

正則化最小二乘法 (Ridge, lasso)

Regularized Least Squares Method

大阪府立大学 工学研究科
清水 悠生

はじめに

- ✓ 本記事の図の作成に使用したPythonコードは全てGitHubで公開しています


(復習)最小二乗法で扱う誤差関数

- ✓ 誤差関数を誤差の2乗の和とし
誤差関数が最小となるような係数を計算する

(入力変数が2つの場合の)最小二乗法で扱う誤差関数 $E(\mathbf{w})$

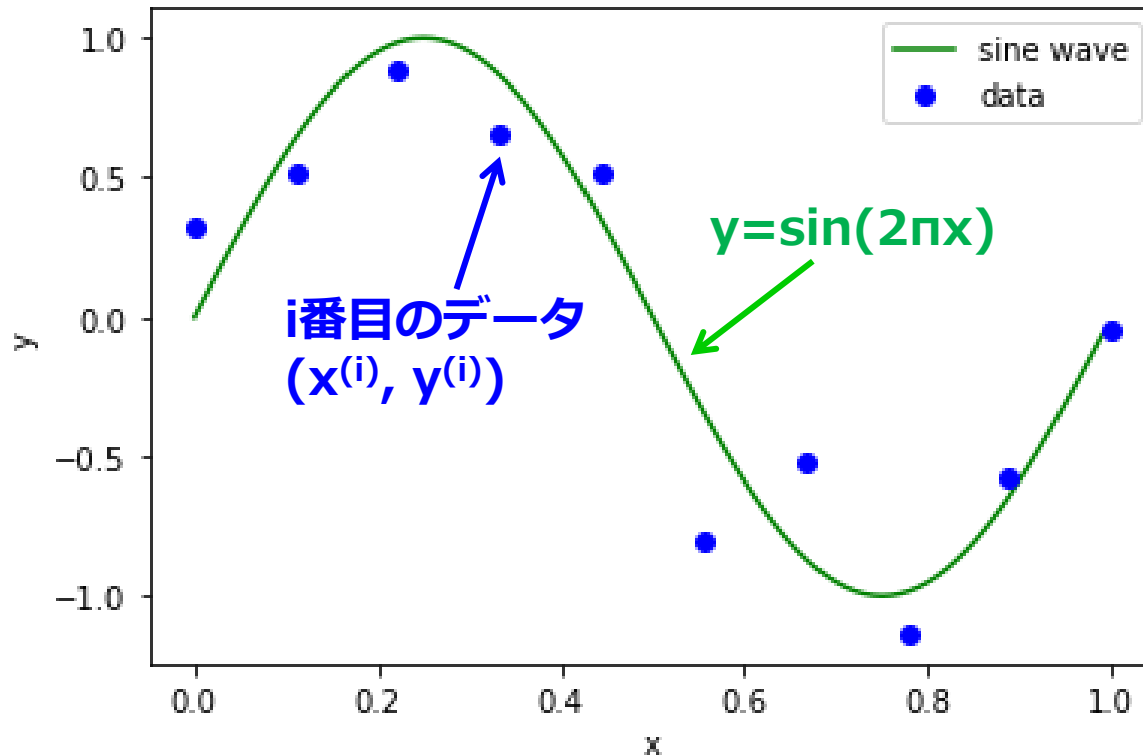
$$E(\mathbf{w}) = \sum_{i=1}^n \frac{1}{2} \underbrace{\left(y^{(i)} - (w_0 + w_1 x_1^{(i)} + w_2 x_2^{(i)}) \right)^2}_{\text{誤差の2乗}} \quad \mathbf{w} = \begin{bmatrix} w_0 \\ w_1 \\ w_2 \end{bmatrix}$$

n個のデータを仮定



多項式回帰の例

- ✓ サインカーブに正規分布ノイズを加えた10個のデータから多項式回帰分析を行う場合を考える



$x^{(i)}$ は区間 $[0,1]$ で等間隔に10点生成

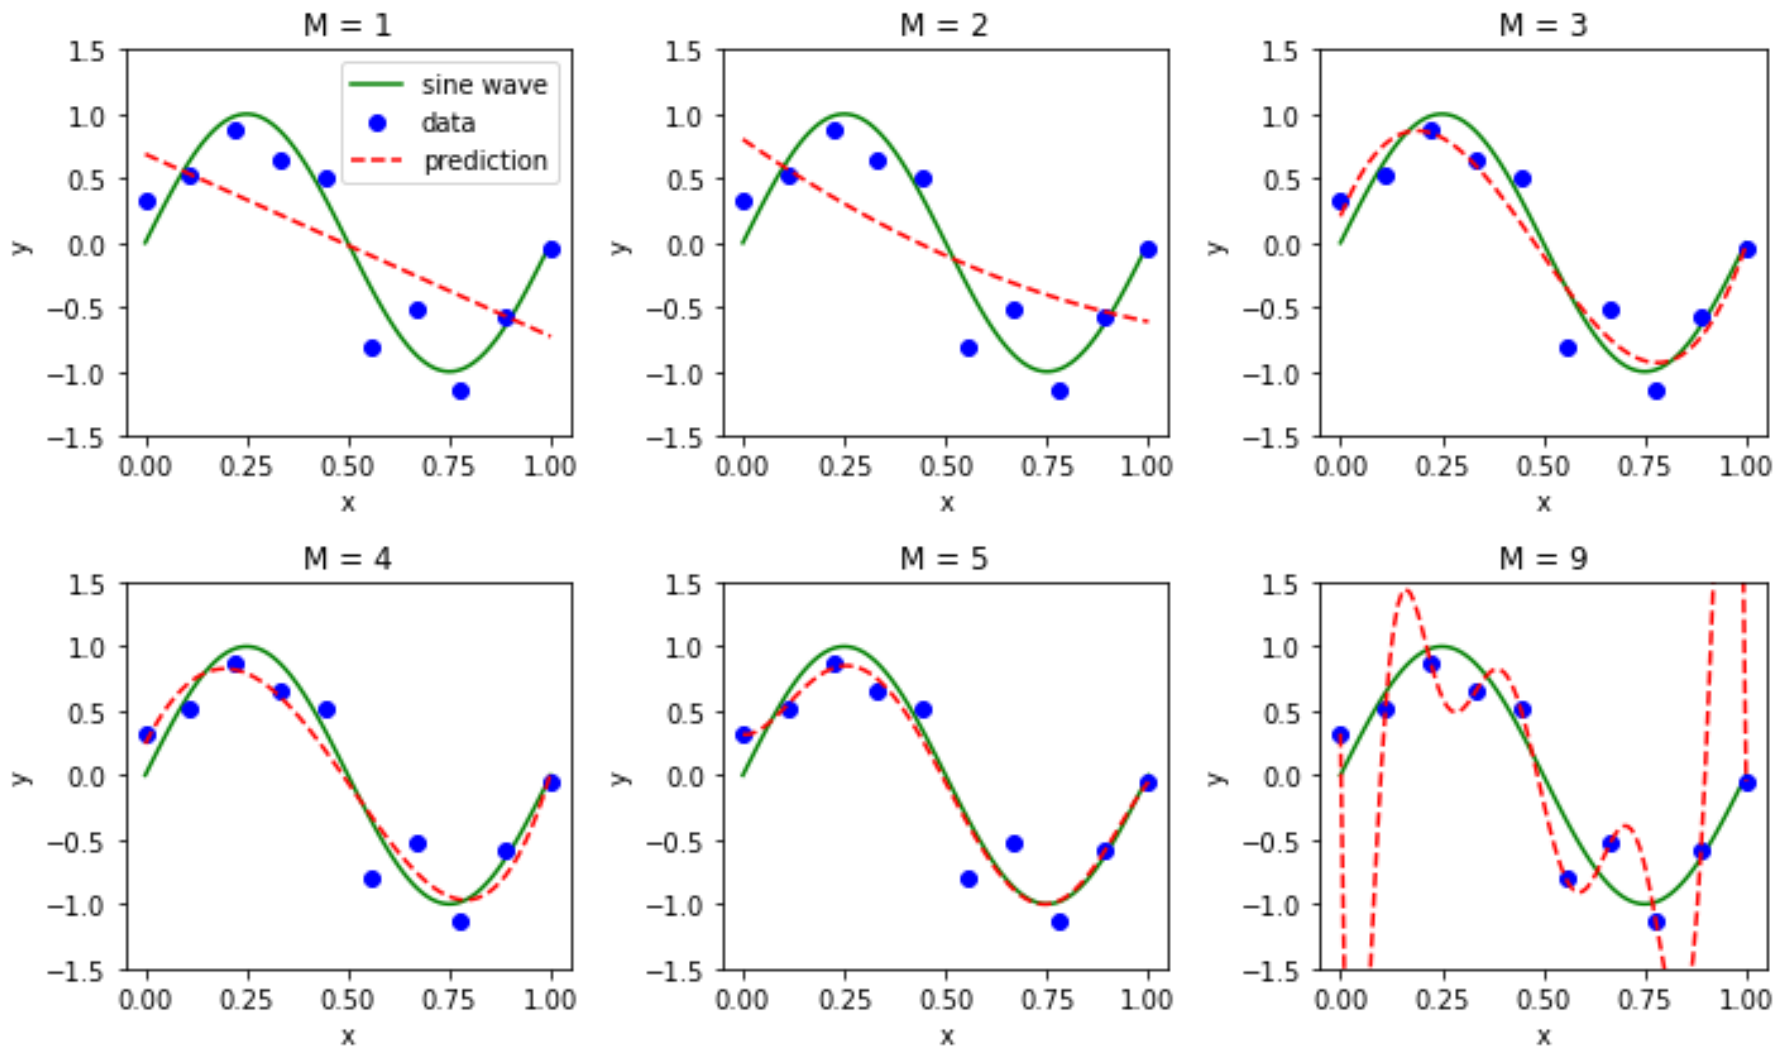
$y^{(i)}$ は平均0, 分散0.04の正規分布ノイズを加味して, 次式に従って生成
$$y^{(i)} = \sin(2\pi x^{(i)}) + N(0,0.04)$$

多項式回帰の例

多項式回帰式


$$y = \sum_{i=0}^M w_i x^i$$

- ✓ 最小二乗法により多項式回帰の係数を計算
- ✓ $M=3\sim 5$ あたりでサインカーブへのあてはまりが良い



過学習とは

- ✓ M=9の例では回帰曲線が全てのデータを通っており誤差関数 $E(\mathbf{w}^*)=0$ となっている
- ✓ これは与えられたデータ数が10組なのに対し学習する係数も10個存在するため
- ✓ 回帰曲線はノイズに過度に引きずられており適切とは言えない⇒**過学習**と呼ばれる現象

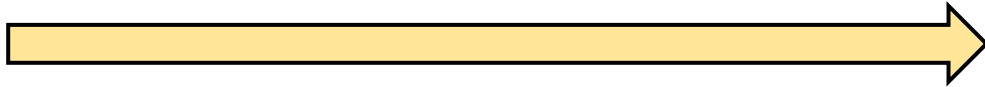


$$y = w_0 + w_1x^1 + w_2x^2 + \dots + w_8x^8 + w_9x^9$$

与えられたノイズを含む点列に過度に適合している
⇒過学習 (過適合; over-fitting)

過学習の際の係数の値

- ✓ 次数が大きくなるにつれ係数の値も大きくなる
- ✓ 直感的には、学習の自由度が増えノイズの影響を受けやすくなるため



次数が増加すると
係数が大きくなる

	M=1	M=2	M=3	M=4	M=5	M=9
w0	0.69	0.80	0.21	0.24	0.32	0.32
w1	-1.42	-2.19	7.66	6.28	-0.47	-254.05
w2	nan	0.78	-25.19	-18.21	38.05	5954.13
w3	nan	nan	17.31	6.12	-152.90	-54168.85
w4	nan	nan	nan	5.60	187.87	257772.53
w5	nan	nan	nan	nan	-72.91	-712418.06
w6	nan	nan	nan	nan	nan	1183107.13
w7	nan	nan	nan	nan	nan	-1162608.56
w8	nan	nan	nan	nan	nan	622374.75
w9	nan	nan	nan	nan	nan	-139759.40

最小二乗法により得られた各回帰式の係数

正則化項の導入

- ✓ 誤差関数に**正則化項**を導入
- ✓ 誤差最小化時に係数も最小化されるので過学習を抑制できる
- ✓ 正則化項の次数 $q=2$ の時の回帰手法を**ridge回帰**
 $q=1$ の時の回帰手法を**lasso**と呼ぶ

正則化最小二乗法で扱う誤差関数

$$\tilde{E}(\mathbf{w}) = \underbrace{E(\mathbf{w})}_{\text{二乗和誤差項}} + \underbrace{\frac{\alpha}{2} \sum_{i=0}^M |w_i|^q}_{\text{正則化項}}$$


α : 二乗和誤差項と正則化項の相対的な重要度を調整するハイパーパラメータ
(パラメータ \mathbf{w} を決定するためのパラメータなのでハイパーパラメータと呼ぶ)

正則化項の代表的な例

$$\sum_{i=0}^M |w_i|^q = \begin{cases} w_0^2 + w_1^2 + \dots + w_M^2 & \mathbf{q=2} \Rightarrow \text{ridge回帰} \\ |w_0| + |w_1| + \dots + |w_M| & \mathbf{q=1} \Rightarrow \text{lasso} \end{cases}$$

正則化項を導入した際の回帰曲線

- ✓ 正則化項を導入すると発振が抑えられ
サインカーブへのあてはまりが良くなることわかる



正則化項を導入した9次多項式回帰の学習結果

正則化項を導入した際の回帰係数

- ✓ 正則化項を導入すると係数の値が小さく抑えられる
- ✓ **lassoにはいくつかの係数が0となる**
スプース（疎）な解が得られやすいという特徴がある

	OLS (M=9)	ridge	lasso
w0	0.3249	0.5736	0.4444
w1	-254.0475	0.7424	2.6888
w2	5954.1292	-3.0046	-7.6257
w3	-54168.8450	-1.8439	-0.0000
w4	257772.5254	-0.3024	0.0000
w5	-712418.0575	0.6704	2.1443
w6	1183107.1250	1.0621	2.3690
w7	-1162608.5621	1.0392	0.0000
w8	622374.7536	0.7569	0.0000
w9	-139759.3957	0.3271	-0.0000

**lassoでは
スプースな解が
得られる**


正則化項を導入した9次多項式回帰の係数

誤差関数の幾何学的解釈(1/2)


- ✓ 線形回帰の誤差関数を考える
- ✓ 係数 w_0, w_1 に対する誤差関数の等高線は楕円型となる

二乗和誤差項(線形回帰)

$$\sum_{i=1}^n \frac{1}{2} \left(y^{(i)} - (w_0 + w_1 x_1^{(i)}) \right)^2$$



二乗和誤差項が最小となる点




係数 w_0, w_1 に対する誤差項の変化

誤差関数の幾何学的解釈(2/2)


✓ 正則化項は下図のようになる

正則化項(ridge)

$$w_0^2 + w_1^2$$





誤差関数が最小となる点は原点



正則化項(lasso)

$$|w_0| + |w_1|$$




係数 w_0 , w_1 に対する正則化項の変化

なぜlassoはスパース解が得られやすいのか(1/2)

✓ 正則化項付き誤差関数の最小化を制約あり最小化に変換

$$\min \underbrace{\sum_{i=1}^n \frac{1}{2} \left(y^{(i)} - (w_0 + w_1 x_1^{(i)}) \right)^2}_{\text{二乗和誤差項}} + \underbrace{\frac{\alpha}{2} \sum_{i=0}^2 |w_i|^q}_{\text{正則化項}}$$



ラグランジュの未定乗数法より等価


η : ラグランジュ乗数
から決まる定数

$$\min \underbrace{\sum_{i=1}^n \frac{1}{2} \left(y^{(i)} - (w_0 + w_1 x_1^{(i)}) \right)^2}_{\text{目的関数は二乗和誤差項のみ}} \quad \text{s.t.} \quad \underbrace{\sum_{i=0}^2 |w_i|^q \leq \eta}_{\text{正則化項は制約条件に}}$$

目的関数は二乗和誤差項のみ

正則化項は制約条件に

イメージ



($q=2$ の場合)
半径 $\sqrt{\eta}$ の円内で
二乗和誤差が最小となる
点を探査する

なぜlassoはスパース解が得られやすいのか(2/2)

✓ lassoではスパース解となりやすい！

