

生成模型入門

田中章詞 (RIKEN AIP/iTHEMS)

@計算物理 春の学校 2023

自己紹介

■ 所属

- 理研 AIP/iTHEMS
—— 上級研究員

■ 研究

- 機械学習 (理論/応用)
- 数理物理 (素粒子理論)



 [AkinoriTanaka-phys](#)

学術変革領域研究（A） 2022～2026年度

深層学習の数理と応用

PD募集中: [JREC-in](#)



- メンバー
 - 唐木田 亮さん (産総研)
 - 瀧 雅人さん (立教大学)
- 目的
 - 深層学習の研究
物理バックグラウンドの人も welcomeです！

1. 導入

1. 導入

■ 1-1. 生成モデルとは？

与えられたデータから、それに似たデータを作り出すモデル



■ 例：文章生成

LARTIUS:

O, 'tis Marcius!
Let's fetch him off, or make
remain alike.

AKINORI:

Came, bloody decrees,
By city, not her brows, he is
bloody woe!

データの住むベクトル空間 X 上に確率分布があると考える：

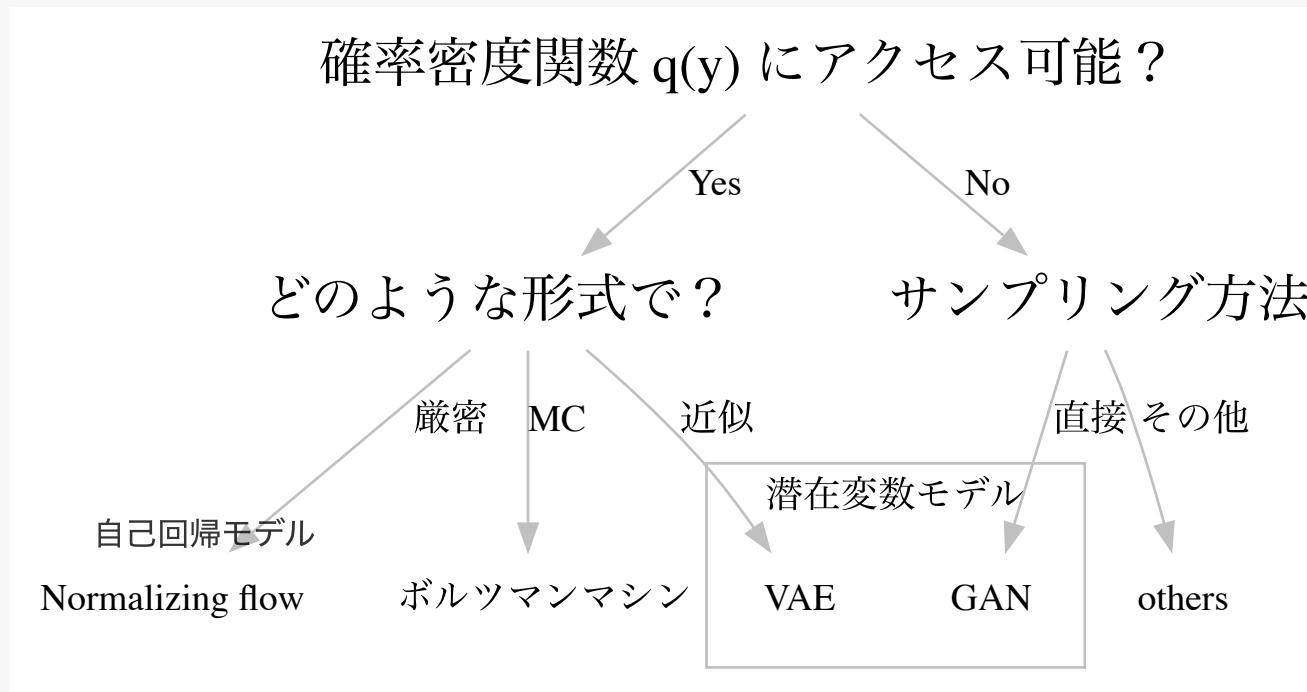


1. 導入

■ 1-2. 生成モデルの分類

(不完全な) 分類図

<https://arxiv.org/abs/1701.00160> より：



最近は 拡散モデル：確率密度にアクセス可能（数値積分が必要）な場合もある

1. 導入

■ 1-2. 生成モデルの分類

訓練方法による分類

KLダイバージェンス最小化によるもの

- ボルツマンマシン
- 自己回帰モデル (teacher-forcing)
- Normalizing flow

潜在変数モデル

- 変分自己符号化器 (VAE) (理想的な場合はKL最小化)
- 敵対的生成ネットワーク(GAN)

拡散モデル

- スコアマッチング
- DDPM (理想的な場合はKL最小化?)
- SDE
- フローマッチング

内容

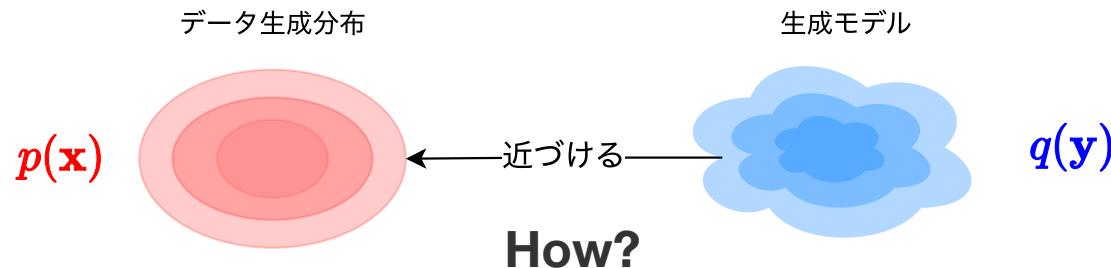
1. 導入
2. KLダイバージェンス最小化によるもの
3. 潜在変数モデル
4. 拡散モデル

2. KLダイバージェンス最小化によるもの

- ボルツマンマシン
- 自己回帰モデル
- Normalizing flow

2. KLダイバージェンス最小化によるもの

■ 2-1. 基本的な考え方

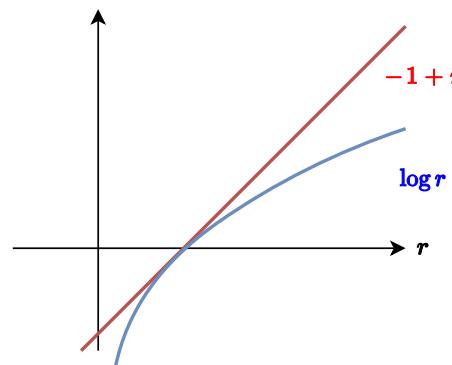


KLダイバージェンス最小化

$$\min_q \underbrace{D_{KL}(p\|q)}_{\left\langle \log \frac{p(\mathbf{x})}{q(\mathbf{x})} \right\rangle_p}$$

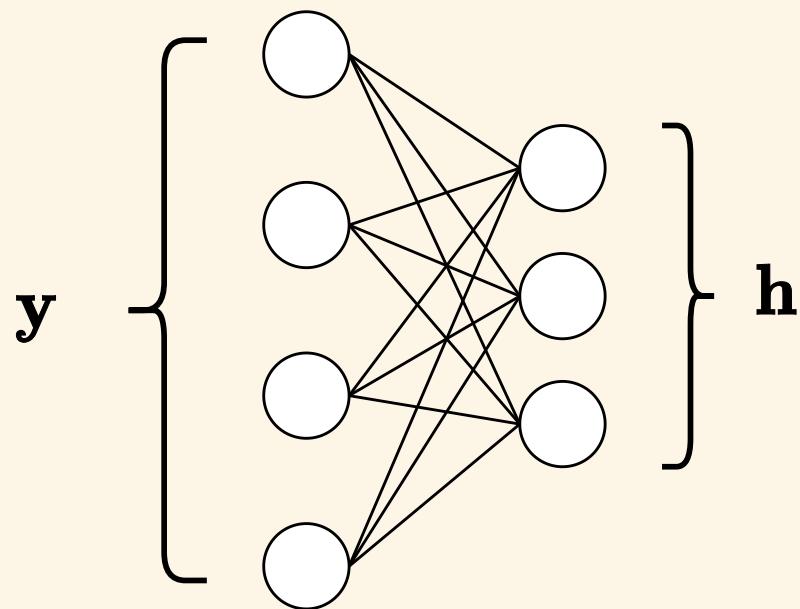
最小値 ($=0$) でのみ $p = q$ となる：

$$D_{KL}(p\|q) = \int p(\mathbf{x}) \left(-\log \frac{q(\mathbf{x})}{p(\mathbf{x})} - 1 + \frac{q(\mathbf{x})}{p(\mathbf{x})} \right) d\mathbf{x} \geq 0$$



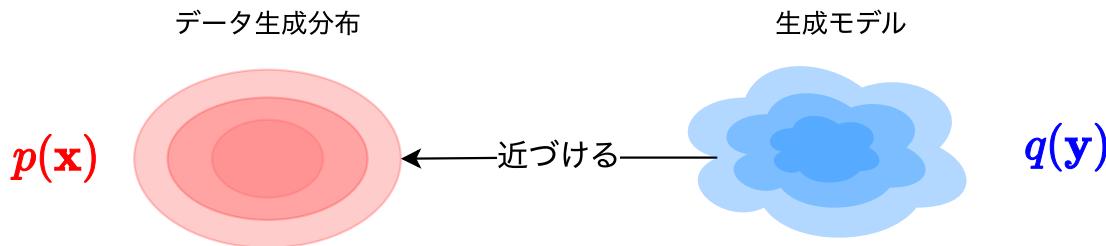
2. KLダイバージェンス最小化によるもの

■ 2-2. ボルツマンマシン



2. KLダイバージェンス最小化によるもの

■ 2-2. ボルツマンマシン



確率密度関数： ボルツマン分布： $q_\theta(\mathbf{y}) = \frac{e^{-E_\theta(\mathbf{y})}}{Z(\theta)}$

やりたいこと

$$\min_{\theta} D_{KL}(p \| q_{\theta})$$

難しいので 以下を繰り返す

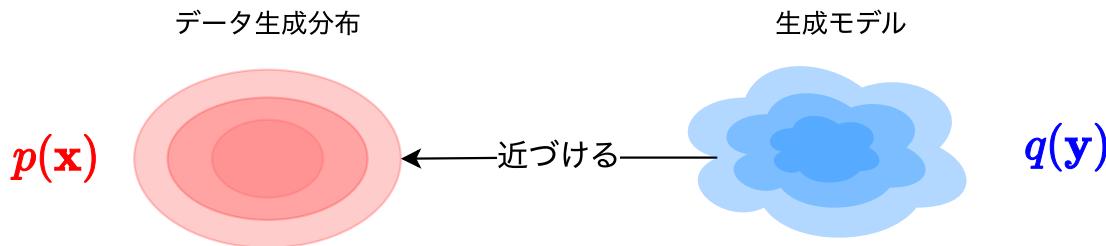
$$\theta_{t+1} = \theta_t - \epsilon_t \frac{\nabla_{\theta} D_{KL}(p \| q_{\theta})}{}$$

ちょっと計算すると以下がわかります：

$$\underline{\nabla_{\theta} D_{KL}(p \| q_{\theta})} = - \langle \nabla_{\theta} E_{\theta}(\mathbf{x}) \rangle_{p(\mathbf{x})} + \langle \nabla_{\theta} E_{\theta}(\mathbf{y}) \rangle_{q_{\theta}(\mathbf{y})}$$

2. KLダイバージェンス最小化によるもの

■ 2-2. ボルツマンマシン



確率密度関数： ボルツマン分布： $q_\theta(\mathbf{y}) = \frac{e^{-E_\theta(\mathbf{y})}}{Z(\theta)}$

理想的な学習ルール

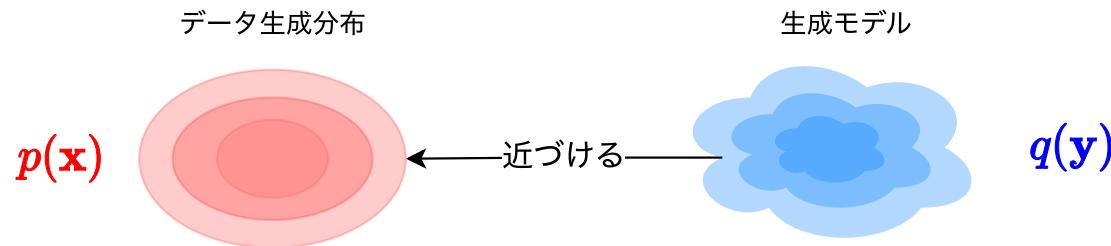
$$\theta_{t+1} = \theta_t + \epsilon_t \left(\langle \nabla_\theta E_\theta(\mathbf{x}) \rangle_{p(\mathbf{x})} - \langle \nabla_\theta E_\theta(\mathbf{y}) \rangle_{q_\theta(\mathbf{y})} \right)$$

実用上の問題：

- $\langle \dots \rangle_{p(\mathbf{x})}$ は不可能 → データ平均に置き換えて近似
- $\langle \dots \rangle_{q_\theta(\mathbf{y})}$ は困難 → モンテカルロ(MC)サンプルで置き換えて近似

2. KLダイバージェンス最小化によるもの

■ 2-2. ボルツマンマシン



確率密度関数： ボルツマン分布： $q_\theta(\mathbf{y}) = \frac{e^{-E_\theta(\mathbf{y})}}{Z(\theta)}$

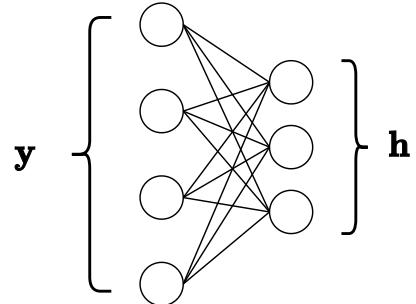
実行可能な学習ルール

$$\theta_{t+1} = \theta_t + \epsilon_t \left(\frac{1}{N_{\text{data}}} \sum_{i=1}^{N_{\text{data}}} \nabla_\theta E_\theta(\underbrace{\mathbf{x}_i}_{\text{データ点}}) - \frac{1}{N_{\text{gen}}} \sum_{j=1}^{N_{\text{gen}}} \nabla_\theta E_\theta(\underbrace{\mathbf{y}_j}_{MC \text{サンプル}}) \right)$$

残る問題：**MC サンプル** の効率

2. KLダイバージェンス最小化によるもの

■ 2-3. 制限ボルツマンマシン



「補助変数 \mathbf{h} 」を設定することで学習がうまくいくようになる：

制限ボルツマンマシン

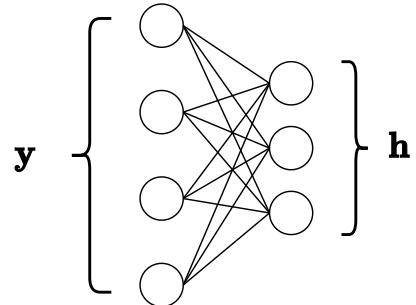
$$E_\theta(\mathbf{y}) = -\log \sum_{\mathbf{h}} e^{-E_\theta(\mathbf{y}, \mathbf{h})}$$

エネルギー関数の微分値？

$$\nabla_\theta E_\theta(\mathbf{y}) = \frac{\sum_{\mathbf{h}} \nabla_\theta E_\theta(\mathbf{y}, \mathbf{h}) e^{-E_\theta(\mathbf{y}, \mathbf{h})}}{\sum_{\mathbf{h}'} e^{-E_\theta(\mathbf{y}, \mathbf{h}')}} = \langle \nabla_\theta E_\theta(\mathbf{y}, \mathbf{h}) \rangle_{\mathbf{h} \sim q_\theta(\mathbf{h}|\mathbf{y})}$$

2. KLダイバージェンス最小化によるもの

■ 2-3. 制限ボルツマンマシン



「補助変数 \mathbf{h} 」を設定することで学習がうまくいくようになる：

理想的な学習ルール

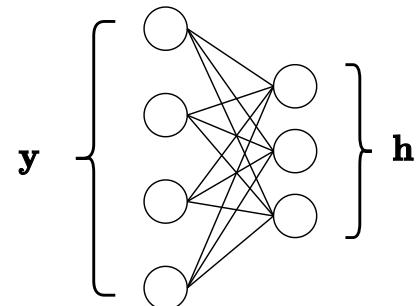
$$\theta_{t+1} = \theta_t + \epsilon_t \left(\langle \nabla_{\theta} E_{\theta}(\mathbf{x}, \mathbf{h}) \rangle_{p(\mathbf{x})q_{\theta}(\mathbf{h}|\mathbf{x})} - \langle \nabla_{\theta} E_{\theta}(\mathbf{y}, \mathbf{h}) \rangle_{q_{\theta}(\mathbf{y})q_{\theta}(\mathbf{h}|\mathbf{y})} \right)$$

実用上は：

- $\langle \dots \rangle_{p(\mathbf{x})q_{\theta}(\mathbf{h}|\mathbf{x})} \rightarrow$ データ $\mathbf{x} \rightarrow q_{\theta}(\mathbf{h}|\mathbf{x})$ で \mathbf{h} をサンプル
- $\langle \dots \rangle_{q_{\theta}(\mathbf{y})q_{\theta}(\mathbf{h}|\mathbf{y})} \rightarrow$ ブロック化ギブスサンプリング

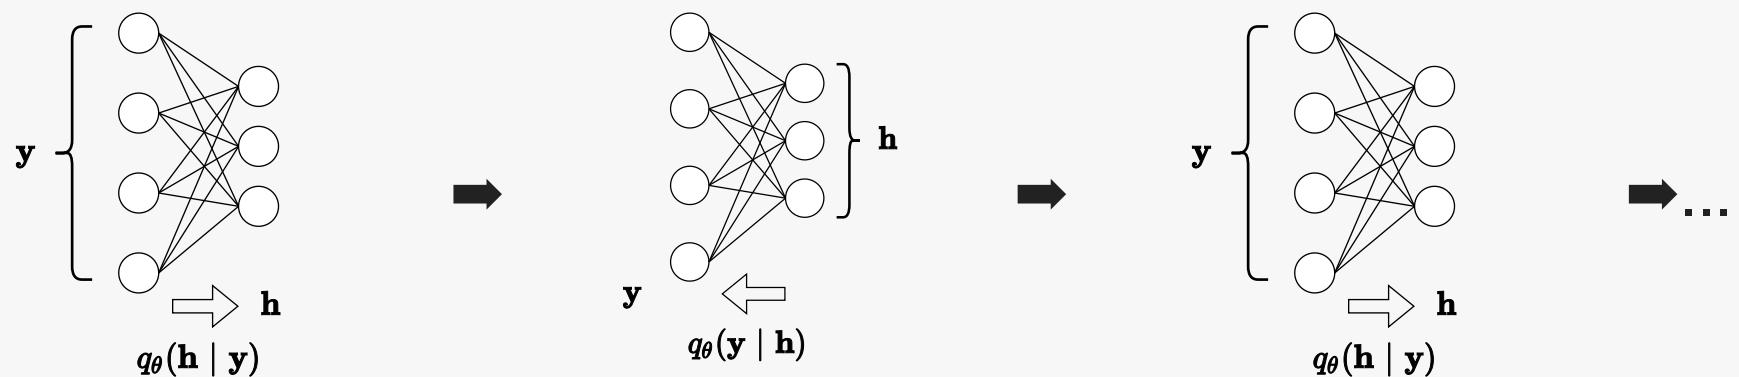
2. KLダイバージェンス最小化によるもの

■ 2-3. 制限ボルツマンマシン



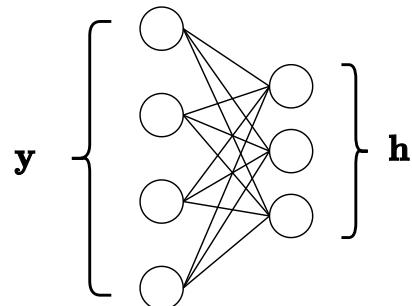
「補助変数 h 」を設定することで学習がうまくいくようになる：

ブロック化ギブスサンプリング



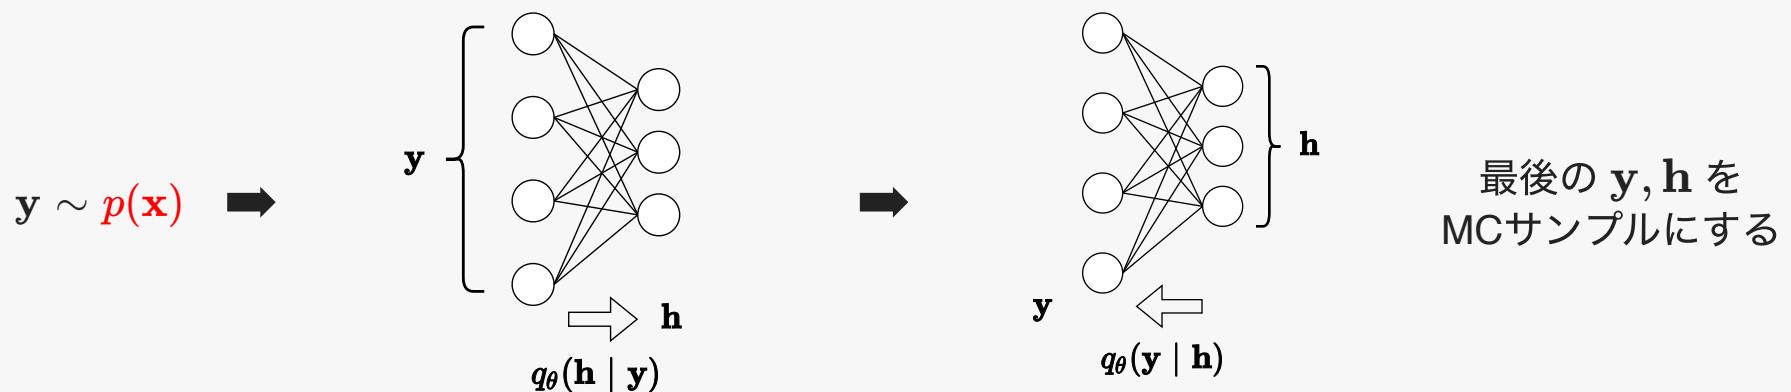
2. KLダイバージェンス最小化によるもの

■ 2-3. 制限ボルツマンマシン



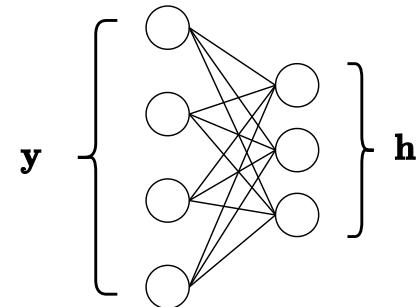
「補助変数 h 」を設定することで学習がうまくいくようになる：

コントラストティブ・ダイバージェンス法 (CD1)



2. KLダイバージェンス最小化によるもの

■ 2-3. 制限ボルツマンマシン



「補助変数 \mathbf{h} 」を設定することで学習がうまくいくようになる：

実行可能な学習ルール

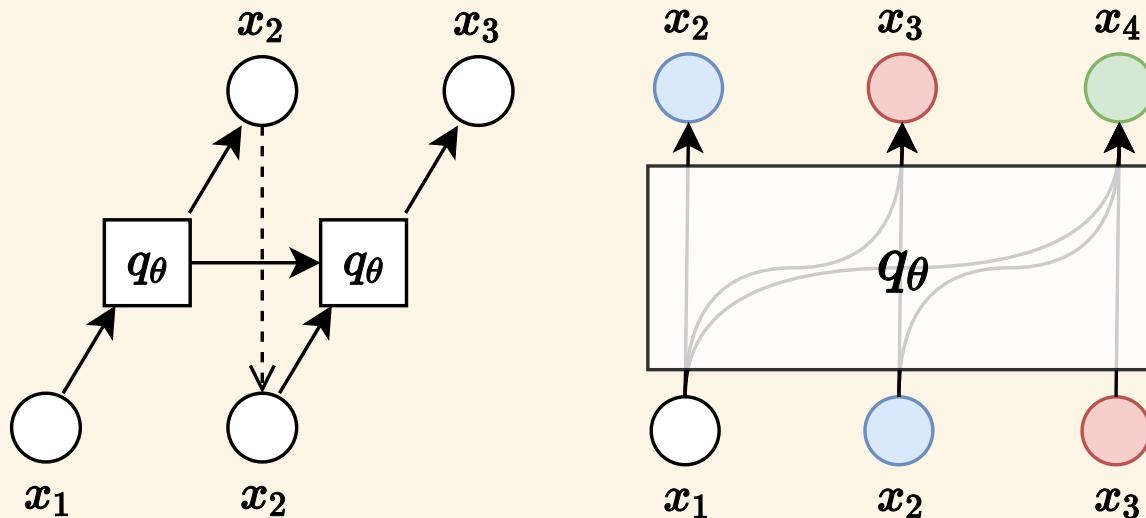
$$\theta_{t+1} = \theta_t + \epsilon_t \left(\frac{1}{N_{\text{data}}} \sum_{i=1}^{N_{\text{data}}} \nabla_{\theta} E_{\theta} \left(\underbrace{\mathbf{x}_i}_{\text{データ点}} , \underbrace{\mathbf{h}_i}_{\sim q_{\theta}(\mathbf{h}|\mathbf{x}_i)} \right) - \frac{1}{N_{\text{gen}}} \sum_{j=1}^{N_{\text{gen}}} \nabla_{\theta} E_{\theta} \left(\underbrace{\mathbf{y}_j, \mathbf{h}_j}_{\text{MCサンプル}} \right) \right)$$

MCサンプルは CD1 で十分とされていたが、近年見直し？

- Langevinサンプリングによる訓練の報告：<https://arxiv.org/abs/2210.10318>

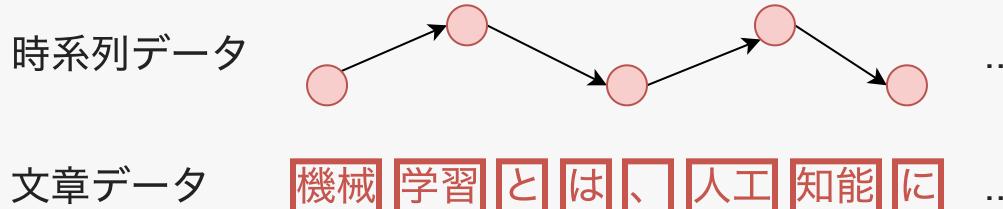
2. KLダイバージェンス最小化によるもの

■ 2-4. 自己回帰モデル



2. KLダイバージェンス最小化によるもの

■ 2-4. 自己回帰モデル



共に連続するベクトルからなるデータと考えられる：

$$\mathbf{x}^{t=1}, \mathbf{x}^{t=2}, \mathbf{x}^{t=3}, \mathbf{x}^{t=4}, \mathbf{x}^{t=5}, \dots, \mathbf{x}^{t=T}$$

\Downarrow 略記

$$\mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3, \mathbf{x}^4, \mathbf{x}^5, \dots, \mathbf{x}^T$$

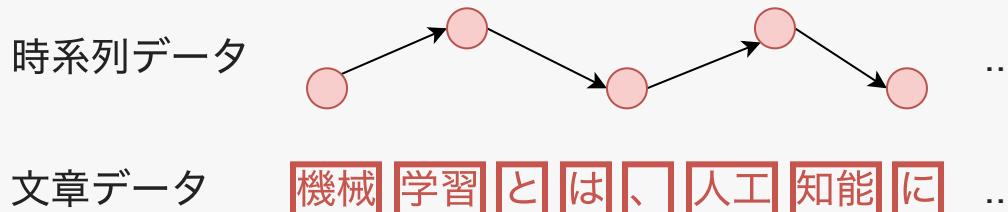
従って、データ生成分布も、モデルも

$$p(\mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3, \mathbf{x}^4, \mathbf{x}^5, \dots, \mathbf{x}^T)$$
$$q_{\theta}(\mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3, \mathbf{x}^4, \mathbf{x}^5, \dots, \mathbf{x}^T)$$

となる。

2. KLダイバージェンス最小化によるもの

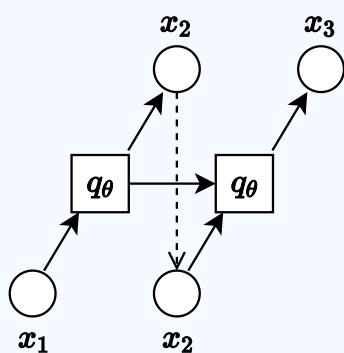
■ 2-4. 自己回帰モデル



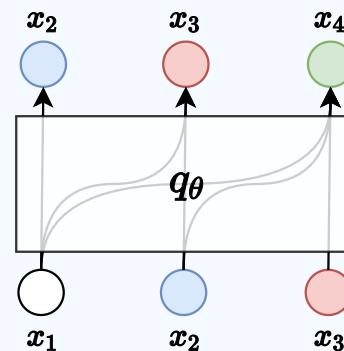
モデルには因果的な構造を課す場合が多い：

$$\begin{aligned} & q_{\theta}(\mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3, \mathbf{x}^4, \mathbf{x}^5, \dots, \mathbf{x}^T) \\ &= q_{\theta}(\mathbf{x}^1) \cdot q_{\theta}(\mathbf{x}^2 | \mathbf{x}^1) \cdot q_{\theta}(\mathbf{x}^3 | \mathbf{x}^1, \mathbf{x}^2) \cdot q_{\theta}(\mathbf{x}^4 | \mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3) \cdot q_{\theta}(\mathbf{x}^5 | \mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3, \mathbf{x}^4) \dots \end{aligned}$$

リカレントニューラルネット

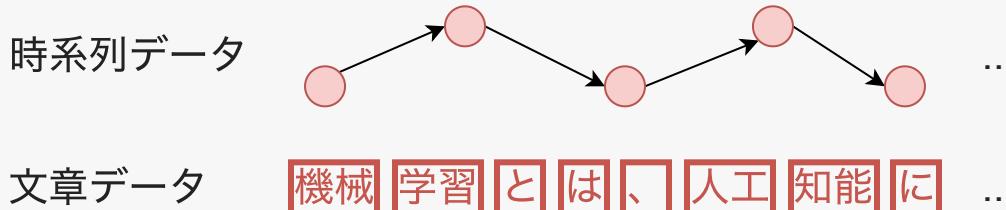


Transformer (位置エンコーディング)



2. KLダイバージェンス最小化によるもの

■ 2-4. 自己回帰モデル



モデルには因果的な構造を課す場合が多い：

$$\begin{aligned} & q_{\theta}(\mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3, \mathbf{x}^4, \mathbf{x}^5, \dots, \mathbf{x}^T) \\ &= q_{\theta}(\mathbf{x}^1) \cdot q_{\theta}(\mathbf{x}^2 | \mathbf{x}^1) \cdot q_{\theta}(\mathbf{x}^3 | \mathbf{x}^1, \mathbf{x}^2) \cdot q_{\theta}(\mathbf{x}^4 | \mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3) \cdot q_{\theta}(\mathbf{x}^5 | \mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3, \mathbf{x}^4) \cdots \end{aligned}$$

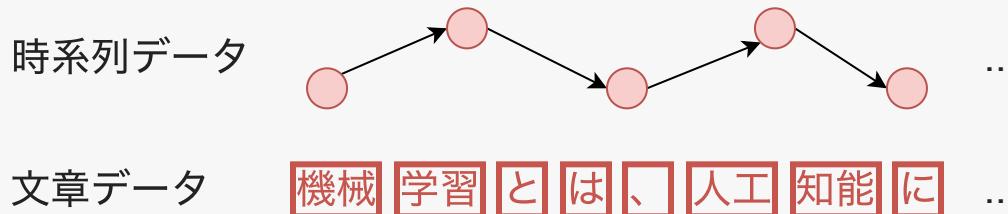
やりたいこと

$$\min_{\theta} D_{KL}(p \| q_{\theta})$$

因果構造があるので、少し分解できる

2. KLダイバージェンス最小化によるもの

■ 2-4. 自己回帰モデル



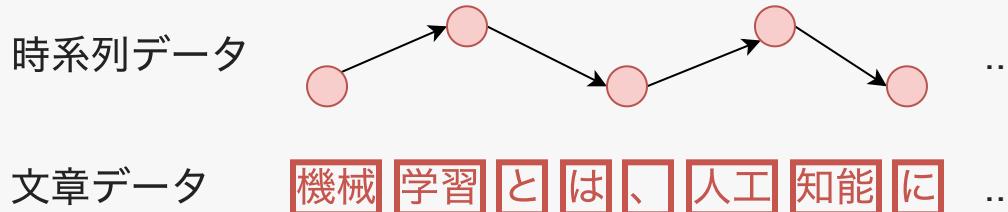
モデルには因果的な構造を課す場合が多い：

$$\begin{aligned} & q_{\theta}(\mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3, \mathbf{x}^4, \mathbf{x}^5, \dots, \mathbf{x}^T) \\ &= q_{\theta}(\mathbf{x}^1) \cdot q_{\theta}(\mathbf{x}^2 | \mathbf{x}^1) \cdot q_{\theta}(\mathbf{x}^3 | \mathbf{x}^1, \mathbf{x}^2) \cdot q_{\theta}(\mathbf{x}^4 | \mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3) \cdot q_{\theta}(\mathbf{x}^5 | \mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3, \mathbf{x}^4) \cdots \end{aligned}$$

$$\begin{aligned} D_{KL}(\mathbf{p} \| q_{\theta}) + \underbrace{S(\mathbf{p})}_{\text{エントロピー}} &= -\langle \log q_{\theta}(\mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3, \dots, \mathbf{x}^T) \rangle_{\mathbf{p}} \\ &= -\langle \log q_{\theta}(\mathbf{x}^1) \cdot q_{\theta}(\mathbf{x}^2 | \mathbf{x}^1) \cdot q_{\theta}(\mathbf{x}^3 | \mathbf{x}^1, \mathbf{x}^2) \cdots \rangle_{\mathbf{p}} \\ &= -\sum_{t=1}^T \langle \log q_{\theta}(\mathbf{x}^t | \mathbf{x}^1, \dots, \mathbf{x}^{t-1}) \rangle_{\mathbf{p}} \end{aligned}$$

2. KLダイバージェンス最小化によるもの

■ 2-4. 自己回帰モデル



モデルには因果的な構造を課す場合が多い：

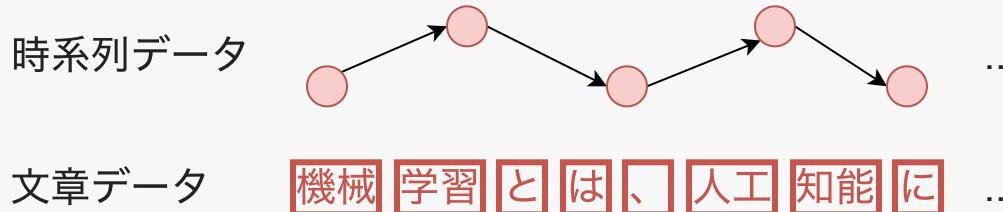
$$\begin{aligned} q_{\theta}(\mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3, \mathbf{x}^4, \mathbf{x}^5, \dots, \mathbf{x}^T) \\ = q_{\theta}(\mathbf{x}^1) \cdot q_{\theta}(\mathbf{x}^2 | \mathbf{x}^1) \cdot q_{\theta}(\mathbf{x}^3 | \mathbf{x}^1, \mathbf{x}^2) \cdot q_{\theta}(\mathbf{x}^4 | \mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3) \cdot q_{\theta}(\mathbf{x}^5 | \mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3, \mathbf{x}^4) \dots \end{aligned}$$

勾配更新

$$\theta_{t+1} = \theta_t - \epsilon_t \nabla_{\theta} \left(- \sum_{t=1}^T \langle \log q_{\theta}(\mathbf{x}^t | \mathbf{x}^1, \dots, \mathbf{x}^{t-1}) \rangle_{\mathbf{p}} \right)$$

2. KLダイバージェンス最小化によるもの

■ 2-4. 自己回帰モデル



モデルには因果的な構造を課す場合が多い：

$$\begin{aligned} q_{\theta}(\mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3, \mathbf{x}^4, \mathbf{x}^5, \dots, \mathbf{x}^T) \\ = q_{\theta}(\mathbf{x}^1) \cdot q_{\theta}(\mathbf{x}^2 | \mathbf{x}^1) \cdot q_{\theta}(\mathbf{x}^3 | \mathbf{x}^1, \mathbf{x}^2) \cdot q_{\theta}(\mathbf{x}^4 | \mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3) \cdot q_{\theta}(\mathbf{x}^5 | \mathbf{x}^1, \mathbf{x}^2, \mathbf{x}^3, \mathbf{x}^4) \dots \end{aligned}$$

実行可能な学習ルール

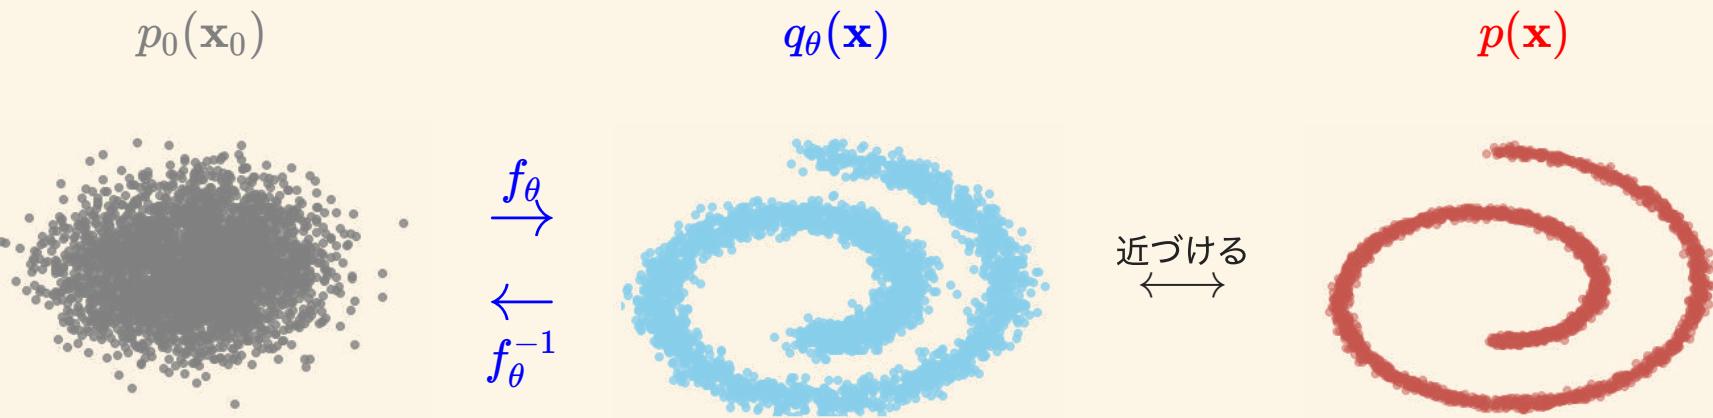
$$\theta_{t+1} = \theta_t - \epsilon_t \nabla_{\theta} \frac{1}{N_{\text{data}}} \sum_{i=1}^{N_{\text{data}}} \left(- \sum_{t=1}^T \log q_{\theta}(\mathbf{x}_i^t | \mathbf{x}_i^1, \dots, \mathbf{x}_i^{t-1}) \right)$$

入力を自身の過去の生成ベクトルではなく、データ（教師）由来のものに取るため、しばしば "teacher-forcing" と呼ばれる。

2. KLダイバージェンス最小化によるもの

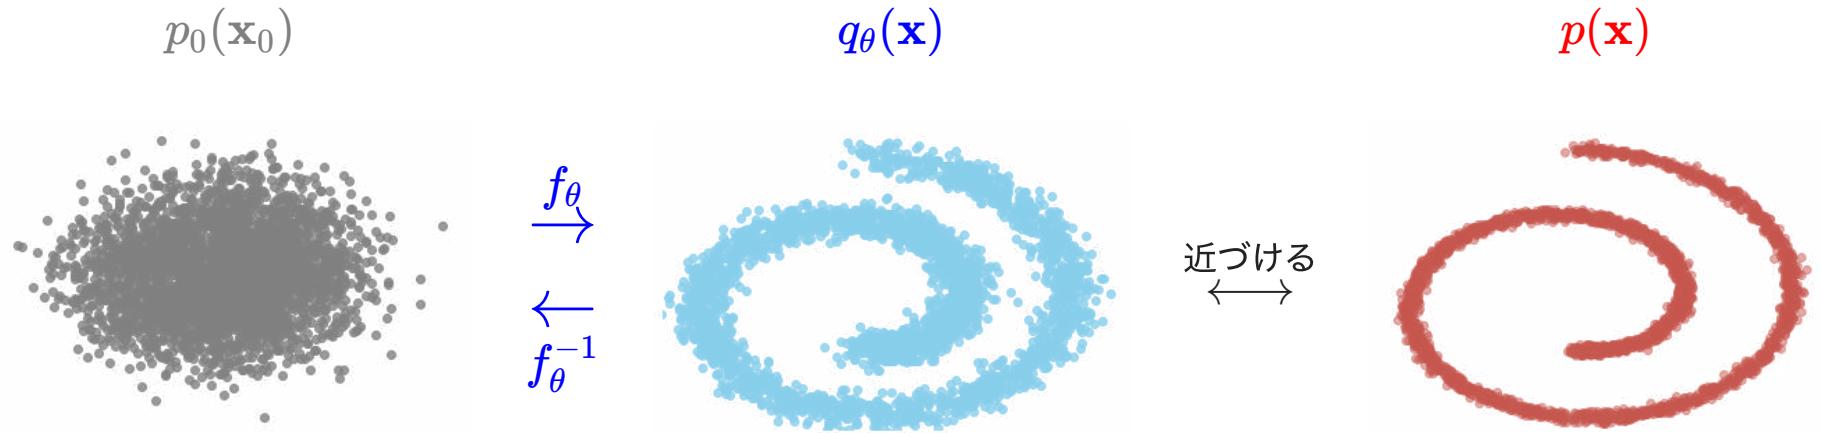
■ 2-5. Normalizing flow

レビュー論文：<https://arxiv.org/abs/1912.02762>



2. KLダイバージェンス最小化によるもの

■ 2-5. Normalizing flow



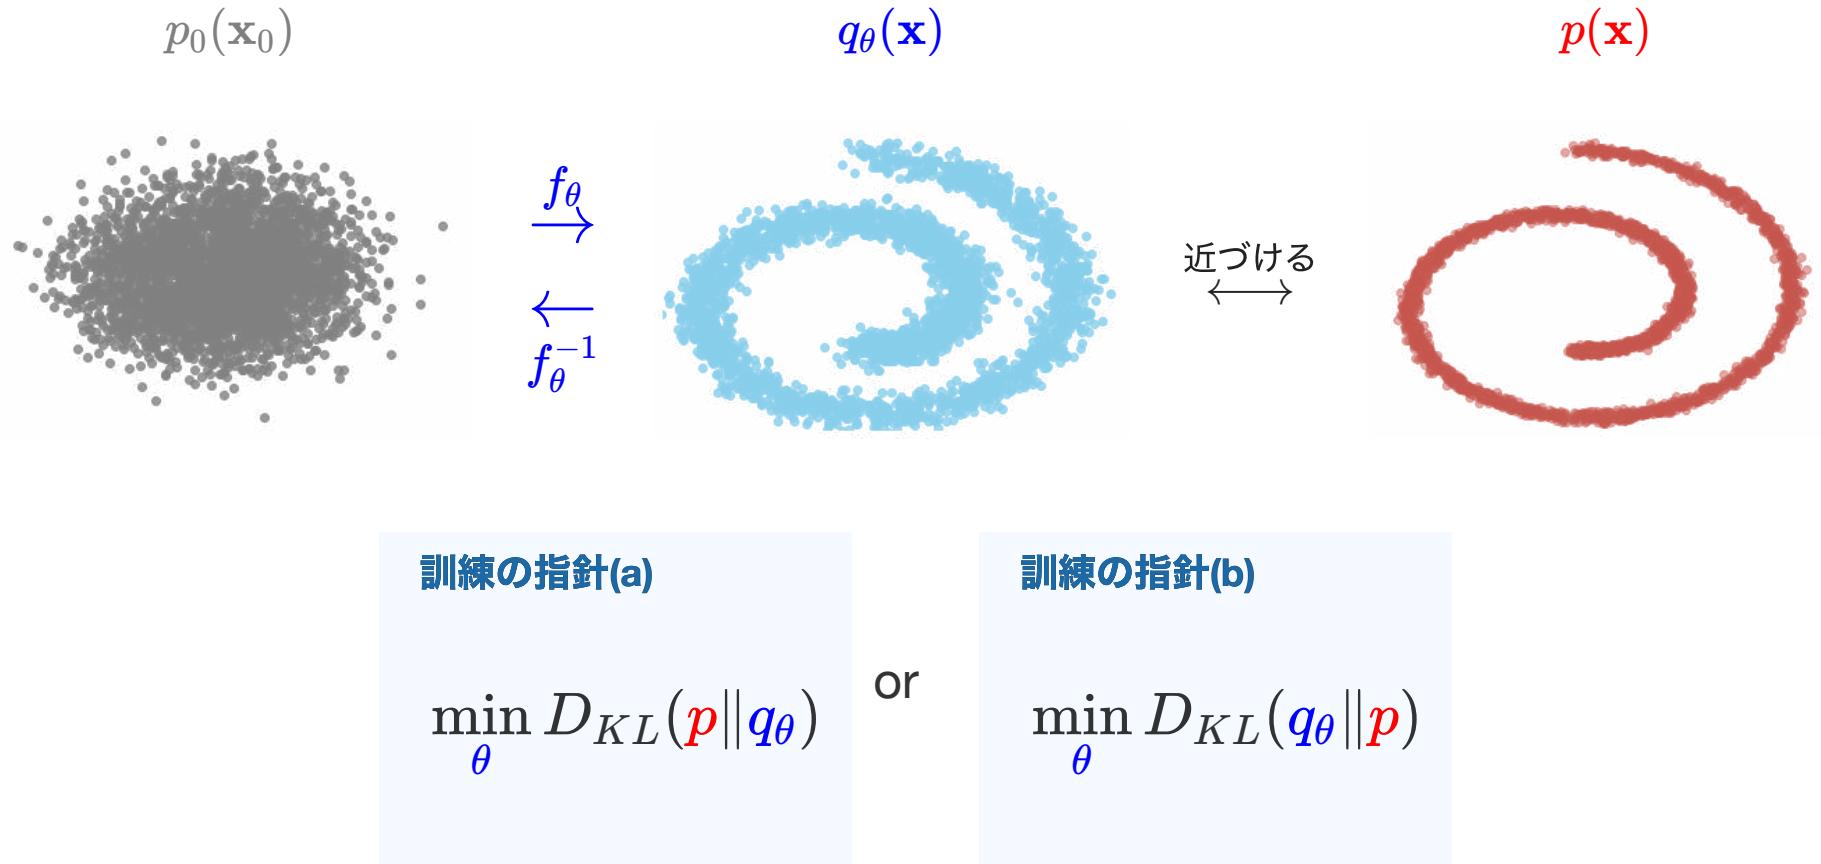
もし、可逆な関数 f_θ があれば、

$$\begin{aligned} q_\theta(\mathbf{x}) &:= \int \delta(\mathbf{x} - f_\theta(\mathbf{x}_0)) p_0(\mathbf{x}_0) d\mathbf{x}_0 \\ &= \underbrace{\det \nabla f_\theta^{-1}(\mathbf{x})}_{\text{Jacobian}} \cdot p_0(f_\theta^{-1}(\mathbf{x})) \end{aligned}$$

Jacobian が計算できれば、密度関数を計算できる！

2. KLダイバージェンス最小化によるもの

■ 2-5. Normalizing flow

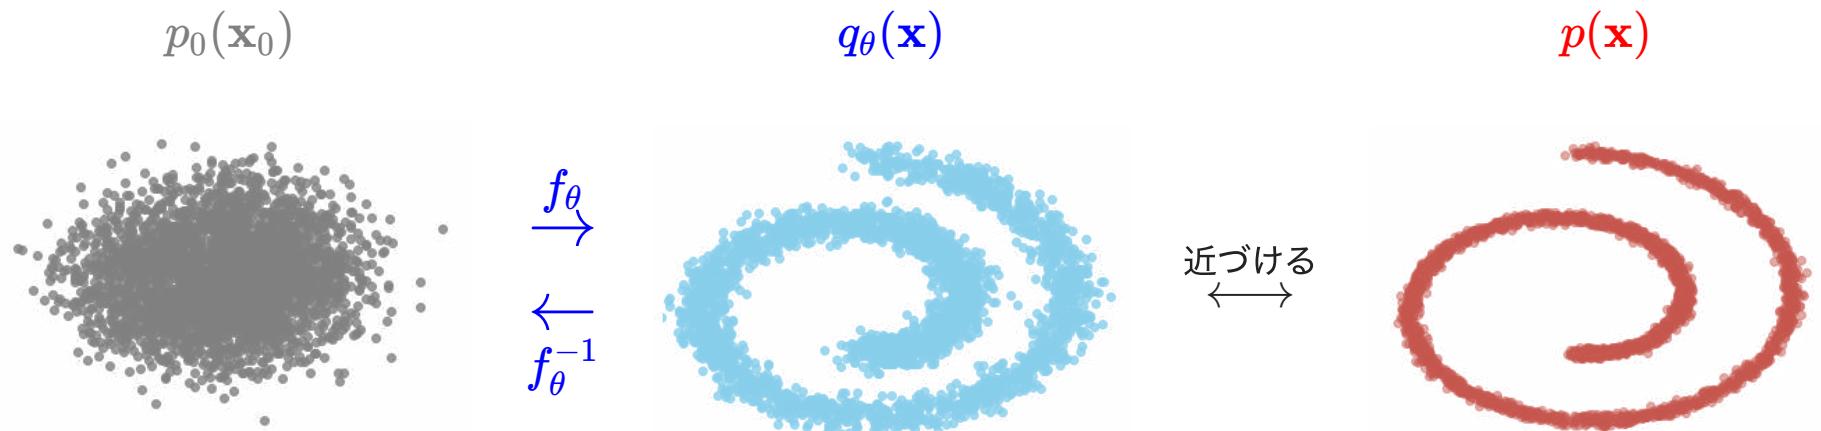


* $D_{KL}(p^{(1)} \parallel p^{(2)}) + S(p^{(1)}) \approx -\frac{1}{N} \sum_{i=1}^N \log p^{(2)}(\mathbf{x}_i^{(1)})$ では、以下が必要

- $p^{(1)}$ からのサンプリング $\mathbf{x}_i^{(1)}$ が容易であること
- $p^{(2)}$ の密度関数が計算できること

2. KLダイバージェンス最小化によるもの

■ 2-5. Normalizing flow



訓練の指針(a)

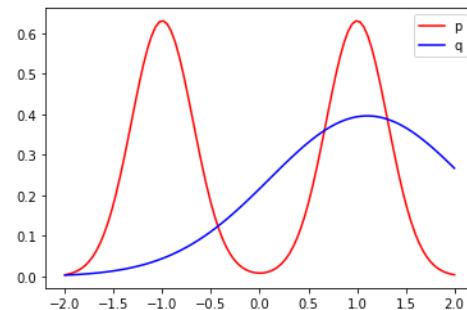
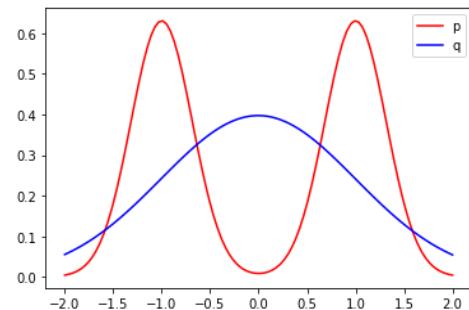
$$\min_{\theta} D_{KL}(p \| q_{\theta})$$

or

訓練の指針(b)

$$\min_{\theta} D_{KL}(q_{\theta} \| p)$$

q_θ : Gaussian
 p : 2つピーク



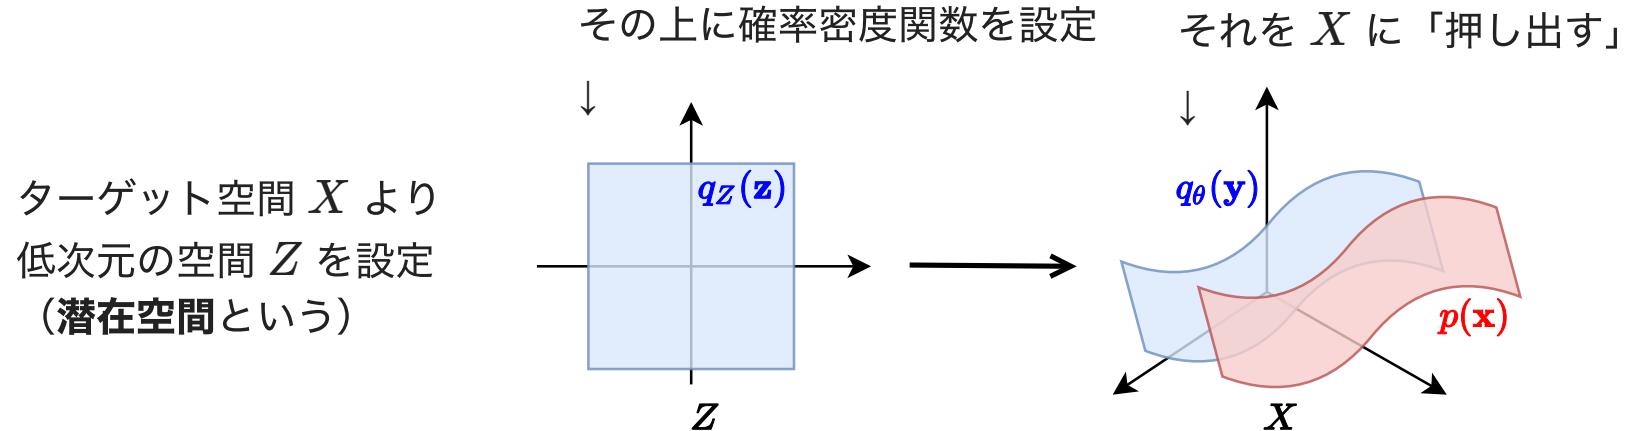
* Normalizing flowではなく
単なる勾配による訓練

3. 潜在変数モデル

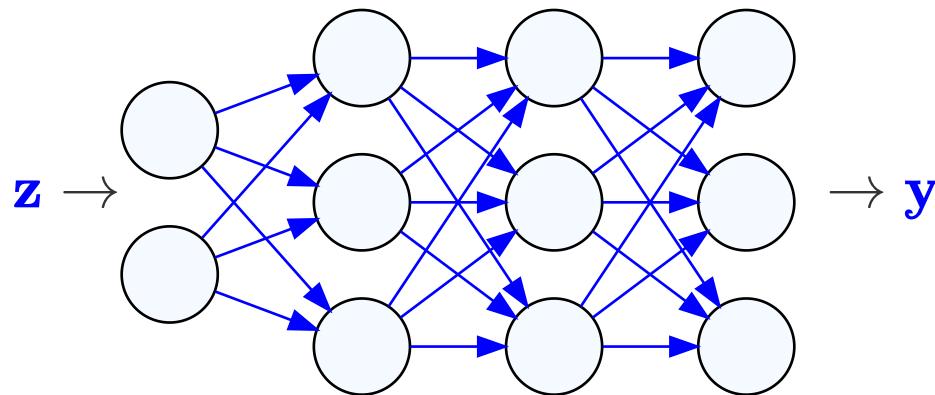
- 变分自己符号化器 (VAE)
- 敵対的生成ネットワーク(GAN)

3. 潜在変数モデル

■ 3-1. 基本的な考え方



→ には色々な物を使って良いが、最近は(深層)ニューラルネットを使うのが多い

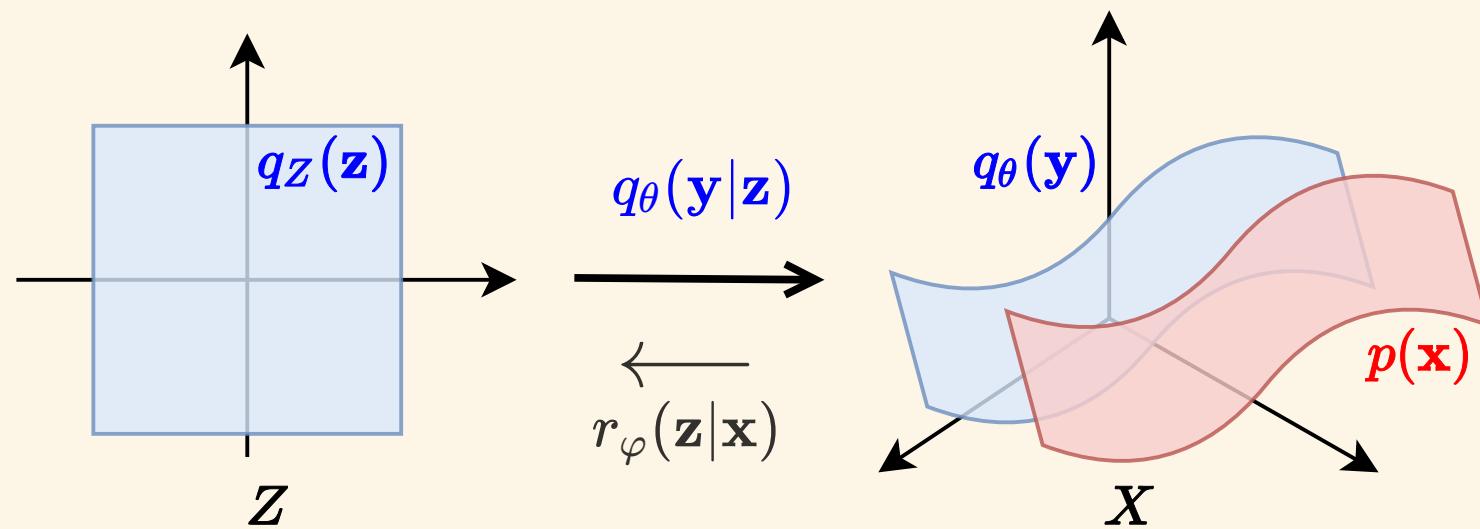


各層での重み行列 + バイアスベクトル = θ

3. 潜在変数モデル

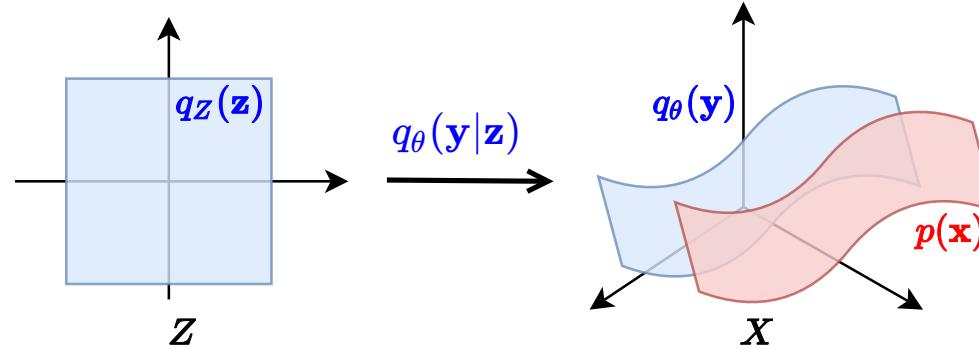
■ 3-2. 变分自己符号化器 (VAE)

レビュー論文：<https://arxiv.org/abs/1906.02691>



3. 潜在変数モデル

■ 3-2. 変分自己符号化器 (VAE)



X 上の 密度 : $q_\theta(\mathbf{y}) = \int_Z q_\theta(\mathbf{y}|\mathbf{z})q_Z(\mathbf{z})d\mathbf{z}$ $\rightarrow \min_{\theta} D_{KL}(p||q_\theta)$ は難

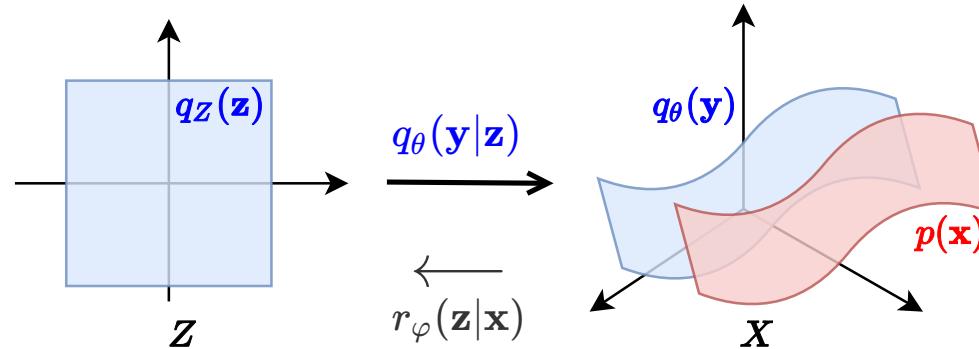
変分によるバウンド (\rightarrow 証明)

任意の逆向きプロセス $r(\mathbf{z}|\mathbf{x})$ について :

$$D_{KL}(p||q_\theta) + \underbrace{S(p)}_{\text{エントロピー}} \leq - \left\langle \log \frac{q_\theta(\mathbf{x}|\mathbf{z})q_Z(\mathbf{z})}{r(\mathbf{z}|\mathbf{x})} \right\rangle_{p(\mathbf{x})r(\mathbf{z}|\mathbf{x})}$$

3. 潜在変数モデル

■ 3-2. 変分自己符号化器 (VAE)



X 上の 密度 : $q_\theta(\mathbf{y}) = \int_Z q_\theta(\mathbf{y}|\mathbf{z})q_Z(\mathbf{z})d\mathbf{z}$ $\rightarrow \min_{\theta} D_{KL}(p||q_\theta)$ は難

VAEの目的

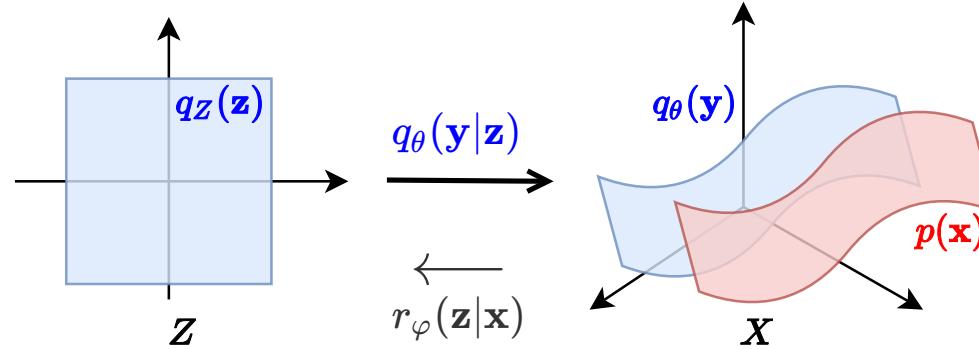
逆向きのモデル $r_\varphi(\mathbf{z}|\mathbf{x})$ を導入して :

$$\min_{\theta, \varphi} \left(- \left\langle \log \frac{q_\theta(\mathbf{x}|\mathbf{z})q_Z(\mathbf{z})}{r_\varphi(\mathbf{z}|\mathbf{x})} \right\rangle_{p(\mathbf{x})r_\varphi(\mathbf{z}|\mathbf{x})} \right)$$

* 実際にはやはり 勾配更新 を行う (次ページ)

3. 潜在変数モデル

■ 3-2. 変分自己符号化器 (VAE)



VAEの勾配更新

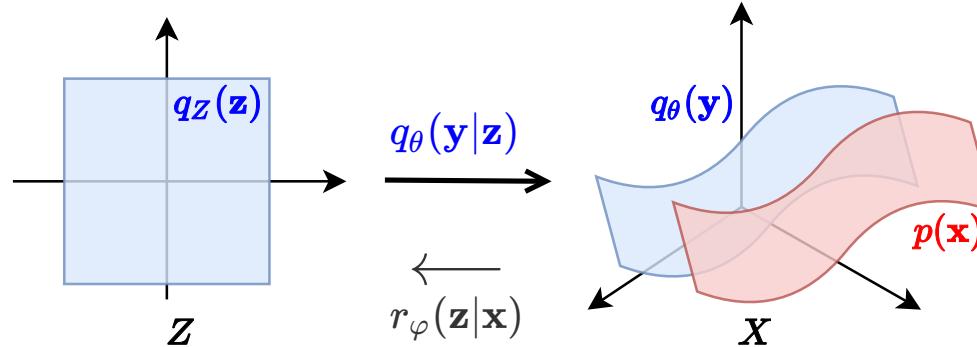
$$\theta_{t+1} = \theta_t + \epsilon_t \nabla_\theta \left\langle \log \frac{q_\theta(\mathbf{x}|\mathbf{z})q_Z(\mathbf{z})}{r_\varphi(\mathbf{z}|\mathbf{x})} \right\rangle_{p(\mathbf{x})r_\varphi(\mathbf{z}|\mathbf{x})}$$

$$\varphi_{t+1} = \varphi_t + \epsilon_t \nabla_\varphi \left\langle \log \frac{q_\theta(\mathbf{x}|\mathbf{z})q_Z(\mathbf{z})}{r_\varphi(\mathbf{z}|\mathbf{x})} \right\rangle_{p(\mathbf{x})r_\varphi(\mathbf{z}|\mathbf{x})}$$

* 実際には 期待値は サンプリングで近似する

3. 潜在変数モデル

■ 3-2. 変分自己符号化器 (VAE)



注意

φ の微分について注意

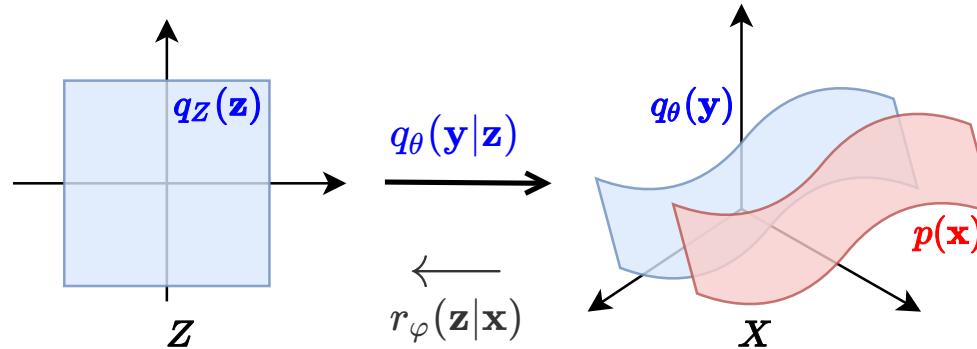
- $\nabla_{\theta} \langle \dots \rangle_{p(\mathbf{x})r_{\varphi}(\mathbf{z}|\mathbf{x})} = \langle \nabla_{\theta} \dots \rangle_{p(\mathbf{x})r_{\varphi}(\mathbf{z}|\mathbf{x})}$ 大数の法則 $\leftarrow \frac{1}{N_{\text{samples}}} \sum_{i=1}^{N_{\text{samples}}} \nabla_{\theta} \dots$
- $\nabla_{\varphi} \langle \dots \rangle_{p(\mathbf{x})r_{\varphi}(\mathbf{z}|\mathbf{x})} \neq \langle \nabla_{\varphi} \dots \rangle_{p(\mathbf{x})r_{\varphi}(\mathbf{z}|\mathbf{x})}$

うまく $\langle \dots \rangle_{p(\mathbf{x})r_{\varphi}(\mathbf{z}|\mathbf{x})} = \langle f(\dots, \varepsilon, \varphi) \rangle_{p(\mathbf{x})s(\varepsilon)}$ となるようなモデルを使う。

これを **reparametrization trick** という。

3. 潜在変数モデル

■ 3-2. 変分自己符号化器 (VAE)



幾つかのコメント :

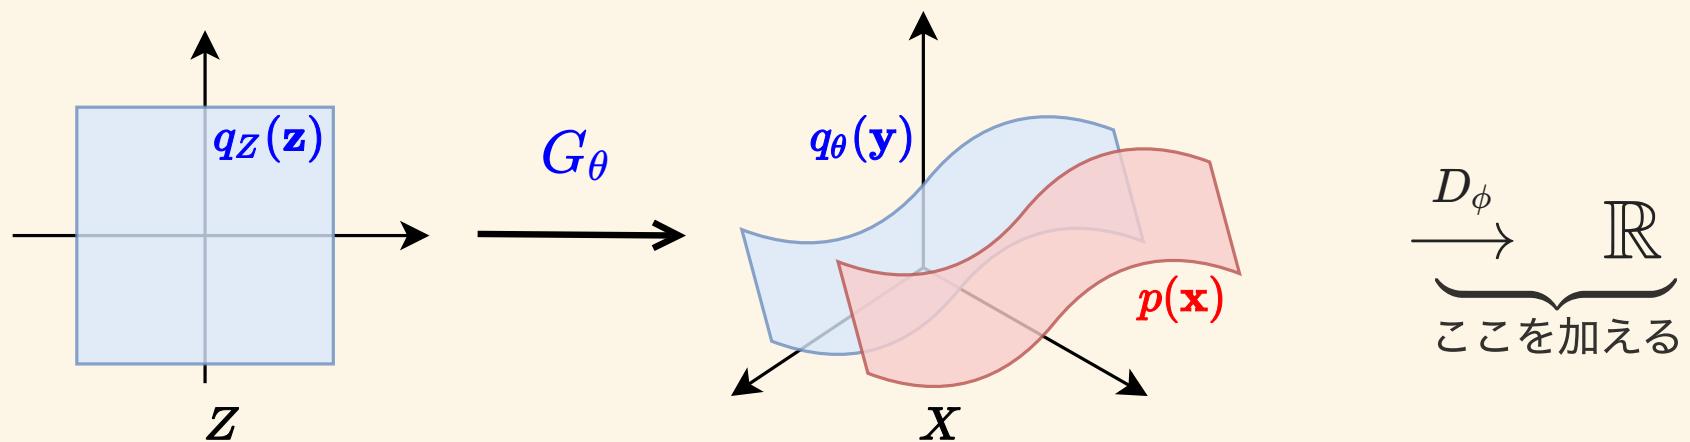
- 理想的なケースでは $q_{\theta^*}(z|x) = r_{\varphi^*}(z|x)$ となる。 (証明の最後の部分で =)
- その場合、 $-\left\langle \log \frac{q_{\theta^*}(x|z)q_z(z)}{r_{\varphi^*}(z|x)} \right\rangle_{r_{\varphi^*}(z|x)} = -\log q_{\theta^*}(x)$

このため「近似的に密度関数 $q(x)$ を計算できるモデル」と言える

3. 潜在変数モデル

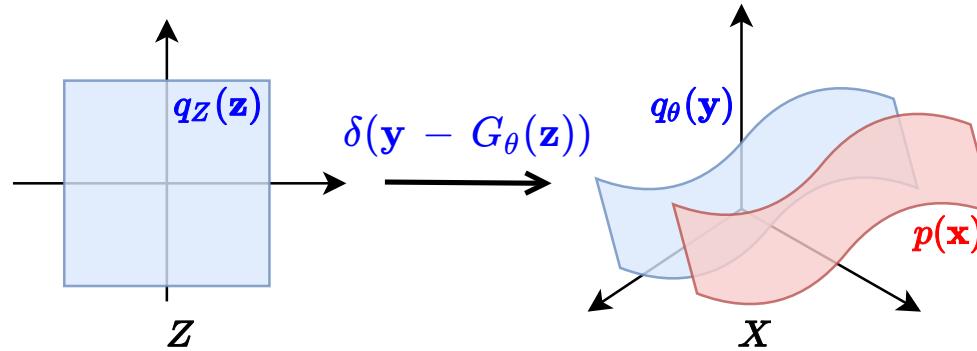
■ 3-3. 敵対的生成ネットワーク (GAN)

(たぶん良い) レビュー論文 : <https://arxiv.org/abs/2001.06937>

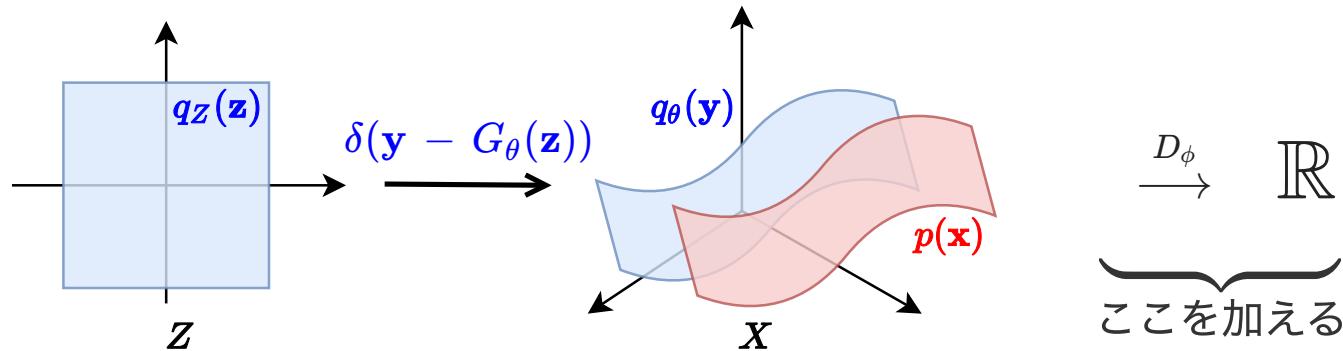


3. 潜在変数モデル

■ 3-3. 敵対的生成ネットワーク (GAN)

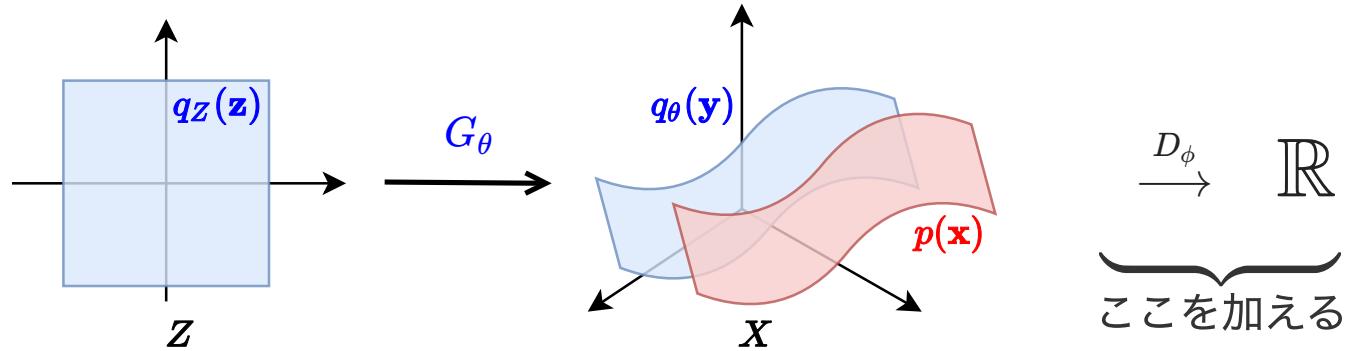


X 上の 密度 : $q_\theta(y) = \int_Z \delta(y - G_\theta(z)) q_z(z) dz \rightarrow \min_{\theta} D_{KL}(p \| q_\theta)$ は難



3. 潜在変数モデル

■ 3-3. 敵対的生成ネットワーク (GAN)



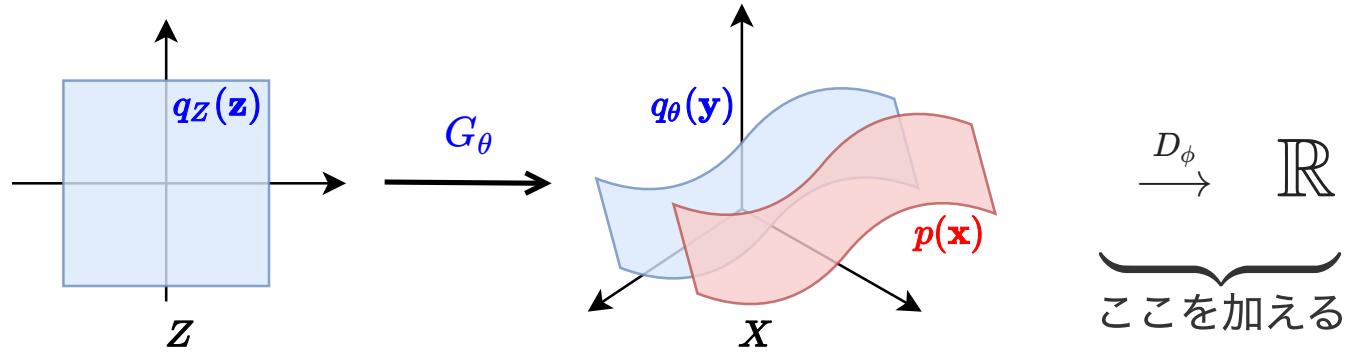
Jensen-Shannon (JS) ダイバージェンス の 汎関数表示 (\rightarrow 証明)

$$\sigma(x) = \frac{1}{1+e^{-x}} \text{ として}$$

$$\begin{aligned} D_{JS}(p, q_\theta) &:= D_{KL}\left(p \middle\| \frac{p + q_\theta}{2}\right) + D_{KL}\left(q \middle\| \frac{p + q_\theta}{2}\right) \\ &= \max_D \left(\left\langle \log \sigma(D(\mathbf{x})) \right\rangle_{p(\mathbf{x})} + \left\langle \log \{1 - \sigma(D(\mathbf{y}))\} \right\rangle_{q_\theta(\mathbf{y})} \right) + 2 \log 2 \end{aligned}$$

3. 潜在変数モデル

■ 3-3. 敵対的生成ネットワーク (GAN)



GANの目的

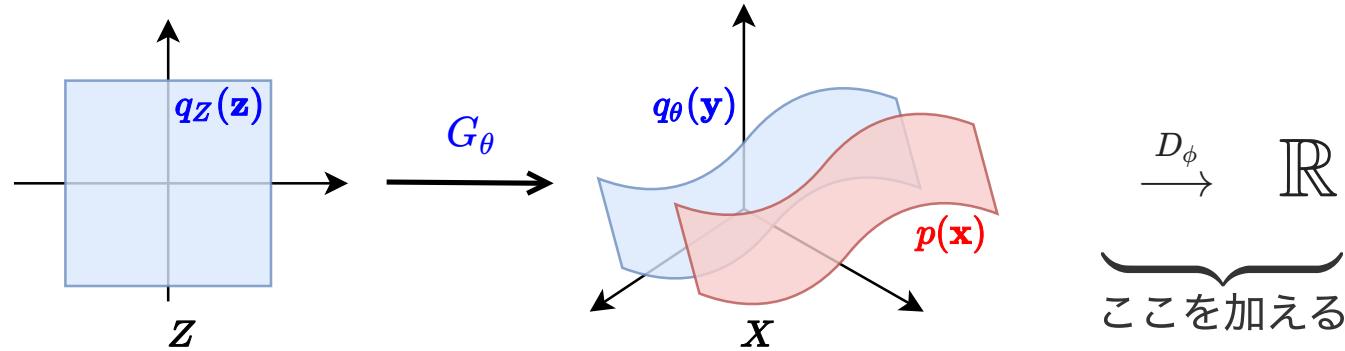
$$\sigma(x) = \frac{1}{1+e^{-x}} \text{ として}$$

$$\min_{\theta} \max_{\phi} \left(\langle \log \sigma(D_\phi(\mathbf{x})) \rangle_{p(\mathbf{x})} + \langle \log \{1 - \sigma(D_\phi(\mathbf{y}))\} \rangle_{q_\theta(\mathbf{y})} \right)$$

* 実際にはやはり 勾配更新を行う (次ページ)

3. 潜在変数モデル

■ 3-3. 敵対的生成ネットワーク (GAN)



GANの勾配更新

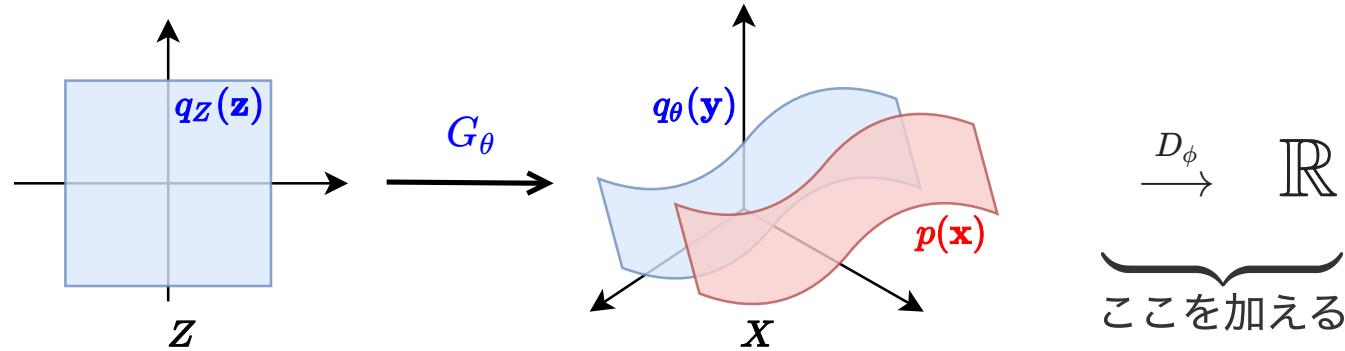
$$\begin{aligned}\theta_{t+1} &= \theta_t + \epsilon_t \nabla_{\theta} \left(\langle \log \sigma(D_{\phi}(\mathbf{x})) \rangle_{p(\mathbf{x})} + \langle \log \{1 - \sigma(D_{\phi}(\mathbf{y}))\} \rangle_{q_{\theta}(\mathbf{y})} \right) \\ \phi_{t+1} &= \phi_t + \eta_t \nabla_{\phi} \left(\langle \log \sigma(D_{\phi}(\mathbf{x})) \rangle_{p(\mathbf{x})} + \langle \log \{1 - \sigma(D_{\phi}(\mathbf{y}))\} \rangle_{q_{\theta}(\mathbf{y})} \right)\end{aligned}$$

* 実際には 期待値は サンプリング で近似する

* $\min_{\theta} \max_{\phi}$ 問題がこれで解けるためには (\dots) が 鞍点型 である必要がある

3. 潜在変数モデル

■ 3-3. 敵対的生成ネットワーク (GAN)



幾つかのコメント

- 理想的なケースでは $e^{D^*(\mathbf{x})} = \frac{p(\mathbf{x})}{q_\theta(\mathbf{x})}$ となる ([証明](#)の中盤)
- つまり $q_\theta(\mathbf{x})$ そのものにはアクセスできないが、ターゲットとの密度比の近似はできると考えられる
- Metropolis-Hastings テストなどを近似するなど：<https://arxiv.org/abs/1811.11357>

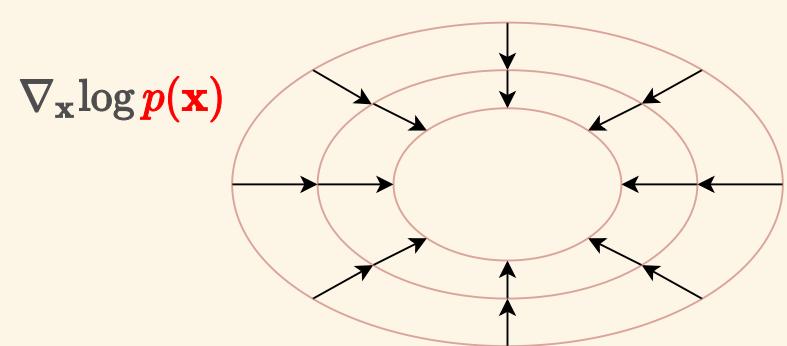
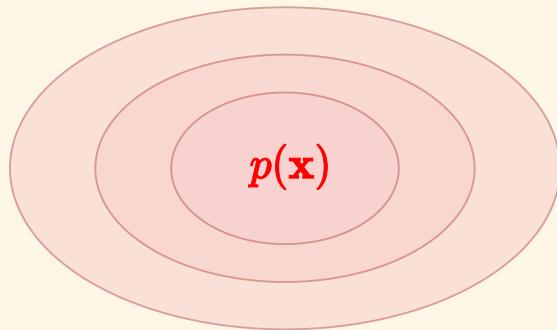
4. 拡散モデル

- スコアマッチング, デノイジング スコアマッチング
- DDPM
- SDE
- フローマッチング

4. 拡散モデル

■ 4-1. スコアマッチング

原論文 : <https://jmlr.org/papers/v6/hyvarinen05a.html>



4. 拡散モデル

■ 4-1. スコアマッチング



スコアがわかれば、適当な \mathbf{x}_0 から Langevin MC

$$\mathbf{x}_t = \mathbf{x}_{t-1} + \epsilon \underbrace{\nabla_{\mathbf{x}} \log p(\mathbf{x}_{t-1})}_{s_{\theta}(\mathbf{x}_{t-1}) \text{ でモデル化}} + \sqrt{2\epsilon} \mathbf{z}_t, \quad \mathbf{z}_t \sim \mathcal{N}(0, I)$$

\Rightarrow (十分小さな ϵ で) $\mathbf{x}_{\infty} \sim p(\mathbf{x})$ ([→証明](#))

* 本来スコアは パラメトリックな確率密度関数 $p_{\theta}(\mathbf{x})$ の パラメータ微分値 $\nabla_{\theta} \log p_{\theta}(\mathbf{x})$ のことを指す？

4. 拡散モデル

■ 4-1. スコアマッチング



スコアマッチングの目的 (\rightarrow 証明)

$$\min_{\theta} \underbrace{\left\langle \left(s_{\theta}(\mathbf{x}) - \nabla_{\mathbf{x}} \log p(\mathbf{x}) \right)^2 \right\rangle}_{\left\langle s_{\theta}(\mathbf{x})^2 + 2\nabla_{\mathbf{x}} \cdot s_{\theta}(\mathbf{x}) \right\rangle} p(\mathbf{x}) + \text{const}$$

… の変形のおかげで、期待値をサンプル平均に置き換えられる

4. 拡散モデル

■ 4-1. スコアマッチング



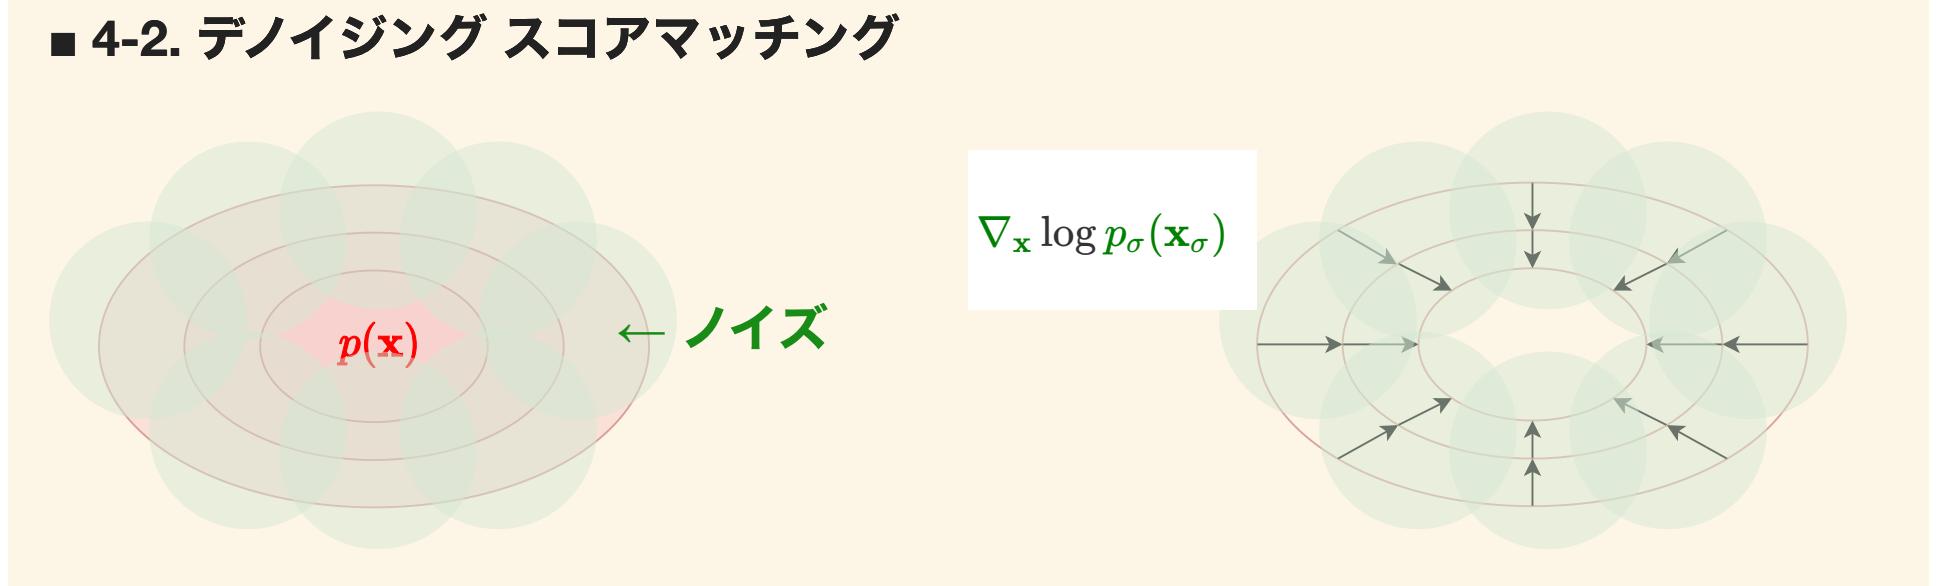
実際にやること

$$\min_{\theta} \frac{1}{N_{\text{data}}} \sum_{i=1}^{N_{\text{data}}} \left(s_{\theta}(\mathbf{x}_i)^2 + 2 \nabla_{\mathbf{x}} \cdot s_{\theta}(\mathbf{x}_i) \right)$$

ただし、データサンプルがない点での精度の保証ができるない（上図を参照）
→ Langevin サンプリングの初期値によっては問題

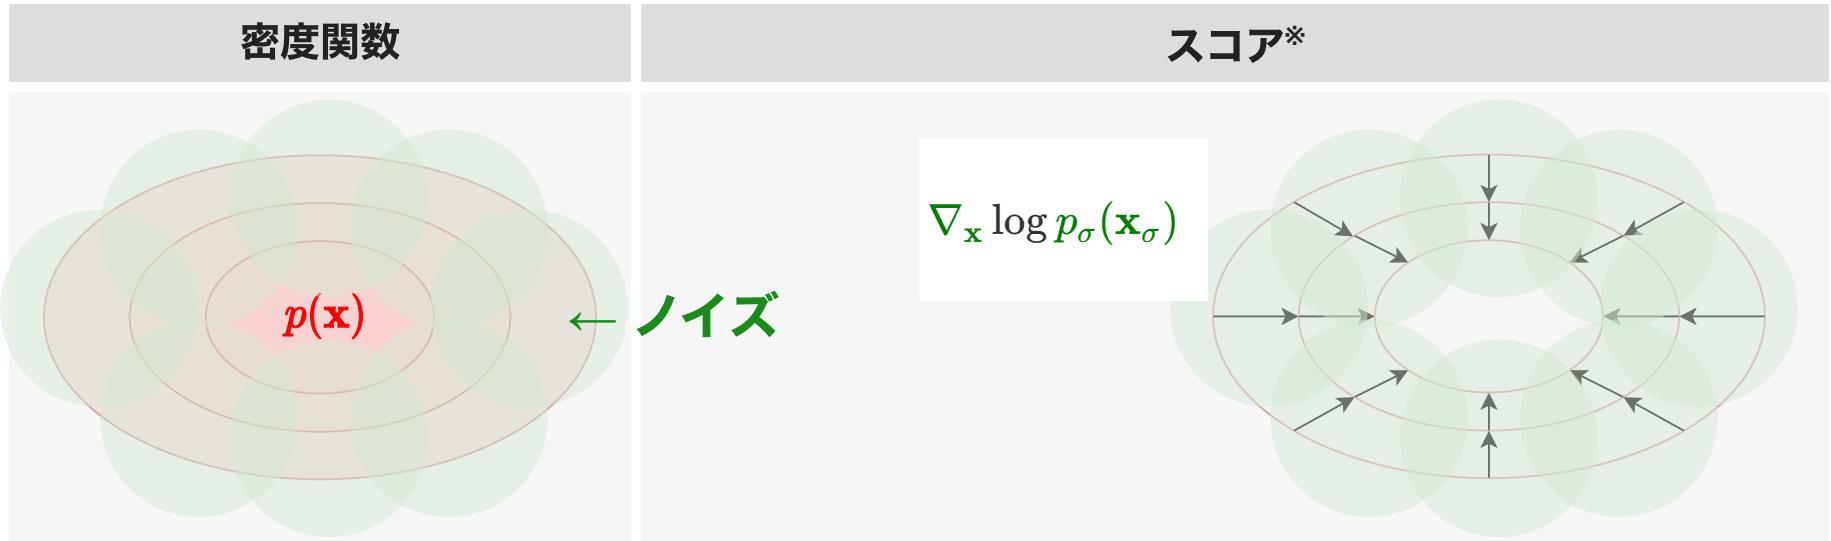
4. 拡散モデル

■ 4-2. デノイジング スコアマッチング



4. 拡散モデル

■ 4-2. デノイジング スコアマッチング



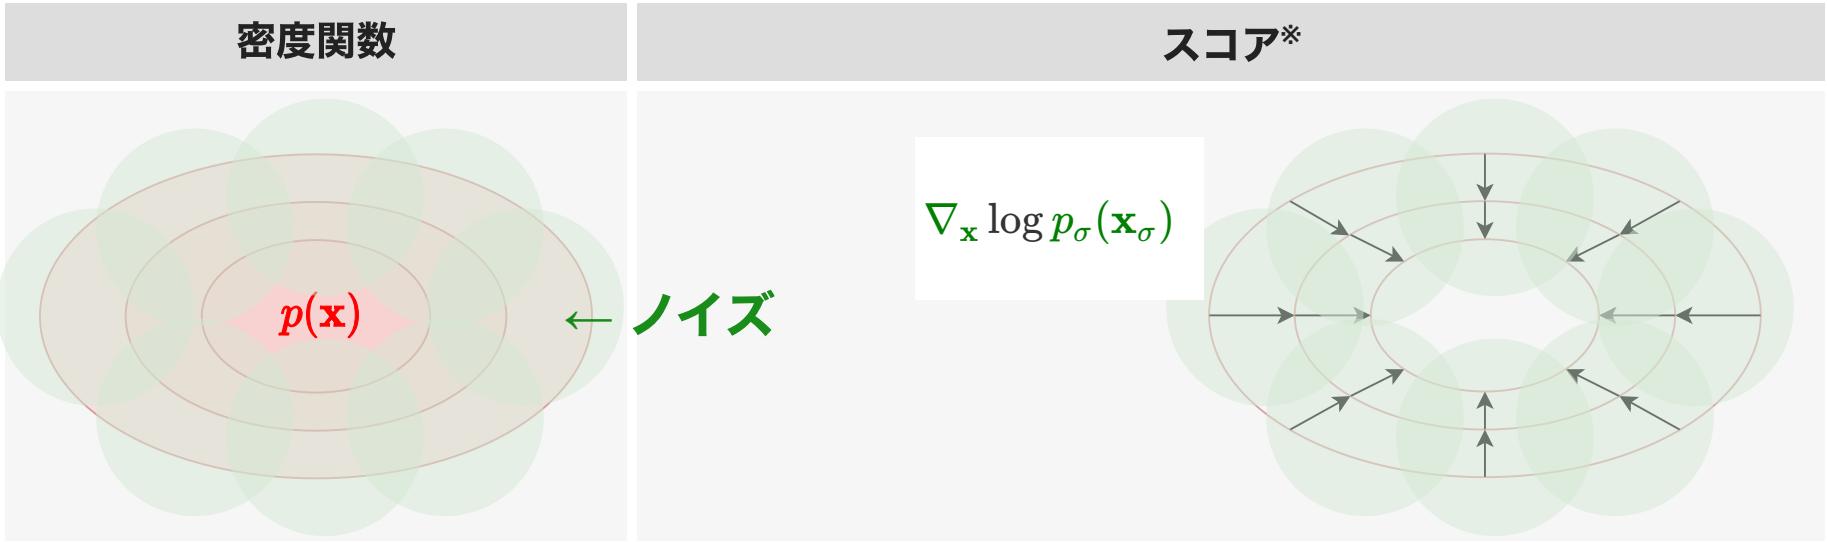
ターゲットに ノイズ を振る：

$$p_{\sigma}(\mathbf{x}_{\sigma}) := \int \underbrace{p_{\sigma}(\mathbf{x}_{\sigma} | \mathbf{x}) p(\mathbf{x}) d\mathbf{x}}_{\text{ノイズ}}$$

分布が広がるので、より広い領域のベクトル場を推定できる
→ $p_{\sigma}(\mathbf{x}_{\sigma})$ のスコア推定をする

4. 拡散モデル

■ 4-2. デノイジング スコアマッチング



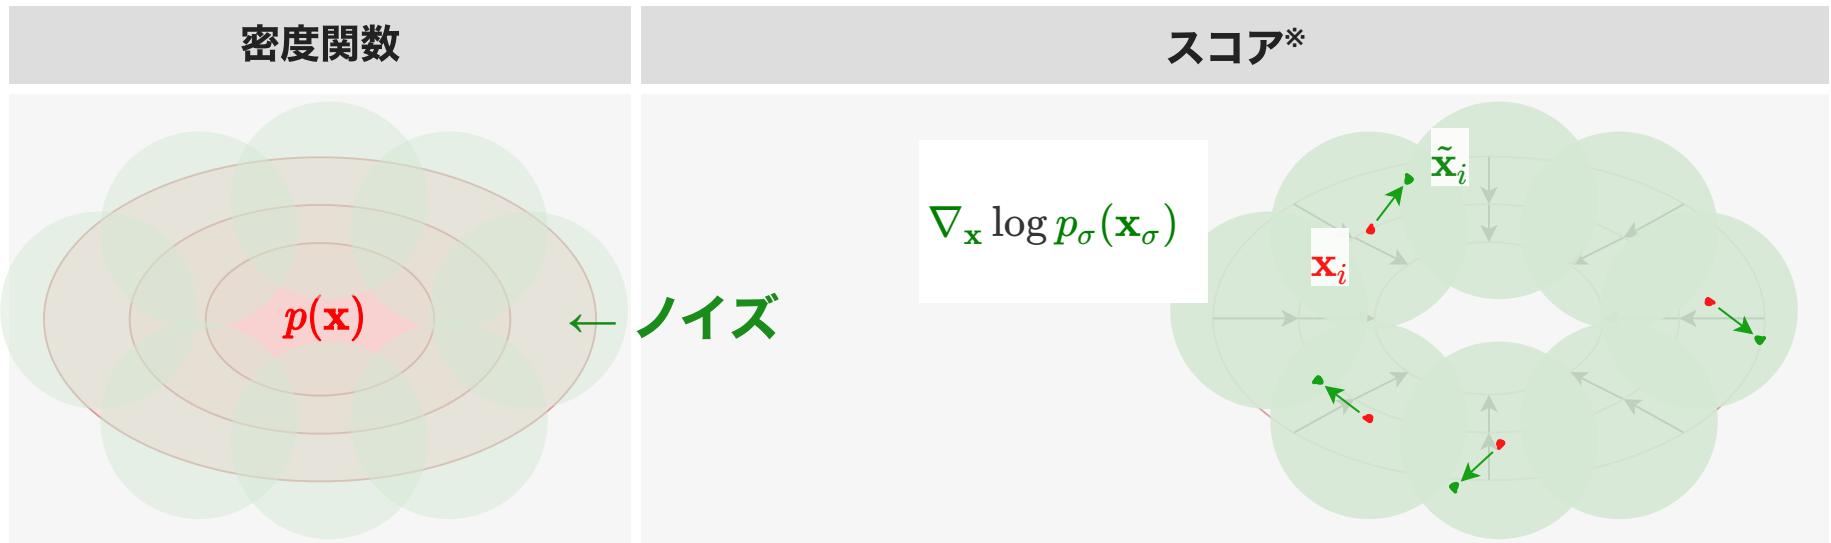
デノイジング スコアマッチングの目的 (→証明) (原論文：https://doi.org/10.1162/NECO_a_00142)

$p_{\sigma}(\mathbf{x}_{\sigma}) := \int p_{\sigma}(\mathbf{x}_{\sigma} | \mathbf{x}) p(\mathbf{x}) d\mathbf{x}$ として、

$$\min_{\theta} \underbrace{\left\langle \left(s_{\theta}(\mathbf{x}_{\sigma}) - \nabla_{\mathbf{x}} \log p_{\sigma}(\mathbf{x}_{\sigma}) \right)^2 \right\rangle}_{p_{\sigma}(\mathbf{x}_{\sigma})} + \text{const}$$
$$\left\langle \left(s_{\theta}(\tilde{\mathbf{x}}) - \nabla_{\mathbf{x}} \log p_{\sigma}(\mathbf{x}_{\sigma} | \mathbf{x}) \right)^2 \right\rangle_{p_{\sigma}(\mathbf{x}_{\sigma} | \mathbf{x}) p(\mathbf{x})}$$

4. 拡散モデル

■ 4-2. デノイジング スコアマッチング



実際にやること

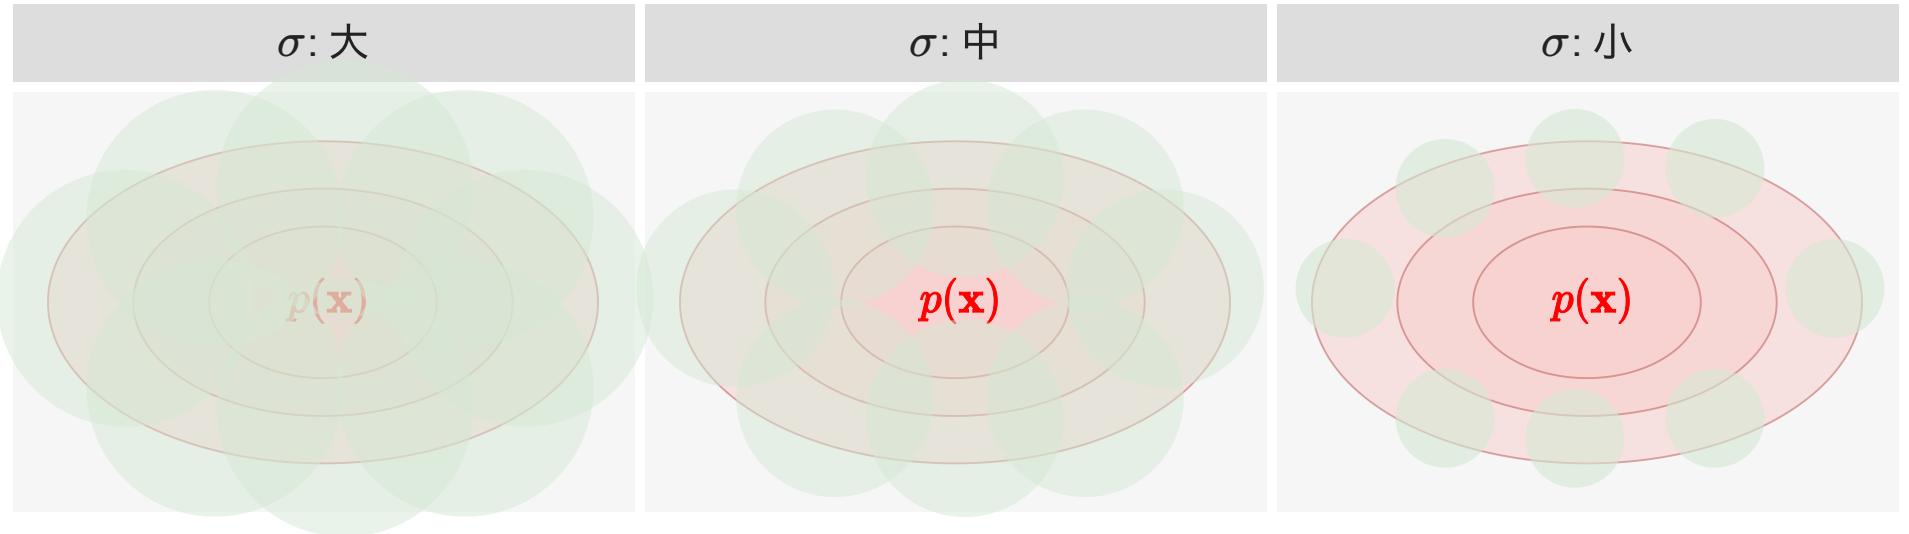
$$\min_{\theta} \frac{1}{N_{\text{data}}} \sum_{i=1}^{N_{\text{data}}} (s_{\theta}(\tilde{\mathbf{x}}_i) - \nabla_{\tilde{\mathbf{x}}} \log p_{\sigma}(\tilde{\mathbf{x}}_i | \mathbf{x}_i))^2$$

- ノイズの大きさ σ 大 \Leftrightarrow 広い範囲で s_{θ} 訓練可能だが、 p から遠ざかる
- ノイズの大きさ σ 小 \Leftrightarrow p に近づくが、狭い範囲でのみ s_{θ} 訓練可能

4. 拡散モデル

■ 4-2. デノイジング スコアマッチング

ノイズをアニーリング+モデルに σ 依存性をつける



改良版 (原論文：<https://arxiv.org/abs/1907.05600>)

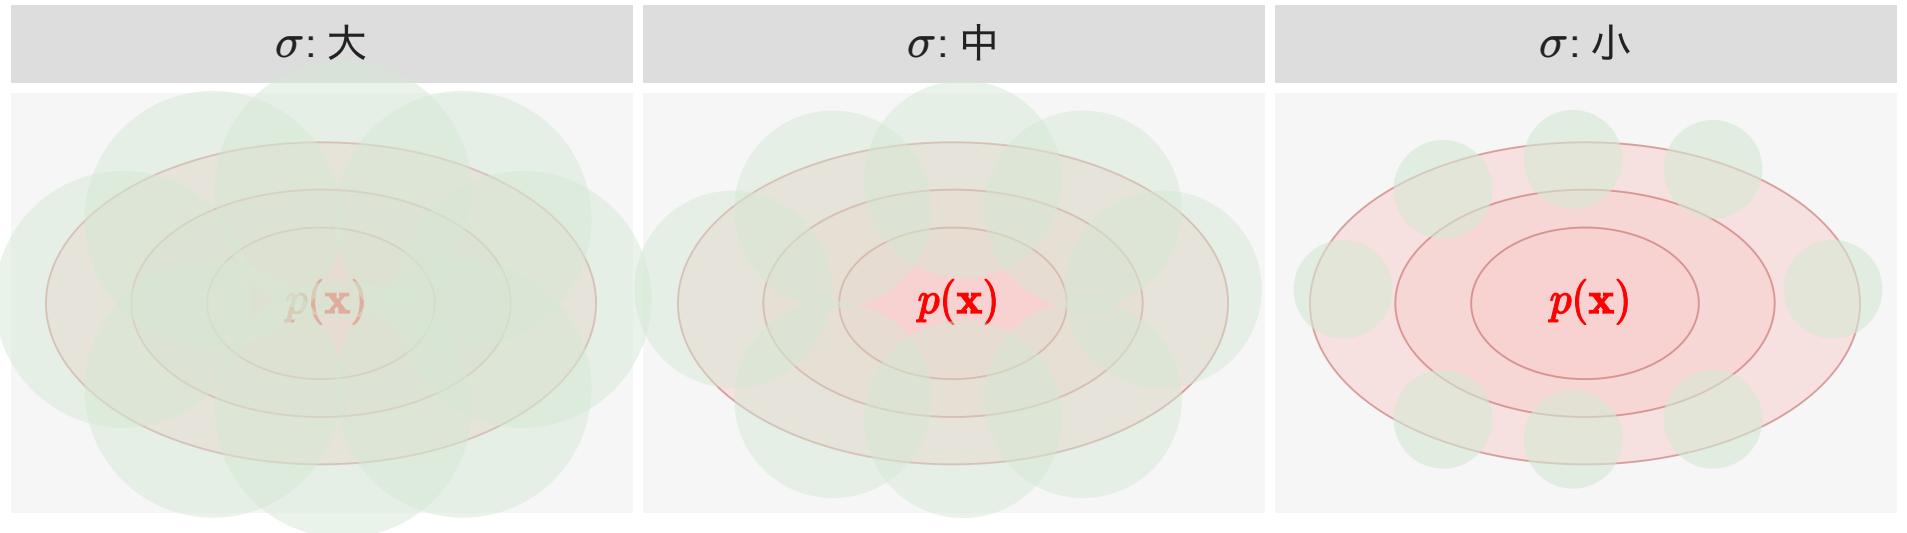
$$p_\sigma(\mathbf{x}_\sigma) := \int p_\sigma(\mathbf{x}_\sigma | \mathbf{x}) p(\mathbf{x}) d\mathbf{x} \text{ として、}$$

$$\min_{\theta} \int d\sigma \underbrace{\lambda(\sigma)}_{\text{重み}} \left\langle \left(\underbrace{s_\theta(\mathbf{x}_\sigma, \sigma)}_{\sigma \text{ 依存性を持たせる}} - \nabla_{\mathbf{x}} \log p_\sigma(\mathbf{x}_\sigma | \mathbf{x}) \right)^2 \right\rangle_{p_\sigma(\mathbf{x}_\sigma | \mathbf{x}) p(\mathbf{x})}$$

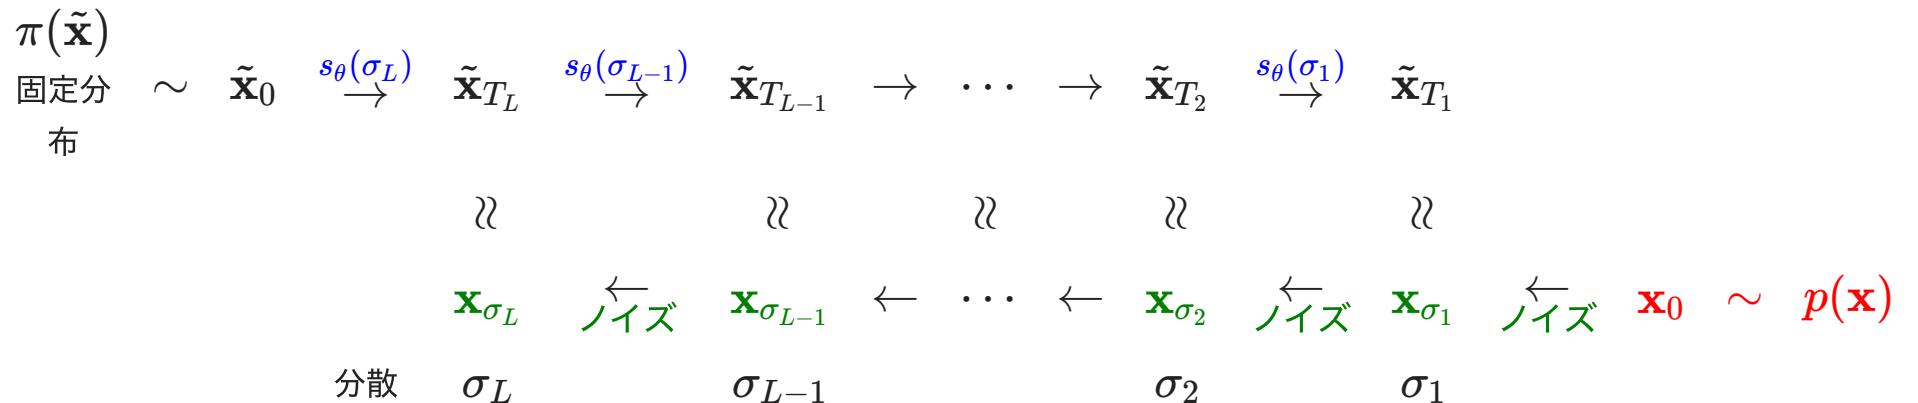
4. 拡散モデル

■ 4-2. デノイジング スコアマッチング

ノイズをアニーリング+モデルに σ 依存性をつける



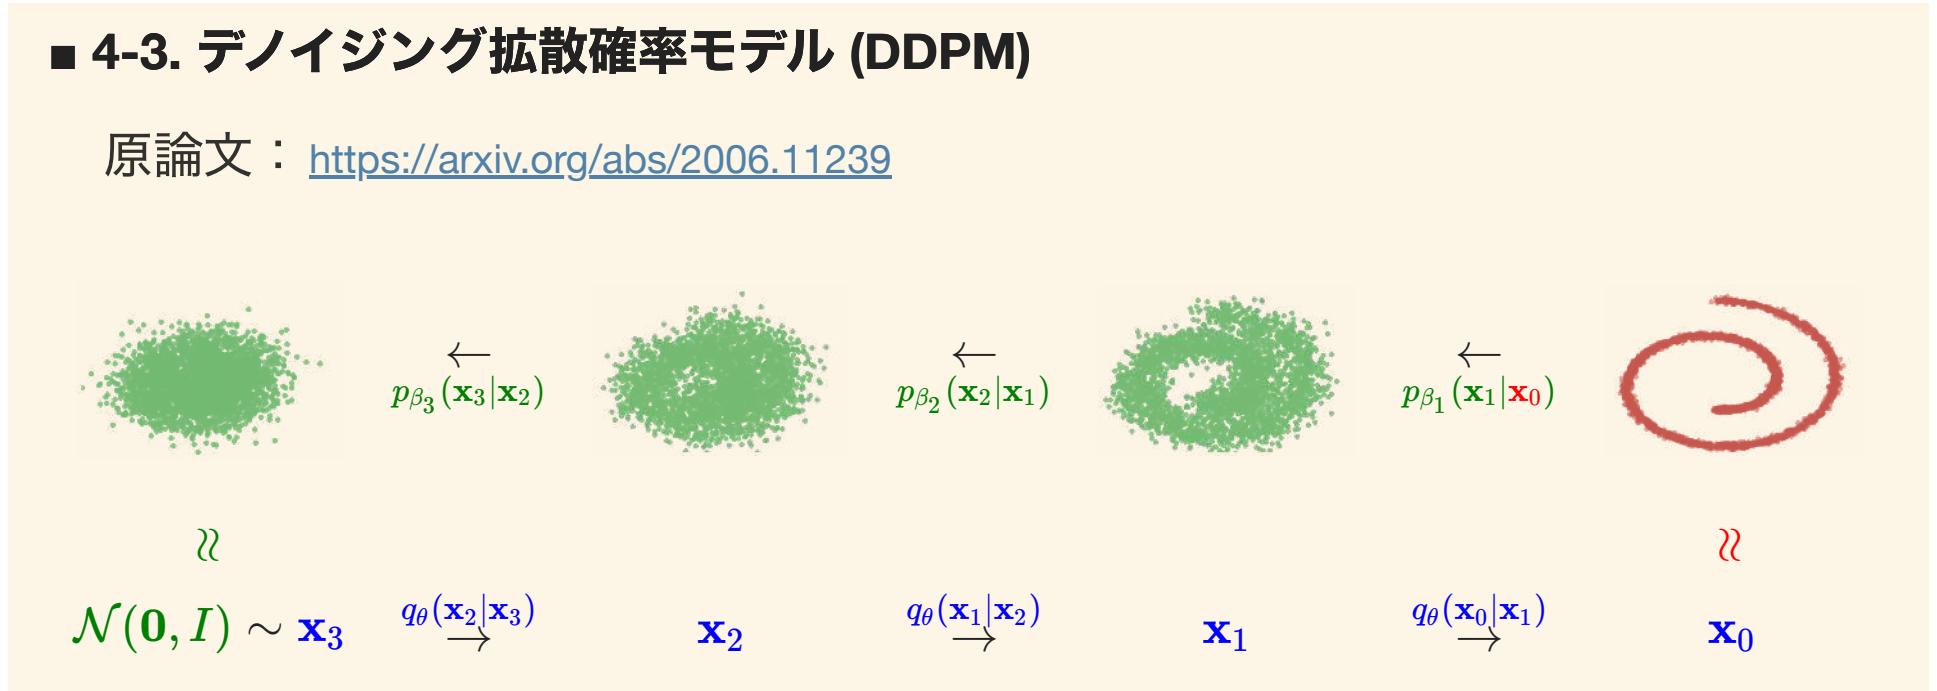
訓練後のデータサンプリング $\xrightarrow{s_\theta(\sigma)}$ は Langevin MC を表す。



4. 拡散モデル

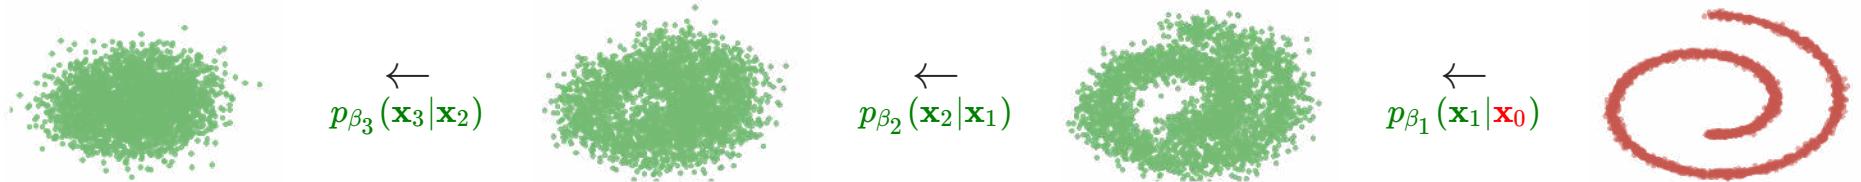
■ 4-3. デノイジング拡散確率モデル (DDPM)

原論文 : <https://arxiv.org/abs/2006.11239>



4. 拡散モデル

■ 4-3. デノイジング拡散確率モデル (DDPM)



別のノイズのかけ方：

$$p_{\beta_t}(\mathbf{x}_t|\mathbf{x}_{t-1}) = \mathcal{N}(\mathbf{x}_t; \sqrt{\alpha_t}\mathbf{x}_{t-1}, \beta_t I), \quad \alpha_t = 1 - \beta_t, \quad \beta_t \in (0, 1)$$

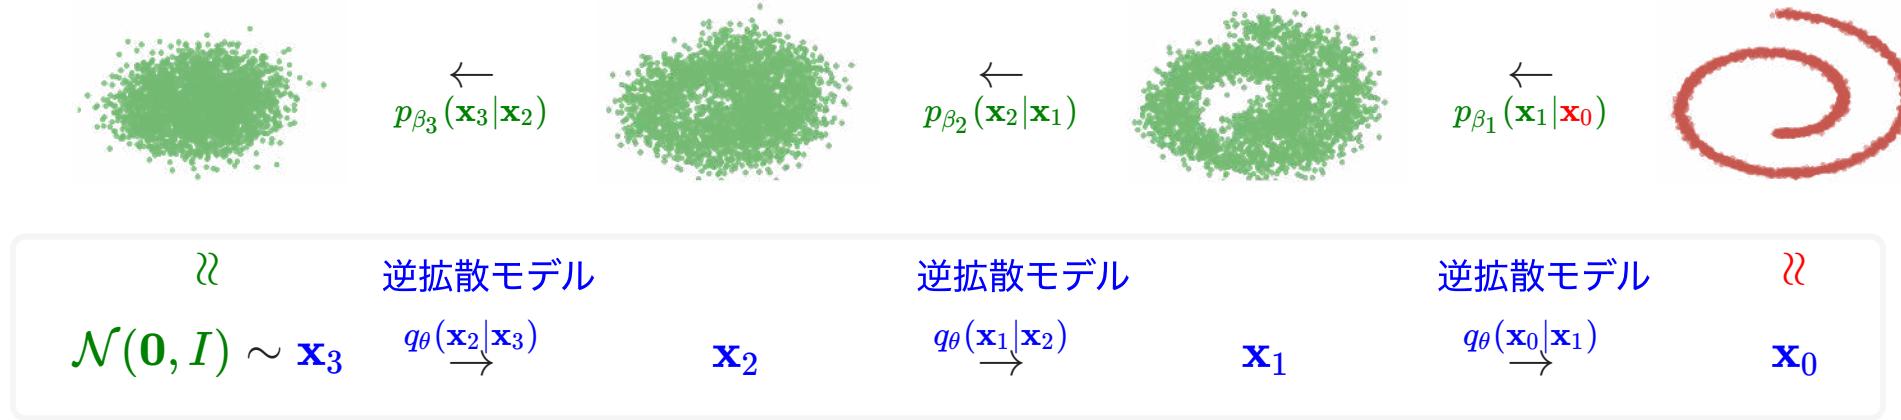
時刻 t での分布 ([→証明](#))

$$p(\mathbf{x}_t|\mathbf{x}_0) = \mathcal{N} \left(\mathbf{x}_t; \sqrt{\prod_{\tau=1}^t \alpha_\tau} \mathbf{x}_0, \left(1 - \prod_{\tau=1}^t \alpha_\tau \right) I \right)$$

特に $\mathbf{x}_\infty \sim \mathcal{N}(\mathbf{0}, I)$ となる。

4. 拡散モデル

■ 4-3. デノイジング拡散確率モデル (DDPM)



$$q_{\theta}(\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_L) := \mathcal{N}(\mathbf{x}_L; \mathbf{0}, I) q_{\theta}(\mathbf{x}_{L-1}|\mathbf{x}_L) \cdots q_{\theta}(\mathbf{x}_0|\mathbf{x}_1) \xrightarrow{\int d\mathbf{x}_1 \dots d\mathbf{x}_L} q_{\theta}(\mathbf{x}_0)$$

バウンド (\rightarrow 証明)

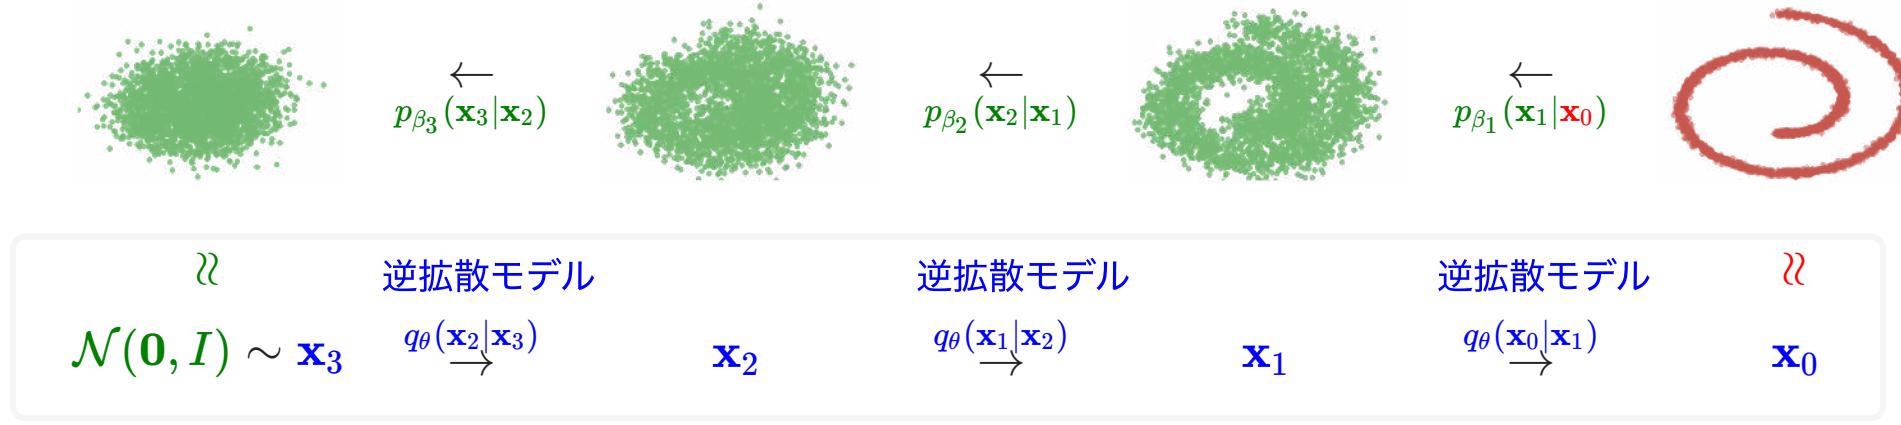
$\Rightarrow \min_{\theta} D_{KL}(p \| q_{\theta})$ は難

$p(\mathbf{x}_1, \dots, \mathbf{x}_L|\mathbf{x}_0) := p_{\beta_L}(\mathbf{x}_L|\mathbf{x}_{L-1}) \cdots p_{\beta_1}(\mathbf{x}_1|\mathbf{x}_0)$ について：

$$D_{KL}(p \| q_{\theta}) + \underbrace{S(p)}_{\text{エントロピー}} \leq - \left\langle \log \frac{q_{\theta}(\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_L)}{p(\mathbf{x}_1, \dots, \mathbf{x}_L|\mathbf{x}_0)} \right\rangle_{p(\mathbf{x}_1, \dots, \mathbf{x}_L|\mathbf{x}_0)p(\mathbf{x}_0)}$$

4. 拡散モデル

■ 4-3. デノイジング拡散確率モデル (DDPM)



バウンドをさらに分解できる: (この辺り煩雑なので、論文を見るか、解説記事をみてください... 🧐)

$$\begin{aligned}
 & - \left\langle \log \frac{q_\theta(\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_L)}{p(\mathbf{x}_1, \dots, \mathbf{x}_L | \mathbf{x}_0)} \right\rangle_{p(\mathbf{x}_1, \dots, \mathbf{x}_L | \mathbf{x}_0) p(\mathbf{x}_0)} \\
 & = \text{定数} + \sum_{t=2}^L \left\langle D_{KL}(p(\mathbf{x}_{t-1} | \mathbf{x}_t, \mathbf{x}_0) \| q_\theta(\mathbf{x}_{t-1} | \mathbf{x}_t)) \right\rangle_{p(\mathbf{x}_t | \mathbf{x}_0) p(\mathbf{x}_0)} - \left\langle \log q_\theta(\mathbf{x}_0 | \mathbf{x}_1) \right\rangle_{p(\mathbf{x}_1 | \mathbf{x}_0) p(\mathbf{x}_0)} \\
 & \quad \downarrow q_\theta(\mathbf{x}_{t-1} | \mathbf{x}_t) = \mathcal{N}\left(\mathbf{x}_{t-1}; \frac{1}{\sqrt{\alpha_t}} (\mathbf{x}_t - \frac{\beta_t}{\sqrt{1-\bar{\alpha}_t}} \epsilon_\theta(\mathbf{x}_t, t)), \sigma_t^2 I\right) \text{ にとる} \\
 & = \text{定数} + \sum_{t=2}^L \frac{\beta_t^2}{2\sigma_t^2(1 - \prod_{\tau=1}^t \alpha_\tau)} \left\langle (\epsilon - \epsilon_\theta(\mathbf{x}_t | \mathbf{x}_0, \epsilon, t))^2 \right\rangle_{p(\mathbf{x}_0) \mathcal{N}(\epsilon; 0, I)} - \left\langle \log q_\theta(\mathbf{x}_0 | \mathbf{x}_1) \right\rangle_{p(\mathbf{x}_1 | \mathbf{x}_0) p(\mathbf{x}_0)}
 \end{aligned}$$

4. 拡散モデル

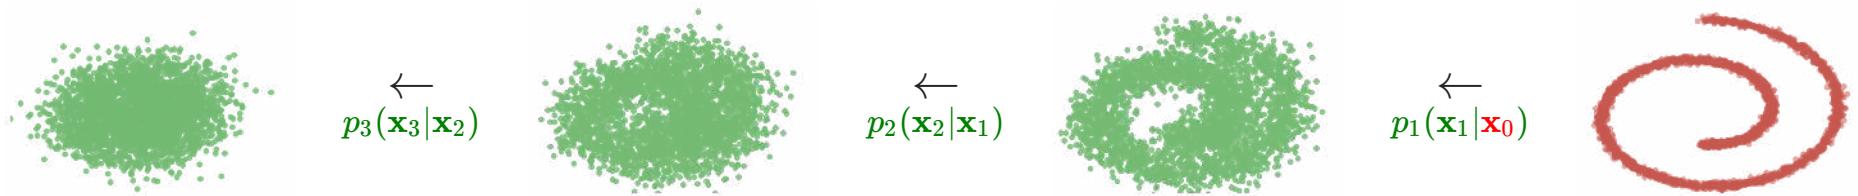
■ 4-4. 確率微分方程式による解釈

原論文 : <https://arxiv.org/abs/2011.13456>

$$\begin{aligned} d\mathbf{x}(t) &= \mathbf{f}(\mathbf{x}(t), t)dt + g(t)d\mathbf{w}(t) \\ &\Downarrow \\ \frac{\partial p_t(\mathbf{x})}{\partial t} &= -\nabla_{\mathbf{x}} \cdot (\mathbf{f}(\mathbf{x}, t)p_t(\mathbf{x})) + \frac{g(t)^2}{2}\nabla_{\mathbf{x}}^2 p_t(\mathbf{x}) \end{aligned}$$

4. 拡散モデル

■ 4-4. 確率微分方程式による解釈



ノイズをより一般化

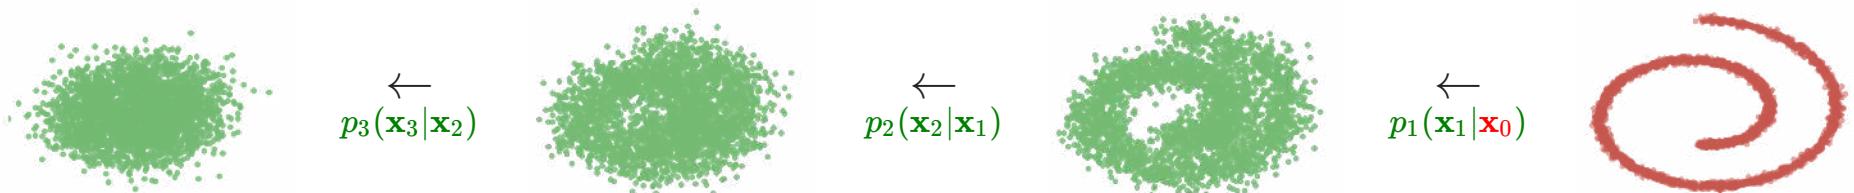
$$p_t(\mathbf{x}_t|\mathbf{x}_{t-1}) = \mathcal{N}(\mathbf{x}_t|\mathbf{x}_{t-1} + \mathbf{f}(\mathbf{x}_{t-1}, t)\Delta t, g(t)^2\Delta t I)$$
$$\Updownarrow$$
$$\mathbf{x}_t = \mathbf{x}_{t-1} + \mathbf{f}(\mathbf{x}_{t-1}, t)\Delta t + g(t)\sqrt{\Delta t}\mathbf{w}_t, \quad \mathbf{w}_t \sim \mathcal{N}(\mathbf{0}, I)$$

$\Delta t \rightarrow +0$ を取ると 確率微分方程式になる。

$$d\mathbf{x}(t) = \mathbf{f}(\mathbf{x}(t), t)dt + g(t)d\mathbf{w}(t)$$

4. 拡散モデル

■ 4-4. 確率微分方程式による解釈



$$d\mathbf{x}(t) = \mathbf{f}(\mathbf{x}(t), t)dt + g(t)d\mathbf{w}(t)$$

これまでの例：

- デノイジング スコアマッチング (Variance Exploding, VE)

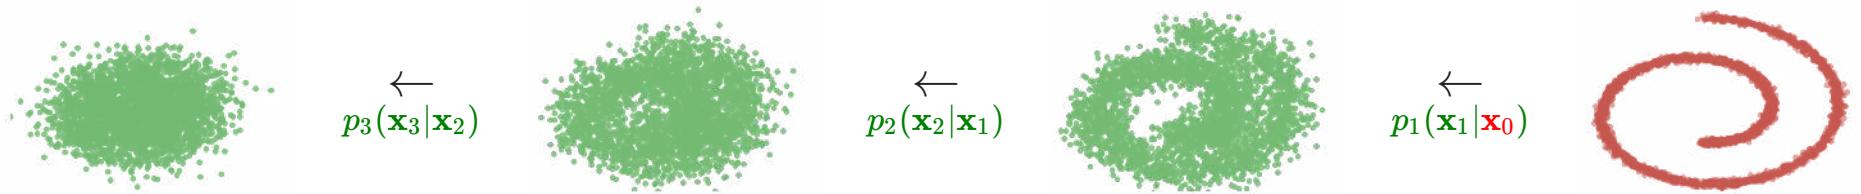
$$\mathbf{f}(\mathbf{x}, t) = \mathbf{0}, \quad g(t) = \sqrt{\frac{\sigma_t^2 - \sigma_{t-1}^2}{\Delta t}} = \sqrt{\frac{d\sigma^2(t)}{dt}}$$

- DDPM (Variance Preserving, VP)

$$\mathbf{f}(\mathbf{x}, t) = (\sqrt{1 - \beta_t}\mathbf{x} - \mathbf{x})/\Delta t \approx -\frac{1}{2} \frac{\beta_t}{\Delta t} \mathbf{x}, \quad g(t) = \sqrt{\frac{\beta_t}{\Delta t}}$$

4. 拡散モデル

■ 4-4. 確率微分方程式による解釈



$$d\mathbf{x}(t) = \mathbf{f}(\mathbf{x}(t), t)dt + g(t)d\mathbf{w}(t)$$

Kolmogorov forward/backward 方程式

- forward: 時刻 t の拡散された粒子の分布 $p_t(\mathbf{x})$ は以下を満たす (Fokker-Planck 方程式)([→証明](#))

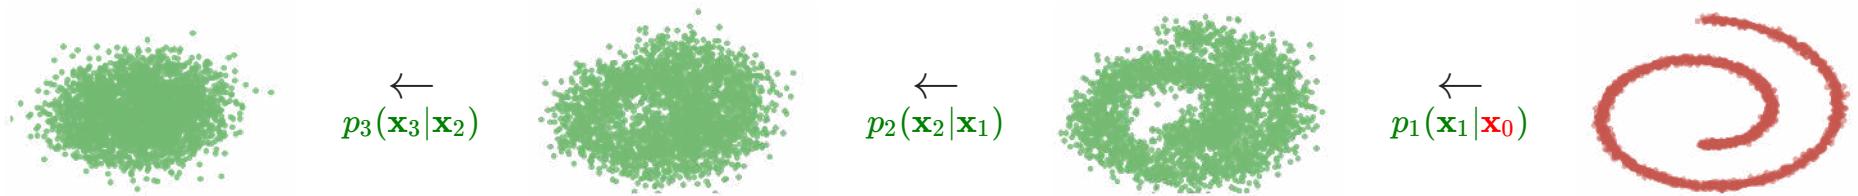
$$\frac{\partial p_t(\mathbf{x})}{\partial t} = -\nabla_{\mathbf{x}} \cdot (\mathbf{f}(\mathbf{x}, t)p_t(\mathbf{x})) + \frac{g(t)^2}{2} \nabla_{\mathbf{x}}^2 p_t(\mathbf{x})$$

- backward: 時刻 t で位置 \mathbf{x} にいる条件で、時刻 $s > t$ で \mathbf{x}_s に見出す確率 $p_t(\mathbf{x}_s|\mathbf{x})$ は以下を満たす ([→証明](#))

$$-\frac{\partial p_t(\mathbf{x}_s|\mathbf{x})}{\partial t} = \mathbf{f}(\mathbf{x}, t) \cdot \nabla_{\mathbf{x}} p_t(\mathbf{x}_s|\mathbf{x}) + \frac{g(t)^2}{2} \nabla_{\mathbf{x}}^2 p_t(\mathbf{x}_s|\mathbf{x})$$

4. 拡散モデル

■ 4-4. 確率微分方程式による解釈



$$d\mathbf{x}(t) = \mathbf{f}(\mathbf{x}(t), t)dt + g(t)d\mathbf{w}(t)$$

逆拡散の確率微分方程式 (→証明)

$\tau = T - t$ として 以下を考えると逆拡散になる。

$$d\mathbf{x}(\tau) = -[\mathbf{f}(\mathbf{x}(\tau), t) - g(t)^2 \nabla_{\mathbf{x}} \log p_t(\mathbf{x}(\tau))]d\tau + g(t)d\bar{\mathbf{w}}(\tau)$$

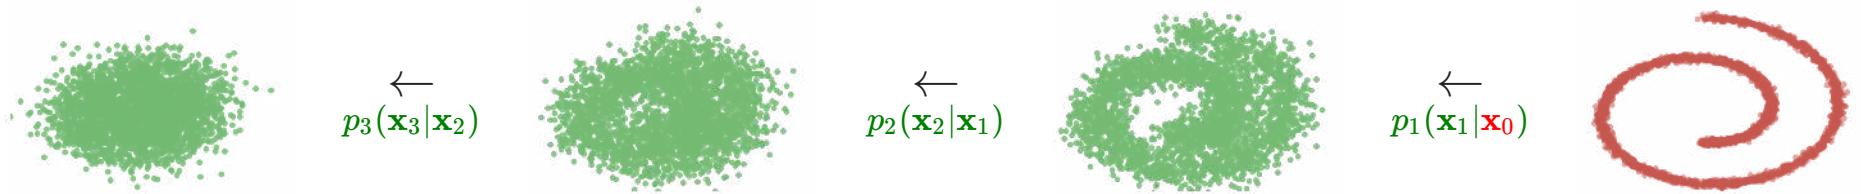
なので、スコアマッチングで $\nabla_{\mathbf{x}} \log p_t(\mathbf{x}) \approx s_{\theta}(\mathbf{x}, t)$ として

$$d\mathbf{x}(\tau) = -[\mathbf{f}(\mathbf{x}(\tau), t) - g(t)^2 s_{\theta}(\mathbf{x}(\tau), t)]d\tau + g(t)d\bar{\mathbf{w}}(\tau)$$

を解けば良い。

4. 拡散モデル

■ 4-4. 確率微分方程式による解釈



$$d\mathbf{x}(t) = \mathbf{f}(\mathbf{x}(t), t)dt + g(t)d\mathbf{w}(t)$$

ところで Fokker-Planck方程式は以下のように書き直せる：

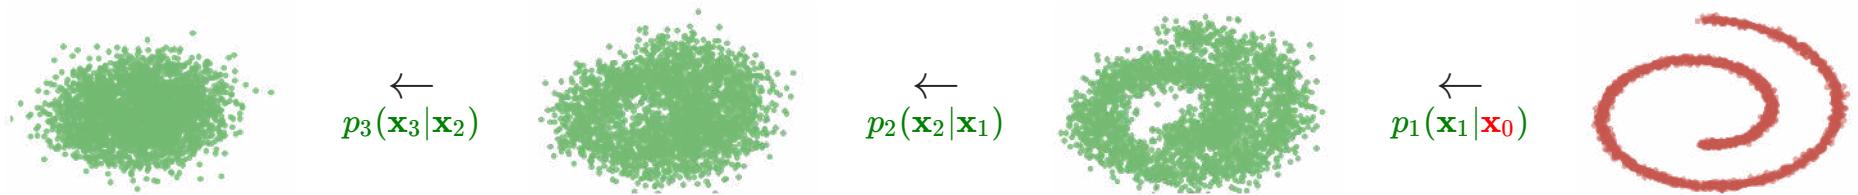
$$\begin{aligned}\frac{\partial p_t(\mathbf{x})}{\partial t} &= -\nabla_{\mathbf{x}} \cdot (\mathbf{f}(\mathbf{x}, t)p_t(\mathbf{x})) + \frac{g(t)^2}{2} \underbrace{\nabla_{\mathbf{x}}^2 p_t(\mathbf{x})}_{\nabla_{\mathbf{x}} \cdot (p_t(\mathbf{x}) \nabla_{\mathbf{x}} \log p_t(\mathbf{x}))} \\ &= -\nabla_{\mathbf{x}} \cdot \left(\left(\mathbf{f}(\mathbf{x}, t) - \frac{g(t)^2}{2} \nabla_{\mathbf{x}} \log p_t(\mathbf{x}) \right) p_t(\mathbf{x}) \right)\end{aligned}$$

同じFP方程式を導く ↑

$$d\mathbf{x}(t) = \left(\mathbf{f}(\mathbf{x}, t) - \frac{g(t)^2}{2} \nabla_{\mathbf{x}} \log p_t(\mathbf{x}) \right) dt \text{ 常微分方程式!}$$

4. 拡散モデル

■ 4-4. 確率微分方程式による解釈



$$d\mathbf{x}(t) = \mathbf{f}(\mathbf{x}(t), t)dt + g(t)d\mathbf{w}(t)$$

逆拡散の確率フロー ([→証明](#))

$$\mathbf{x}(T) \sim p_T \Rightarrow d\mathbf{x}(t) = \left(\mathbf{f}(\mathbf{x}, t) - \frac{g(t)^2}{2} \mathbf{s}(\mathbf{x}, t) \right) dt$$

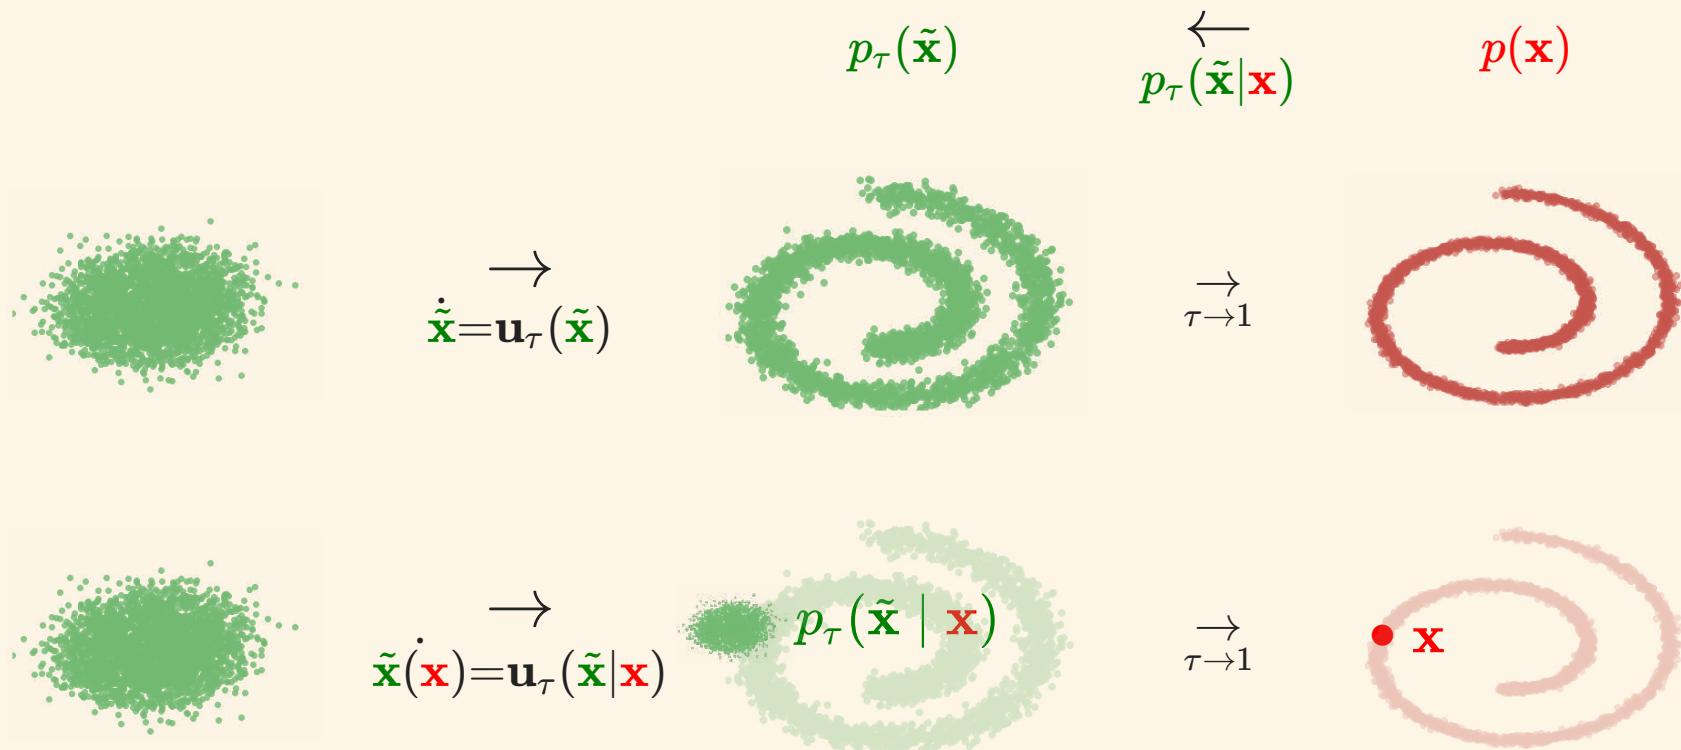
(ここでは時間座標が t なのに注意) この時モデルの密度関数が書き下せる：

$$\log p_0(\mathbf{x}) = \log p_T(\mathbf{x}(T)) + \int_0^T \nabla_{\mathbf{x}} \cdot \left(\mathbf{f}(\mathbf{x}(t), t) - \frac{g(t)^2}{2} \mathbf{s}(\mathbf{x}(t), t) \right) dt$$

4. 拡散モデル

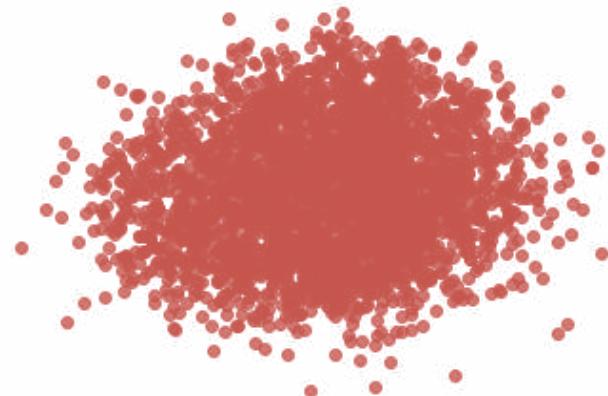
■ 4-5. フローマッ칭

原論文：<https://arxiv.org/abs/2210.02747>

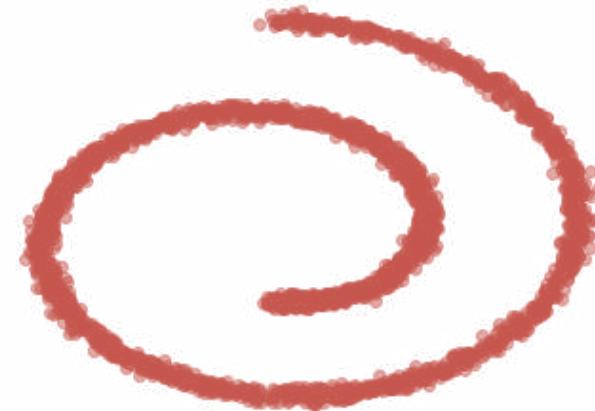


4. 拡散モデル

■ 4-5. フローマッチング



$$\dot{\mathbf{x}}(\tau) \xrightarrow{\longrightarrow} \mathbf{u}_\tau(\mathbf{x}(\tau))$$



ODE からのアプローチ

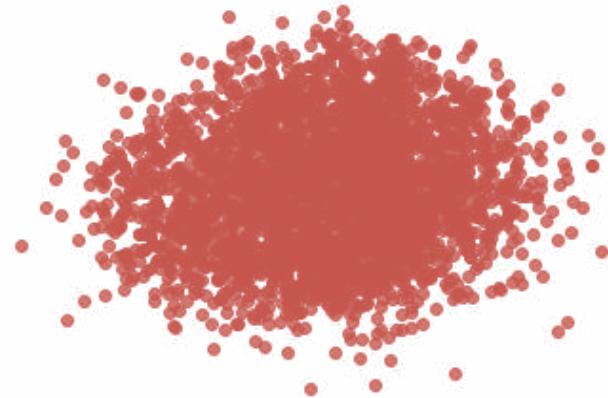
連続の方程式 (\rightarrow 証明)

$\mathbf{x}(0) \sim p_0(\mathbf{x})$, $\dot{\mathbf{x}}(\tau) = \mathbf{u}_\tau(\mathbf{x}(\tau))$ で出来る分布 $p_\tau(\mathbf{x})$ は以下を満たす：

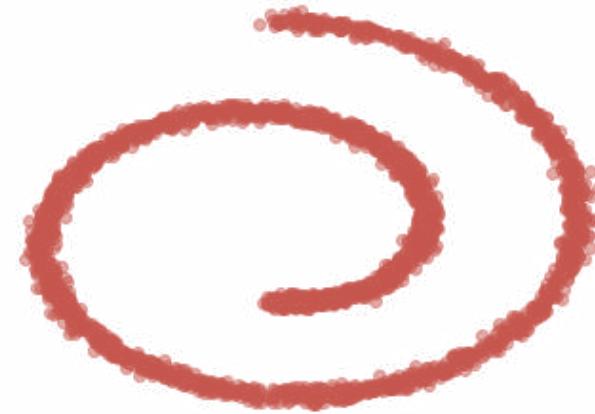
$$\frac{\partial p_\tau(\mathbf{x})}{\partial \tau} + \nabla \cdot (p_\tau(\mathbf{x}) \mathbf{u}_\tau(\mathbf{x})) = 0$$

4. 拡散モデル

■ 4-5. フローマッチング



$$\dot{\mathbf{x}}(\tau) \xrightarrow{\longrightarrow} \mathbf{u}_\tau(\mathbf{x}(\tau))$$



なので \mathbf{u}_τ が学習できれば良い：

$$\langle (\mathbf{v}_{\tau,\theta}(\mathbf{x}) - \mathbf{u}_\tau(\mathbf{x}))^2 \rangle_{\tau \sim U[0,1], \mathbf{x} \sim p_\tau}$$

ただし、 $p_1 = p$ (ターゲット分布)となるような \mathbf{u}_τ ...

絵に描いた餅：そのような \mathbf{u}_τ がわかれれば 学習の必要などない。

4. 拡散モデル

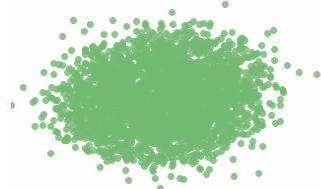
■ 4-5. フローマッチング

p_τ を ノイズで作る：

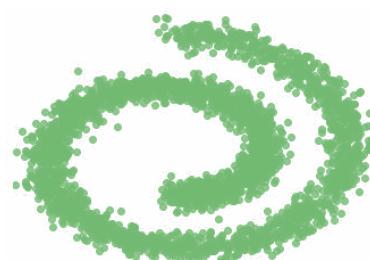
$$p_\tau(\tilde{\mathbf{x}})$$

$$p_\tau(\tilde{\mathbf{x}}|\mathbf{x})$$

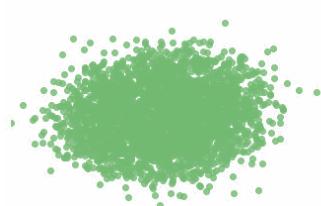
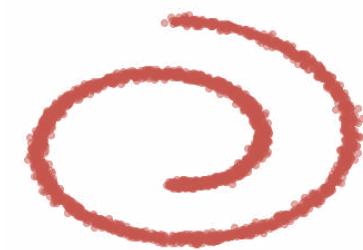
$$p(\mathbf{x})$$



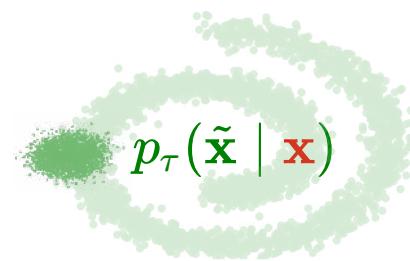
$$\dot{\tilde{\mathbf{x}}} = \mathbf{u}_\tau(\tilde{\mathbf{x}})$$



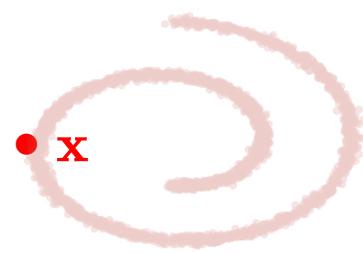
$$\tau \rightarrow 1$$



$$\dot{\tilde{\mathbf{x}}}(\mathbf{x}) = \mathbf{u}_\tau(\tilde{\mathbf{x}}|\mathbf{x})$$



$$\tau \rightarrow 1$$



条件付きフロー (\rightarrow 証明)

$$p_\tau(\tilde{\mathbf{x}}|\mathbf{x}) = \mathcal{N}(\tilde{\mathbf{x}}|\mu_\tau(\mathbf{x}), \sigma_\tau(\mathbf{x})^2 I) \quad \text{ならば} \quad \mathbf{u}_\tau(\tilde{\mathbf{x}}|\mathbf{x}) = \frac{\dot{\sigma}_\tau(\mathbf{x})}{\sigma_\tau(\mathbf{x})} (\tilde{\mathbf{x}} - \mu_\tau(\mathbf{x})) + \dot{\mu}_\tau(\mathbf{x})$$

4. 拡散モデル

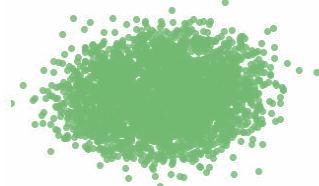
■ 4-5. フローマッチング

p_τ を ノイズで作る：

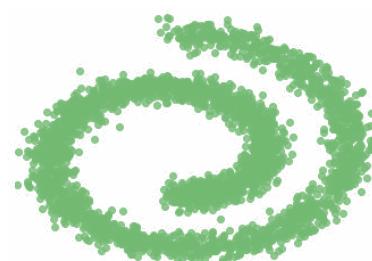
$$p_\tau(\tilde{\mathbf{x}})$$

$$p_\tau(\tilde{\mathbf{x}}|\mathbf{x})$$

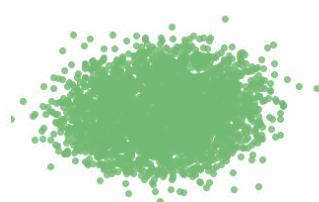
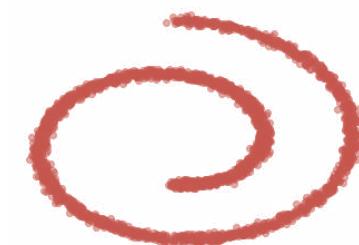
$$p(\mathbf{x})$$



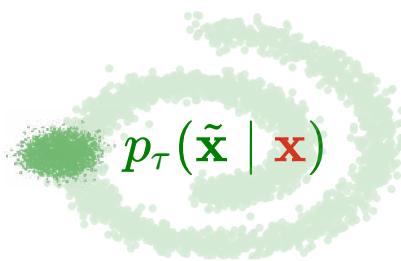
$$\dot{\tilde{\mathbf{x}}} = \mathbf{u}_\tau(\tilde{\mathbf{x}})$$



$$\tau \rightarrow 1$$



$$\dot{\tilde{\mathbf{x}}}(\mathbf{x}) = \mathbf{u}_\tau(\tilde{\mathbf{x}}|\mathbf{x})$$



$$\tau \rightarrow 1$$



ノイズ入りフローマッチング ([→証明](#))

$$\langle (\mathbf{v}_{\tau,\theta}(\tilde{\mathbf{x}}) - \mathbf{u}_\tau(\tilde{\mathbf{x}}))^2 \rangle_{\tau,p_\tau(\tilde{\mathbf{x}})} = \langle (\mathbf{v}_{\tau,\theta}(\tilde{\mathbf{x}}) - \mathbf{u}_\tau(\tilde{\mathbf{x}}|\mathbf{x}))^2 \rangle_{\tau,p_\tau(\tilde{\mathbf{x}}|\mathbf{x})p(\mathbf{x})} + \text{const.}$$

終わり

- 1. 導入
- 2. KLダイバージェンス最小化によるもの
- 3. 潜在変数モデル
- 4. 拡散モデル

Appendix

■ 変分バウンドの証明

$$\begin{aligned}
D_{KL}(p\|q_\theta) + S(p) &= -\langle \log q_\theta(\mathbf{x}) \rangle_{p(\mathbf{x})} \\
&= -\langle \log \underbrace{q_\theta(\mathbf{x})}_{\frac{q_\theta(\mathbf{x}|\mathbf{z})q_Z(\mathbf{z})}{q_\theta(\mathbf{z}|\mathbf{x})}} \rangle_{p(\mathbf{x})r(\mathbf{z}|\mathbf{x})} \\
&= -\left\langle \log \frac{q_\theta(\mathbf{x}|\mathbf{z})q_Z(\mathbf{z})}{q_\theta(\mathbf{z}|\mathbf{x})} \frac{r(\mathbf{z}|\mathbf{x})}{r(\mathbf{z}|\mathbf{x})} \right\rangle_{p(\mathbf{x})r(\mathbf{z}|\mathbf{x})} \\
&= -\left\langle \log \frac{q_\theta(\mathbf{x}|\mathbf{z})q_Z(\mathbf{z})}{r(\mathbf{z}|\mathbf{x})} \frac{r(\mathbf{z}|\mathbf{x})}{q_\theta(\mathbf{z}|\mathbf{x})} \right\rangle_{p(\mathbf{x})r(\mathbf{z}|\mathbf{x})} \\
&= -\left\langle \log \frac{q_\theta(\mathbf{x}|\mathbf{z})q_Z(\mathbf{z})}{r(\mathbf{z}|\mathbf{x})} \right\rangle_{p(\mathbf{x})r(\mathbf{z}|\mathbf{x})} - \langle D_{KL}(r(\mathbf{z}|\mathbf{x})\|q_\theta(\mathbf{z}|\mathbf{x})) \rangle_{p(\mathbf{x})} \\
&\leq -\left\langle \log \frac{q_\theta(\mathbf{x}|\mathbf{z})q_Z(\mathbf{z})}{r(\mathbf{z}|\mathbf{x})} \right\rangle_{p(\mathbf{x})r(\mathbf{z}|\mathbf{x})}
\end{aligned}$$

↔ バウンドの式に戻る

↔ コメントに戻る

■ JSダイバージェンス汎関数表示の証明

1. $\log \sigma(x)$ や $\log\{1 - \sigma(x)\}$ が x について上に凸
2. なので、 D について変分をとって0とおけば \max_D での値が求まる：

$$\begin{aligned}
 V(D) &:= \left\langle \log \sigma(D(\mathbf{x})) \right\rangle_{p(\mathbf{x})} + \left\langle \log \{1 - \sigma(D(\mathbf{y}))\} \right\rangle_{q_\theta(\mathbf{y})} \\
 &= \int_X \left\{ p(\mathbf{x}) \log \frac{1}{1 + e^{-D(\mathbf{x})}} + q_\theta(\mathbf{x}) \log \frac{1}{1 + e^{+D(\mathbf{x})}} \right\} d\mathbf{x} \\
 &\Downarrow \\
 \delta V(D) &= \int_X \frac{\delta D(\mathbf{x})}{1 + e^{+D(\mathbf{x})}} \left\{ p(\mathbf{x}) - q_\theta(\mathbf{x}) e^{+D(\mathbf{x})} \right\} d\mathbf{x} \quad \Rightarrow e^{D^*(\mathbf{x})} = \frac{p(\mathbf{x})}{q_\theta(\mathbf{x})} \\
 &\Downarrow \\
 \max_D V(D) &= V(D^*) = \int_X \left\{ p(\mathbf{x}) \log \frac{1}{1 + \frac{q_\theta(\mathbf{x})}{p(\mathbf{x})}} + q_\theta(\mathbf{x}) \log \frac{1}{1 + \frac{p(\mathbf{x})}{q_\theta(\mathbf{x})}} \right\} d\mathbf{x} \\
 &= D_{JS}(p, q_\theta) - 2 \log 2
 \end{aligned}$$

[← 汎関数表示に戻る](#)

[← コメントに戻る](#)

■ ランジュバンMCの平衡分布が $p(\mathbf{x})$ であること

1. $p(\mathbf{x}) = \frac{e^{-E(\mathbf{x})}}{Z}$ と表現しても一般性は失いません。この時

$$\nabla_{\mathbf{x}} \log p(\mathbf{x}) = -\nabla_{\mathbf{x}} E(\mathbf{x})$$

2. ランジュバンダイナミクスの式は

$$\begin{aligned} \mathbf{x}_t &= \underbrace{\mathbf{x}_{t-1} - \epsilon \nabla_{\mathbf{x}} E(\mathbf{x})}_{\text{平均}} + \sqrt{2\epsilon} \underbrace{\mathbf{z}_t}_{\text{分散}}, \quad \mathbf{z}_t \sim \mathcal{N}(0, I) \\ \Leftrightarrow \mathbf{x}_t &\sim p_{\epsilon}(\mathbf{x}_t | \mathbf{x}_{t-1}) \propto \exp \left(-\frac{1}{2(\underbrace{2\epsilon}_{\text{分散}})} \left(\mathbf{x}_t - \underbrace{(\mathbf{x}_{t-1} - \epsilon \nabla_{\mathbf{x}} E(\mathbf{x}))}_{\text{平均}} \right)^2 \right) \end{aligned}$$

3. p_{ϵ} は $\epsilon \rightarrow 0$ で 平衡分布が $\frac{e^{-E(\mathbf{x})}}{Z}$ の時の詳細釣り合い条件を満たす

(次ページに続く)

■ ランジュバンMCの平衡分布が $p(\mathbf{x})$ であること

$$\begin{aligned}
 & \frac{p_\epsilon(\mathbf{x}|\mathbf{y})}{p_\epsilon(\mathbf{y}|\mathbf{x})} \\
 &= \exp \left[\frac{-1}{2(2\epsilon)} \left\{ (\mathbf{x} - \mathbf{y} + \epsilon \nabla_{\mathbf{y}} E(\mathbf{y}))^2 - (\mathbf{y} - \mathbf{x} + \epsilon \nabla_{\mathbf{x}} E(\mathbf{x}))^2 \right\} \right] \\
 &= \exp \left[\frac{-1}{2(2\epsilon)} \left\{ (\mathbf{x} - \mathbf{y})^2 - (\mathbf{y} - \mathbf{x})^2 + 2\epsilon \underbrace{(\mathbf{x} - \mathbf{y})(\nabla_{\mathbf{x}} E(\mathbf{x}) + \nabla_{\mathbf{y}} E(\mathbf{y}))}_{\text{(cross term)}} + O(\epsilon^2) \right\} \right] \\
 &= \exp \left[\frac{-1}{2} \left\{ (\mathbf{x} - \mathbf{y})(\nabla_{\mathbf{x}} E(\mathbf{x}) + \underbrace{\nabla_{\mathbf{y}} E(\mathbf{y})}_{\nabla_{\mathbf{x}} E(\mathbf{x}) + O(\mathbf{x}-\mathbf{y})}) + O(\epsilon) \right\} \right] \\
 &= \exp \left[-1 \left\{ \underbrace{(\mathbf{x} - \mathbf{y})(\nabla_{\mathbf{x}} E(\mathbf{x}) + O(\mathbf{x} - \mathbf{y}))}_{E(\mathbf{x}) - E(\mathbf{y}) + O((\mathbf{x} - \mathbf{y})^2)} + O(\epsilon) \right\} \right] \\
 &= \frac{e^{-E(\mathbf{x})}}{e^{-E(\mathbf{y})}} \exp \left(O(\epsilon) + \underbrace{O((\mathbf{x} - \mathbf{y})^2)}_{\text{分散程度なので } O(\epsilon)} \right)
 \end{aligned}$$

[← ランジュバンMCの説明に戻る](#)

■ スコアマッチング目的関数の変形

$$\begin{aligned}
& \left\langle \left(s_\theta(\mathbf{x}) - \nabla_{\mathbf{x}} \log p(\mathbf{x}) \right)^2 \right\rangle_{p(\mathbf{x})} \\
&= \int d\mathbf{x} p(\mathbf{x}) \left(s_\theta(\mathbf{x}) - \nabla_{\mathbf{x}} \log p(\mathbf{x}) \right)^2 \\
&= \int d\mathbf{x} p(\mathbf{x}) s_\theta(\mathbf{x})^2 - 2 \int d\mathbf{x} p(\mathbf{x}) s_\theta(\mathbf{x}) \cdot \underbrace{\nabla_{\mathbf{x}} \log p(\mathbf{x})}_{\nabla_{\mathbf{x}} p(\mathbf{x})/p(\mathbf{x})} + \underbrace{\int d\mathbf{x} p(\mathbf{x}) (\nabla_{\mathbf{x}} \log p(\mathbf{x}))^2}_{\text{const}} \\
&= \int d\mathbf{x} p(\mathbf{x}) [s_\theta(\mathbf{x})^2 + 2\nabla_{\mathbf{x}} \cdot s_\theta(\mathbf{x})] - 2 \underbrace{\int d\mathbf{x} \nabla_{\mathbf{x}} \cdot (s_\theta(\mathbf{x}) p(\mathbf{x}))}_{\text{表面項で } 0} + \text{const} \\
&= \langle s_\theta(\mathbf{x})^2 + 2\nabla_{\mathbf{x}} \cdot s_\theta(\mathbf{x}) \rangle_{p(\mathbf{x})} + \text{const}
\end{aligned}$$

[← スコアマッチング目的に戻る](#)

■ デノイジング スコアマッチング目的関数の変形

$$\begin{aligned}
& \left\langle \left(s_\theta(\tilde{\mathbf{x}}) - \nabla_{\tilde{\mathbf{x}}} \log p_\sigma(\tilde{\mathbf{x}}) \right)^2 \right\rangle_{p_\sigma(\tilde{\mathbf{x}})} \\
&= \int d\tilde{\mathbf{x}} p_\sigma(\tilde{\mathbf{x}}) \left(s_\theta(\tilde{\mathbf{x}}) - \nabla_{\tilde{\mathbf{x}}} \log p_\sigma(\tilde{\mathbf{x}}) \right)^2 \\
&= \int d\tilde{\mathbf{x}} p_\sigma(\tilde{\mathbf{x}}) s_\theta(\tilde{\mathbf{x}})^2 - 2 \underbrace{\int d\tilde{\mathbf{x}} p_\sigma(\tilde{\mathbf{x}}) s_\theta(\tilde{\mathbf{x}}) \cdot \underbrace{\nabla_{\tilde{\mathbf{x}}} \log p_\sigma(\tilde{\mathbf{x}})}_{\nabla_{\tilde{\mathbf{x}}} p_\sigma(\tilde{\mathbf{x}})/p_\sigma(\tilde{\mathbf{x}})}}_{s_\theta(\tilde{\mathbf{x}}) \cdot \nabla_{\tilde{\mathbf{x}}} p_\sigma(\tilde{\mathbf{x}})} + \underbrace{\int d\tilde{\mathbf{x}} p_\sigma(\tilde{\mathbf{x}}) (\nabla_{\tilde{\mathbf{x}}} \log p_\sigma(\tilde{\mathbf{x}}))^2}_{\text{const}} \\
&= \int d\tilde{\mathbf{x}} \underbrace{p_\sigma(\tilde{\mathbf{x}})}_{\int d\mathbf{x} p_\sigma(\tilde{\mathbf{x}}|\mathbf{x}) p(\mathbf{x})} s_\theta(\tilde{\mathbf{x}})^2 - 2 \int d\tilde{\mathbf{x}} s_\theta(\tilde{\mathbf{x}}) \cdot \nabla_{\tilde{\mathbf{x}}} \underbrace{p_\sigma(\tilde{\mathbf{x}})}_{\int d\mathbf{x} p_\sigma(\tilde{\mathbf{x}}|\mathbf{x}) p(\mathbf{x})} + \text{const} \\
&= \iint d\tilde{\mathbf{x}} d\mathbf{x} \left[p_\sigma(\tilde{\mathbf{x}}|\mathbf{x}) p(\mathbf{x}) s_\theta(\tilde{\mathbf{x}})^2 - 2 s_\theta(\tilde{\mathbf{x}}) \cdot \underbrace{\left(\nabla_{\tilde{\mathbf{x}}} p_\sigma(\tilde{\mathbf{x}}|\mathbf{x}) \right)}_{p_\sigma(\tilde{\mathbf{x}}|\mathbf{x}) \nabla_{\tilde{\mathbf{x}}} \log p_\sigma(\tilde{\mathbf{x}}|\mathbf{x})} p(\mathbf{x}) \right] + \text{const} \\
&= \iint d\tilde{\mathbf{x}} d\mathbf{x} p_\sigma(\tilde{\mathbf{x}}|\mathbf{x}) p(\mathbf{x}) \underbrace{\left[s_\theta(\tilde{\mathbf{x}})^2 - 2 s_\theta(\tilde{\mathbf{x}}) \cdot \nabla_{\tilde{\mathbf{x}}} \log p_\sigma(\tilde{\mathbf{x}}|\mathbf{x}) \right]}_{(s_\theta(\tilde{\mathbf{x}}) - \nabla_{\tilde{\mathbf{x}}} \log p_\sigma(\tilde{\mathbf{x}}|\mathbf{x}))^2 - \text{const}_2} + \text{const} \\
&= \left\langle \left(s_\theta(\tilde{\mathbf{x}}) - \nabla_{\tilde{\mathbf{x}}} \log p_\sigma(\tilde{\mathbf{x}}|\mathbf{x}) \right)^2 \right\rangle_{p_\sigma(\tilde{\mathbf{x}}|\mathbf{x}) p(\mathbf{x})} + \text{const}' \quad \leftarrow \text{説明に戻る}
\end{aligned}$$

■ 拡散バウンドの証明

$$\begin{aligned}
& \log q_{\theta}(\mathbf{x}_0) \\
&= \langle \log q_{\theta}(\mathbf{x}_0) \rangle_{p(\mathbf{x}_1, \dots, \mathbf{x}_L | \mathbf{x}_0)} \\
&= \left\langle \log \frac{q_{\theta}(\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_L)}{q_{\theta}(\mathbf{x}_1, \dots, \mathbf{x}_L | \mathbf{x}_0)} \right\rangle_{p(\mathbf{x}_1, \dots, \mathbf{x}_L | \mathbf{x}_0)} \\
&= \left\langle \log \frac{q_{\theta}(\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_L)}{q_{\theta}(\mathbf{x}_1, \dots, \mathbf{x}_L | \mathbf{x}_0)} \frac{p(\mathbf{x}_1, \dots, \mathbf{x}_L | \mathbf{x}_0)}{p(\mathbf{x}_1, \dots, \mathbf{x}_L | \mathbf{x}_0)} \right\rangle_{p(\mathbf{x}_1, \dots, \mathbf{x}_L | \mathbf{x}_0)} \\
&= \left\langle \log \frac{q_{\theta}(\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_L)}{p(\mathbf{x}_1, \dots, \mathbf{x}_L | \mathbf{x}_0)} \frac{p(\mathbf{x}_1, \dots, \mathbf{x}_L | \mathbf{x}_0)}{q_{\theta}(\mathbf{x}_1, \dots, \mathbf{x}_L | \mathbf{x}_0)} \right\rangle_{p(\mathbf{x}_1, \dots, \mathbf{x}_L | \mathbf{x}_0)} \\
&= \left\langle \log \frac{q_{\theta}(\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_L)}{p(\mathbf{x}_1, \dots, \mathbf{x}_L | \mathbf{x}_0)} \right\rangle_{p(\mathbf{x}_1, \dots, \mathbf{x}_L | \mathbf{x}_0)} + \underbrace{D_{KL}(p(\mathbf{x}_1, \dots, \mathbf{x}_L | \mathbf{x}_0) \| q_{\theta}(\mathbf{x}_1, \dots, \mathbf{x}_L | \mathbf{x}_0))}_{\geq 0} \\
&\geq \left\langle \log \frac{q_{\theta}(\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_L)}{p(\mathbf{x}_1, \dots, \mathbf{x}_L | \mathbf{x}_0)} \right\rangle_{p(\mathbf{x}_1, \dots, \mathbf{x}_L | \mathbf{x}_0)}
\end{aligned}$$

あとはこれを $p(\mathbf{x}_0)$ で期待値を取る。

← 説明に戻る

■ Gaussian のマルコフ過程における補題

補題1

$$\begin{array}{ccccc}
 & \mathcal{N}(\mathbf{x}; \sqrt{\alpha_x} \mathbf{y}, \beta_x I) & & \mathcal{N}(\mathbf{y}; \sqrt{\alpha_y} \mathbf{z}, \beta_y I) & \\
 & \overbrace{\quad\quad\quad}^{p(\mathbf{x}|\mathbf{y})} & & \overbrace{\quad\quad\quad}^{p(\mathbf{y}|\mathbf{z})} & \\
 \mathbf{x} & \longleftarrow & \mathbf{y} & \longleftarrow & \mathbf{z} \\
 & & \Downarrow & & \\
 p(\mathbf{x}|\mathbf{z}) = \int p(\mathbf{x}|\mathbf{y})p(\mathbf{y}|\mathbf{z})d\mathbf{y} & = & \mathcal{N}(\mathbf{x}; \sqrt{\alpha_x \alpha_y} \mathbf{z}, (\alpha_x \beta_y + \beta_x)I)
 \end{array}$$

素朴に積分を取れば平方完成で示せるが、直感的には

$$\begin{aligned}
 \mathbf{x} &= \sqrt{\alpha_x} \mathbf{y} + \sqrt{\beta_x} \epsilon_x, \quad \epsilon_x \sim \mathcal{N}(0, I) \\
 \mathbf{y} &= \sqrt{\alpha_y} \mathbf{z} + \sqrt{\beta_y} \epsilon_y, \quad \epsilon_y \sim \mathcal{N}(0, I)
 \end{aligned}
 \Rightarrow \mathbf{x} = \sqrt{\alpha_x \alpha_y} \mathbf{z} + \underbrace{\sqrt{\alpha_x \beta_y} \epsilon_y + \sqrt{\beta_x} \epsilon_x}_{(*)}$$

ϵ_x, ϵ_y は独立なので、 $(*)$ が与える分散はそれぞれの分散の和

$$\alpha_x \beta_y + \beta_x$$

となるのがわかることからも示せる。 時刻 t での拡散が従う分布の証明に戻る

■ 時刻 t での拡散が従う分布

時刻 t での分布

$$p(\mathbf{x}_t | \mathbf{x}_0) = \mathcal{N} \left(\mathbf{x}_t; \sqrt{\prod_{\tau=1}^t \alpha_\tau} \mathbf{x}_0, \left(1 - \prod_{\tau=1}^t \alpha_\tau \right) I \right)$$

特に $\mathbf{x}_\infty \sim \mathcal{N}(\mathbf{0}, I)$ となる。

$t = 1$ の時 明らかに成り立つ (定義そのもの)

t で成り立つとする。この時 $t + 1$ の分布は

$$p(\mathbf{x}_{t+1} | \mathbf{x}_0) = \int \underbrace{p(\mathbf{x}_{t+1} | \mathbf{x}_t)}_{\mathcal{N}(\sqrt{\prod_{\tau=1}^t \alpha_\tau} \mathbf{x}_t, (\mathbf{I} - \prod_{\tau=1}^t \alpha_\tau)^{-1})} \underbrace{p(\mathbf{x}_t | \mathbf{x}_0)}_{\mathcal{N}(\mathbf{x}_0, (\mathbf{I} - \prod_{\tau=1}^t \alpha_\tau)^{-1})} d\mathbf{x}_t$$

となるため、1ページ前の補題1を使うと $t + 1$ の場合も $\beta_{t+1} = 1 - \alpha_{t+1}$ に注意すれば示せる。[← 説明に戻る](#)

■ Gauss分布の分散による展開

補題2

$$\mathcal{N}(\tilde{\mathbf{x}}; \mathbf{x}, \sigma^2 I) = \delta(\tilde{\mathbf{x}} - \mathbf{x}) + \frac{\sigma^2}{2} \nabla^2 \delta(\tilde{\mathbf{x}} - \mathbf{x}) + O(\sigma^4)$$

形式的にテイラー展開すると

$$\begin{aligned} \mathcal{N}(\tilde{\mathbf{x}}|\mathbf{x}, \sigma^2 I) &= \underbrace{\mathcal{N}(\tilde{\mathbf{x}}|\mathbf{x}, \sigma^2 I)|_{\sigma^2 \downarrow 0}}_{\delta(\tilde{\mathbf{x}}-\mathbf{x})} + \sigma^2 \underbrace{\frac{\partial}{\partial \sigma^2} \mathcal{N}(\tilde{\mathbf{x}}|\mathbf{x}, \sigma^2 I)|_{\sigma^2 \downarrow 0}}_{\frac{1}{2\sigma^2} \left(-\dim(\tilde{\mathbf{x}}) + \frac{(\tilde{\mathbf{x}}-\mathbf{x})^2}{\sigma^2} \right)} + O(\sigma^4) \end{aligned}$$

ところで、 $\mathcal{N}(\tilde{\mathbf{x}}|\mathbf{x}, \sigma^2 I)$ のラプラシアンを計算すると

$$\nabla^2 \mathcal{N}(\tilde{\mathbf{x}}|\mathbf{x}, \sigma^2 I)|_{\sigma^2 \downarrow 0} = \frac{1}{2\sigma^2} \left(-\dim(\tilde{\mathbf{x}}) + \frac{(\tilde{\mathbf{x}} - \mathbf{x})^2}{\sigma^2} \right) \mathcal{N}(\tilde{\mathbf{x}}|\mathbf{x}, \sigma^2 I)|_{\sigma^2 \downarrow 0}$$

となるので示せたことになる。 [← forwardの証明に戻る](#) [← backwardの証明に戻る](#)

■ デルタ関数の公式

補題3

$$\delta(\tilde{\mathbf{x}}_t - \tilde{\mathbf{x}} - \mathbf{f}(\tilde{\mathbf{x}}, t)\Delta t) = \frac{\delta(\tilde{\mathbf{x}}_t - \tilde{\mathbf{x}} - \mathbf{f}(\tilde{\mathbf{x}}_t, t)\Delta t)}{1 + \nabla_{\tilde{\mathbf{x}}} \cdot \mathbf{f}(\tilde{\mathbf{x}}_t, t)\Delta t} + O(\Delta t^2)$$

$$\delta(F(\tilde{\mathbf{x}})) = \frac{F(\tilde{\mathbf{x}}) \text{のゼロ点まわり1次展開}}{\det |\nabla_{\tilde{\mathbf{x}}} F^\top(\tilde{\mathbf{x}})|}$$

を使う。まず分子は、ゼロ点を見つけないといけないが、再起的に

$$\tilde{\mathbf{x}} = \tilde{\mathbf{x}}_t - \mathbf{f}(\tilde{\mathbf{x}}, t)\Delta t = \tilde{\mathbf{x}}_t - \mathbf{f}(\tilde{\mathbf{x}}_t - \mathbf{f}(\tilde{\mathbf{x}}, t)\Delta t, t)\Delta t = \tilde{\mathbf{x}}_t - \mathbf{f}(\tilde{\mathbf{x}}_t, t)\Delta t + O(\Delta t^2)$$

となって、右辺のデルタ関数での指定になる。分母は

$$\begin{aligned} \det | -I - \nabla_{\tilde{\mathbf{x}}} \mathbf{f}^\top(\tilde{\mathbf{x}}, t)\Delta t | &= \det(I + \nabla_{\tilde{\mathbf{x}}} \mathbf{f}^\top(\tilde{\mathbf{x}}, t)\Delta t) \\ &= \sum_{\sigma \in S_N} |\sigma| \prod_{i=1}^N \left(\delta_{i,\sigma(i)} + \partial_i f^{\sigma(i)}(\tilde{\mathbf{x}}, t)\Delta t \right) = \sum_{\sigma \in S_N} |\sigma| \underbrace{\left(\prod_{i=1}^N \delta_{i,\sigma(i)} + \sum_{j=1}^N \left[\prod_{i=1, i \neq j}^N \delta_{i,\sigma(i)} \right] \partial_j f^{\sigma(j)}(\tilde{\mathbf{x}}, t)\Delta t + o(\Delta t) \right)}_{\sigma=1 \text{のみ非ゼロ}} \\ &= 1 + \nabla_{\tilde{\mathbf{x}}} \cdot \mathbf{f}(\tilde{\mathbf{x}}, t) + o(\Delta t) \end{aligned}$$

↔ forwardの証明に戻る

■ Kolmogorov forward 方程式 (Fokker-Planck方程式)

離散版 (Gauss分布によるMarkov連鎖) を考え、時刻 t での分布の表現を Δt 一次までで考える。ここでは $\mathbf{x}_t = \tilde{\mathbf{x}}$, $\mathbf{x}_{t-1} = \mathbf{x}$ としている。

$$\begin{aligned}
p_t(\tilde{\mathbf{x}}) &= \int p_t(\tilde{\mathbf{x}}|\mathbf{x})p_{t-1}(\mathbf{x})d\mathbf{x} \\
&= \int \underbrace{\mathcal{N}(\tilde{\mathbf{x}}|\mathbf{x} + \mathbf{f}(\mathbf{x}, t)\Delta t, g(t)^2 \Delta t I)}_{\delta(\tilde{\mathbf{x}} - \mathbf{x} - \mathbf{f}(\mathbf{x}, t)\Delta t) + \frac{g(t)^2 \Delta t}{2} \nabla_{\tilde{\mathbf{x}}}^2 \delta(\tilde{\mathbf{x}} - \mathbf{x} - \mathbf{f}(\mathbf{x}, t)\Delta t)} p_{t-1}(\mathbf{x})d\mathbf{x} \\
&\stackrel{\text{補題2}}{=} p_{t-1}(\tilde{\mathbf{x}} - \mathbf{f}(\tilde{\mathbf{x}}, t)\Delta t)/(1 + \nabla_{\tilde{\mathbf{x}}} \cdot \mathbf{f}(\tilde{\mathbf{x}}, t)\Delta t) + \frac{g(t)^2 \Delta t}{2} \nabla_{\tilde{\mathbf{x}}}^2 p_{t-1}(\tilde{\mathbf{x}}) \\
&= p_{t-1}(\tilde{\mathbf{x}}) \underbrace{-\mathbf{f}(\tilde{\mathbf{x}}, t)\Delta t \cdot \nabla_{\tilde{\mathbf{x}}} p_{t-1}(\tilde{\mathbf{x}}) - \nabla_{\tilde{\mathbf{x}}} \cdot \mathbf{f}(\tilde{\mathbf{x}}, t)\Delta t p_{t-1}(\tilde{\mathbf{x}})}_{-\Delta t \nabla_{\tilde{\mathbf{x}}} \cdot (\mathbf{f}(\tilde{\mathbf{x}}, t)p_{t-1}(\tilde{\mathbf{x}}))} + \frac{g(t)^2 \Delta t}{2} \nabla_{\tilde{\mathbf{x}}}^2 p_{t-1}(\tilde{\mathbf{x}})
\end{aligned}$$

あとは一項目を移行し、 Δt で割れば

$$\frac{p_t(\tilde{\mathbf{x}}) - p_{t-1}(\tilde{\mathbf{x}})}{\Delta t} = -\nabla_{\tilde{\mathbf{x}}} \cdot (\mathbf{f}(\tilde{\mathbf{x}}, t)p_{t-1}(\tilde{\mathbf{x}})) + \frac{g(t)^2}{2} \nabla_{\tilde{\mathbf{x}}}^2 p_{t-1}(\tilde{\mathbf{x}})$$

最後に $p_{t-1} = p_t + O(\Delta t)$ を使い $\Delta t \rightarrow +0$ 。 [← 説明に戻る](#)

■ Kolmogorov backward 方程式

離散版 (Gauss分布によるMarkov連鎖) を考え、時刻 t での分布の表現を Δt 一次までで考える。ここでは $\mathbf{x}_t = \tilde{\mathbf{x}}$, $\mathbf{x}_{t+1} = \mathbf{x}$ としている。

$$\begin{aligned}
p_t(\mathbf{x}_s | \tilde{\mathbf{x}}) &= \int p_{t+1}(\mathbf{x}_s | \mathbf{x}) p_t(\mathbf{x} | \tilde{\mathbf{x}}) d\mathbf{x} \\
&= \int p_{t+1}(\mathbf{x}_s | \mathbf{x}) \underbrace{\mathcal{N}(\mathbf{x} | \tilde{\mathbf{x}} + \mathbf{f}(\tilde{\mathbf{x}}, t)\Delta t, g(t)^2 \Delta t I)}_{\delta(\mathbf{x} - \tilde{\mathbf{x}} - \mathbf{f}(\tilde{\mathbf{x}}, t)\Delta t) + \frac{g(t)^2 \Delta t}{2} \nabla_{\mathbf{x}}^2 \delta(\mathbf{x} - \tilde{\mathbf{x}} - \mathbf{f}(\tilde{\mathbf{x}}, t)\Delta t)} d\mathbf{x} \quad \text{補題2} \\
&= \underbrace{p_{t+1}(\mathbf{x}_s | \tilde{\mathbf{x}} + \mathbf{f}(\tilde{\mathbf{x}}, t)\Delta t)}_{p_{t+1}(\mathbf{x}_s | \tilde{\mathbf{x}}) + \mathbf{f}(\tilde{\mathbf{x}}, t)\Delta t \cdot \nabla_{\tilde{\mathbf{x}}} p_{t+1}(\mathbf{x}_s | \tilde{\mathbf{x}})} + \frac{g(t)^2}{2} \Delta t \nabla_{\tilde{\mathbf{x}}}^2 p_{t+1}(\mathbf{x}_s | \tilde{\mathbf{x}})
\end{aligned}$$

あとは一項目を移行し、 Δt で割れば

$$\frac{p_t(\mathbf{x}_s | \tilde{\mathbf{x}}) - p_{t+1}(\mathbf{x}_s | \tilde{\mathbf{x}})}{\Delta t} = \mathbf{f}(\tilde{\mathbf{x}}, t) \cdot \nabla_{\tilde{\mathbf{x}}} p_{t+1}(\mathbf{x}_s | \tilde{\mathbf{x}}) + \frac{g(t)^2}{2} \nabla_{\tilde{\mathbf{x}}}^2 p_{t+1}(\mathbf{x}_s | \tilde{\mathbf{x}})$$

最後に $p_{t+1} = p_t + O(\Delta t)$ を使い $\Delta t \rightarrow +0$ 。 [← 説明に戻る](#)

■ 逆拡散

時刻 t で \mathbf{x} 、時刻 s で \mathbf{x}_s を見出す確率密度は、 $p_t(\mathbf{x}_s, \mathbf{x}) = p_t(\mathbf{x}_s | \mathbf{x})p_t(\mathbf{x})$ だが、これを時間微分すると

$$\begin{aligned}
& \frac{\partial}{\partial t} \underbrace{p_t(\mathbf{x}_s, \mathbf{x})}_{p_t(\mathbf{x}_s | \mathbf{x})p_t(\mathbf{x})} \\
= & \underbrace{\frac{\partial}{\partial t} p_t(\mathbf{x}_s | \mathbf{x})}_{-\mathbf{f}(\mathbf{x}, t) \cdot \nabla_{\mathbf{x}} p_t(\mathbf{x}_s | \mathbf{x}) - \frac{g(t)^2}{2} \nabla_{\mathbf{x}}^2 p_t(\mathbf{x}_s | \mathbf{x})} \quad p_t(\mathbf{x}) + p_t(\mathbf{x}_s | \mathbf{x}) \underbrace{\frac{\partial}{\partial t} p_t(\mathbf{x})}_{-\nabla_{\mathbf{x}} \cdot (\mathbf{f}(\mathbf{x}, t)p_t(\mathbf{x})) + \frac{g(t)^2}{2} \nabla_{\mathbf{x}}^2 p_t(\mathbf{x})} \\
= & -\nabla_{\mathbf{x}}(\mathbf{f}(\mathbf{x}, t)p_t(\mathbf{x}_s | \mathbf{x})p_t(\mathbf{x})) + \frac{g(t)^2}{2} \left(-\underbrace{\nabla_{\mathbf{x}}^2 p_t(\mathbf{x}_s | \mathbf{x}) \cdot p_t(\mathbf{x})}_{-\nabla_{\tilde{\mathbf{x}}}^2(p_t(\tilde{\mathbf{x}}_s | \tilde{\mathbf{x}})p_t(\tilde{\mathbf{x}})) + 2\nabla_{\tilde{\mathbf{x}}}p_t(\tilde{\mathbf{x}}_s | \tilde{\mathbf{x}}) \cdot \nabla_{\tilde{\mathbf{x}}}p_t(\tilde{\mathbf{x}})} + \color{red}{p_t(\mathbf{x}_s | \mathbf{x})\nabla_{\mathbf{x}}^2 p_t(\mathbf{x})} \right. \\
& \quad \left. -\nabla_{\tilde{\mathbf{x}}}^2(p_t(\tilde{\mathbf{x}}_s | \tilde{\mathbf{x}})p_t(\tilde{\mathbf{x}})) + 2\nabla_{\tilde{\mathbf{x}}}p_t(\tilde{\mathbf{x}}_s | \tilde{\mathbf{x}}) \cdot \nabla_{\tilde{\mathbf{x}}}p_t(\tilde{\mathbf{x}}) + \color{red}{p_t(\tilde{\mathbf{x}}_s | \tilde{\mathbf{x}})\nabla_{\tilde{\mathbf{x}}}^2 p_t(\tilde{\mathbf{x}})} \right) \\
= & -\nabla_{\tilde{\mathbf{x}}} \left\{ [\mathbf{f}(\tilde{\mathbf{x}}, t) - g(t)^2 \nabla_{\tilde{\mathbf{x}}} \log p_t(\tilde{\mathbf{x}})] \underbrace{p_t(\tilde{\mathbf{x}}_s | \tilde{\mathbf{x}})p_t(\tilde{\mathbf{x}})}_{p_t(\tilde{\mathbf{x}}_s, \tilde{\mathbf{x}})} \right\} + \frac{g(t)^2}{2} \left(-\nabla_{\tilde{\mathbf{x}}}^2 \left(\underbrace{p_t(\tilde{\mathbf{x}}_s | \tilde{\mathbf{x}})p_t(\tilde{\mathbf{x}})}_{p_t(\tilde{\mathbf{x}}_s, \tilde{\mathbf{x}})} \right) \right)
\end{aligned}$$

最後の段までくると、 $p_t(\mathbf{x}_s, \mathbf{x})$ に関する方程式。これを \mathbf{x}_s について積分する

■ 逆拡散

$\int p_t(\mathbf{x}_s, \mathbf{x}) d\mathbf{x}_s := p_t^{(b)}(\mathbf{x})$ とすると

$$\frac{\partial}{\partial t} p_t^{(b)}(\mathbf{x}) = -\nabla_{\mathbf{x}} \left\{ [\tilde{\mathbf{f}}(\mathbf{x}, t) - g(t)^2 \nabla_{\mathbf{x}} \log p_t(\mathbf{x})] p_t^{(b)}(\mathbf{x}) \right\} + \frac{g(t)^2}{2} (-\nabla_{\mathbf{x}}^2 p_t^{(b)}(\mathbf{x}))$$

さらに $\tau = T - t$ とすると

$$\frac{\partial}{\partial \tau} p_t^{(b)}(\mathbf{x}) = -\nabla_{\mathbf{x}} \left\{ -[\mathbf{f}(\mathbf{x}, t) - g(t)^2 \nabla_{\mathbf{x}} \log p_t(\mathbf{x})] p_t^{(b)}(\mathbf{x}) \right\} + \frac{g(t)^2}{2} \nabla_{\mathbf{x}}^2 p_t^{(b)}(\mathbf{x})$$

ドリフトと分散を読み取ると、これは 以下の確率微分方程式から誘導される Fokker-Plank方程式であるのがわかる：

$$d\mathbf{x}(\tau) = -[\mathbf{f}(\mathbf{x}, t) - g(t)^2 \nabla_{\mathbf{x}} \log p_t(\mathbf{x})] d\tau + g(t) d\bar{\mathbf{w}}(\tau)$$

[← 説明に戻る](#)

■ 逆拡散の確率フローでの尤度計算

解を $\mathbf{x}(t)$ とかくと、微分の連鎖率から

$$\begin{aligned}
 & \frac{d}{dt} p_t(\mathbf{x}(t)) \\
 &= \underbrace{\dot{p}_t(\mathbf{x})}_{\text{Fokker-Planck方程式}} + \underbrace{\dot{\mathbf{x}}(t)}_{\text{逆拡散の確率フロー}} \cdot \nabla_{\mathbf{x}} p_t(\mathbf{x}(t)) \\
 &= -\nabla_{\mathbf{x}} \cdot \left([\mathbf{f}(\mathbf{x}, t) - \frac{g(t)^2}{2} s(\mathbf{x}, t)] p_t(\mathbf{x}) \right) + [\mathbf{f}(\mathbf{x}, t) - \frac{g(t)^2}{2} s(\mathbf{x}, t)] \cdot \nabla_{\mathbf{x}} p_t(\mathbf{x}(t)) \\
 &= -\left(\nabla_{\mathbf{x}} \cdot [\mathbf{f}(\mathbf{x}, t) - \frac{g(t)^2}{2} s(\mathbf{x}, t)] \right) p_t(\mathbf{x}) \\
 &\Downarrow \\
 & \frac{d}{dt} \log p_t(\mathbf{x}(t)) = -\nabla_{\mathbf{x}} \cdot [\mathbf{f}(\mathbf{x}, t) - \frac{g(t)^2}{2} s(\mathbf{x}, t)] \\
 &\Downarrow \\
 & \log p_T(\mathbf{x}(T)) - \log p_0(\mathbf{x}(0)) = - \int_0^T \nabla_{\mathbf{x}} \cdot [\mathbf{f}(\mathbf{x}(t), t) - \frac{g(t)^2}{2} s(\mathbf{x}(t), t)] dt
 \end{aligned}$$

[← 説明に戻る](#)

■ 連続の方程式

まず、時刻 τ での分布は以下のようにかける：

$$p_\tau(\mathbf{x}) = \int \delta(\mathbf{x} - \mathbf{x}(\tau)) p_0(\mathbf{x}(0)) d\mathbf{x}(0)$$

これを素朴に時間微分すると示せる：

$$\begin{aligned}\frac{\partial p_\tau(\mathbf{x})}{\partial \tau} &= \frac{\partial}{\partial \tau} \int \delta(\mathbf{x} - \mathbf{x}(\tau)) p_0(\mathbf{x}(0)) d\mathbf{x}(0) \\ &= \int \left(- \underbrace{\dot{\mathbf{x}}(\tau)}_{\mathbf{u}_\tau(\mathbf{x}(\tau))} \right) \cdot \nabla_{\mathbf{x}} \delta(\mathbf{x} - \mathbf{x}(\tau)) p_0(\mathbf{x}(0)) d\mathbf{x}(0) \\ &= - \nabla_{\mathbf{x}} \cdot \int \left(\mathbf{u}_\tau \left(\underbrace{\mathbf{x}(\tau)}_{\text{xに置き換えて良い}} \right) \right) \delta(\mathbf{x} - \mathbf{x}(t)) p_0(\mathbf{x}(0)) d\mathbf{x}(0) \\ &= - \nabla_{\mathbf{x}} \cdot \left(\mathbf{u}_\tau(\mathbf{x}) \underbrace{\int \delta(\mathbf{x} - \mathbf{x}(\tau)) p_0(\mathbf{x}(0)) d\mathbf{x}(0)}_{p_\tau(\mathbf{x})} \right)\end{aligned}$$

[← 説明に戻る](#)

■ 条件付きフロー

$$\int \delta(\tilde{\mathbf{x}} - \tilde{\mathbf{x}}_\tau(\mathbf{x})) \underbrace{p_0(\tilde{\mathbf{x}}_0)}_{\mathcal{N}(\mathbf{0}, I)} d\tilde{\mathbf{x}}_0 = \underbrace{p_\tau(\tilde{\mathbf{x}} | \mathbf{x})}_{\mathcal{N}(\mu_\tau(\mathbf{x}), \sigma_\tau(\mathbf{x})^2)}$$

が条件なので $\dot{\tilde{\mathbf{x}}_\tau(\mathbf{x})} = \mathbf{u}_\tau(\tilde{\mathbf{x}}_\tau \mid \mathbf{x})$ の解は

$$\tilde{\mathbf{x}}_\tau(\mathbf{x}) = \mu_\tau(\mathbf{x}) + \sigma_\tau(\mathbf{x}) \tilde{\mathbf{x}}_0$$

となる。これを τ 微分すれば

$$\begin{aligned} \mathbf{u}_\tau(\tilde{\mathbf{x}}_\tau \mid \mathbf{x}) &= \dot{\mu}_\tau(\mathbf{x}) + \dot{\sigma}_\tau(\mathbf{x}) \underbrace{\mathbf{x}_0}_{(\mathbf{x}_\tau(\mathbf{x}) - \mu_\tau(\mathbf{x})) / \sigma_\tau(\mathbf{x})} \\ &= \frac{\dot{\sigma}_\tau(\mathbf{x})}{\sigma_\tau(\mathbf{x})} (\mathbf{x}_\tau(\mathbf{x}) - \mu_\tau(\mathbf{x})) + \dot{\mu}_\tau(\mathbf{x}) \end{aligned}$$

となる。[← 説明に戻る](#)

■ フローと条件付きフローの関係式

補題4

$$\mathbf{u}_\tau(\tilde{\mathbf{x}}) = \frac{\int \mathbf{u}_\tau(\tilde{\mathbf{x}}|\mathbf{x}) p_\tau(\tilde{\mathbf{x}}|\mathbf{x}) p(\mathbf{x}) d\mathbf{x}}{p_\tau(\tilde{\mathbf{x}})}$$

連続の方程式を比較する。

$$\begin{aligned} -\nabla_{\tilde{\mathbf{x}}} \cdot \left(\underline{\mathbf{u}_\tau(\tilde{\mathbf{x}}) p_\tau(\tilde{\mathbf{x}})} \right) &= \frac{\partial}{\partial \tau} p_\tau(\tilde{\mathbf{x}}) \\ &= \frac{\partial}{\partial \tau} \int p_\tau(\tilde{\mathbf{x}}|\mathbf{x}) p(\mathbf{x}) d\mathbf{x} \\ &= -\nabla_{\tilde{\mathbf{x}}} \cdot \underline{\int \mathbf{u}_\tau(\tilde{\mathbf{x}}|\mathbf{x}) p_\tau(\tilde{\mathbf{x}}|\mathbf{x}) p(\mathbf{x}) d\mathbf{x}} \end{aligned}$$

あとは移行すればOK。 [←ノイズ入りフローマッチング証明に戻る](#)

■ ノイズ入りフローマッチング

ノルム二乗を展開して比較します：

$$\begin{aligned}
 & \langle (\mathbf{v}_{\tau,\theta}(\tilde{\mathbf{x}}) - \mathbf{u}_{\tau}(\tilde{\mathbf{x}}))^2 \rangle_{\tau, p_{\tau}(\tilde{\mathbf{x}})} \\
 &= \left\langle \mathbf{v}_{\tau,\theta}(\tilde{\mathbf{x}})^2 - 2\mathbf{v}_{\tau,\theta}(\tilde{\mathbf{x}}) \cdot \underbrace{\mathbf{u}_{\tau}(\tilde{\mathbf{x}})}_{\int d\mathbf{x} p(\mathbf{x}) [p_{\tau}(\tilde{\mathbf{x}}|\mathbf{x}) \mathbf{u}_{\tau}(\tilde{\mathbf{x}}|\mathbf{x})] / p_{\tau}(\tilde{\mathbf{x}})} \right\rangle + \text{const.} \\
 &= \left\langle \int \underbrace{p_{\tau}(\tilde{\mathbf{x}})}_{\int p_{\tau}(\tilde{\mathbf{x}}|\mathbf{x}) p(\mathbf{x}) d\mathbf{x}} \mathbf{v}_{\tau,\theta}(\tilde{\mathbf{x}})^2 d\tilde{\mathbf{x}} - 2 \int \frac{p_{\tau}(\tilde{\mathbf{x}}) \mathbf{v}_{\tau,\theta}(\tilde{\mathbf{x}}) \cdot \frac{\int \mathbf{u}_{\tau}(\tilde{\mathbf{x}}|\mathbf{x}) p_{\tau}(\tilde{\mathbf{x}}|\mathbf{x}) p(\mathbf{x}) d\mathbf{x}}{p_{\tau}(\tilde{\mathbf{x}})}}{d\tilde{\mathbf{x}}} \right\rangle_{\tau} \\
 &\quad + \text{const.} \\
 &= \langle \mathbf{v}_{\tau,\theta}(\tilde{\mathbf{x}})^2 - 2\mathbf{v}_{\tau,\theta}(\tilde{\mathbf{x}}) \cdot \mathbf{u}_{\tau}(\tilde{\mathbf{x}}|\mathbf{x}) \rangle_{\tau, p_{\tau}(\tilde{\mathbf{x}}|\mathbf{x}) p(\mathbf{x})} + \text{const.} \\
 &= \langle (\mathbf{v}_{\tau,\theta}(\tilde{\mathbf{x}}) - \mathbf{u}_{\tau}(\tilde{\mathbf{x}}|\mathbf{x}))^2 \rangle_{\tau, p_{\tau}(\tilde{\mathbf{x}}|\mathbf{x}) p(\mathbf{x})} + \text{const}'.
 \end{aligned}$$

[← 説明に戻る](#)

