

拡散生成モデルの基石礎:

物理学的な視点から

田中 章詞 (RIKEN AIP / iTHEMS
Keio)

レビ² - 論文 ("Generative Diffusion Models: Principles and Applications")

J. Phys. Soc. Jpn. 94, 031009 (2025) に基づく)

📅 はじめに

生成 AI

- Chat GPT / Gemini / Claude / ...

自己回帰モデル

→ [A][B][C][?] の [?] を出力

主にテキストを生成

- Suno / Udio / ...

???モデル

音楽を生成

- Stable Diffusion / Mid Journey / DALL·E 3 / ...

拡散モデル 今日のターゲット



主に画像を生成

■ 本日の内容

■ 1. 生成モデルとは？

■ 2. 拡散モデルとは

■ 3. 粒子と分布の対応 (2の1)

■ 4. 粒子と分布の対応 (2の2)

■ 1. 生成モデルとは？

例：私が子供の頃



「学習データ」



⇒



「生成データ」

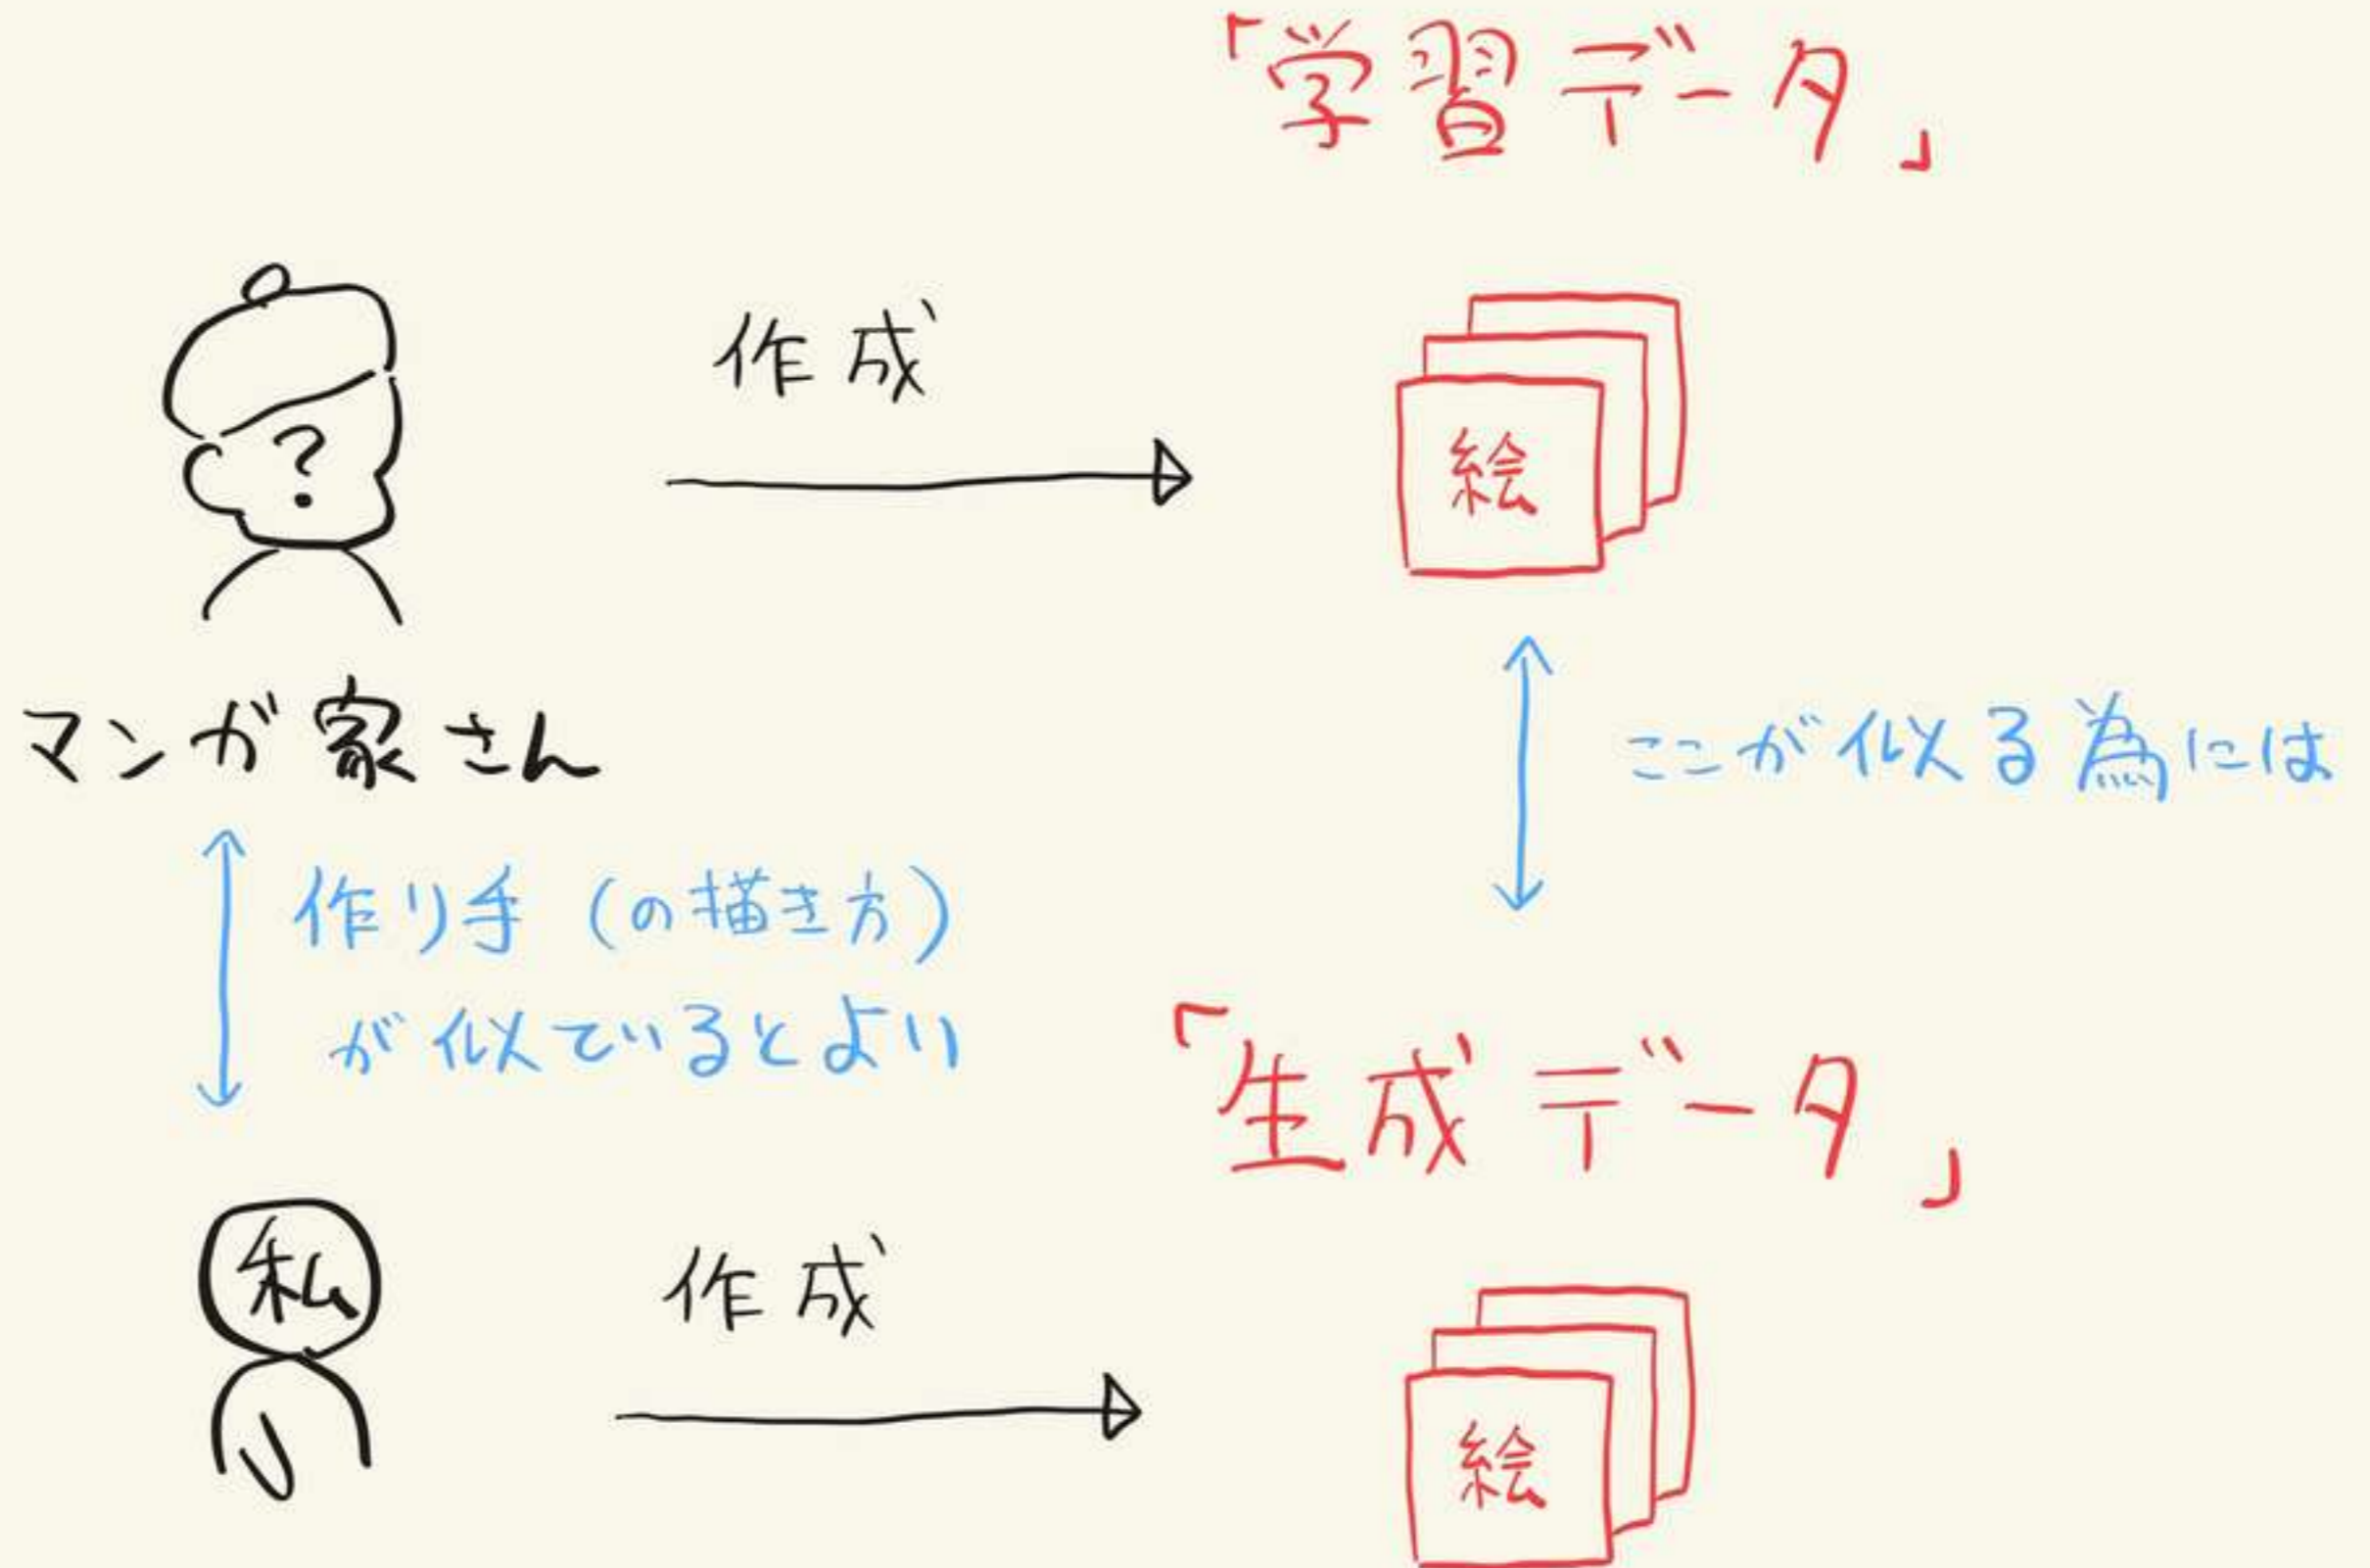


似ているけど別物



■ 1. 生成モデルとは？

例：私が子供の頃



■ 1. 生成モデルとは？

生成モデルの"定義"

$P(x)$ の値は未知なことが多い

「学習データ」

標本抽出

~~$P(x)$~~

x_1, x_2, x_3, \dots

~~確率分布~~

どうやって似せるか
"

「学習」

ここが似る為には

分布

が似ているとよい

「生成データ」

生成モデル

\Rightarrow

$Q(y)$


標本抽出

y_1, y_2, y_3, \dots

■ 1. 生成モデルとは？





例

どの面がどれ位出るか
あからずい



振る

「学習データ」

出た面(x)				
出た回数	3	1	6	0





(てきとうな形の) 4面サイコロ





出た回数
振った回数

なぜこれぞ
良いか？

「生成データ」

プログラムなど


出た面(x)				
Q(x)	$\frac{3}{10}$	$\frac{1}{10}$	$\frac{6}{10}$	0

出た面(x)				
出た回数	2	1	7	0

■ 1. 生成モデルとは？





例

どの面がどれ位出るか
わからない



振る

「学習データ」

出た面(x)				
出た回数	3	1	6	0

(てきとうな形の) 4面サイコロ

出た回数
振った回数

なぜこれ
良いか？

$Q(x)$ の値を決めたい

→ $Q(x)$ で面が出ていると仮定

→ 確率 $Q(\bullet)$ の事象が N 回起こる確率 = $Q(\bullet) \times Q(\bullet) \times \dots \times Q(\bullet)$


$Q(\bullet)^N$

→ 「学習データ」 が出てくる確率 $\propto Q(\text{red})^3 \times Q(\text{blue})^1 \times Q(\text{green})^6 \times Q(\text{yellow})^0$

■ 1. 生成モデルとは？

例

どの面がどれ位出るか
わからない



振る

「学習データ」

出た面(x)	●	●	●	●
出た回数	3	1	6	0

(てきとうな形の) 4面サイコロ

出た回数
振った回数

なぜこれぞ
良いか？

Q(x) の値を決めたい

→ 「学習データ」がでてくる確率 $\propto Q(\text{●})^3 \times Q(\text{●})^1 \times Q(\text{●})^6 \times Q(\text{●})^0$

3. これが出てくる！

2. この値を
大きくしたい

Q(x)は確率なので: $Q(\text{●}) + Q(\text{●}) + Q(\text{●}) + Q(\text{●}) = 1$


1. この制約
を満たす

最尤推定 (Maximum Likelihood Estimation, MLE) という.

■ 1. 生成モデルとは?

一般化

面 x が出る確率 $P(x)$



N回振る

「学習データ」

出た面 (x)	●	●	●	●
出た回数	n_{\bullet}	n_{\bullet}	n_{\bullet}	n_{\bullet}

(てきとうな形の) 四面サイコロ

$Q(x)$ の値を決めたい

→ 「学習データ」がでてくる確率

組み合わせの数

$$= {}_N C_{n_{\bullet} n_{\bullet} n_{\bullet} n_{\bullet}} \times Q(\bullet) \times Q(\bullet) \times Q(\bullet) \times Q(\bullet)$$

$(N \rightarrow \infty)$
→ $e^{N \times \left(- \sum_{x \in \{\bullet, \bullet, \bullet, \bullet\}} P(x) \log \frac{P(x)}{Q(x)} \right)}$ \approx $KL(P \parallel Q)$ "Kullback-Leibler
ダイバージェンス"


重要な性質

- $KL(P \parallel Q) \geq 0$
- 等号は $P=Q$ のときのみ成立

1. 生成モデルとは？

一般化

面 x が出る確率 $P(x)$



N回振る

「学習データ」

出た面 (x)	●	●	●	●
出た回数	n_{\bullet}	n_{\bullet}	n_{\bullet}	n_{\bullet}

(てきとうな形の) 四面サイコロ

$Q(\bullet)^{n_{\bullet}} \times Q(\bullet)^{n_{\bullet}} \times Q(\bullet)^{n_{\bullet}} \times Q(\bullet)^{n_{\bullet}}$
を大きくする <small>し</small>かできない。

本当は

$KL(P \parallel Q) \geq 0$

を小さくしたい

(0で $P=Q$ になる)

($N \rightarrow \infty$)

$\frac{n_{\bullet}}{N} \log \frac{1}{Q(\bullet)} + \frac{n_{\bullet}}{N} \log \frac{1}{Q(\bullet)} + \frac{n_{\bullet}}{N} \log \frac{1}{Q(\bullet)} + \frac{n_{\bullet}}{N} \log \frac{1}{Q(\bullet)}$

を小さくする

「log 3 4 など」

$Q(x)$

出た面 (x)	●	●	●	●
出た回数	-	-	-	-

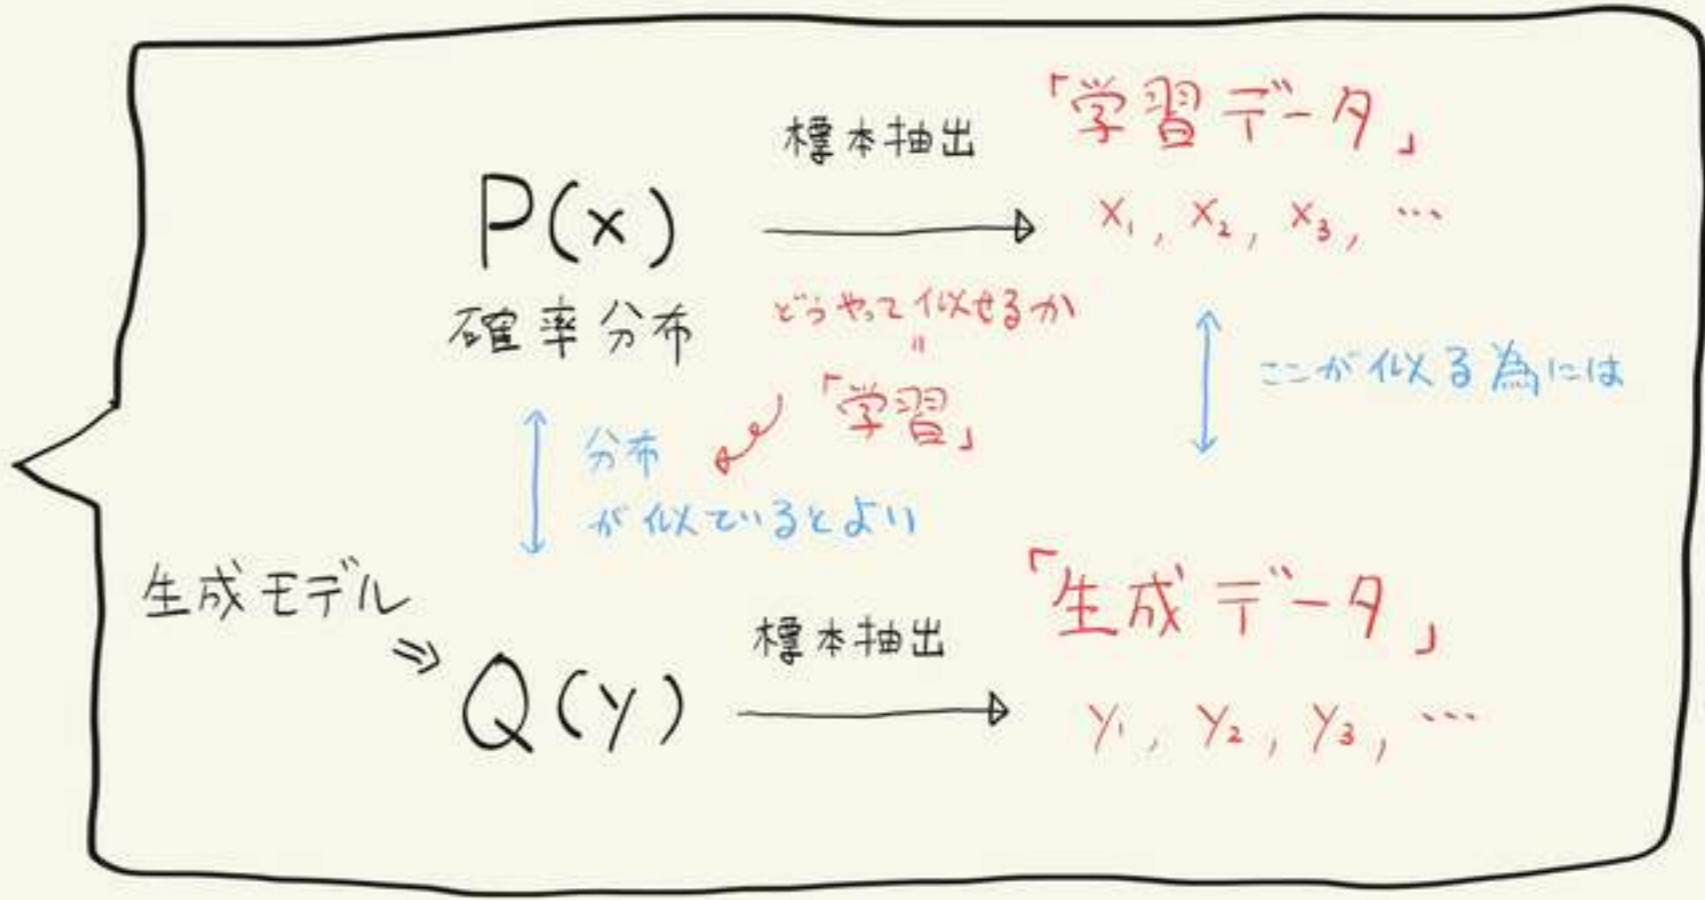
■ 本日の内容

■ 1. 生成モデルとは？

■ 2. 拡散モデルとは

■ 3. 粒子と分布の対応 (2の1)

■ 4. 粒子と分布の対応 (2の2)




2. 拡散モデルとは

画像 = 高次元空間上の点

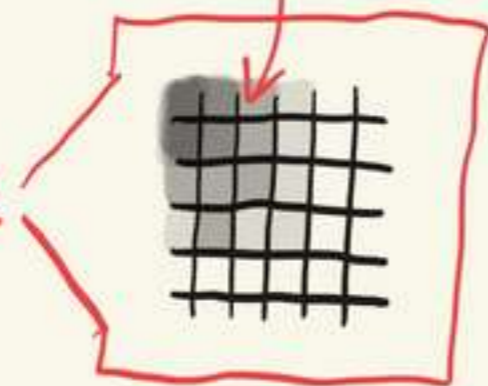
白黒の濃さ



各相の中には 0~255 の値



拡大すると

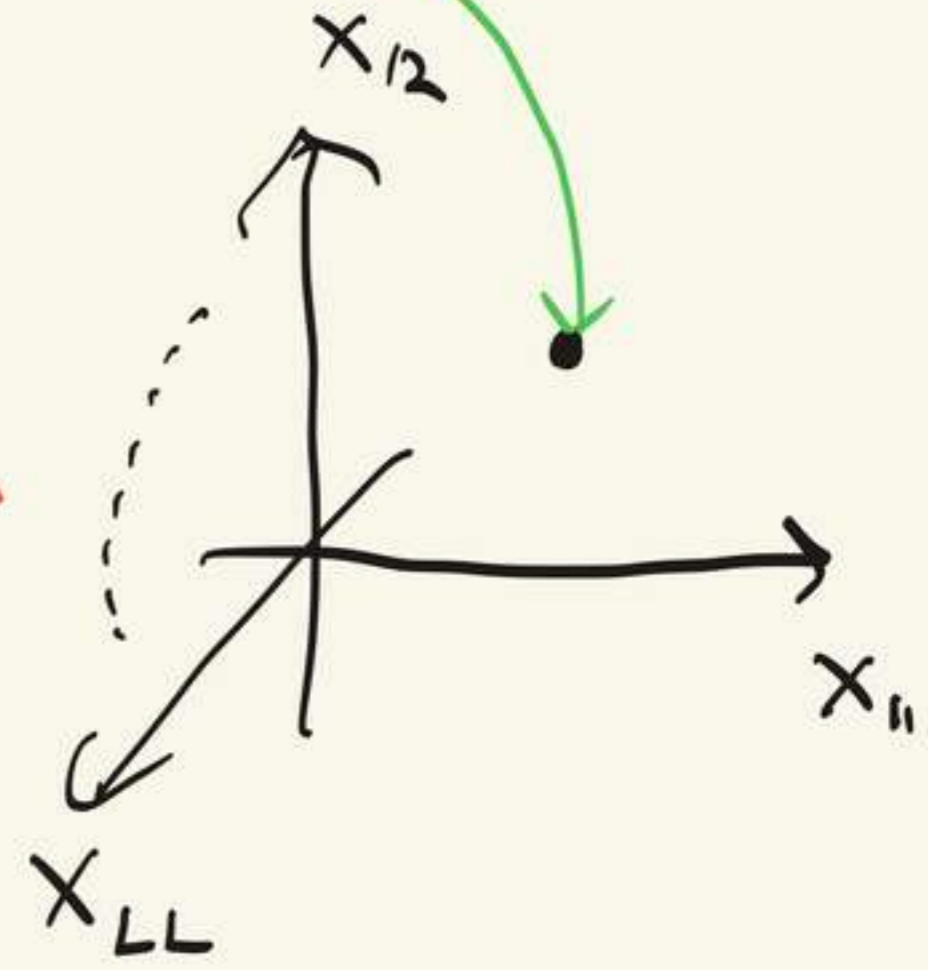


画像は $L \times L$ 次元空間上の一点に対応

X_{11} X_{12} X_{13} ... X_{1L}
 X_{21} X_{22} X_{23} ... X_{2L}
 \vdots \vdots \vdots \ddots \vdots
 X_{L1} X_{L2} X_{L3} ... X_{LL}

$= (X_{11}, \dots, X_{21}, \dots, X_{L1}, \dots)$


(x, y, z) の一般化



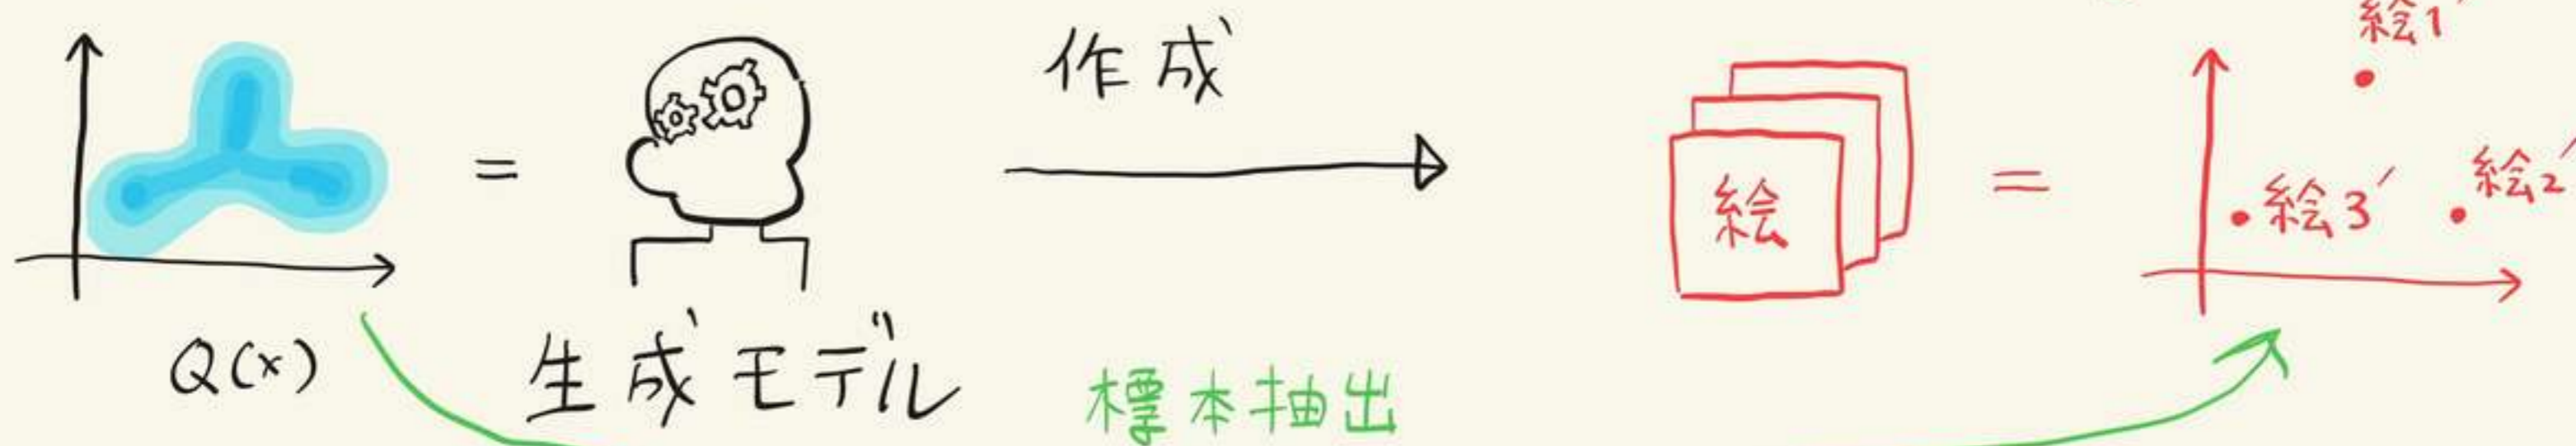
2. 拡散モデルとは

画像 = 高次元空間上の点

「学習データ」



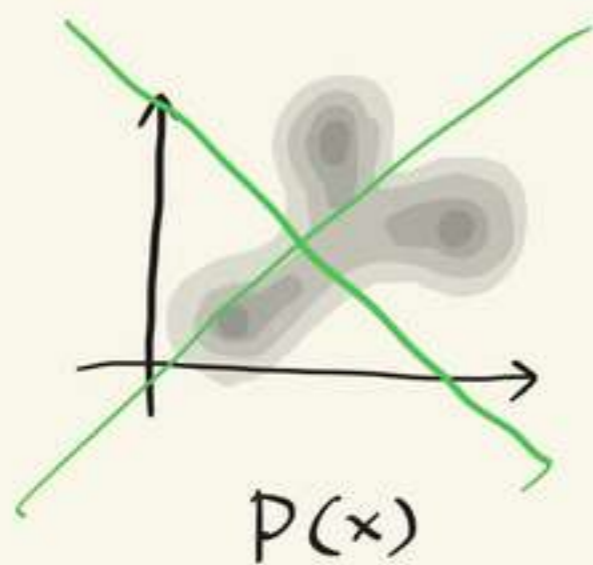
「生成データ」



2. 拡散モデルとは

画像 = 高次元空間上の点


この分布の
形や値は
未知



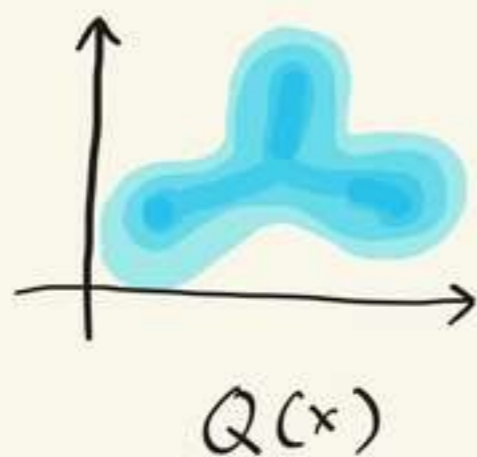
標本抽出



「学習データ」




どうやって
似せるか?



標本抽出



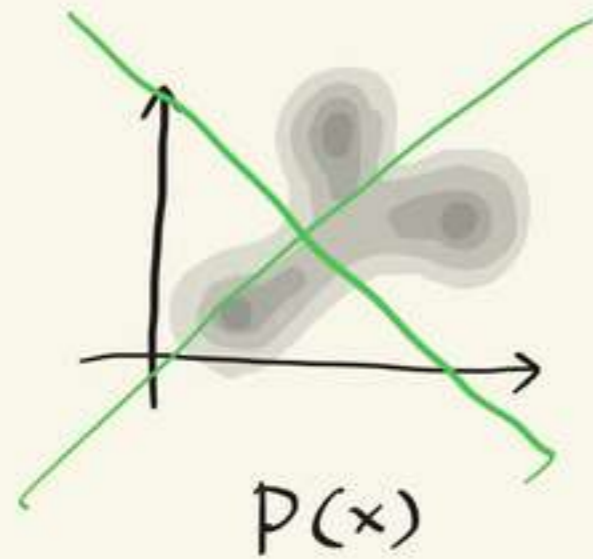
「生成データ」



2. 拡散モデルとは


最尤推定 (MLE)

この分布の
形や値は
未知

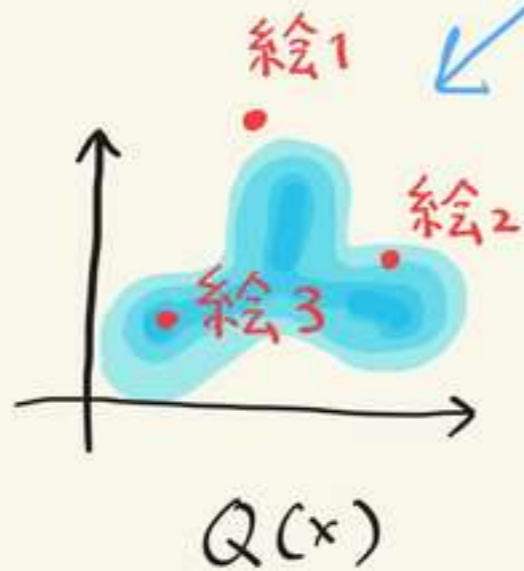


標本抽出

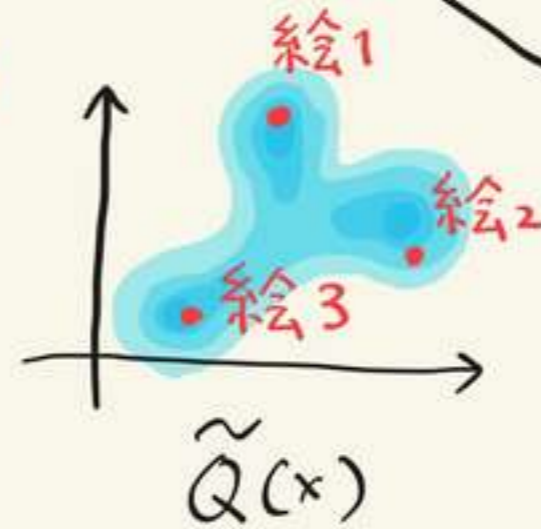
「学習データ」



1. 「学習データ」を「重ねる」



2. 山を変形




「一見良さそうだが」
ここが「難しい」
なぜなら

$$1 = \int Q(x) dx$$

を保たないといけないから。


2. 拡散モデルとは

拡散モデルのヒト型




$$P(x) = \frac{e^{-V(x)}}{Z}$$

ポテンシャル
エネルギー



$$\rightarrow -\nabla_x V(x) = F(x) \text{ は「力」}$$



$$Q(x)$$

1. 積分して1
になるように
分布をおく

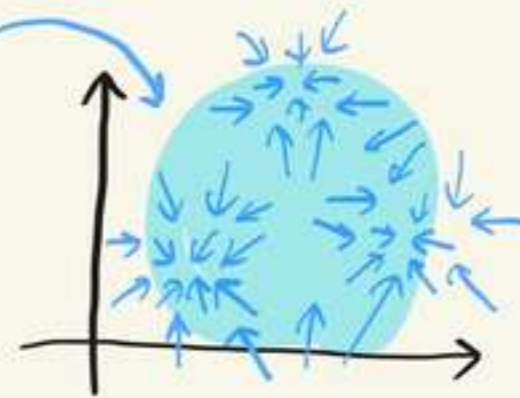
2. 各点をベクトル場
で flow させる
(流す)

ここを合わせるようにすると

$$1 = \int Q(x) dx$$

を考えなくて良くなる!


なぜか?



$$\text{ベクトル場 } S(x)$$


2. 拡散モデルとは

拡散モデルのヒト型



$$P(x) = \frac{e^{-V(x)}}{Z}$$

ポテンシャル
エネルギー



$$Q(x)$$

具体的には

$$\int P(x) (S(x) + \nabla_x V(x))^2 dx \downarrow \text{を考える.}$$

$$= \int P(x) \{ S(x)^2 + 2 \underbrace{S(x) \cdot \nabla_x V(x)}_{\text{部分積分}} \} dx + \text{定数}$$

$$= \int P(x) \{ S(x)^2 + 2 \nabla_x \cdot S(x) \} + \text{定数}$$

} 近似


スコアマッチング

$$\frac{1}{N} \sum_{x \sim Q} \{ S(x)^2 + 2 \nabla_x \cdot S(x) \} \downarrow$$

2. 拡散モデルとは

拡散モデルのヒト型


直観的な説明





$$P(x) = \frac{e^{-V(x)}}{Z}$$

ポテンシャル
エネルギー

$$\rightarrow -\nabla_x V(x) = F(x)$$



Q(x)



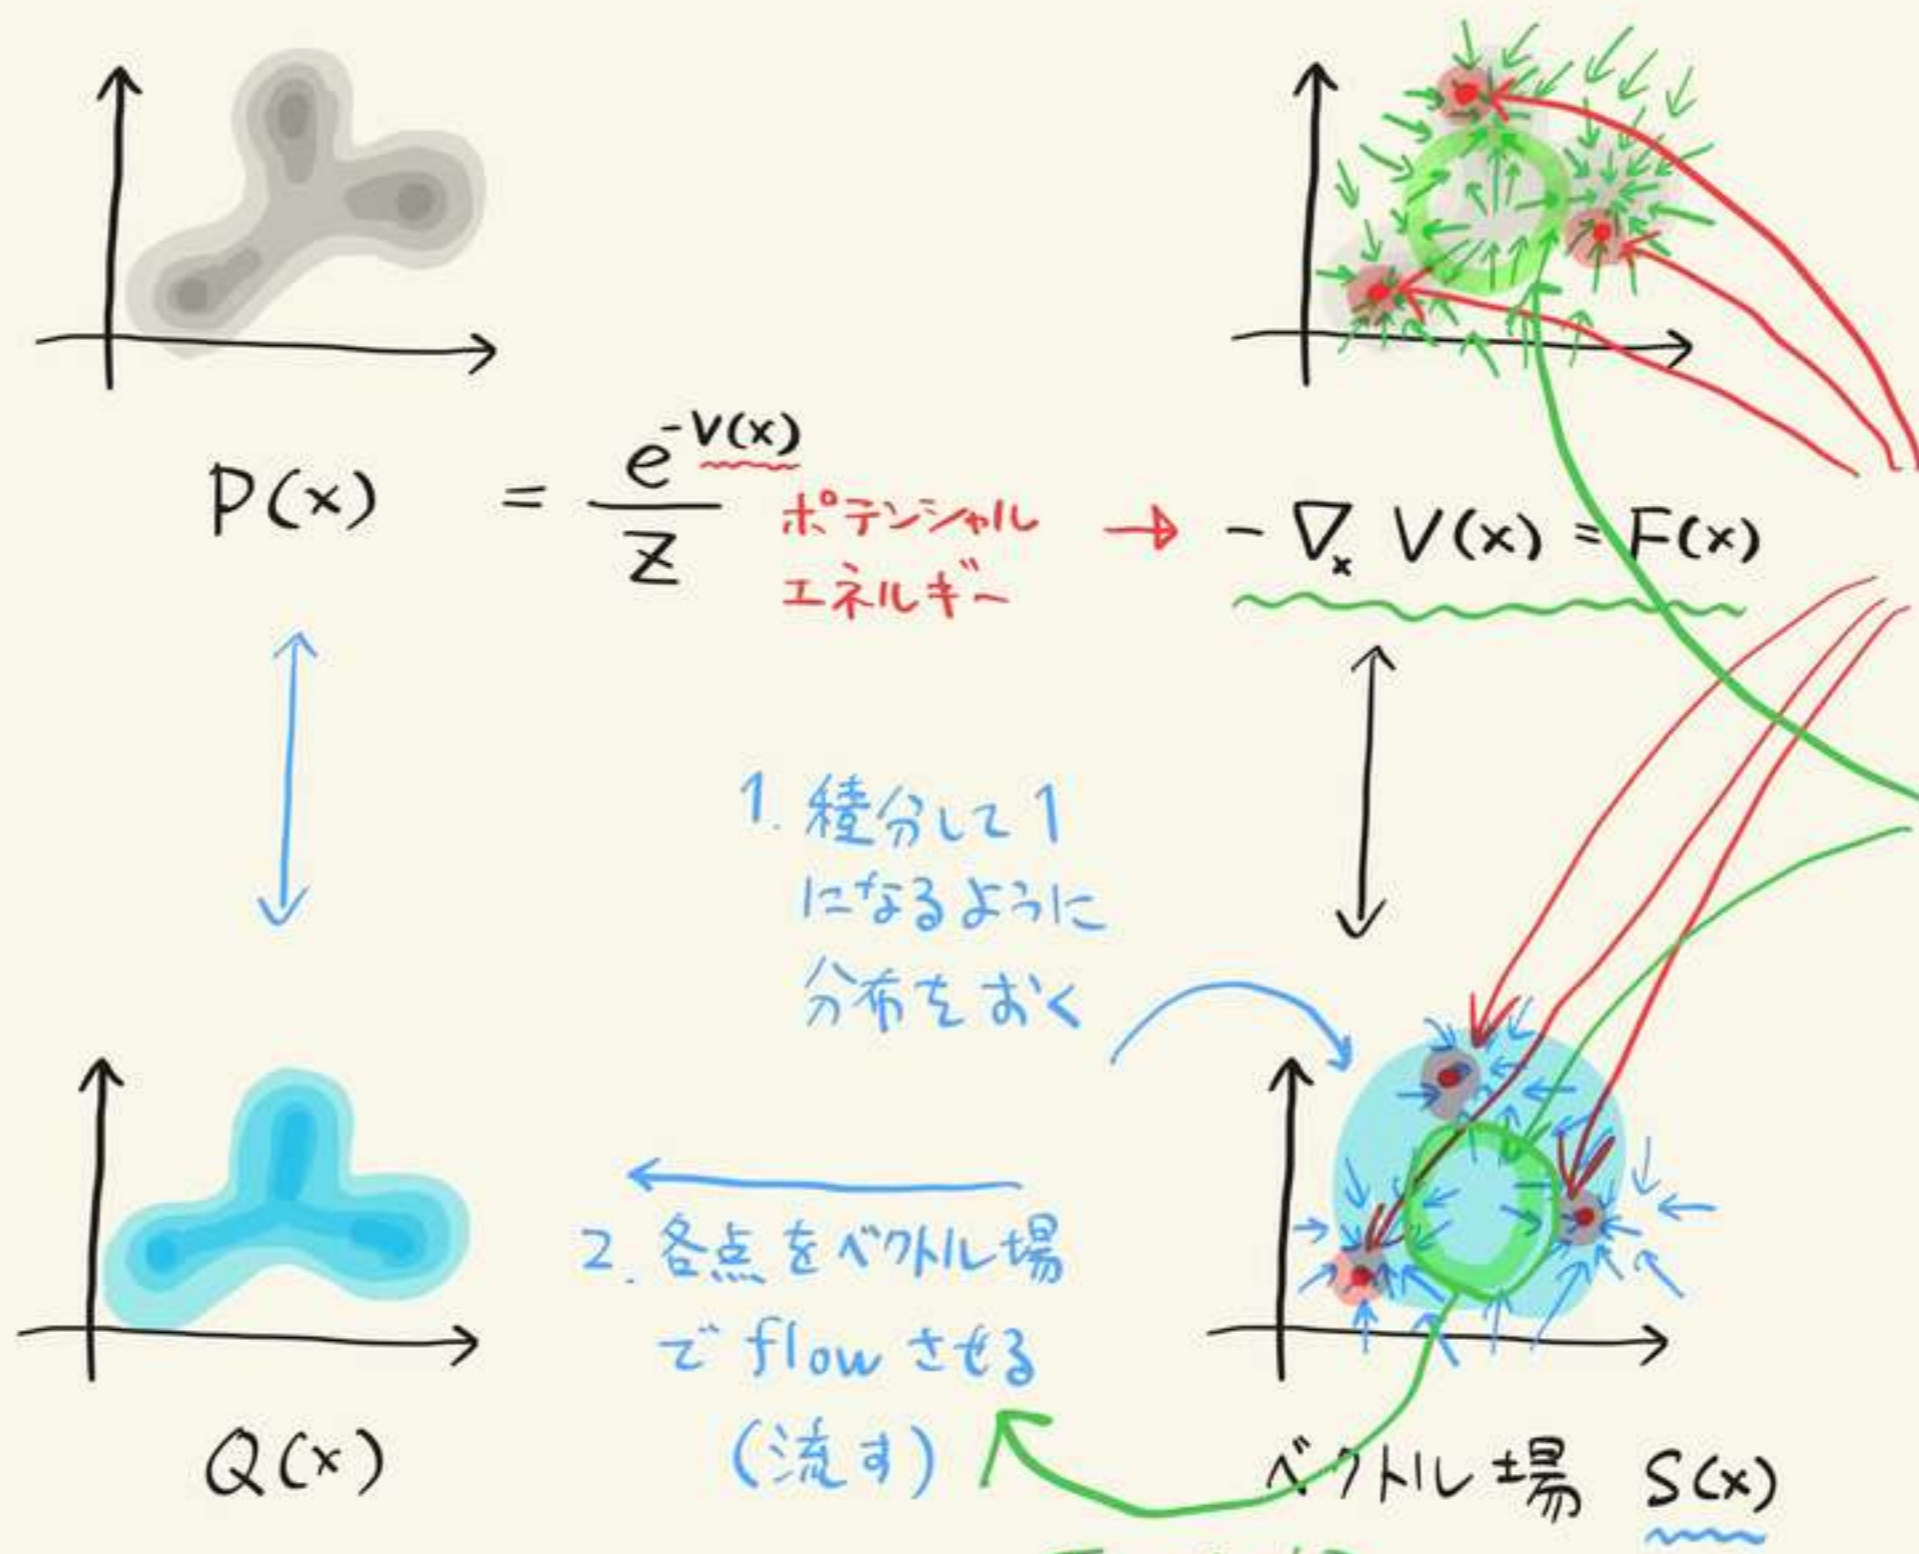
ベクトル場 S(x)

2. 「学習データ」
上の「力」 \nearrow と
モデル \nearrow を合わせる

1. ある程度の
連続性を仮定

2. 拡散モデルとは

素朴なやり方の弱点



$$P(x) = \frac{e^{-V(x)}}{Z} \quad \text{ポテンシャルエネルギー} \rightarrow -\nabla_x V(x) = F(x)$$

1. 積分して1になるように分布をおく

2. 各点をバケル場で flow させる (流す)

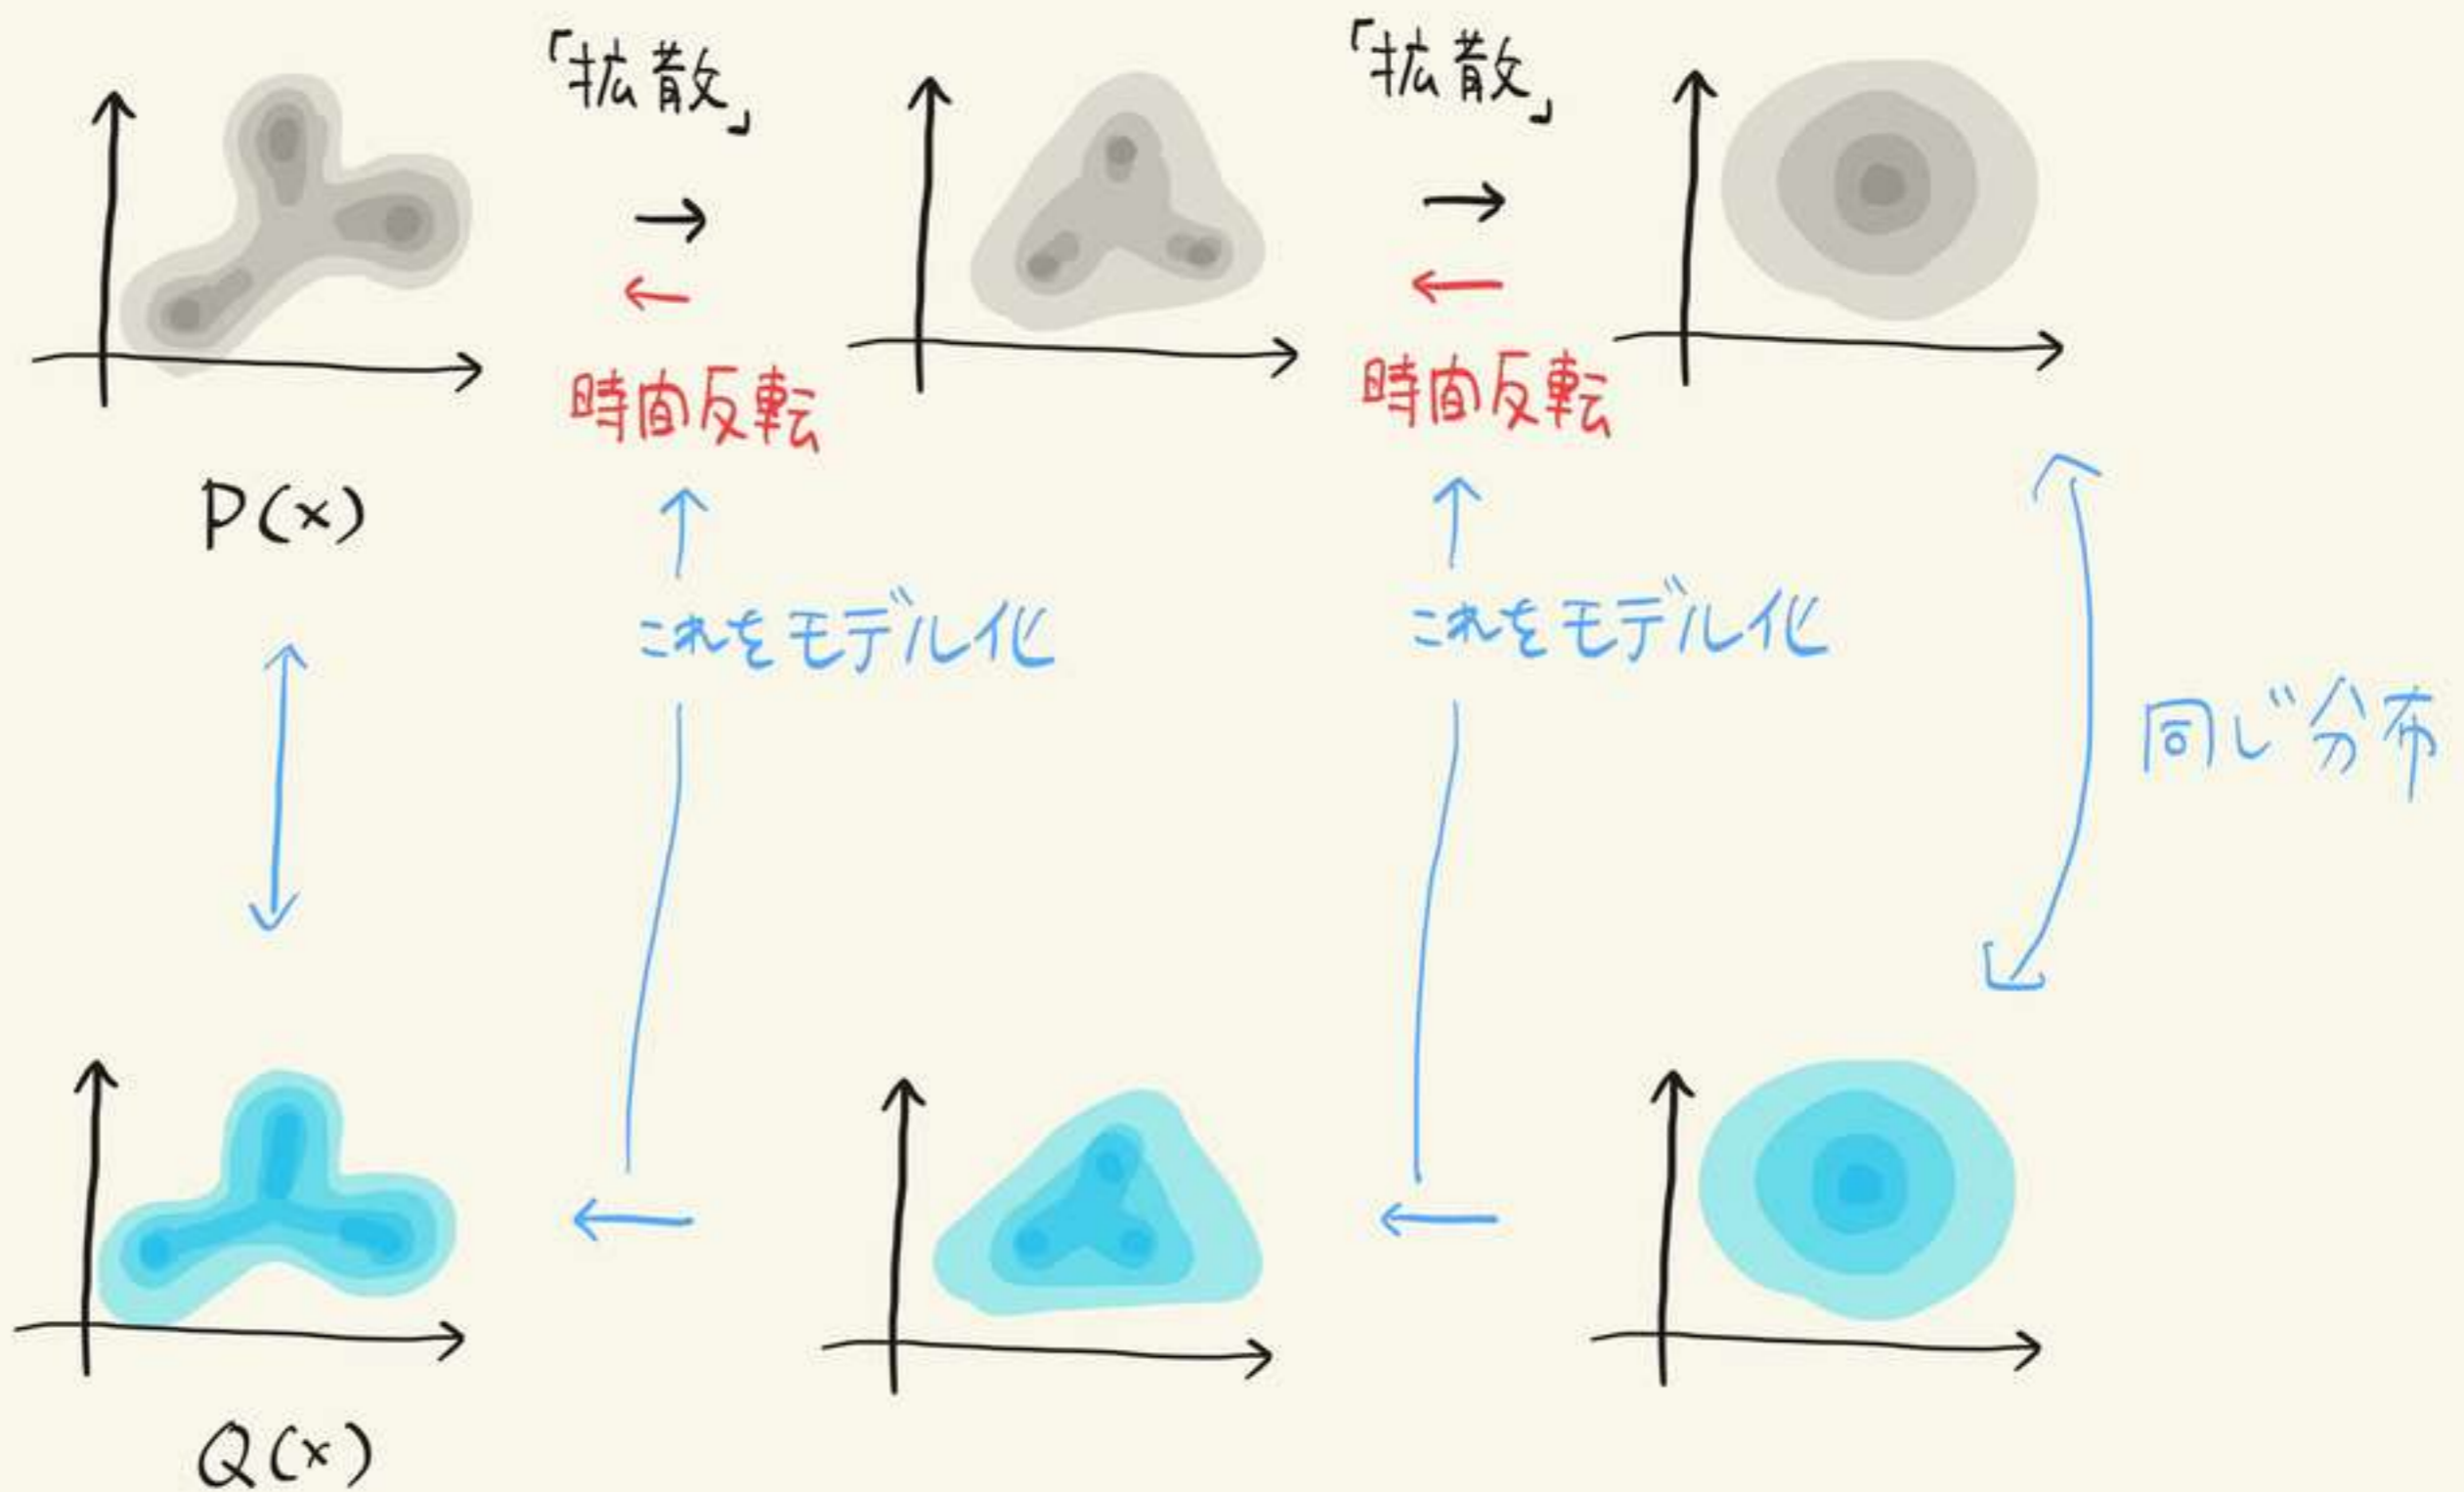
悪さをする

この周りは合うが... (データ周り)

データがない場所についての保障がない

2. 拡散モデルとは

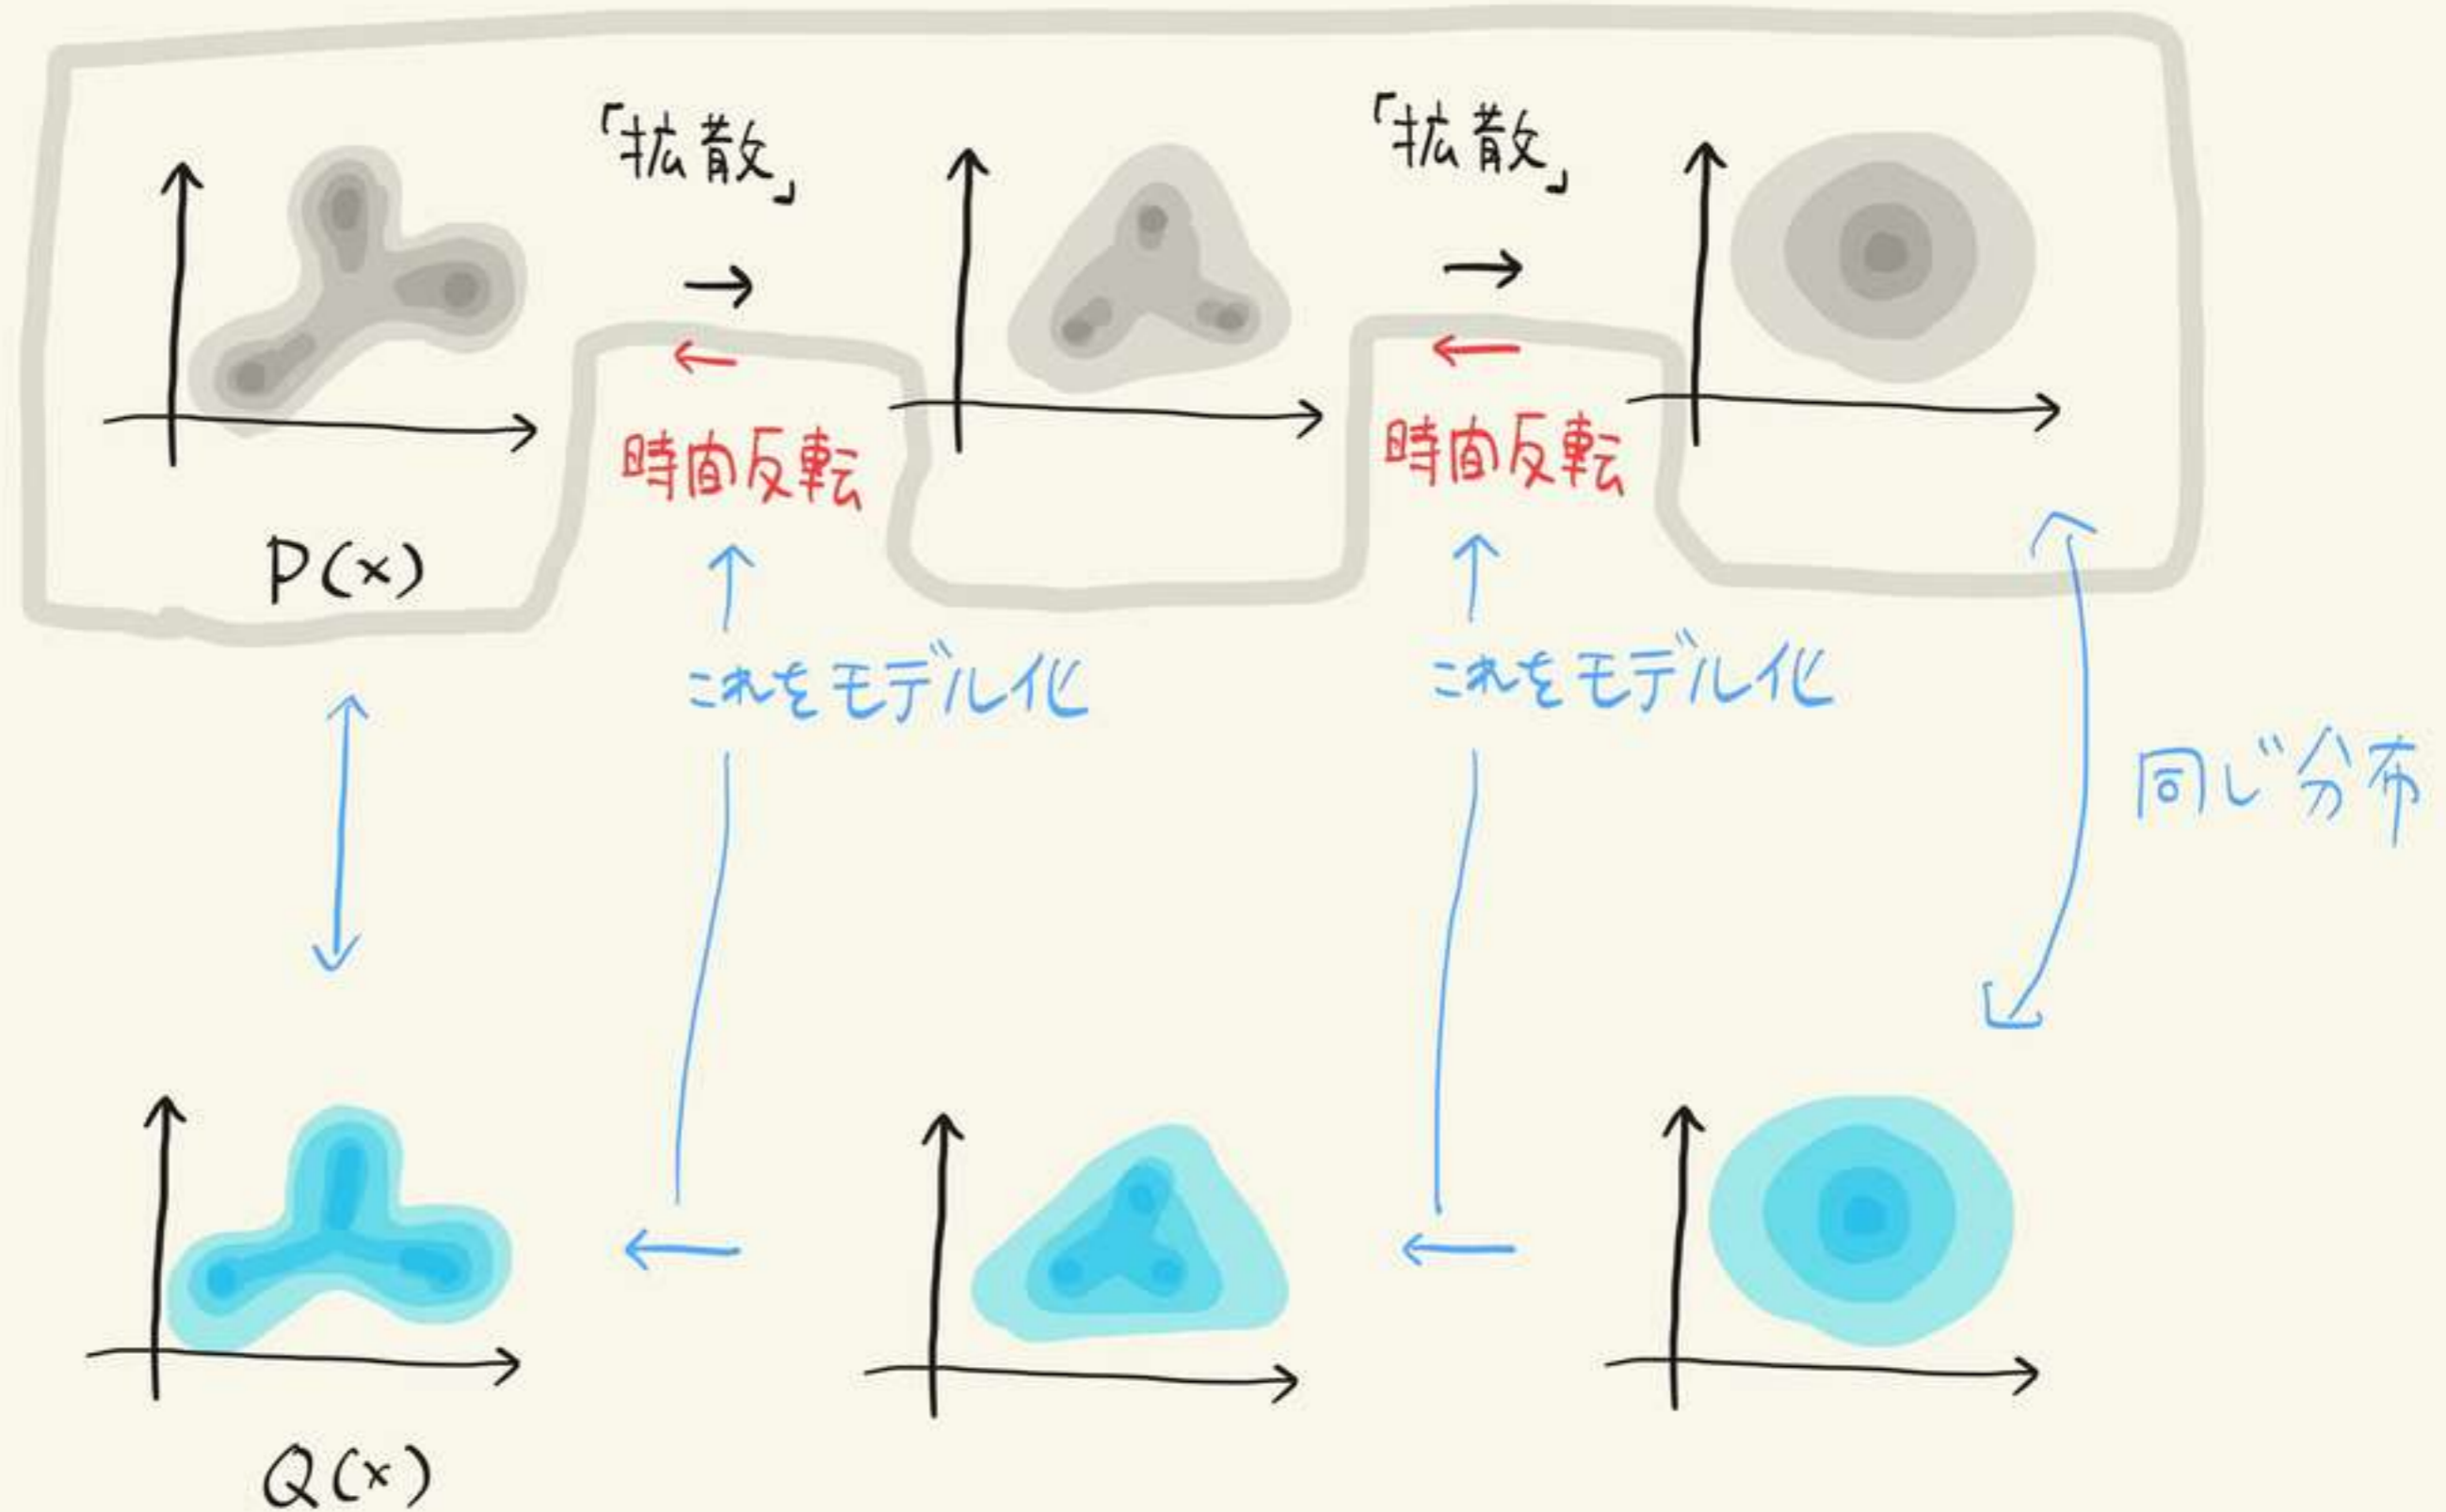
拡散モデル (本物)



2. 拡散モデルとは

拡散モデル (本物)

この部分



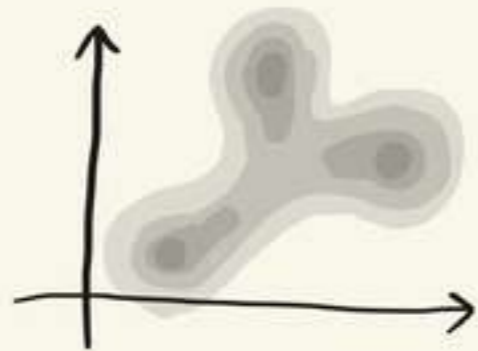
2. 拡散モデルとは

拡散モデル (本物)


「時間」 t



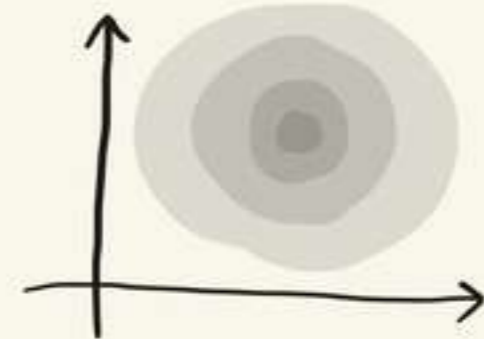
$P_t(\vec{x})$



「拡散」



「拡散」



$P_0(x)$

$P_{t_1}(\vec{x})$

$P_{t_2}(\vec{x})$

対応がある


たくさん
↓
標本をとる

たくさん
↓
標本をとる


たくさん
↓
標本をとる

x: 標本

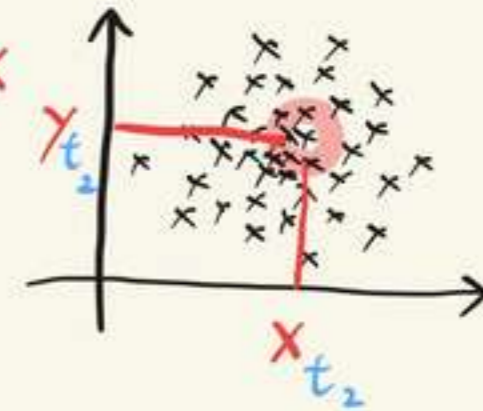
$\vec{x}_t = (x_t, y_t)$



点が動く



点が動く




2. 拡散モデルとは

拡散モデル (本物)

「時間」 t



$P_t(\vec{x})$



分布の方程式
「連続の方程式」


$$\frac{\partial}{\partial t} P_t(\vec{x}) = -\nabla_{\vec{x}} \cdot (P_t(\vec{x}) \vec{V}_t(\vec{x}))$$

対応がある

ここを定めると
拡散のしかたが
決まる

x : 標本

$$\vec{x}_t = (x_t, y_t)$$



粒子の方程式


$$d\vec{x}_t = \underbrace{\vec{f}_t(\vec{x}_t)}_{\text{drift}} dt + \underbrace{g_t d\vec{w}_t}_{\text{diffusion}}$$

ここを定めると決まる

2. 拡散モデルとは

拡散モデル (本物)

「時間反転」



$P_t(\vec{x})$

分布の方程式
「連続の方程式」

$$\frac{\partial}{\partial t} P_t(\vec{x}) = -\nabla_x \cdot (P_t(\vec{x}) \vec{V}_t(\vec{x}))$$


これが「学習」
できれば
よい

対応が
ある

ここを定めると
拡散のしかたが
決まる

x: 標本

$$\vec{x}_t = (x_t, y_t)$$




粒子の方程式

$$d\vec{x}_t = \vec{f}_t(\vec{x}_t)dt + g_t d\vec{w}_t$$

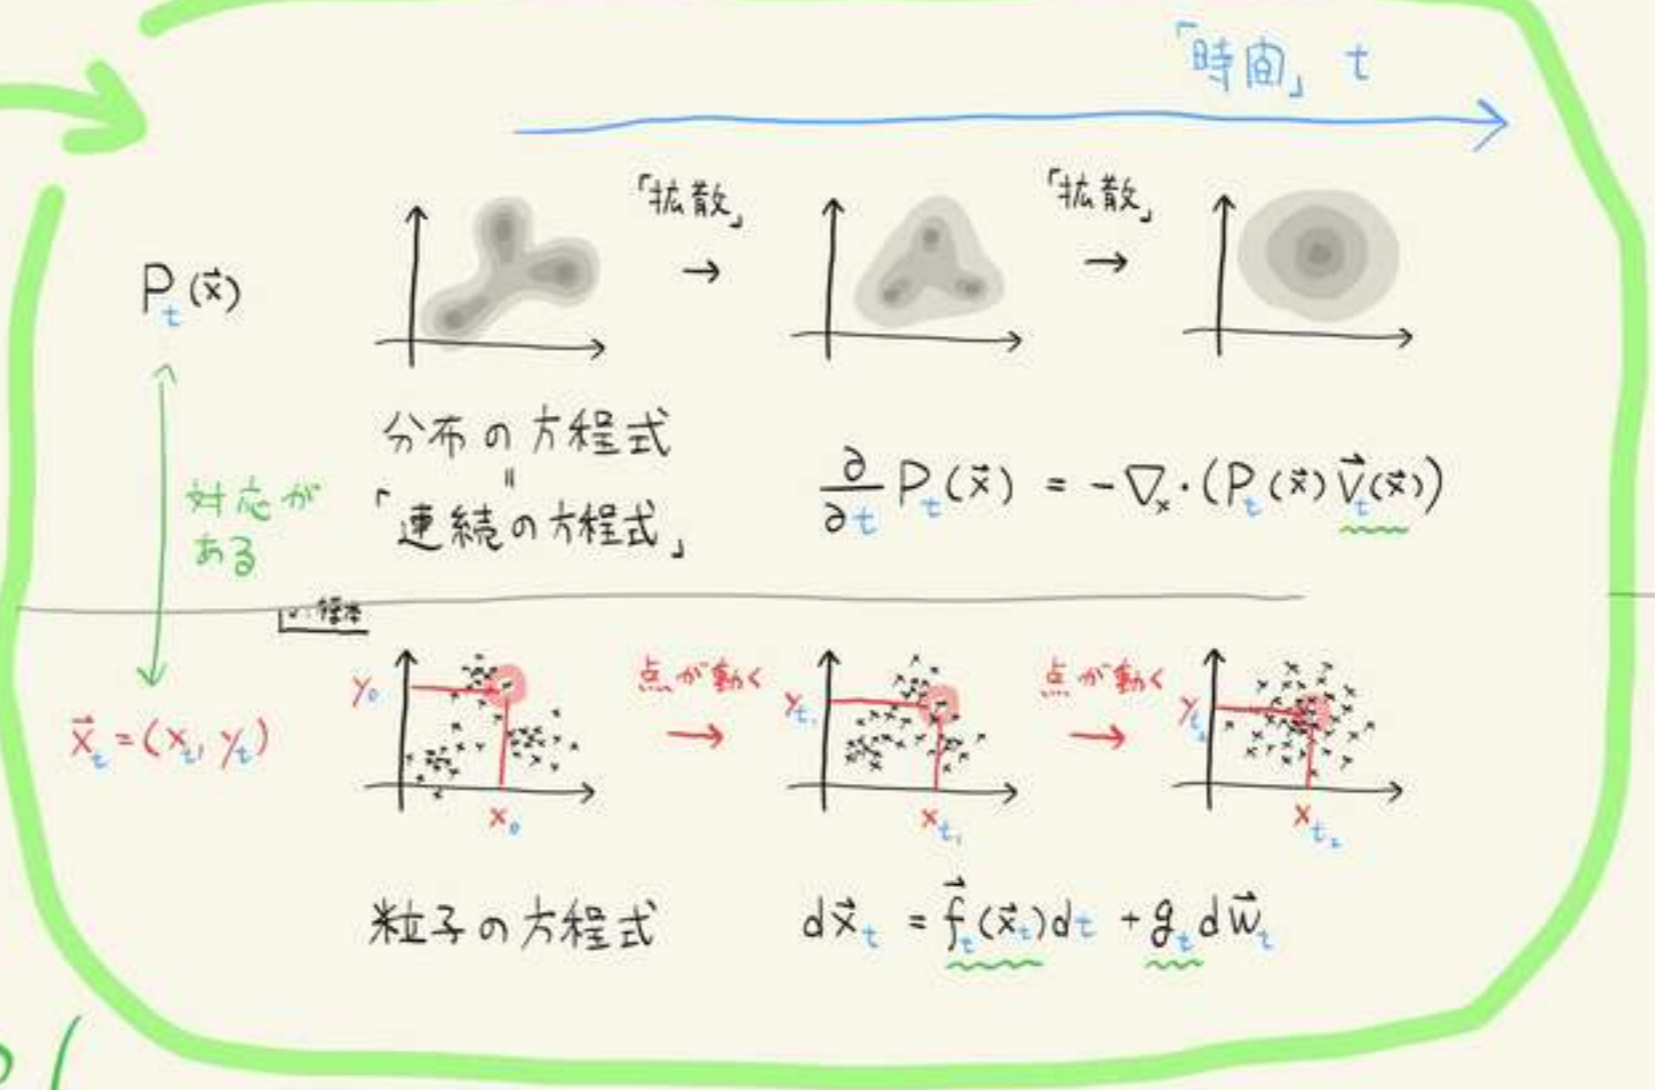

ここを定めると決まる

■ 本日の内容

■ 1. 生成モデルとは?



■ 2. 拡散モデルとは



■ 3. 粒子と分布の対応 (2の1)


■ 4. 粒子と分布の対応 (2の2)

3. 粒子と分布の対応 (その1)

拡散モデル (本物)

「時間」 t

$P_t(\vec{x})$




分布の方程式
「連続の方程式」

$$\frac{\partial}{\partial t} P_t(\vec{x}) = -\nabla_x \cdot (P_t(\vec{x}) \vec{V}_t(\vec{x}))$$

対応がある

\times : 標本

$$\vec{x}_t = (x_t, y_t)$$



粒子の方程式

$$d\vec{x}_t = \vec{f}_t(\vec{x}_t) dt + g_t d\vec{w}_t$$

この対応も等しく。

3. 粒子と分布の対応 (その1)

確率微分方程式 (SDE)



$$d\vec{x}_t = \underbrace{\vec{f}_t(\vec{x}_t)}_{\text{ドリフト}} dt + \underbrace{g_t}_{\text{ノイズ}} d\vec{w}_t$$

だいたい
 $\sqrt{dt} \times \vec{\epsilon}_t$ と見ると
よ
 $N(0, I)$
 (ガウスノイズ)

\Downarrow (だいたい)

$$\vec{x}_{t+dt} = \underbrace{\vec{x}_t + \vec{f}_t(\vec{x}_t) dt}_{\vec{\mu}_{t,dt}(\vec{x}_t)} + \underbrace{g_t \sqrt{dt} \vec{\epsilon}_t}_{\sigma_{t,dt}}$$

$\vec{\mu}_{t,dt}(\vec{x}_t)$

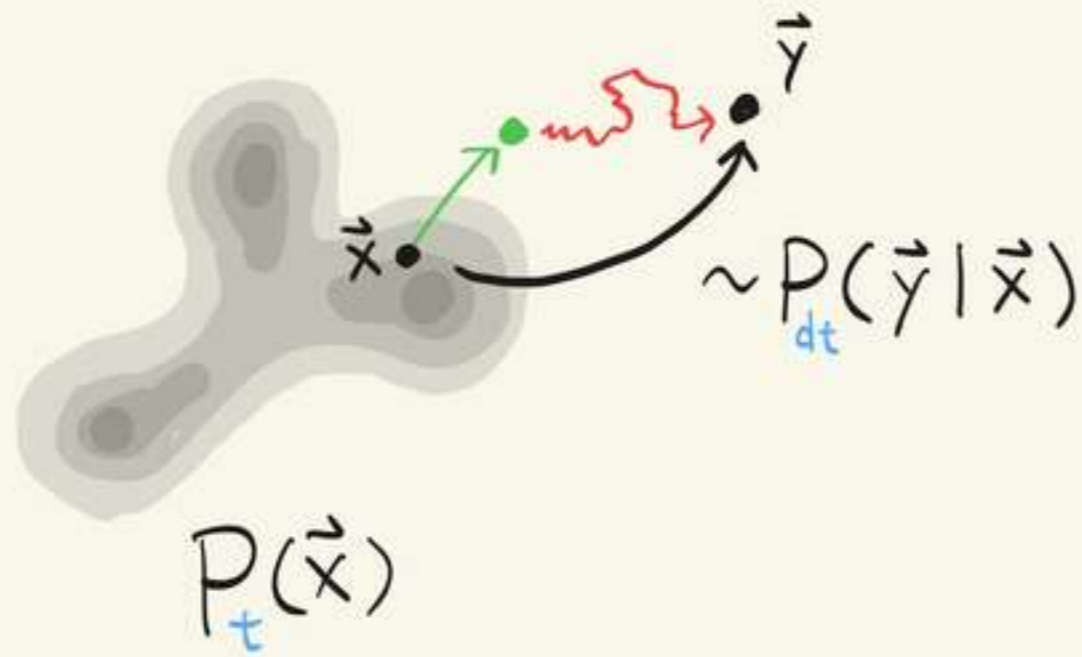
$\sigma_{t,dt}$

$(t+dt \leftarrow t)$ の時内発展

$$\sim N(\vec{x}_{t+dt} \mid \vec{\mu}_{t,dt}(\vec{x}_t), \sigma_{t,dt} I) =: P_{dt}(\vec{x}_{t+dt} \mid \vec{x}_t)$$

3. 粒子と分布の対応 (その1)

SDE $\rightarrow P_t(\vec{x})$ の方程式



全2の \vec{x} からの影響を加味

\vec{x} について積分

$P_{t+dt}(\vec{y})$ になるはず

$$P_{t+dt}(\vec{y}) = \int P_{t+dt}(\vec{y}|\vec{x}) P_t(\vec{x}) d\vec{x}$$


Fokker-Planck 方程式 \downarrow dt が小さいとして1次まで Taylor 展開

$$\frac{\partial}{\partial t} P_t(\vec{x}) = -\nabla_{\vec{x}} \cdot (P_t(\vec{x}) \vec{f}_t(\vec{x})) + \frac{g_t^2}{2} \nabla_{\vec{x}}^2 P_t(\vec{x})$$

3. 粒子と分布の対応 (その1)

SDE $\rightarrow P_t(\vec{x})$ の方程式

「時間」 t




$$\frac{\partial}{\partial t} P_t(\vec{x}) = -\nabla_{\vec{x}} \cdot (P_t(\vec{x}) \vec{f}_t(\vec{x})) + \frac{\sigma_t^2}{2} \nabla_{\vec{x}}^2 P_t(\vec{x})$$

対応がある

x: 標本

$$\vec{x}_t = (x_t, y_t)$$



粒子の方程式


$$d\vec{x}_t = \vec{f}_t(\vec{x}_t) dt + g_t d\vec{w}_t$$

この対応も等しい!

3. 粒子と分布の対応 (その1)

時内反転?


「時間反転」



$$1. \frac{\partial}{\partial t} P_t(\vec{x}) = -\nabla_{\vec{x}} \cdot (P_t(\vec{x}) \vec{f}_t(\vec{x})) + \frac{g_t^2}{2} \nabla_{\vec{x}}^2 P_t(\vec{x})$$

対応がある

x: 標本



$$\vec{x}_t = (x_t, y_t)$$


2. 粒子の方程式

$$d\vec{x}_t = \vec{f}_t(\vec{x}_t) dt + g_t d\vec{w}_t$$

3. 粒子と分布の対応 (その1)

時間反転?

「時間反転」



$$1. \frac{\partial}{\partial t} P_t(\vec{x}) = -\nabla_{\vec{x}} \cdot (P_t(\vec{x}) \vec{f}_t(\vec{x})) + \frac{g^2}{2} \nabla_{\vec{x}}^2 P_t(\vec{x})$$

$$\bar{t} := -t \Rightarrow \frac{\partial}{\partial \bar{t}} P_t(\vec{x}) = +\nabla_{\vec{x}} \cdot (P_t(\vec{x}) \vec{f}_t(\vec{x})) - \frac{g^2}{2} \nabla_{\vec{x}}^2 P_t(\vec{x})$$

↑
この符号は、ここに
吸収できる


↑
この符号は
正でない

Fokker-Planck 方程式
にならない

3. 粒子と分布の対応 (2の1)

時間反転?

「時間反転」



$$1. \frac{\partial}{\partial t} P_t(\vec{x}) = -\nabla_{\vec{x}} \cdot (P_t(\vec{x}) \vec{f}_t(\vec{x})) + \frac{g_t^2}{2} \nabla_{\vec{x}}^2 P_t(\vec{x})$$

$$\bar{t} := -t \Rightarrow$$

$$\frac{\partial}{\partial \bar{t}} P_t(\vec{x}) = +\nabla_{\vec{x}} \cdot (P_t(\vec{x}) \vec{f}_t(\vec{x})) - \frac{g_t^2}{2} \nabla_{\vec{x}}^2 P_t(\vec{x})$$


$$- \frac{g_t^2}{2} \nabla_{\vec{x}}^2 P_t(\vec{x}) \quad + \frac{g_t^2}{2} \nabla_{\vec{x}}^2 P_t(\vec{x})$$

合書せる

3. 粒子と分布の対応 (2の1)

時間反転?

「時間反転」



$$1. \frac{\partial}{\partial t} P_t(\vec{x}) = -\nabla_{\vec{x}} \cdot (P_t(\vec{x}) \vec{f}_t(\vec{x})) + \frac{g_t^2}{2} \nabla_{\vec{x}}^2 P_t(\vec{x})$$

$$\bar{t} := -t \Rightarrow$$

$$\frac{\partial}{\partial \bar{t}} P_t(\vec{x}) = +\nabla_{\vec{x}} \cdot (P_t(\vec{x}) \vec{f}_t(\vec{x}))$$

$$-g_t^2 \nabla_{\vec{x}}^2 P_t(\vec{x})$$


$$+ \frac{g_t^2}{2} \nabla_{\vec{x}}^2 P_t(\vec{x})$$

$$-\nabla_{\vec{x}} \cdot (P_t(\vec{x}) g_t^2 \nabla_{\vec{x}} \log P_t(\vec{x}))$$

3. 粒子と分布の対応 (2の1)

時間反転?

「時間反転」




$$1. \frac{\partial}{\partial t} P_t(\vec{x}) = -\nabla_{\vec{x}} \cdot (P_t(\vec{x}) \vec{f}_t(\vec{x})) + \frac{g_t^2}{2} \nabla_{\vec{x}}^2 P_t(\vec{x})$$

$$\bar{t} := -t \Rightarrow \frac{\partial}{\partial \bar{t}} P_t(\vec{x}) = -\nabla_{\vec{x}} \cdot (P_t(\vec{x}) \{ g_t^2 \nabla_{\vec{x}} \log P_t(\vec{x}) - \vec{f}_t(\vec{x}) \}) + \frac{g_t^2}{2} \nabla_{\vec{x}}^2 P_t(\vec{x})$$

3. 粒子と分布の対応 (その1)

時内反転?

「時間反転」




$P_t(\vec{x})$

対応がある

$$1. \frac{\partial}{\partial t} P_t(\vec{x}) = -\nabla_{\vec{x}} \cdot (P_t(\vec{x}) \{ g_t^2 \nabla_{\vec{x}} \log P_t(\vec{x}) - \vec{f}_t(\vec{x}) \}) + \frac{g_t^2}{2} \nabla_{\vec{x}}^2 P_t(\vec{x})$$

x: 標本

$\vec{x}_t = (x_t, y_t)$




2. 粒子の方程式

$$d\vec{x}_t = \vec{f}_t(\vec{x}_t) dt + g_t d\vec{w}_t$$

3. 粒子と分布の対応 (その1)

時内反転?

「時間反転」




$P_t(\vec{x})$

対応がある

$$1. \frac{\partial}{\partial \bar{t}} P_t(\vec{x}) = -\nabla_{\vec{x}} \cdot (P_t(\vec{x}) \{ g_t^2 \nabla_{\vec{x}} \log P_t(\vec{x}) - \vec{f}_t(\vec{x}) \}) + \frac{g_t^2}{2} \nabla_{\vec{x}}^2 P_t(\vec{x})$$

x: 標本

$\vec{x}_t = (x_t, y_t)$




2. 粒子の方程式

$$d\vec{x}_t = \{ g_t^2 \nabla_{\vec{x}} \log P_t(\vec{x}) - \vec{f}_t(\vec{x}) \} d\bar{t} + g_t d\vec{w}_{\bar{t}}$$

3. 粒子と分布の対応 (その1)

時内反転?


「時間反転」



生成モデル
の目的と同じ
x: 標本

「拡散」させる前の分布
からの標本とみなせる!

標本をとる



$$\vec{x}_t = (x_t, y_t)$$


2. 粒子の方程式

$$d\vec{x}_t = \left\{ g_t^2 \nabla_{\vec{x}} \log P_t(\vec{x}) - \vec{f}_t(\vec{x}) \right\} d\bar{t} + g_t d\vec{w}_{\bar{t}}$$

3. 粒子と分布の対応 (その1)

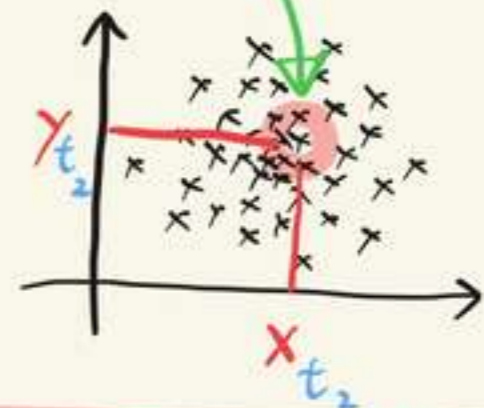

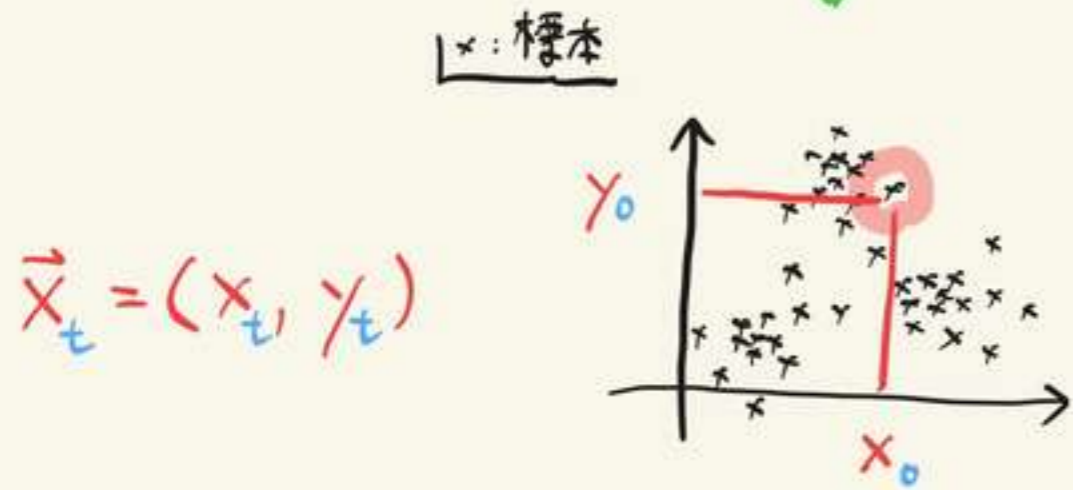
時内反転?

「時間反転」



未知 \Rightarrow モデル $\vec{S}_t(\vec{x})$ でおきかえる

標本をとる

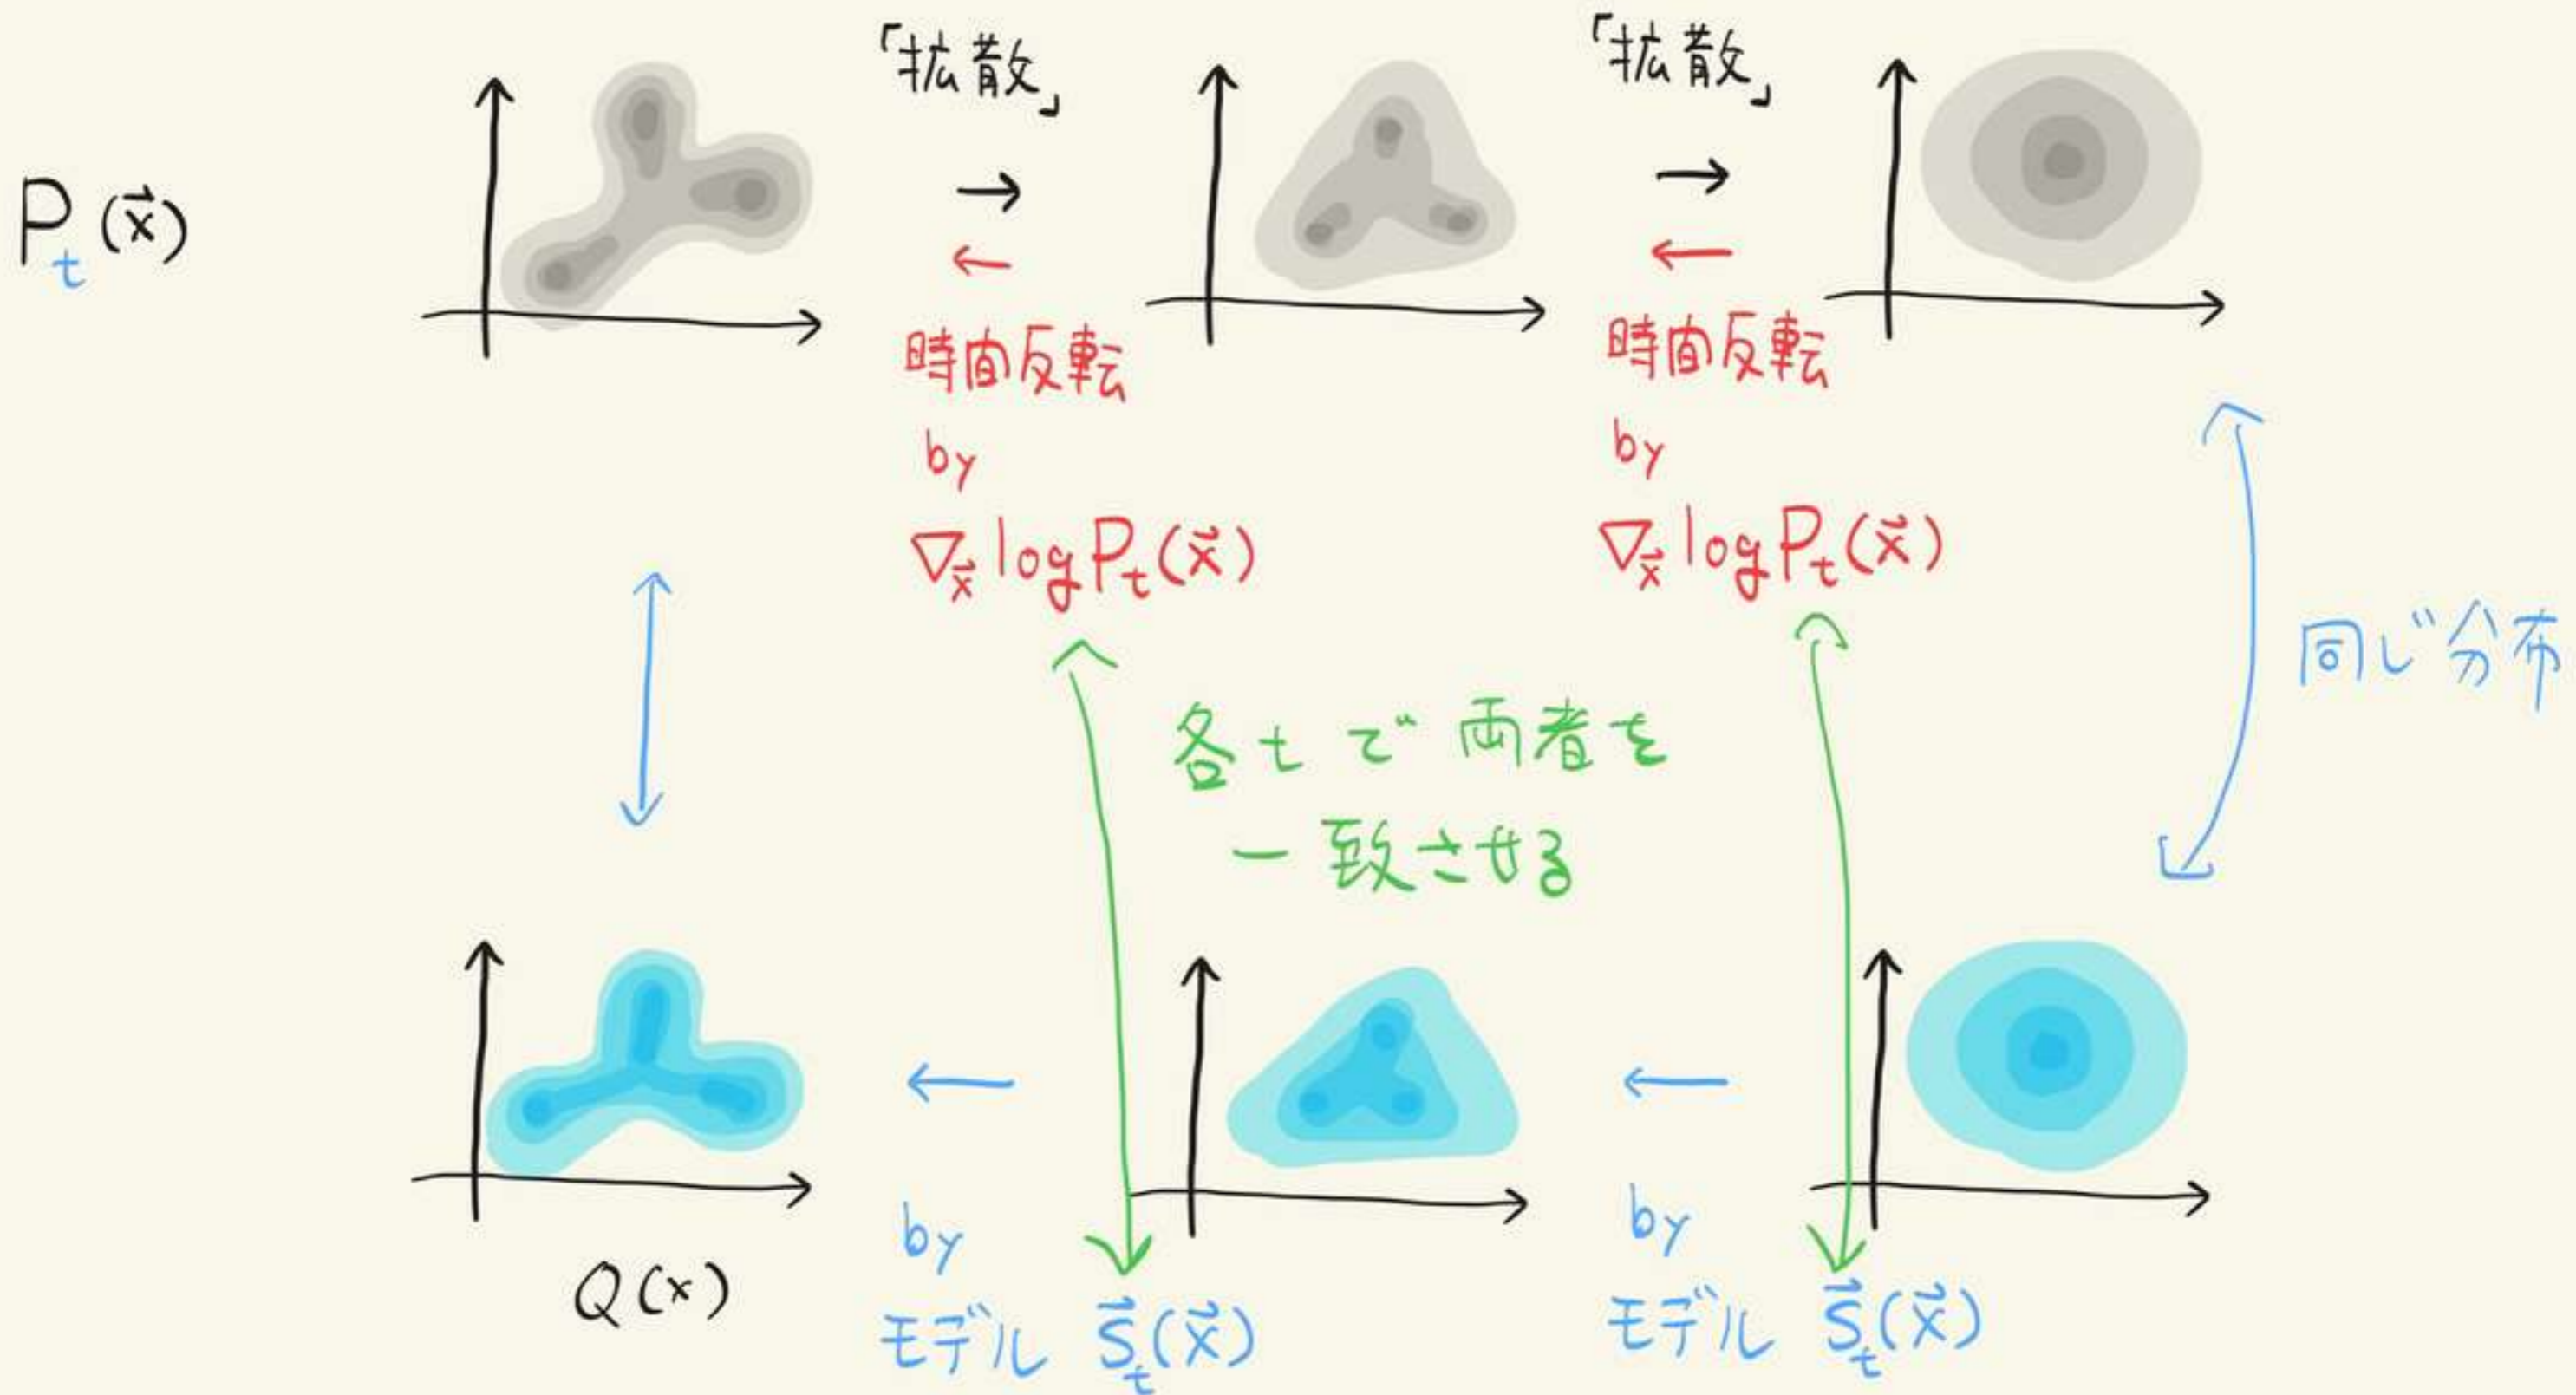


2. 粒子の方程式

$$d\vec{x}_t = \left\{ g_t^2 \nabla_{\vec{x}} \log P_t(\vec{x}) - \vec{f}_t(\vec{x}) \right\} d\bar{t} + g_t d\vec{w}_{\bar{t}}$$

3. 粒子と分布の対応 (その1)


スコアマッチング"再び"




3. 粒子と分布の対応 (その1)

スコアマッチング"再び"


$P_t(\vec{x})$



「拡散」



「拡散」



時間反転

by

$$\nabla_{\vec{x}} \log P_t(\vec{x}) \frac{e^{-V_t(\vec{x})}}{Z_t}$$


時間反転

by


$$\nabla_{\vec{x}} \log P_t(\vec{x})$$

$$= -\nabla_{\vec{x}} V_t(\vec{x}) : \text{時間依存する「力」}$$

同じ分布




$Q(x)$



by

$$\text{モデル } \vec{S}_t(\vec{x})$$



by


$$\text{モデル } \vec{S}_t(\vec{x})$$

3. 粒子と分布の対応 (その1)


スコアマッチング^{再び}

※ 実際はその派生形「デライジング・スコアマッチング」を使うことが多い

$P_t(\vec{x})$




$$\int P_t(x) (s_t(x) + \nabla_x V_t(x))^2 dx$$



3. 粒子と分布の対応 (その1)

ノイズは必須ではない!



$$\frac{\partial}{\partial t} P_t(\vec{x}) = -\nabla_{\vec{x}} \cdot (P_t(\vec{x}) \vec{f}_t(\vec{x})) + \frac{g_t^2}{2} \nabla_{\vec{x}}^2 P_t(\vec{x})$$

$$\nabla_{\vec{x}} \cdot P_t(\vec{x}) \frac{g_t^2}{2} \nabla_{\vec{x}} \log P_t(\vec{x})$$


$$= -\nabla_{\vec{x}} \cdot (P_t(\vec{x}) \left[\vec{f}_t(\vec{x}) - \frac{g_t^2}{2} \nabla_{\vec{x}} \log P_t(\vec{x}) \right])$$

新しいドリフト項 $\tilde{\vec{f}}_t(\vec{x})$ とみなす

3. 粒子と分布の対応 (その1)

ノイズは必須ではない!

「時間」 t




$$\frac{\partial}{\partial t} P_t(\vec{x}) = -\nabla_{\vec{x}} \cdot (P_t(\vec{x}) \underbrace{\left[\vec{f}_t(\vec{x}) - \frac{g_t^2}{2} \nabla_{\vec{x}} \log P_t(\vec{x}) \right]}_{\vec{f}_t(\vec{x})})$$

対応がある

x: 標本

$$\vec{x}_t = (x_t, y_t)$$




粒子の方程式

$$d\vec{x}_t = \vec{f}_t(\vec{x}_t) dt + \cancel{g_t d\vec{w}_t}$$

3. 粒子と分布の対応 (その1)

ノイズは必須ではない!

「時間反転」



$P_t(\vec{x})$


対応がある

$$\frac{\partial}{\partial t} P_t(\vec{x}) = -\nabla_{\vec{x}} \cdot (P_t(\vec{x}) \left[\underbrace{\vec{f}_t(\vec{x})}_{\tilde{\vec{f}}_t(\vec{x})} - \frac{g_t^2}{2} \nabla_{\vec{x}} \log P_t(\vec{x}) \right])$$

x(-1)

x: 標本

$\vec{x}_t = (x_t, y_t)$



粒子の方程式

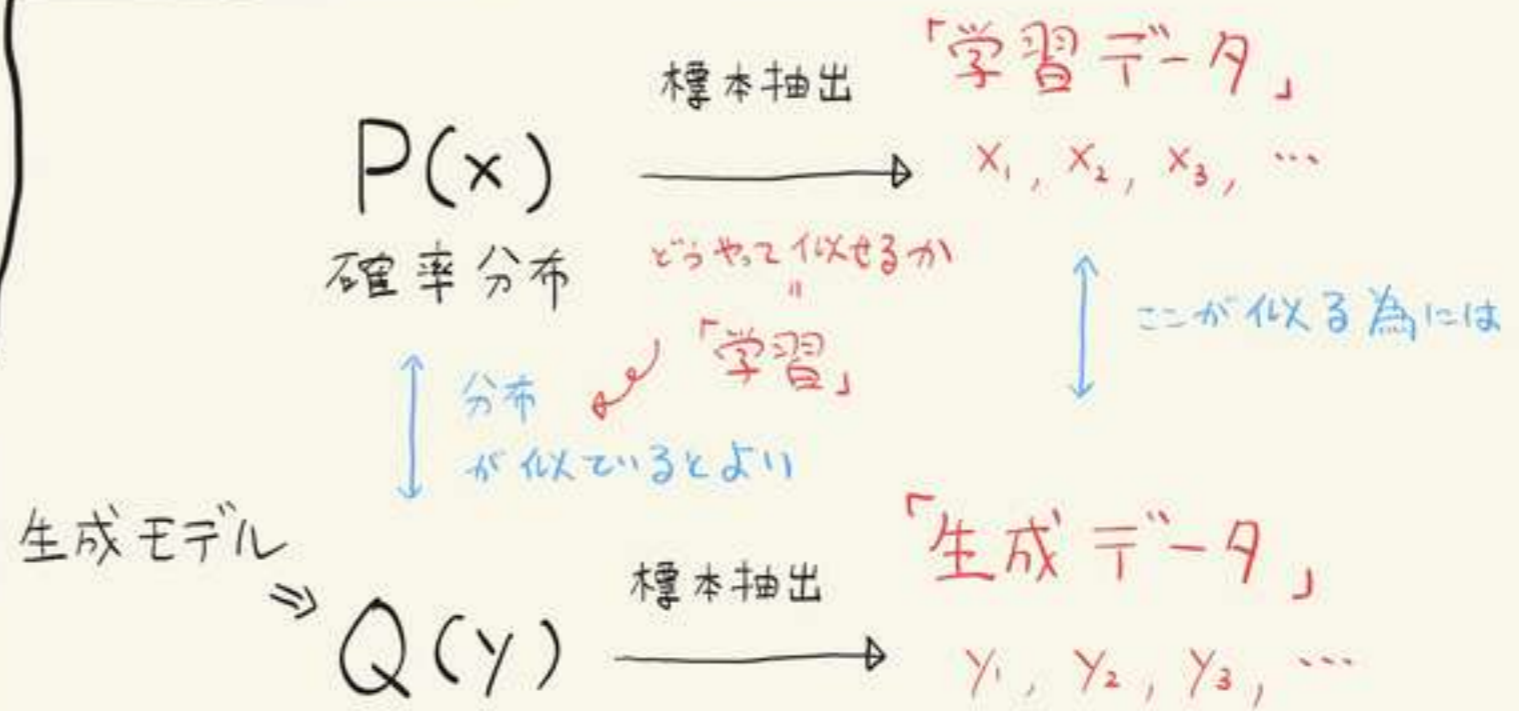
$$d\vec{x}_t = \tilde{\vec{f}}_t(\vec{x}_t) dt + \cancel{g_t d\vec{w}_t}$$

x(-1)



モデル
 この中の $S_t(x)$ にしたものを生成に使える。

■ 本日の内容

■ 1. 生成モデルとは?



■ 2. 拡散モデルとは



■ 3. 粒子と分布の対応 (2の1)

■ 4. 粒子と分布の対応 (2の2)


→ スコアマッチング

4. 粒子と分布の対応 (その2)

最初からノイズ無しで考える

「時間」 t

$P_t(\vec{x})$




分布の方程式
「連続の方程式」

$$\frac{\partial}{\partial t} P_t(\vec{x}) = -\nabla_x \cdot (P_t(\vec{x}) \vec{u}_t(\vec{x}))$$

対応がある

x : 標本

$$\vec{x}_t = (x_t, y_t)$$



粒子の方程式

$$d\vec{x}_t = \vec{u}_t(\vec{x}_t) dt$$


どう構成すればよいか?

4. 粒子と分布の対応 (その2)

最初からノイズ無しで考える

「時間」 t

$P_t(\vec{x})$



分布の方程式

「連続の方程式」

$$\frac{\partial}{\partial t} P_t(\vec{x}) = -\nabla_x \cdot (P_t(\vec{x}) \vec{u}_t(\vec{x}))$$


今まで: $\vec{u}_t(\vec{x}) \Rightarrow P_t(\vec{x})$

発想を逆転させる: $P_t(\vec{x}) \Rightarrow \vec{u}_t(\vec{x})$

4. 粒子と分布の対応 (その2)

最初からノイズ無しで考える

「時間」 t



$$\int P(\vec{y}_0) \tilde{P}(\vec{y}_1) N(\vec{x} | t \cdot \vec{y}_1 + (1-t) \cdot \vec{y}_0, \sigma^2) d\vec{y}_0 d\vec{y}_1 \quad \text{だとする.}$$

どういふ分布か? \Rightarrow まず t については連続


端でどうなる?

$$\begin{aligned}
 P_{t=0}(\vec{x}) &= \int P(\vec{y}_0) \tilde{P}(\vec{y}_1) N(\vec{x} | t \cdot \vec{y}_1 + (1-t) \cdot \vec{y}_0, \sigma^2) d\vec{y}_0 d\vec{y}_1 \\
 &= \int P(\vec{y}_0) N(\vec{x} | \vec{y}_0, \sigma^2) d\vec{y}_0 \quad \text{先に積分}
 \end{aligned}$$

4. 粒子と分布の対応 (その2)

最初からノイズ無しで考える

「時間」 t



$P_t(\vec{x})$
||

$$\int P(\vec{y}_0) \tilde{P}(\vec{y}_1) N(\vec{x} | t \cdot \vec{y}_1 + (1-t) \cdot \vec{y}_0, \sigma^2) d\vec{y}_0 d\vec{y}_1 \quad \text{だとする.}$$

どういふ分布か? \Rightarrow まず t については連続

端でどうなる?

$$P_{t=0}(\vec{x}) = \int P(\vec{y}_0) \underbrace{N(\vec{x} | \vec{y}_0, \sigma^2)}_{\approx P(\vec{x})} d\vec{y}_0$$



$$P_{t=1}(\vec{x}) = \int \tilde{P}(\vec{y}_1) \underbrace{N(\vec{x} | \vec{y}_1, \sigma^2)}_{\approx \tilde{P}(\vec{x})} d\vec{y}_1$$

σ^2 小で Dirac のデルタ

4. 粒子と分布の対応 (その2)

最初からノイズ無しで考える


「時間」 t



4. 粒子と分布の対応 (その2)

最初からノイズ無しで考える

「時間」 t



$P_t(\vec{x})$

分布の方程式
"連続の方程式"

$$\frac{\partial}{\partial t} P_t(\vec{x}) = -\nabla_{\vec{x}} \cdot (P_t(\vec{x}) \vec{u}_t(\vec{x}))$$

$$\vec{u}_t(\vec{x}) = \frac{1}{P_t(\vec{x})} \int P(\vec{y}_0) \tilde{P}(\vec{y}_1) N(\vec{x} | t \cdot \vec{y}_1 + (1-t) \cdot \vec{y}_0, \sigma^2) (\vec{y}_1 - \vec{y}_0) d\vec{y}_0 d\vec{y}_1$$

値が未知 (のことが多く)!


粒子の方程式

$$d\vec{x}_t = \vec{u}_t(\vec{x}_t) dt$$

4. 粒子と分布の対応 (その2)

フロー-マッチング

「時間」 t



$$\int P_t(\vec{x}) (\vec{v}_t(\vec{x}) - \vec{u}_t(\vec{x}))^2 d\vec{x}$$
 がモンテカルロ計算可能

粒子の方程式

モデル


$$\vec{v}_t(\vec{x}_t)$$

$$d\vec{x}_t = \vec{u}_t(\vec{x}_t) dt$$

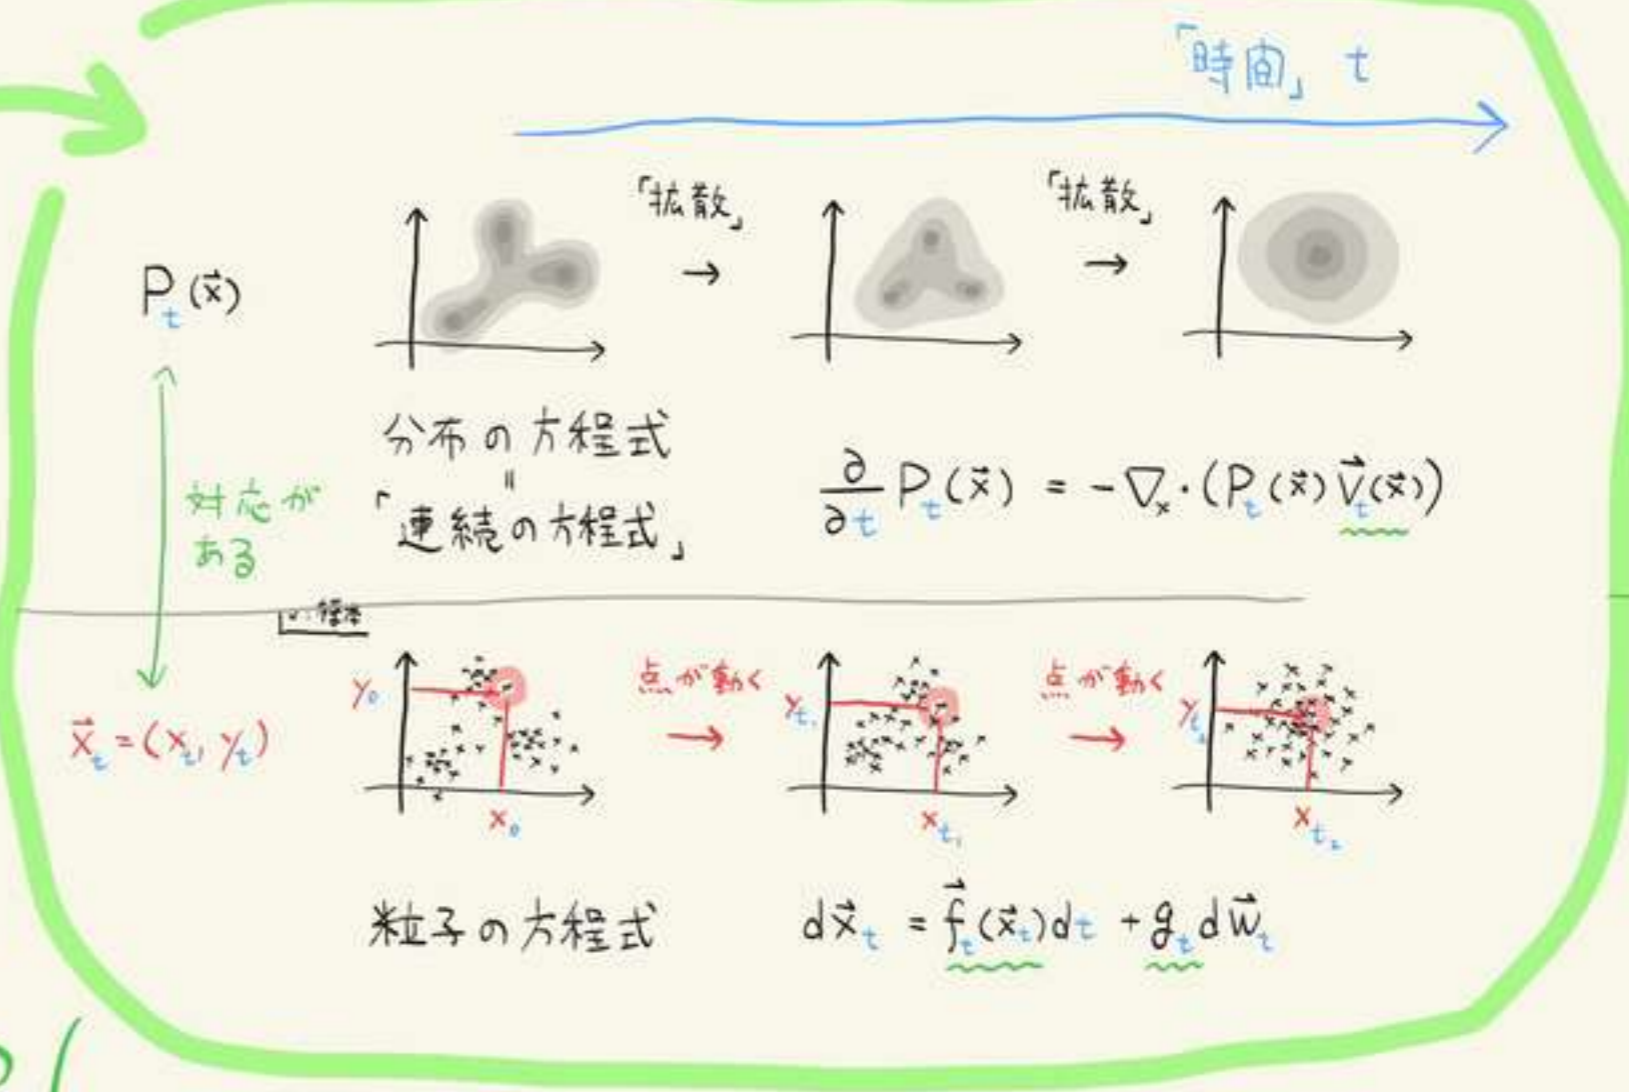

 \approx 一致するようにする

■ 本日のまとめ

■ 1. 生成モデルとは?



■ 2. 拡散モデルとは



■ 3. 粒子と分布の対応 (2の1)

→ スコアマッチング

■ 4. 粒子と分布の対応 (2の2)

→ フローマッチング

$g_t \neq 0$

$g_t = 0$