

パターン認識と機械学習

1.2.5 曲線フィッティング再訪

吉田拓夢

曲線フィッティング問題

- ・N個の入力値の訓練データ集合 $\mathbf{x} = (x_1, \dots, x_N)^T$
それに対応する目標値 $\mathbf{t} = (t_1, \dots, t_N)^T$
→新たな入力値 x に対する目標変数 t の予測

- ・ 目標変数の値に関する不確実性→確率分布
 x に対する t は平均が多項式曲線 $y(x, \mathbf{w})$ に等しい
ガウス分布に従う

$$p(t|x, \mathbf{w}, \beta) = \mathcal{N}(t|y(x, \mathbf{w}), \beta^{-1})$$

β : 分布の逆分散に相当するパラメータ

最尤推定

- 訓練データ $\{\mathbf{x}, \mathbf{t}\}$ を用いて未知パラメータ \mathbf{w}, β を求める
データが分布から独立に取られるとして尤度関数は

$$p(\mathbf{t}|\mathbf{x}, \mathbf{w}, \beta) = \prod_{n=1}^N \mathcal{N}(t_n | y(x_n, \mathbf{w}), \beta^{-1})$$

- 尤度関数の最大化が便利

ガウス分布の形を置きかえると対数尤度関数は

$$\ln p(\mathbf{t}|\mathbf{x}, \mathbf{w}, \beta) = -\frac{\beta}{2} \sum_{n=1}^N \{y(x_n, \mathbf{w}) - t_n\}^2 + \frac{N}{2} \ln \beta - \frac{N}{2} \ln(2\pi)$$

最尤推定

- 最尤解で定まる多項式の係数 \mathbf{w}_{ML} (\mathbf{w} の最大化)

$$-\frac{\beta}{2} \sum_{n=1}^N \{y(x_n, \mathbf{w}) - t_n\}^2 + \frac{N}{2} \ln \beta - \frac{N}{2} \ln(2\pi)$$

$$-\frac{\beta}{2} \sum_{n=1}^N \{y(x_n, \mathbf{w}) - t_n\}^2 \quad \leftarrow \mathbf{w} \text{に依存しない項を無視}$$

$$-\frac{1}{2} \sum_{n=1}^N \{y(x_n, \mathbf{w}) - t_n\}^2 \quad \leftarrow \text{正の定数倍で}\mathbf{w} \text{の最大値の位置は変わらない}$$

$$\frac{1}{2} \sum_{n=1}^N \{y(x_n, \mathbf{w}) - t_n\}^2 \quad \leftarrow -1 \text{倍: (最大化} \rightarrow \text{最小化)}$$

- \mathbf{w} を決める観点で二乗和誤差の最小化と等価
- 二乗和誤差関数 \leftarrow 尤度の最大化の結果
(ノイズがガウス分布に従う仮定の下で)

最尤推定

- 条件付きガウス分布の精度パラメータ β

$$\frac{1}{\beta_{\text{ML}}} = \frac{1}{N} \sum_{n=1}^N \{y(x_n, \mathbf{w}_{\text{ML}}) - t_n\}^2$$

予測分布

- パラメータ w, β の決定 $\rightarrow x$ の新たな値の予測
- 確率モデルで定式化 \rightarrow 予測分布という形で t の確率分布を与えられる

$$p(t|x, \mathbf{w}_{\text{ML}}, \beta_{\text{ML}}) = \mathcal{N}(t|y(x, \mathbf{w}_{\text{ML}}), \beta_{\text{ML}}^{-1})$$

事前分布の導入

- 簡便のため、以下のガウス分布を考える

$$p(\mathbf{w}|\alpha) = \mathcal{N}(\mathbf{w}|\mathbf{0}, \alpha^{-1}\mathbf{I}) = \left(\frac{\alpha}{2\pi}\right)^{(M+1)/2} \exp\left\{-\frac{\alpha}{2}\mathbf{w}^T\mathbf{w}\right\}$$

α : 分布の精度パラメータ ← 超パラメータ(hyperparameter)

$M+1$: M 次多項式に対する \mathbf{w} の要素数

- ベイズの定理から \mathbf{w} の事後分布は事前分布と尤度関数との積に比例

$$p(\mathbf{w}|\mathbf{x}, \mathbf{t}, \alpha, \beta) \propto p(\mathbf{t}|\mathbf{x}, \mathbf{w}, \beta)p(\mathbf{w}|\alpha)$$

- 与えられたデータに基づく最も確からしい \mathbf{w} の値を見つける。
(事後分布を最大化する \mathbf{w} を決める)

→ 最大事後確率推定(maximum posterior)/MAP推定

最大事後確率推定

- 事後確率の最大値は以下の最小値として与えられる

$$\frac{\beta}{2} \sum_{n=1}^N \{y(x_n, \mathbf{w}) - t_n\}^2 + \frac{\alpha}{2} \mathbf{w}^T \mathbf{w}$$

{ $p(\mathbf{t}|\mathbf{x}, \mathbf{w}, \beta)p(\mathbf{w}|\alpha)$ を対数をとって符号を反転 }

→ 正則化された二乗和誤差の最小化と等価

$$\tilde{E}(\mathbf{w}) = \frac{1}{2} \sum_{n=1}^N \{y(x_n, \mathbf{w}) - t_n\}^2 + \frac{\lambda}{2} \|\mathbf{w}\|^2$$

正規化パラメータは $\lambda = \alpha/\beta$