Subject Data Shift

Date /

Attendants

April 28, 2022

〈Uncertainty のスライドより〉

Dataset shift

$$P_{train}(x, y) \neq P_{test}(x, y)$$

Concept shift

$$P_{t_0}(x, y) \neq P_{t_1}(x, y)$$

$$P_{t_0}(y|x) \neq P_{t_1}(y|x)$$

Covariate Shift

$$P_{train}(y|x) = P_{test}(y|x)$$

$$P_{train}(x) \neq P_{test}(x)$$

Target Shift

$$P_{train}(y|x) \neq P_{Test}(y|x)$$

$$P_{train}(x|y) \neq P_{test}(x|y)$$

Subject Date 2

Attendants <D2L>

Covariate Shift

labeling function

$P(y|x)$ doesn't change

$P_{train}(X) \neq P_{test}(X)$

this problem arises due to a shift in the distribution of the covariates. (features)

cat dog

$P_{train}(X)$ photo

↓ shift

$P_{test}(X)$ cartoon

$P(Y|X)$: image ↦ label

XがYを引き起こす

Label Shift

病状からインフルか診断

$P_{train}(Y)$ 夏・インフル少ない

$P_{test}(Y)$ 冬インフル多い

Covariate shiftと同時に起こりうる

$P(X|Y)$

YがXを引き起こす

e.g. 病気が症状を引き起こす

Subject

Date 3

Attendants <D2L>

Concept Shift

tricky. eg. soft drink names in US

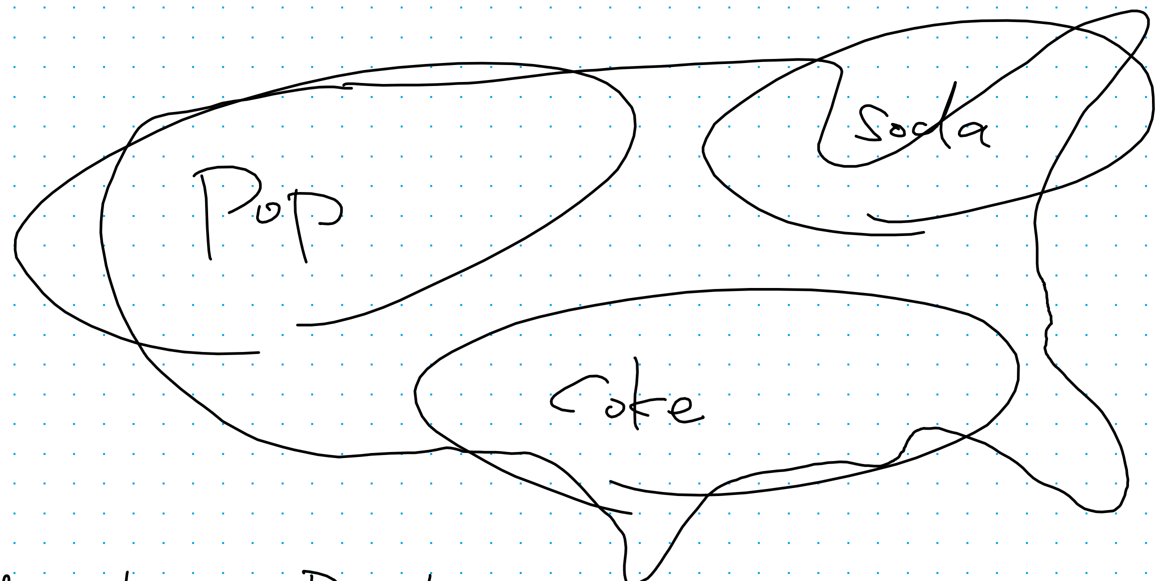

the distribution $P(y|x)$ might be different on our location.

Subject　　　　　　　　　　　　　　　　Date　4

Attendants

Case study

1. 血液から patient の cancer を predict

↙

健康な人だけから Data 集めたら

test 時には covariate shift

2. 自動運転

(ゲームの画像で学習)

road side detector

↳ 単純な texture で表示されてた

3. NonStationary Distribution (非定常分布)

Amazon リコメンド

クリスマスすぎても サンタ帽 をリコメンドしちゃう.

4. More Anecdotes (逸話)

-face recognition

(顔が画像の全体みたいなデータが train にはない

Subject Correction Date 5

Attendants

ERM

$$\min_f \frac{1}{n}\sum_{i=1}^{n} l(f(x_i), y_i)$$

$$\mathbb{E}_{p(x,y)}[l(f(x), y)] = \iint l(f(x), y)\, p(x,y)\, dx\, dy$$

Covariate shift correction

↳ Assumption $p(y|x) = q(y|x)$

$p(x) \neq q(x)$

$$\mathbb{E}_{p(x,y)}[\cdot\cdot] = \mathbb{E}_{\underbrace{q(y|x)}_{= p(y|x)} p(x)}[\cdot\cdot]$$

$$= \iint l(f(x), y)\, q(y|x)\, p(x)\, dx\, dy$$

$$= \iint l(f(x), y)\, q(y|x)\, q(x) \underbrace{\frac{p(x)}{q(x)}}_{\text{reweight}}\, dx\, dy$$

Subject: Correction (Covariate Shift) Date: 6

Attendants

$$\beta_i \overset{\text{def}}{=} \frac{p(x_i)}{q(x_i)}$$

plugging in the reweight β_i

$$\min_f \frac{1}{n} \sum_{i=1}^{n} \beta_i \, \ell(f(x_i), y_i)$$

weighted empirical risk minimization

However we don't know β_i (ratio)

estimate

p(x) q(x) からもサンプルをアクセスしなきゃいけない

ただし feature だけでよくて. y はいらない

test data にもアクセスしなきゃいけない

$z=1$ from $p(x)$
$z=-1$ from $q(x)$

$$P(z=1 \mid x) = \frac{p(x)}{p(x)+q(x)} = \frac{1}{1+\exp(-h(x))}$$

(logistic regression)

$$\& \quad \frac{P(z=1 \mid x)}{P(z=-1 \mid x)} = \frac{p(x)}{q(x)}$$

$$\beta_i = \frac{p(x)}{q(x)} = \frac{\frac{1}{1+\exp(-h(x))}}{\frac{\exp(-h(x))}{1+\exp(-h(x))}} = \frac{1}{\exp(-h(x))} = \exp(h(x))$$

Subject: Correction (Covariate Shift)

Date: 7

Attendants

Training set $\{(x_1, y_1) \dots (x_n, y_n)\}$

unlabeled test set $\{u_1 \dots u_m\}$ for covariate shift

1. Generate binary classification

$$\{(x_1, -1), \dots (x_n, -1), (u_1, 1) \dots (u_m, 1)\}$$

2. Train binary classifier using logistic regression to get function h.

3. Weigh training data using

$$\beta_i = \exp(h(x_i)) \quad \text{or} \quad \max(\exp(h(x_i)), c)$$

some constants.

4. use weights β_i for training on

$$\{(x_1, y_1) \dots (x_n, y_n)\}$$

Note that the above algorithm relies on a crucial assumption. $\frac{p(x)}{q(x)}$

For this scheme to work, we need that each data sample in target dist had non-zero prob of occuring at train time.

Subject Date

Attendants

Label Shift Correction

k- class classification

As assumption $q(x|y) = p(x|y)$

e.g. 病気の診断 → 症状

source distribution → $q(y) \neq p(y)$

インフル流行　　夏、インフル無し。

$$\mathbb{E}_{p(x,y)}[\cdots] = \iint l(f(x), y)\, p(x|y)\, p(y)\, dx\, dy$$

↑ target

$$= \iint l(f(x), y)\, q(x|y)\, q(y) \frac{p(y)}{q(y)}\, dx\, dy$$

$$= \frac{1}{n} \sum_{i=1}^{n} \beta_i\, l(f(x_i), y_i)$$

(混同行列)

Calculate confusion matrix $C \in \mathbb{R}^{k \times k}$

C_{ij}

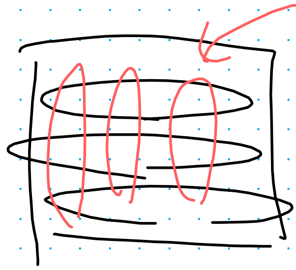

column label category (j)

(ground Truth)

(i)

row: models prediction category

Subject Date 9

Attendants

Mean model outputs $\mu(\hat{y}) \in \mathbb{R}^k$

whose i^{th} element $\mu(\hat{y}_i)$

is the fraction of total precisions on the test set where model predicted i

(テストセットのモデルによる予測 i)

$q(x|y)$

$Cp(y) = \mu(\hat{y})$

Label Shift $\beta_i = \dfrac{p(y_i)}{q(y_i)}$

Covariate Shift $\beta_i = \dfrac{p(x_i)}{q(x_i)}$

$p(x) = \sum_y p(x, y)$ yは低次元

$p(y) = \sum_x p(x, y)$ xは高次元

Subject　　　　　　　　　　　　　　　　　　　　Date 10

Attendants

Target label の分布を推論

$p(y)$

$q(y|x)$ を活用したい

confusion matrix

$\boxed{C}$

$$C_{ij} = \frac{\text{model predicted } i}{\text{total pred (true label} = j)}$$

		prediction cat	prediction dog
source label	cat		
	dog		

Binary case

一般的な confusion matrixの定義

target のラベルの distribution はアクセスできない

⇒ 混合行列を計算できない

しかし モデル outputの平均 (target データの) は計算できる

$\mu(\hat{y}_i)$, where i は cat の prediction

Subject　　　　　　　　　　　　Date　/ /

Attendants

Label Shift : Assumption が正しいとする

$$p(x|y) = q(x|y)$$
$$p(y) \neq q(y)$$

we estimate the test set label distribution by solving a simple linear system

$$C\,p(y) = \mu(\hat{y})$$

because

$$\sum_{j=1}^{k} C_{ij}\, p(y_j) = \mu(\hat{y}_i)$$

false negative

C_{ij}

$$\begin{array}{cc|cc} & & \multicolumn{2}{c}{\text{(prediction) } (i)} \\ & & \text{cat} & \text{dog} \\ \hline \text{(source label) } (j) & \text{cat} & C_{00} & C_{01} \\ & \text{dog} & C_{10} & C_{11} \end{array}$$

model pred (dog)
source label (cat)

$P(y_j)$

$$[\,C\,] \begin{pmatrix} \bigcirc \\ \bigcirc \end{pmatrix} = \begin{pmatrix} \square \\ \square \end{pmatrix} \begin{matrix} \leftarrow \mu(\hat{y}_0) \\ \leftarrow \mu(\hat{y}_1) \end{matrix}$$

prediction

$$\begin{pmatrix} a & b \\ c & d \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} ax+by \\ cx+dy \end{pmatrix} \begin{matrix} \leftarrow \text{label } (j:\text{cat}) \\ \leftarrow \text{label } (j:\text{dog}) \end{matrix}$$

Subject　　　　　　　　　　　　　　　　　Date 12

Attendants

ラベルの Marginal Dist $p(y)$ を
もとに、あるラベル内での prediction
の結果で重み付けを行い、

あるラベルを予測する期待値を
$\mu(\hat{y})$ として計算する

(pred)

		cat	dog	
label	cat	70	30	100
	dog	10	40	50
		80	70	150

これは prediction

$$\begin{bmatrix} \frac{70}{100} & \frac{30}{100} \\ \frac{10}{50} & \frac{40}{50} \end{bmatrix} = \begin{array}{c|cc} & \text{cat} & \text{dog} \\ \hline \text{cat} & 0.7 & 0.3 \\ \text{dog} & 0.2 & 0.8 \end{array}$$

(label) (pred)

$$\begin{bmatrix} 0.7 & 0.3 \\ 0.2 & 0.8 \end{bmatrix} \begin{pmatrix} P(y=cat) \\ P(y=dog) \end{pmatrix} = \begin{pmatrix} 0.7\,P(cat) + 0.3\,P(dog) \\ 0.2\,P(cat) + 0.8\,P(dog) \end{pmatrix} = \begin{pmatrix} \mu(\hat{y}\ cat) \\ \mu(\hat{y}\ dog) \end{pmatrix}$$

これはラベル

Subject: Label Shift Correlation

Date: 13

Attendants

C^{-1}が存在するとすれば

$$Cp(y) = \mu(\hat{y})$$ より

estimate

target label にはアクセスできないが $\mu(\hat{y})$ は分かる

$$p(y) = C^{-1}\mu(\hat{y})$$

$q(y)$ は source

$p(y)$ は target

これを使って $\frac{p(y_i)}{q(y_i)} = \beta_i$

で weighted ERM できる

☆ Confusion Matrix は

training (source)

distribution で計算する

(valid dataset)

Subject Concept Shift Correction　　Date 14

Attendants

↳ むずい

<Example>

① CTR estimation
- 新しい商品
- 人気落ちてきた商品

dist over ads
popularity
が変化するので gradually に変更が必要

② Traffic Camera lenses
劣化する → 画像の quality に影響

③ News content が gradually に変わる

from scratch で学習し直すのではなく
既存の NN を update していくのが基本的

Subject: Review　　Date: 15

Attendants

日本　　　　　　カナダ

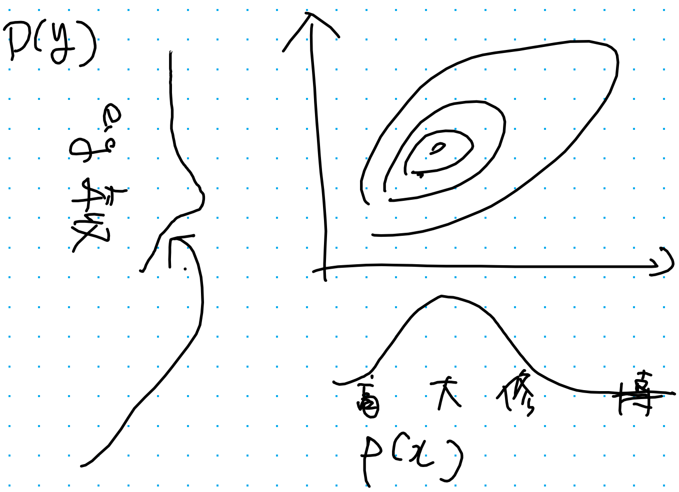

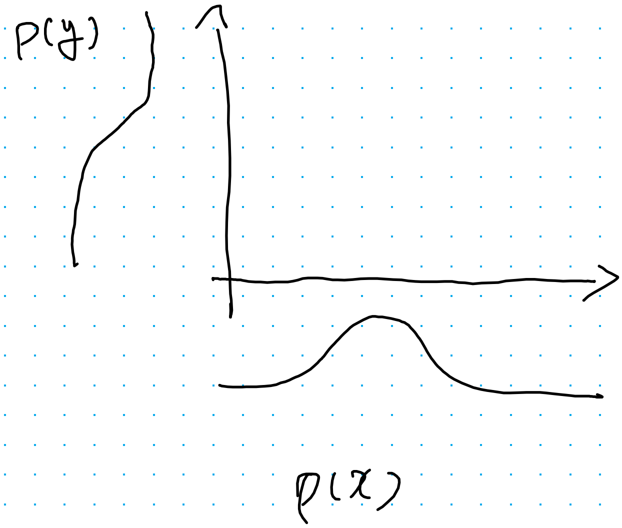

年収が低くなったら高い

院卒は少数

e.g. 学歴

は同じとする。

q(source)
p(target)

$\boxed{\text{Covariate shift}}$

$q(y|x) = p(y|x)$
$q(x) \neq p(x)$

学歴の分布は違うけど
学歴による年収の関数は
かわらない

$\boxed{\text{Label shift}}$

$q(x|y) = p(x|y)$
$q(y) \neq p(y)$

年収の分布違うけど
年収→学歴はかわらない