


PRML 3.2

11/13/2019

Sakai Kazunori

3.2 バイアス-バリアンス分解

解きたい問題に合わせて
適切な複雑さのモデルを選択したい



頻度主義においてはそれをどう果たすのか？



キーワード
バイアス、バリアンス

バイアス

モデル近似誤差。

バリアンス

統計的推定誤差。

➤ **最尤推測**
 $= p(\mathbf{x}|\mathbf{w}_{ML})$

➤ **平均プラグイン推測**
 $= p(\mathbf{x}|\mathbb{E}_{\mathbf{w}}[\mathbf{w}])$

➤ **MAP推測**
 $= p(\mathbf{x}|\mathbf{w}_{MAP})$

➤ **ベイズ推測**
 $= \mathbb{E}_{\mathbf{w}}[p(\mathbf{x}|\mathbf{w})]$

- **最尤推測**
 $= p(\mathbf{x}|\mathbf{w}_{ML})$

- **平均プラグイン推測**
 $= p(\mathbf{x}|\mathbb{E}_{\mathbf{w}}[\mathbf{w}])$


- **MAP推測**
 $= p(\mathbf{x}|\mathbf{w}_{MAP})$

- **ベイズ推測**
 $= \mathbb{E}_{\mathbf{w}}[p(\mathbf{x}|\mathbf{w})]$

Given

入力: \mathbf{x}

教師: $t = g(\mathbf{x}) + \text{noise}$



モデル: $y = f(\mathbf{x}, \mathbf{w}) + \text{noise}$

任意の誤差関数: $\mathcal{L}(\mathbf{x}, \mathbf{w}, t)$

$y(\mathbf{x}; \mathcal{D}) = f(\mathbf{x}, \mathbf{w}^*) + \text{noise}$



\mathbf{w}_{ML} とか、 \mathbf{w}_{MAP} とか、

教師: $t = g(\mathbf{x}) + \text{noise}$

学習後のモデル: $y(\mathbf{x}; \mathcal{D}) = f(\mathbf{x}, \mathbf{w}^*) + \text{noise}$


訓練誤差

$$\frac{1}{|\mathcal{D}|} \sum \mathcal{L}(\mathbf{x}, \mathbf{w}^*, t)$$

汎化誤差

$g(\mathbf{x})$ と $f(\mathbf{x}, \mathbf{w}^*)$ の差。


\mathcal{L} を二乗誤差関数とすれば？



二乗誤差を最小にするパラメータを \mathbf{w}^* とする。

訓練誤差

$$T(\mathbf{w}^*) = \frac{1}{|\mathcal{D}|} \sum_i (t_i - f(\mathbf{x}_i, \mathbf{w}^*))^2$$




汎化誤差

$$G(\mathbf{w}^*) = \iint (t - f(\mathbf{x}, \mathbf{w}^*))^2 p(\mathbf{x}, t) d\mathbf{x} dt$$

バイアス モデル近似誤差。


どんなにパラメータを工夫しても
 $f(\mathbf{x}, \mathbf{w})$ は $g(\mathbf{x})$ になれない。



バリアンス 統計的推定誤差。

データにはノイズが含まれており、
使うデータセットに応じてパラメータの推定がばらつく。

実際に数式を分解してみる



誤差関数: $\mathcal{L}(t, y(\mathbf{x}))$

期待損失(汎化誤差): $\mathbb{E} [\mathcal{L}] = \iint \mathcal{L}(t, y(\mathbf{x})) p(\mathbf{x}, t) d\mathbf{x} dt$


$$h(\mathbf{x}) = \arg \min_y \mathbb{E} [\mathcal{L}]$$

$\mathcal{L}(t, y(\mathbf{x}))$ が二乗誤差関数の場合、 $h(\mathbf{x}) = \mathbb{E}_t [t | \mathbf{x}]$



$y(\mathbf{x})$ を求める問題を、
 $y(\mathbf{x}, \mathbf{w})$ のパラメータを \mathbf{w} 求める問題に。

データにはノイズが含まれるため、推定値はデータセットによってぶれる



$$\mathbf{w}_1^* = \arg \min_{\mathbf{w}} \sum_{\mathcal{D}_1} \mathcal{L}$$

$$\mathbf{w}_2^* = \arg \min_{\mathbf{w}} \sum_{\mathcal{D}_2} \mathcal{L}$$

⋮

データセットについて平均して評価する。

$$\mathbb{E}_{\mathcal{D}} [\mathbb{E} [\mathcal{L}]] = \mathbb{E}_{\mathcal{D}} [G]$$

$$= \int \{\mathbb{E}_{\mathcal{D}}[y(\mathbf{x}; \mathcal{D})] - h(\mathbf{x})\}^2 p(\mathbf{x}) d\mathbf{x}$$


(バイアス)²

$$+ \int \mathbb{E}_{\mathcal{D}} \left[\{y(\mathbf{x}; \mathcal{D}) - \mathbb{E}_{\mathcal{D}}[y(\mathbf{x}; \mathcal{D})]\}^2 \right] p(\mathbf{x}) d\mathbf{x}$$

バリアンス

$$+ \iint \{h(\mathbf{x}) - t\}^2 p(\mathbf{x}, t) d\mathbf{x} dt$$

ノイズ



$$h(x) = \sin(2\pi x)$$

$$\mathcal{D}^{(l)} (l = 1, \dots, L; L = 100)$$

$$\mathcal{D} = \{x_n, t_n\}_{n=1}^{N=25}$$


$$\frac{1}{2} \sum_{n=1}^N \left\{ t_n - \mathbf{w}^T \phi(\mathbf{x}_n) \right\}^2 + \frac{\lambda}{2} \mathbf{w}^T \mathbf{w}$$

100個の回帰を得る

平均をとることは有用かも？



単なる平均と
ベイズ推測の違いは？



- **最尤推測**
 $= p(\mathbf{x}|\mathbf{w}_{ML})$

- **平均プラグイン推測**
 $= p(\mathbf{x}|\mathbb{E}_{\mathbf{w}}[\mathbf{w}])$

- **MAP推測**
 $= p(\mathbf{x}|\mathbf{w}_{MAP})$

- **ベイズ推測**
 $= \mathbb{E}_{\mathbf{w}}[p(\mathbf{x}|\mathbf{w})]$

$$(\text{bias})^2 = \frac{1}{N} \sum_{n=1}^N \{\bar{y}(x_n) - h(x_n)\}^2$$

$$\text{variance} = \frac{1}{N} \sum_{n=1}^N \frac{1}{L} \sum_{l=1}^L \left\{ y^{(l)}(x_n) - \bar{y}(x_n) \right\}^2$$

$$\bar{y}(x) = \frac{1}{L} \sum_{l=1}^L y^{(l)}(x) \approx \mathbb{E}_{\mathcal{D}} [y(x; \mathcal{D})]$$

データセットを複数用意することで
モデルの複雑さについて考察ができた。

