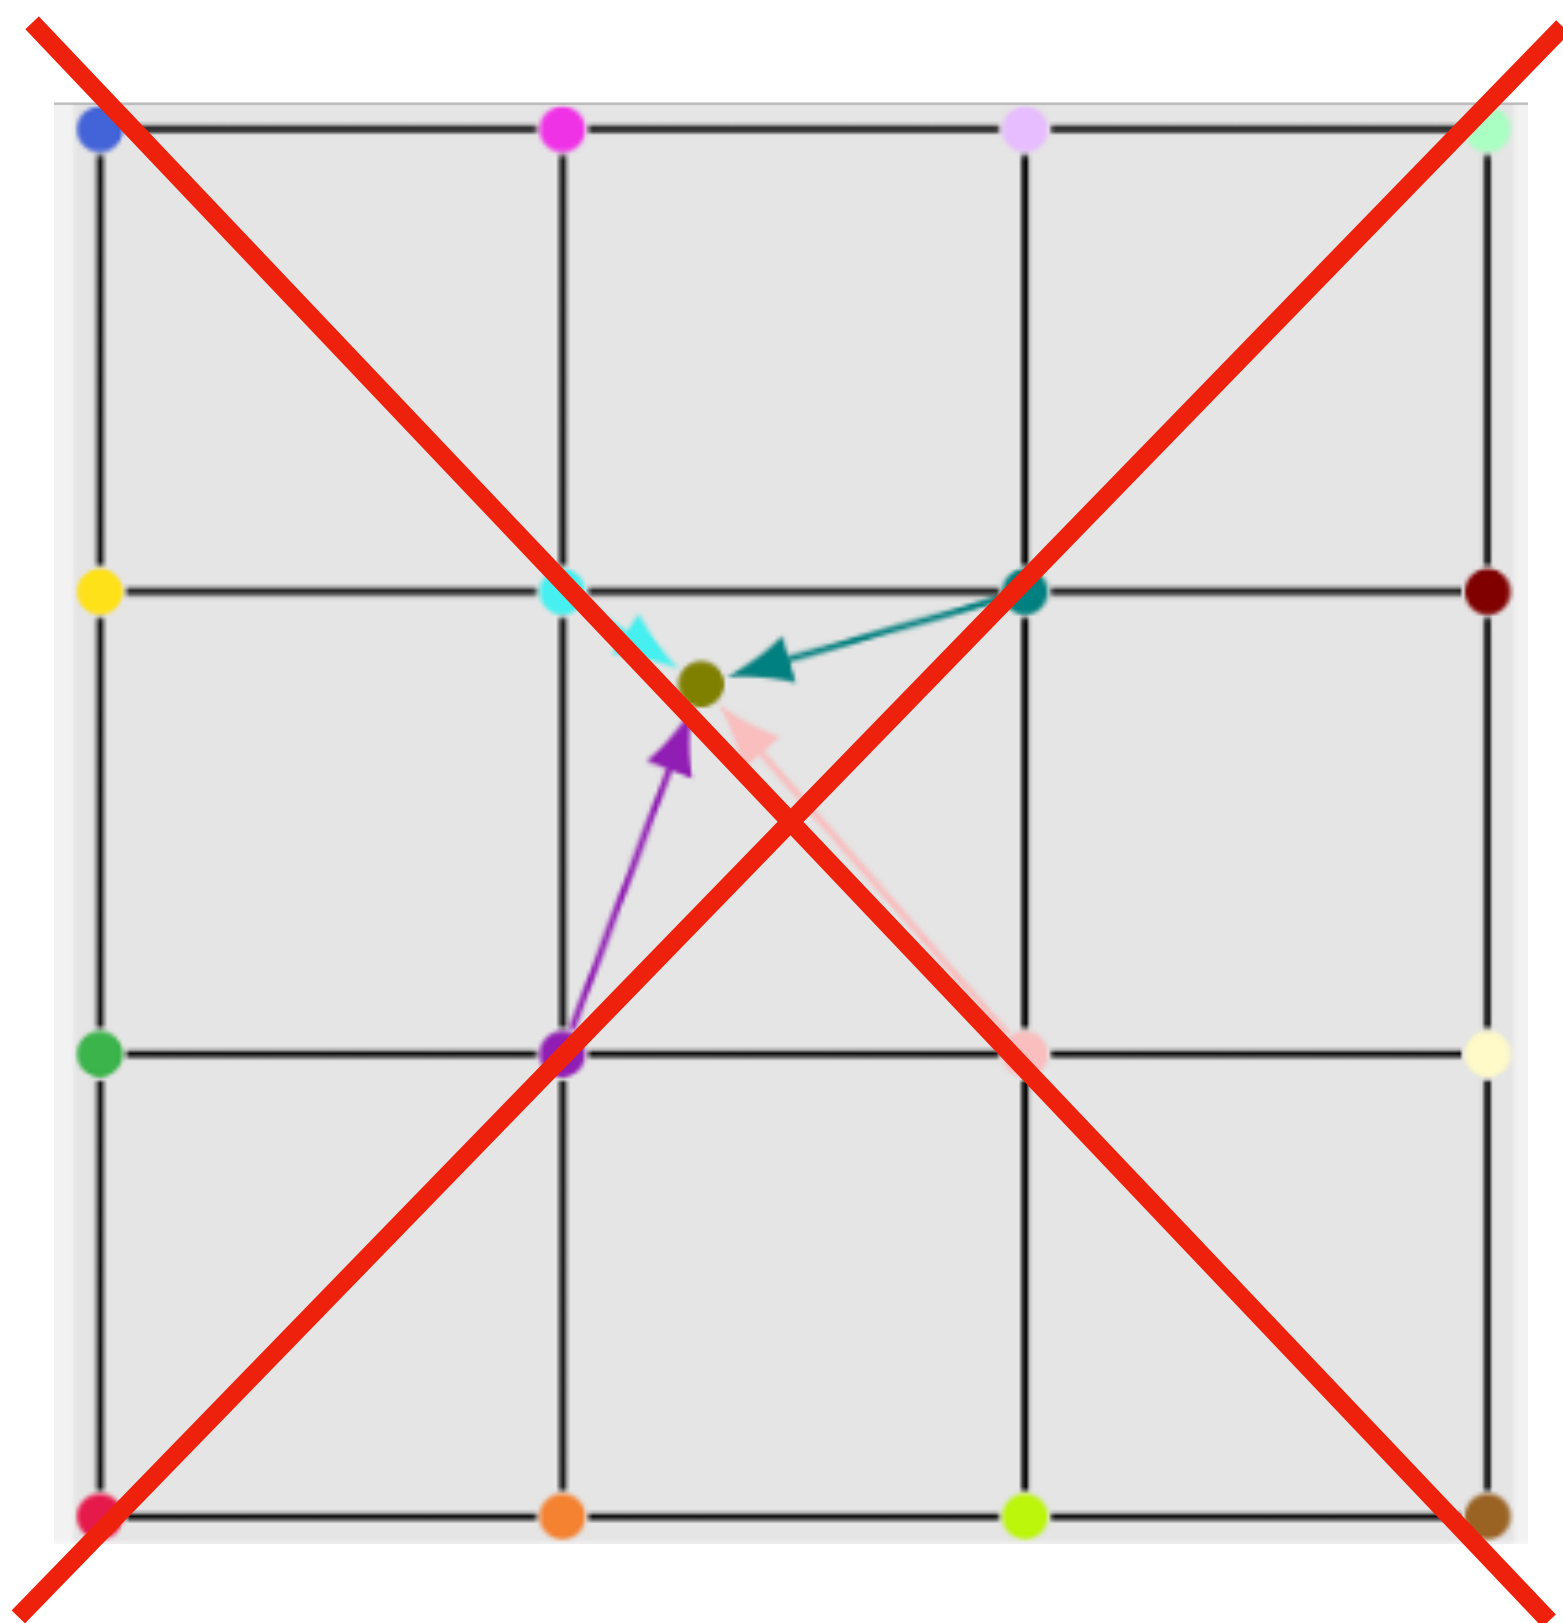
# Neurális Reprezentációk

Diszkretizáció helyett – Neurális reprezentáció?



# Neurális Reprezentációk


Diszkretizáció helyett – Neurális reprezentáció?




# Neurális Reprezentációk

## Függvények reprezentációja neurális hálókkal


- Ezidáig: neurális hálókkal sok dimenziós leképezést közelítettünk (pl. kép  $\rightarrow$  címke, kép  $\rightarrow$  kép)
- Modern trend: 2D/3D koordináták függvényeinek reprezentációja neurális hálókkal
- Különböző elnevezések:
  - Neurális mező (Neural field)
  - Implicit neurális reprezentáció (INR)
  - Neurális implicit (függvény)
  - Koordináta háló



(b) Image regression  
 $(x, y) \rightarrow \text{RGB}$



(c) 3D shape regression  
 $(x, y, z) \rightarrow \text{occupancy}$



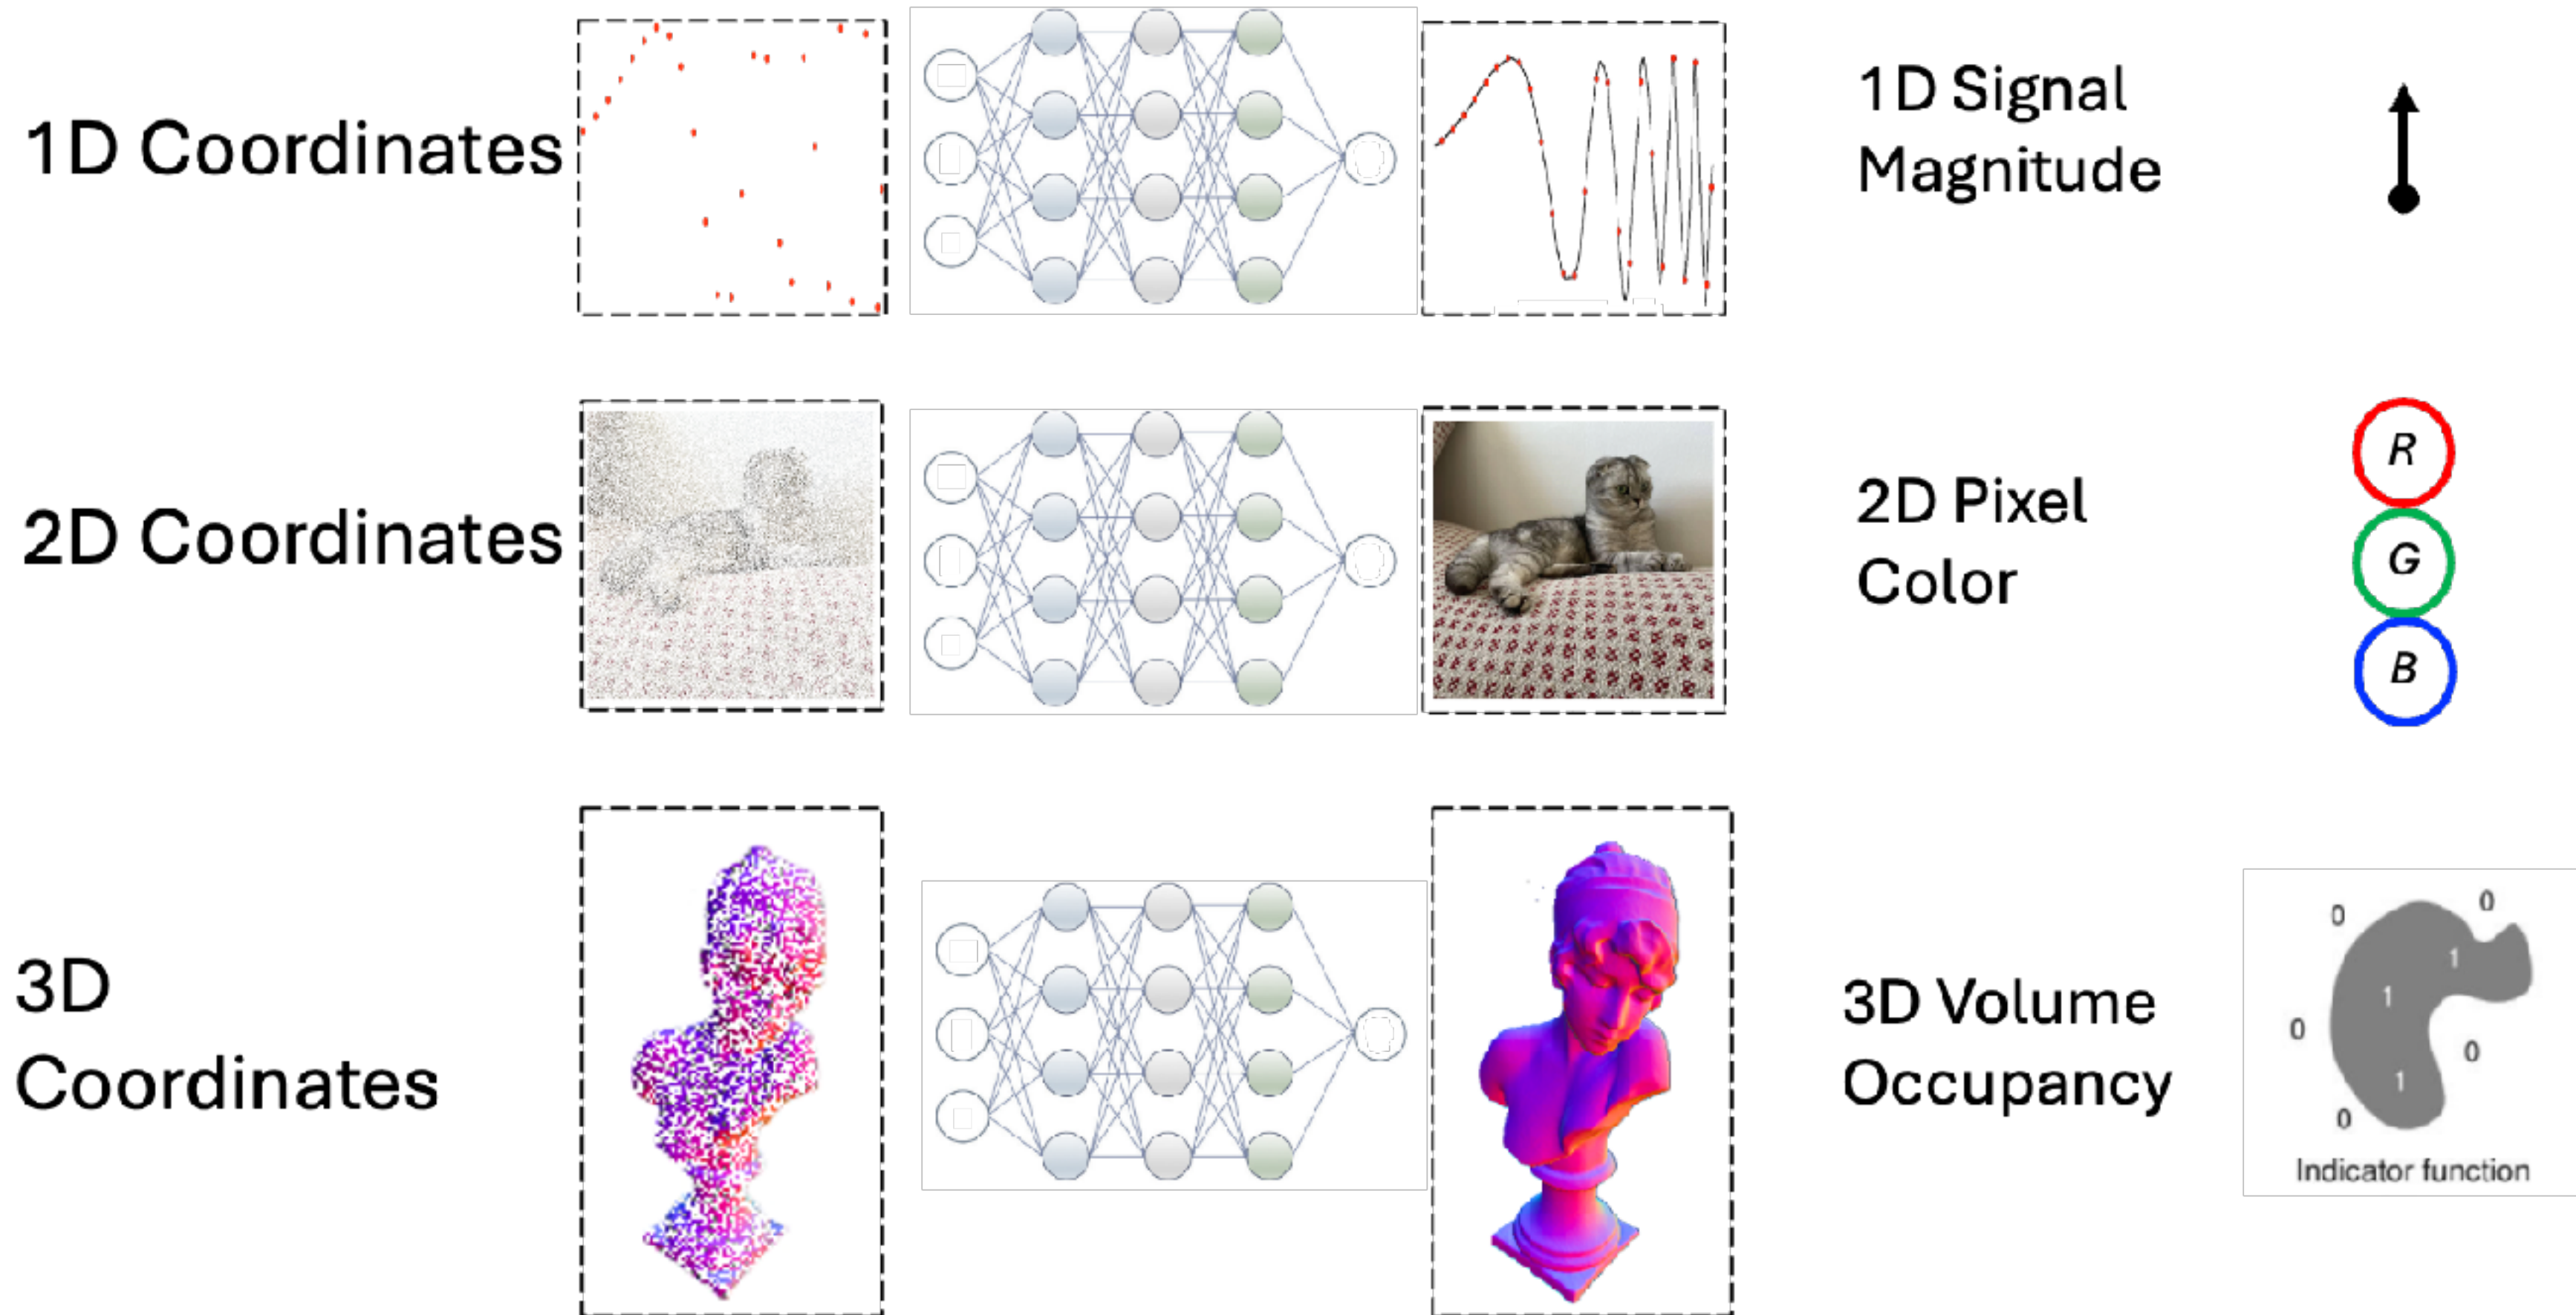
(d) MRI reconstruction  
 $(x, y, z) \rightarrow \text{density}$



(e) Inverse rendering  
 $(x, y, z) \rightarrow \text{RGB, density}$

# Neurális Reprezentációk

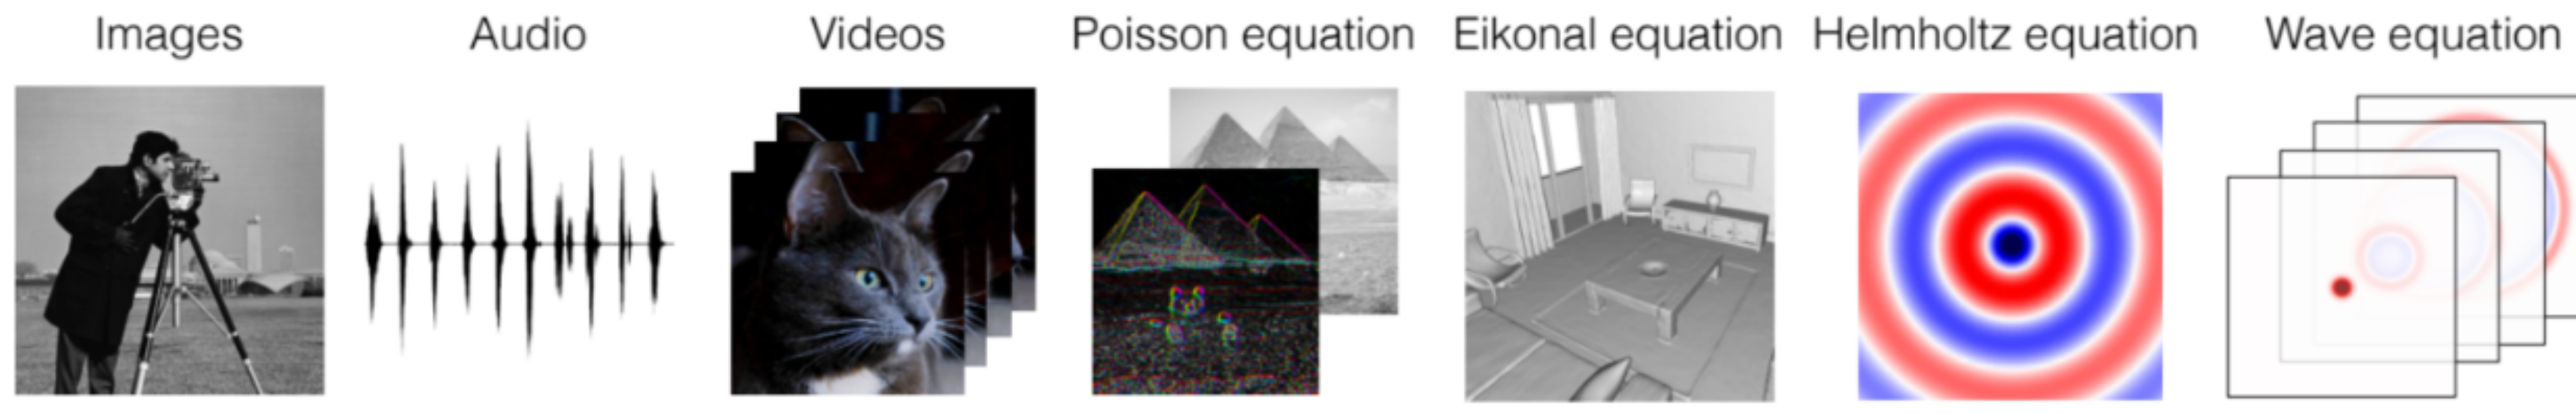
## Példák



# Neurális Reprezentációk

## Példák

- Kép
- Hang
- Videó
- 3D adatok (implicit függvény, sűrűség, távolság, stb.)
- **Radiancia mezők (NeRF)**
- Fizikai mennyiségek (hőmérséklet, áramlási sebesség, stb.)
- **Differenciálegyenletek megoldása (PINN)**




# Neurális Reprezentációk

## Neural Radiance Field (NeRF)

NeRF: Representing Scenes as  
Neural Radiance Fields for View Synthesis

Ben Mildenhall<sup>1\*</sup> Pratul P. Srinivasan<sup>1\*</sup> Matthew Tancik<sup>1\*</sup>  
Jonathan T. Barron<sup>2</sup> Ravi Ramamoorthi<sup>3</sup> Ren Ng<sup>1</sup>

Cited by 14782




# Neurális Reprezentációk

## Neural Radiance Field (NeRF)

NeRF: Representing Scenes as  
Neural Radiance Fields for View Synthesis

Ben Mildenhall<sup>1\*</sup> Pratul P. Srinivasan<sup>1\*</sup> Matthew Tancik<sup>1\*</sup>  
Jonathan T. Barron<sup>2</sup> Ravi Ramamoorthi<sup>3</sup> Ren Ng<sup>1</sup>

Cited by 14782



# Neurális Reprezentációk


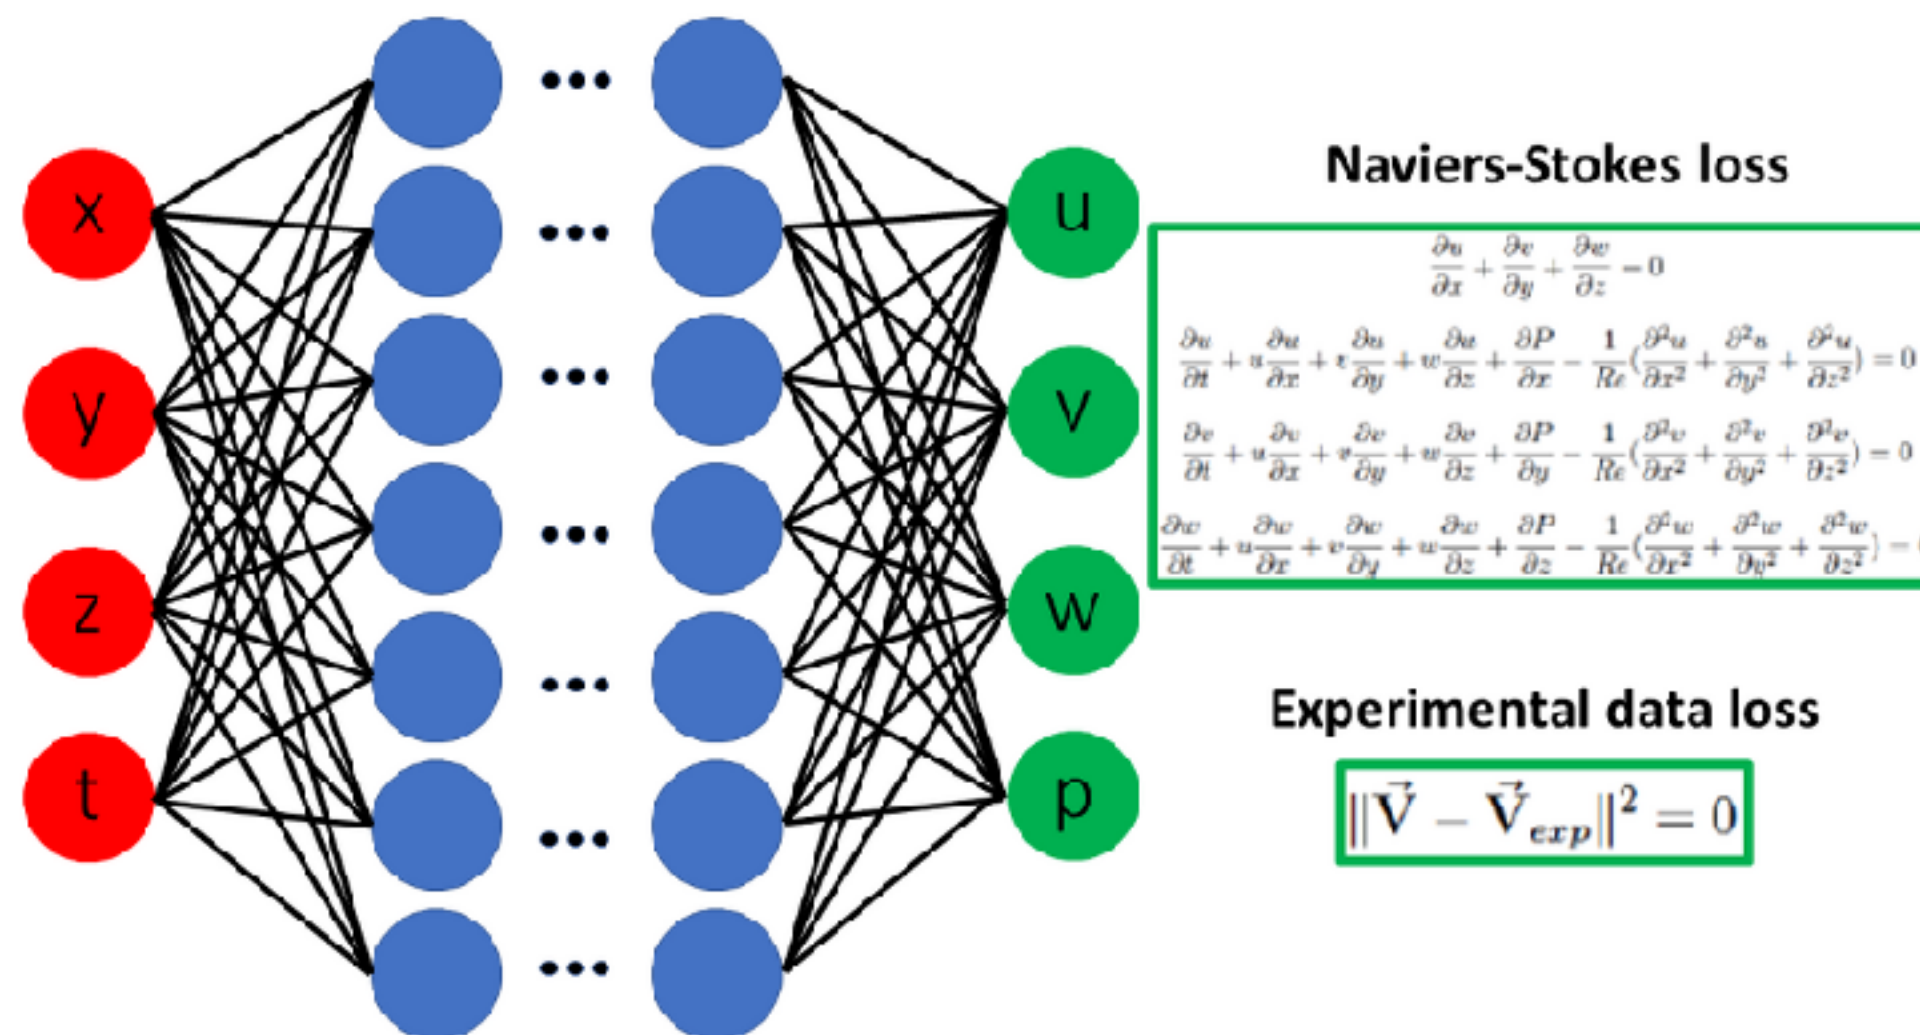
## Physics-Informed Neural Networks (PINN)



Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations

M. Raissi<sup>a</sup>, P. Perdikaris<sup>b</sup>, G.E. Karniadakis<sup>a</sup>

Cited by (10950)



# Neurális Reprezentációk



## Physics-Informed Neural Networks (PINN)



Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations

M. Raissi<sup>a</sup>, P. Perdikaris<sup>b</sup>, G.E. Karniadakis<sup>a</sup>

Cited by (10950)



# Neurális Reprezentációk




## Előnyök és hátrányok

- Előnyök (klasszikus diszkretizációs módszerekkel szemben):

- Adaptívitás
- Erős tömörítési ráta
- Differenciálhatóság
- Egyszerű implementáció

- Hátrányok:

- Költséges kiértékelés és optimalizáció
- Nehézkes interpretáció és módosíthatóság




**ReLU MLP:**  
adaptív szakaszosan lineáris  
függvény approximáció

# Neurális Implicit Felületek

- **Neurális implicit felület:** a 3D felületet egy  $F_\theta(x, y, z)$  neurális háló (implicit) szintfelületeként definiáljuk
- A neurális háló általában egyszerű architektúrájú (tipikusan MLP)
  - Kritikus implementációs részletek: koordináta beágyazás, aktivációs függvények, inicializáció, stb.
- A hálót tipikusan “túlillesztjük” egyetlen 3D modellre!
  - Nincs “tanulás” vagy “intelligencia” – a neurális háló csak egy sajátos függvény reprezentáció!!
- Pontfelhőre illesztés =  $\theta$  háló paraméterek optimalizációja (pl. SGD/ADAM) mintapontokban való illeszkedésre:

$$L(\theta) = \sum_i w_{p,i} ||F_\theta(\mathbf{p}_i) - f_i|| + w_{n,i} ||\nabla F_\theta(\mathbf{p}_i) - \mathbf{n}_i|| \rightarrow \min$$





# Neurális Implicit Felületek




## Eikonál regularizáció

- Érvényesítsük az “**eikonál**” (egység-gradiens) tulajdonságot (távolságmező szükséges feltétele):

$$\ell(\theta) = \ell_{\mathcal{X}}(\theta) + \lambda \mathbb{E}_{\mathbf{x}} \left( \|\nabla_{\mathbf{x}} f(\mathbf{x}; \theta)\| - 1 \right)^2$$

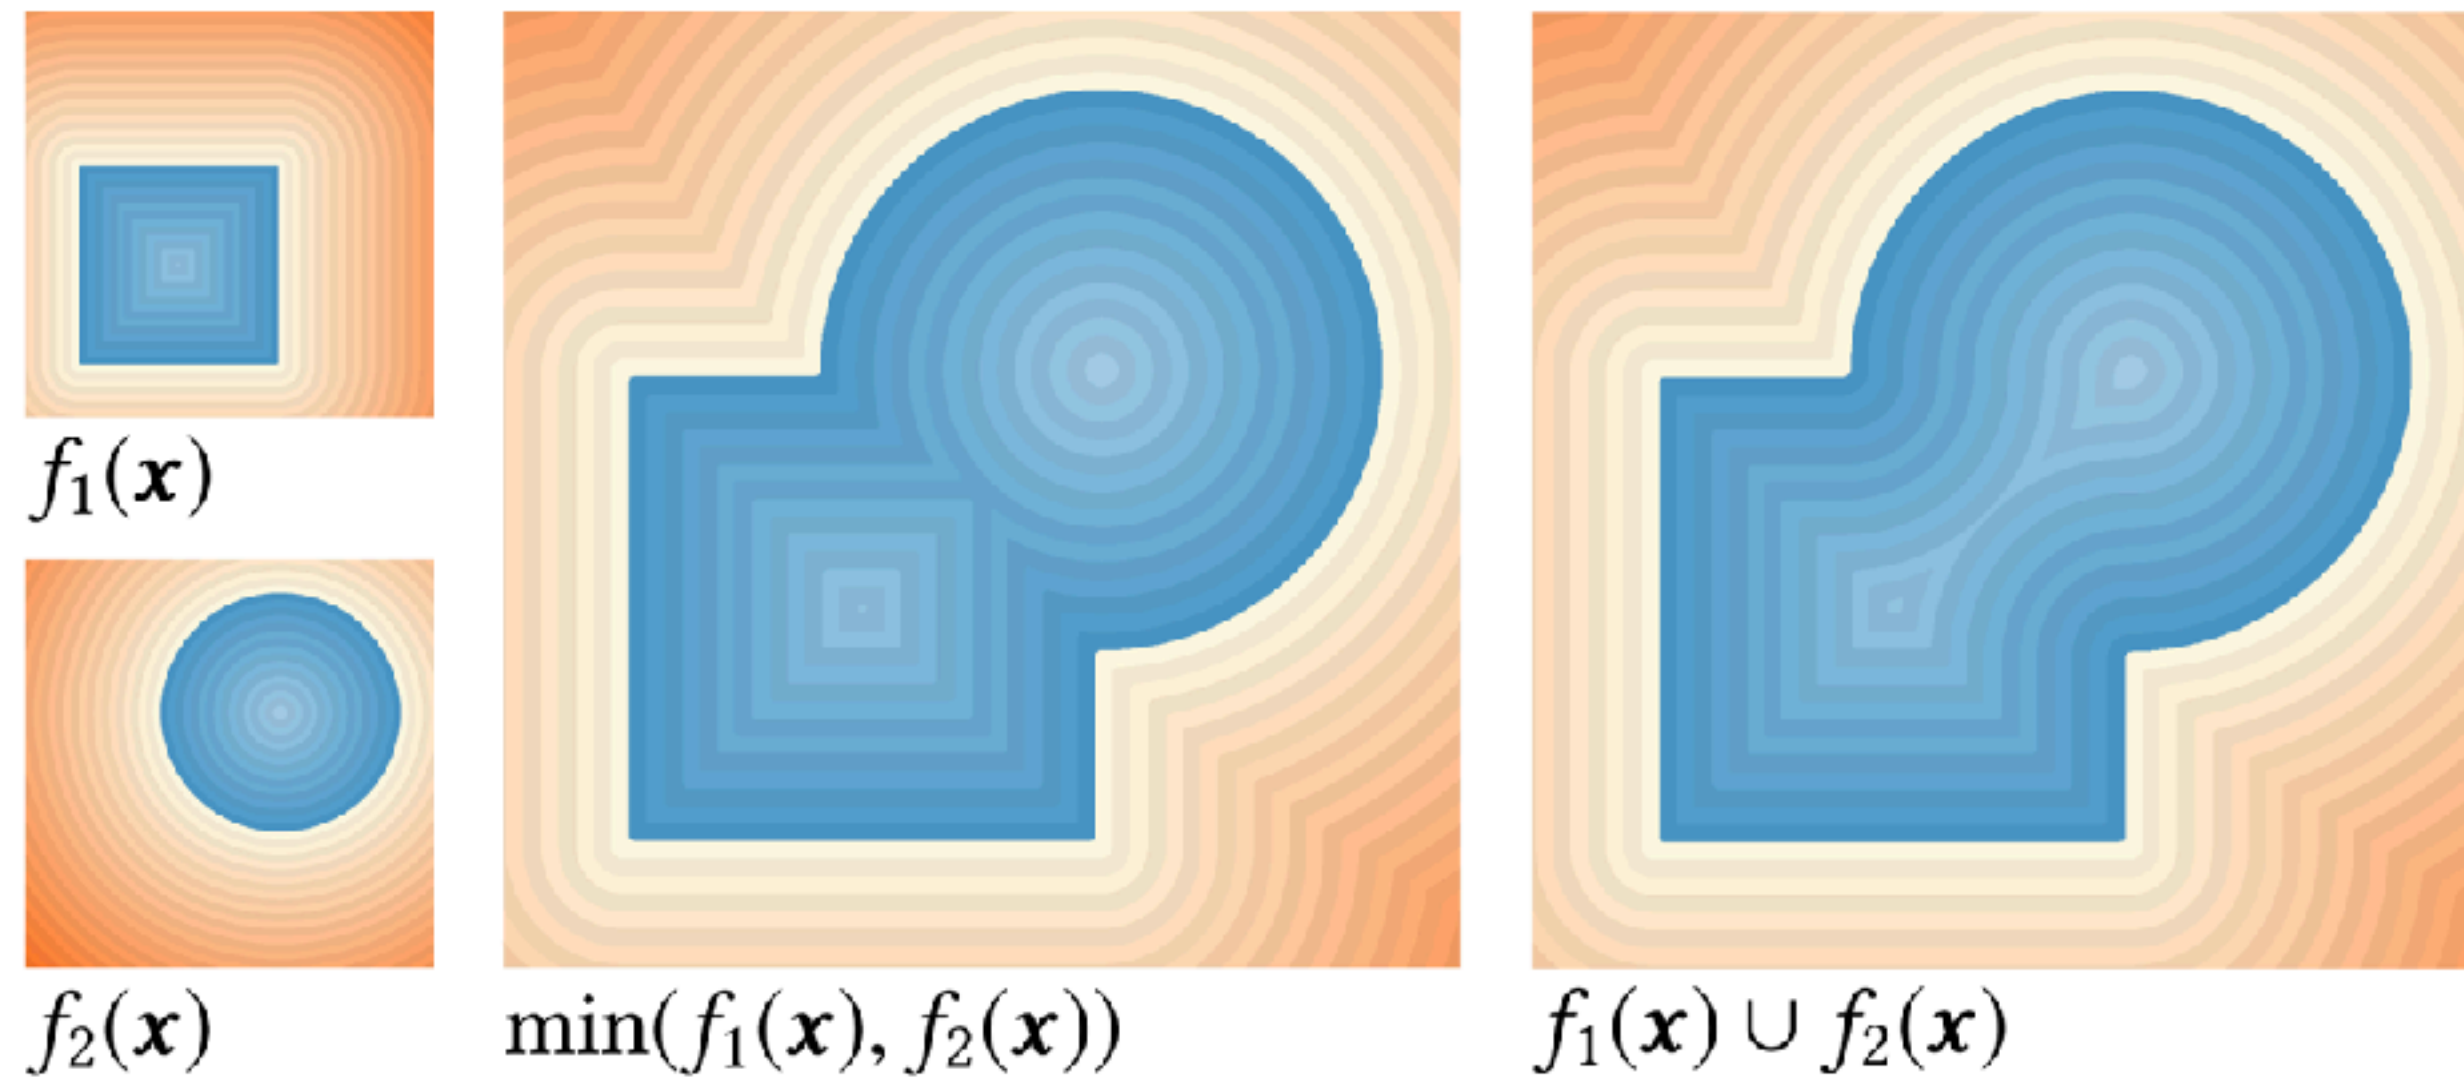
$$\ell_{\mathcal{X}}(\theta) = \frac{1}{|I|} \sum_{i \in I} \left( |f(\mathbf{x}_i; \theta)| + \tau \|\nabla_{\mathbf{x}} f(\mathbf{x}_i; \theta) - \mathbf{n}_i\| \right)$$

- PINN speciális esete
- Sík reprodukciós tulajdonság
- Gyakran használatos — de sajnos megvan az ára:
  - A loss-ban a deriváltak számításához két backprop pass (vagy numerikus differenciálás) szükséges!
  - Az egész téren mintavételezni kell!



# Neurális Implicit Felületek

## Boolean operációk

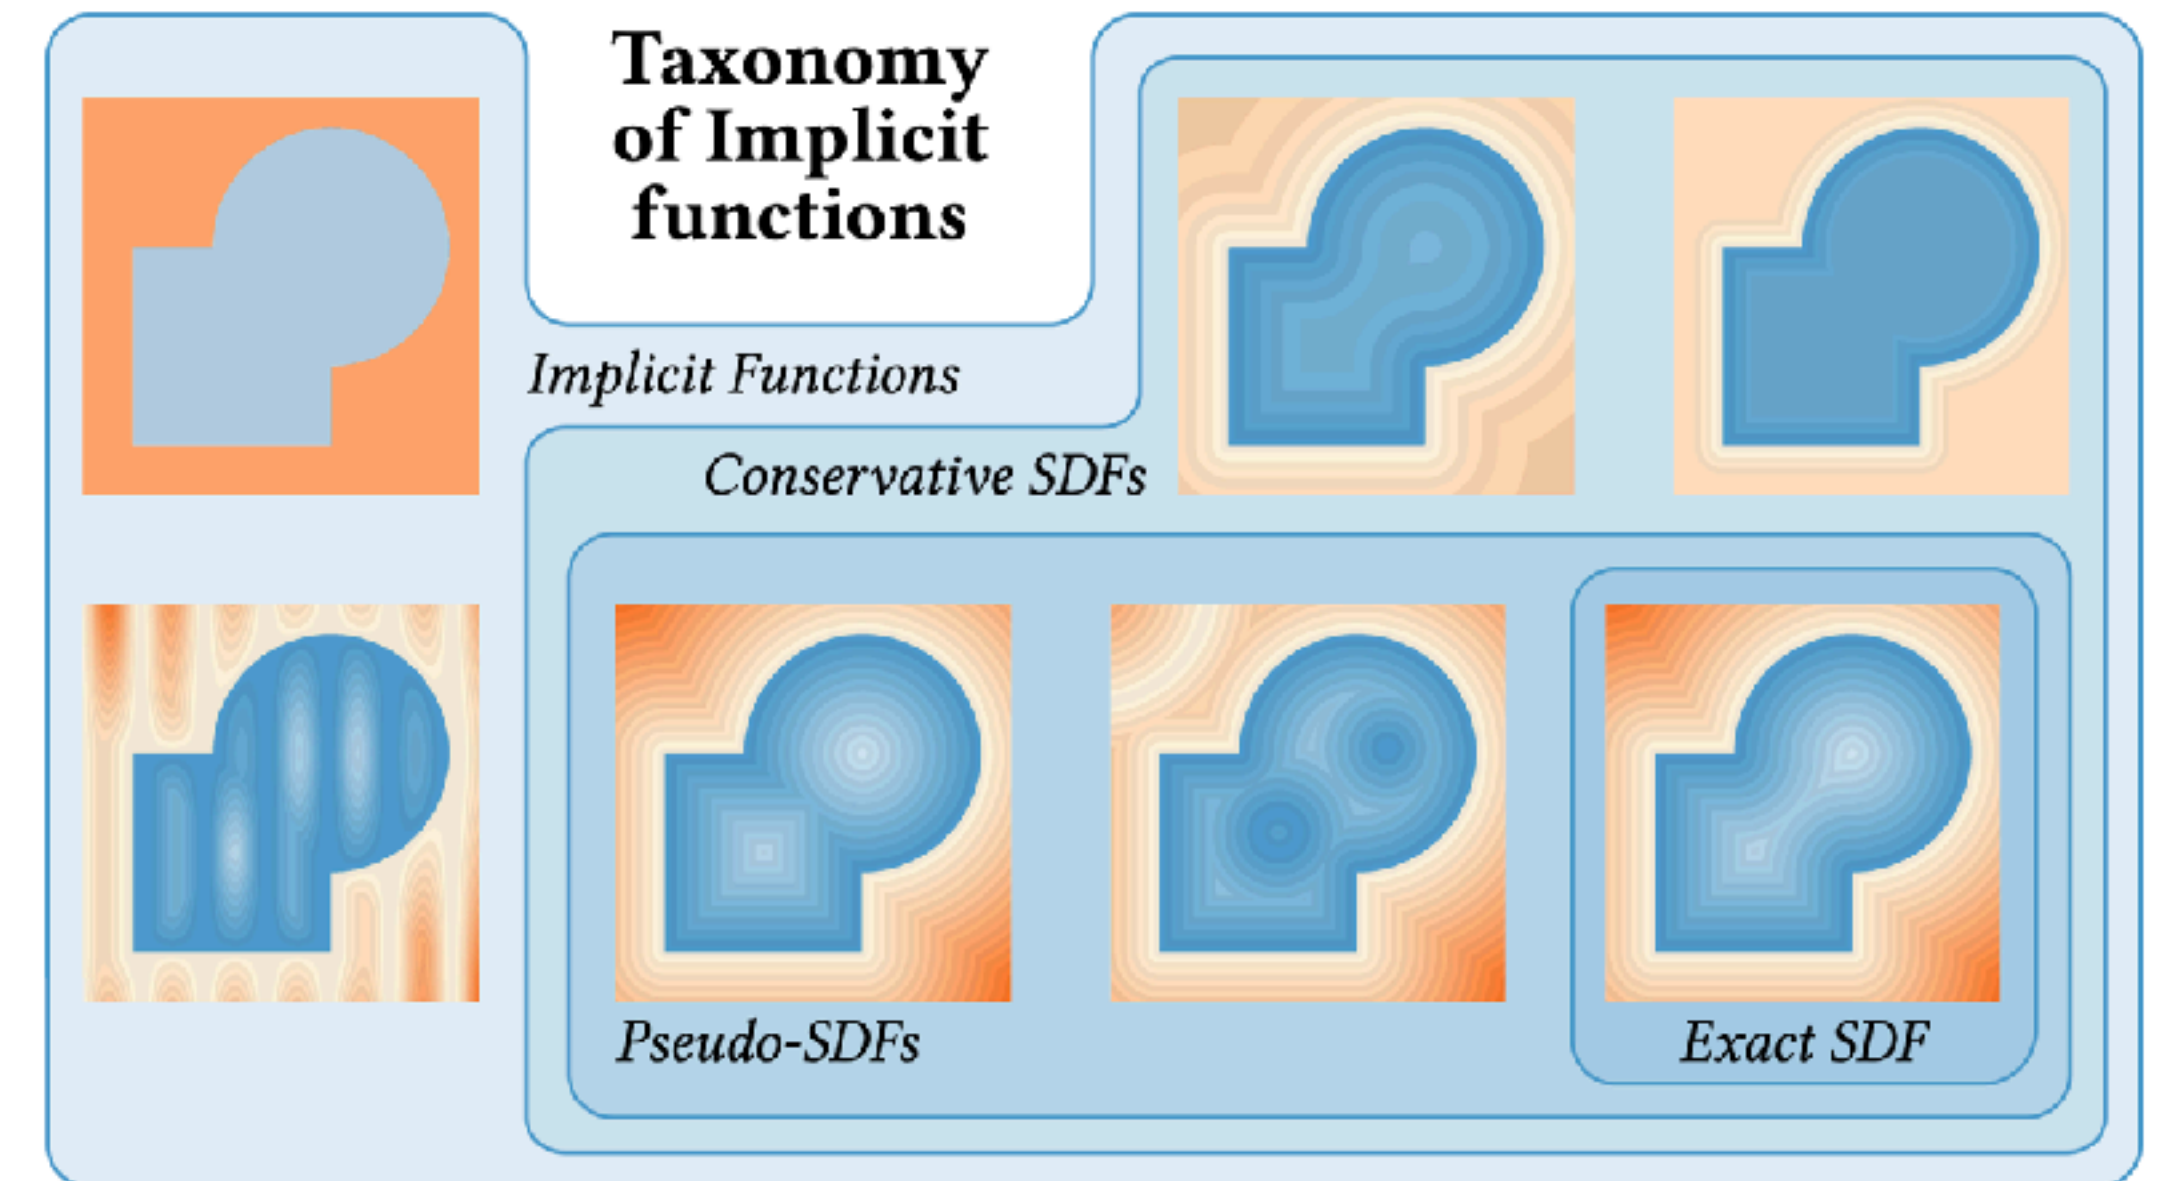


**SDF-ek Boolean-ja  $\neq$  Boolean SDF-je!!!**

Azonos 0 szintfelületek, de különböző implicit függvények!

$|\nabla f(x)| = 1$  (majdnem mindenhol) teljesül!


$|\nabla f(x)| = 1$ : SDF szükséges, de nem elégséges feltétele!



# Neurális Implicit Felületek


## Neurális CSG, regularizáció

### Constructive Solid Geometry on Neural Signed Distance Fields



$$E_{CP} = \frac{1}{|\mathcal{X}|} \sum_{x \in \mathcal{X}} f_{\theta}(x - f_{\theta}(x) \nabla_x f_{\theta}(x))^2$$

**Closest-point loss**

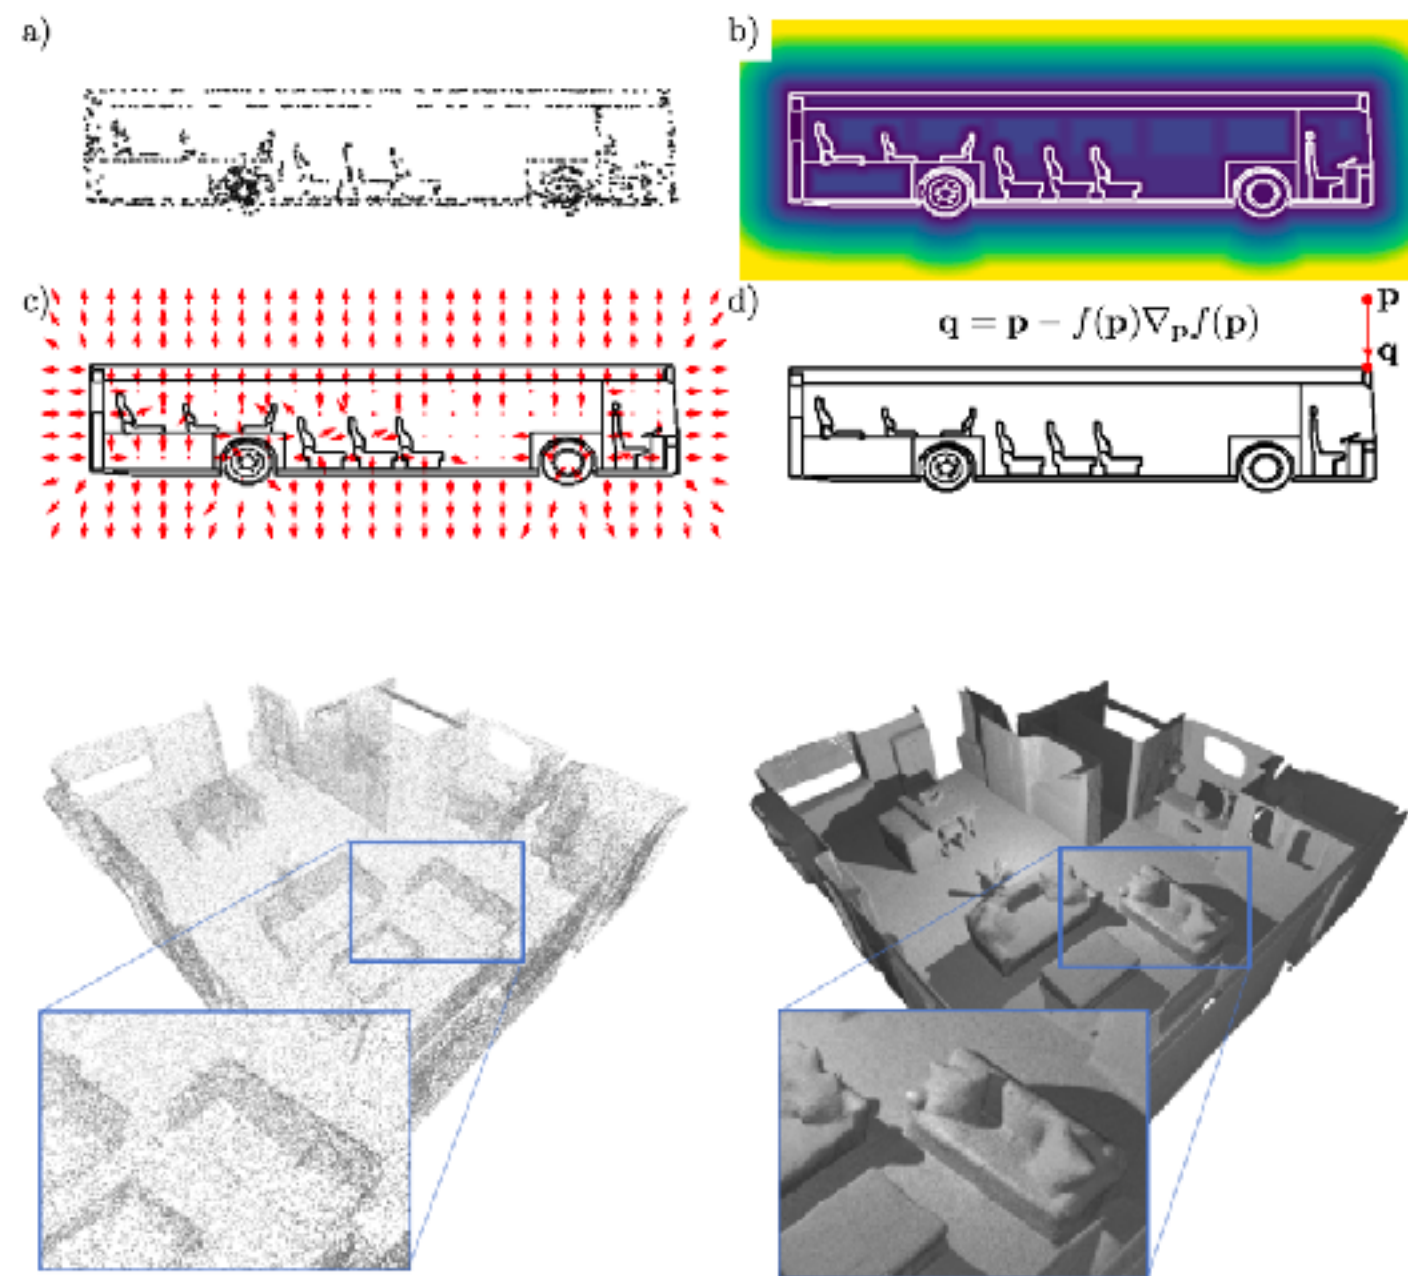


# Neurális Implicit Felületek

## Peremes felületek\*

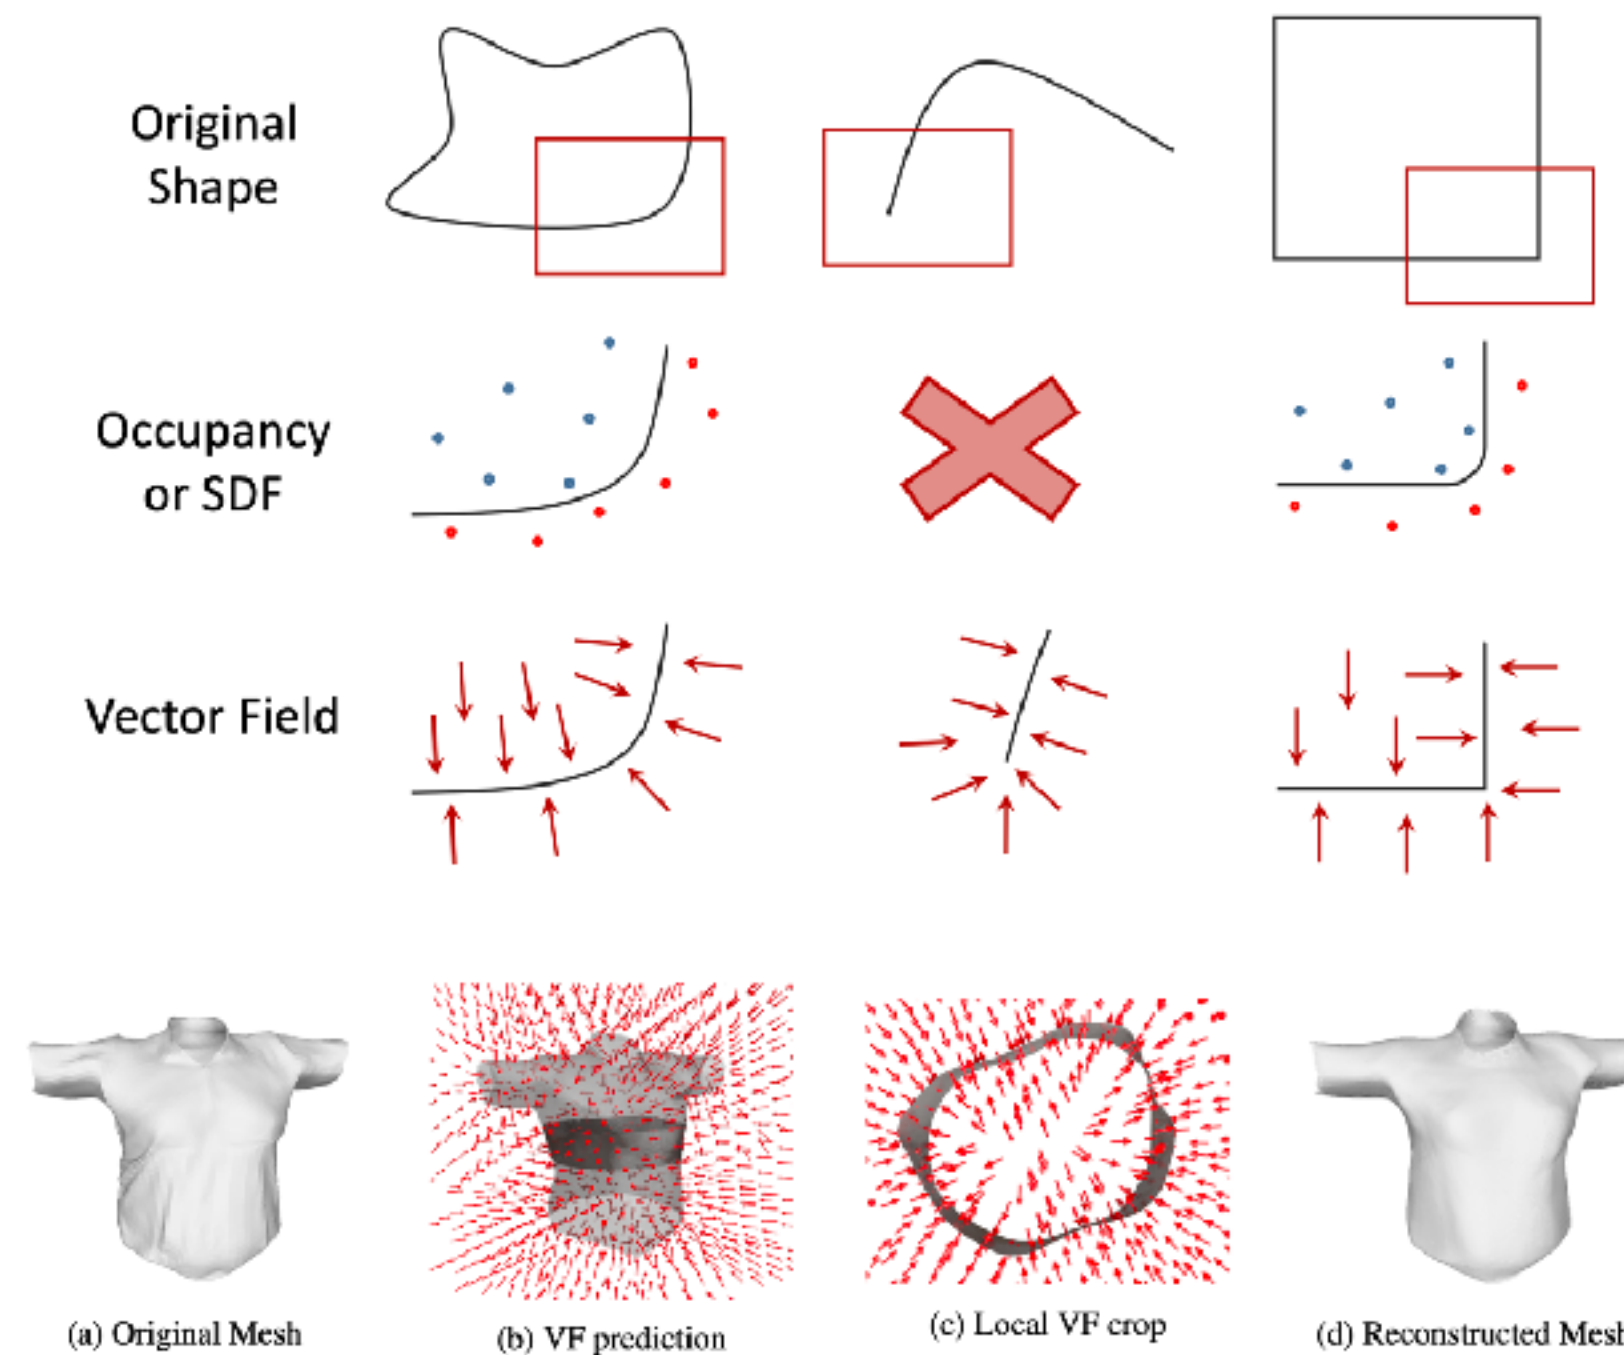
### Neural Unsigned Distance Fields for Implicit Function Learning

Julian Chibane    Aymen Mir    Gerard Pons-Moll



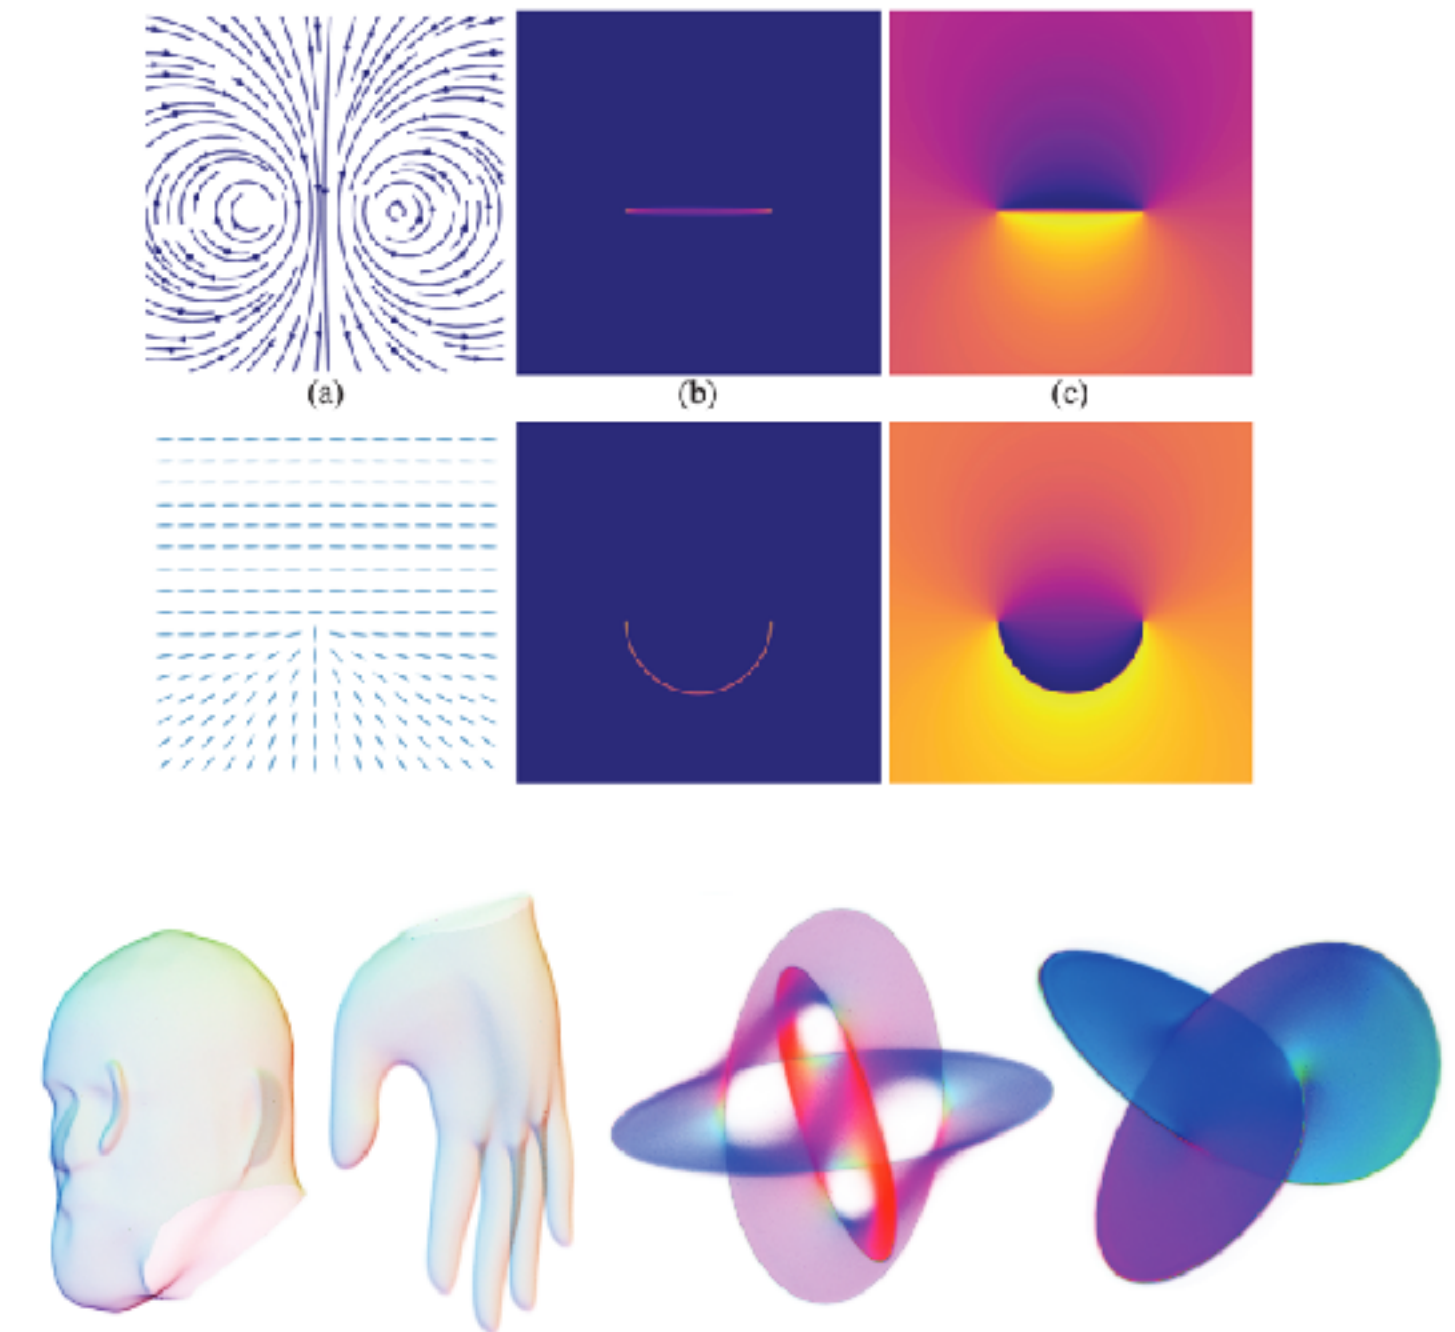
### Neural Vector Fields for Implicit Surface Representation and Inference

Edoardo Mello Rella<sup>1</sup>    Ajad Chhatkuli<sup>1</sup>    Ender Konukoglu<sup>1</sup>    Luc Van Gool<sup>1,2</sup>  
<sup>1</sup>Computer Vision Lab, ETH Zurich    <sup>2</sup>VISICS, KU Leuven



### DeepCurrents: Learning Implicit Representations of Shapes with Boundaries

David Palmer<sup>\*1</sup>    Dmitriy Smirnov<sup>\*1</sup>    Stephanie Wang<sup>2</sup>    Albert Chern<sup>2</sup>    Justin Solomon<sup>1</sup>  
<sup>1</sup>Massachusetts Institute of Technology    <sup>2</sup>UC San Diego




Közös gondolat: gradiens vektormező illesztése — számos variáció...

# Neurális Implicit Felületek

## Koordináta beágyazás – Motiváció


- Kísérlet: tanítsunk egy  $(X, Y) \mapsto (R, G, B)$  **ReLU** MLP-t egy adott kép reprodukciójára (pl. L2 pixel hibát optimalizálva)
- Eredmény: homályos kép (még ha több neuron van, mint ahány pixel)!
- Miért?



# Neurális Implicit Felületek

## Koordináta beágyazás – Motiváció


- Kísérlet: tanítsunk egy  $(X, Y) \mapsto (R, G, B)$  **ReLU** MLP-t egy adott kép reprodukciójára (pl. L2 pixel hibát optimalizálva)
- Eredmény: homályos kép (még ha több neuron van, mint ahány pixel)!
- Miért?



# Neurális Implicit Felületek


## Koordináta beágyazás – Motiváció

- Megfigyelés: egy betanított ReLU MLP tkp. aluláteresztő szűrést végez a tanító adatpontokon (“Neural Tangent Kernel”)!
  - “Spectral bias”: egy ReLU MLP egy függvény alacsonyfrekvenciás komponenseit tudja legkönnyebben reprodukálni
- Magas dimenziójú adatokra ez kifejezetten előnyös (“implicit regularizáció” egy példája)
- Alacsony dimenziójú adatokra már nem mindig ezt szeretnénk...



On the Spectral Bias of Neural Networks


Nasim Rahaman<sup>\*1,2</sup> Aristide Baratin<sup>\*1</sup> Devansh Arpit<sup>1</sup> Felix Draxler<sup>2</sup> Min Lin<sup>1</sup> Fred A. Hamprecht<sup>2</sup>  
Yoshua Bengio<sup>1</sup> Aaron Courville<sup>1</sup>



# Neurális Implicit Felületek

## Koordináta beágyazás


- Direkt  $(x, y, z)$  bemenettel tanítva egy ReLU MLP csak kisméretű geometriát képes jól közelíteni...
- Megoldás: **koordináta beágyazás** (coordinate embedding)
  - Ld. transformer koordináta enkódolás!
- *Mindig* használjuk, ha ReLU hálóval közelítünk implicit függvényt!



Fourier Features Let Networks Learn High Frequency Functions in Low Dimensional Domains

NeurIPS 2020 (spotlight)

Matthew Tancik\* UC Berkeley  
 Pratul Srinivasan\* UC Berkeley  
 Ben Mildenhall\* UC Berkeley  
 Sara Fridovich-Keil UC Berkeley  
 Nithin Raghavan UC Berkeley  
 Utkarsh Singhal UC Berkeley  
 Ravi Ramamoorthi UC San Diego  
 Jonathan T. Barron Google Research  
 Ren Ng UC Berkeley



$$\gamma(\mathbf{x}) = [\gamma_1(\mathbf{x}), \dots, \gamma_n(\mathbf{x})]$$

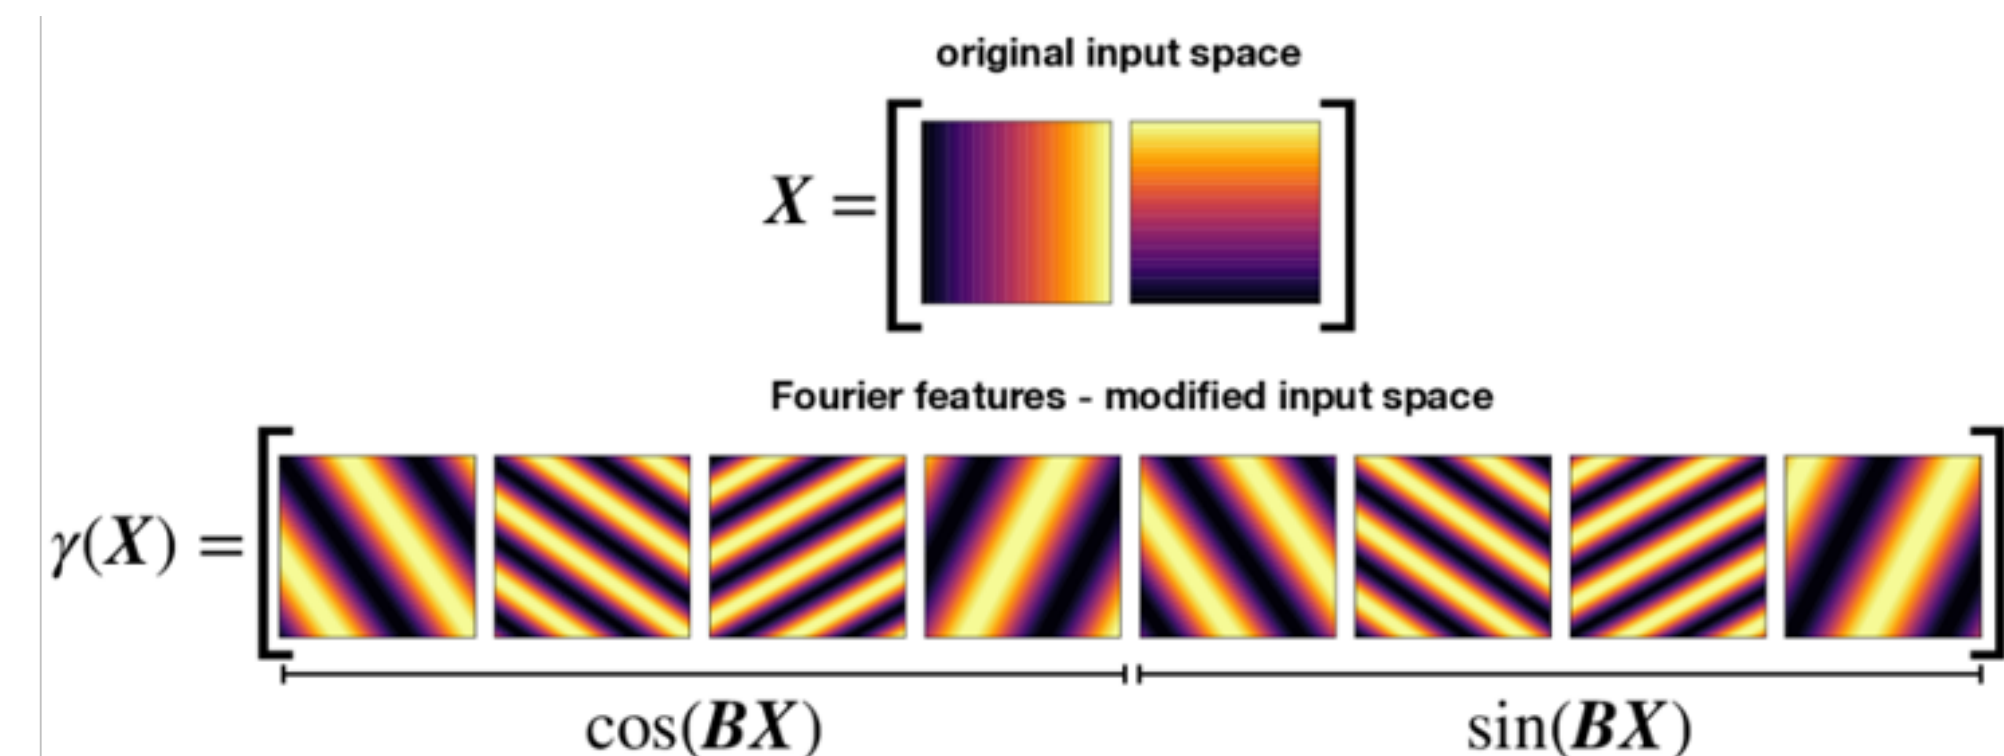
$$\gamma_{2i}(\mathbf{x}) = \sin(2^{i-1}\pi x_i)$$

$$\gamma_{(2i+1)}(\mathbf{x}) = \cos(2^{i-1}\pi x_i)$$

**Sinusoidal Embeddings**  
 Zhong et al. ICLR 2020  
 Mildenhall et al., ECCV 2020


$$\gamma(\mathbf{x}) = \exp\left(-\frac{\|t - x\|^2}{2\sigma^2}\right)$$

**Gaussian Embeddings**  
 Zheng et al., arXiv 2021



# Neurális Implicit Felületek

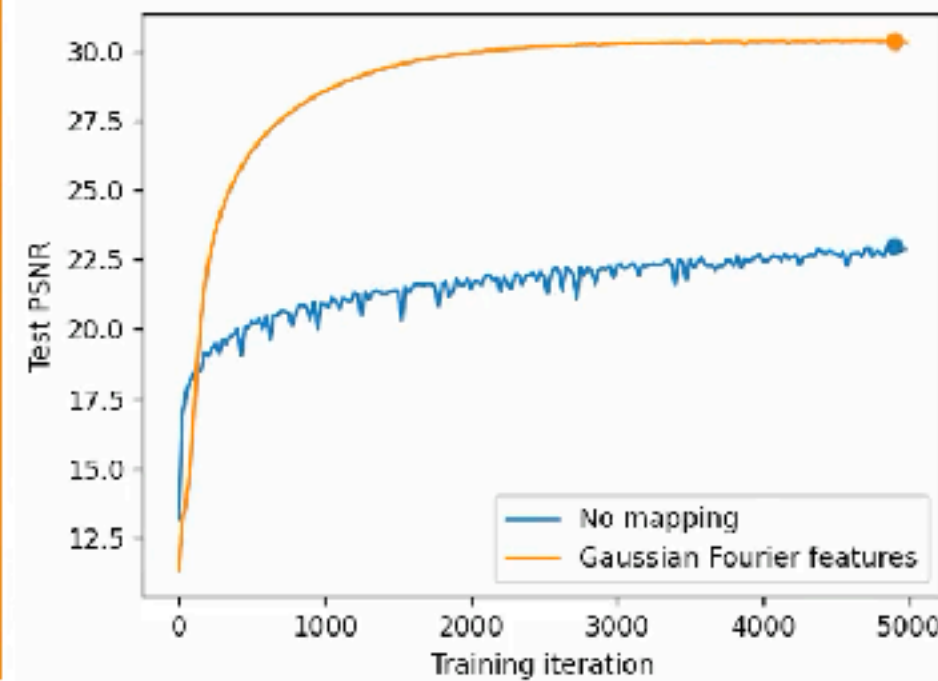
## Koordináta beágyazás



|   |   |   |  |  |
|---|---|---|--|--|
| No Fourier features<br>$\gamma(\mathbf{v}) = \mathbf{v}$              |   |   |  |  |
| With Fourier features<br>$\gamma(\mathbf{v}) = \text{FF}(\mathbf{v})$ |   |   |  |  |
|   | (b) Image regression<br>$(x, y) \rightarrow \text{RGB}$ | (c) 3D shape regression<br>$(x, y, z) \rightarrow \text{occupancy}$ | (d) MRI reconstruction<br>$(x, y, z) \rightarrow \text{density}$ | (e) Inverse rendering<br>$(x, y, z) \rightarrow \text{RGB, density}$ |

# Neurális Implicit Felületek

## Koordináta beágyazás



|   |   |   |  |  |
|---|---|---|--|--|
| No Fourier features<br>$\gamma(\mathbf{v}) = \mathbf{v}$              |   |   |  |  |
| With Fourier features<br>$\gamma(\mathbf{v}) = \text{FF}(\mathbf{v})$ |   |   |  |  |
|   | (b) Image regression<br>$(x, y) \rightarrow \text{RGB}$ | (c) 3D shape regression<br>$(x, y, z) \rightarrow \text{occupancy}$ | (d) MRI reconstruction<br>$(x, y, z) \rightarrow \text{density}$ | (e) Inverse rendering<br>$(x, y, z) \rightarrow \text{RGB, density}$ |

# Neurális Implicit Felületek

## SIREN

- Koordináta beágyazás: 1 db szinusz-függvény réteg
- **Sinusoidal Representation Networks (SIREN)** – ReLU aktivációkat cseréljük szinusz-függvényekre!

$$\Phi(\mathbf{x}) = \mathbf{W}_n (\phi_{n-1} \circ \phi_{n-2} \circ \dots \circ \phi_0)(\mathbf{x}) + \mathbf{b}_n, \quad \mathbf{x}_i \mapsto \phi_i(\mathbf{x}_i) = \sin(\mathbf{W}_i \mathbf{x}_i + \mathbf{b}_i)$$

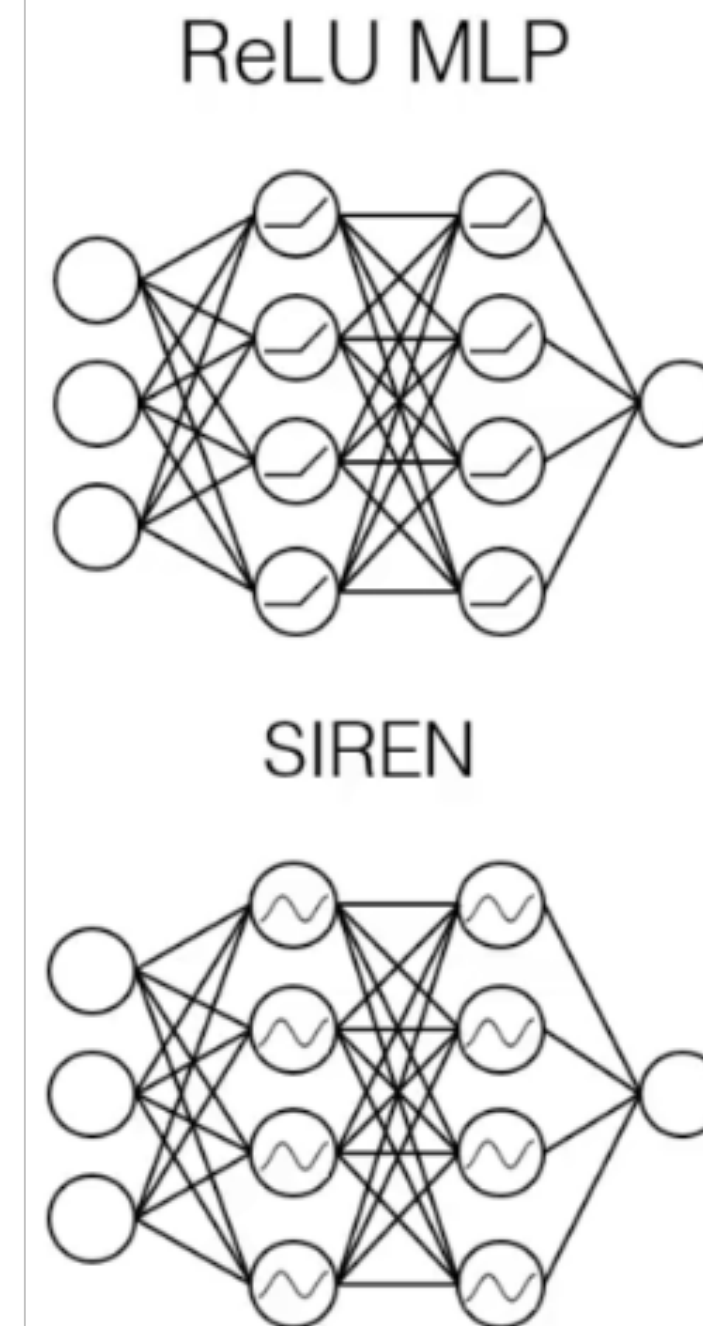


- Sokkal jobban reprodukálja a nagyfrekvenciás részleteket, mint a ReLU!

$$\mathcal{L}_{\text{sdf}} = \int_{\Omega} \left\| |\nabla_{\mathbf{x}} \Phi(\mathbf{x})| - 1 \right\| d\mathbf{x} + \int_{\Omega_0} \|\Phi(\mathbf{x})\| + (1 - \langle \nabla_{\mathbf{x}} \Phi(\mathbf{x}), \mathbf{n}(\mathbf{x}) \rangle) d\mathbf{x} + \int_{\Omega \setminus \Omega_0} \psi(\Phi(\mathbf{x})) d\mathbf{x}$$

$$\psi(\mathbf{x}) = \exp(-\alpha \cdot |\Phi(\mathbf{x})|), \alpha \gg 1$$

(Felülettől távoli  $\Phi(\mathbf{x}) = 0$  értékek büntetése)

- Speciális inicializációt igényel
- Jó default neurális implicit reprezentációra



# Neurális Implicit Felületek

## SIREN

- Koordináta beágyazás: 1 db szinusz-függvény réteg
- **Sinusoidal Representation Networks (SIREN)** – ReLU aktivációkat cseréljük szinusz-függvényekre!

$$\Phi(\mathbf{x}) = \mathbf{W}_n (\phi_{n-1} \circ \phi_{n-2} \circ \dots \circ \phi_0)(\mathbf{x}) + \mathbf{b}_n, \quad \mathbf{x}_i \mapsto \phi_i(\mathbf{x}_i) = \sin(\mathbf{W}_i \mathbf{x}_i + \mathbf{b}_i)$$



- Sokkal jobban reprodukálja a nagyfrekvenciás részleteket, mint a ReLU!

$$\mathcal{L}_{\text{sdf}} = \int_{\Omega} \left\| |\nabla_{\mathbf{x}} \Phi(\mathbf{x})| - 1 \right\| d\mathbf{x} + \int_{\Omega_0} \|\Phi(\mathbf{x})\| + (1 - \langle \nabla_{\mathbf{x}} \Phi(\mathbf{x}), \mathbf{n}(\mathbf{x}) \rangle) d\mathbf{x} + \int_{\Omega \setminus \Omega_0} \psi(\Phi(\mathbf{x})) d\mathbf{x}.$$

$$\psi(\mathbf{x}) = \exp(-\alpha \cdot |\Phi(\mathbf{x})|), \alpha \gg 1$$

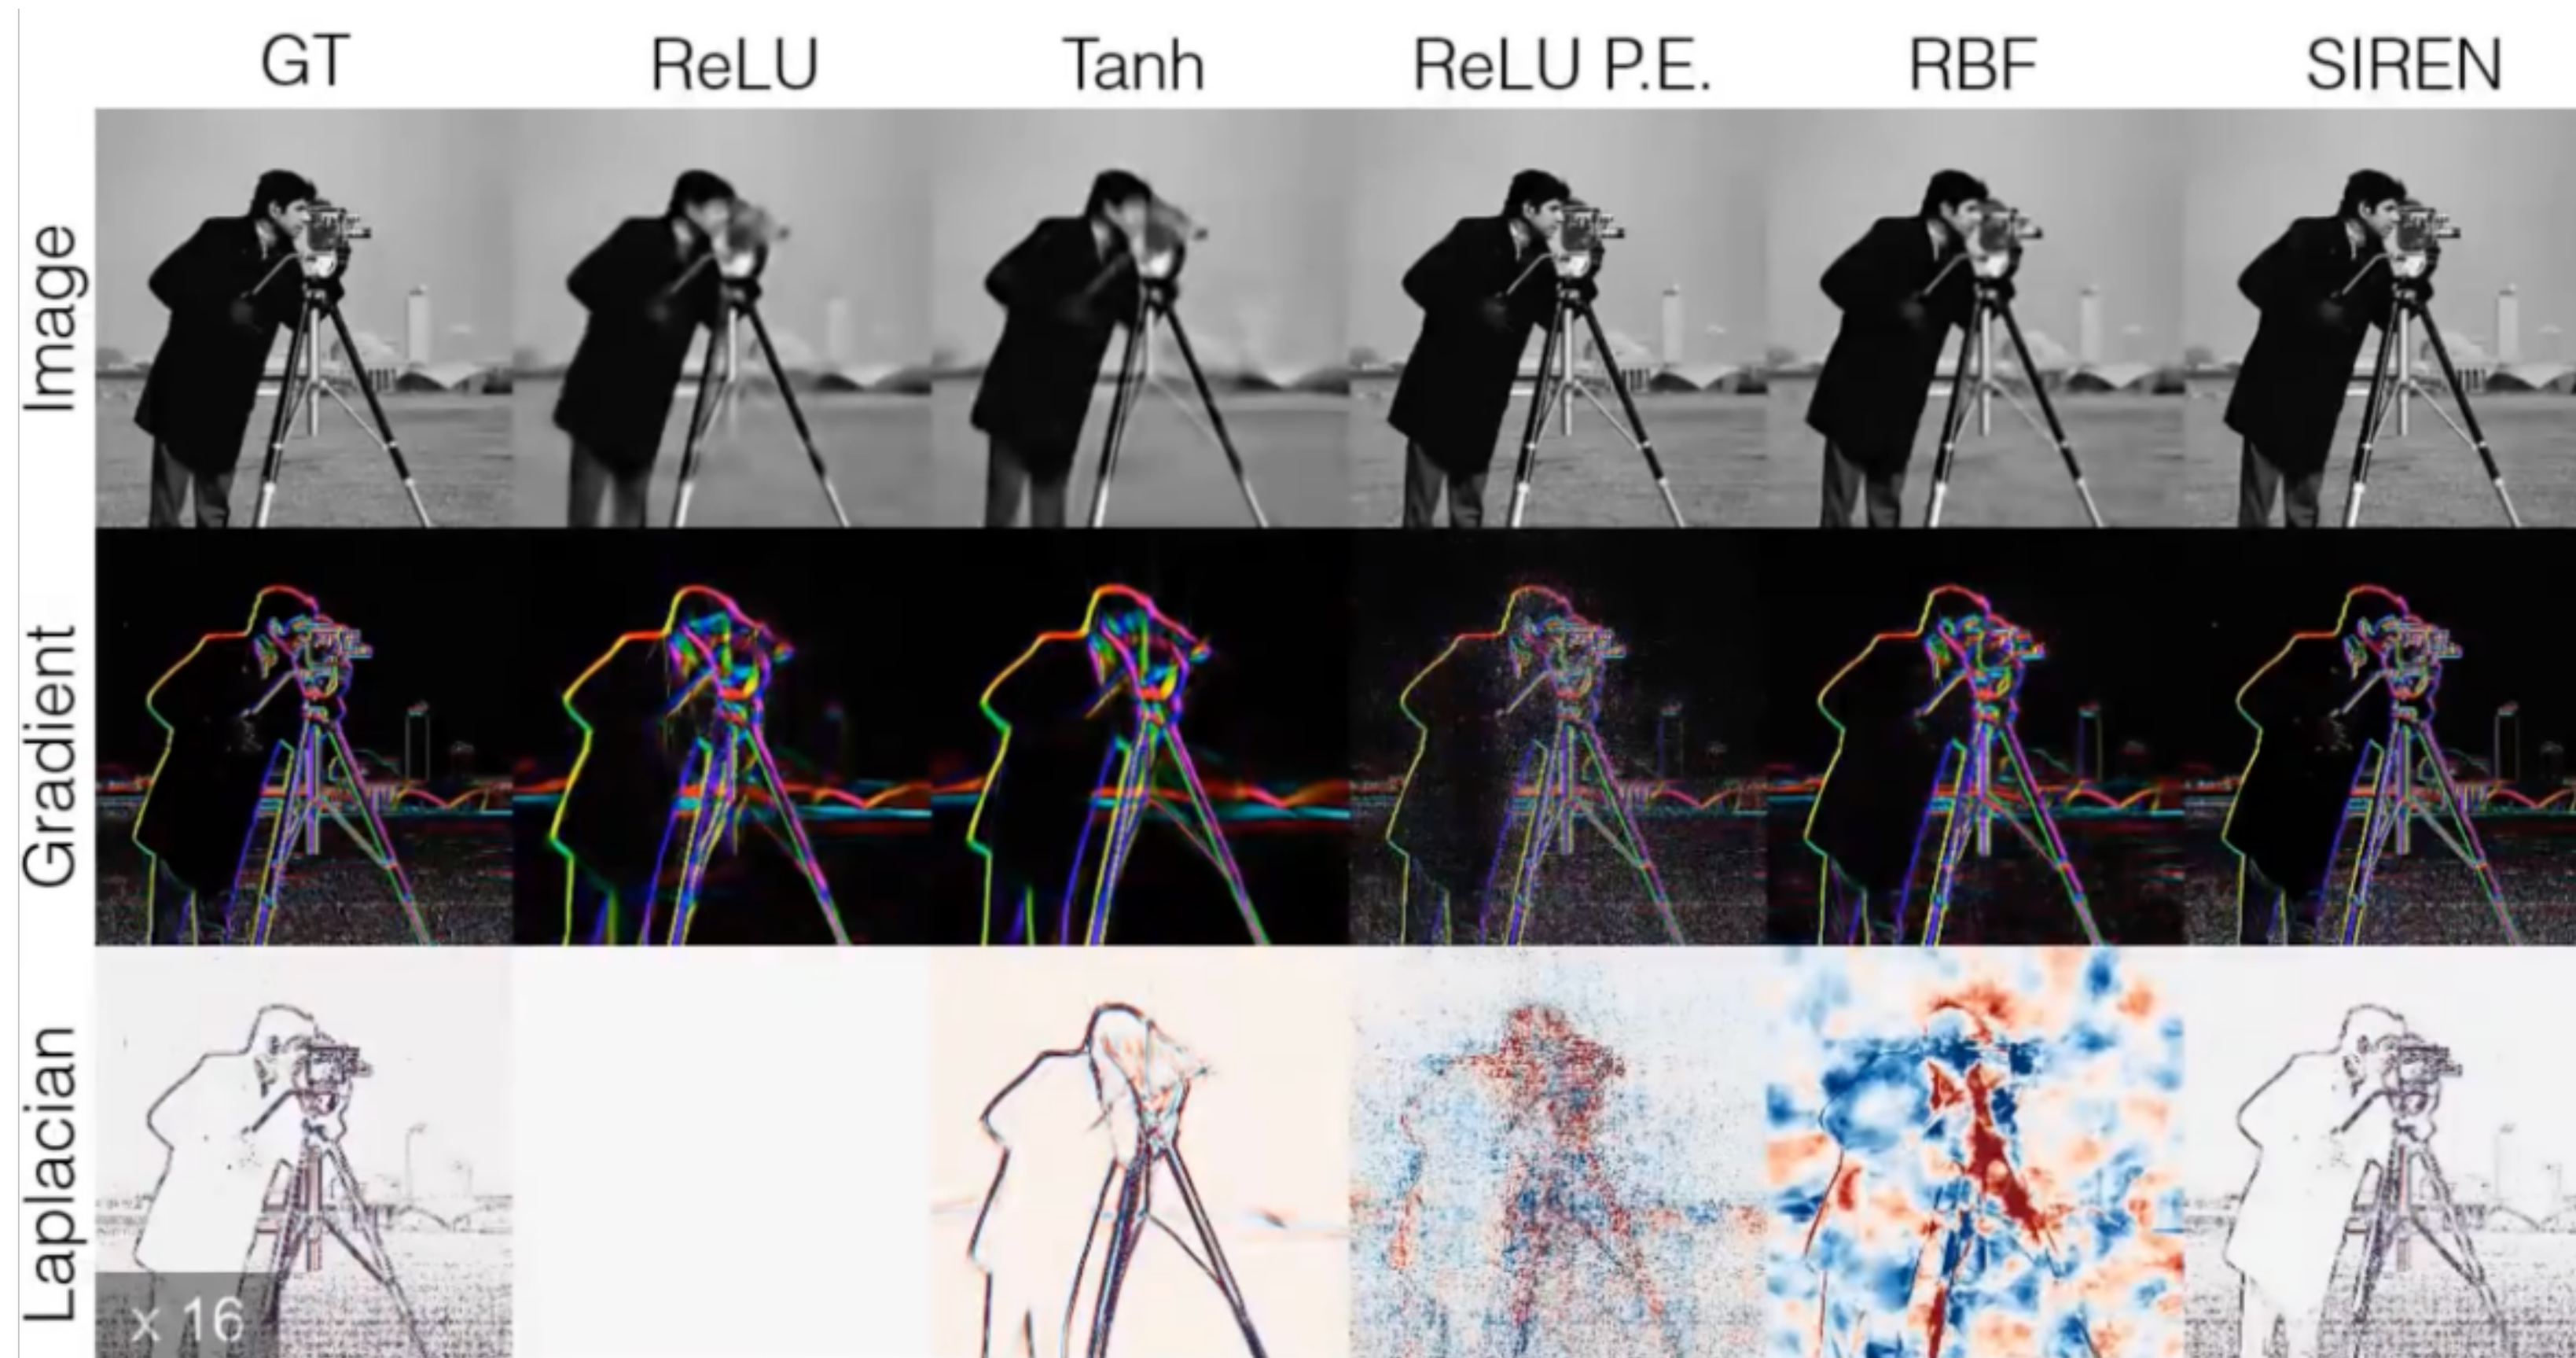
(Felülettől távoli  $\Phi(\mathbf{x}) = 0$  értékek büntetése)

- Speciális inicializációt igényel
- Jó default neurális implicit reprezentációra



# Neurális Implicit Felületek

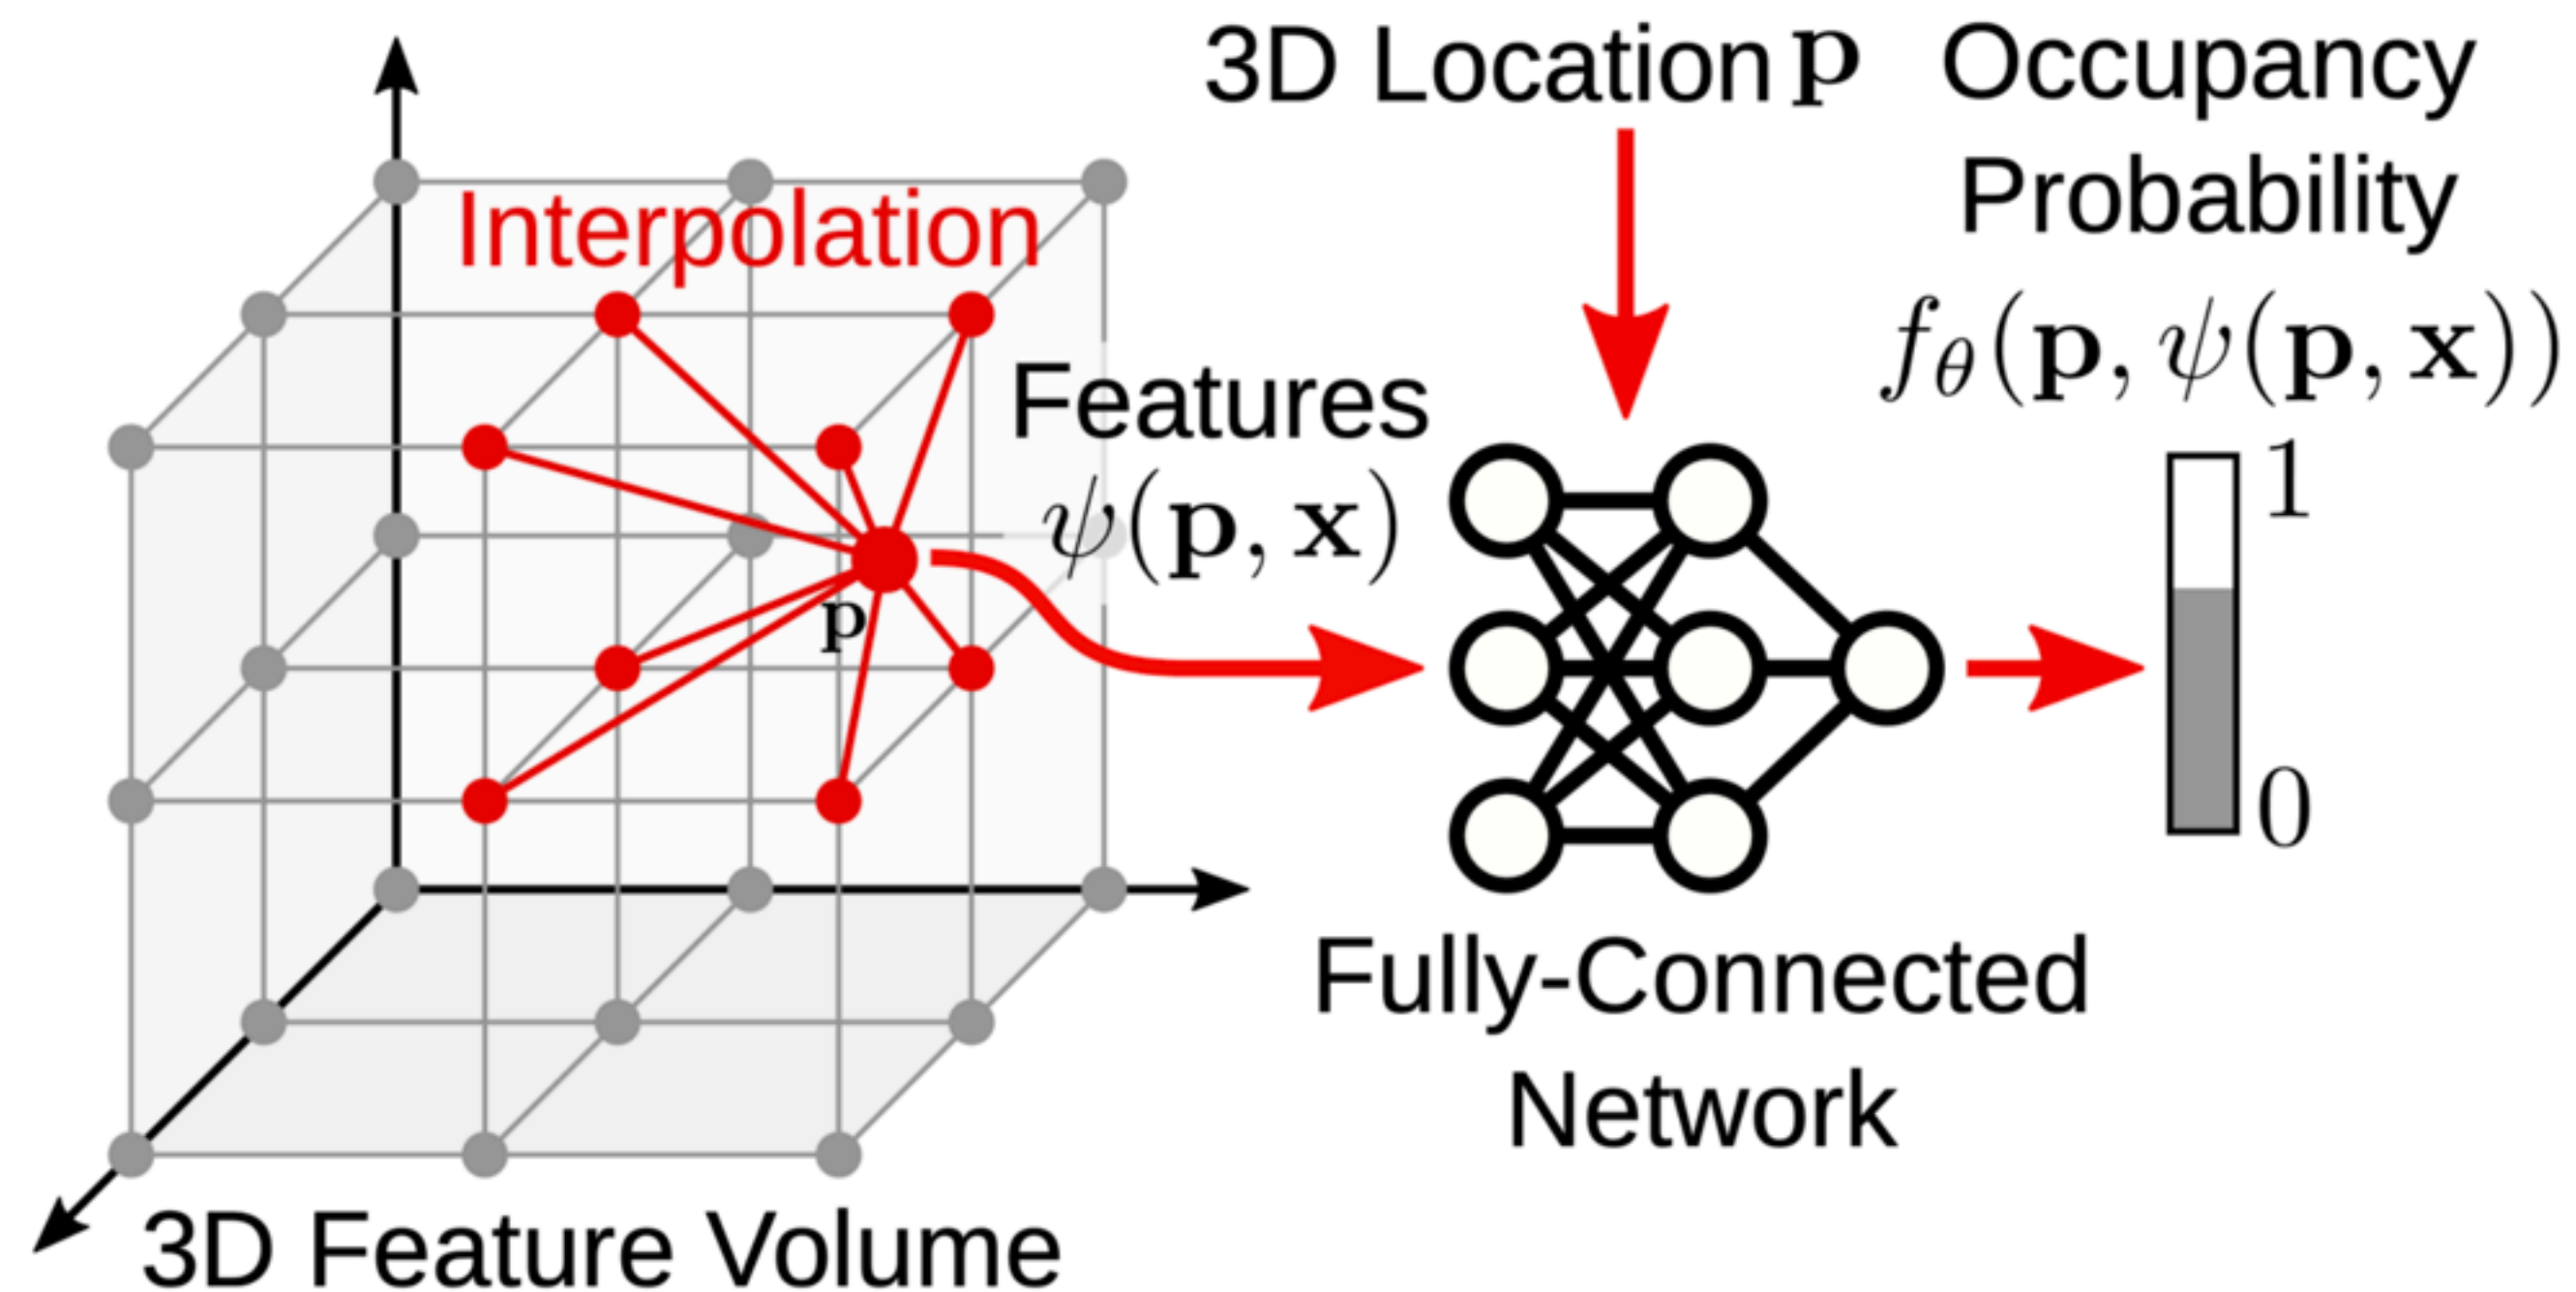
## SIREN



Egy SIREN háló minden deriváltja maga is SIREN háló!!

# Neurális Implicit Felületek

## Hibrid reprezentációk



Neurális háló, mint "interpolációs kernel"


# Neurális Implicit Felületek

## Hibrid reprezentációk


- Ezidáig: minden információt a neurális háló paramétereiben tároltunk
- **Hibrid / struktúrált reprezentáció:** kombináljunk egy térbeli adatstruktúrát egy neurális hálóval
- Tipikusan: az adatstruktúrában látens vektorokat tárolunk — a(z esetleg interpolált) látens kódot egy neurális háló dekódolja pl. távolság értéké
- A neurális háló ezáltal kisebb/egyszerűbb lehet — az információ “megoszlik” a látens kódok és a háló között!
- Számos variáció lehetséges...

## Convolutional Occupancy Networks


Songyou Peng<sup>1,2</sup> Michael Niemeyer<sup>2,3</sup> Lars Mescheder<sup>2,4\*</sup>  
Marc Pollefeys<sup>1,5</sup> Andreas Geiger<sup>2,3</sup>



(c) Convolutional Single-Plane Decoder



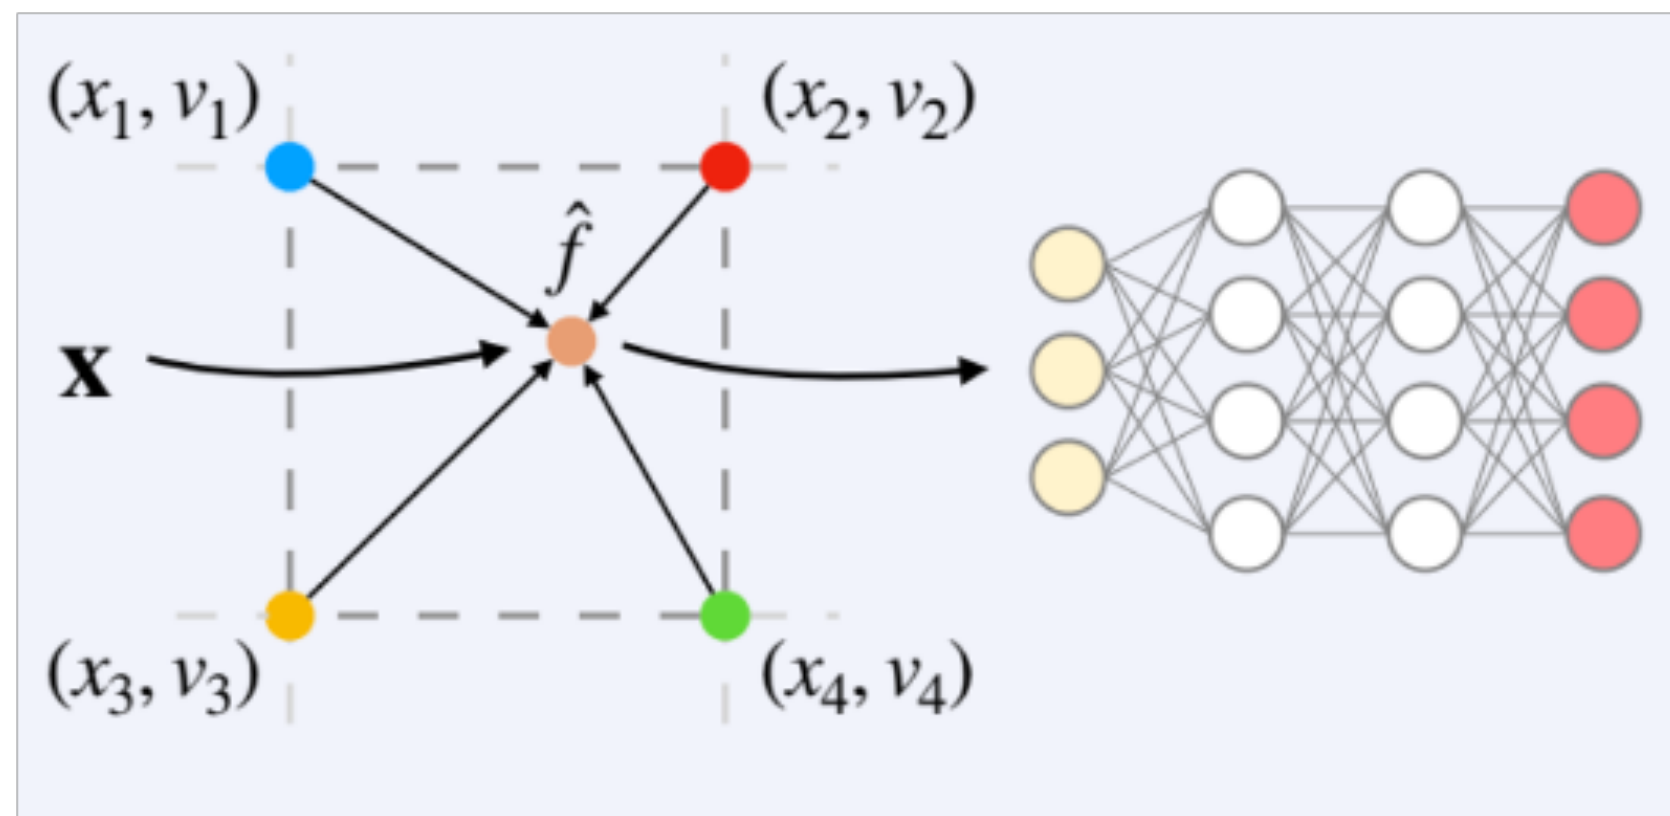
(d) Convolutional Multi-Plane Decoder




(e) Convolutional Volume Decoder

# Neurális Implicit Felületek


## Hibrid reprezentációk – Példák



Látens rács





Tri-plane



Látens halmaz (attention)

# Neurális Implicit Felületek

## Hibrid reprezentációk – Neurális Level-of-Detail



DeepSDF [39]


FFN [47]

SIREN [45]

Neural Implicits [9]

Ours / LOD 5

Reference



7.63 KB

19.25 KB

903.63 KB

56.00 KB

210.75 KB

2

2.5

3

3.5

4

# Neurális Implicit Felületek

## Hibrid reprezentációk – Instant NGP

Instant Neural Graphics Primitives with a Multiresolution Hash Encoding

THOMAS MÜLLER, NVIDIA, Switzerland


ALEX EVANS, NVIDIA, United Kingdom

CHRISTOPH SCHIED, NVIDIA, USA

ALEXANDER KELLER, NVIDIA, Germany

<https://nvlabs.github.io/instant-ngp>

SIGGRAPH Best Paper  
TIME's Best Inventions of 2022



Egymásba ágyazott térbeli hash táblák + kicsi MLP



Optimalizált GPU implementáció – *villámgyors* tanítás & kiértékelés!

# Neurális Implicit Felületek

## Hibrid reprezentációk – Instant NGP

Instant Neural Graphics Primitives with a Multiresolution Hash Encoding

THOMAS MÜLLER, NVIDIA, Switzerland


ALEX EVANS, NVIDIA, United Kingdom

CHRISTOPH SCHIED, NVIDIA, USA

ALEXANDER KELLER, NVIDIA, Germany

<https://nvlabs.github.io/instant-ngp>

SIGGRAPH Best Paper  
TIME's Best Inventions of 2022



Egymásba ágyazott térbeli hash táblák + kicsi MLP




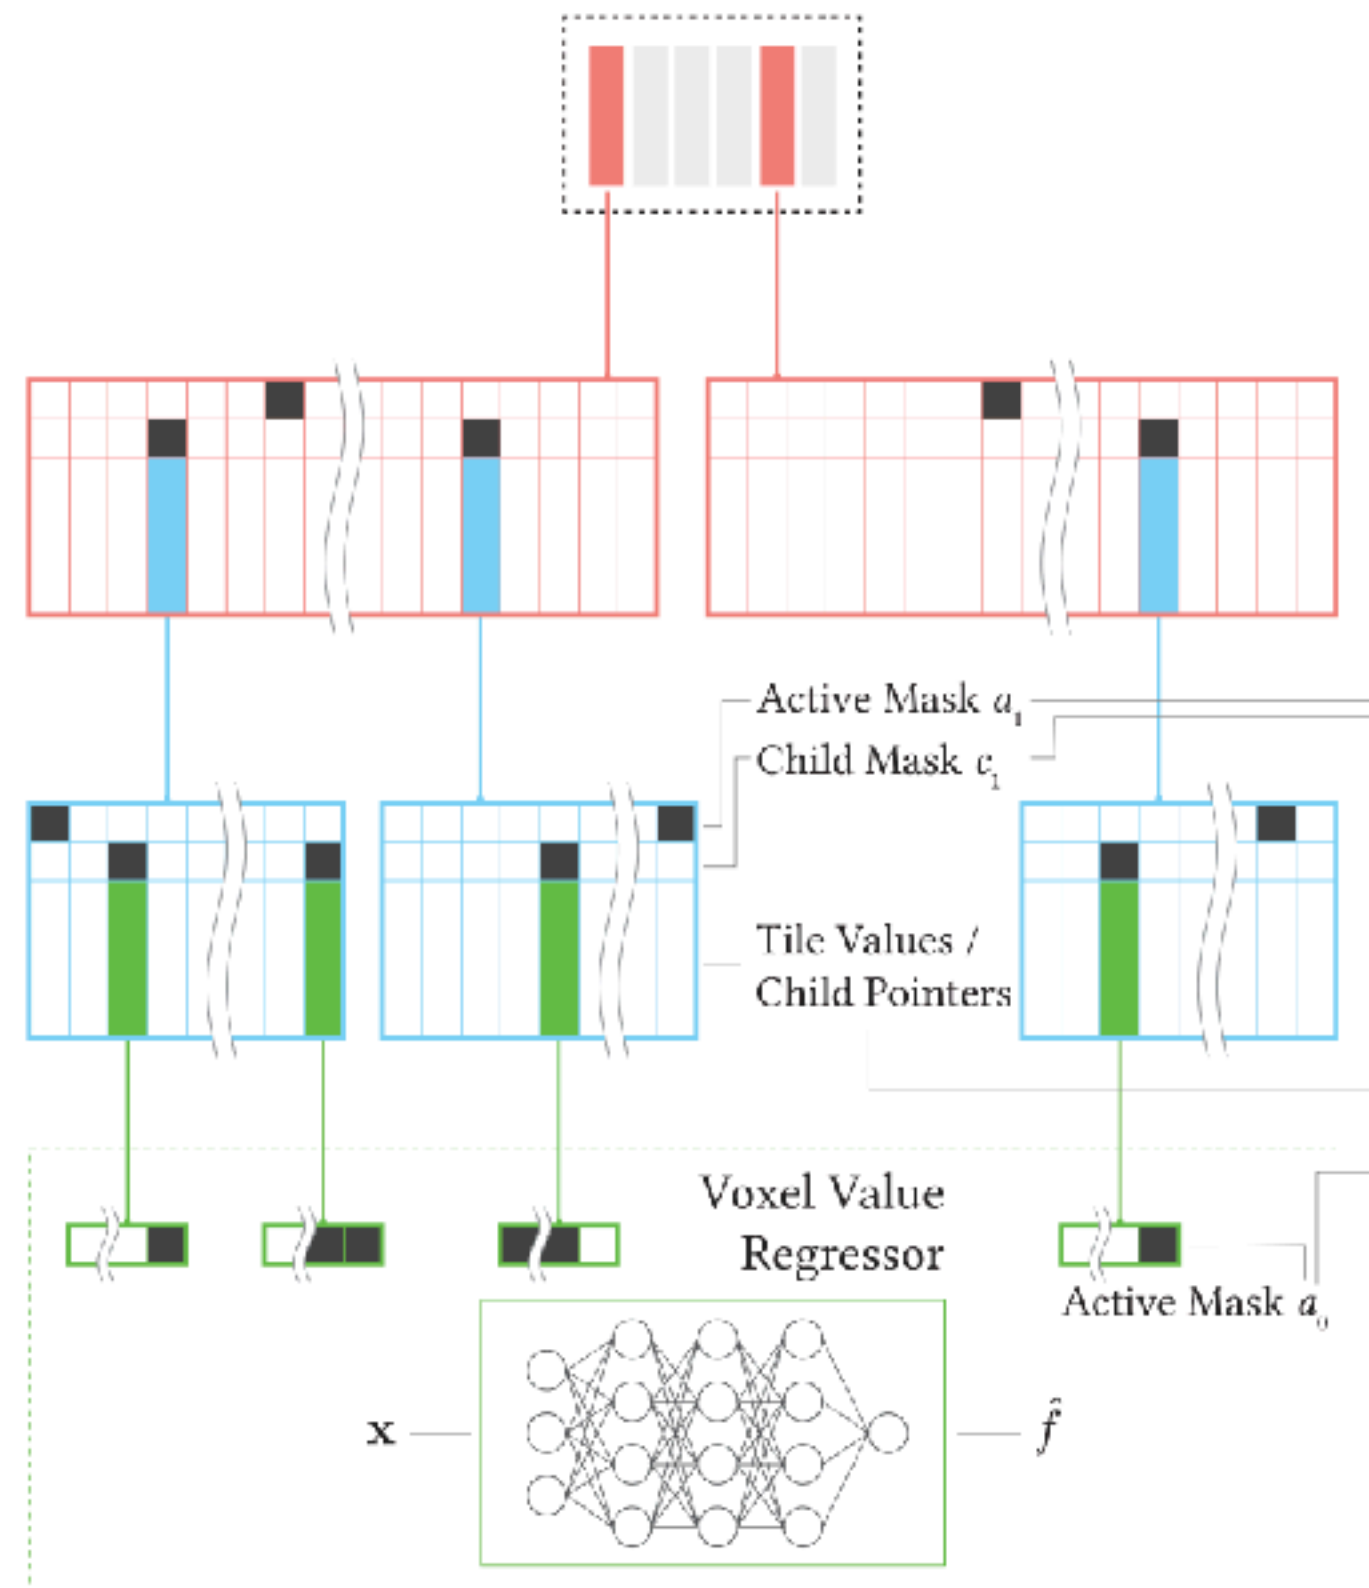
Optimalizált GPU implementáció – *villámgyors* tanítás & kiértékelés!

# Neurális Implicit Felületek

## Hibrid reprezentációk – Neural VDB\*


NeuralVDB: High-resolution Sparse Volume Representation using Hierarchical Neural Networks

DOYUB KIM, MINJAE LEE, and KEN MUSETH, NVIDIA, Santa Clara, USA



# Neurális Implicit Felületek

## Hibrid reprezentációk – fVDB\*



*f*VDB: A Deep-Learning Framework for Sparse, Large-Scale, and High-Performance Spatial Intelligence



FRANCIS WILLIAMS, NVIDIA Research, USA  
JIAHUI HUANG, NVIDIA Research, USA  
JONATHAN SWARTZ, NVIDIA Research, New Zealand  
GERGELY KLÁR, NVIDIA Research, New Zealand  
VIJAY THAKKAR, NVIDIA Research, USA  
MATTHEW CONG, NVIDIA Research, USA  
XUANCHI REN, NVIDIA Research, Canada  
RUILONG LI, NVIDIA Research, USA  
CLEMENT FUJI-TSANG, NVIDIA Research, Canada  
SANJA FIDLER, NVIDIA Research, Canada  
EFTYCHIOS SIFAKIS, University of Wisconsin-Madison, USA and NVIDIA Research, USA  
KEN MUSETH, NVIDIA Research, USA

Hatékony konvolúció VDB adatstruktúrával – km méretű neurális SDF!

# Neurális Implicit Felületek

## Hibrid reprezentációk – ReLU mezők\*

- Meglepő megfigyelés: közönséges trilineáris interpoláció + ReLU nemlinearitás is versenyképes egy sokrétegű MLP-vel!



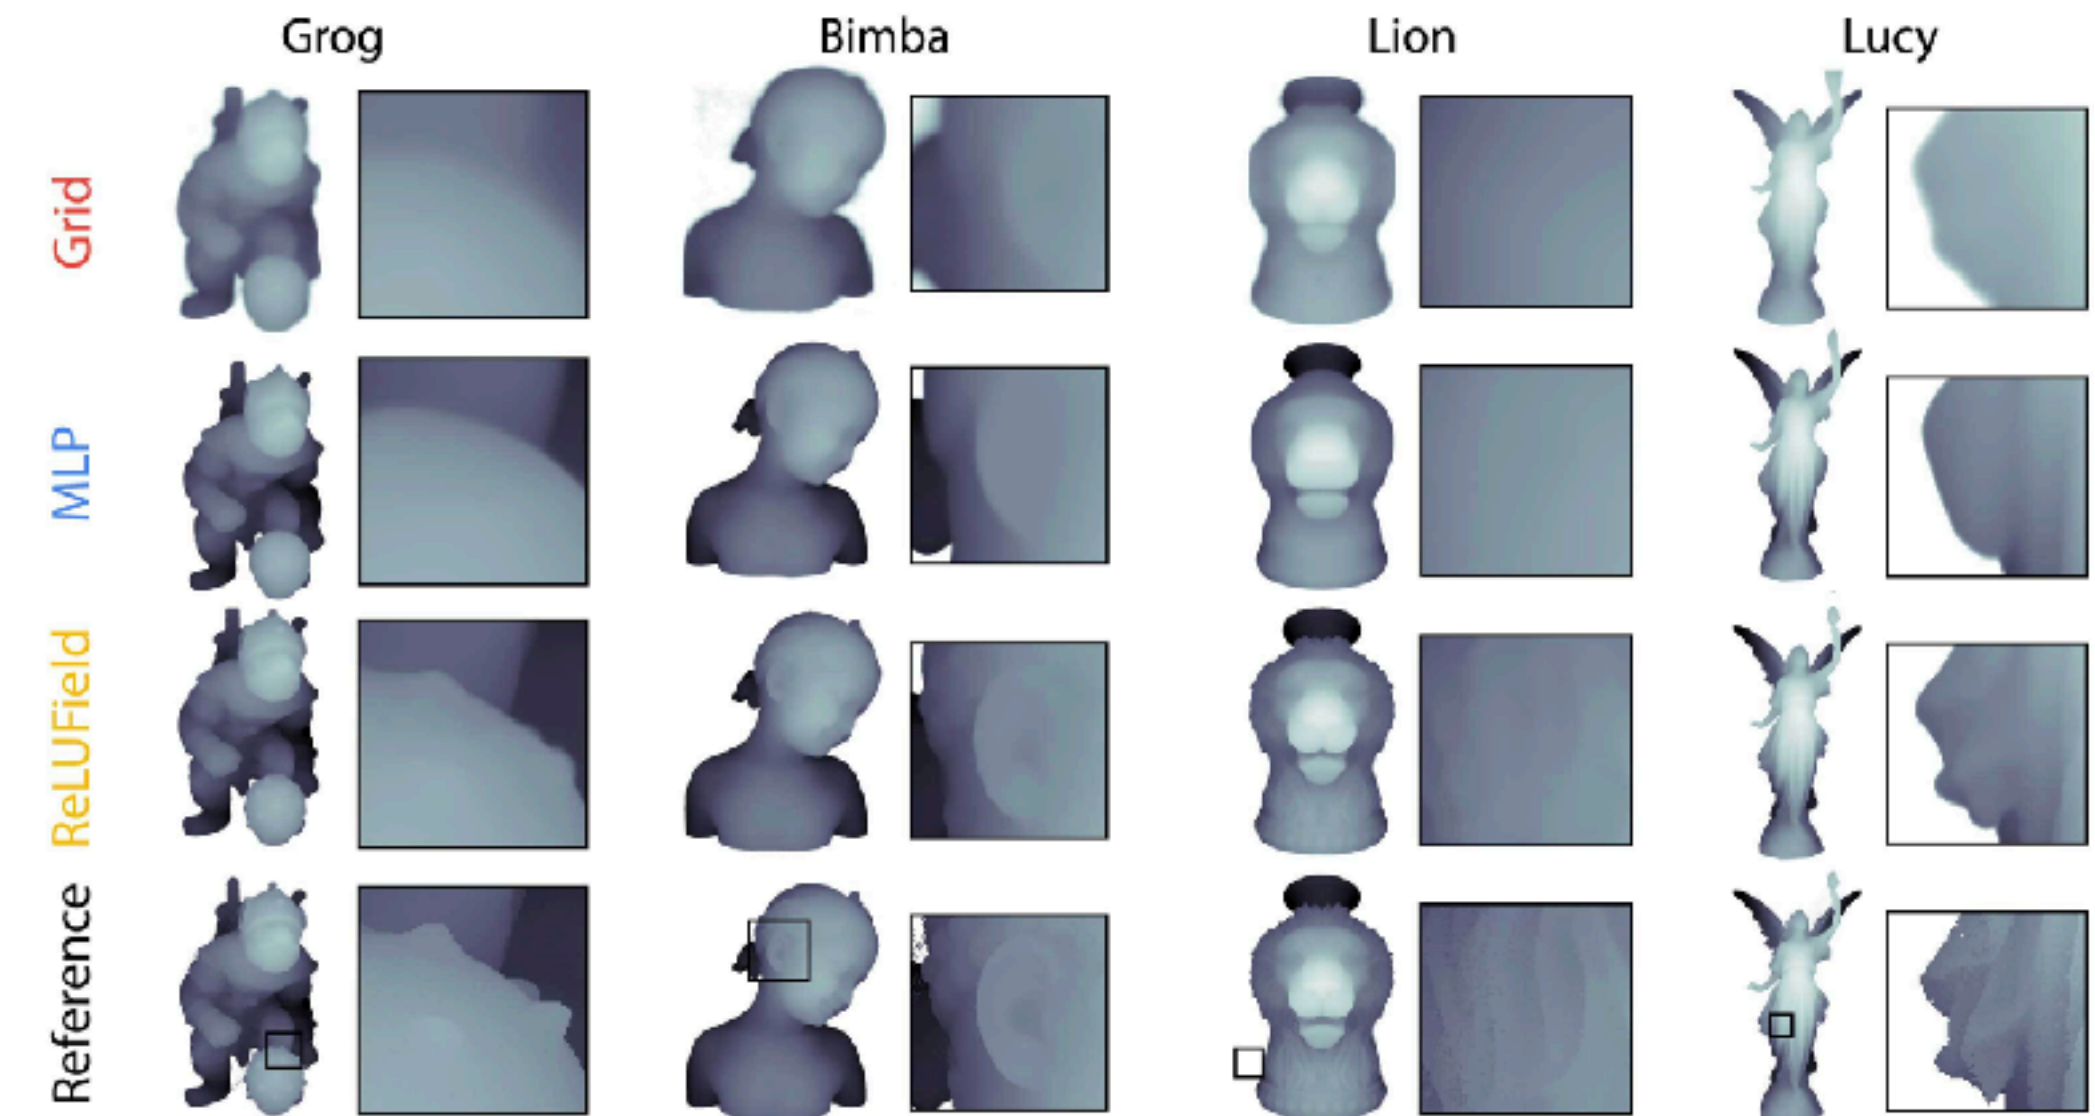
## ReLU Fields: The Little Non-linearity That Could

ANIMESH KARNEWAR, University College London, UK

TOBIAS RITSCHER, University College London, UK

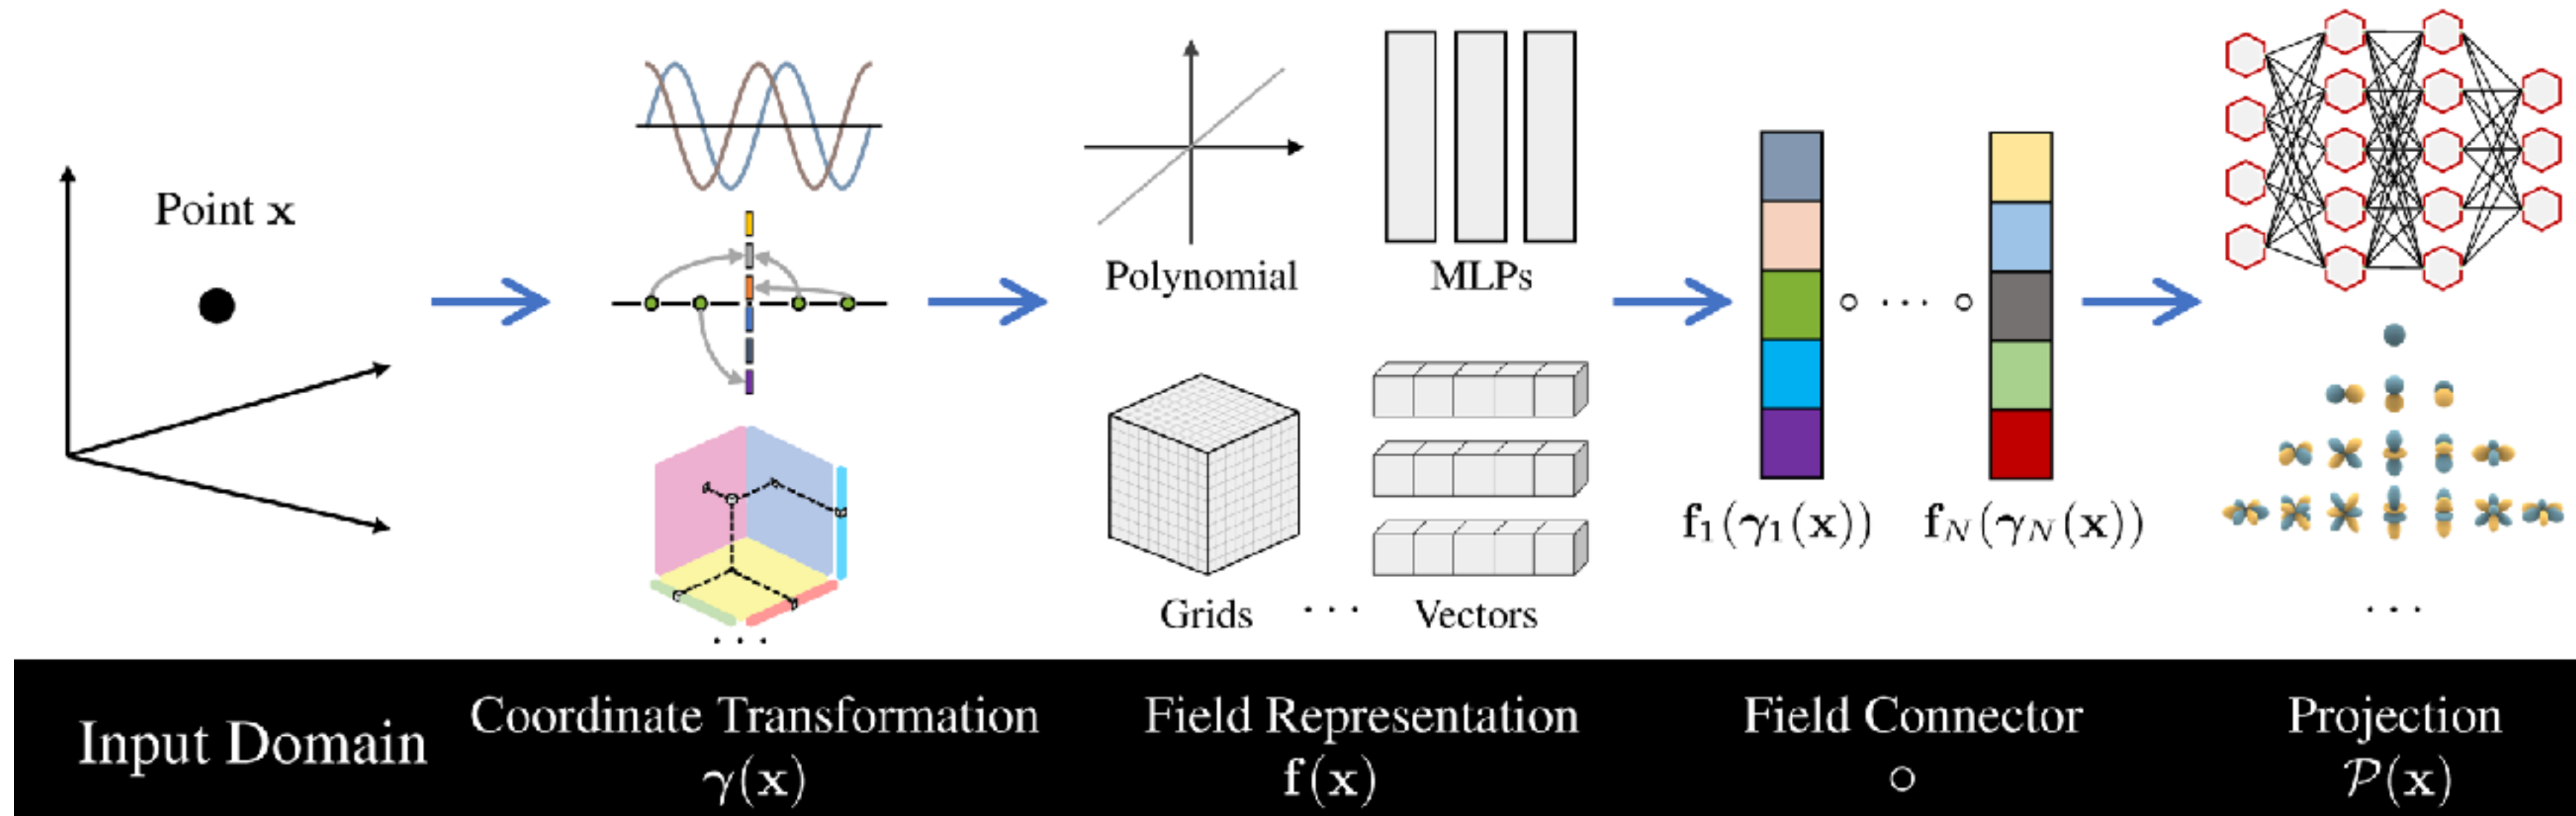
OLIVER WANG, Adobe Research, USA

NILOY J. MITRA, Adobe Research, USA and University College London, UK



# Neurális Implicit Felületek

## Hibrid reprezentációk – Faktor Mezők\*



Egységes elméleti keretrendszer a különböző hibrid neurális reprezentációkhoz

<https://apchenstu.github.io/FactorFields/>

# Neurális Implicit Felületek


## Hibrid reprezentációk – Irreguláris diszkretizáció\*

### 3DILG: Irregular Latent Grids for 3D Generative Modeling

Biao Zhang  
KAUST  
biao.zhang@kaust.edu.sa


Matthias Nießner  
Technical University of Munich  
niessner@tum.de

Peter Wonka  
KAUST  
pwonka@gmail.com



### PIN-SLAM: LiDAR SLAM Using a Point-Based Implicit Neural Representation for Achieving Global Map Consistency


Yue Pan, Xingguang Zhong, Louis Wiesmann, Thorbjörn Posewsky, Jens Behley, and Cyrill Stachniss



3D pontfelhő + látens vektorok + interpoláció

# Neurális Implicit Felületek

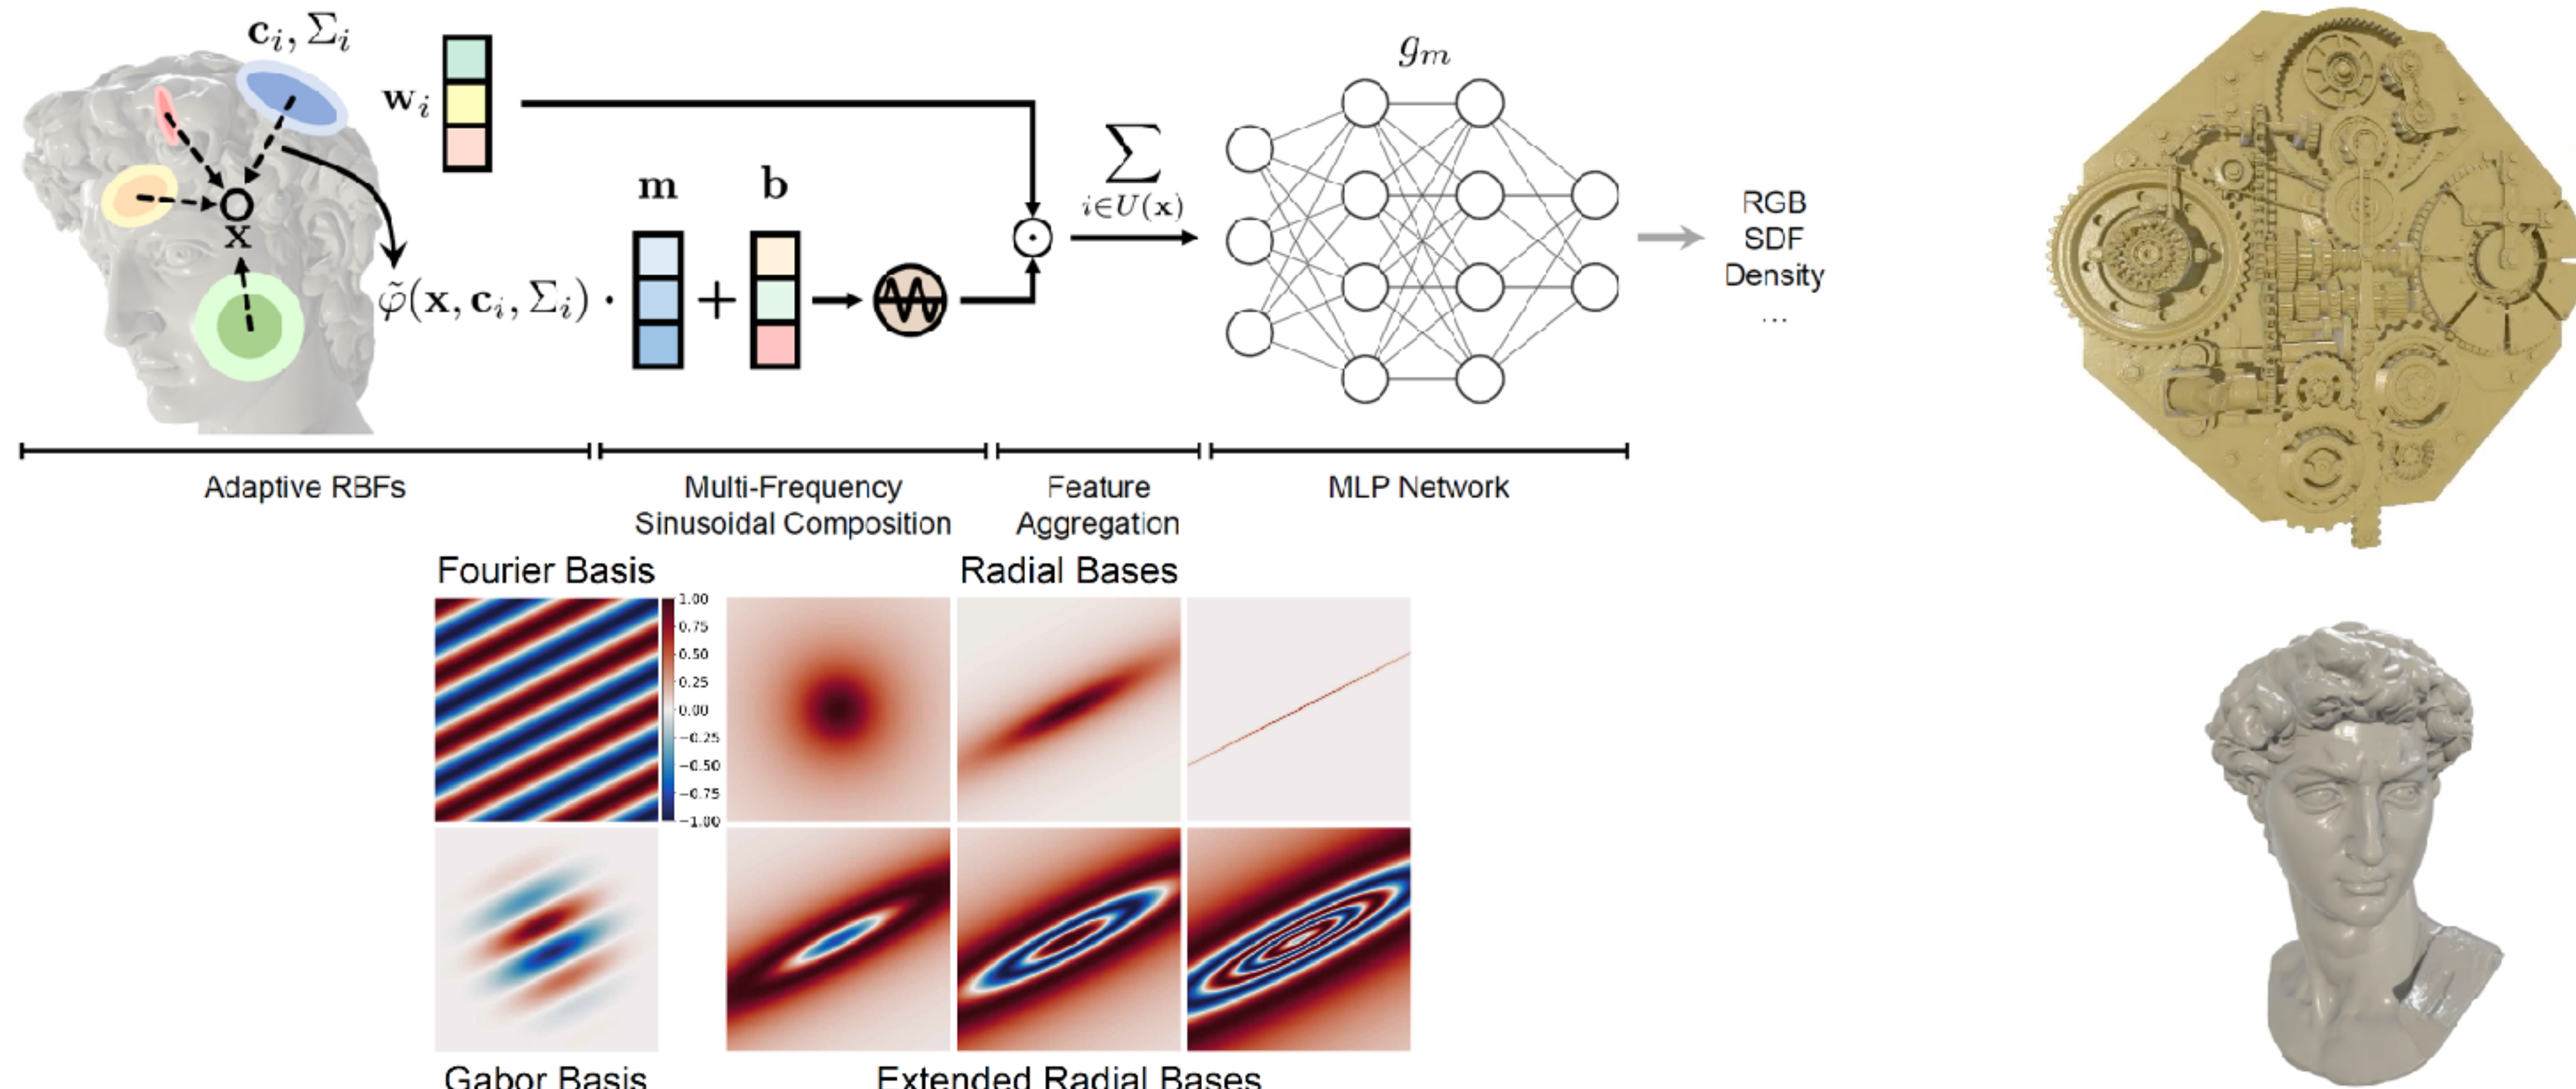
## Hibrid reprezentációk – Irreguláris diszkretizáció\*



<https://oppo-us-research.github.io/NeuRBF-website/>  
(Gaussian Splatting-hez hasonló)

# Neurális Implicit Felületek

## Hibrid reprezentációk – Irreguláris diszkretizáció\*





<https://oppo-us-research.github.io/NeuRBF-website/>  
(Gaussian Splatting-hez hasonló)

# Neurális Implicit Felületek

## Hibrid reprezentációk – Attention

3DShape2VecSet: A 3D Shape Representation for Neural Fields and Generative Diffusion Models

BIAO ZHANG, KAUST, Saudi Arabia  
 JIAPENG TANG, TU Munich, Germany  
 MATTHIAS NIESSNER, TU Munich, Germany  
 PETER WONKA, KAUST, Saudi Arabia



Látens vektorok rendezetlen halmazából figyelemmechanizmussal dekódolunk pl. SDF-et

$$\hat{O}_{\text{RBF}}(\mathbf{x}) = \sum_{i=1}^M \lambda_i \cdot \phi(\mathbf{x}, \mathbf{x}_i) \quad \longleftrightarrow \quad \hat{\mathcal{F}}(\mathbf{x}) = \sum_{i=1}^M \mathbf{v}(\mathbf{f}_i) \cdot \frac{1}{Z(\mathbf{x}, \{\mathbf{f}_i\}_{i=1}^M)} e^{\mathbf{q}(\mathbf{x})^\top \mathbf{k}(\mathbf{f}_i) / \sqrt{d}}$$

Attention  $\approx$  Gauss simítás tanult látens térben!

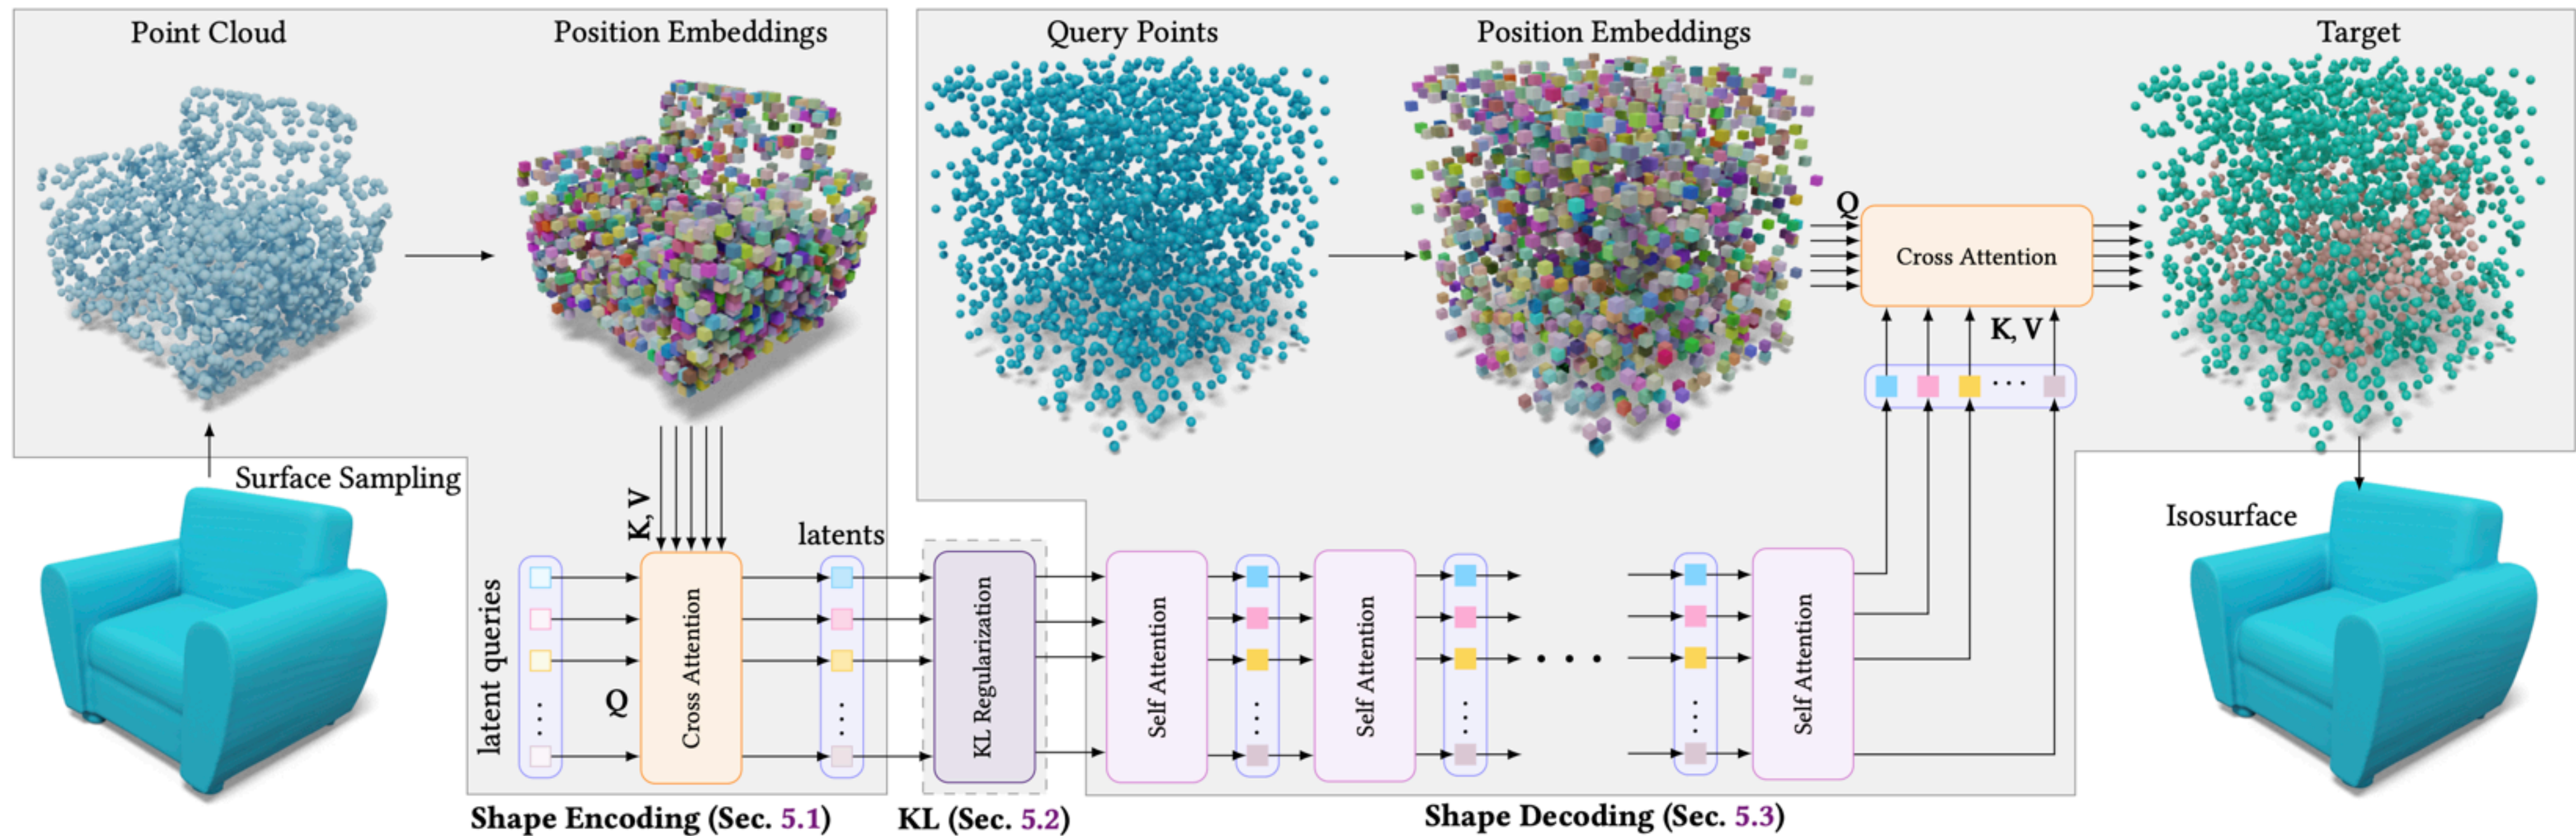
Elterjedten használt 3D generatív modellekben!

# Neurális Implicit Felületek

## Hibrid reprezentációk – Attention

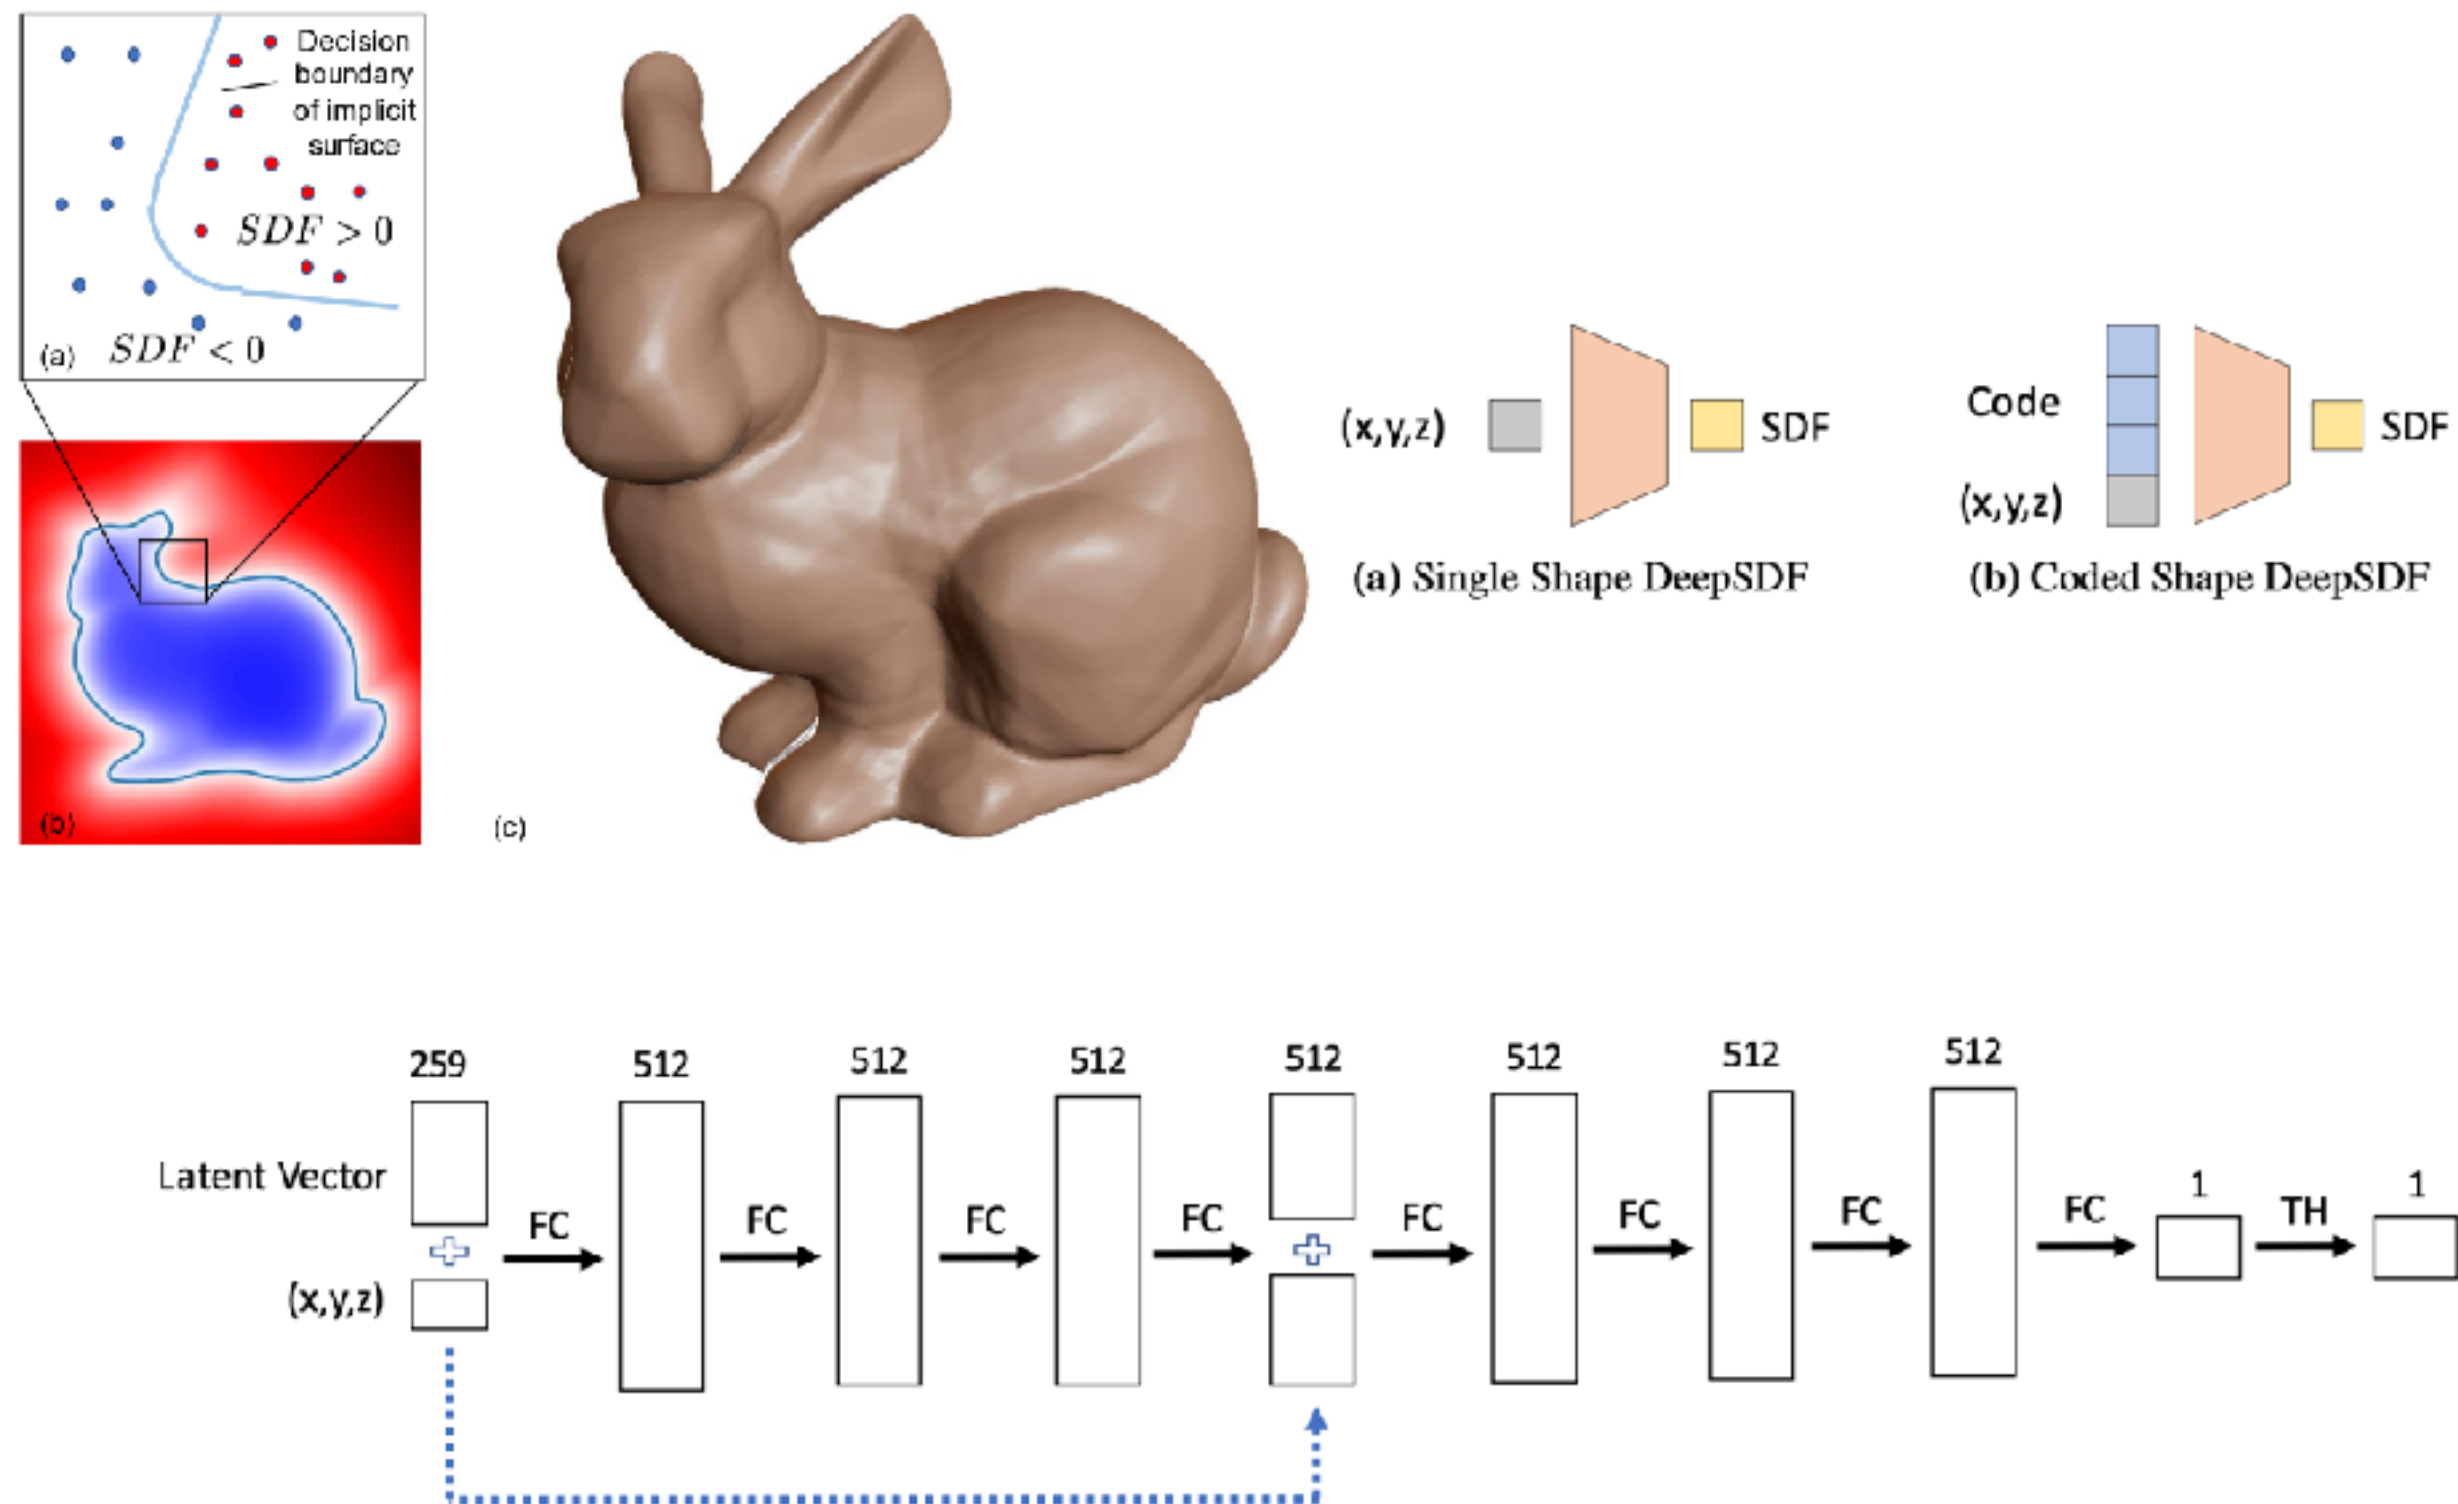
3DShape2VecSet: A 3D Shape Representation for Neural Fields and Generative Diffusion Models

BIAO ZHANG, KAUST, Saudi Arabia  
JIAPENG TANG, TU Munich, Germany  
MATTHIAS NIESSNER, TU Munich, Germany  
PETER WONKA, KAUST, Saudi Arabia

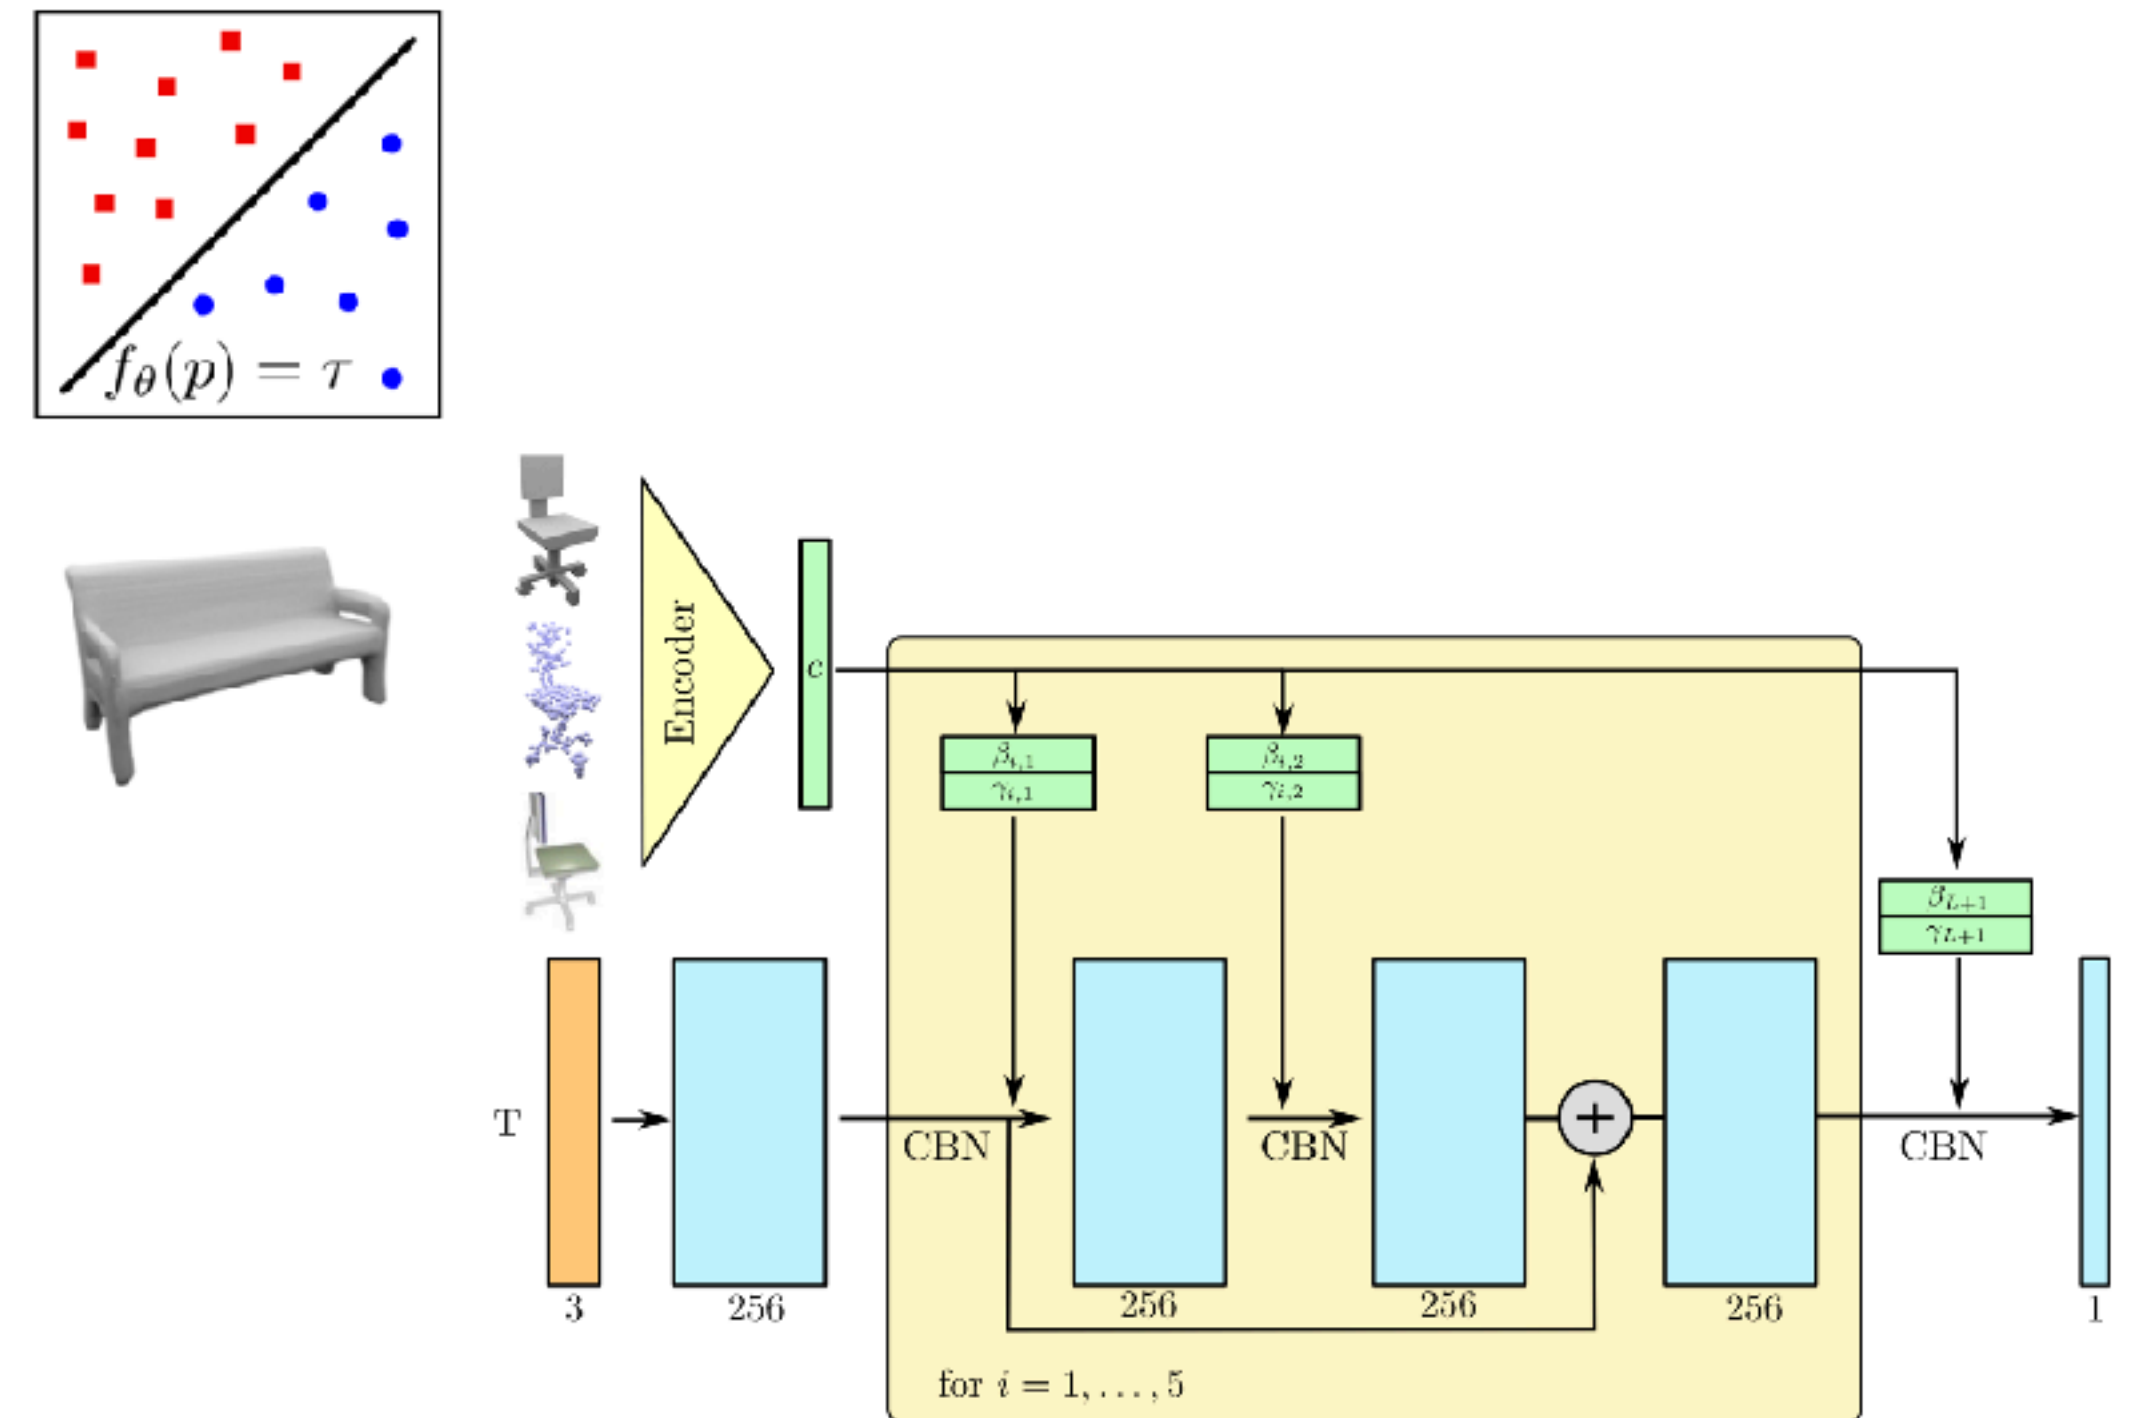


# 3D Generatív Modellezés

## DeepSDF, Occupancy Networks



**DeepSDF (2019)**



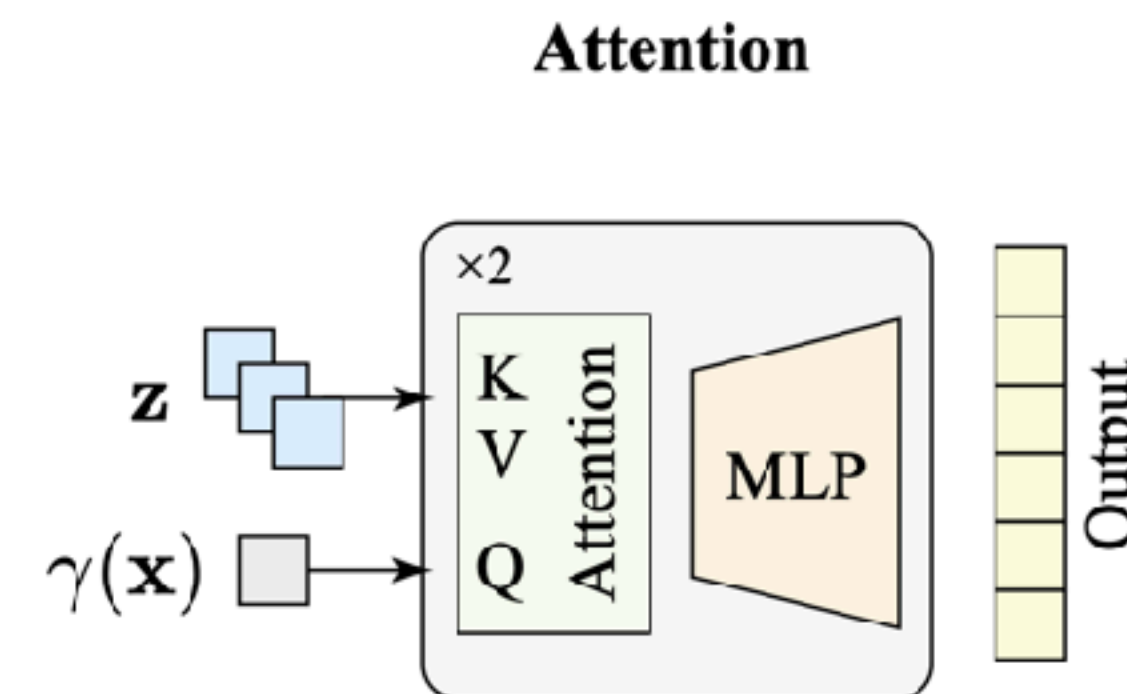
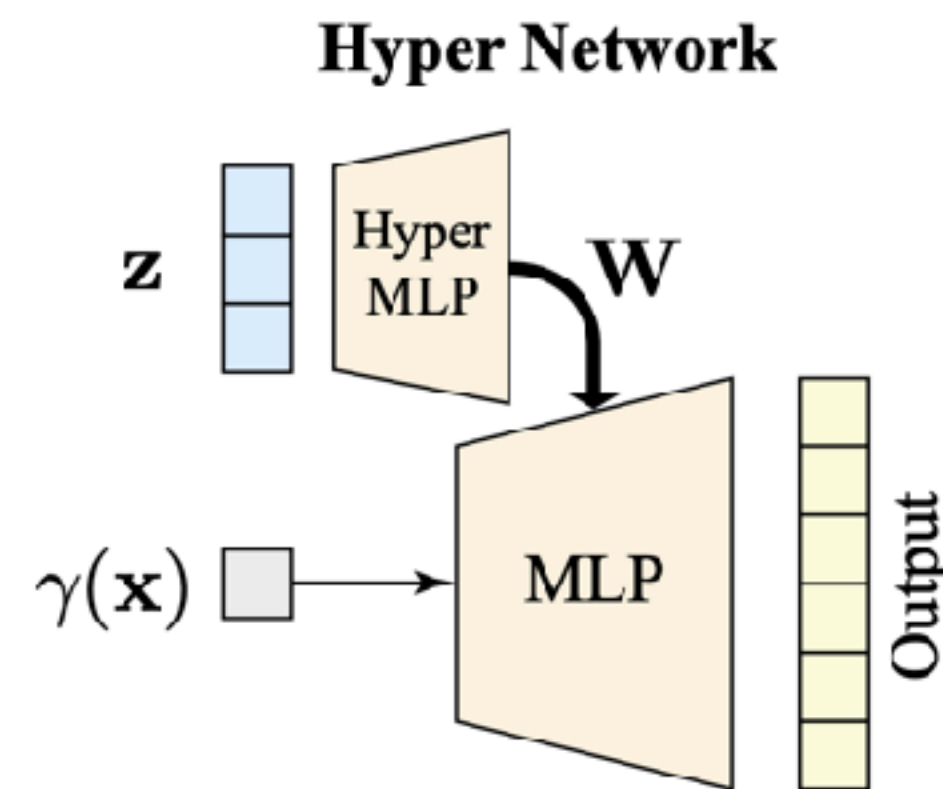

**Occupancy Networks (2019)**

*Úttörő jellegű munkák — generatív alkalmazások által motiválva*

# 3D Generatív Modellelés

## Kondicionálási módszerek

A kondíció figyelembe vétele több módon is lehetséges...



### Attention Beats Concatenation for Conditioning Neural Fields

Daniel Rebain

*University of British Columbia  
Google Research*

Mark J. Matthews

*Google Research*

Kwang Moo Yi

*University of British Columbia*

Gopal Sharma

*University of British Columbia*

Dmitry Lagun

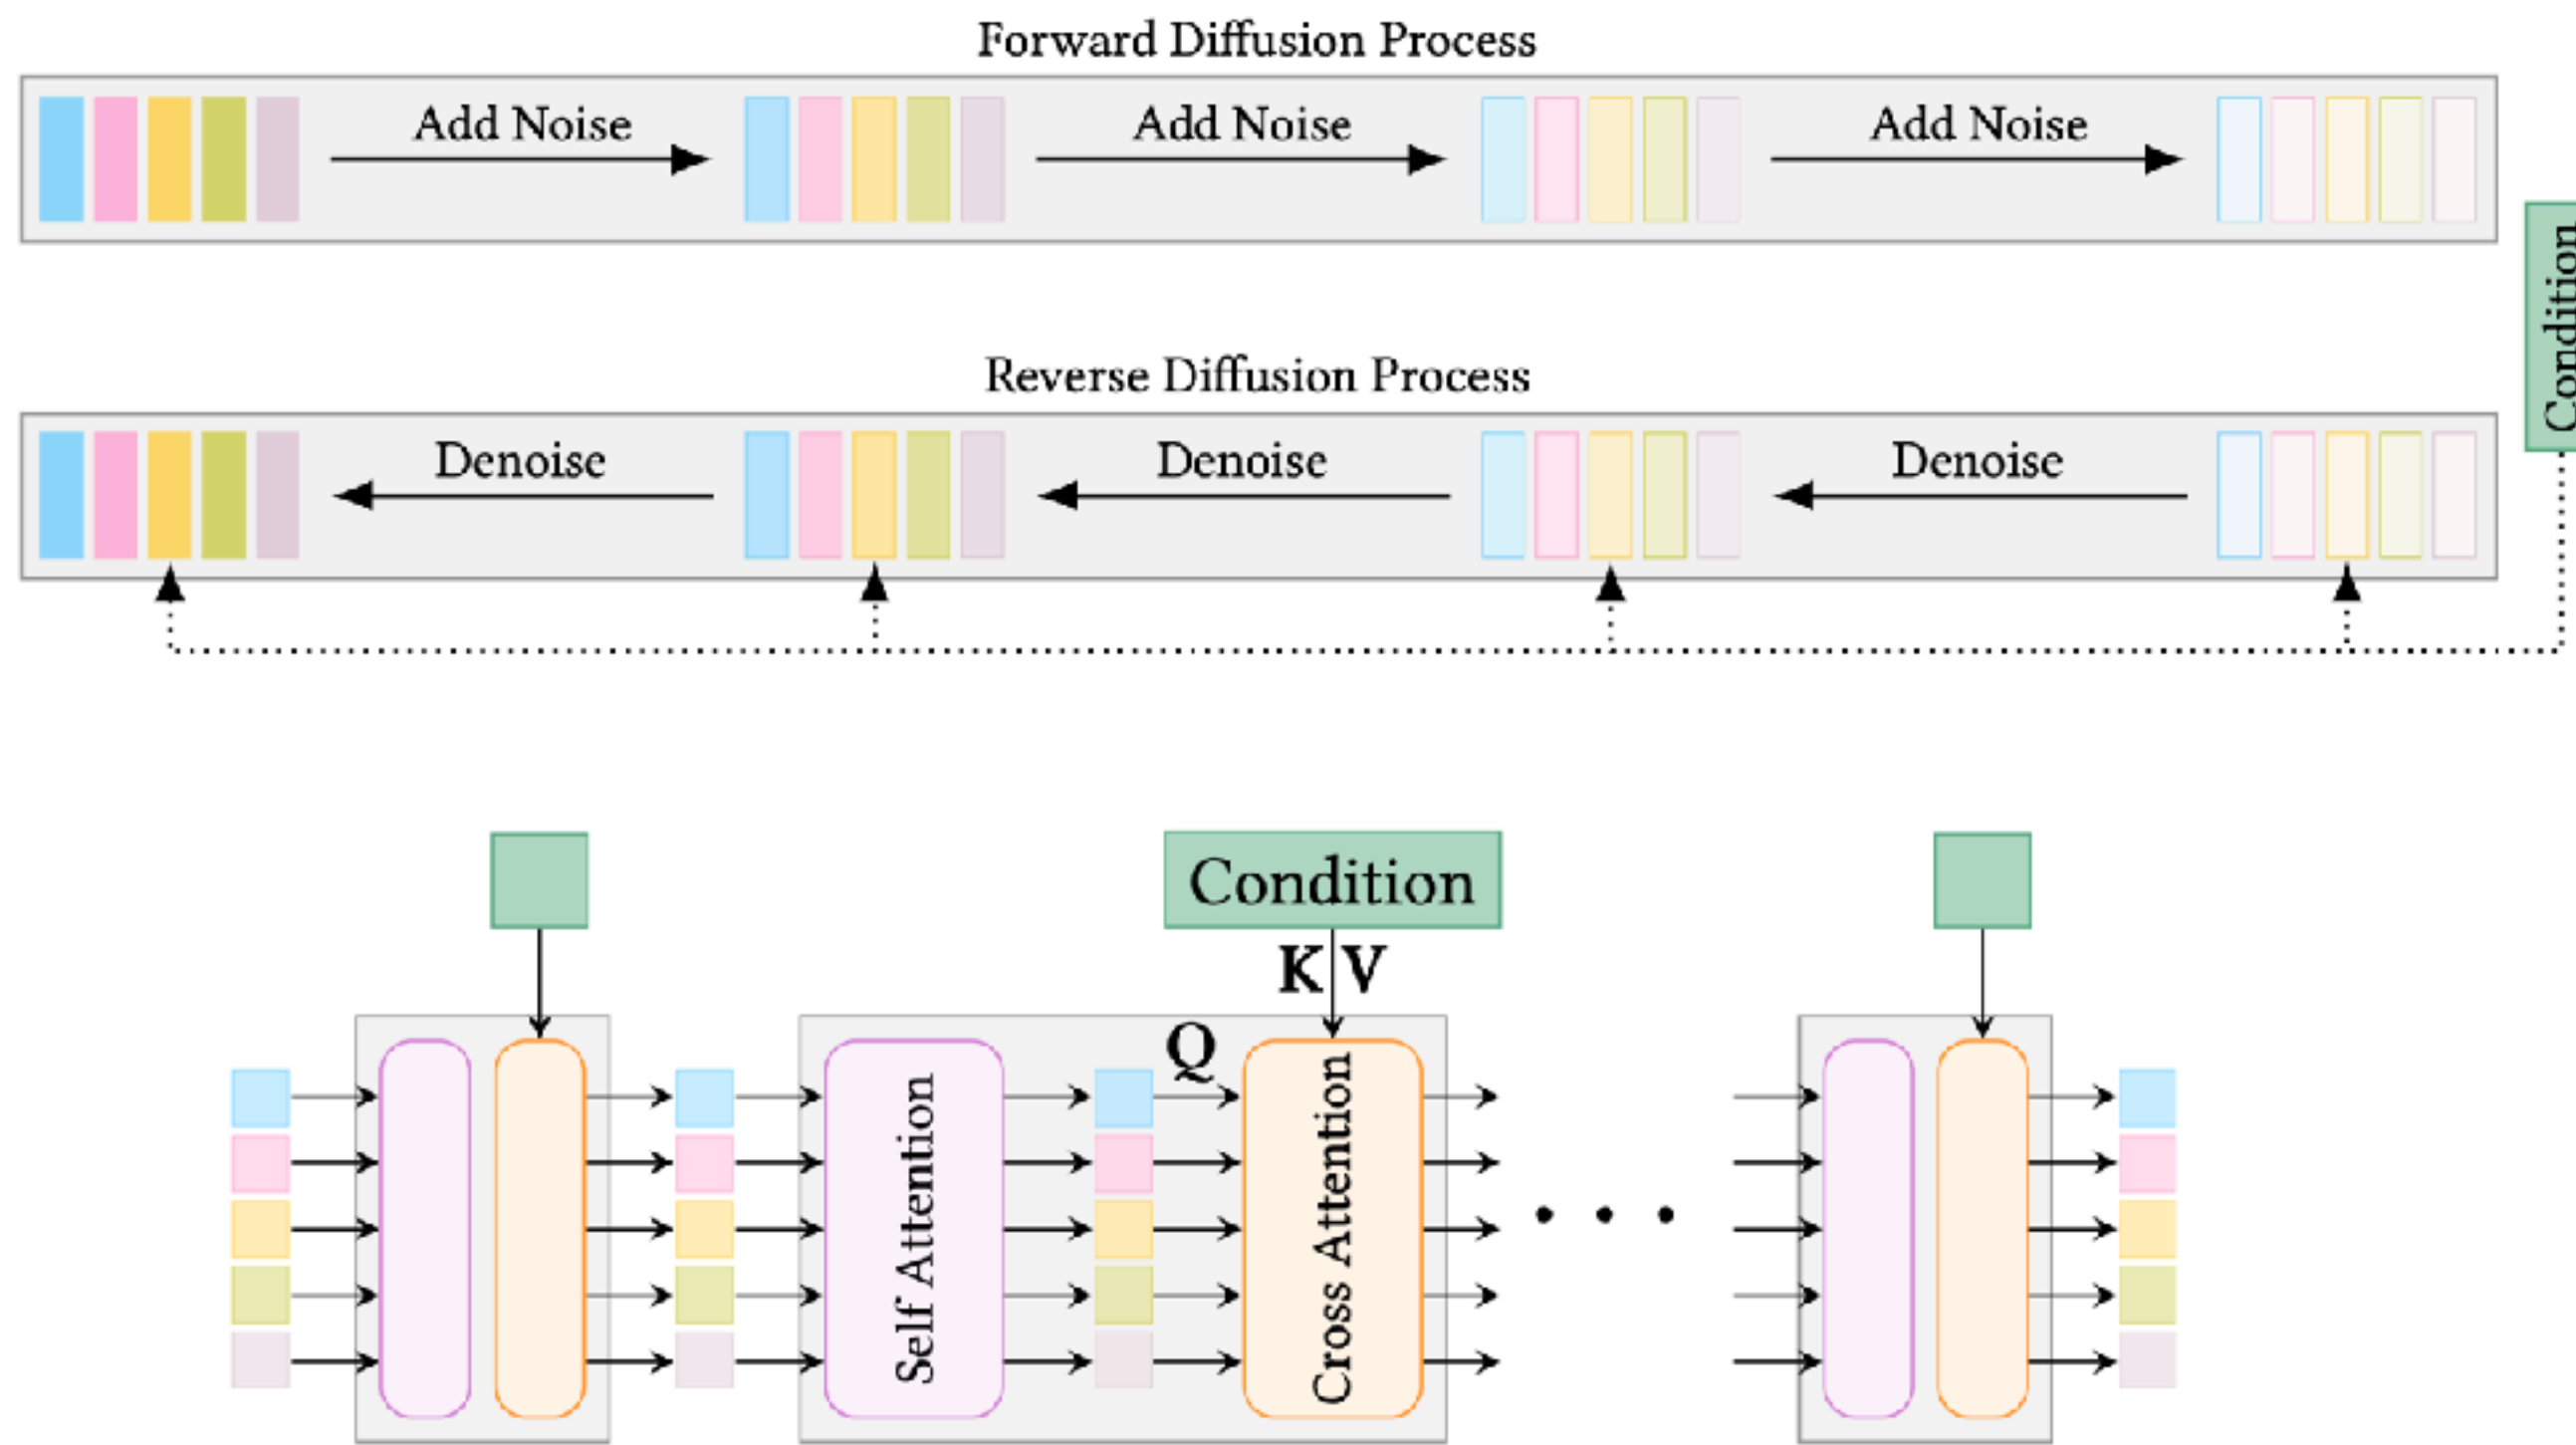
*Google Research*

Andrea Tagliasacchi

*Google Research  
Simon Fraser University*

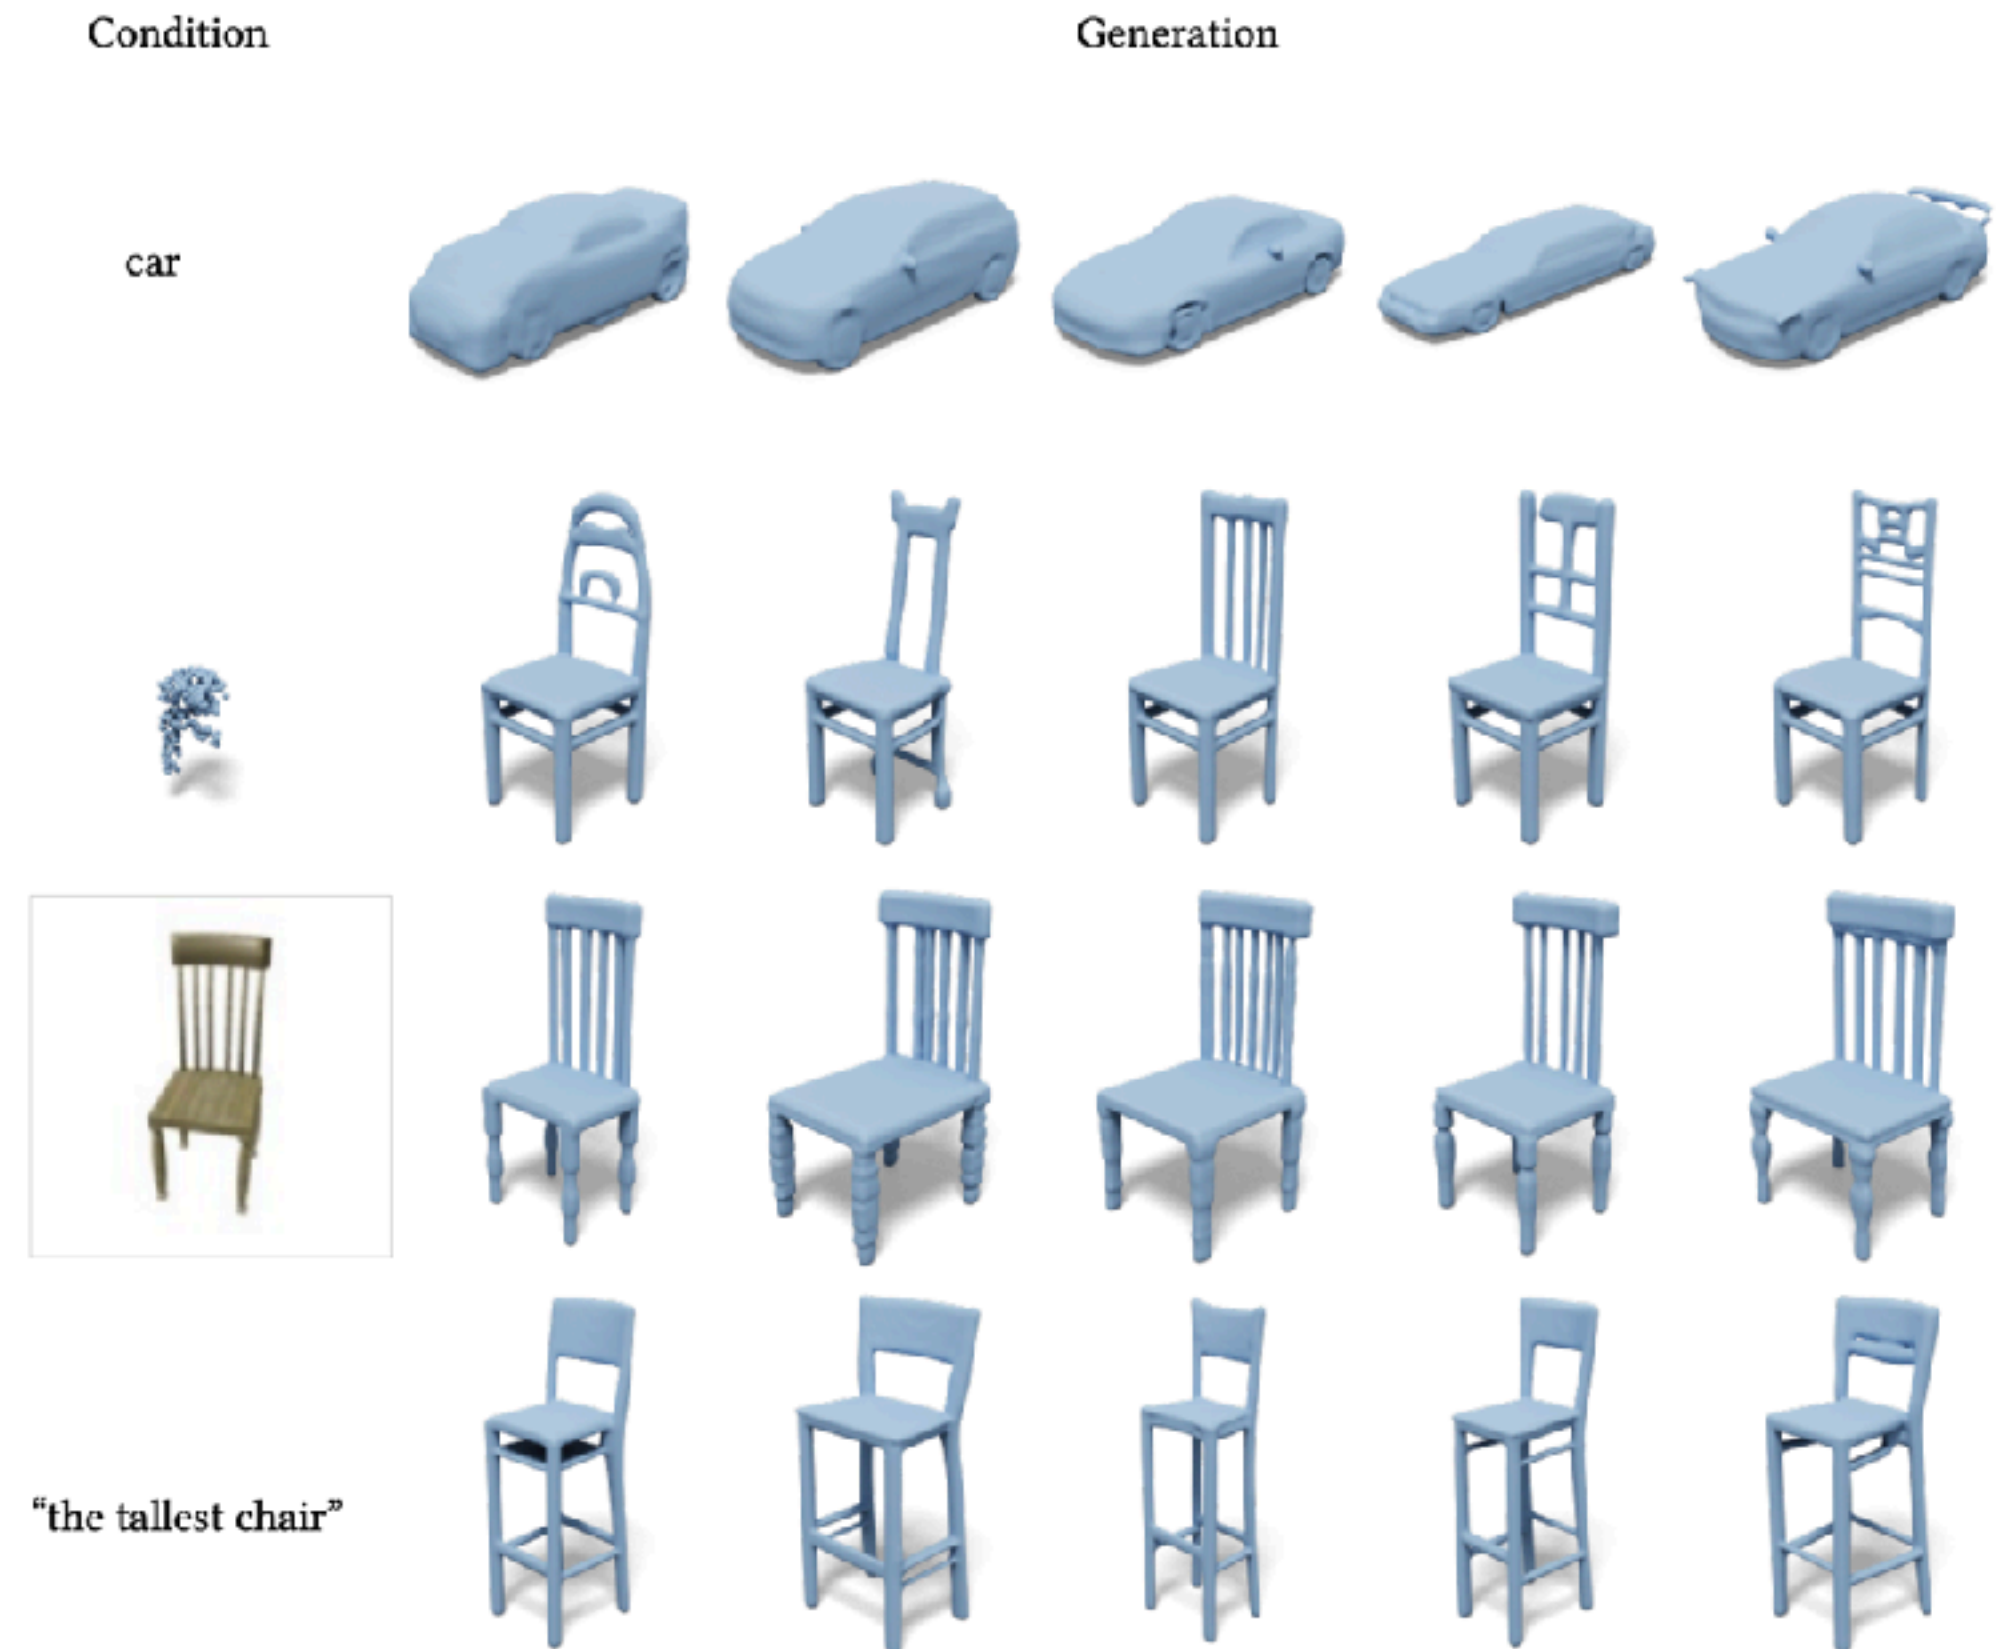
# 3D Generatív Modellelés

## 3DShape2VecSet



3DShape2VecSet: A 3D Shape Representation for Neural Fields and Generative Diffusion Models

BIAO ZHANG, KAUST, Saudi Arabia  
 JIAPENG TANG, TU Munich, Germany  
 MATTHIAS NIESSNER, TU Munich, Germany  
 PETER WONKA, KAUST, Saudi Arabia



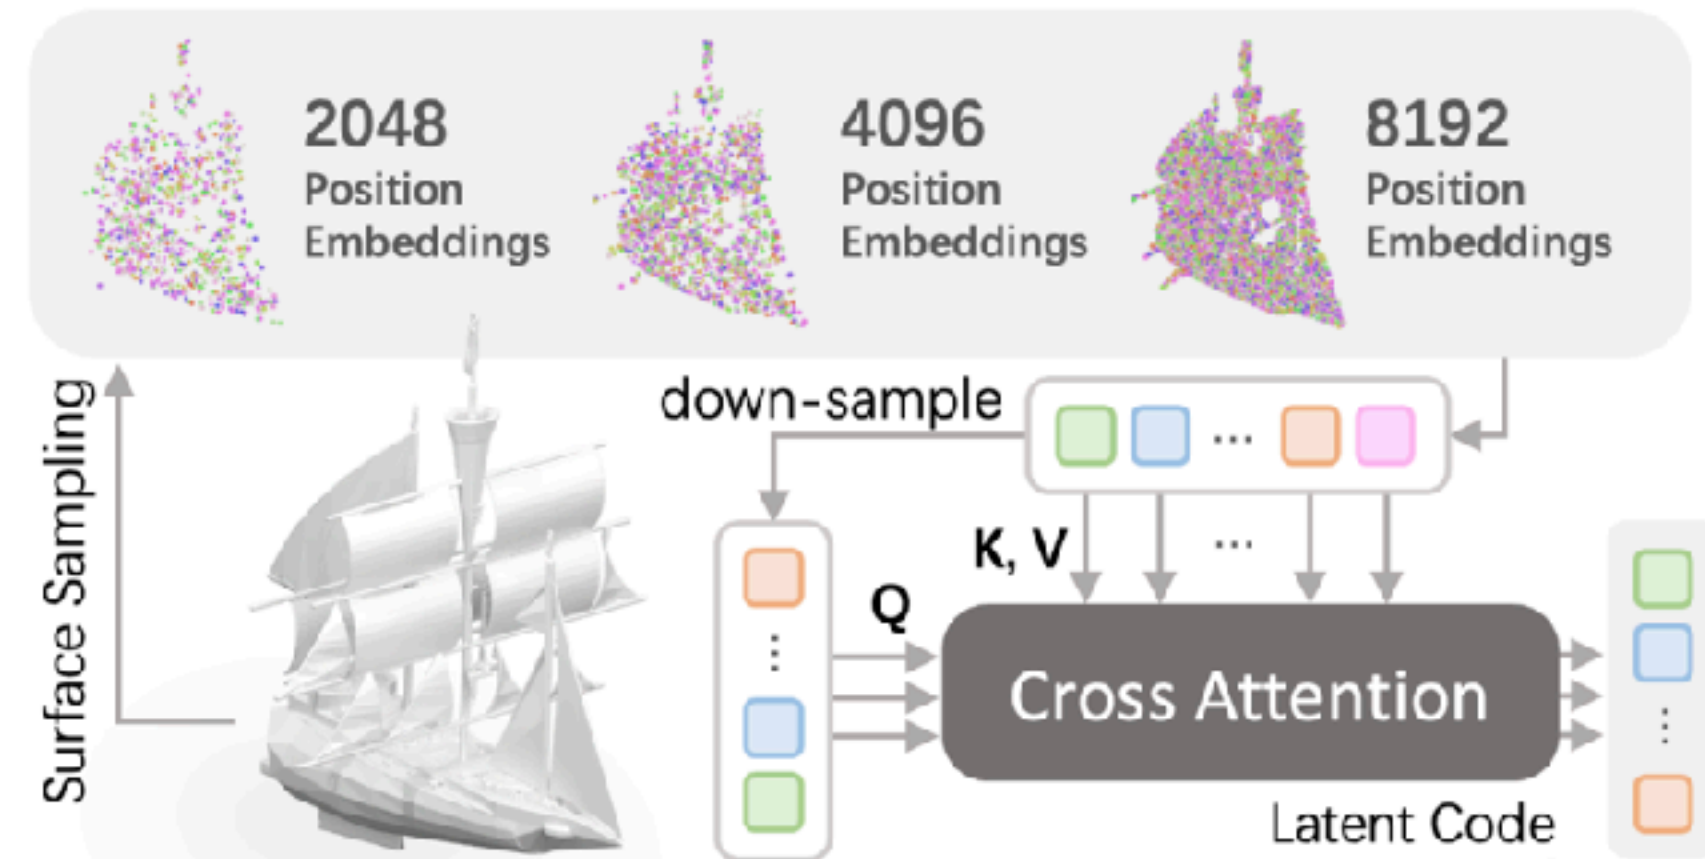
# 3D Generatív Modellelés

## CLAY

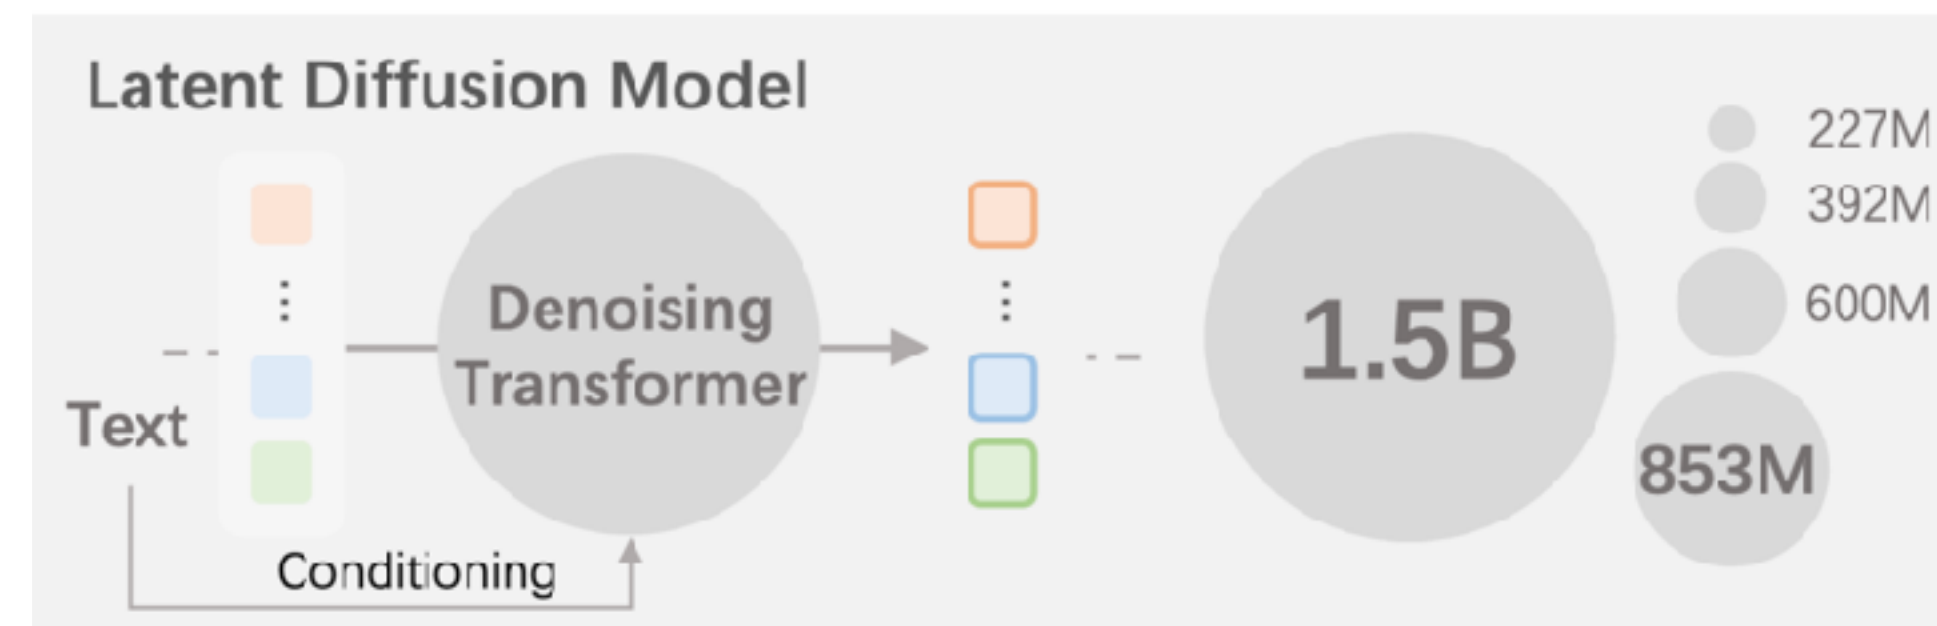

CLAY: A Controllable Large-scale Generative Model for Creating High-quality 3D Assets

LONGWEN ZHANG\*, ShanghaiTech University and Deemos Technology Co., Ltd., China  
 ZIYU WANG\*, ShanghaiTech University and Deemos Technology Co., Ltd., China  
 QIXUAN ZHANG†, ShanghaiTech University and Deemos Technology Co., Ltd., China  
 QIWEI QIU, ShanghaiTech University and Deemos Technology Co., Ltd., China  
 ANQI PANG, ShanghaiTech University, China  
 HAORAN JIANG, ShanghaiTech University and Deemos Technology Co., Ltd., China  
 WEI YANG, Huazhong University of Science and Technology, China  
 LAN XU‡, ShanghaiTech University, China  
 JINGYI YU‡, ShanghaiTech University, China

### VAE Geometry Encoder



### VAE Geometry Decoder




# 3D Generatív Modellelés

## CLAY


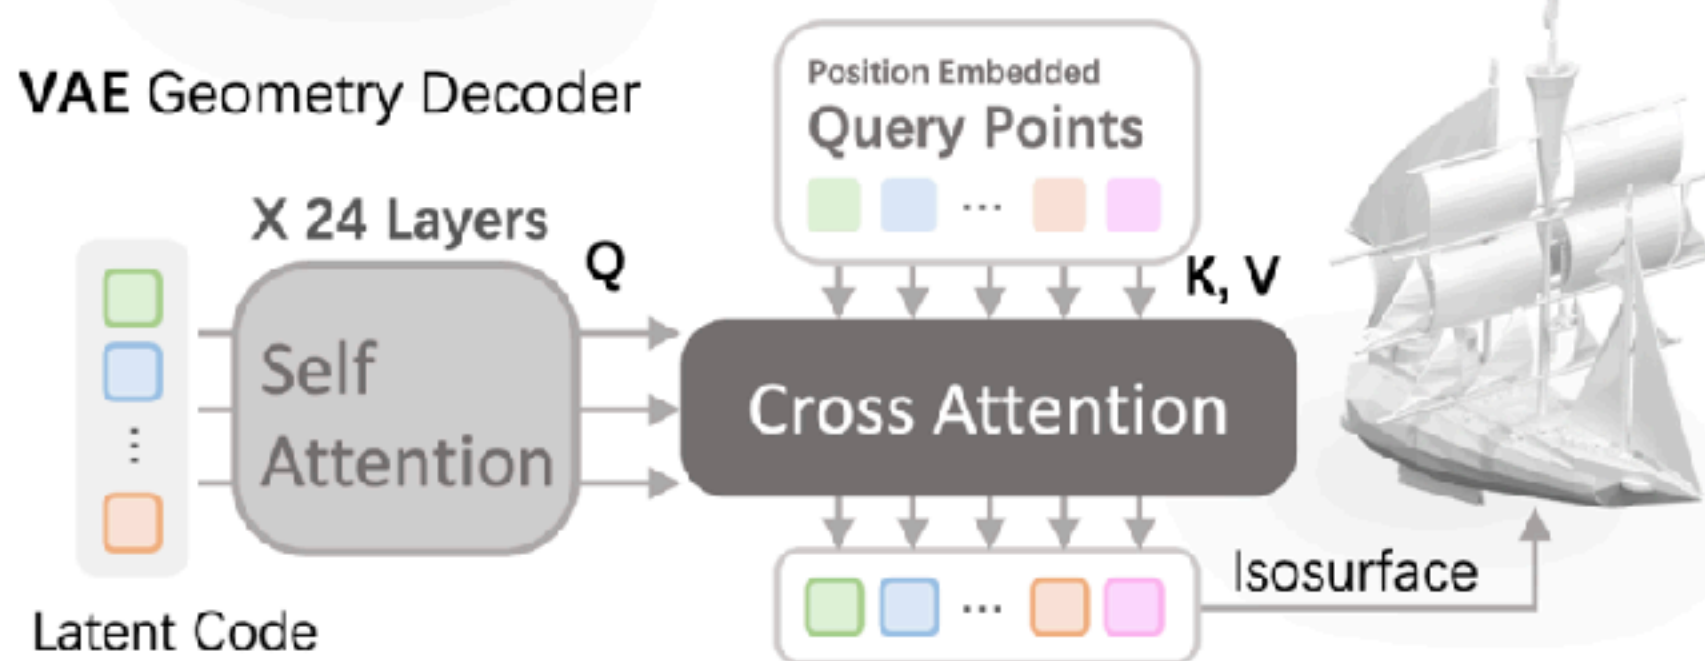
CLAY: A Controllable Large-scale Generative Model for Creating High-quality 3D Assets

LONGWEN ZHANG\*, ShanghaiTech University and Deemos Technology Co., Ltd., China  
 ZIYU WANG\*, ShanghaiTech University and Deemos Technology Co., Ltd., China  
 QIXUAN ZHANG†, ShanghaiTech University and Deemos Technology Co., Ltd., China  
 QIWEI QIU, ShanghaiTech University and Deemos Technology Co., Ltd., China  
 ANQI PANG, ShanghaiTech University, China  
 HAORAN JIANG, ShanghaiTech University and Deemos Technology Co., Ltd., China  
 WEI YANG, Huazhong University of Science and Technology, China  
 LAN XU‡, ShanghaiTech University, China  
 JINGYI YU‡, ShanghaiTech University, China

### VAE Geometry Encoder

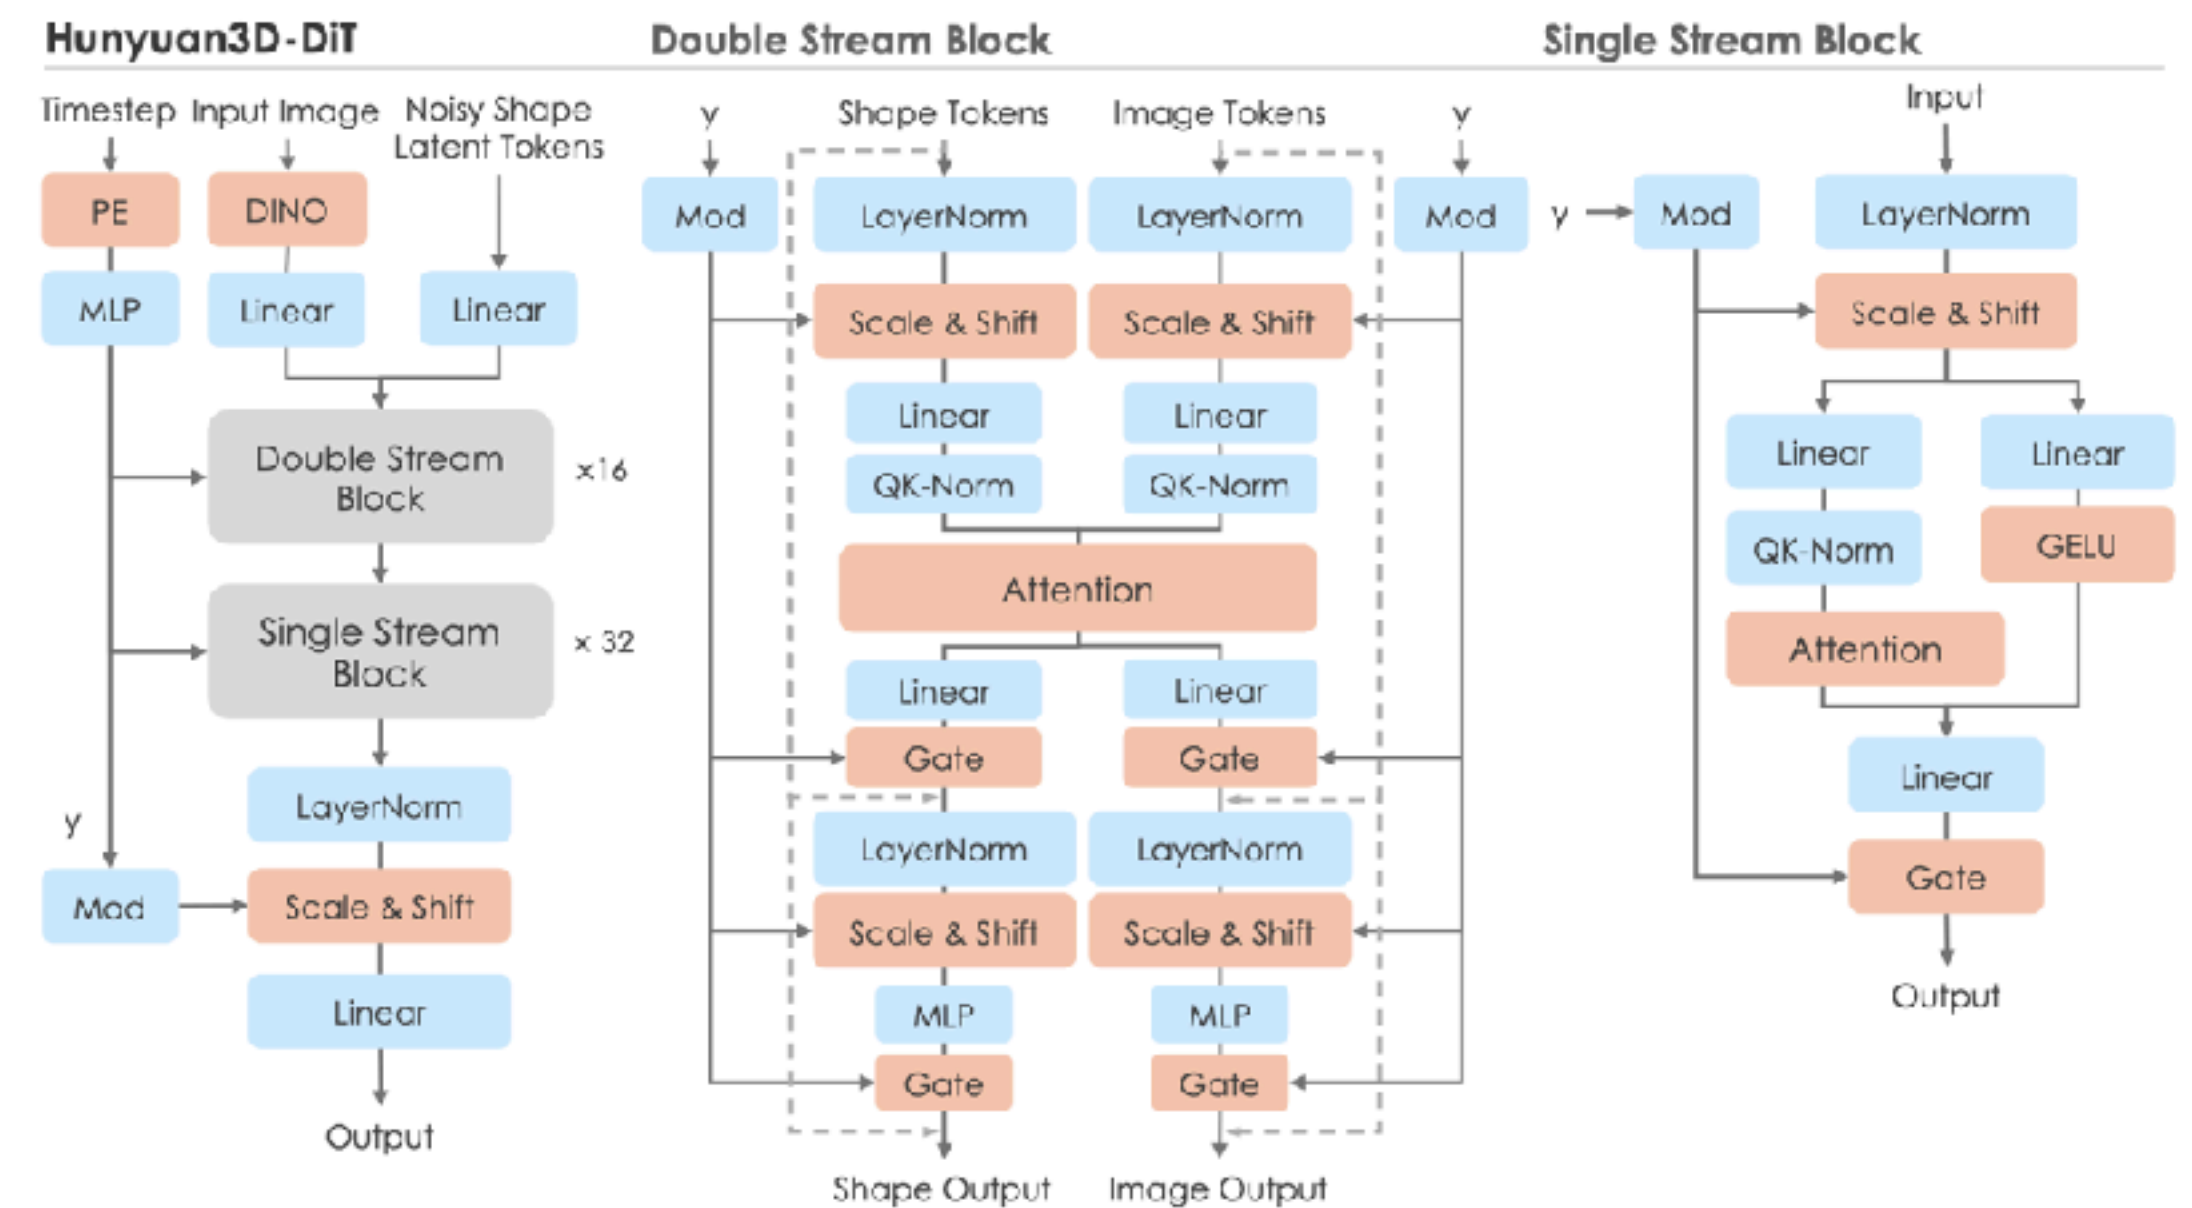
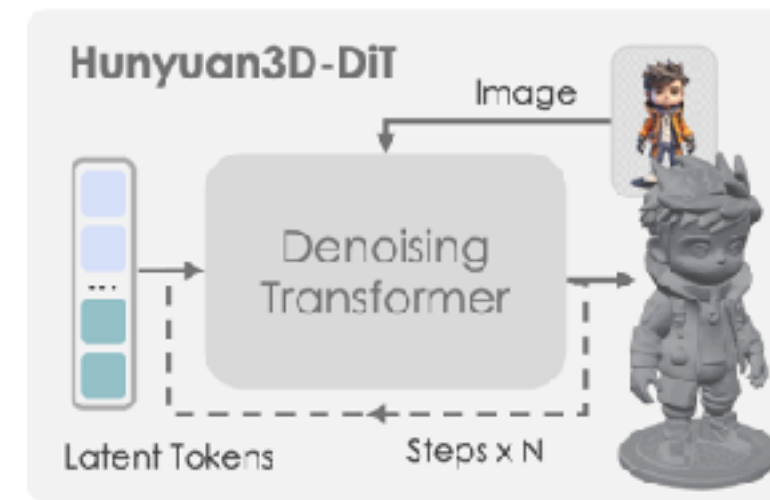
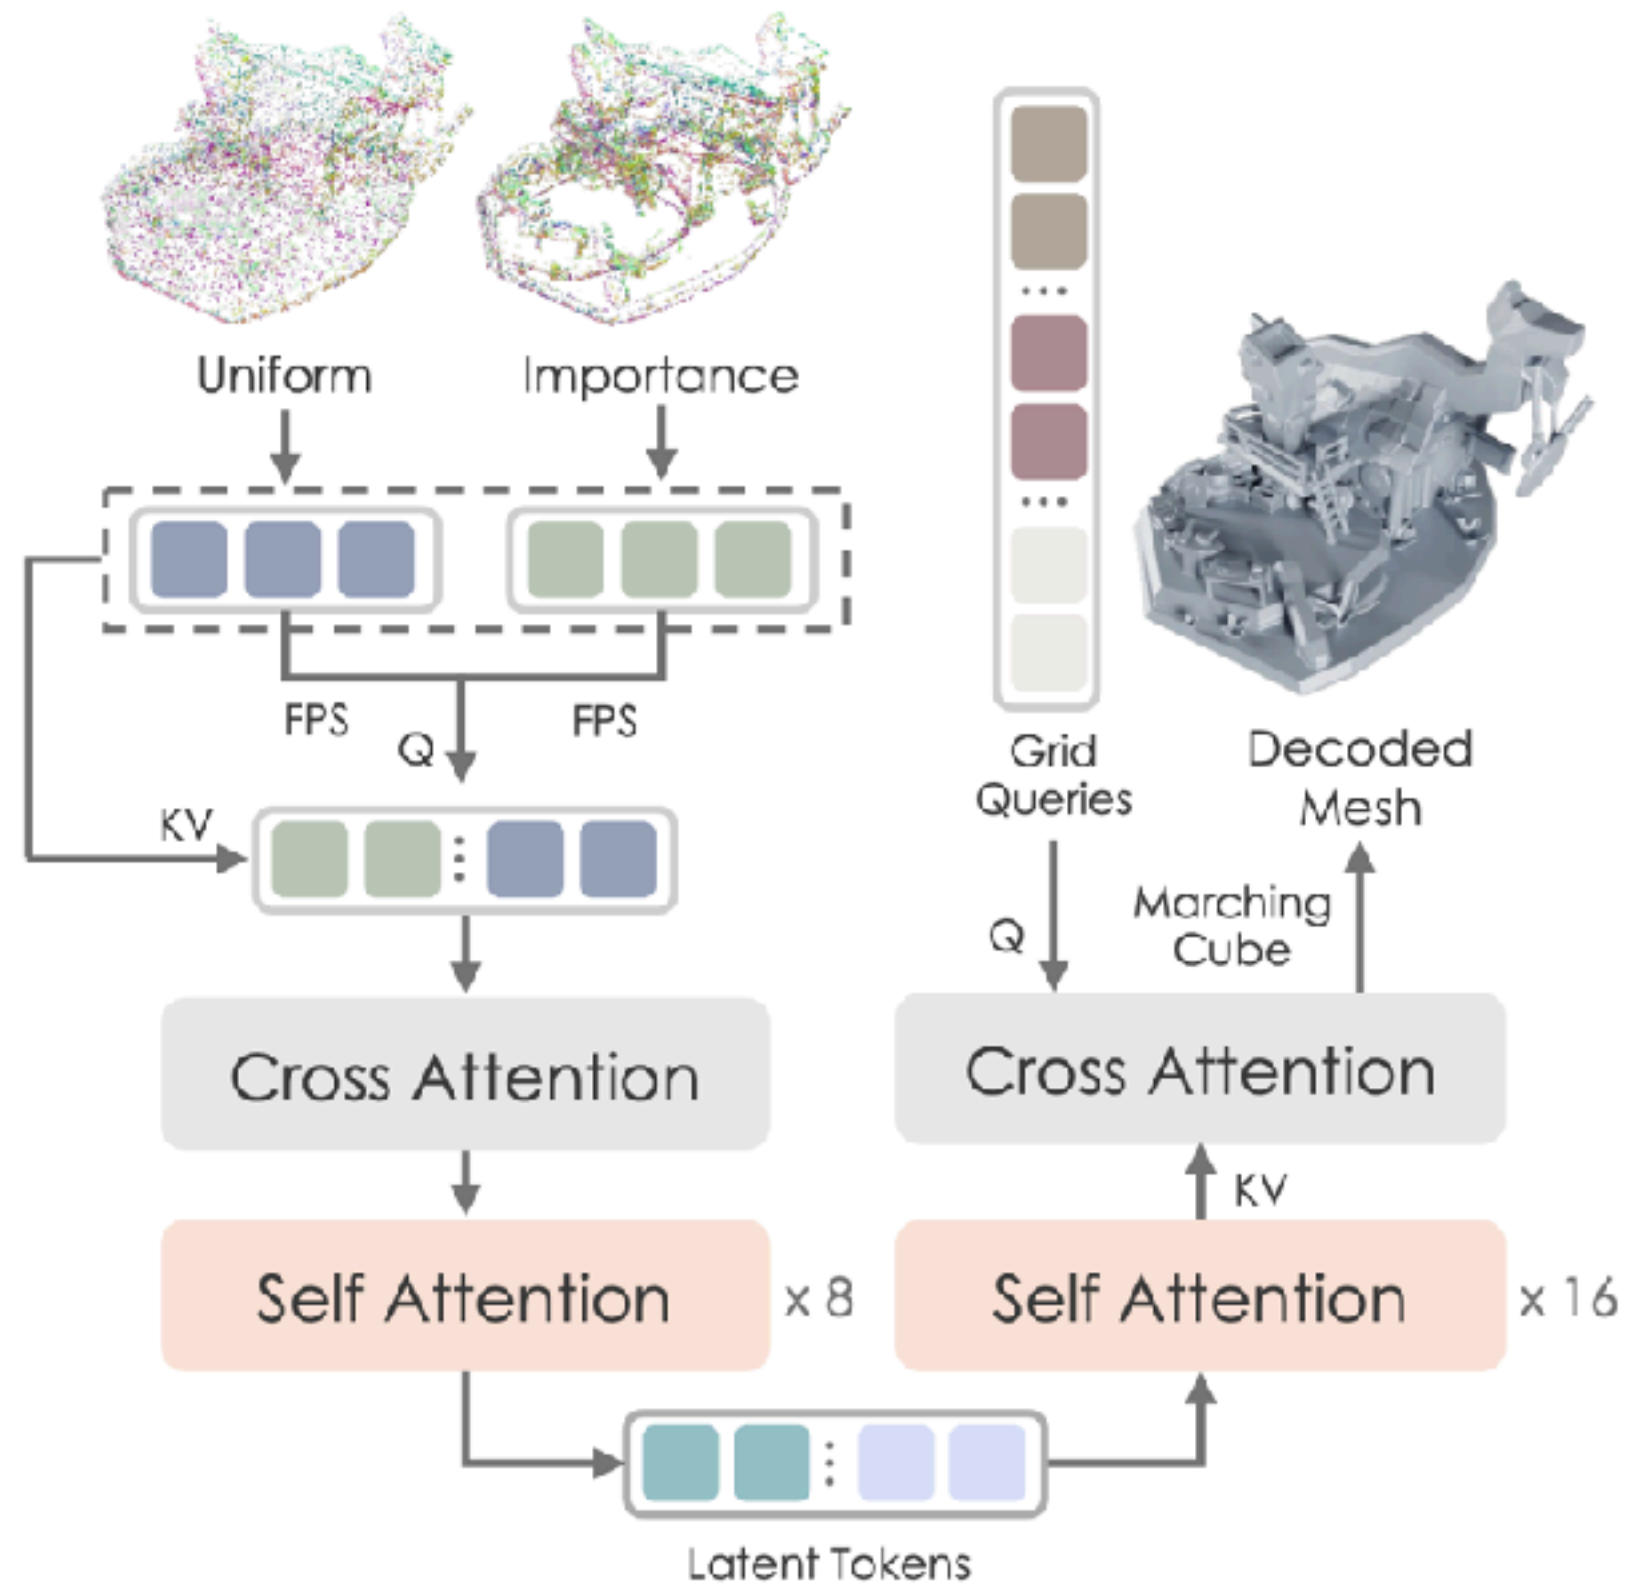


### VAE Geometry Decoder



# 3D Generatív Modellelés

## Hunyuan3D



# 3D Generatív Modellezés

## Struktúrált látens generálás (TRELLIS)

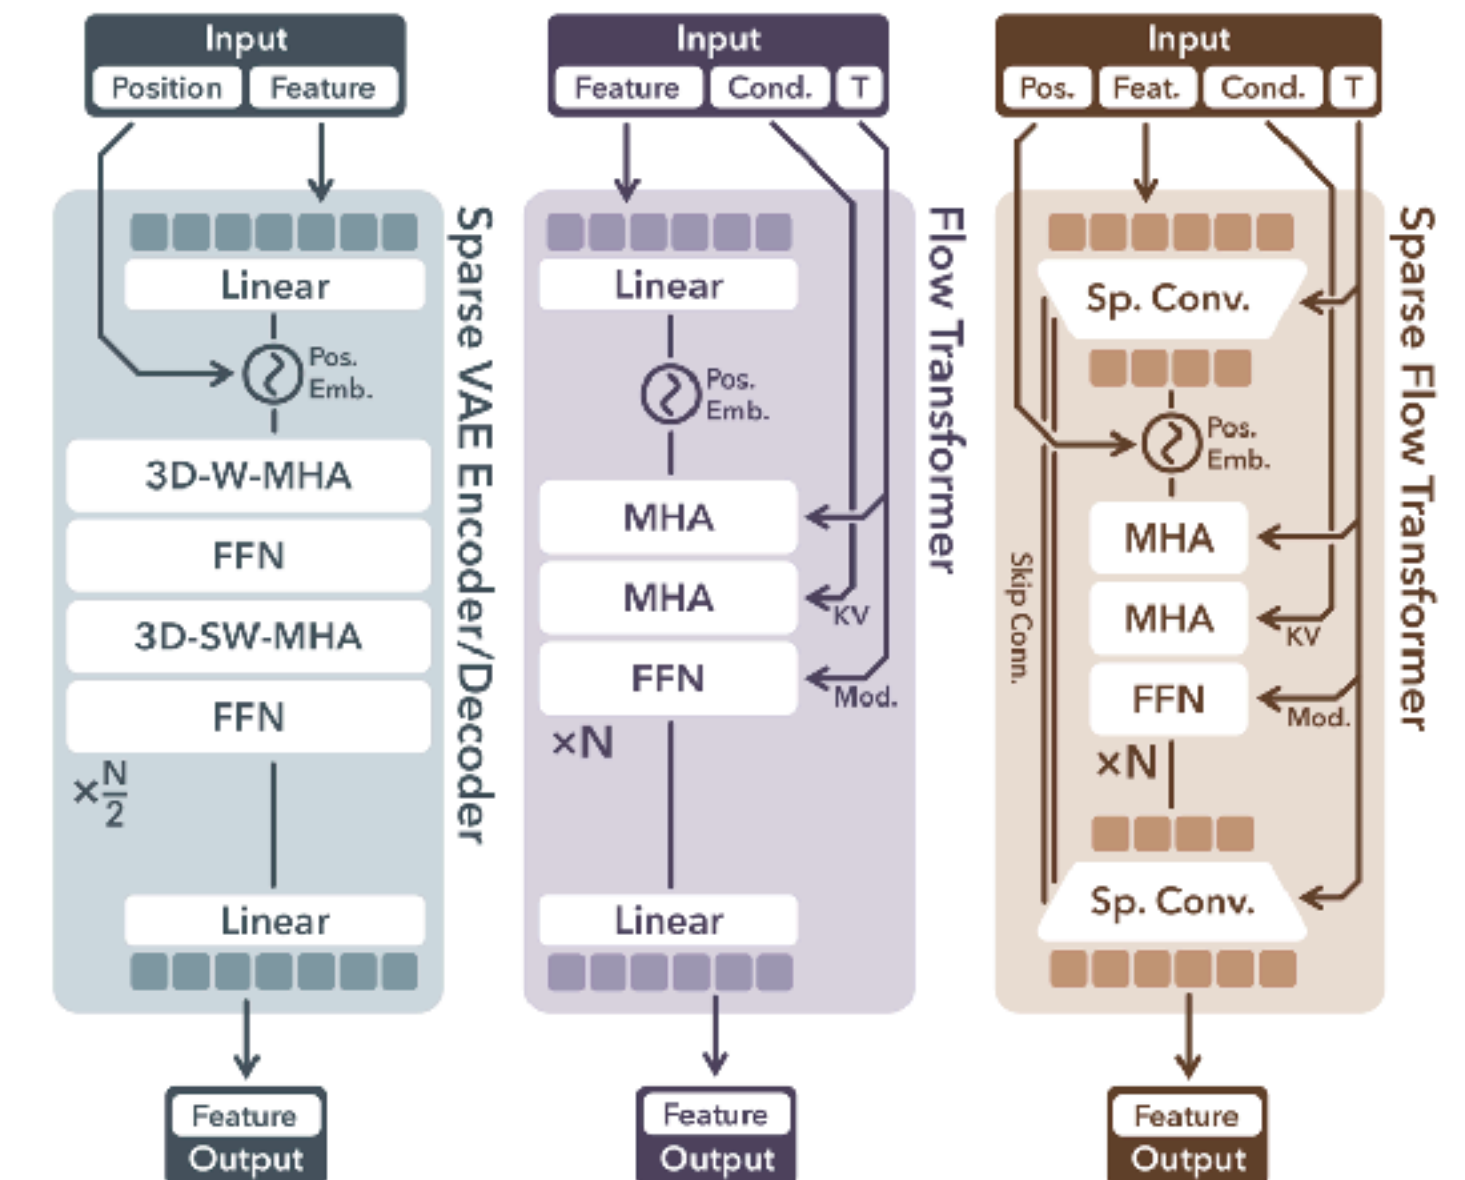



<https://microsoft.github.io/TRELLIS/>

### 3D Assets Encoding & Decoding



### 3D Assets Generation



# 3D Generatív Modellezés

## Struktúrált látens generálás (TRELLIS)


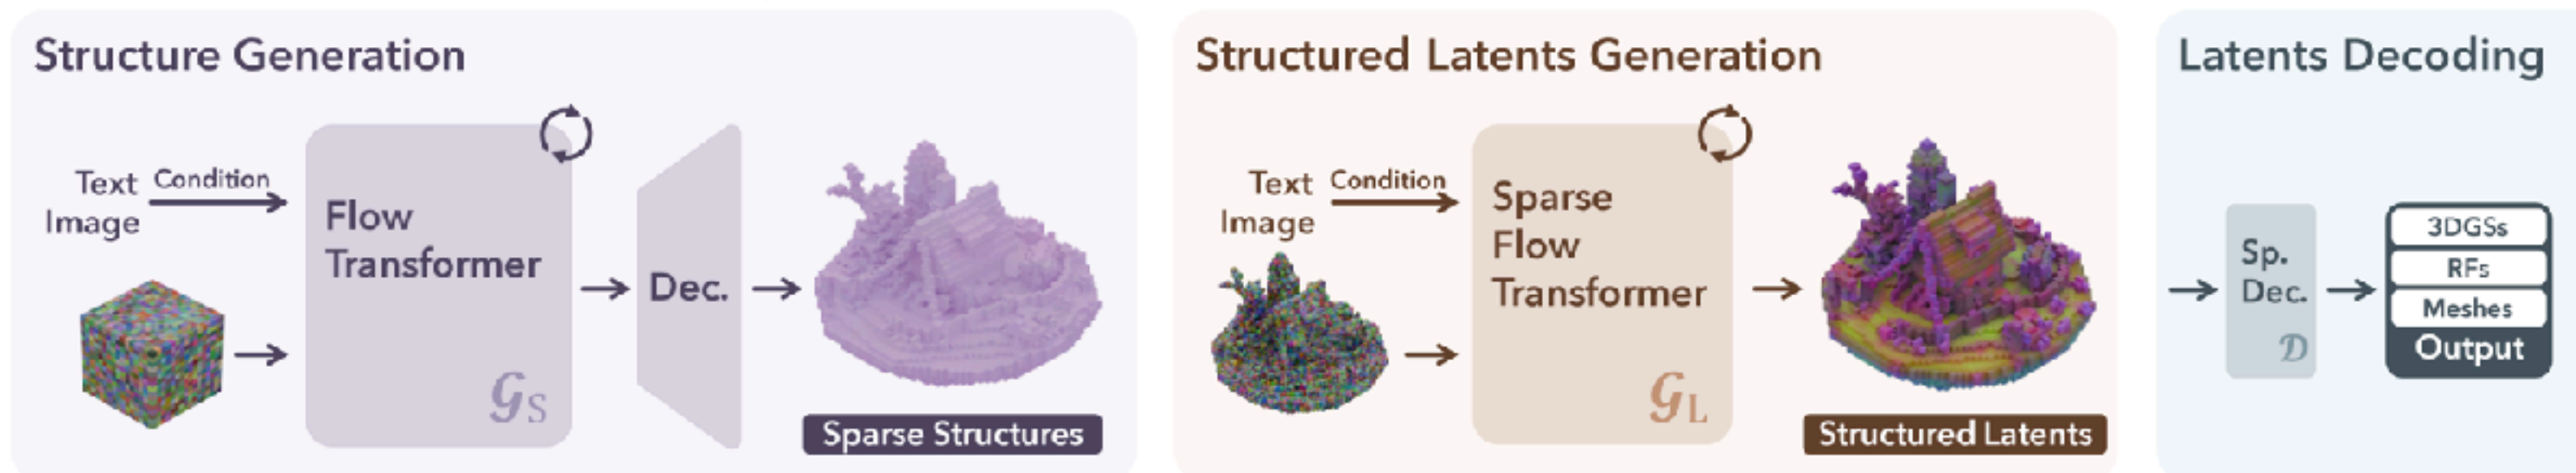


<https://microsoft.github.io/TRELLIS/>

### 3D Assets Encoding & Decoding



### 3D Assets Generation



# Következő előadás:

## Inverz grafika alapjai

