Beágyazások nemeuklideszi terekbe

Varga Dániel

Rényi Intézet

ELTE TTK Számítógéptudományi Tanszék

…de először
euklideszi terekbe

skip-gram word2vec

“You shall know a word by the company it keeps.”
(John Rupert Firth)

word embedding

- Cél: a valós vektorokon operáló mesterséges neuronhálók számárá elérhetővé tenni az írott szavak világát.
- Eszköz: egybillió szónyi összegyűjtött szöveg és hatalmas számítási kapacitás. (Google, Stanford)

softmax

$$p(w_O|w_I) = \frac{\exp({v'_{w_O}}^\top v_{w_I})}{\sum_{i=1}^{V} \exp({v'_{w_i}}^\top v_{w_I})}$$

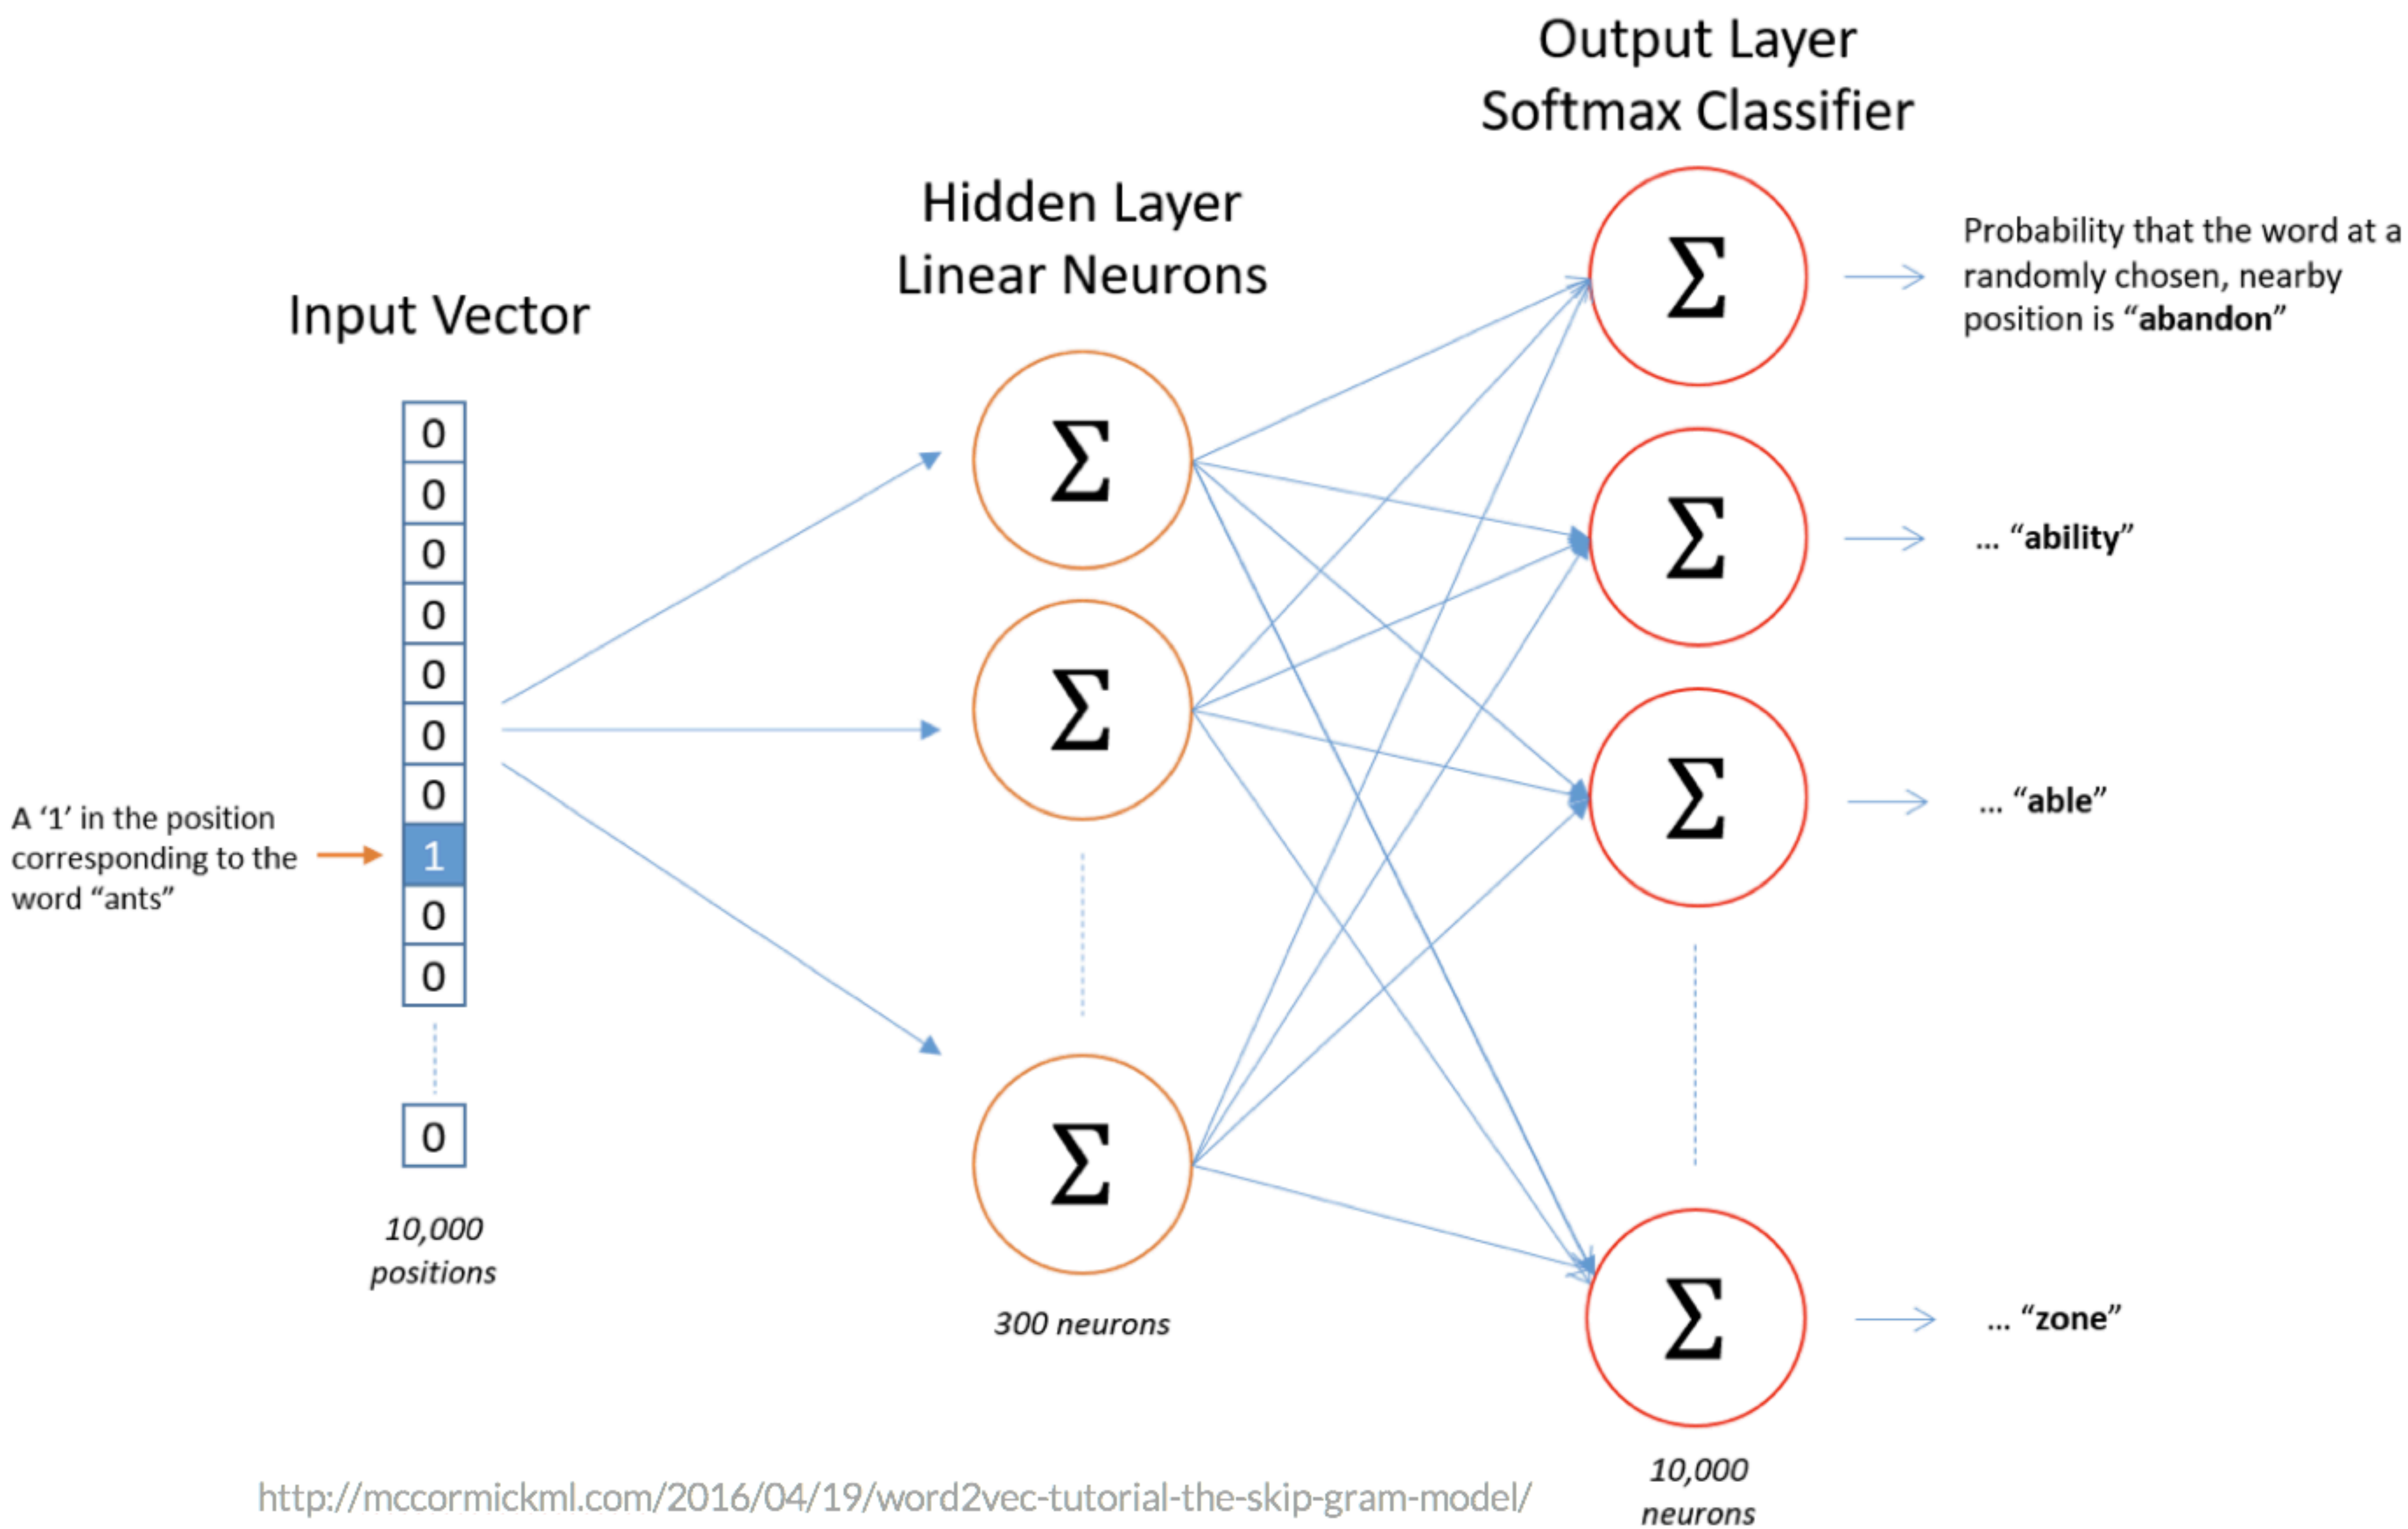
Output Layer
Softmax Classifier
Hidden Layer
Linear Neurons
Input Vector
Probability that the word at a randomly chosen, nearby position is "abandon"
... "ability"
... "able"
... "zone"
0
0
0
0
0
0
0
1
0
0
0
A '1' in the position corresponding to the word "ants"
10,000 positions
300 neurons
10,000 neurons
http://mccormickml.com/2016/04/19/word2vec-tutorial-the-skip-gram-model/

word embedding vizualizáció

http://projector.tensorflow.org/

http://127.0.0.1:8080/vis/?q=föld

kenyerek	pirosas	egerekkel	fiaik	megeszi
kiflik(349)	lilás(2476)	patkányokkal(524)	lányaik(593)	eszi(12615)
zsemlék(283)	rózsaszínes(1638)	férgekkel(513)	leányaik(251)	megenné(563)
lepények(202)	barnás(6463)	majmokkal(606)	férjeik(759)	elfogyasztja(1129)
pogácsák(539)	sárgás(7365)	hangyákkal(343)	gyermekeik(12028)	megeszik(6433)
pékáruk(771)	zöldes(5215)	nyulakkal(366)	feleségeik(638)	Megeszi(189)
péksütemények(997)	fehéres(2517)	legyekkel(252)	gyerekeik(5806)	megette(7868)
sonkák(613)	vöröses(5496)	rágcsálókkal(259)	asszonyaik(458)	megrágja(477)
tészták(2466)	feketés(1157)	hüllőkkel(241)	gyermekei(31241)	megeheti(287)
kalácsok(277)	narancssárgás(429)	pókokkal(436)	fiak(1523)	bekapja(977)
kekszek(1046)	sárgászöld(723)	bogarakkal(425)	unokái(3528)	lenyeli(1862)

Siklósi, Novák 2016

kenyér	eszik	csavargó	csónak	franciakulcs
hús(136814)	iszik(244247)	koldus(15793)	tutaj(3950)	feszítővas(846)
kalács(10658)	főz(120634)	zsivány(3497)	ladik(3895)	csípőfogó(345)
rizs(31678)	csinál(1194585)	haramia(2024)	motorcsónak(4079)	csavarkulcs(473)
zsemle(6690)	megeszik(68347)	vadember(2497)	hajó(238807)	kisbalta(491)
pogácsa(11066)	fogyaszt(160724)	csirkefogó(2019)	kenu(6649)	konyhakés(1501)
sajt(46660)	etet(43539)	szatír(1649)	kocsi(283438)	pajszer(567)
kifli(9715)	zabál(13699)	útonálló(1942)	gumicsónak(1033)	partvis(648)
krumpli(37271)	megiszik(31002)	bandita(6334)	mentőcsónak(2511)	villáskulcs(764)
búzakenyér(306)	eszeget(3928)	suhanc(4144)	dereglye(962)	erővágó(360)
tej(113911)	alszik(359268)	vándor(14070)	sikló(4394)	péklapát(475)

Siklósi, Novák 2016

angolúl	mittomén	hehehe
magyarúl(486)	mittudomén(2969)	hihihi(1203)
németűl(132)	mifene(2455)	hahaha(3822)
francziáúl(25)	mittoménmi(412)	höhö(1827)
angolol(27)	mittudoménmi(441)	brr(1212)
írül(95)	nemtommi(469)	muhaha(1498)
mindenrõl(422)	neadjisten(1741)	heh(1603)
minderrõl(129)	blablabla(2590)	Muhaha(879)
ilyenröl(58)	stbstb(1739)	muhahaha(428)
Amirõl(143)	bla-bla-bla(711)	hajaj(1579)
olyasmirôl(38)	jahh(466)	höhöhö(361)

Siklósi, Novák 2016

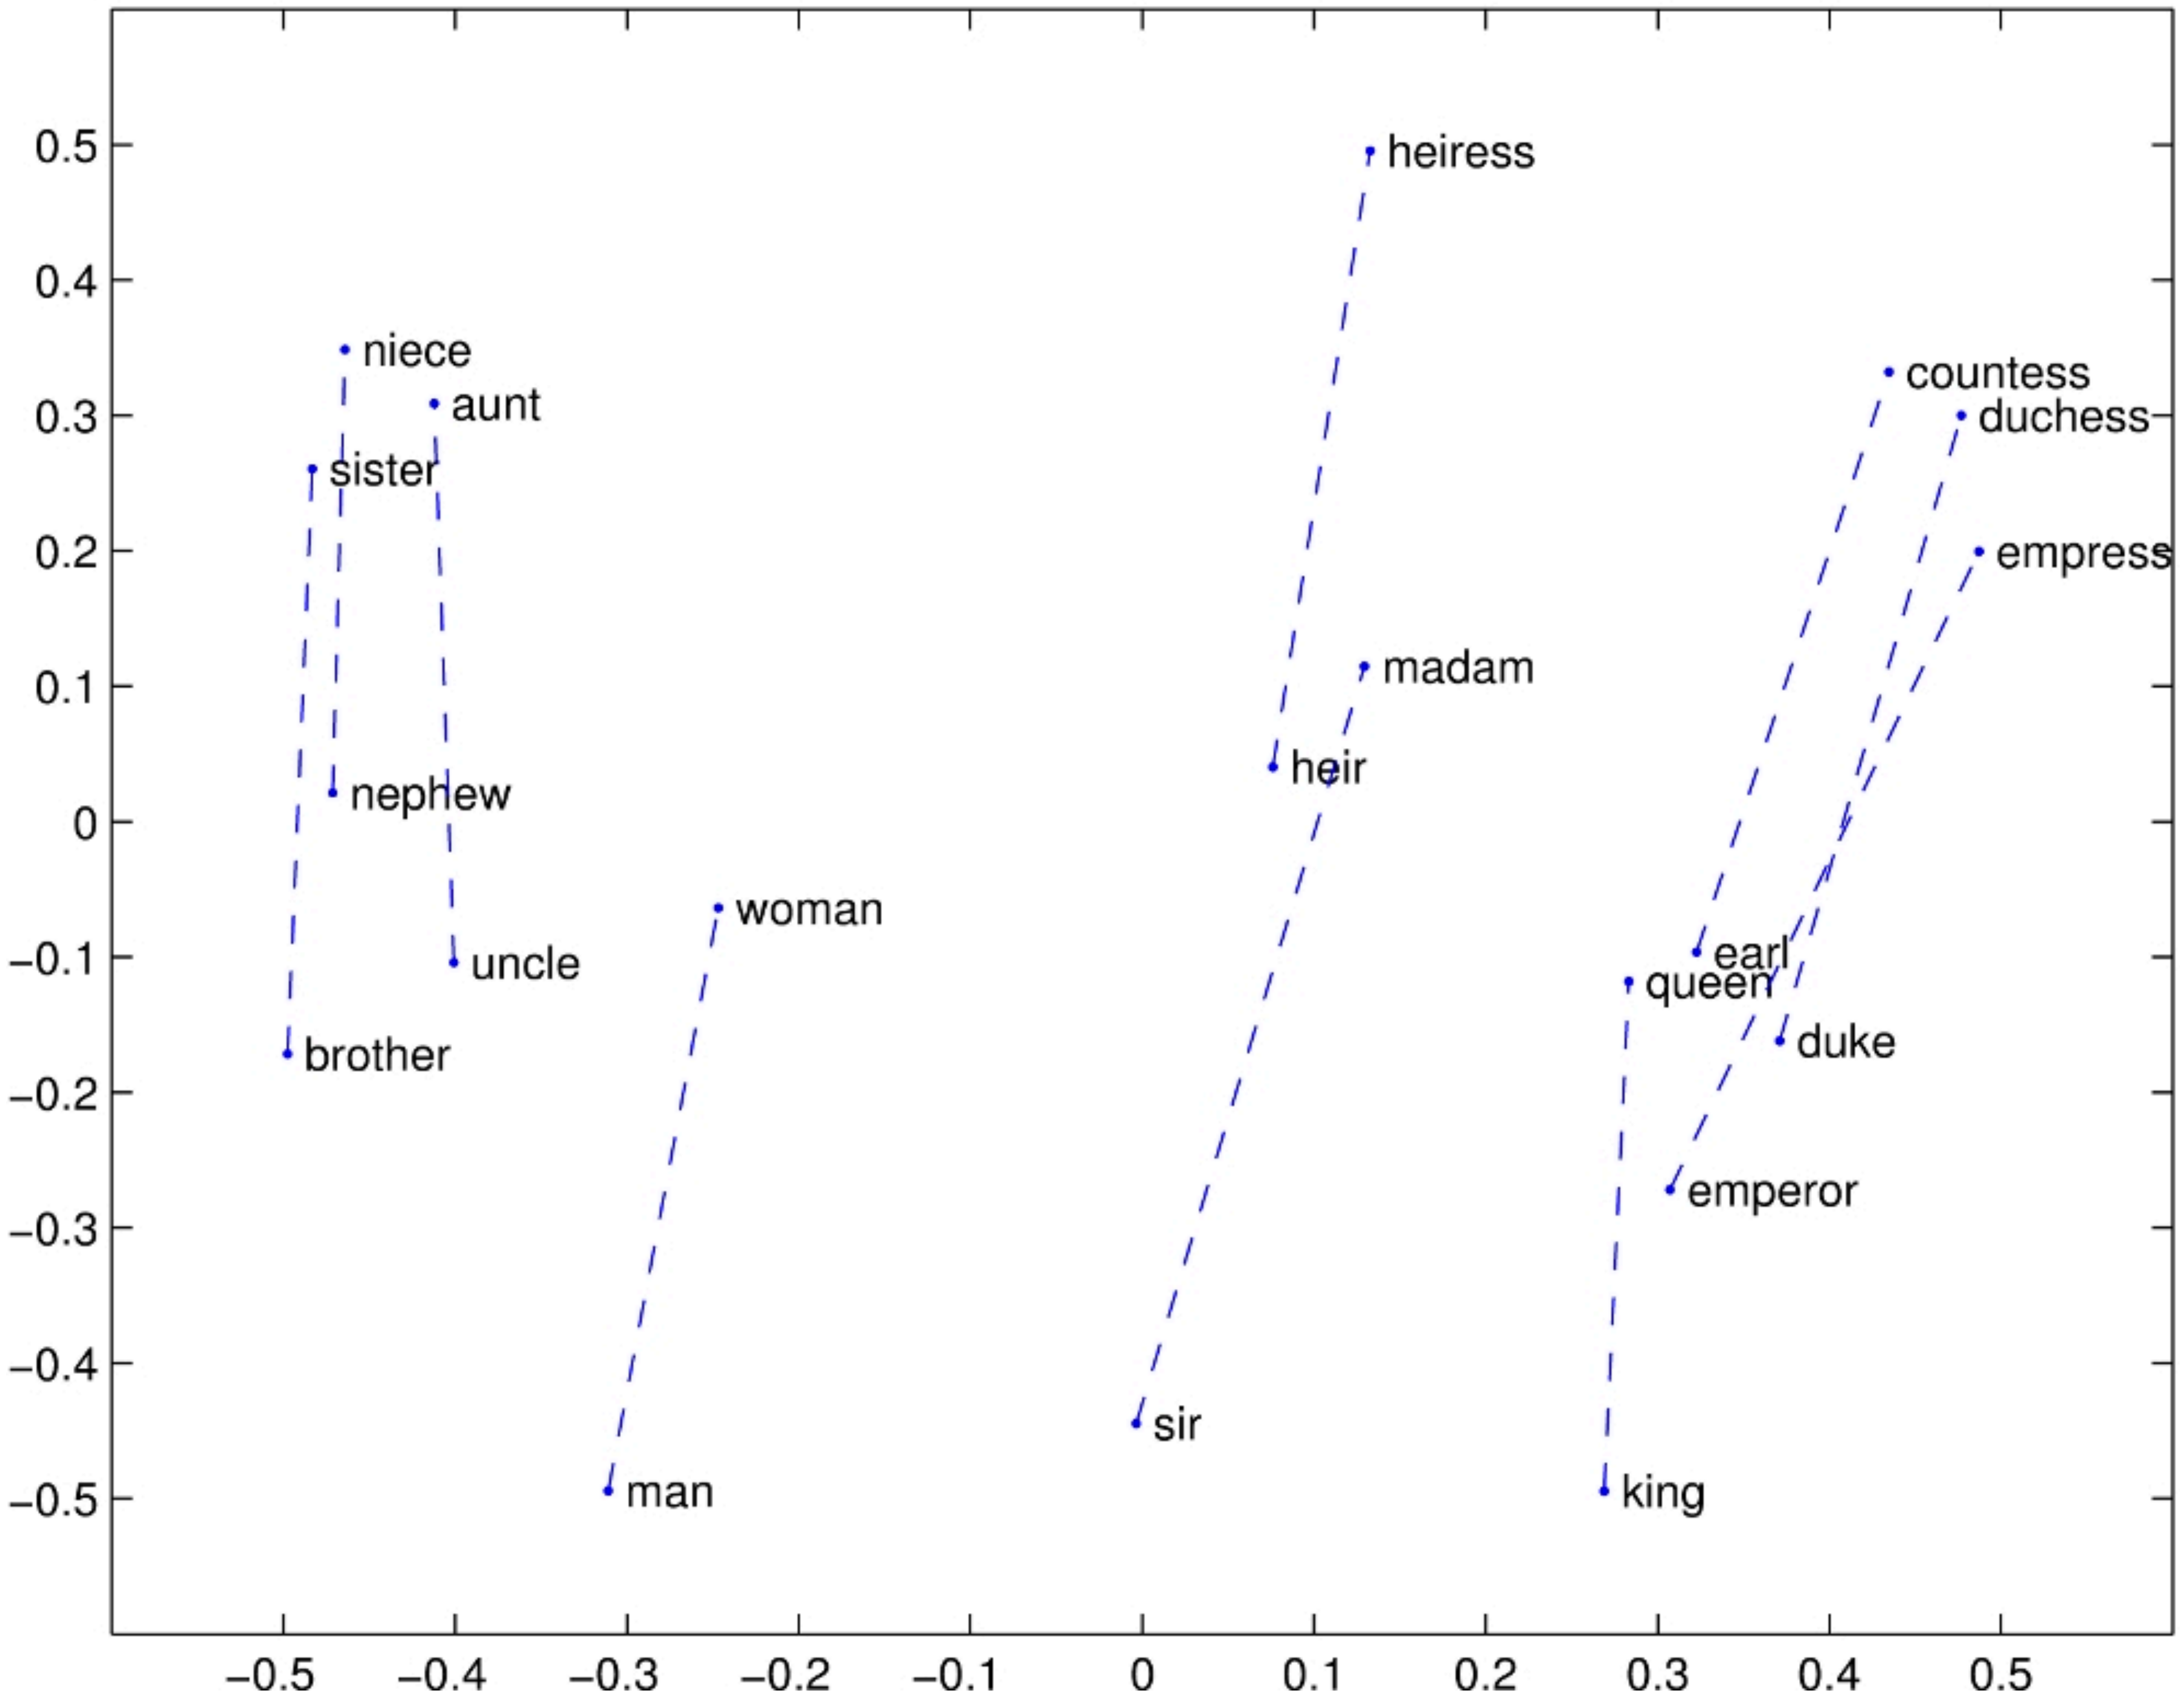

heiress
niece
aunt
sister
countess
duchess
empress
madam
heir
nephew
woman
uncle
earl
queen
duke
brother
emperor
sir
man
king
0.5
0.4
0.3
0.2
0.1
0
−0.1
−0.2
−0.3
−0.4
−0.5
−0.5
−0.4
−0.3
−0.2
−0.1
0
0.1
0.2
0.3
0.4
0.5

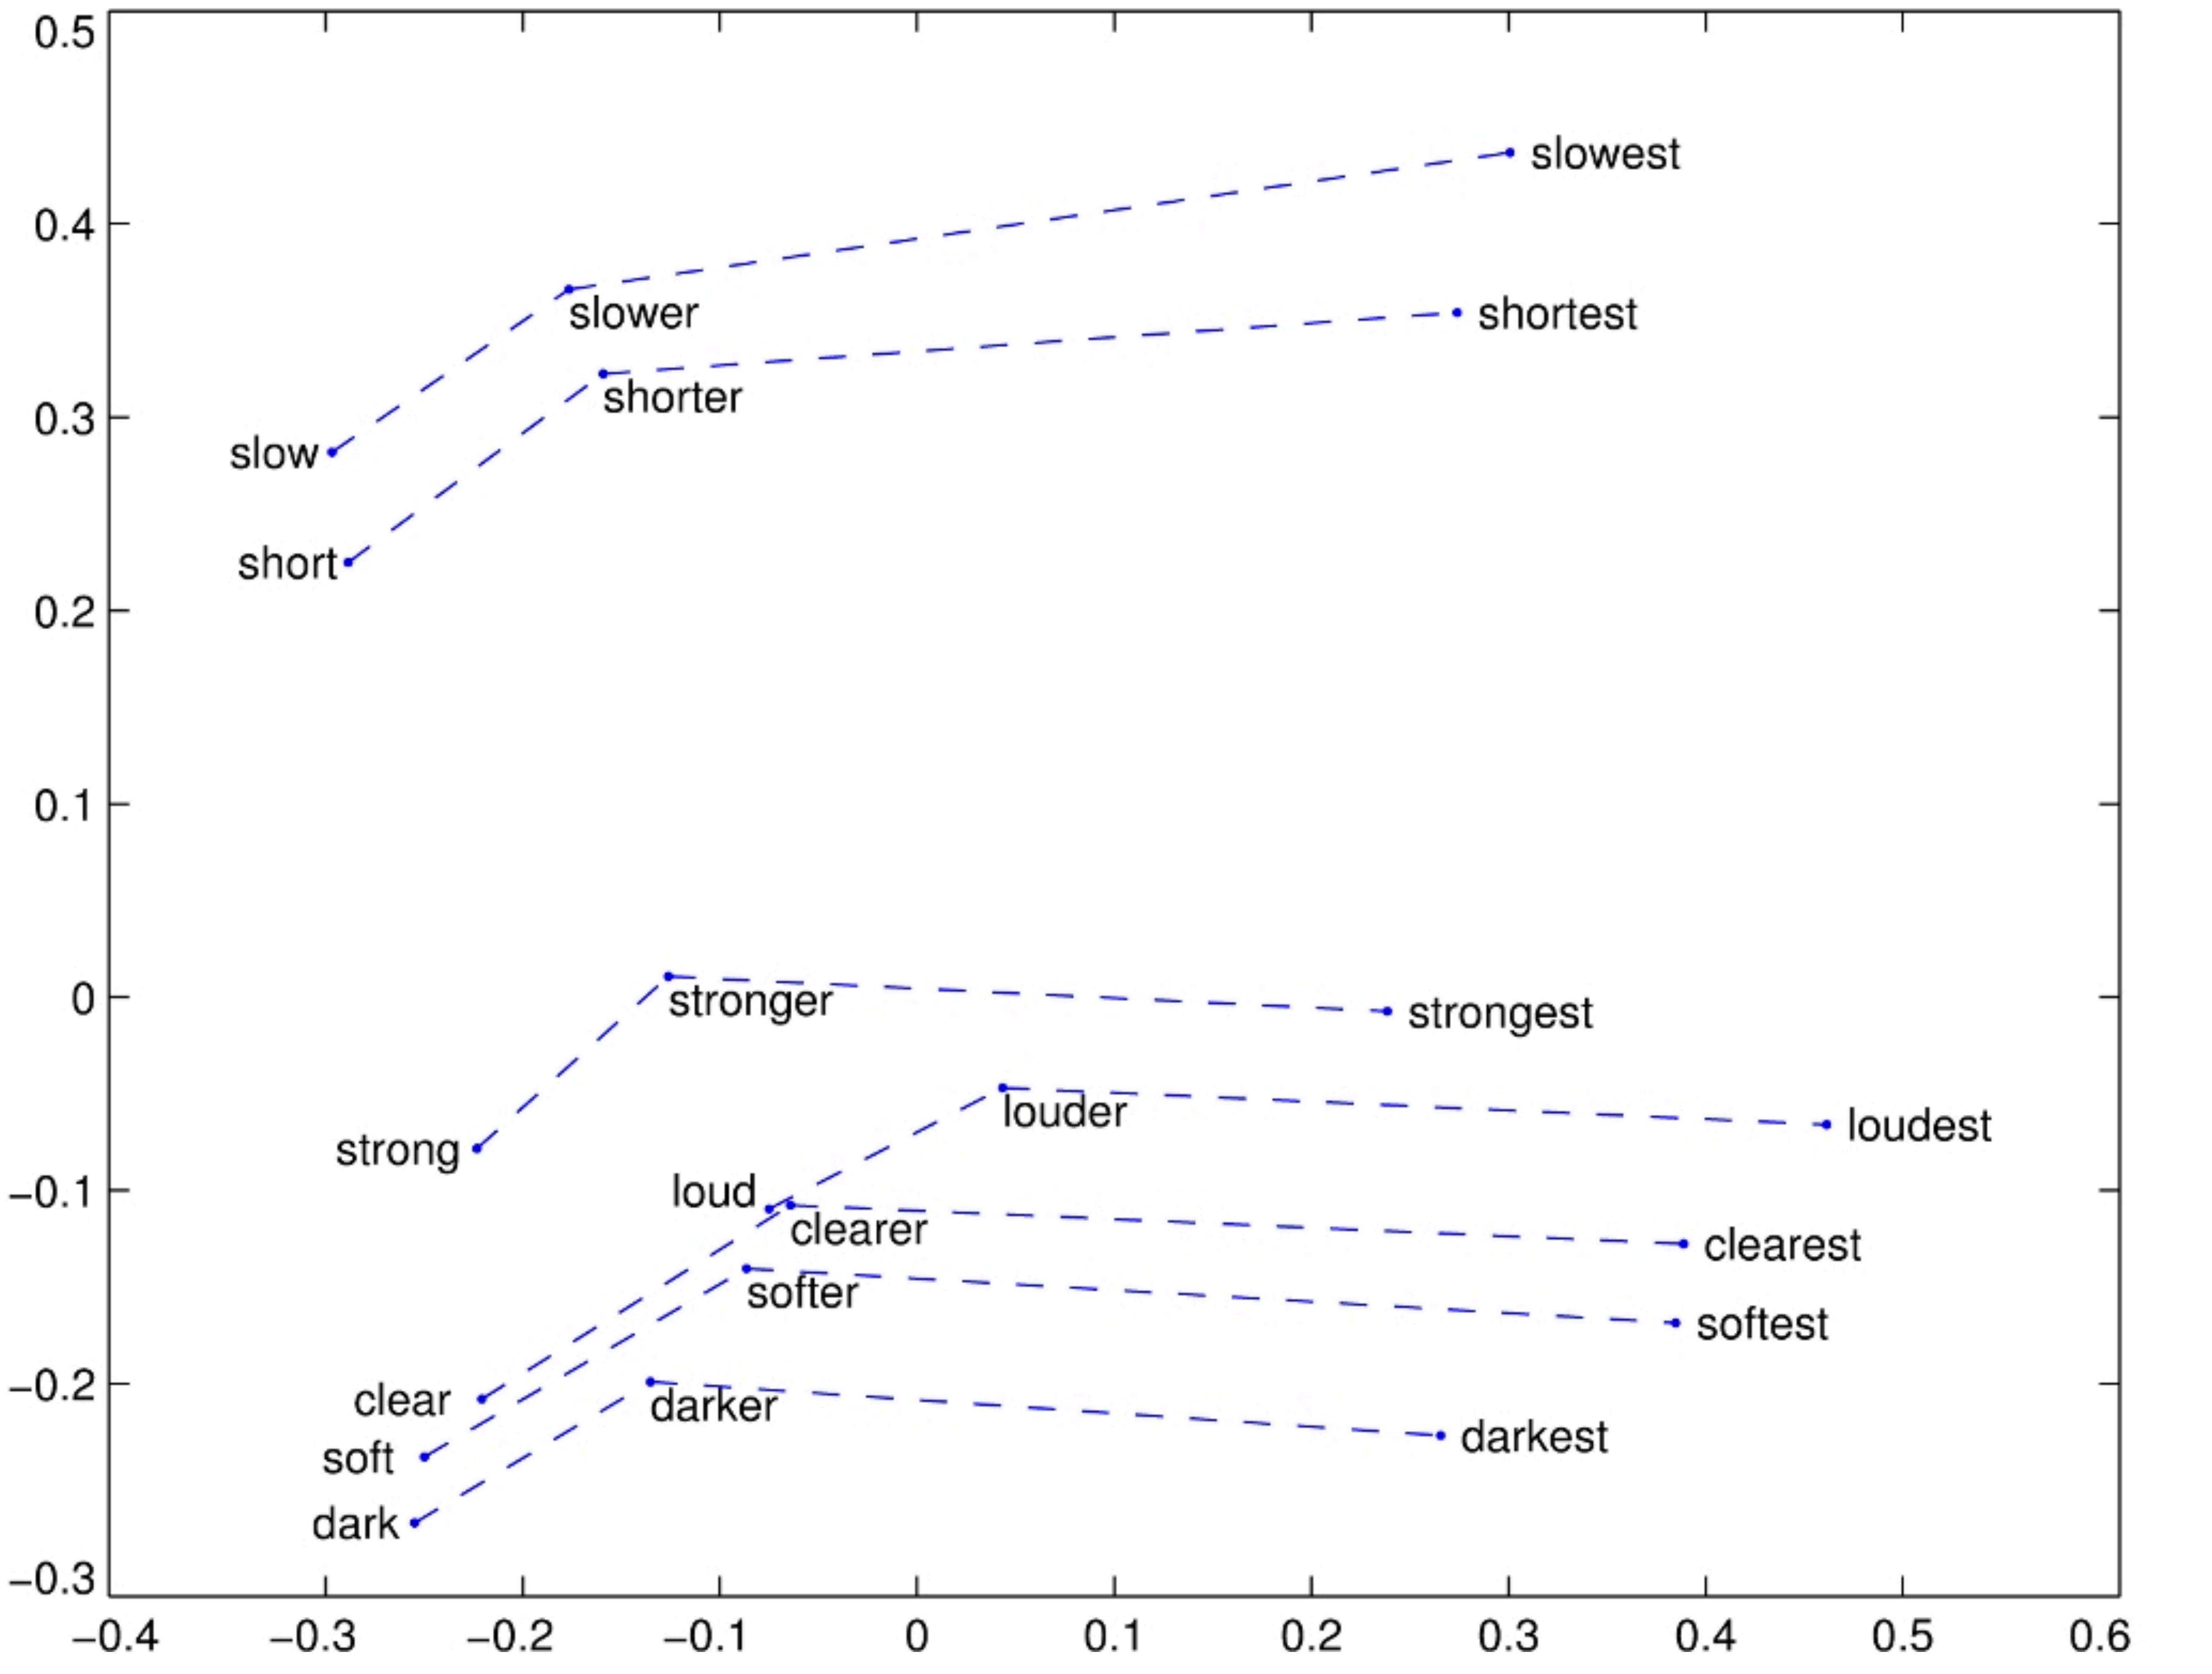

slowest
slower
shortest
shorter
slow
short
stronger
strongest
strong
louder
loudest
loud
clearer
clearest
softer
softest
clear
soft
darker
darkest
dark
0.5
0.4
0.3
0.2
0.1
0
−0.1
−0.2
−0.3
−0.4
−0.3
−0.2
−0.1
0
0.1
0.2
0.3
0.4
0.5
0.6

Rome - Italy + China = Beijing
China - Taiwan + Russia = Ukraine
house - roof + castle = dome
knee - leg + elbow = forearm
love - indifference + fear = apathy

https://deeplearning4j.org/word2vec.html

kicsit előreugorva az autoencoderekhez

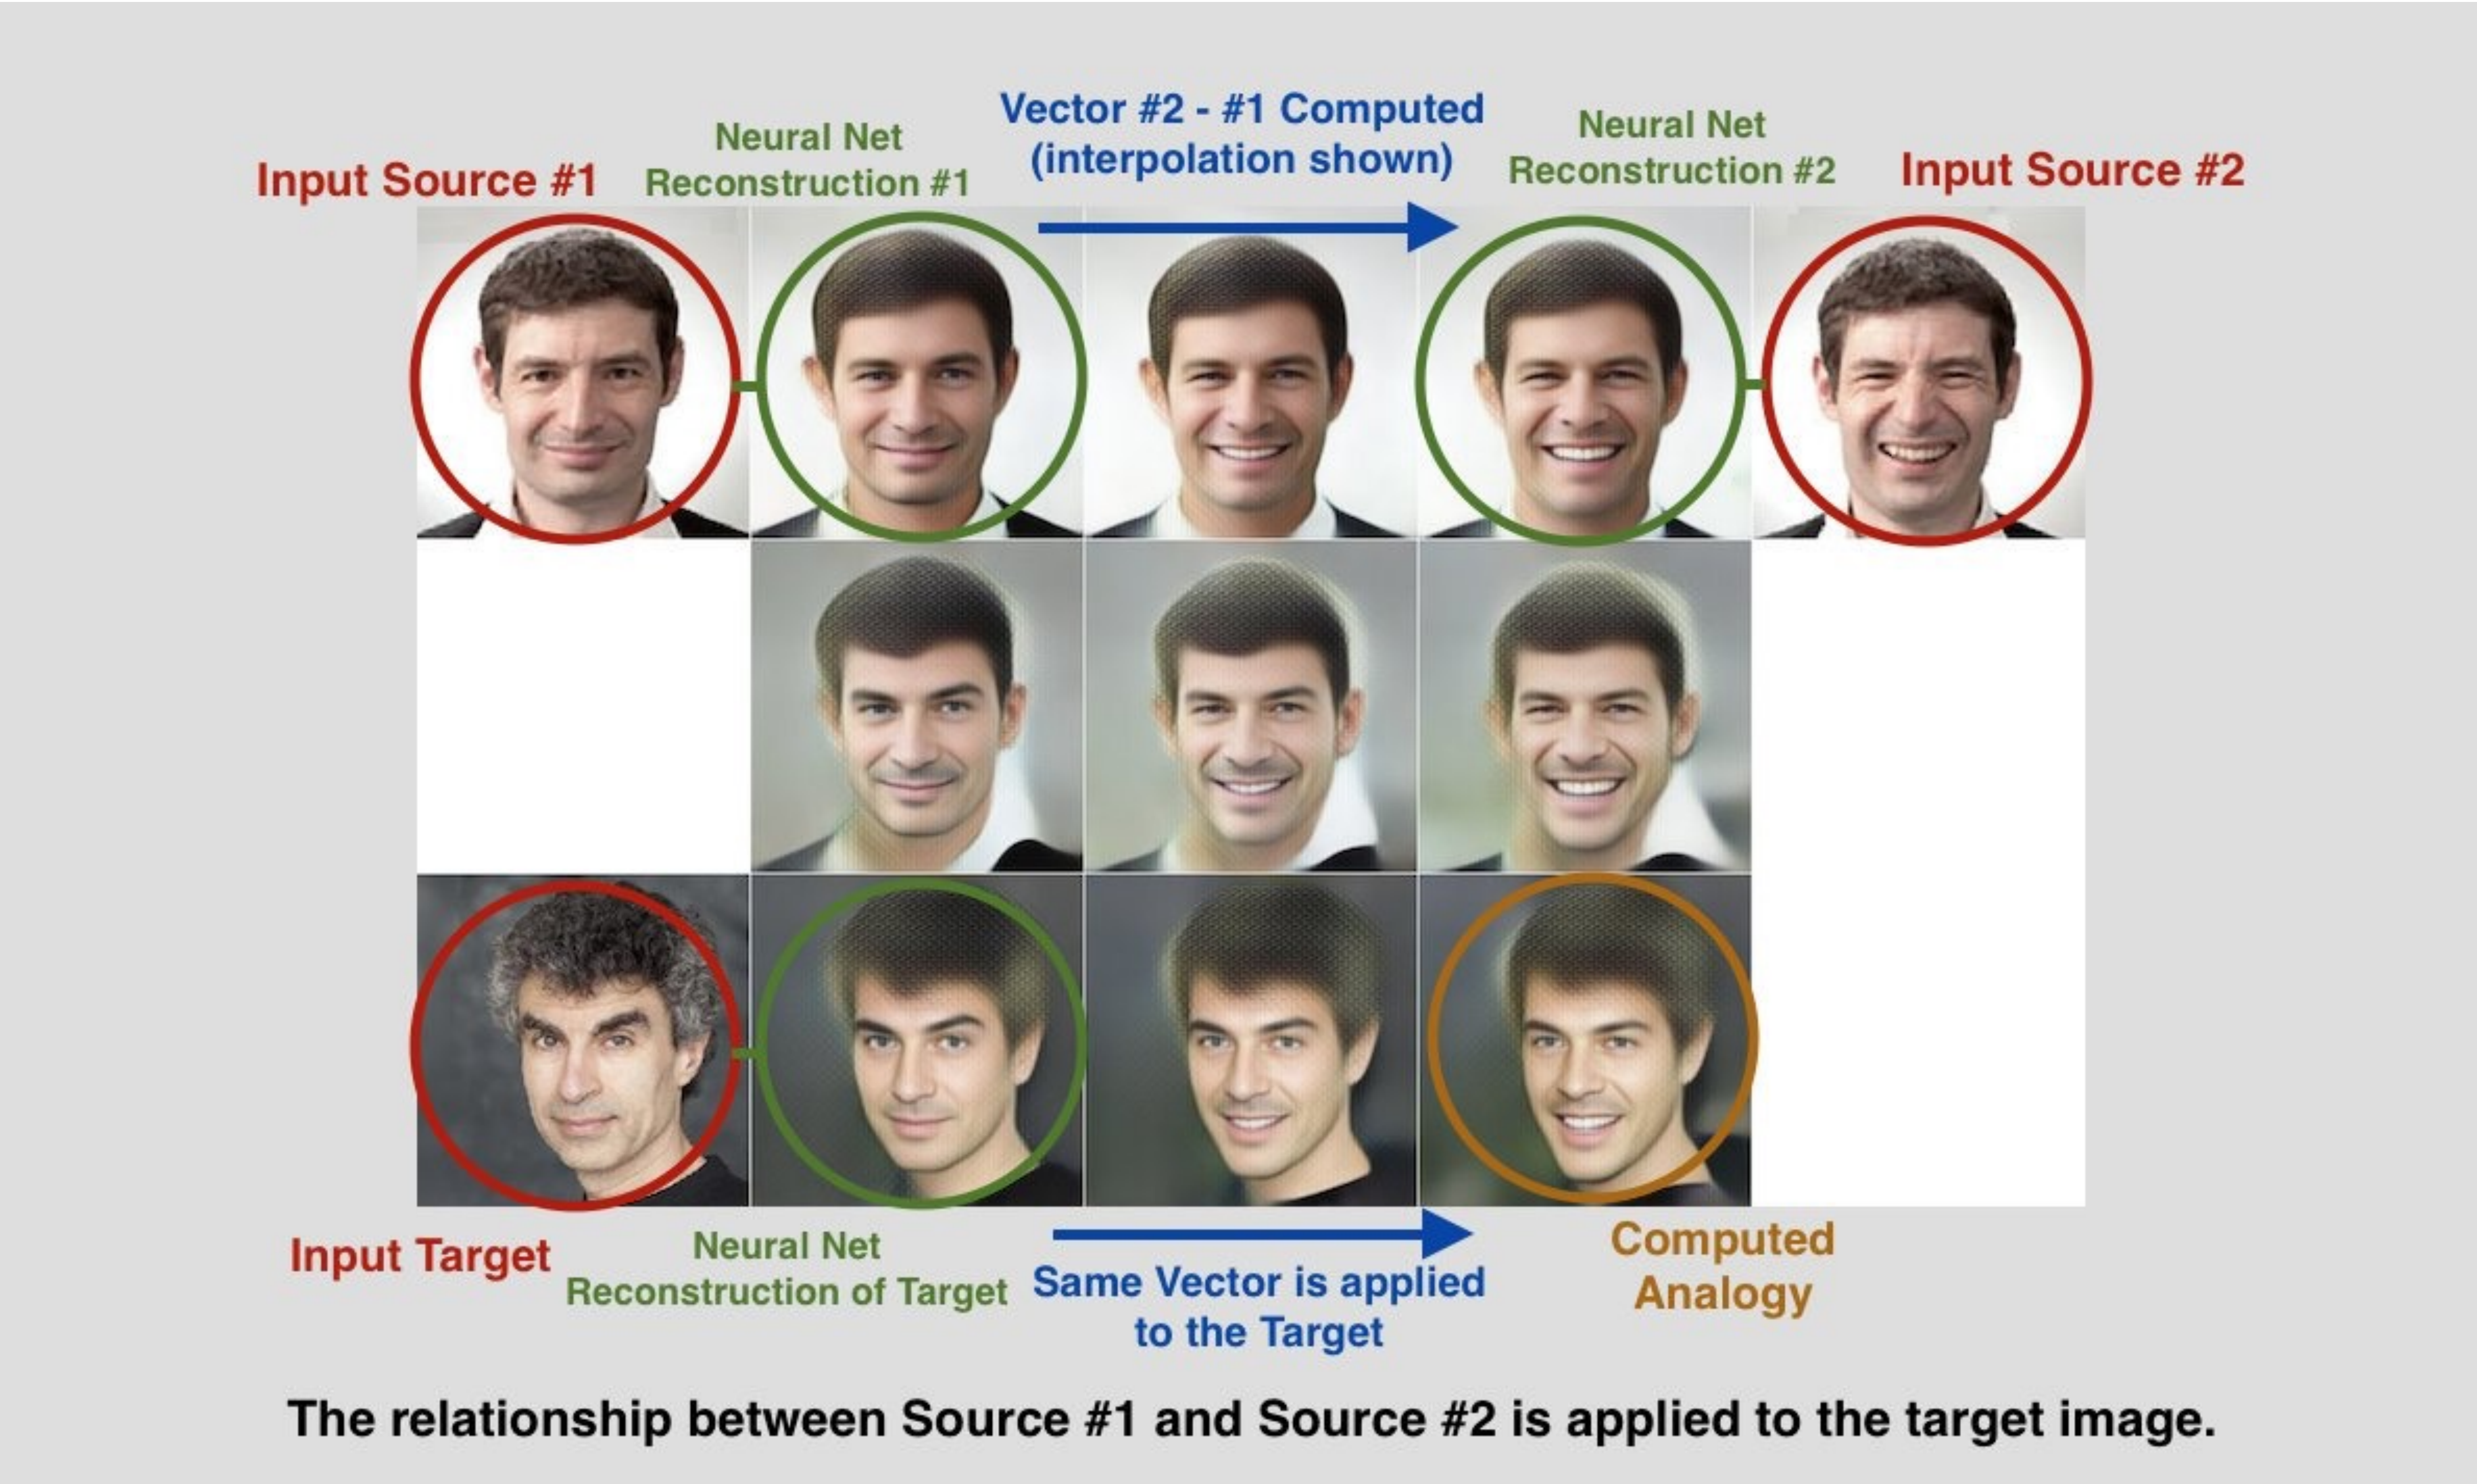

Input Source #1
Neural Net Reconstruction #1
Vector #2 - #1 Computed (interpolation shown)
Neural Net Reconstruction #2
Input Source #2
Input Target
Neural Net Reconstruction of Target
Same Vector is applied to the Target
Computed Analogy
The relationship between Source #1 and Source #2 is applied to the target image.

Tom White

Reconstruction	Gender-biased smilevector	Gender-balanced smilevector

Tom White

Hiperbolikus terek

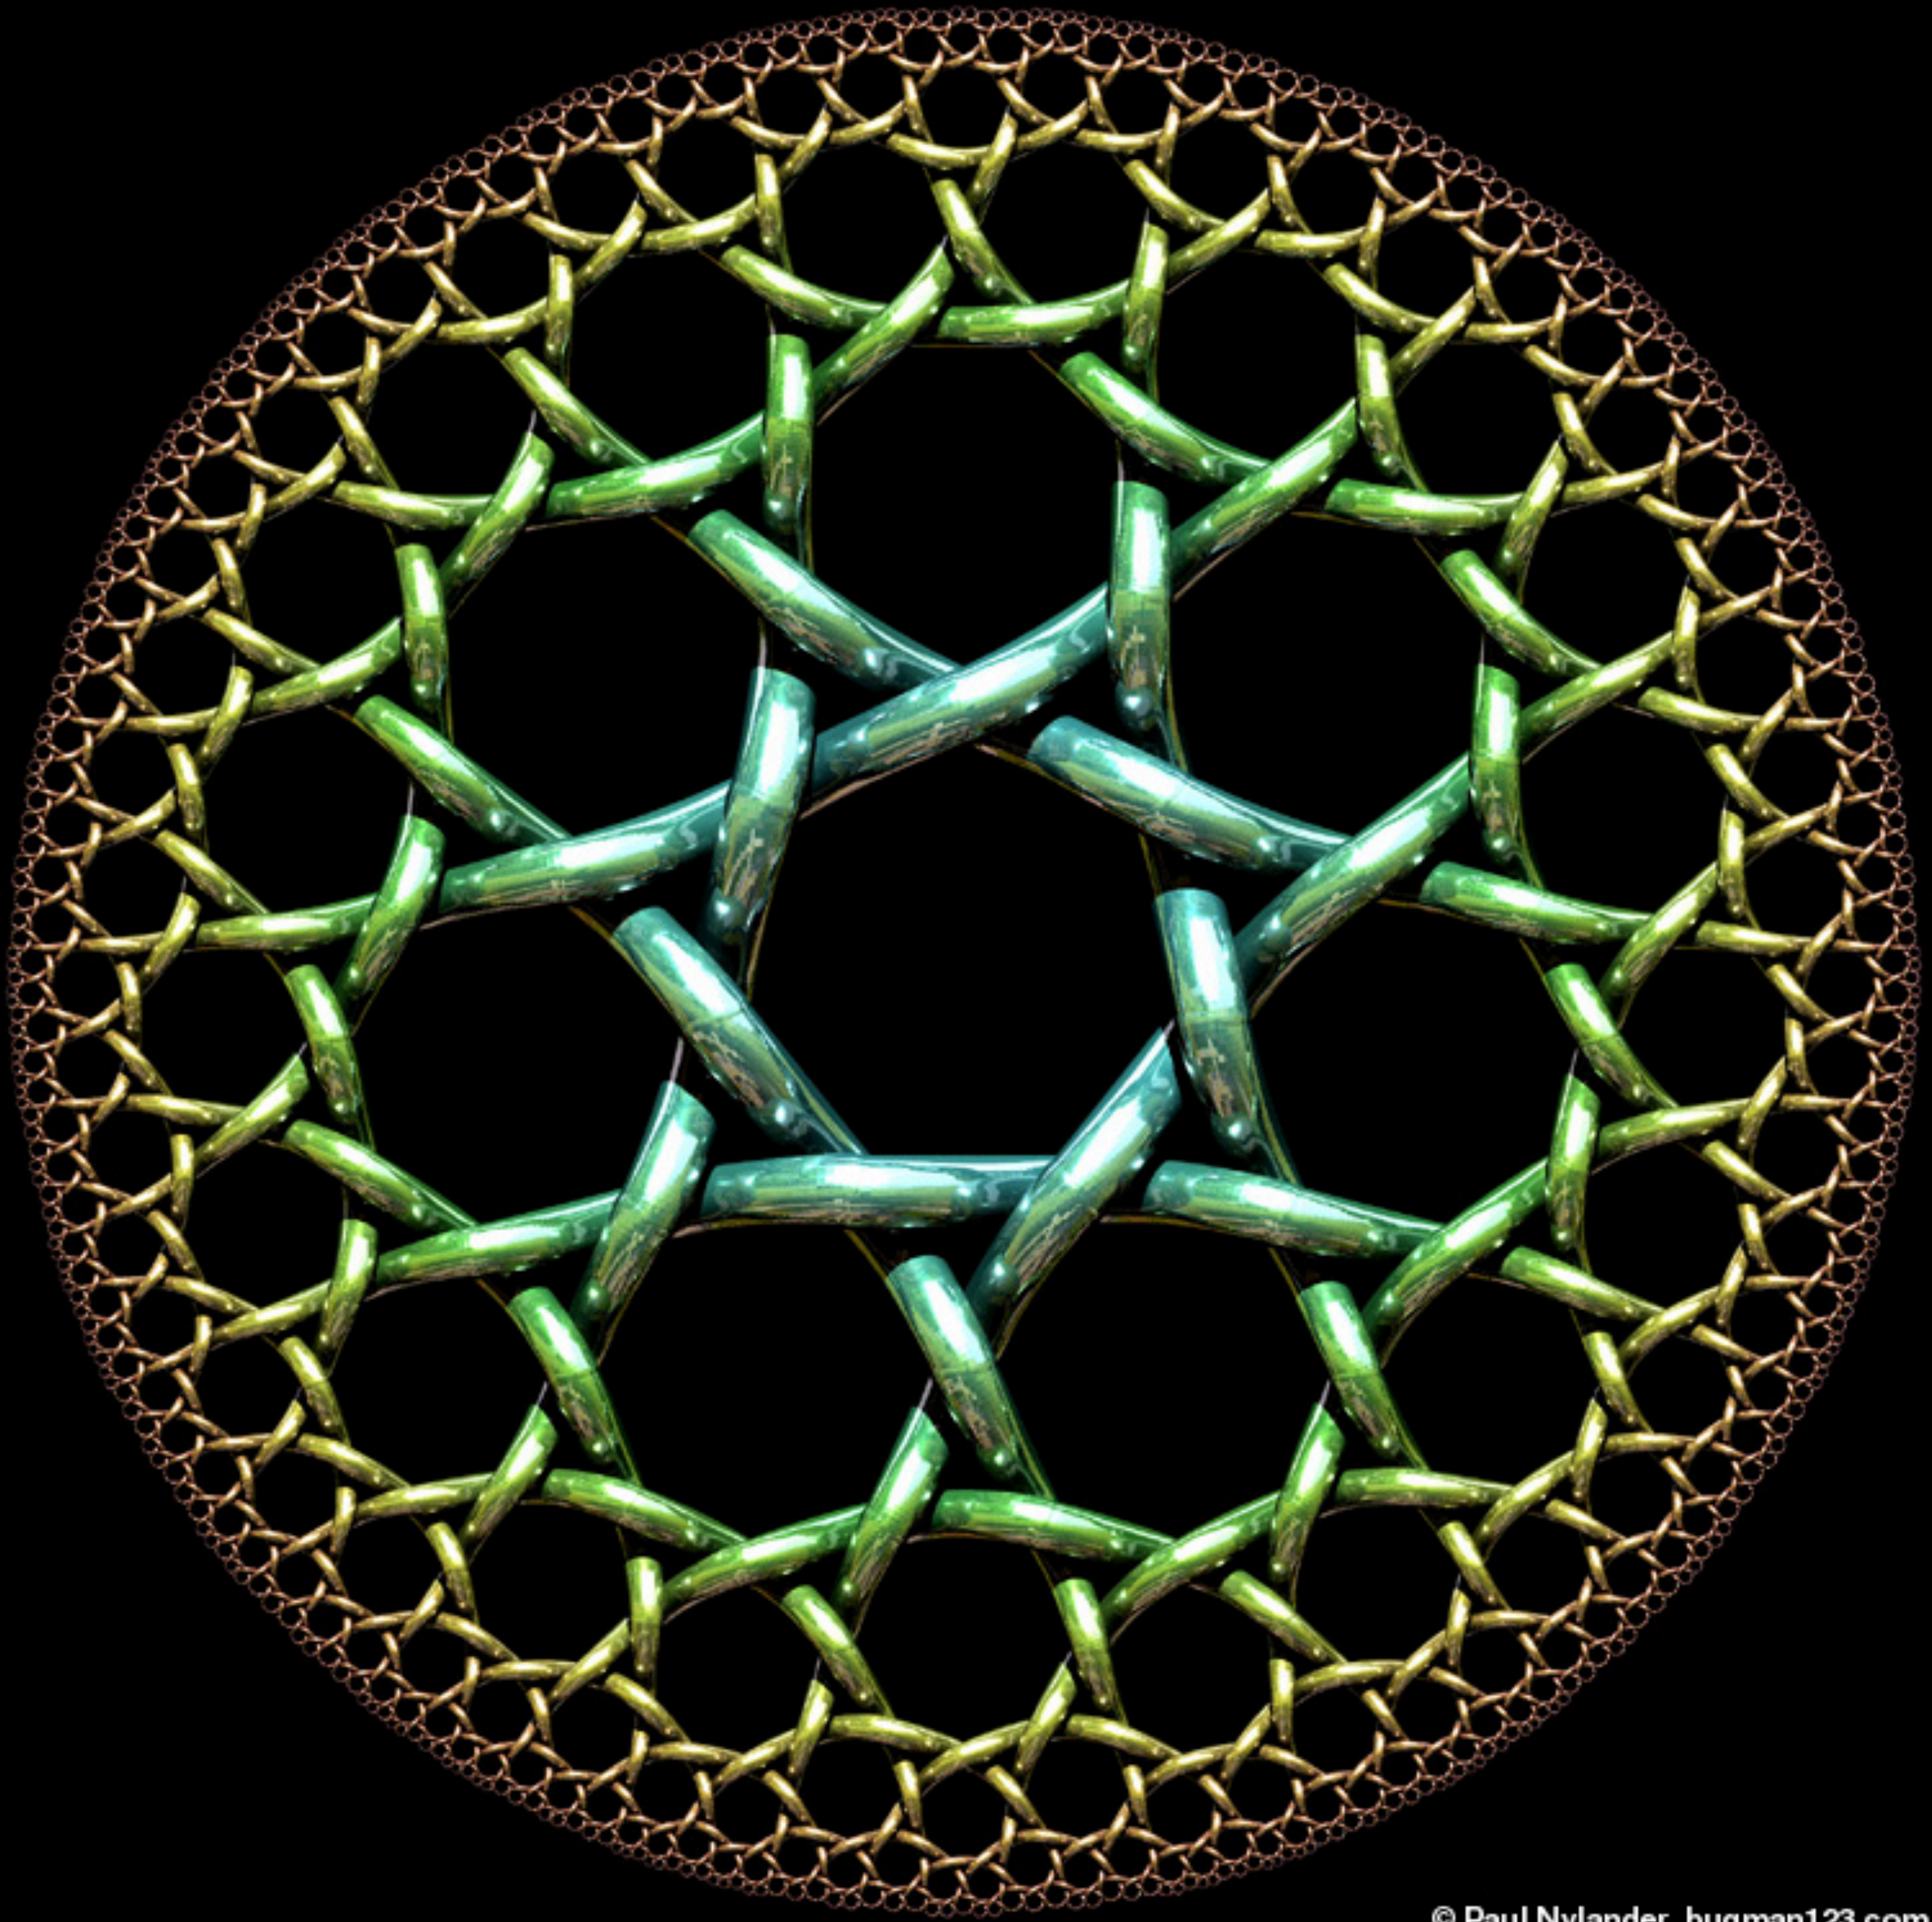

© Paul Nylander, bugman123.com

“[…] random geometric graphs in hyperbolic spaces are an adequate model for complex networks. The high-level explanation of this connection is that complex networks exhibit hierarchical, tree-like organization, while hyperbolic geometry is the geometry of trees. Graphs representing complex networks appear then as discrete samples from the continuous world of hyperbolic geometry.”

(Fragkiskos Papadopoulos)

https://www.caida.org/publications/papers/2015/network_mapping_replaying_hyperbolic/network_mapping_replaying_hyperbolic.pdf

Poincaré Embeddings

$$d(\boldsymbol{u}, \boldsymbol{v}) = \operatorname{arcosh}\left(1 + 2\frac{\|\boldsymbol{u} - \boldsymbol{v}\|^2}{(1 - \|\boldsymbol{u}\|^2)(1 - \|\boldsymbol{v}\|^2)}\right)$$

Nickel and Kiela

https://arxiv.org/pdf/1705.08039.pdf

Poincaré Embeddings

minimalizáljuk, azaz
maximum likelihood

ez nem logit

$$\mathcal{L}(\Theta) = -\sum_{(\boldsymbol{u},\boldsymbol{v})\in D} log \frac{e^{-d(\boldsymbol{u},\boldsymbol{v})}}{\sum_{v\prime\in\mathcal{N}(u)} e^{-d(\boldsymbol{u},\boldsymbol{v}\prime)}}$$

$$\mathcal{L}(\Theta) = -\sum_{(\boldsymbol{u},\boldsymbol{v})\in D} log \frac{e^{-d(\boldsymbol{u},\boldsymbol{v})}}{e^{-d(\boldsymbol{u},\boldsymbol{v})} + \sum_{v\prime\in\mathcal{N}(u)} e^{-d(\boldsymbol{u},\boldsymbol{v}\prime)}}$$

ez hiányzott kicsit

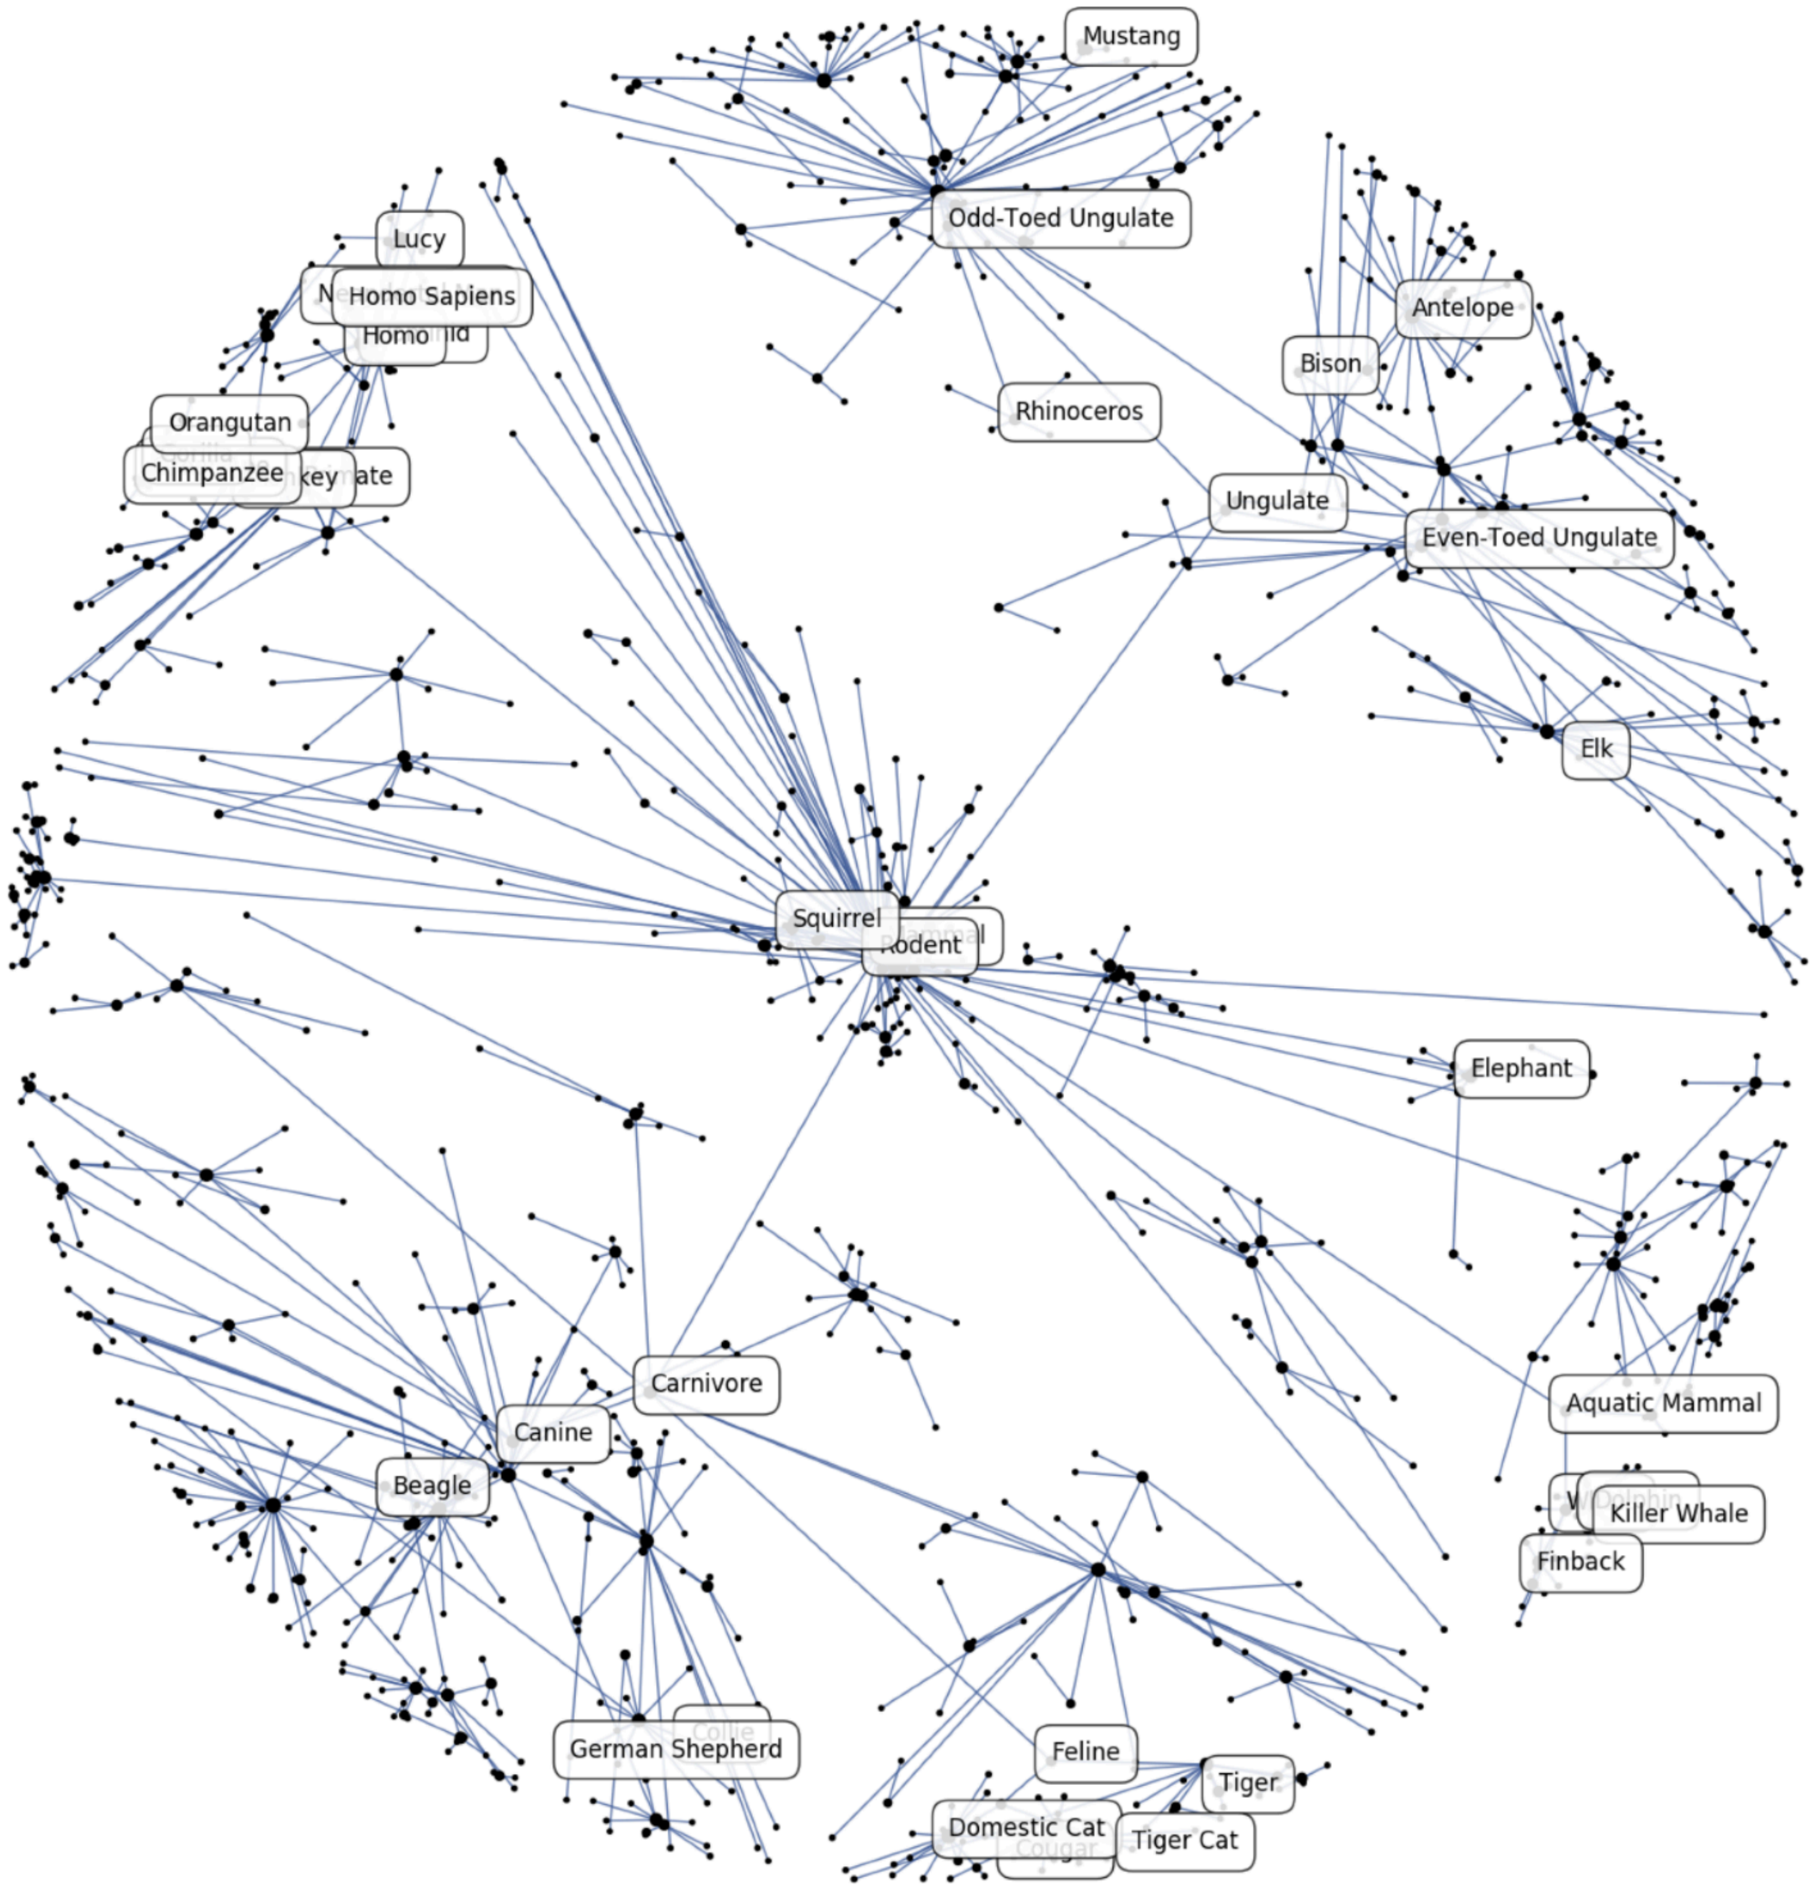

Mustang
Odd-Toed Ungulate
Rhinoceros
Lucy
Homo Sapiens
Homo
Orangutan
Chimpanzee
Antelope
Bison
Ungulate
Even-Toed Ungulate
Elk
Squirrel
Rodent
Elephant
Carnivore
Canine
Beagle
German Shepherd
Aquatic Mammal
Killer Whale
Finback
Feline
Tiger
Domestic Cat
Tiger Cat

Poincaré embeddings, link prediction

$$P((u,v) = 1 \mid \Theta) = \frac{1}{e^{(d(\boldsymbol{u},\boldsymbol{v})-r)/t} + 1}$$

a távolság szigmoid függvénye

HyBed

ez nem skalárszorzat

$$\langle \mathbf{x}_1, \mathbf{x}_2 \rangle_H = \|\mathbf{x_1}\| \|\mathbf{x_2}\| \cos(\theta_1 - \theta_2) = 4 \operatorname{arctanh} r_1 \operatorname{arctanh} r_2 \cos(\theta_1 - \theta_2)$$

$$p(w_O | w_I) = \exp(\langle v'_{w_O}, v_{w_I} \rangle_H) / \sum_{i=1}^{V} \exp(\langle v'_{w_i}, v_{w_I} \rangle_H)$$

Chamberlain, Clough, Deisenroth

https://openreview.net/pdf?id=S1xDcSR6W

Hipergömbök

Hyperspherical Variational Autoencoder

Davidson et al.

https://arxiv.org/abs/1804.00891

Autoencoder

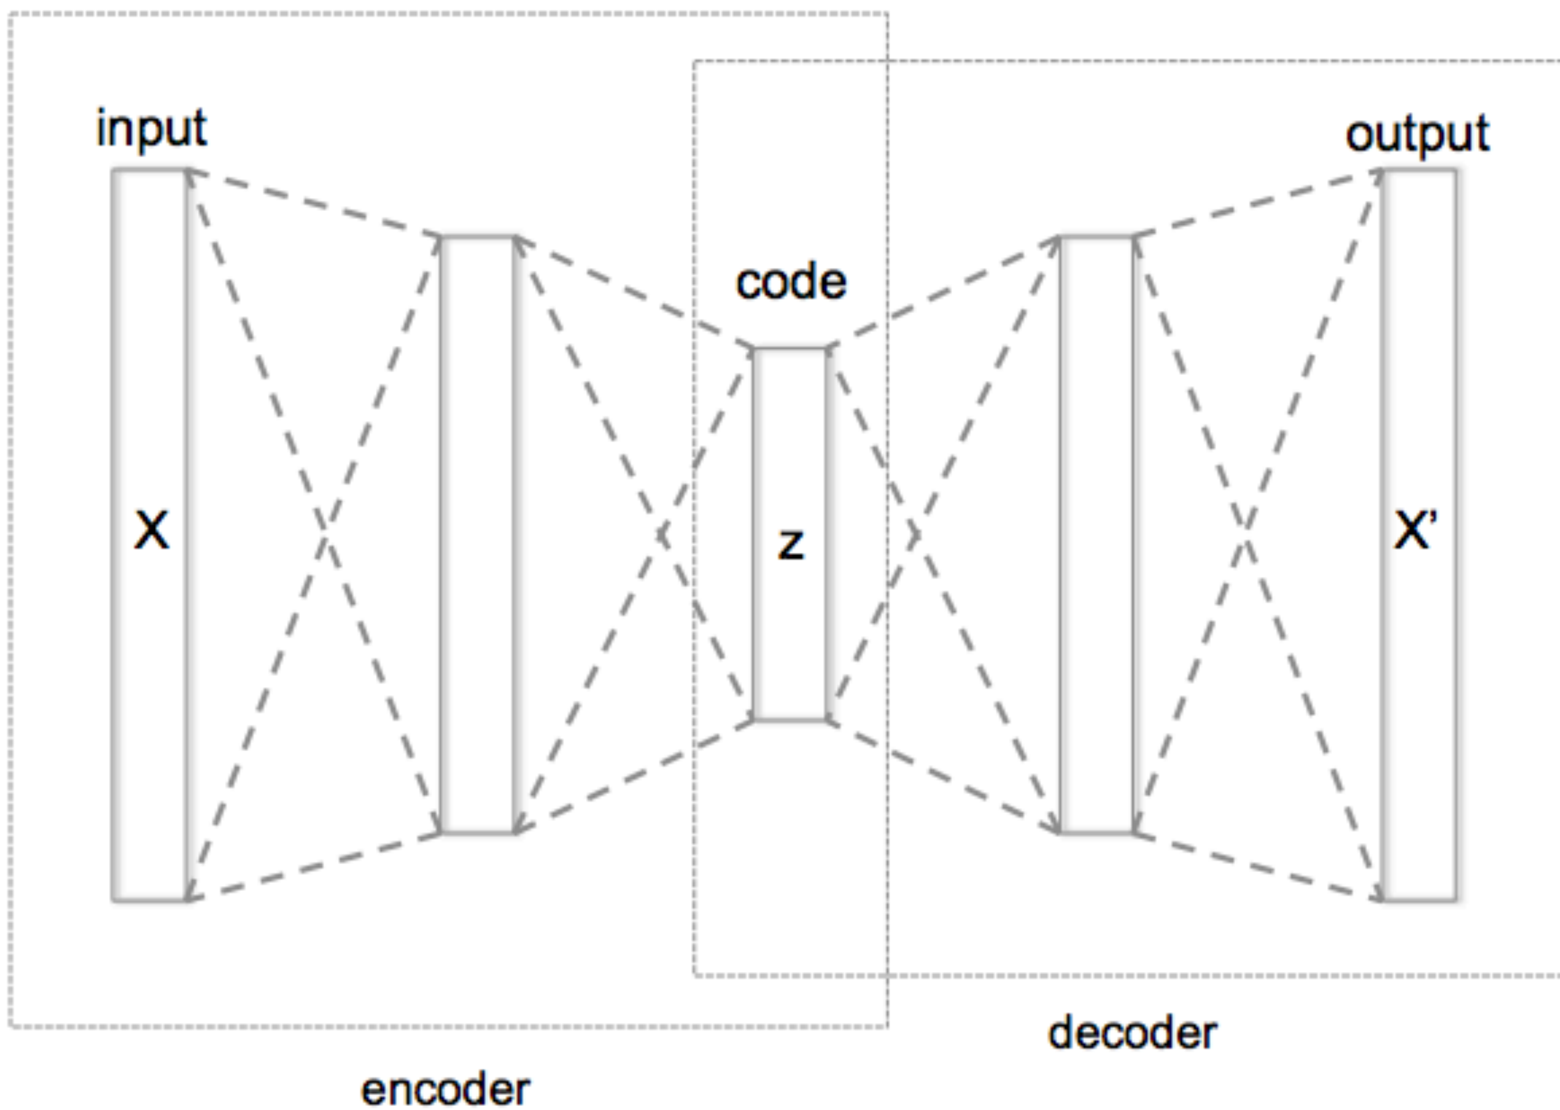

Von Mises–Fisher eloszlás

$$f_p(\mathbf{x}; \boldsymbol{\mu}, \kappa) = C_p(\kappa) \exp\left(\kappa \boldsymbol{\mu}^T \mathbf{x}\right)$$

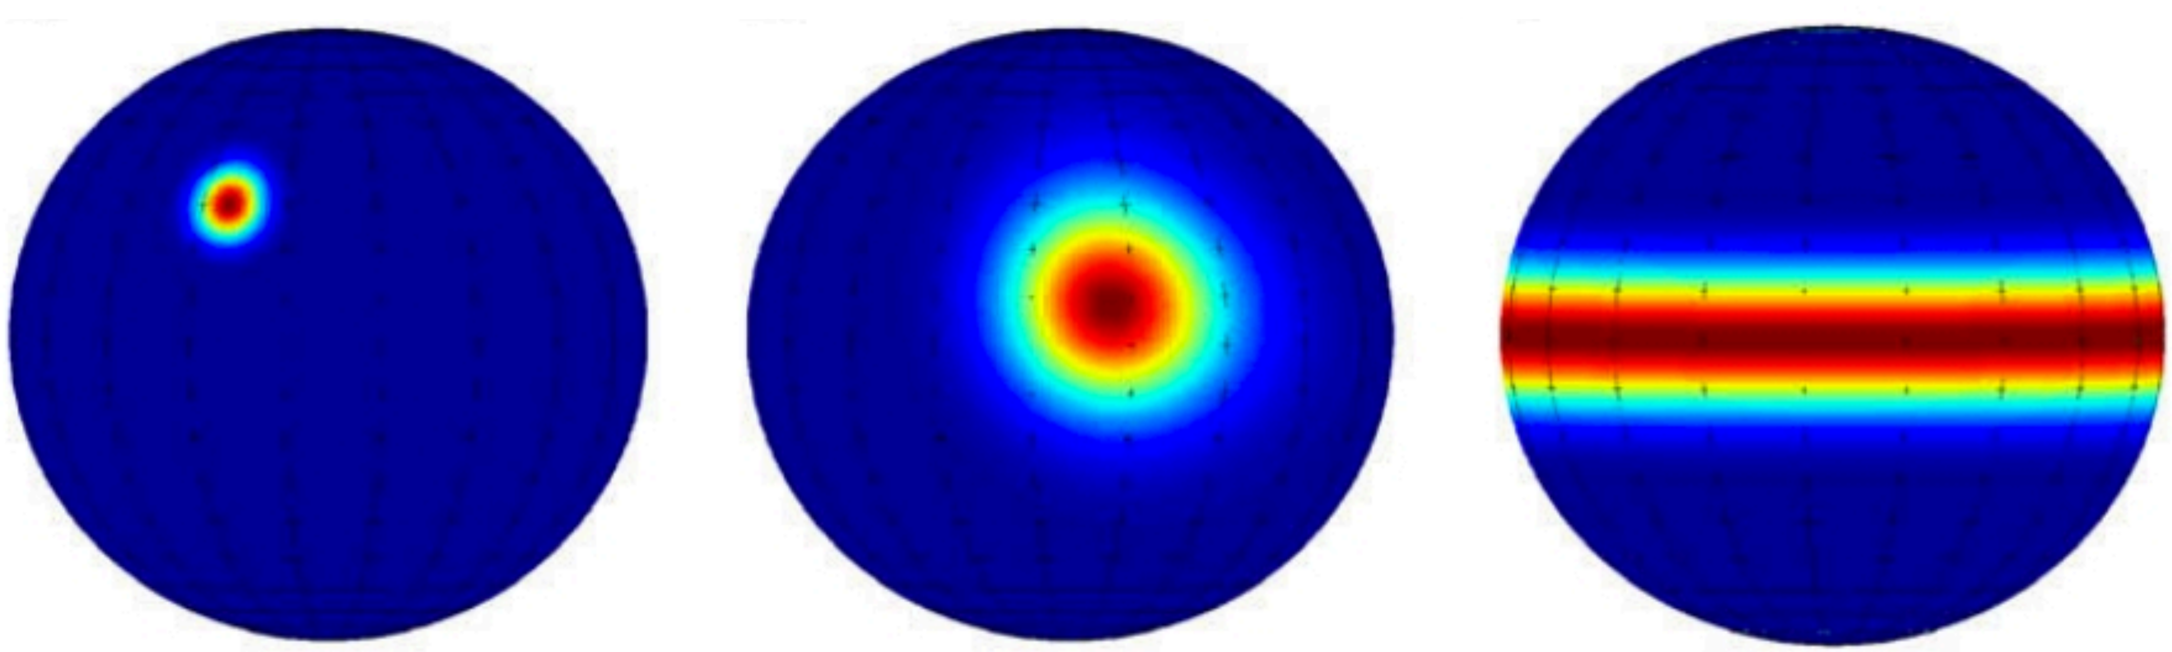

Tóruszok

Analóg óra

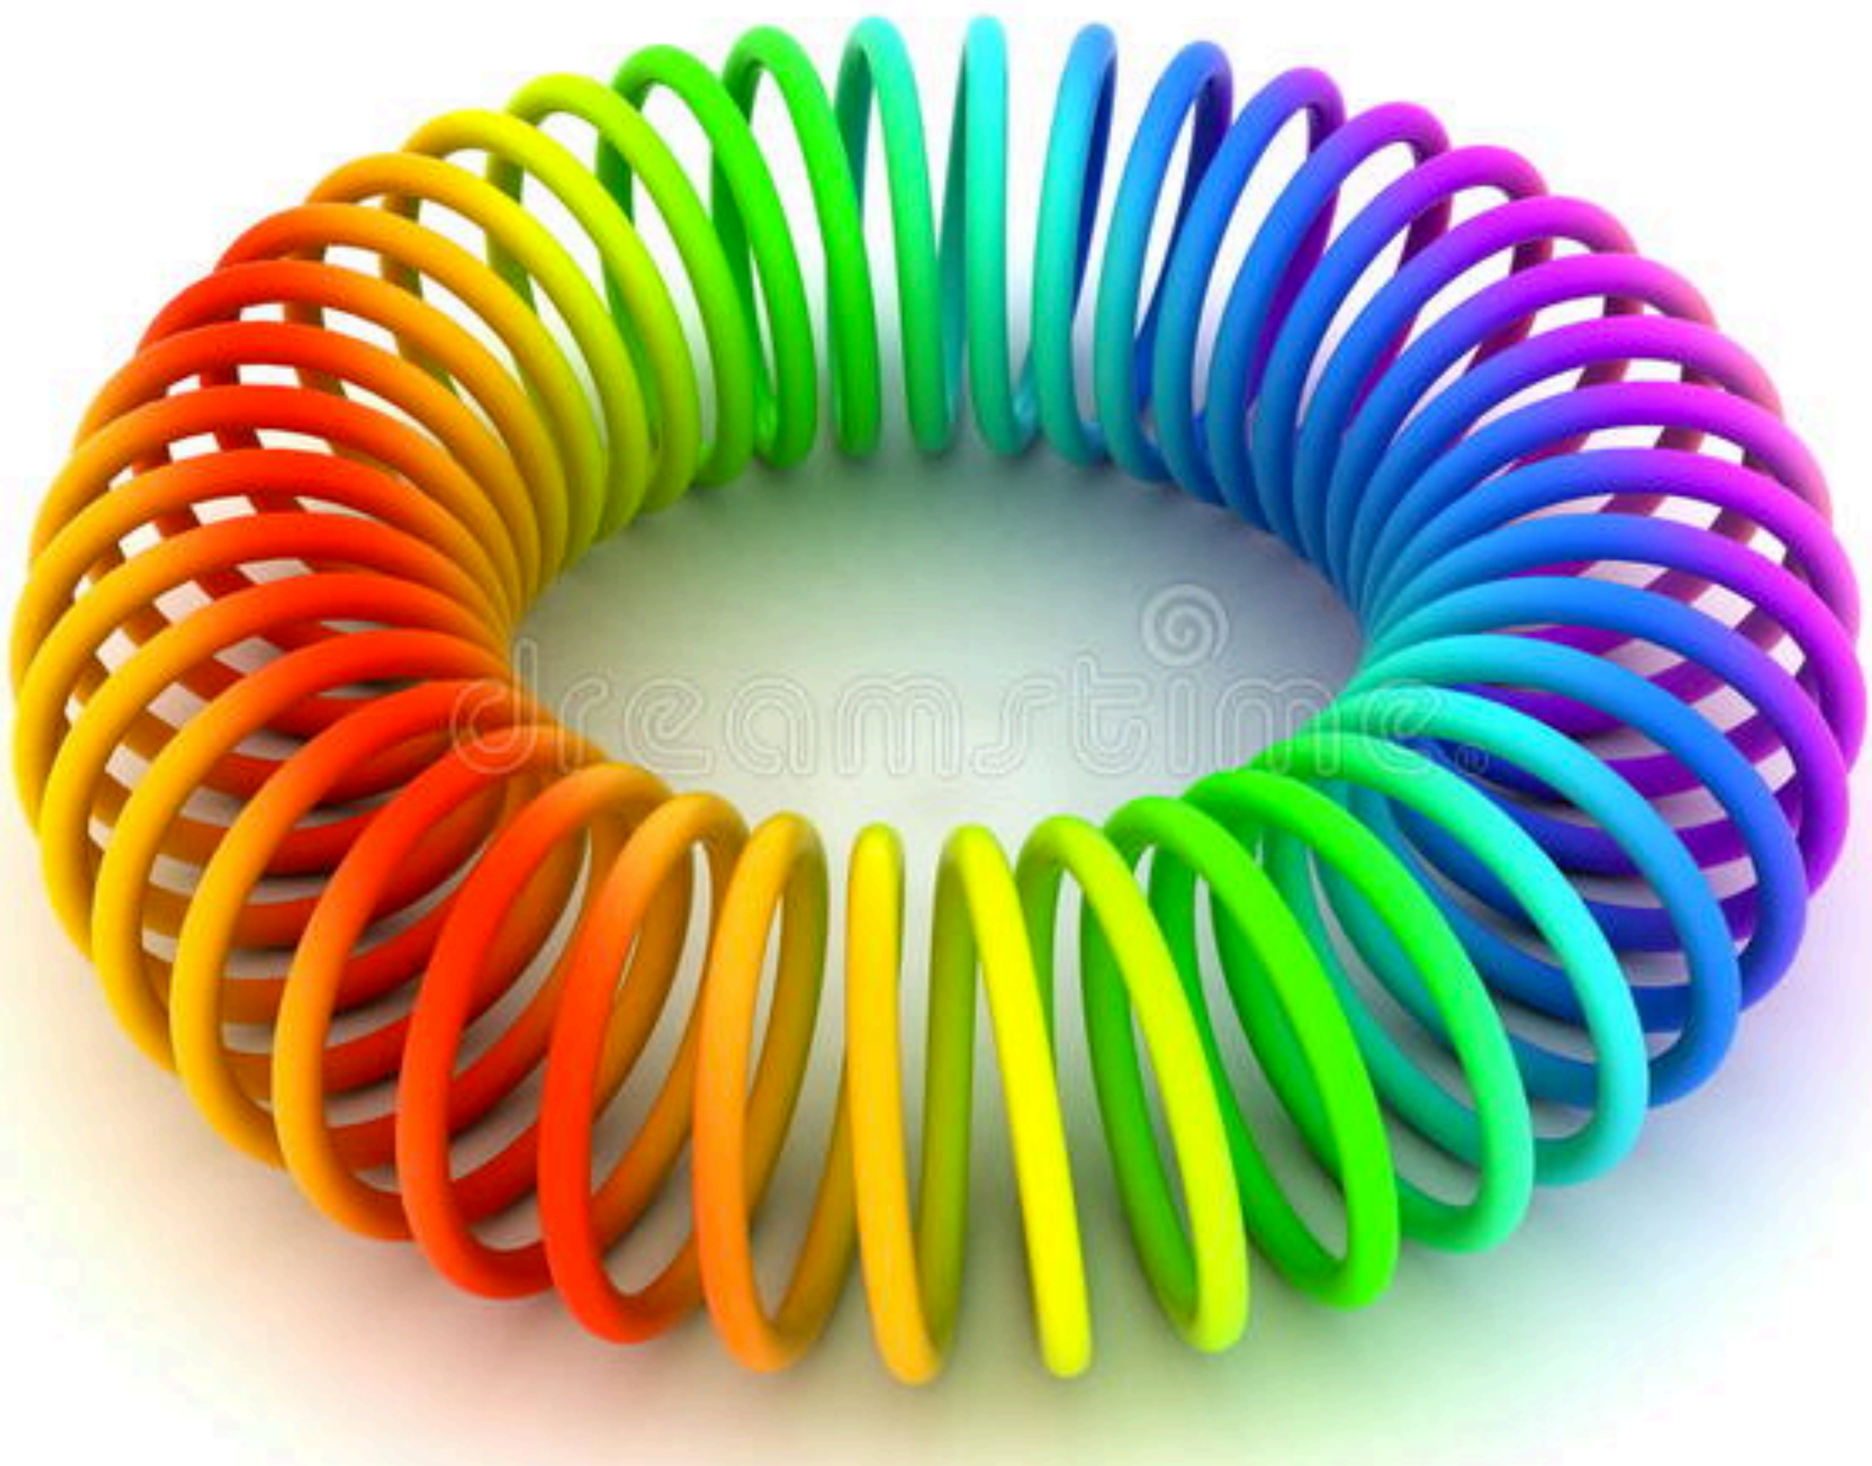

1D tóruszok

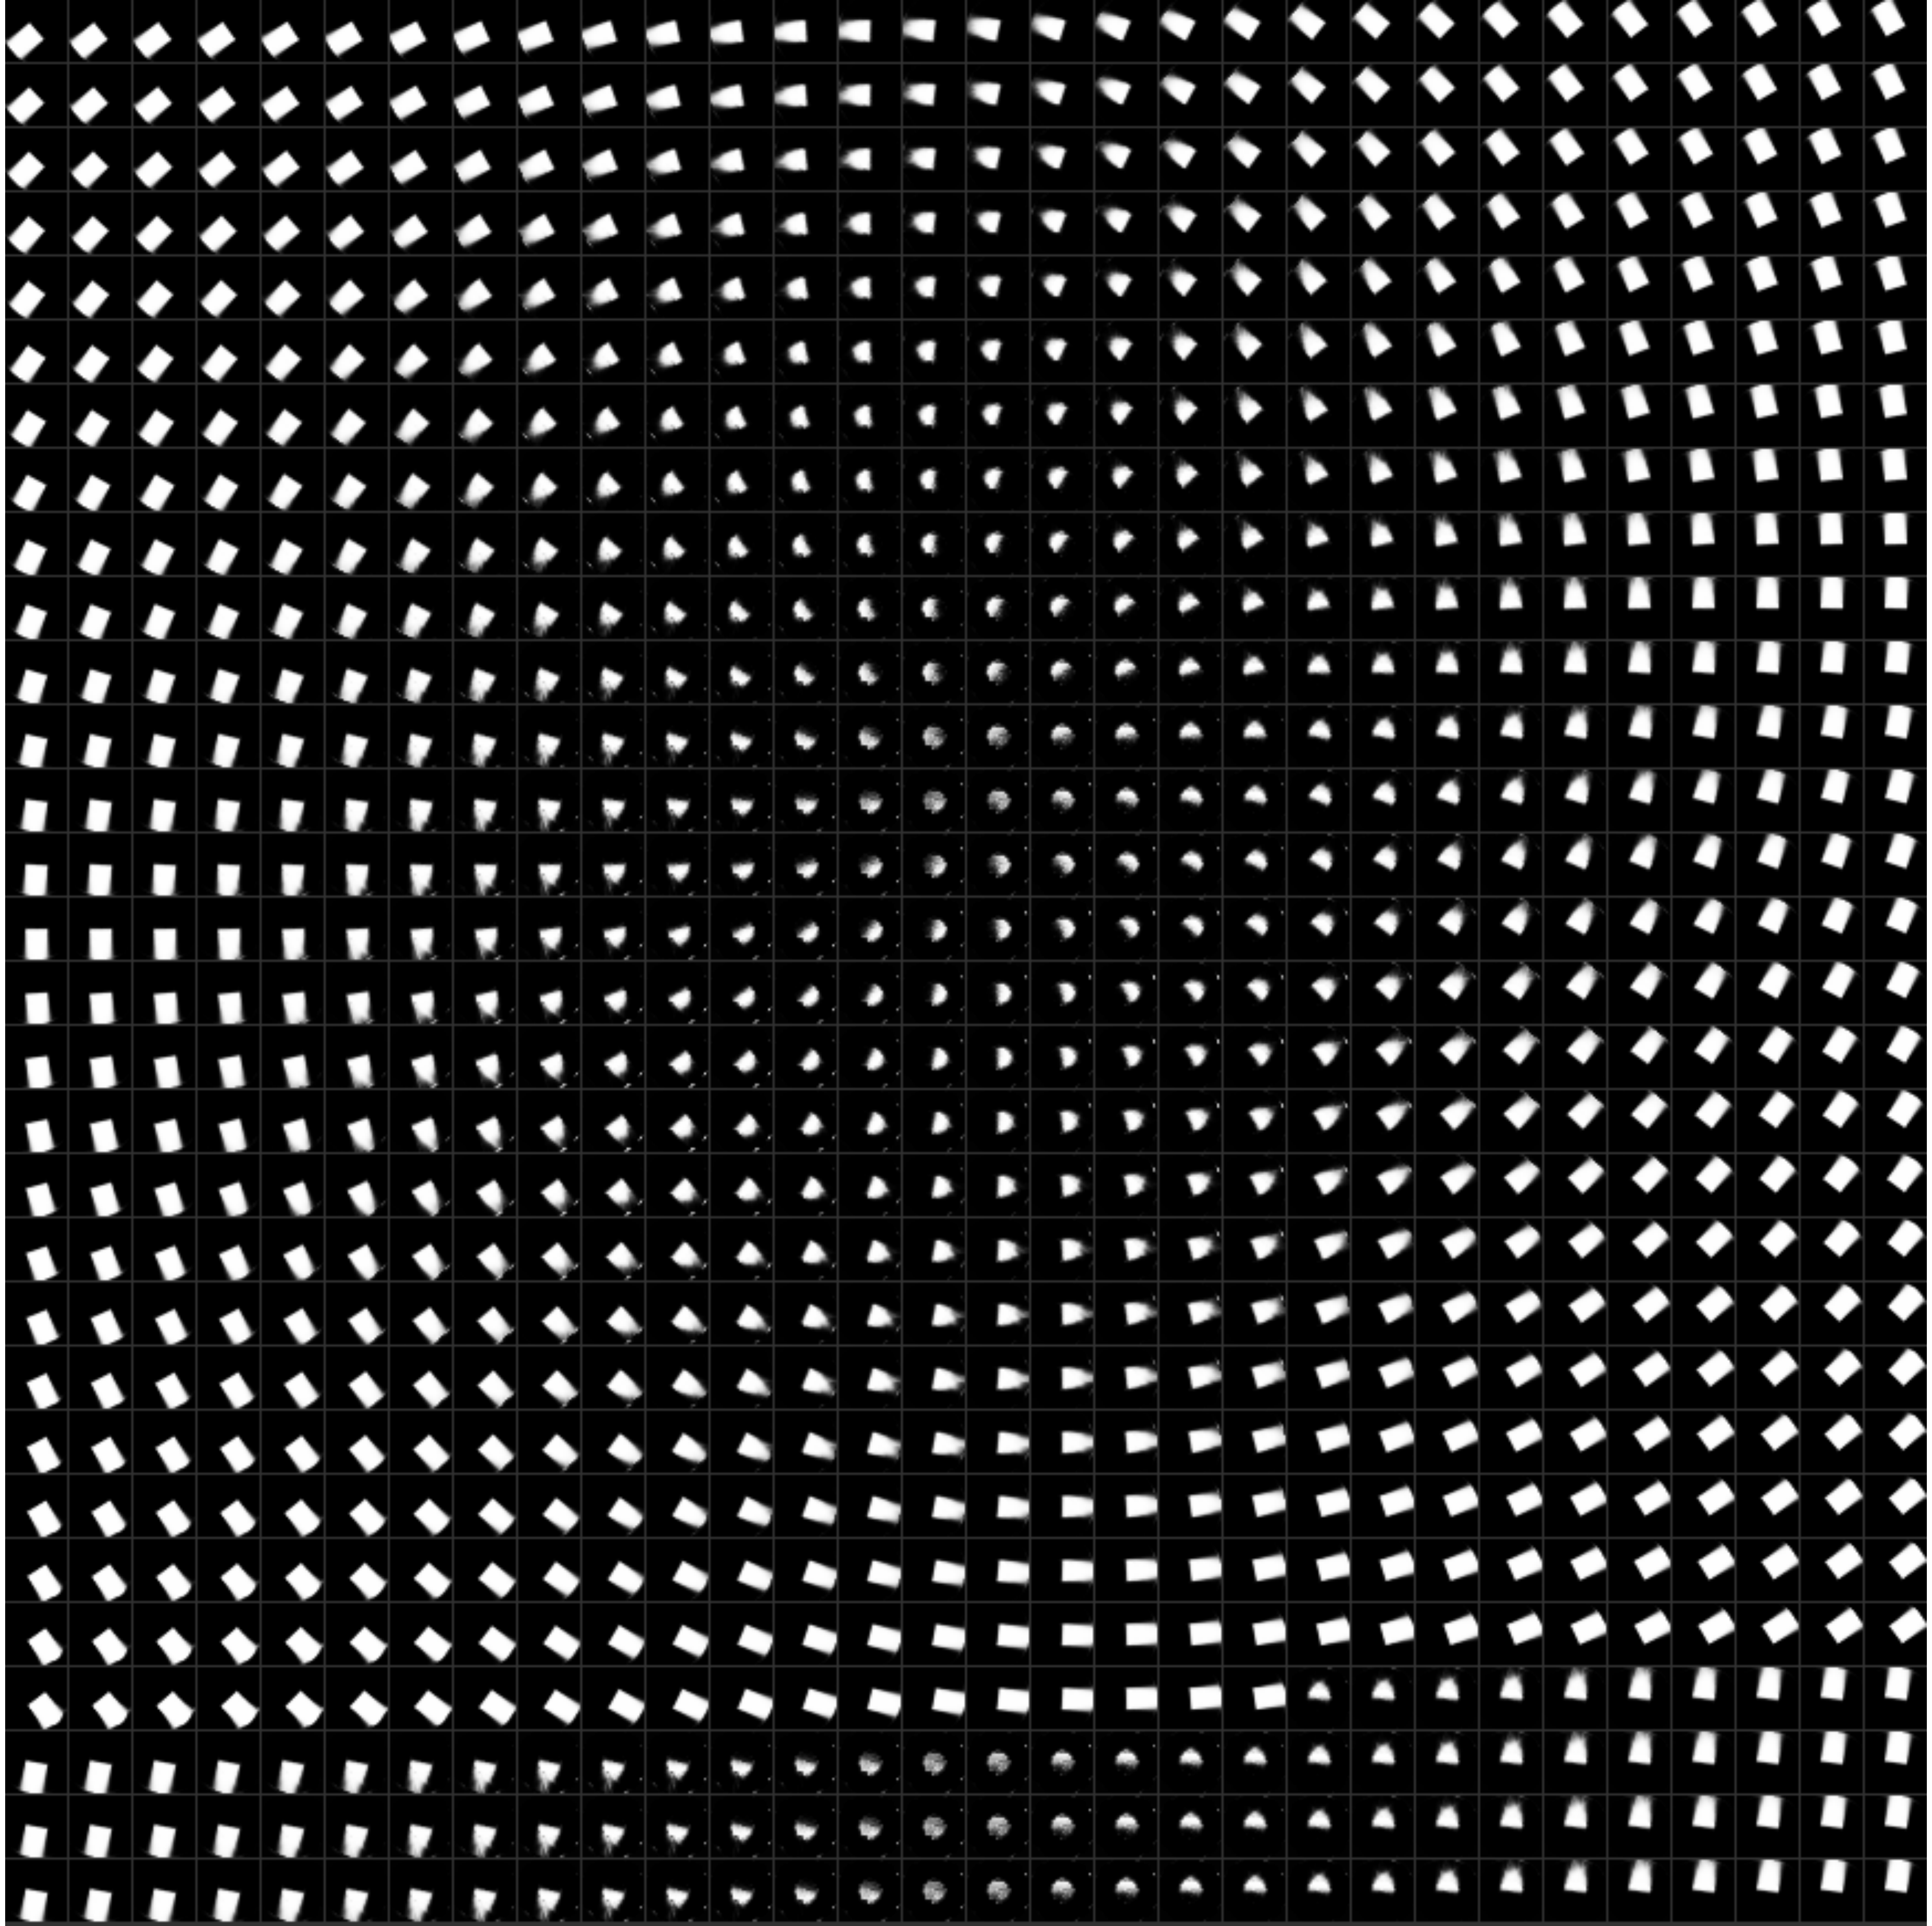

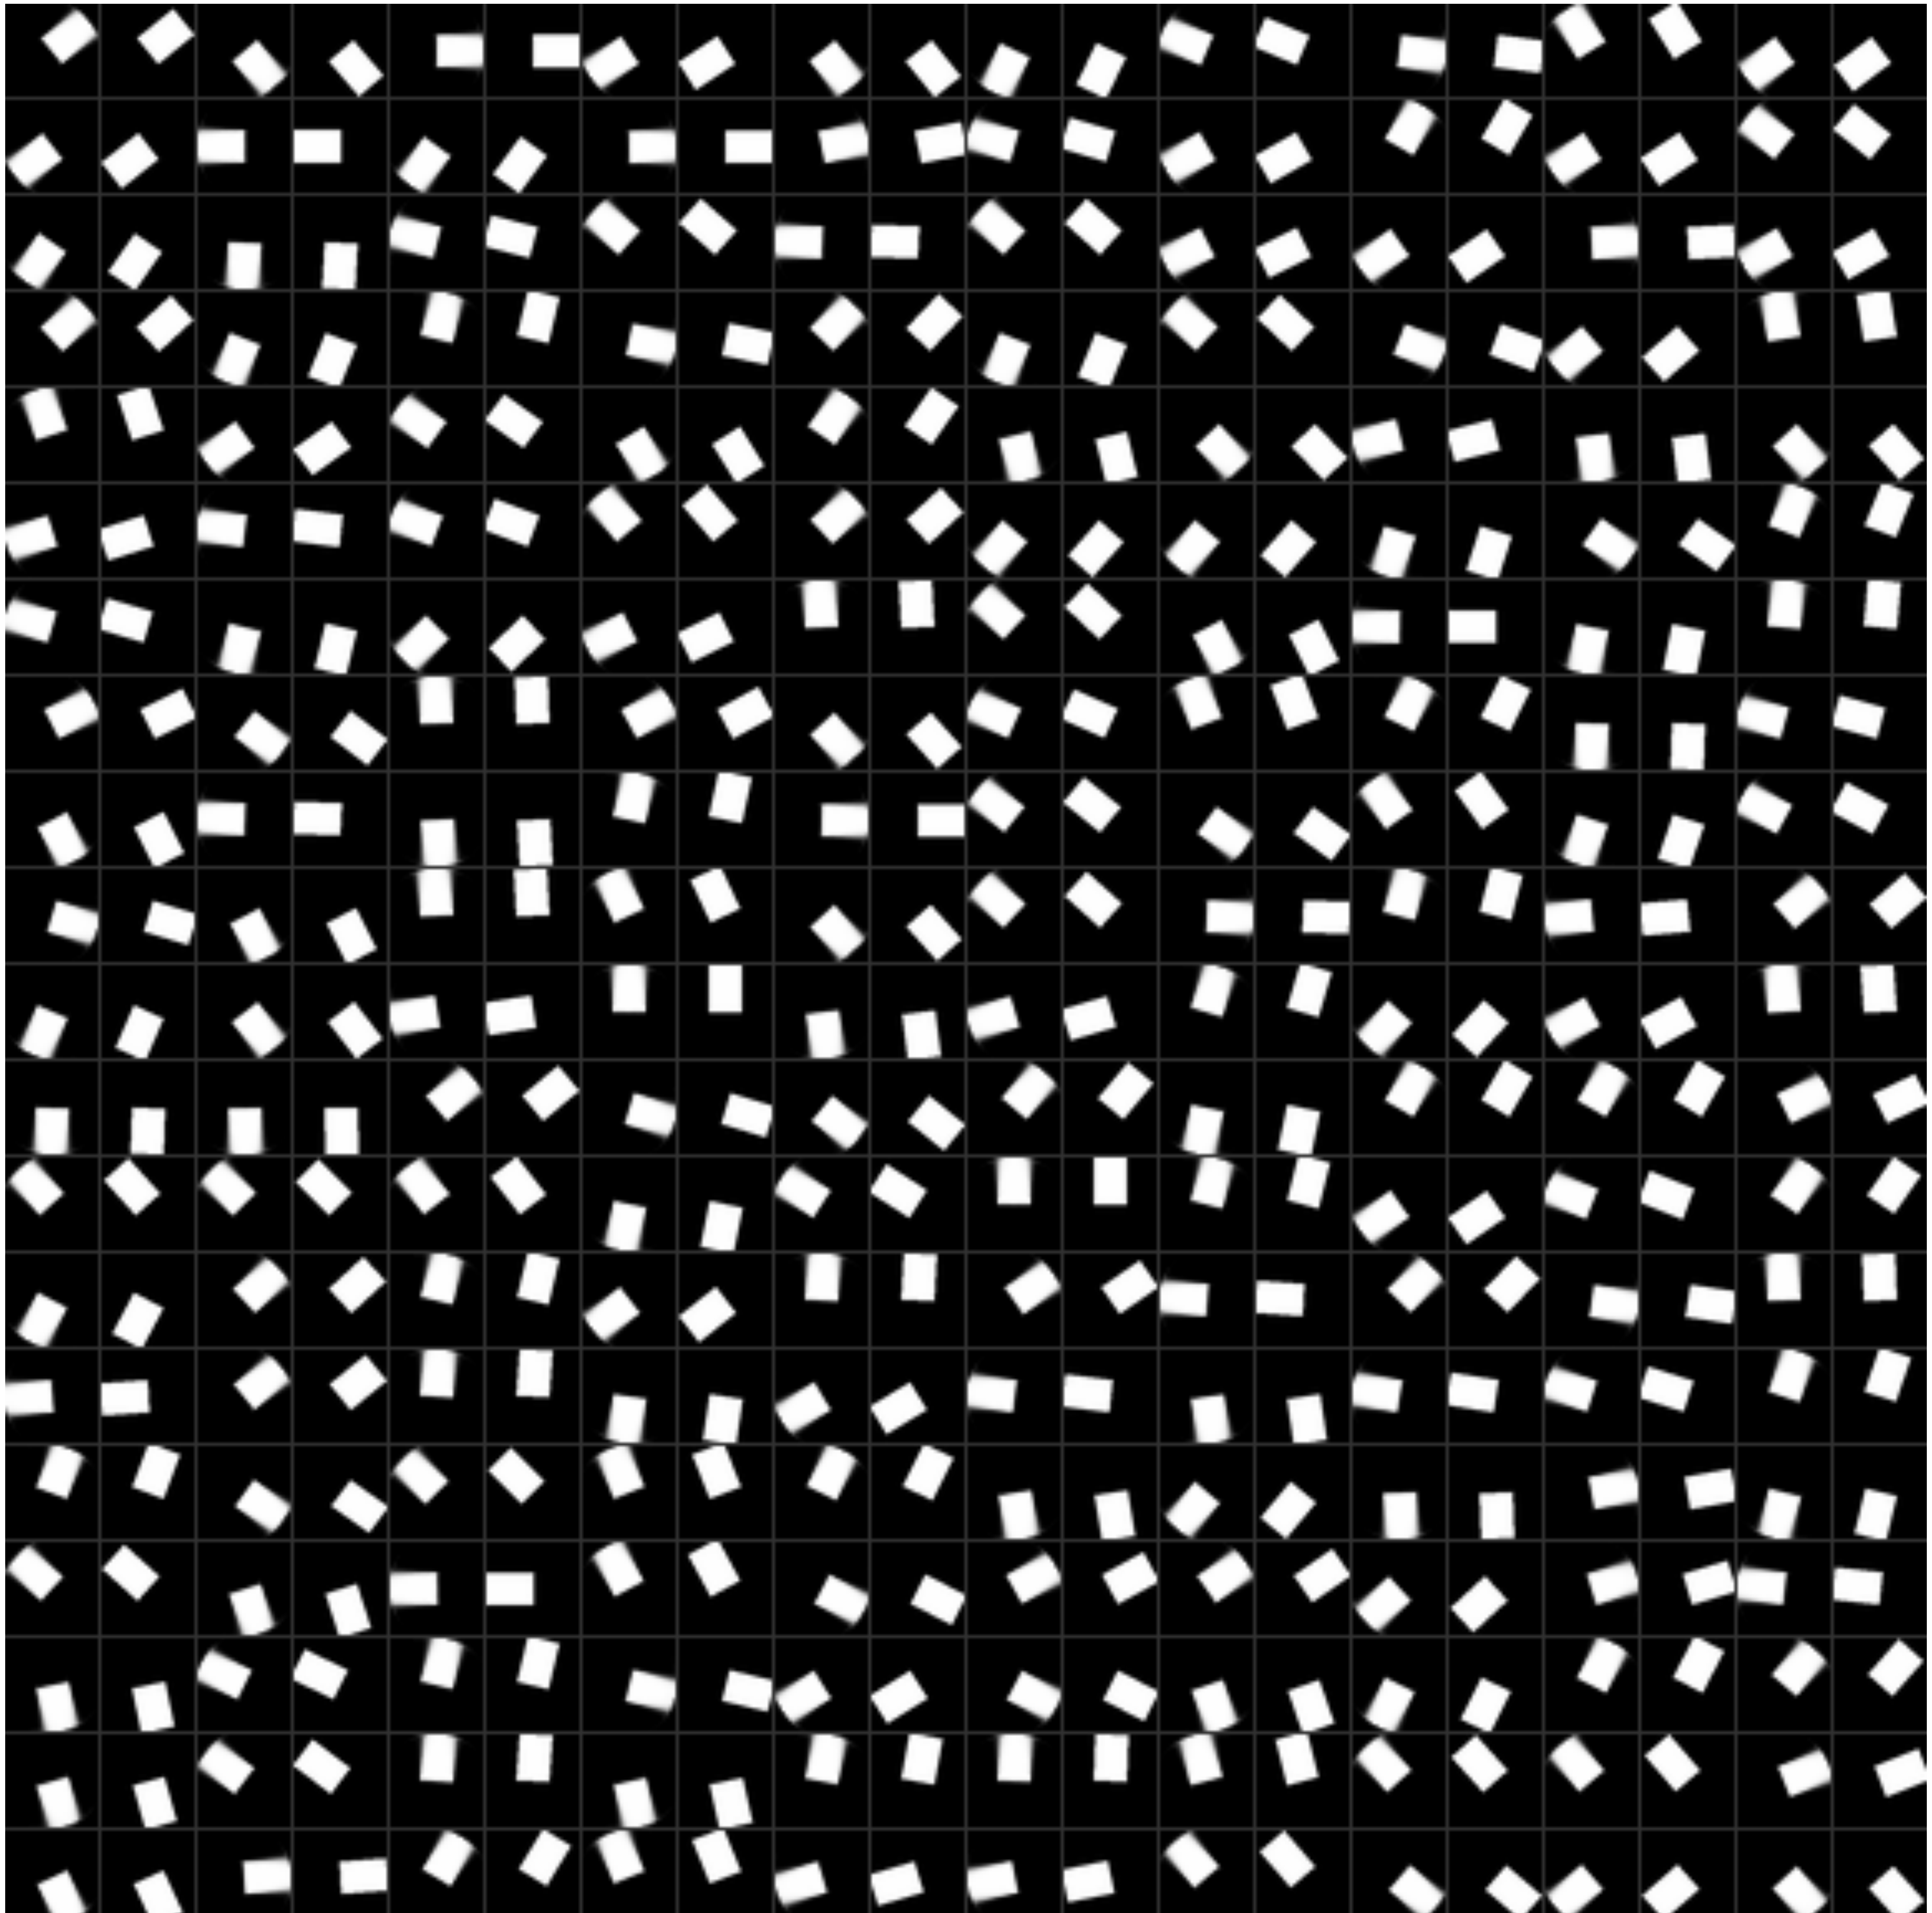

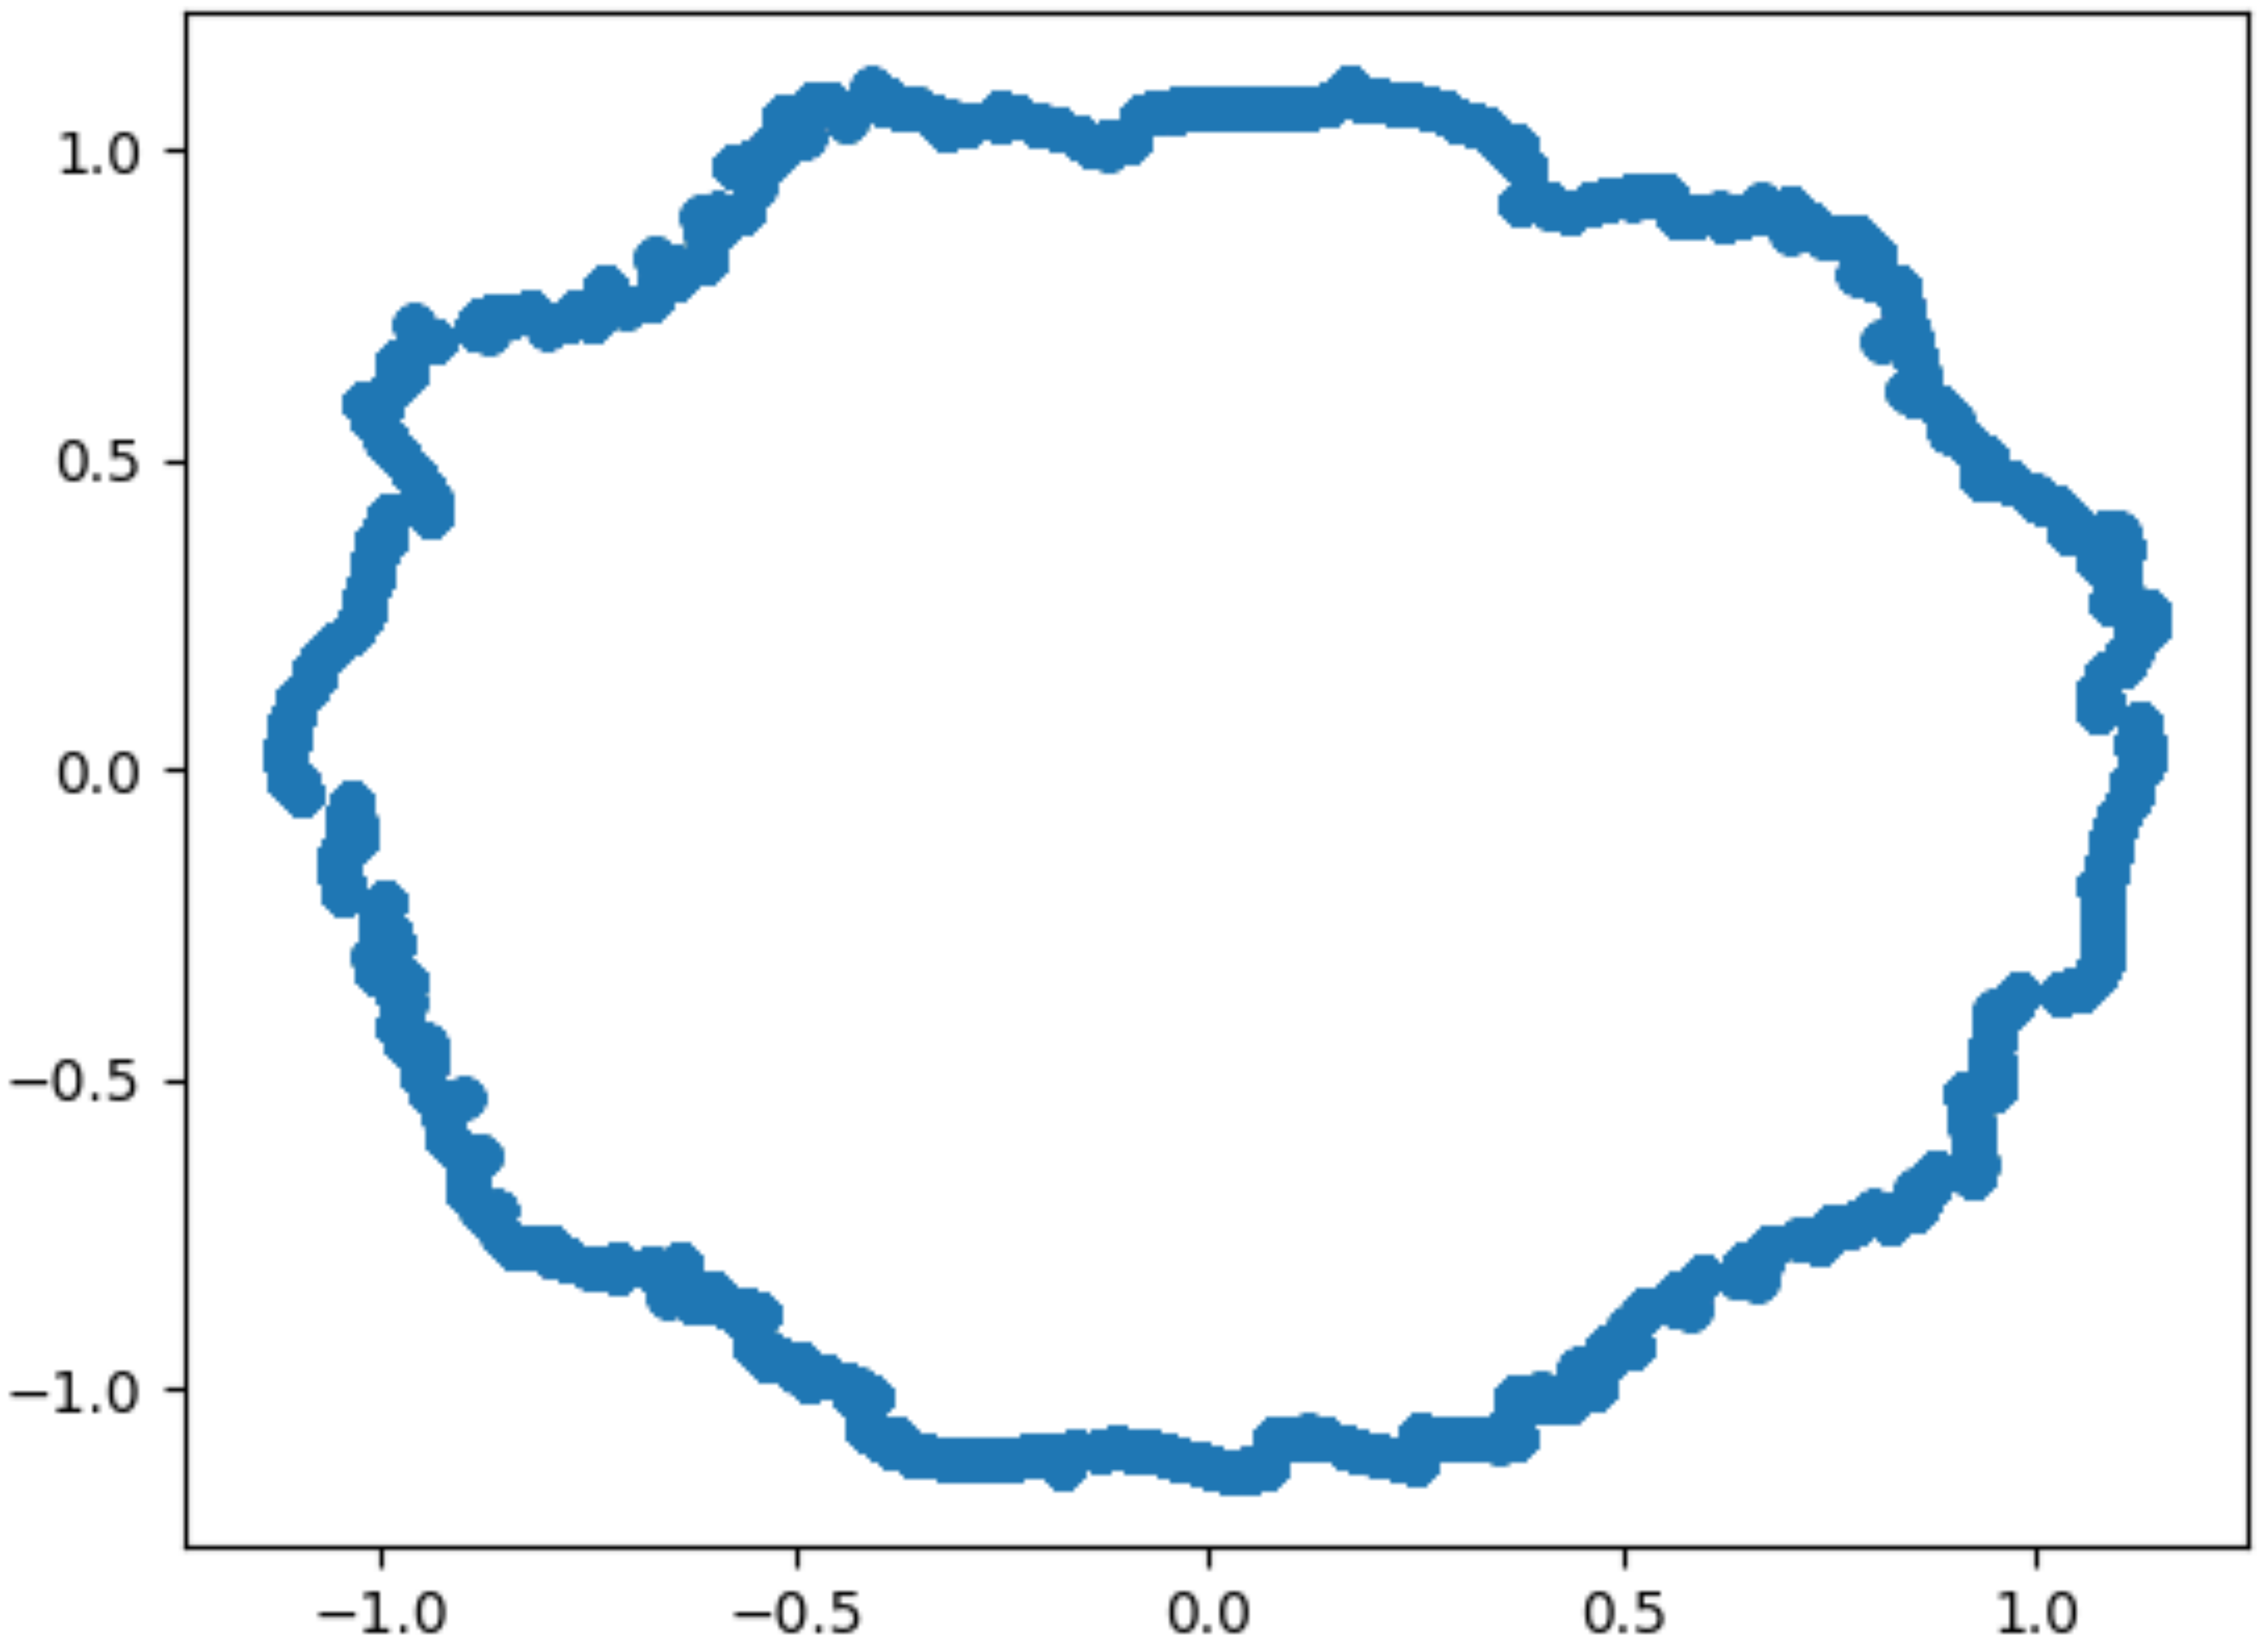
1.0
0.5
0.0
−0.5
−1.0
−1.0
−0.5
0.0
0.5
1.0

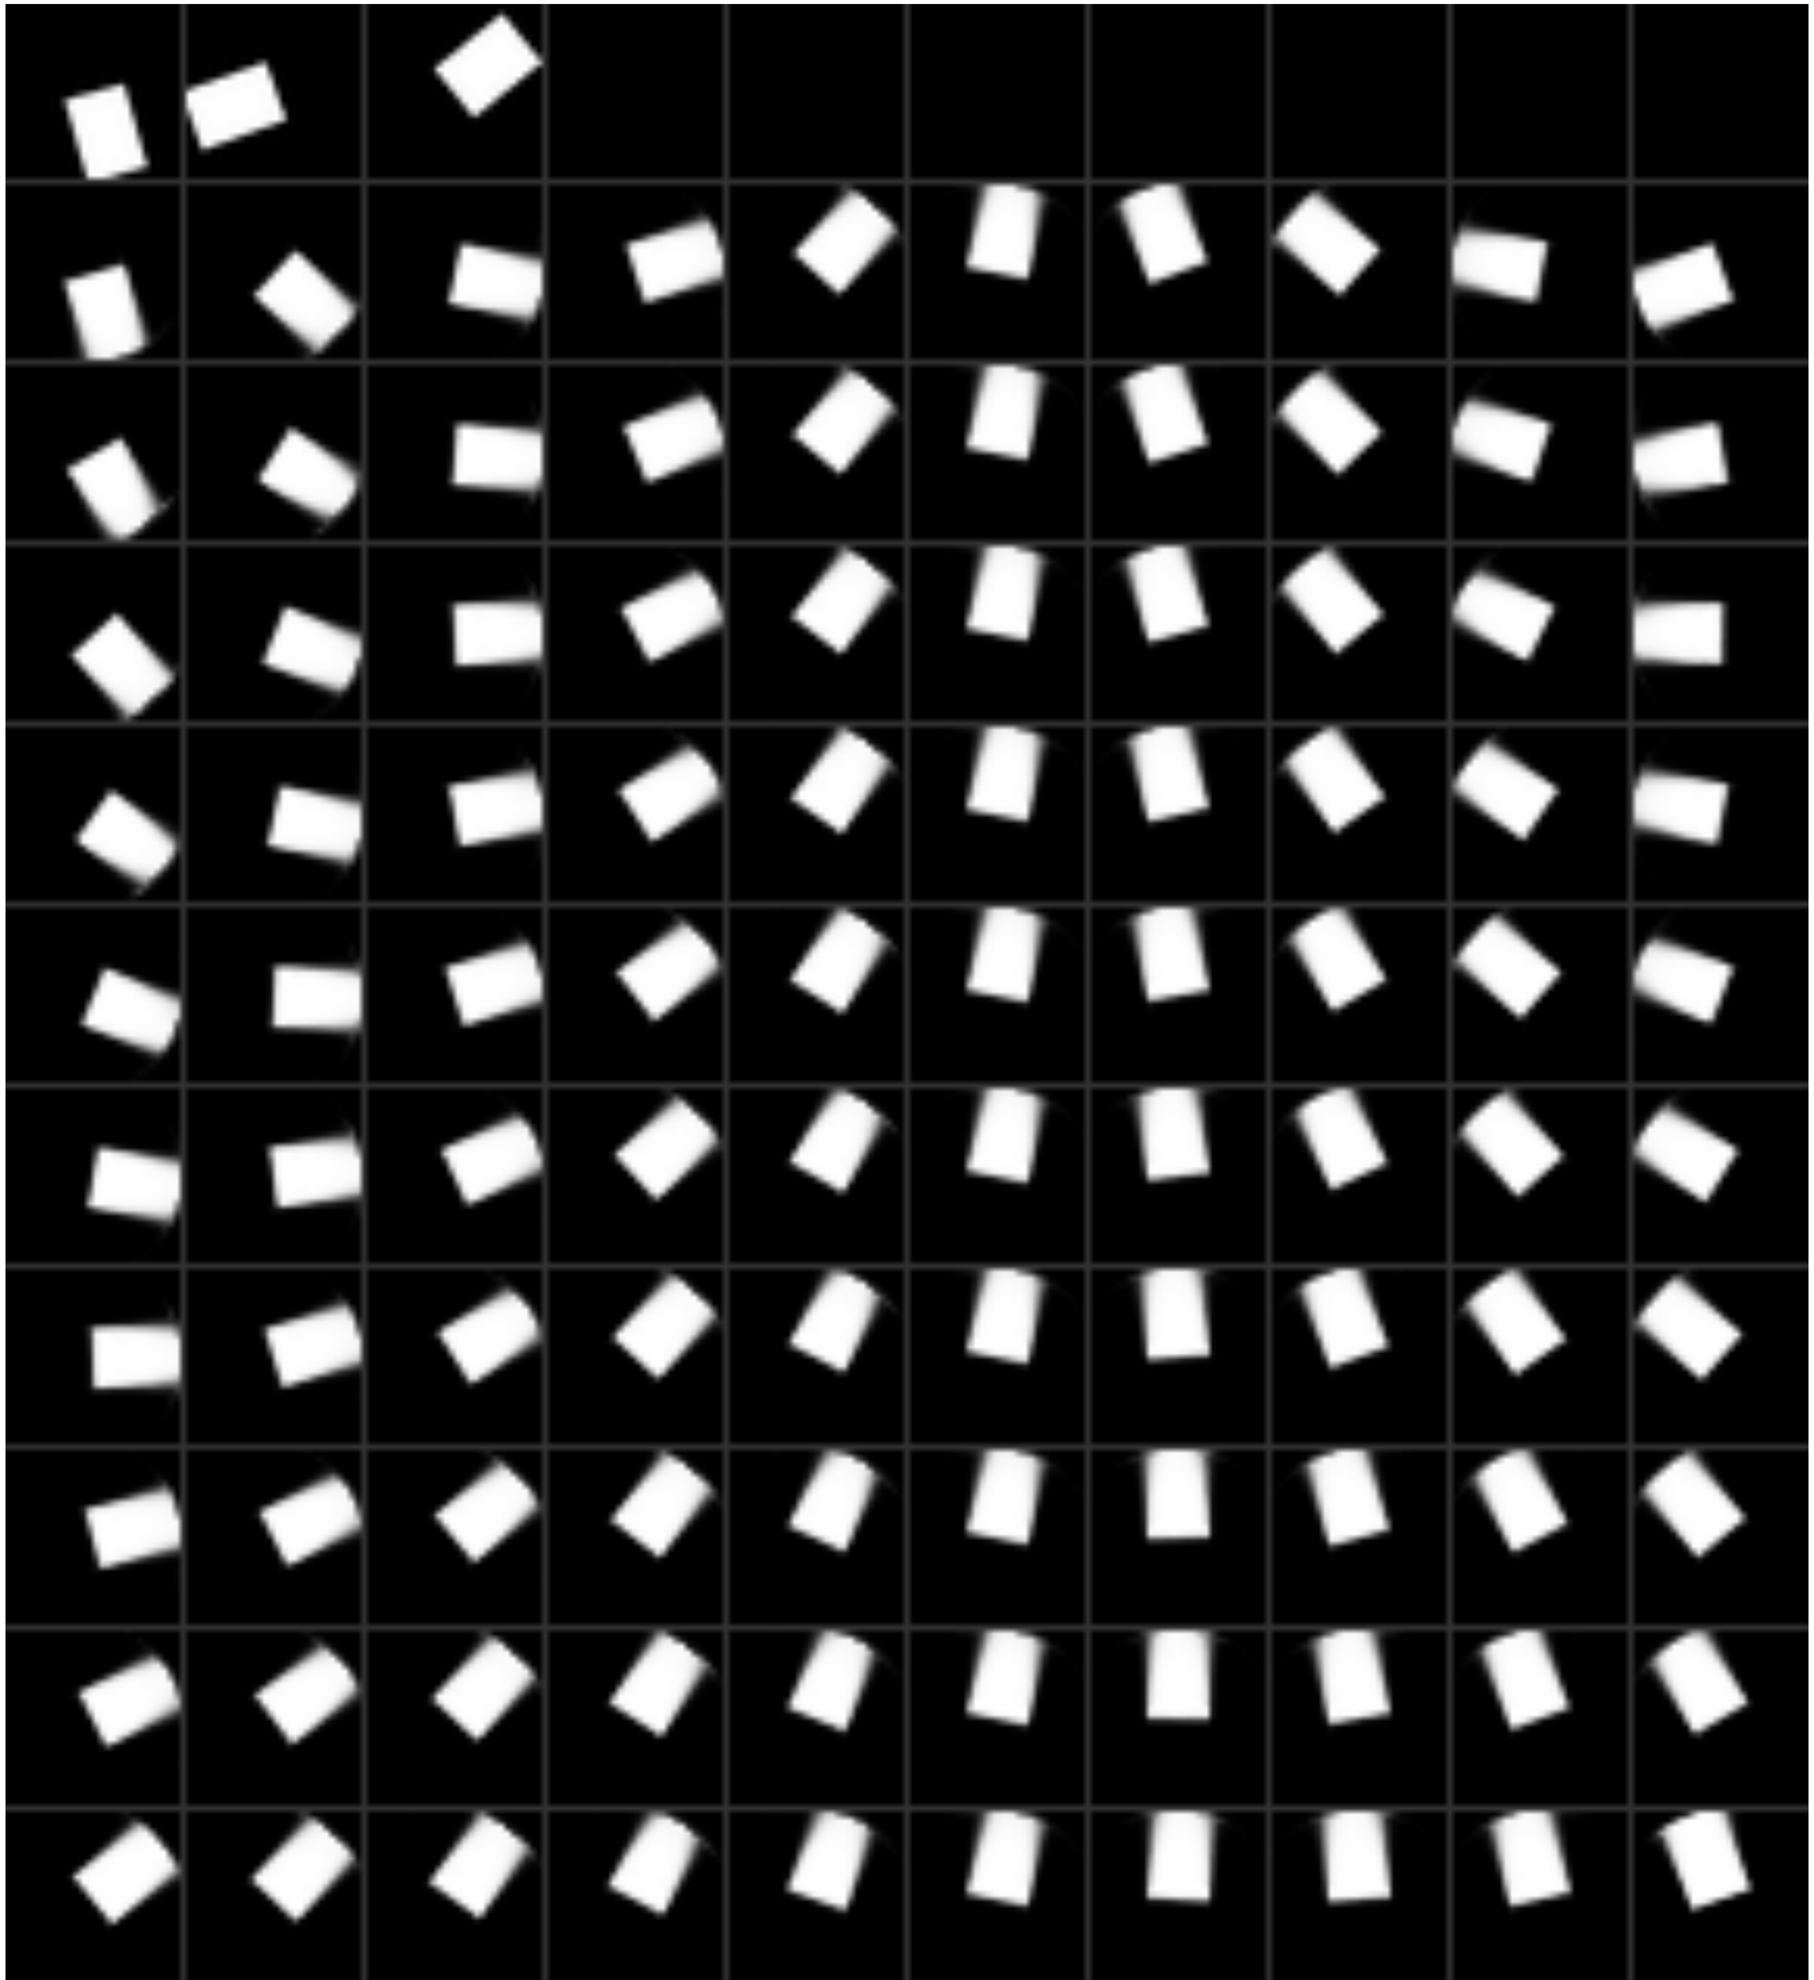

2D tóruszok