

深層生成モデルによる統計的推論

福水 健次


統計数理研究所 統計的機械学習研究センター長

統計数理研究所 創立75周年記念チュートリアル講演

2019年6月5日



(極私的) 統計的機械学習の歴史




深層学習の隆盛

大量データ



計算能力



高い性能



プラットフォーム

 TensorFlow



PYTORCH

theano

講演の概要

1. はじめに
2. 深層生成モデル
3. 深層生成モデルによるBayes推論
4. おわりに

GAN: 敵対的生成ネットワーク

Generative Adversarial Nets. (Goodfellow et al. NIPS2014)

- 生成モデルの深層学習
- 「敵対的学習」という枠組み
- 良好な画像の生成に成功



深層生成モデルの発展：顔画像




2014
(Goodfellow et al)



2015



2016



2017
(Karas et al ProgressiveGAN)



2018
(Karas et al StyleGAN)

(Goodfellow, ICLR2019より)

State-of-the-Art

Cycle-GAN (Zhu et al ICCV2017)

<https://www.youtube.com/watch?v=9reHvktowLY>

- Everybody Dance Now (Chan et al 2018)

YouTube: Everybody Dance Now.
<https://youtu.be/PCBTZh41Ris>

生成モデル

- 生成モデル： データを生成する確率分布のモデル

Graphical model

Mixture model


カーネル密度推定 etc...

- 深層生成モデル

$$X = f_w(Z)$$

Z : 簡単な確率分布 e.g. $N(0, I_d)$

$f_w(z)$: 深層ニューラルネット




生成モデルの学習

- 分布を近くすればよい

d : 分布の相違をはかる尺度

- f-divergence
 - f-GAN (Nowozin et al NIPS2016)
- Wasserstein距離
 - Wasserstein-GAN (Arjovsky et al ICLR2017)
- MMD(カーネル法)
 - MMD-GAN (Li et al NIPS2017; Binkowski et al ICLR2018)



GAN : 敵対的学習


p_D : データ (真) の密度関数
 p_w : 生成モデルの密度関数 $X = f_w(Z)$

- 分布の距離 : Jensen-Shannon divergence

$$JS(p_D, p_w) = KL(p_D \parallel (p_D + p_w)/2) + KL(p_w \parallel (p_D + p_w)/2)$$

- 生成ネット : 分布間距離の最小化

$$\min_{f_w} JS(p_D, p_w)$$



- 識別ネット : JS-距離は計算困難 → 識別問題に還元

$$JS(p_D, p_w) = \sup_{D(x): \text{DNN}} E_{Y \sim p_D} [\log D(Y)] - E_{X = f_w(Z)} [\log(1 - D(X))] + \text{const.}$$

— Logistic loss


$D(x) := \frac{p_D(x)}{p_D(x) + p_w(x)}$ が最適

- GAN : minmaxによる学習

- Discriminator: ロジスティック判別

$$\max_D E_{X \sim p} [\log D(X)] - E_{X \sim q} [\log(1 - D(X))]$$


$D(x)$ の値: p で 1, q で 0 が有利



- Generator: 判別できなくしたい


$$\min_{q: X=g(Z)} \max_D E_{X \sim p} [\log D(X)] - E_{X \sim q} [\log(1 - D(X))]$$

$D(x) = 1$ の領域で確率大が有利



サンプリング

- 高次元で高性能なサンプラーができた！



DNN



Generated by <http://www.whichfaceisreal.com/> (StyleGAN)
by Jevin West and Carl Bergstrom, U. Washington

- 画像、映像の生成
アニメーション、実写、アート、 etc



Edmond de Belamy (Oblivious)



Cycle GAN (Zhu et al 2017)




Yanghua Jin et al (Comiket 92, 2017)



Crypko
by Preferred Networks

- サンプルングによる統計的推論

深層生成モデルによるBayes推論



Bayes推論

事後確率

$$q(\theta|y) = \frac{p(y|\theta)\pi(\theta)}{\int p(y|\theta)\pi(\theta)d\theta}$$

$\pi(\theta)$: 事前確率 (prior)
 $p(y|\theta)$: 尤度 (likelihood)
 y : 観測データ



Thomas Bayes (1701-1761)

$$q(\theta|y) = \frac{p(y|\theta)\pi(\theta)}{\int p(y|\theta)\pi(\theta)d\theta}$$

大問題「どう計算するか？」

- サンプルング： Markov Chain Monte Carlo (MCMC), Sequential MC /粒子法, ...
- 近似計算： Laplace近似, 変分ベイズ, etc

→ GANによるサンプルングを使おう！

(Tran et al NIPS 2017; Yang et al NeurIPS2018)



生成モデルによるベイズ推論

• 同時分布の比較

$$p(\theta, y) = p(y|\theta)\pi(\theta)$$

$$q(\theta, y) := q(\theta|y)p(y), \quad p(y) = \int p(y|\theta)\pi(\theta)d\theta$$

$p(\theta, y) = q(\theta, y)$ ならば $q(\theta|y)$ は事後確率


サンプリング → GAN的学習

$$p(\theta, y): \quad \theta_i \sim \pi(\theta)d\theta,$$

$$y_i \sim p(y|\theta_i)dy$$

$$q(\theta, y): \quad \tilde{\theta}_i = f_w(y_i, z_i), \quad \text{DNN生成モデル}$$

$z_i \sim p_0(z)dz$ (ガウスなど)



- 分布の違いをどう測るか？

1. KL-divergence (Yang et al NeurIPS2018)

$$\int q(y, \theta) \log \frac{p(y, \theta)}{q(y, \theta)} d\theta$$

学習データ

生成データ

2. 変分Bayesからの導出 (Tran et al NIPS 2017)

変分ベイズとしての見方 Hierarchical Implicit Models and

Likelihood-Free Variational Inference (Tran, Ranganath, Blei, NIPS2017)

- 変分Bayes : 事後確率の有力な近似手法

$$\begin{aligned}\log p(y) &= \int p(y|\theta)\pi(\theta)d\theta \\ &\geq -KL(q(\theta|y)||\pi(\theta)) + E_{q(\theta|y)}[\log p(y|\theta)]\end{aligned}$$

Evidence lower bound
(ELBO)

$q(\theta|y)$ は任意の分布. 等号成立 $\Leftrightarrow q(\theta|y) = p(\theta|y)$

ELBOを最大にする q によって事後確率を近似する

- $ELBO = \int q(\theta|y) \log \frac{p(y, \theta)}{q(y, \theta)} d\theta + \log p(y) \rightarrow$ 生成モデルの目的関数！

* 深層生成モデルの尤度関数は計算不能 (c.f. Autoregressive flow, Glow)


- $\log \frac{p(\theta, y)}{q(\theta, y)}$ の推定 \rightarrow Logistic判別により可能 (\doteq GANの識別機)

命題 識別問題

$$\max_r E_{p(y, \theta)} [\log \sigma(r(Y, \theta))] - E_{q(y, \theta)} [\log (1 - \sigma(r(Y, \theta)))] \quad \sigma(t) = \frac{1}{1 + e^{-t}}$$

の解は $r_{opt}(y, \theta) = \log \frac{p(y, \theta)}{q(y, \theta)}$

$r(y, \theta)$ をDNNで構成する



変分Bayes \doteq GAN

変分ベイズとGAN



- 変分Bayes + 深層生成モデル
 - Discriminator: ロジスティック判別

$$\max_{r(y, \theta)} E_{(y, \theta) \sim p} [\log \sigma(r(y, \theta))] - E_{(y, \tilde{\theta}) \sim q} \left[\log \left(1 - \sigma \left(r(y, \tilde{\theta}) \right) \right) \right]$$

r の値 : p で + , q で - が有利

- Generator: 変分Bayes (max ELBO)

$$\max_{q: \theta = f(y^*, \xi)} \int q(\theta | y^*) r(y^*, \theta) d\theta$$




- GAN (振り返り)

- Discriminator: ロジスティック判別

$$\max_D E_{X \sim p} [\log D(X)] - E_{X \sim q} [\log(1 - D(X))]$$


$D(x)$ の値 : p で 1 , q で 0 が有利



- Generator: Discriminatorの与える値が目的関数

$$\min_{q: X=f(Z)} \max_D E_{X \sim p} [\log D(X)] - E_{X \sim q} [\log(1 - D(X))]$$

$D(x) = 1$ の領域で確率大が有利



近似Bayes推論 (ABC) における比較

Lotka-Volterra Predator-Prey Simulator (確率微分方程式)

See Tran et al NIPS2017

おわりに：興味ある方向性

- GANによるサンプリング + Bayes推論

 - シミュレーター

 - 時系列解析（粒子フィルター）


 - etc

- 非線形時系列モデル

 - センサーデータなど、多くのデータは時系列

 - HMM/時空間モデルを超えた時系列解析

 - NEDOプロジェクト「確率深層コンピューティング」
（理研・泰地代表，アルゴリズム：樋口，福水，今泉）



- より計算量の少ないモデルへ
 - 社会の隅々までのAI化には必要
 - よりよい関数族、関数空間？
 - 可変基底 vs 固定基底を超えられるか？

(参考) 学習時間 CycleGANの顔画像：
Tesla V100 GPU 8個で1週間

- 学習ダイナミクスと汎化誤差
 - 確率降下法の理解
 - 汎化誤差とFlat minimaの関係？
(Fukumizu et al 2019, in preparation)

