

# 識別器による最適輸送

Akinori Tanaka (RIKEN iTHEMS/AIP, 慶應数理)

 [AkinoriTanaka-phys](https://github.com/AkinoriTanaka-phys)

※1 Images are derived from CIFAR-10,  
and some pretrained machines available from github.

※2 In this slide, we use "sloppy" math notations.  
Sometimes,  $\min$  should be replaced by  $\inf$ , etc.

# TOC

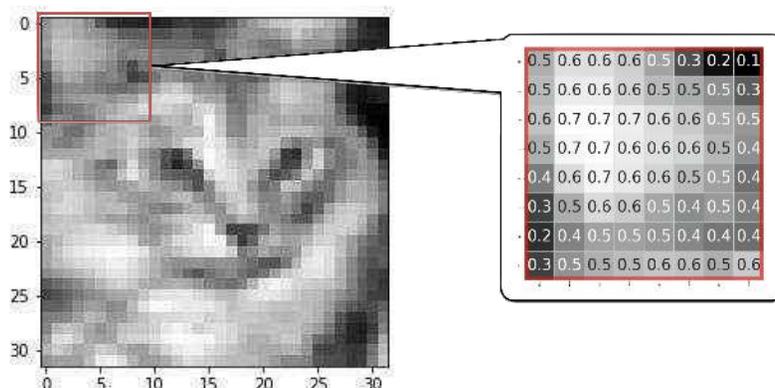
- 1. Generative Models
  - 1.1. What is the Generative Model ?
  - 1.2. Motivations
  - 1.3. Deep Generative Models
- 2. Optimal Transport (OT)
  - 2.1. What is the Optimal Transport ?
  - 2.2. Generative models and Optimal transport
  - 2.3. Duality
- 3. Post processing on DGMs
  - 3.1. Motivations
  - 3.2. Post processing of GAN
  - 3.3. Related works
- Summary

# 1. Generative Models

# 1.1. What is the Generative Model ?

---

## ■ 画像 = ベクトル



$$\mathbf{x} = [0.5, 0.6, 0.6, 0.6, 0.5, \dots]$$

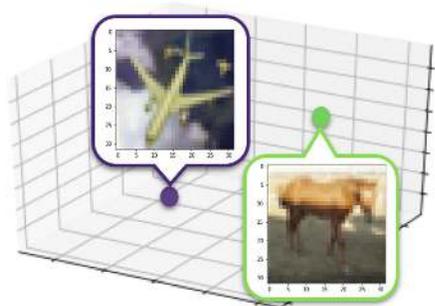
注意：

- カラー画像は、例えば、赤、緑、青、の次元も加わる
- テンソル(多次元配列)として扱う場合が多い

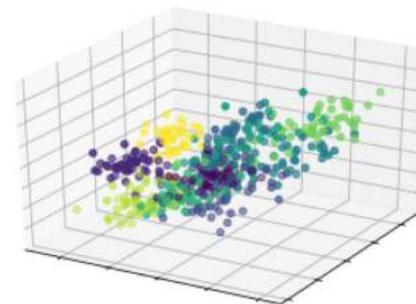
# 1.1. What is the Generative Model ?

---

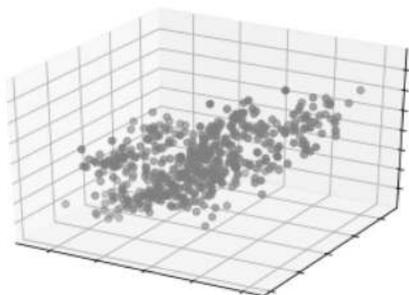
## ■ $x$ を「図示」してみる



たくさん集める  
→

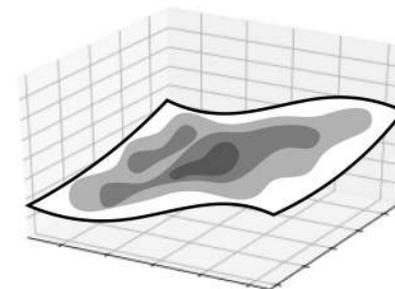


## ■ 仮定：「画像生成確率」があるとする



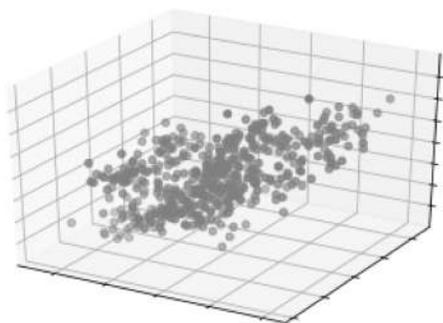
無限に集める  
→

←  
サンプリング



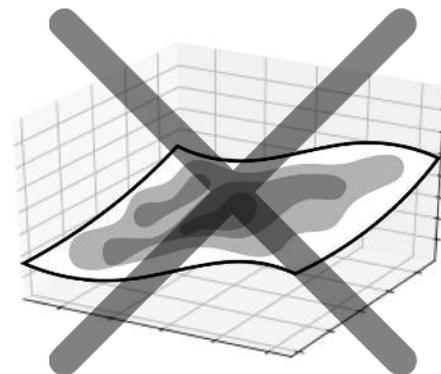
# 1.1. What is the Generative Model ?

## ■ 生成モデル (Generative Model)



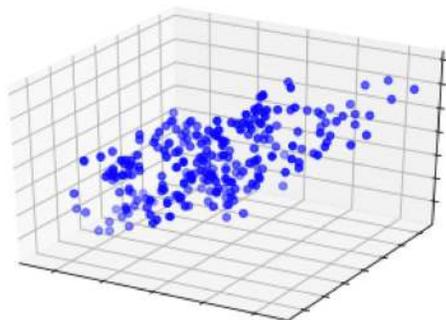
無限に集める  
→  
←  
サンプリング

$$p_{\mathcal{X}}(\mathbf{x})$$

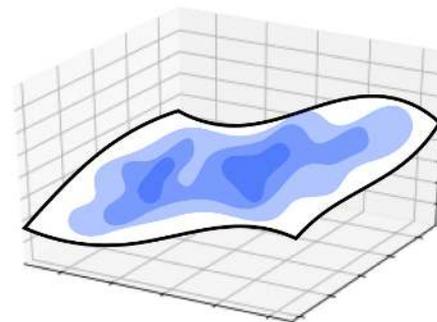


⇕ 合わせる

生成モデル :  $p_{\theta}(\mathbf{x})$



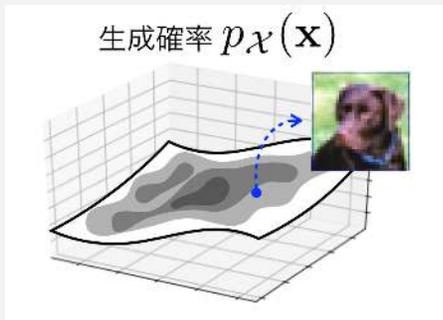
←  
サンプリング



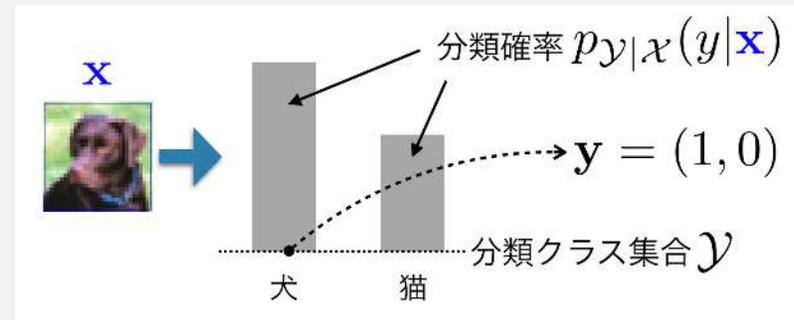
# 1.2. Motivations

## ■教師あり機械学習

### ・入力ドメイン



### ・出力ドメイン



- 問題ごとに背後に  $p_{\mathcal{X}}, p_{\mathcal{Y}|\mathcal{X}}$  が存在すると考える
- 学習のゴールはサンプルだけから  $p_{\mathcal{Y}|\mathcal{X}}$  を近似すること

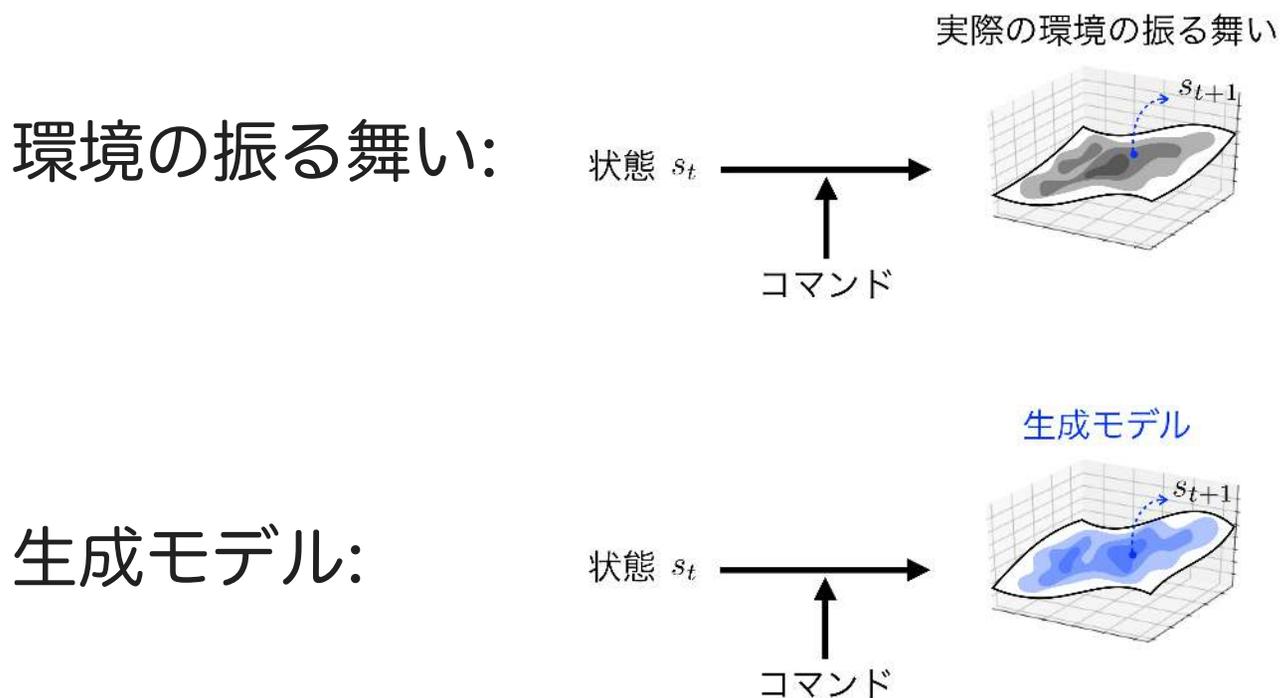
+生成モデル =  $p_{\mathcal{X}}$  の近似

→ 敵対的擾動 [Szegedy+ (2013)] に強固に？

(c.f. Tomczakのブログ)

## 1.2. Motivations

### ■ 強化学習 (モデルベース強化学習)

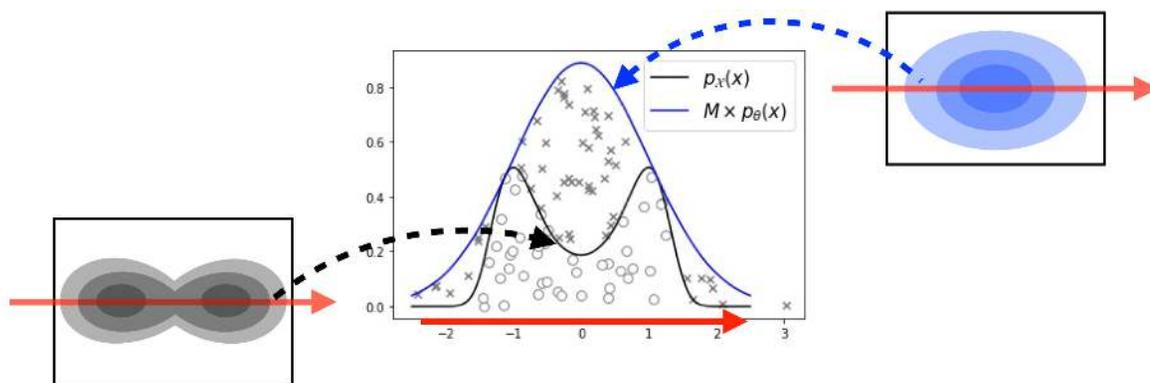


1. 環境が高価な場合に(うまくいけば)有用
2. 手法として興味深い(c.f. [Ha&Schmidhuber (2018)])

## 1.2. Motivations

### ■ $p_x$ からのサンプリング

- 棄却サンプリング



提案分布(生成モデル)  $p_\theta$  が  $p_x$  に近いと受け入れ確率  $\uparrow$

(注意：確率密度比  $\frac{p_\theta(\mathbf{x})}{p_x(\mathbf{x})}$  の値が必要)

応用: SLMC [Liu+ (2016)] 詳細は DLAP第1回、23回

## 1.3. Deep Generative Models

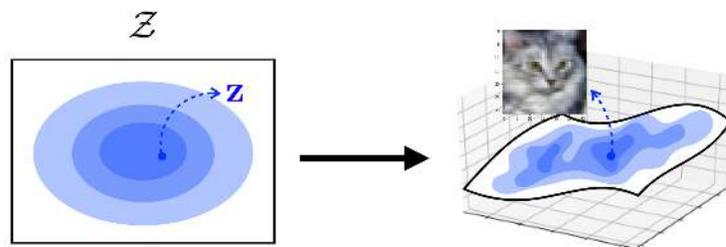
---

色々な手法がある けれど、今回は以下に注目

### ■ 潜在変数モデル

別の空間  $\mathcal{Z}$  から  $\mathcal{X}$  上の確率が由来すると考える

$$p_{\theta}(\mathbf{x}) = \int_{\mathcal{Z}} p_{\theta}(\mathbf{x} | \mathbf{z}) p_{\mathcal{Z}}(\mathbf{z}) d\mathbf{z}$$

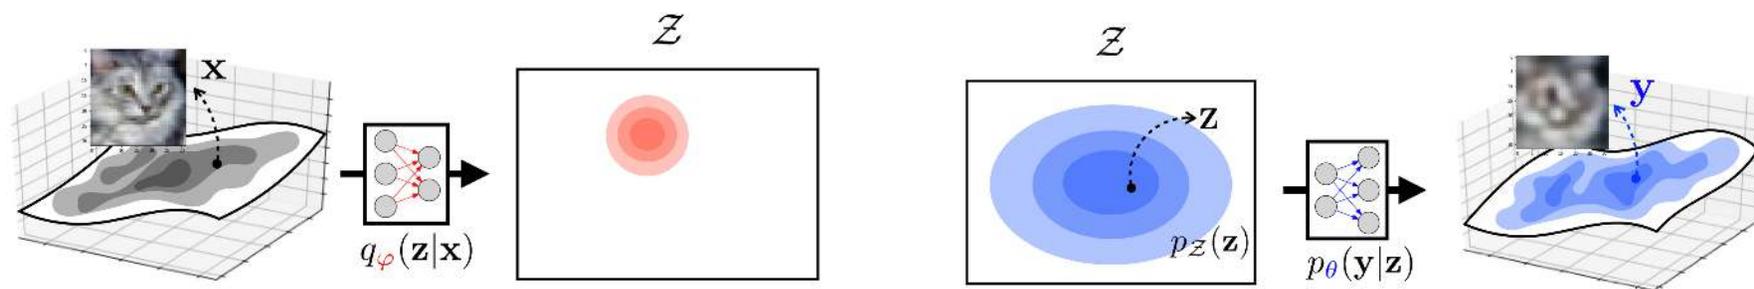


深層学習で代表的な2つ

- 変分自己符号化器 [Kingma&Welling (2013)]
- 敵対的生成ネットワーク [Goodfellow+ (2014)]

# 1.3. Deep Generative Models

## ■ 変分自己符号化器(Variational Auto-Encoder, VAE)



符号化器

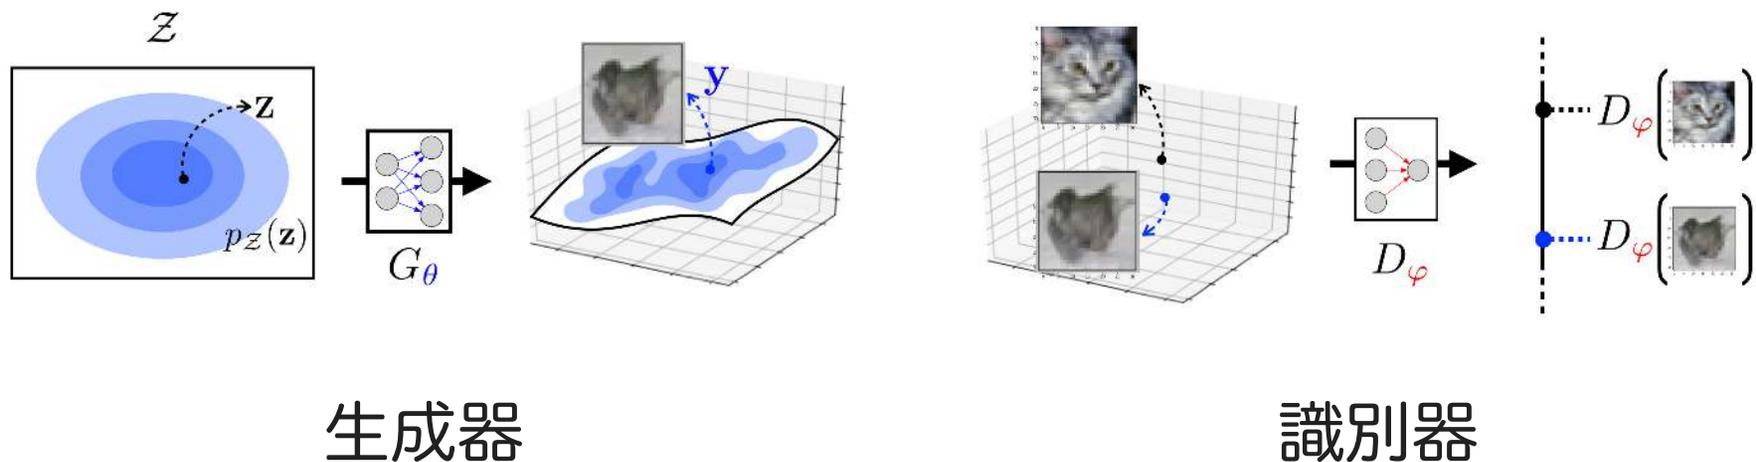
復号化器

- 目的関数と訓練

$$\left[ \underbrace{D_{KL} \left( q_{\varphi}(\mathbf{z}|\mathbf{x}) \parallel p_Z(\mathbf{z}) \right)}_{\text{符号化誤差}} \underbrace{- \mathbb{E}_{q_{\varphi}(\mathbf{z}|\mathbf{x})} [\log p_{\theta}(\mathbf{y}|\mathbf{z})]}_{\text{再構成誤差}} \right] \downarrow \text{w.r.t. } \varphi, \theta$$

# 1.3. Deep Generative Models

## ■ 敵対的生成ネットワーク(Generative Adversarial Net, GAN)



- 目的関数と訓練  $(\sigma(D) = \frac{1}{1+e^{-D}})$

$$\left[ \underbrace{\log \sigma(D_\phi(\mathbf{x}))}_{\text{本物を見分ける項}} + \underbrace{\log(1 - \sigma(D_\phi(G_\theta(\mathbf{z}))))}_{\text{偽物を見分ける項}} \right] \begin{array}{l} \uparrow \text{w.r.t. } \phi \\ \downarrow \text{w.r.t. } \theta \end{array}$$

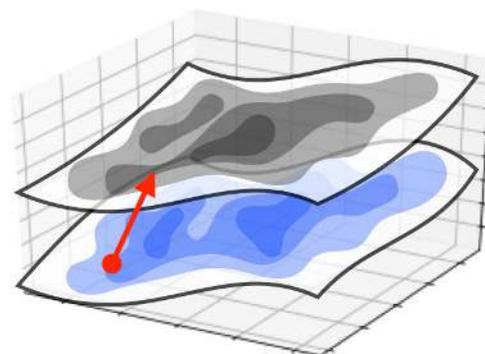
## 2. Optimal Transport (OT)

## 2.1. What is the Optimal Transport ?

### ■ Mongeの問題

コスト最小限の輸送  $\uparrow_T$

$p(\mathbf{x})$   
 $q(\mathbf{x})$



- 輸送コスト最小方法を求めたい：
$$\min_T \int \underbrace{\|\mathbf{x} - T(\mathbf{x})\|}_{\text{ユークリッド距離}} q(\mathbf{x}) d\mathbf{x}$$
- ただし、確率解釈は保存したい：
$$\int \delta(\mathbf{x} - T(\mathbf{y})) q(\mathbf{y}) d\mathbf{y} = p(\mathbf{x})$$

解の存在は、一般に非自明（いつでも存在するとは限らない）

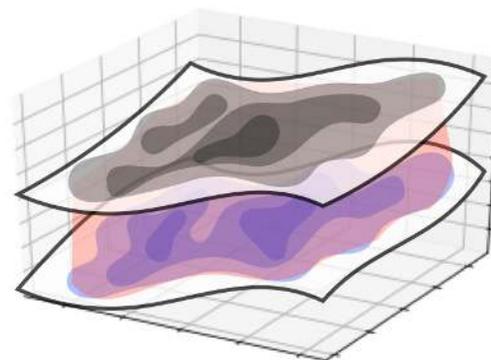
## 2.1. What is the Optimal Transport ?

### ■ Kantorovichによる問題の緩和

コスト最小限の確率  $\pi$

$p(\mathbf{x})$

$q(\mathbf{y})$



- 輸送コスト最小方法を求めたい：
$$\min_{\pi} \int \underbrace{\|\mathbf{x} - \mathbf{y}\|}_{\text{ユークリッド距離}} \pi(\mathbf{x}, \mathbf{y}) d\mathbf{x} d\mathbf{y}$$
- 確率解釈保存：
$$\int \pi(\mathbf{x}, \mathbf{y}) d\mathbf{y} = p(\mathbf{x}), \int \pi(\mathbf{x}, \mathbf{y}) d\mathbf{x} = q(\mathbf{y})$$

確率間の距離とみなせる： $D_W(p, q)$  (1-Wasserstein距離)

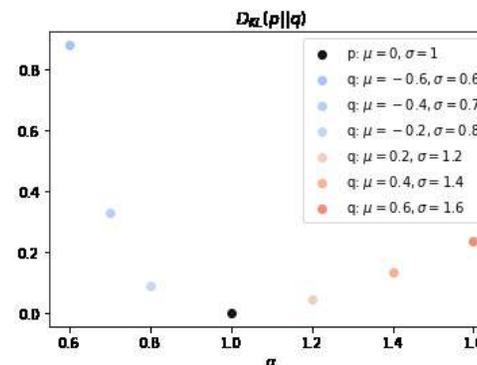
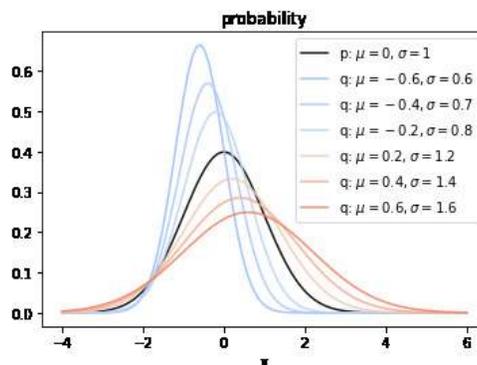
## 2.2. Generative models and Optimal transport

生成モデルの訓練：

$$\min_{\theta} \underbrace{D(p_{\mathcal{X}}, p_{\theta})}_{\text{何らか距離、0以上}}$$

■例：  $D = D_{KL}$  (サンプル数無限の最尤推定)

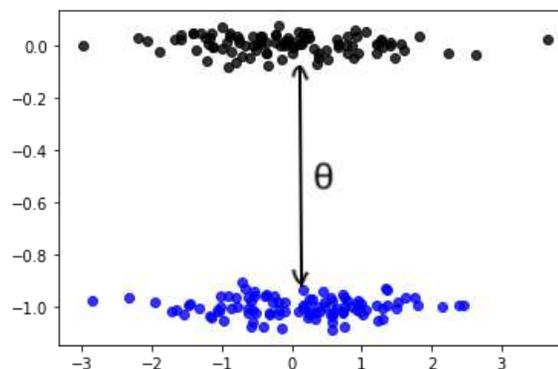
$$p_{\mathcal{X}}(x) = \frac{e^{-\frac{x^2}{2}}}{\sqrt{2\pi}}$$
$$p_{\mu, \sigma}(x) = \frac{e^{-\frac{(x-\mu)^2}{2\sigma^2}}}{\sqrt{2\pi\sigma^2}}$$



## 2.2. Generative models and Optimal transport

### ■ 確率分布が重ならないとき [Arjovsky+ (2017)]

$$p_{\mathcal{X}}(x) = \{\bullet\}$$
$$p_{\theta}(x) = \{\bullet\}$$



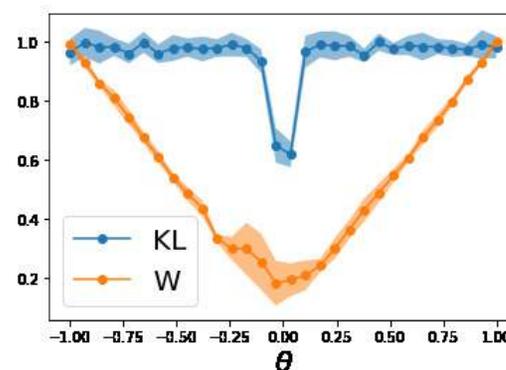
#### • Kullback-Leibler vs Wasserstein

確率分布が重ならない場合

$D_{KL}$  : ほとんど勾配がない

$D_W$  : 勾配をもつ

$\Rightarrow \min_{\theta} D_W(p_{\mathcal{X}}, p_{\theta})$  がベター?



## 2.3. Duality

---

### ■ Wasserstein Auto-Encoder [Tolstikhin+ (2017)]

$D_W(p_\chi, p_\theta)$  を最適輸送問題と思う：

$$\min_{\theta} \min_{\pi \in \Pi(p_\chi, p_\theta)} \underbrace{\int \|\mathbf{x} - \mathbf{y}\| \pi(\mathbf{x}, \mathbf{y}) d\mathbf{x}d\mathbf{y}}_{D_W(p_\chi, p_\theta)}$$

で  $\pi(\mathbf{x}, \mathbf{y}) = \int d\mathbf{z} p_\theta(\mathbf{y}|\mathbf{z})q_\varphi(\mathbf{z}|\mathbf{x})p_\chi(\mathbf{x})$  と仮定すると？

- 最適輸送問題 = 再構成誤差最小化
- 確率解釈保存 = 符号化誤差最小化

変分自己符号化機の一つと考える

## 2.3. Duality

### ■ Kantorovich-Rubinstein 双対性

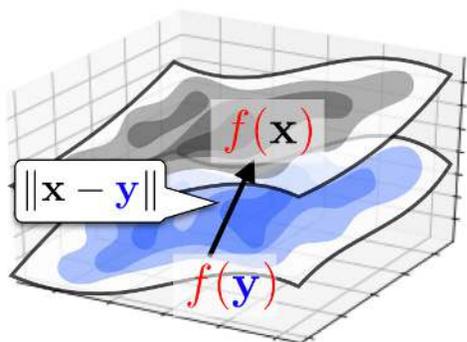
最適輸送問題

その双対問題

$$\min_{\pi \in \Pi(p, q)} \int \| \mathbf{x} - \mathbf{y} \| \pi(\mathbf{x}, \mathbf{y}) d\mathbf{x} d\mathbf{y} = D_W = \max_{f \in \text{Lip}} \left\{ \int f(\mathbf{x}) p(\mathbf{x}) d\mathbf{x} - \int f(\mathbf{y}) q(\mathbf{y}) d\mathbf{y} \right\}$$

Lipはリプシッツ制約:  $|f(\mathbf{x}) - f(\mathbf{y})| \leq \| \mathbf{x} - \mathbf{y} \|$

- 直感的(?)な説明(きちんとした説明:[Herrmann氏ブログ](#))



最適輸送問題(運送屋)

$\| \mathbf{x} - \mathbf{y} \|$  円の報酬

※なるべく安い輸送を目指す

双対問題(商人)

$f(\mathbf{y})$ 円で買い  $f(\mathbf{x})$ 円で売る

※運送屋より安くないと選ばれない

$$\hookrightarrow \underbrace{|f(\mathbf{x}) - f(\mathbf{y})|}_{\text{商人儲け}} \leq \underbrace{\| \mathbf{x} - \mathbf{y} \|}_{\text{運送屋儲け}}$$

## 2.3. Duality

---

### ■ Wasserstein GAN [Arjovsky+ (2017)]

$D_W(p_\chi, p_\theta)$  を双対問題と思う：

$$\min_{\theta} \max_{f \in \text{Lip}} \underbrace{\left\{ \int f(\mathbf{x}) p_\chi(\mathbf{x}) d\mathbf{x} - \int f(\mathbf{y}) p_\theta(\mathbf{y}) d\mathbf{y} \right\}}_{D_W(p_\chi, p_\theta)}$$

で  $f(\mathbf{x}) = D_\varphi(\mathbf{x})$  と仮定すると？

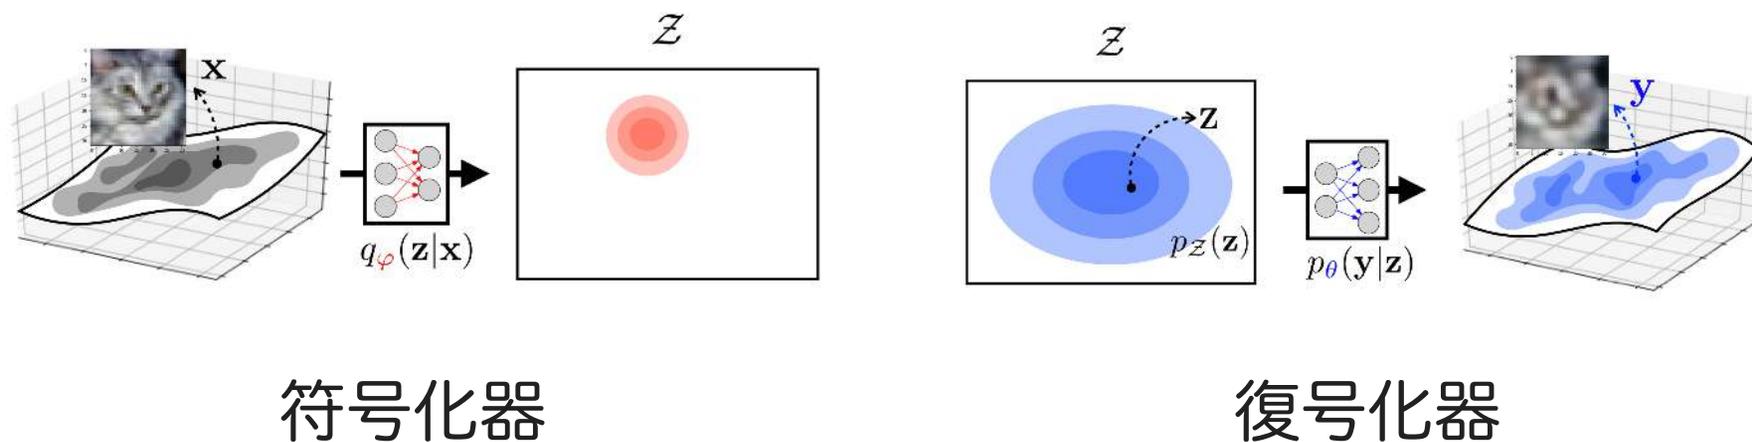
- 1 項目 = 本物を見分ける項
- 2 項目 = 偽物を見分ける項

$p_\theta(\mathbf{y}) = \int \delta(\mathbf{y} - G_\theta(\mathbf{z})) p_{\mathbf{z}}(\mathbf{z}) d\mathbf{z} \rightarrow$  敵対的生成ネットワークの一種

# 3. Post processing on DGMs

## 3.1. Motivations

### ■ VAEのトレーニング後



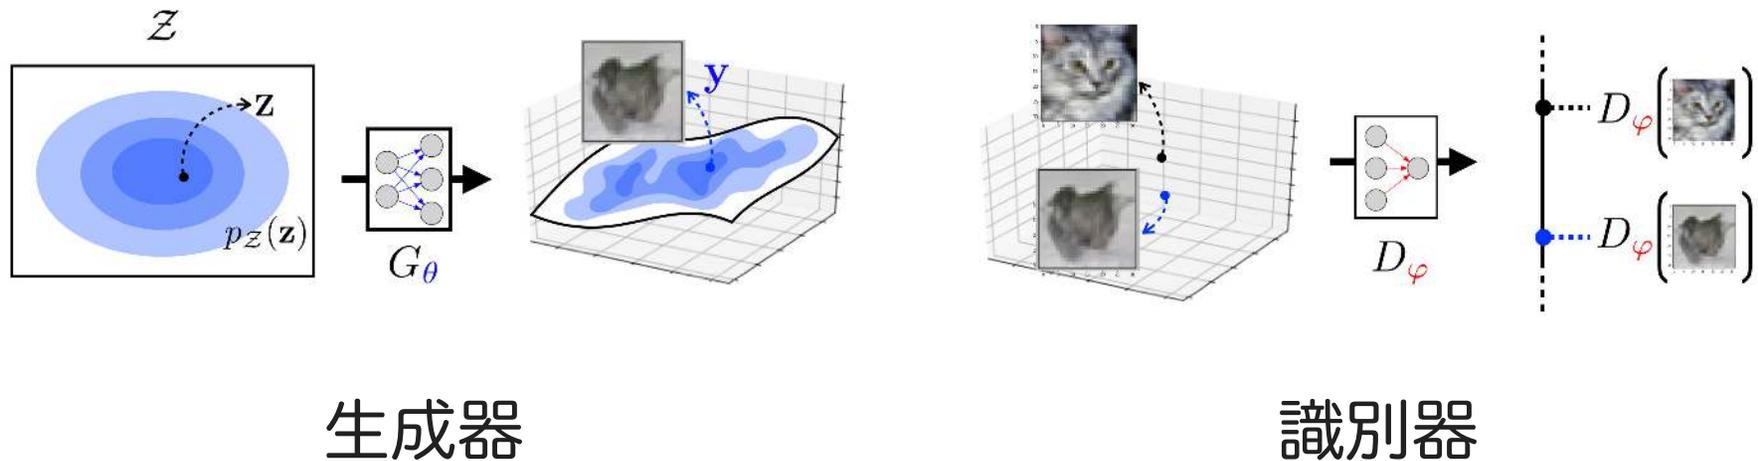
トレーニング後の用途：

- 復号化器 = 生成モデル (潜在空間から画像を作る)
- 符号化器 = 画像を潜在空間に埋め込む

どちらも使える

# 3.1. Motivations

## ■ GANのトレーニング後



トレーニング後の用途：

- 生成器 = 生成モデル (潜在空間から画像を作る)
- 識別器 = ???

識別器も訓練するので、何かに使いたい

# 3.1. Motivations

## ■GANのトレーニング後

生成画像に「不自然な部分」が出てくる場合がある

画像の例:

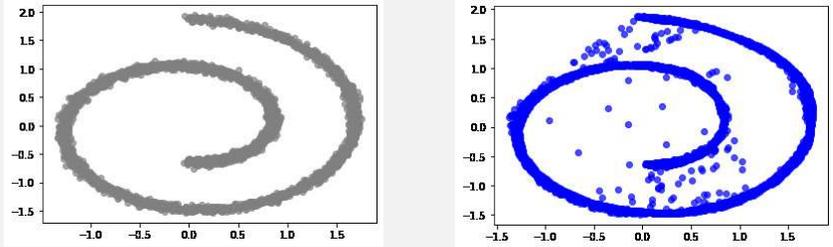
◎ ○ △ ×



[https://github.com/pfnet-research/sngan\\_projection](https://github.com/pfnet-research/sngan_projection)

$p_x(\mathbf{x})$        $p_\theta(\mathbf{x})$

2Dの例:



どうにかして「不自然な部分」を直せないか？

## 3.2. Post processing of GAN

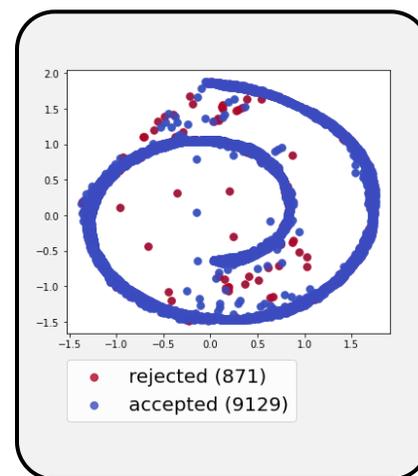
### ■ 識別器による棄却サンプリング [Azadi+ (2018)]

$$D^* = \arg \max_D \left[ \underbrace{\log \sigma(D(\mathbf{x}))}_{\text{本物を見分ける項}} + \underbrace{\log(1 - \sigma(D(G_\theta(\mathbf{z})))}_{\text{偽物を見分ける項}} \right]$$

$$\Rightarrow e^{-D^*(\mathbf{x})} = \frac{p_\theta(\mathbf{x})}{p_\chi(\mathbf{x})} \approx D_\varphi(\mathbf{x}) : \text{密度比を近似}$$

⇒ 棄却サンプリングの近似が可能  
手順

1.  $M = 1 / \min(e^{-D_\varphi(\mathbf{x})})$
2.  $\mathbf{z} \sim p_{\mathbf{z}}, \mathbf{y} = G_\theta(\mathbf{z})$
3. 確率  $1 / (M e^{-D(\mathbf{y})})$  で  $\mathbf{y}$  を採用



## 3.2. Post processing of GAN

### ■ 識別器による最適輸送 [AT (2019)]

$$\max_D \left[ \underbrace{\log \sigma(D(\mathbf{x}))}_{\text{本物を見分ける項}} + \underbrace{\log(1 - \sigma(D(G_\theta(\mathbf{z})))}_{\text{偽物を見分ける項}} \right]$$

$$\leq \max_D \left[ D(\mathbf{x}) - D(G_\theta(\mathbf{z})) \right] \approx D_W(p_X, p_\theta): \text{双対問題を近似}$$

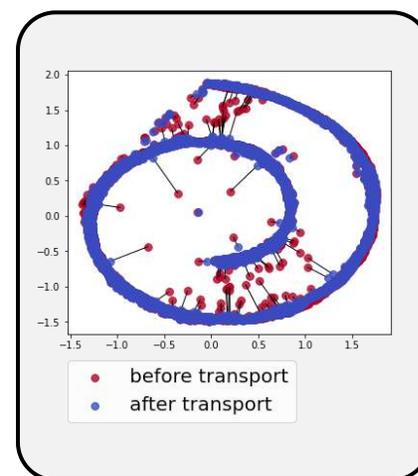
⇒ OTの近似が可能(→なぜ?)

手順:

1.  $\mathbf{z} \sim p_Z, \mathbf{y} = G_\theta(\mathbf{z})$

2. 以下繰り返す

3.  $\mathbf{y} = \mathbf{y} - \epsilon \nabla_{\mathbf{y}} (\|\mathbf{y} - G_\theta(\mathbf{z})\| - D_\varphi(\mathbf{y}))$



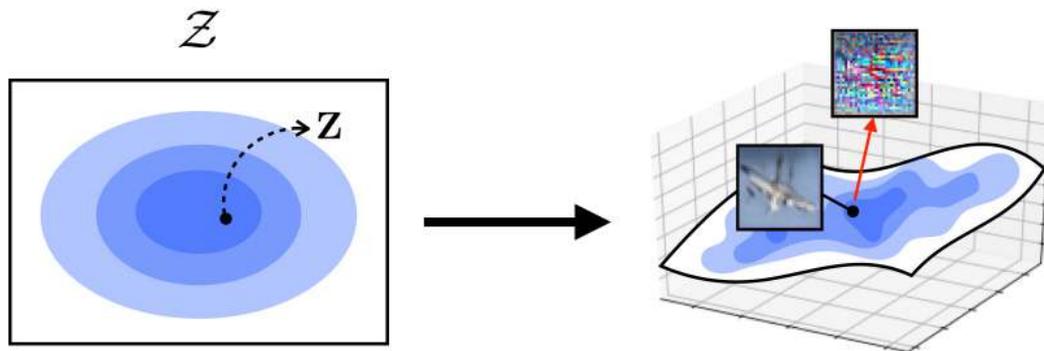
## 3.2. Post processing of GAN

### ■ 識別器による最適輸送 [AT (2019)]

画像空間で直接最適輸送をやろうとすると失敗する



推測:高次元 + 多様体仮説のせい?



高次元だと外にはみ出やすい?

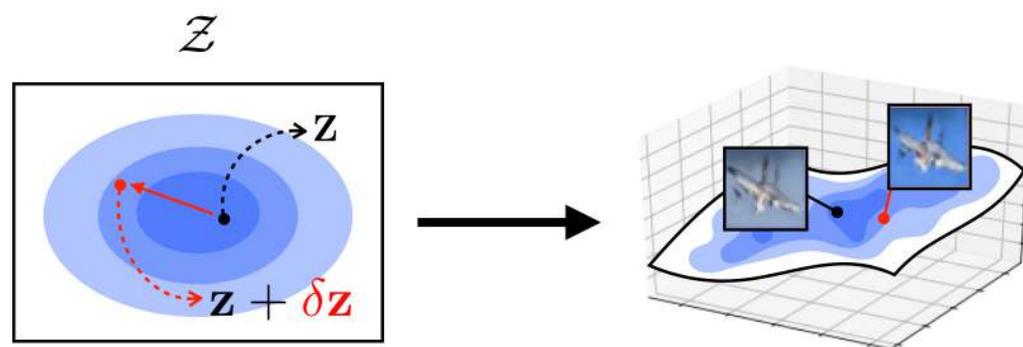
例:  $\dim(\mathcal{X}) = 10, \dim(\mathcal{Z}) = 2$

⇒ 直行する次元=8

## 3.2. Post processing of GAN

### ■ 識別器による最適輸送 [AT (2019)]

潜在空間に"引き戻す"と良い



仮定:  $G_\theta(\mathbf{z}_x) = \mathbf{x} \Rightarrow$  潜在空間の  $p_Z$  についての最適輸送

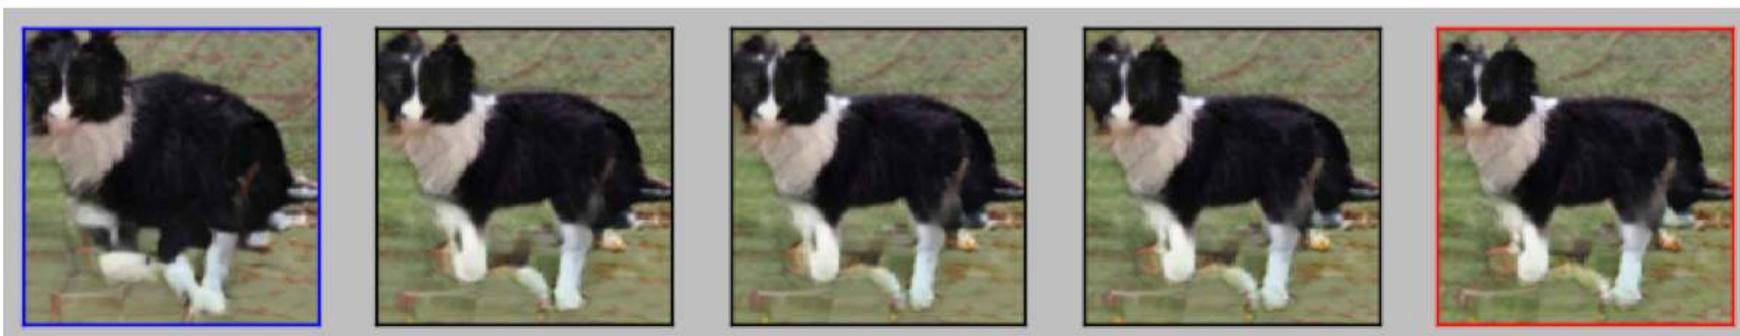
$$\max_D \left[ D(\mathbf{x}) - D(G_\theta(\mathbf{z})) \right] \approx \max_D \left[ D(G_\theta(\mathbf{z}_x)) - D(G_\theta(\mathbf{z})) \right]$$

$D \circ G_\theta$  を  $D_W(G_\theta^{-1} p_X, p_Z)$  の双対問題の解だと考える

## 3.2. Post processing of GAN

### ■ 識別器による最適輸送 [AT (2019)]

↓元の生成画像 [https://github.com/pfnet-research/sngan\\_projection](https://github.com/pfnet-research/sngan_projection)



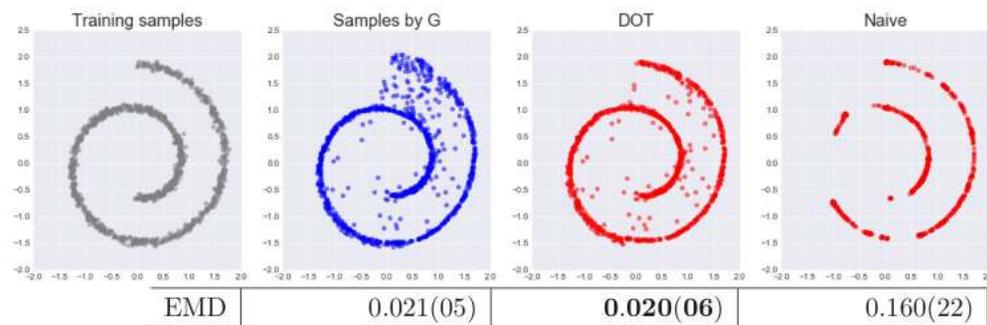
生成画像クォリティ値の改善(IS(大が良い)/FID(小が良い))

	Gのみ		改善後
CIFAR-10:	7.85/21.53	→	8.50/19.71
STL-10:	9.29/45.79	→	10.30/40.51
ImageNet:	36.40/43.34	→	37.61/42.35

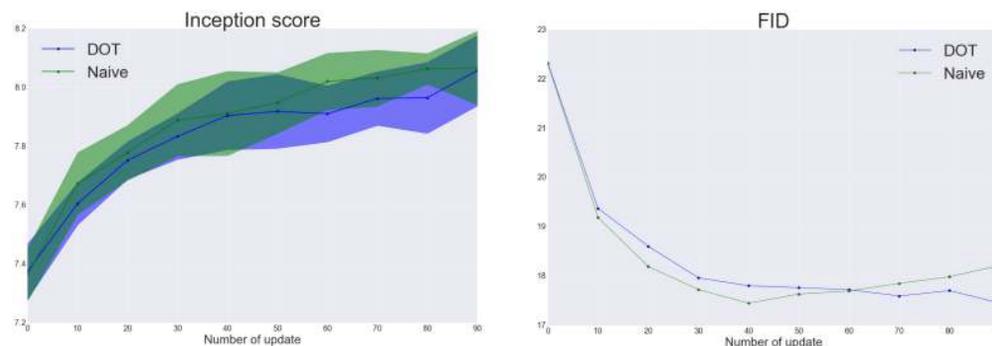
## 3.2. Post processing of GAN

### ■ 識別器による最適輸送 [AT (2019)]

コメント1. 低次元では「素朴な改善( $D \uparrow$ の改善)」より良い



コメント2. 高次元(画像)では「素朴な改善」より少し良いくらい



## 3.3. Related works

---

- MHGAN [Turner+ (2018)]  
棄却サンプリングではなくMCMCで効率を上げる。
- Energy-based改善 [Arbel+ (2020)] [Che+ (2020)]  
訓練後D = ポテンシャル  
潜在空間サンプリング=Langevin動力学で改善

チュートリアルやテキスト

- GAN: [Goodfellow (2016)]
- VAE: [Kingma&Welling (2019)]
- 最適輸送: [Peyré&Cuturi (2018)]

# Summary

- やったこと
  - GAN+最適輸送理論 → 識別器による最適輸送を提案
  - 画像の場合 → 潜在空間の最適輸送と思うと○
  - 全ての場合で改善がみられた
    - ただし、パラメータの調節は必須
    - 画像の場合は潜在空間に戻らないとだめ
    - 潜在空間でのOTは理論的に弱い(が、実験では成功する)
- 素朴な疑問(個人的にできたら面白いと思っていること)
  - 潜在空間でのOTの理論？
  - 画像生成ではなく、文章生成に応用？
    - "離散"最適輸送？
  - 潜在空間の確率  $p_Z$  の役割は何か？

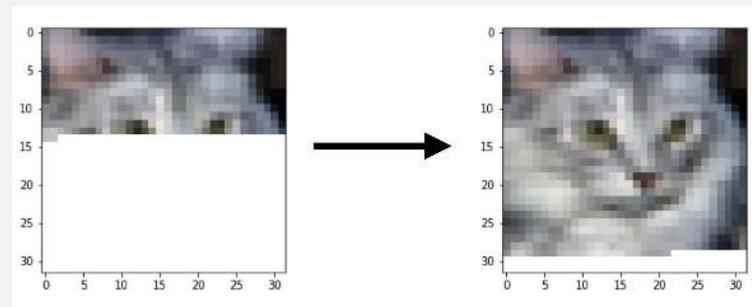
# Appendix

## 他の深層生成モデル ↩

### ■ other models

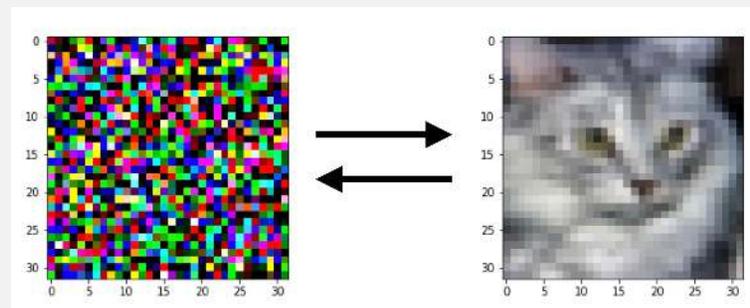
- 自己回帰モデル: ベクトル  $\mathbf{x}$  の成分を順番に生成する

$$p_{\theta}(\mathbf{x}) = \prod_i p_{\theta}(x_i | x_1, \dots, x_{i-1})$$



- Flow-basedモデル: 逆関数をもつ  $f_{\theta}$  で単純な分布に変形

$$p_{\theta}(\mathbf{x}) = p_{\text{simple}}(f_{\theta}(\mathbf{x})) J_{\theta}(\mathbf{x})$$



## なぜ双対問題から最適輸送が導かれるか ↩

entropy制約バージョンの説明。一般の場合の詳細は、Monge問題の解の存在仮定が必要。詳しくは論文 [AT (2019)] の付録

最適輸送

双対

$$\min_{\pi} \int \left( \|\mathbf{x} - \mathbf{y}\| + \frac{1}{\beta} \log \pi(\mathbf{x}, \mathbf{y}) \right) \pi(\mathbf{x}, \mathbf{y}) d\mathbf{x} d\mathbf{y} = \max_{f, g} \left\{ \int f(\mathbf{x}) p(\mathbf{x}) d\mathbf{x} + \int g(\mathbf{y}) q(\mathbf{y}) d\mathbf{y} \right\}$$

以下が成り立つ

([Proposition 4.3. Peyré&Cuturi]や[拙書6.3.2節]参照) :

- $\pi^*(\mathbf{x}, \mathbf{y}) \propto \exp \left[ -\beta(\|\mathbf{x} - \mathbf{y}\| - f^*(\mathbf{x}) - g^*(\mathbf{y})) \right]$
- $\pi^*(\mathbf{x}|\mathbf{y}) \propto \exp \left[ \underbrace{-\beta(\|\mathbf{x} - \mathbf{y}\| - f^*(\mathbf{x}))}_{\text{ここが最小の}\mathbf{x}\text{にピーク}} \right] : \text{最適輸送に対応}$