

変分ベイズ法からVAEへ

持橋大地

統計数理研究所 数理・推論研究系

daichi@ism.ac.jp

首都大小町研究室講義, 2018-2-6(火)

変分ベイズで何が不足？

- 共役分布族 (ディリクレ-多項分布など) でないと EM アルゴリズムが導けない

$$\text{期待値 } \langle \log p(D, z | \theta) \rangle_{q(z)}, \langle \log p(D, z | \theta) \rangle_{q(\theta)}$$

が解析的に解けない

- 強い因子分解の仮定


$$q(z, \theta) = q(z)q(\theta)$$



- 複雑なデータの正確なモデル化が難しい

逆に、ニューラルネットでは？

- 通常のオートエンコーダでは、新しいデータを生成できない
 - 潜在変数 z に分布がない
- きちんとした確率的生成モデルになっていない！




Variational Autoencoder (VAE)

- Kingma & Welling (ICLR 2014)
 - 元のタイトル: “*Stochastic Gradient VB and the Variational Auto-Encoder*”
- 変分下限をニューラルネットで近似
 - 因子分解不要
 - Stochastic Gradientで学習可能
 - \mathbf{z} は典型的には多変量標準ガウス分布

$$\mathbf{z} \sim \mathcal{N}(\mathbf{0}, \mathbf{I}_K)$$

VAEのモデル: 前提



- θ の分布は(とりあえず)考えない
(定数として最適化)
- $p(\mathbf{x}|\theta) = \int p(\mathbf{x}|\mathbf{z}, \theta)p(\mathbf{z})d\mathbf{z}$ を最大化
- $\mathbf{z} \sim \mathcal{N}(\mathbf{0}, \mathbf{I}_K)$ が典型的

VAEの導出 (1)


$$\begin{aligned}\log p(\mathbf{x}|\theta) &= \log \int p(\mathbf{x}, \mathbf{z}|\theta) d\mathbf{z} = \log \int q(\mathbf{z}|\phi) \frac{p(\mathbf{x}, \mathbf{z}|\theta)}{q(\mathbf{z}|\phi)} d\mathbf{z} \\ &\geq \int q(\mathbf{z}|\phi) \log \frac{p(\mathbf{x}, \mathbf{z}|\theta)}{q(\mathbf{z}|\phi)} d\mathbf{z} \quad (\text{Jensen}) \\ &= \int q(\mathbf{z}|\phi) \log \frac{p(\mathbf{x}|\mathbf{z}, \theta)p(\mathbf{z}|\theta)}{q(\mathbf{z}|\phi)} d\mathbf{z} \\ &= \underbrace{-D(q(\mathbf{z}|\phi) || p(\mathbf{z}|\theta))}_{(1)} + \underbrace{\int q(\mathbf{z}|\phi) \log p(\mathbf{x}|\mathbf{z}, \theta) d\mathbf{z}}_{(2)}\end{aligned}$$

- Jensenの不等式で下限を取っているだけ
- (2)項を最大化したいが、(1)項がペナルティ(正則化)

VAEの導出 (2)

$$\log p(\mathbf{x}|\theta) \geq \underbrace{-D(q(\mathbf{z}|\phi)||p(\mathbf{z}|\theta))}_{(1)} + \underbrace{\int q(\mathbf{z}|\phi) \log p(\mathbf{x}|\mathbf{z}, \theta) d\mathbf{z}}_{(2)}$$

- $q(\mathbf{z}|\phi) = \mathcal{N}(\boldsymbol{\mu}(\phi), \text{diag}(\boldsymbol{\sigma}(\phi)))$ とすれば、
(1) は解析的
(2) はモンテカルロ近似できる } SGDで最適化できる!



VAEの導出 (3)

- 正規分布の間のKLダイバージェンス $D(q(\mathbf{z}|\phi)\|p(\mathbf{z}))$ は解析的に求められるので、結局

$$\log p(\mathbf{x}|\theta) \geq \frac{1}{2} \sum_{k=1}^K (1 + \log \sigma_k^2 - \mu_k^2 - \sigma_k^2) + \frac{1}{L} \sum_{\ell=1}^L \log p(\mathbf{x}|\mathbf{z}^{(\ell)}, \theta)$$

$\mathbf{z}^{(\ell)} \sim q(\mathbf{z}|\phi)$

- この下限のGradientを計算してSGDに入ればよい.
- Reparametrization trick (正規乱数の変換)

VAE: ポイント

- Jensenで下限をとった後の $q(z|\phi)$ は任意の関数でよい
 - 因子化仮定は必須ではない
 - $q(z|\phi)$ をニューラルネットでモデル化
- ガウス分布間のKLダイバージェンスは解析的に計算できる
 - 本質的には必ずガウス分布である必要はない



VAE=変分近似+ニューラルネット
ニューラルネットの確率的生成モデル化.

VAE: 注意点

ただし...

- Jensenの不等式により、 $D(q(\mathbf{z}|\phi)||p(\mathbf{z}))$ を最小化
× $D(p(\mathbf{z})||q(\mathbf{z}|\phi))$ ではない

$$D(q(\mathbf{z}|\phi)||p(\mathbf{z})) = \int q(\mathbf{z}|\phi) \log \frac{q(\mathbf{z}|\phi)}{p(\mathbf{z})} d\mathbf{z}$$

- モデル化している範囲で、 $q(\mathbf{z}|\phi)$ と $p(\mathbf{z})$ の差が小さければよい
- $p(\mathbf{z})$ が大, $q(\mathbf{z}|\phi)$ が小の領域があっても気にしない
- Peakyな事後分布 (Mode-finding: PRML参照)

まとめ

- VAE ... 変分ベイズ法の正統進化
 - $q(z|\phi)$ として解析関数ではなく、 $p(z)$ と同じ分布族(たとえば正規分布)を与えるニューラルネットを考える
 - 勾配が解析的には解けないので、モンテカルロ近似
- 通常のNNと異なり、データを簡単に生成できる
- 変分下限を考える際に、真の事後分布より尖っている可能性が高いので注意が必要