

Answer of AD-Q2-5 assume x as input

define encoder as $p^{-1}(\hat{z}(x))$

$$\hat{z} = \mu(x), \sigma(x)$$

as reparameterization trick

$$z = \mu(x) + \epsilon \times \sigma(x)$$

$$\text{where } \epsilon \sim \mathcal{N}(0, I)$$

then define decoder as $p(z(x))$

$$\hat{x} = p(z|x)$$

so minimize L as reconstruction

is goal of training VAE

$$\text{where } L = \|x - \hat{x}\|^2$$


VAE = Variational Auto Encoder

Encoder $q_{\phi}(z|x)$ $\phi = \text{param}$

Decoder $p_{\theta}(x|z)$ $\theta = \text{param}$

where $z \sim \mathcal{N}(0,1)$

$\tilde{z}$
 $\uparrow$ latent variable



潜在変数 z から
高次元データ x を生成可能

$q_{\phi}(z|x)$ x を生成した z を推定可能

ポイントは Encoder は直接 z を生成するのではなく

FBZ の x に対して z を決める 正規分布のパラメータ

μ, σ を生成

Encoder

Decoder

$$X \rightarrow q_{\phi}(z|x) \begin{cases} \rightarrow \mu(x) \rightarrow z \sim \\ \rightarrow \sigma(x) \rightarrow \mathcal{N}(\mu(x), \sigma(x)) \rightarrow p_{\theta}(x|z) \end{cases}$$

$p(x)$ の尤度を最大にする θ, ϕ を最適化したい

↓
^
X

$$\log p(x) = \log \int p(x, z) dz$$

$$= \log \int q(z|x) \frac{p(x, z)}{q(z|x)} dz$$

$$\geq \int q(z|x) \log \frac{p(x, z)}{q(z|x)} dz$$

Jensen's
Inequality

||

$\mathcal{L}(x, z)$... 変分 F 関数

この変分下限 $L(x, z)$ と $\log p(x)$ の差は

$$\log p(x) - L(x, z) = D_{KL}[q(z|x) \| p(z|x)] \geq 0$$

つまり $L(x, z) = \underbrace{\log p(x)}_{\text{固定値}} - \underbrace{D_{KL}[q(z|x) \| p(z|x)]}_{\text{φ, θ に依存して変化}}$

よこの最大値をとるために

$$D_{KL}[q(z|x) \| p(z|x)] = -D_{KL}[q(z|x) \| p(z)] + \underbrace{E_{q(z|x)}[\log p(x|z)]}_{\text{ここ}}$$

正則化項

その分布が $p(z)$
つまり $N(0, I)$
と近似するように制約

Encoder, Decoder
で推論した
その分布
を戻す

の期待値
 $\log p(x|z)$ の
期待値を
取り

Reparameterization Trick

$z \sim \mathcal{N}(\mu(x), \sigma(x))$ という確率分布から
10000個の Backprop 使えない

$\epsilon \sim \mathcal{N}(0, 1)$ に 1 だけ生成

$$z = \mu(x) + \epsilon \times \sigma(x) \text{ とし}$$

確率変数 ϵ を選んで

Back Prop 適用

