

数理情報工学特論第一
【機械学習とデータマイニング】
2章：回帰（3）

かしま ひさし
鹿島 久嗣
(数理 6 研)

kashima@mist.i.~

教師つき学習の王道である「回帰」について学びます

- 回帰問題の定義
 - 線形回帰問題の定式化
 - 線形回帰問題の初等的解法
 - リッジ回帰： L_2 正則化による過学習の回避
 - 交差確認によるハイパーパラメータの決定
 - Leave-one-out交差確認
 - 回帰問題の確率モデル的解釈
-
- 回帰の応用
 - カーネル回帰
 - L_1 正則化



回帰の重要な応用

線形回帰の自明でない使い方を2つ紹介します

- 時系列予測
- 分類

時系列予測

- 線形回帰の1つの使い方として、時系列予測に用いることができる
- 時系列とは、時刻 $t=1,2,\dots$ に関連づけられた、実数値の列 $x_1, x_2, \dots (x_t \in \mathcal{R})$
- 時系列予測の目的は、ある時刻 t における時系列の値 $x_t \in \mathcal{R}$ をそれ以前の値 x_1, x_2, \dots, x_{t-1} から予測すること
- 時系列予測のための代表的モデルの1つが、**自己回帰モデル**もしくは**AR(Auto Regressive)モデル**と呼ばれるモデル
- D 次の自己回帰モデル：

$$x_t = w_1 x_{t-1} + w_2 x_{t-2} + \dots + w_D x_{t-D}$$

- ある時刻 t における値は、過去 D 時点分の値から決まる
- モデルのパラメータは (w_1, w_2, \dots, w_D)

自己回帰モデルの学習は、 線形回帰としてみることができます

- D次の自己回帰モデルは、

$$x_t = w_1 x_{t-1} + w_2 x_{t-2} + \cdots + w_D x_{t-D}$$

- これは、特徴ベクトルを $(x_{t-1}, x_{t-2}, \dots, x_{t-D})$ 、パラメータを (w_1, w_2, \dots, w_D) と考えれば、まさに線形回帰のモデル
- 時刻1から時刻 T までの時系列の値 x_1, x_2, \dots, x_T が与えられたときに時刻 $T+1$ の値を予測したいものとする
- 時刻 T までの時系列 x_1, x_2, \dots, x_T から長さ $D+1$ の窓をずらしながら $T-D$ 個の訓練データを作ることができる。
- これらから、線形回帰の方法を用いてパラメータ w を推定し、それをもとに x_T を予測する。
- 時系列予測については、より詳細なモデルや特化した解法がある

回帰で分類問題を解く

- 回帰を用いて分類問題（例えば、2値分類 $y \in \{+1, -1\}$ の場合）を解く
- 便宜的に各訓練データの出力を $y^{(i)} \in \{+1, -1\}$ として回帰を適用する
 - 予測時には、 $f(x; \mathbf{w})$ が0以上の値であるなら出力「+1」、そうでないならば「-1」として予測する
- 出力は+1か-1のどちらかなので、回帰の仮定（出力にガウスのノイズが入る）は成立せず、このような適用は厳密には少しおかしい
- 分類問題をより適切にモデル化する方法は複雑になるため、分類問題を手軽に扱えるという意味で、このやり方は妥協に値する。
- なお、実際は訓練データの出力を $y^{(i)} \in \{+1, -1\}$ とするのではなく、 $y^{(i)} \in \{+1/|N_+|, -1/|N_-|\}$ としたほうがよい
 - 出力が+1の訓練データの数を $|N_+|$ 、出力が-1の訓練データの数を $|N_-|$
 - フィッシャー判別に対応

カーネル回帰

データ数よりも次元数が大きい場合の回帰： データ数に依存した計算量にすることができます

- リッジ回帰の解は、以下で与えられた

$$\mathbf{w}^* = (\Phi^\top \Phi + \lambda \mathbf{I})^{-1} \Phi^\top \mathbf{y}$$

- これは次元数×次元数 ($D \times D$) の行列の逆行列計算（もしくは連立方程式の解）が必要

– $O(D^3)$

- もしも（訓練データ数 N と比較して）次元数 D が大きい場合にはどうしたらよいだろうか？

- 実は、計算量が訓練データ数に依存するように問題を変換することができる

– $O(N^3)$

ここで便利なのが、ウッドベリーの公式です：
逆行列計算のサイズを小さくできることがあります

- ウッドベリー(Woodbury)の公式：

$$(\mathbf{A} + \mathbf{UCV}^\top)^{-1} = \mathbf{A}^{-1} - \mathbf{A}^{-1}\mathbf{U}(\mathbf{C}^{-1} + \mathbf{V}^\top\mathbf{A}^{-1}\mathbf{U})^{-1}\mathbf{V}^\top\mathbf{A}^{-1}$$

– シャーマン・モリソンの公式の一般化になっている

- $\mathbf{C} \equiv \mathbf{I}$ として、 \mathbf{U} と \mathbf{V} をベクトルとするとシャーマン-モリソンに一致する
- $$(\mathbf{A} + \mathbf{uv}^\top)^{-1} = \mathbf{A}^{-1} - \frac{\mathbf{A}^{-1}\mathbf{u}\mathbf{v}^\top\mathbf{A}^{-1}}{1 + \mathbf{v}^\top\mathbf{A}^{-1}\mathbf{u}}$$

- 重要なポイントは：

- LOOCVのときと同じく \mathbf{A}^{-1} が出てくるところ
- \mathbf{U} と \mathbf{V} が縦長の行列の場合、
右辺のほうが逆行列のサイズが小さいところ

ウッドベリーの公式を用いると、リッジ回帰の計算量を $O(D^3) \rightarrow O(N^3)$ (次元の3乗からデータ数の3乗) にできます

■ ウッドベリー

$$(\mathbf{A} + \mathbf{UCV}^\top)^{-1} = \mathbf{A}^{-1} - \mathbf{A}^{-1}\mathbf{U}(\mathbf{C}^{-1} + \mathbf{V}^\top\mathbf{A}^{-1}\mathbf{U})^{-1}\mathbf{V}^\top\mathbf{A}^{-1}$$

で $\mathbf{A} \equiv \lambda \mathbf{I}$ 、 $\mathbf{U} \equiv \mathbf{V} \equiv \Phi^\top$ 、 $\mathbf{C} \equiv \mathbf{I}$ とおいてみると、リッジ回帰の解における逆行列の部分を以下のように書き直せる

$$(\Phi^\top\Phi + \lambda\mathbf{I})^{-1} = \frac{1}{\lambda}\mathbf{I} + \frac{1}{\lambda^2}\Phi^\top\left(\mathbf{I} + \frac{1}{\lambda}\Phi\Phi^\top\right)^{-1}\Phi$$

– 左辺では $D \times D$ の逆行列計算が、右辺では $N \times N$ の逆行列計算

- 両辺で逆行列の中の Φ と Φ^\top の順序が逆になっていることに注意

– つまり、 $D > N$ のときには、右辺のほうが計算量的に有利

■ 右辺に出てくる行列 $\Phi\Phi^\top$ はグラム行列と呼ばれ、その各要素は訓練データの特徴ベクトル間の内積になっている

■ これはまさにカーネル法におけるカーネル関数であり、我々は「ウッドベリーの公式を用いてカーネルリッジ回帰を導いた」

L_1 正則化

L_1 正則化は、疎な解を与えるため、 L_2 正則化と並び重要な正則化のひとつです

- 1-ノルムを用いた正則化は L_1 正則化と呼ばれる
 - L_2 正則化と並び、よく利用される

- L_1 正則化を用いた時の線形回帰の目的関数：

$$L(\mathbf{w}) = \|\Phi\mathbf{w} - \mathbf{y}\|_2^2 + \lambda \|\mathbf{w}\|_1$$

- L_1 正則化は「疎な解」を与える
 - 目的関数を最小化する \mathbf{w}^* において、多くの次元が丁度0になる
 - 特徴ベクトル ϕ の次元が非常に高く、
その一方で、実際に予測に有用な特徴が少ない場合に特に有効
 - 学習済みのモデルを用いて予測を行う際、
予測の計算量は \mathbf{w} の 0 でない次元数に依存する

L_1 正則化を用いた場合には (L_1 正則化の場合と違い) 最適化問題の解が閉じた形では求まりません

- L_1 正則化を用いた回帰における最適化問題は、リッジ回帰のときと異なり、解が閉じた形で求まらないため、その解法は複雑になる

- L_2 正則化を用いた回帰 (リッジ回帰) の解

$$\mathbf{w}^* = (\Phi^\top \Phi + \lambda \mathbf{I})^{-1} \Phi^\top \mathbf{y}$$

- 以降、2つの比較的簡単な方法を見ていくことにする

- 方法1: 次元ごとの逐次解法

- 方法2: L_2 正則化への帰着

方法1: 次元ごとの逐次解法

1つのパラメータに注目した最適化を繰り返します

- L_1 正則化項 $\| \mathbf{w} \|_1$ は：
 - 原点で微分できない
 - 原点が最適解となる場合が多いという問題があり、扱いづらい
- パラメータ $\mathbf{w} = (w_1, w_2, \dots, w_D)$ の、ある特定の次元 w_d に注目すると目的関数 $L(\mathbf{w}) = \| \Phi \mathbf{w} - \mathbf{y} \|_2^2 + \lambda \| \mathbf{w} \|_1$ の最小化は簡単に行える
- そこで、
 1. 次元 d を適当に選ぶ
 2. パラメータ w_d についての最適化を行うを、収束するまで繰り返すアルゴリズムを考える

ある次元のパラメータ (w_d) に注目した目的関数を考えます

- i 番目のデータに対するモデルの予測は、パラメータの d 次元目 w_d を特別扱いすれば：

$$\mathbf{w}^\top \phi(x^{(i)}) = w_d \phi_d(x^{(i)}) + \sum_{j \neq d} w_j \phi_j(x^{(i)})$$

- 目的関数を w_d についての関数であると思えば：

$$L(w_d) = \sum_{i=1}^N \left(w_d \phi_d(x^{(i)}) - \left(y^{(i)} - \sum_{j \neq d} w_j \phi_j(x^{(i)}) \right) \right)^2 + \lambda |w_d| + \sum_{j \neq d} |w_j|$$

– 残りの w_j ($j \neq d$) は定数であると思う

- 最後の項は w_d に関係ないので無視すると、最小化問題は：

$$w_d^* = \operatorname{argmin}_{w_d} \sum_{i=1}^N \left(w_d \phi_d(x^{(i)}) - \left(y^{(i)} - \sum_{j \neq d} w_j \phi_j(x^{(i)}) \right) \right)^2 + \lambda |w_d|$$

ひとまずは、正則化項を無視して解いてみます

- 以下の1変数最小化問題を解きたい

$$w_d^* = \operatorname{argmin}_{w_d} \sum_{i=1}^N \left(w_d \phi_d(x^{(i)}) - \left(y^{(i)} - \sum_{j \neq d} w_j \phi_j(x^{(i)}) \right) \right)^2 + \lambda |w_d|$$

- 厄介なのが最後の項 $\lambda |w_d|$
- この項は $w_d = 0$ において、微分が定義されないために、単純に目的関数の微分を取って0とにおいて...という方法が使えない

- ひとまずは、最後の項を無視して：

$$\tilde{w}_d = \operatorname{argmin}_{w_d} \sum_{i=1}^N \left(w_d \phi_d(x^{(i)}) - \left(y^{(i)} - \sum_{j \neq d} w_j \phi_j(x^{(i)}) \right) \right)^2$$

を解いてみると、この解は簡単に求まり：

$$\tilde{w}_d = \frac{\sum_{i=1}^N \left(y^{(i)} - \sum_{j \neq d} w_j \phi_j(x^{(i)}) \right) \phi_d(x^{(i)})}{\sum_{i=1}^N \phi_d(x^{(i)})^2}$$

正則化ナシの解を使って、目的関数を書き換えてみます

- これを用いて損失関数の部分を書き換えてみると、

$$w_d^* = \operatorname{argmin}_{w_d} \left(\sum_{i=1}^N \phi_d(x^{(i)})^2 \right) (w_d - \tilde{w}_d)^2 + \lambda |w_d|$$

— 定数項は最小化に関係ないので無視した

- ここで、今後の表記を簡単にするために

$$\gamma \equiv \frac{\lambda}{2 \sum_{i=1}^N \phi_d(x^{(i)})^2}$$

とおく

- γ を使って目的関数を書きなおすと：

$$w_d^* = \operatorname{argmin}_{w_d} \tilde{L}(w_d)$$

$$\tilde{L}(w_d) \equiv \frac{1}{2} (w_d - \tilde{w}_d)^2 + \gamma |w_d|$$

目的関数の微分を考えてみます（場合分け）

- $\tilde{L}(w_d) \equiv \frac{1}{2}(w_d - \tilde{w}_d)^2 + \gamma|w_d|$ の微分を計算してみると

$$\frac{dL(w_d)}{dw_d} = \begin{cases} w_d - \tilde{w}_d + \gamma & (\text{if } w_d > 0) \\ w_d - \tilde{w}_d - \gamma & (\text{if } w_d < 0) \\ \text{undefined} & (\text{if } w_d = 0) \end{cases}$$

– $w_d = 0$ のとき：

- $|w_d|$ が微分できないため定義されない


– $w_d > 0$ のとき：

- 傾き1で切片が $-\tilde{w}_d + \gamma$ の一次関数

– $w_d < 0$ のとき：


- 傾き1で切片が $-\tilde{w}_d - \gamma$ の一次関数

- これが0になる w_d を探す



求まった解を見てみると、確かに「疎」な傾向が見えてきます

- グラフが0と交わる w_d を探す
- 場合1: $-\tilde{w}_d + \gamma < 0$ すなわち $\tilde{w}_d > \gamma$ のときには解は $w_d^* = \tilde{w}_d - \gamma$
- 場合2: $-\tilde{w}_d - \gamma < 0$ すなわち $\tilde{w}_d < -\gamma$ のときには解は $w_d^* = \tilde{w}_d + \gamma$
- 場合3: $-\gamma \leq \tilde{w}_d \leq \gamma$ のとき
 - $w_d^* > 0$ とすると $w_d^* = \tilde{w}_d - \gamma \leq 0$ となり矛盾
 - $w_d^* < 0$ とすると $w_d^* = \tilde{w}_d + \gamma \geq 0$ となり矛盾
 - 解は必ず存在するので、
従って $w_d^* = 0$ でないと困る
- 場合3を見ると、正則化なしの解 \tilde{w}_d が0に近いところでは、 L_1 正則化の解が0になる
(→ 疎になる)



方法2: L_2 正則化 (リッジ回帰) への帰着

簡単に解けるリッジ回帰の繰り返し解法に変換します

- L_1 正則化項 $\| \mathbf{w} \|_1 \equiv \sum_{d=1}^D |w_d|$ を直接扱うのは若干煩雑
- 一方、 L_2 正則化を用いた回帰 (リッジ回帰) は、逆行列の計算によって求まるのでシンプル

$$\mathbf{w}^* = (\Phi^T \Phi + \lambda \mathbf{I})^{-1} \Phi^T \mathbf{y}$$

- そこで、 L_1 正則化による回帰 (ラッソ回帰) を、リッジ回帰の繰り返しによって解く方法を考える
- ポイントは、 L_1 正則化項の上界を、 L_2 正則化項を用いて作るところ
 - その代償として、パラメータが2倍に増える

L_1 正則化項の上界を、相加相乗平均によって作ります

- d 次元目についての正則化項 $|w_d|$ の上界を以下のように求める。

$$|w_d| = \sqrt{w_d^2} = \sqrt{\beta_d \frac{w_d^2}{\beta_d}} \leq \frac{1}{2} \left(\beta_d + \frac{w_d^2}{\beta_d} \right)$$

- 新たなパラメータ $\beta_d \geq 0$ が導入されていることに注意
- 最後の不等号は相加相乗平均、すなわち $a, b \geq 0$ について

$$\sqrt{ab} \leq \frac{a+b}{2}$$

できた上界は L_2 ノルムで書かれていることが分かります
(パラメータの数は増えてしまいます)

- L_1 正則化項の上界は：

$$\|\mathbf{w}\|_1 \leq \sum_{d=1}^D \beta_d + \sum_{d=1}^D \frac{w_d^2}{\beta_d}$$

- 特筆すべきは、上界においては各パラメータの2乗が現れるため、微分不可能な点が無くなっている点
- 新たなパラメータ $\beta \equiv (\beta_1, \beta_2, \dots, \beta_D)$ を導入したことにより、 \mathbf{w} と併せて、モデルパラメータの数は D から $2D$ に増加
- 従って、左辺の $\|\mathbf{w}\|_1$ を \mathbf{w} について最小化するかわりに、右辺を \mathbf{w} と β の両方について最小化することになる

増えたパラメータをまとめて最適化する必要があります

- L_1 正則化を用いた時の線形回帰の目的関数は

$$L(\mathbf{w}) \equiv \|\Phi\mathbf{w} - \mathbf{y}\|_2^2 + \lambda \|\mathbf{w}\|_1$$

- $L(\mathbf{w})$ の上界 $\tilde{L}(\mathbf{w})$ を作ると：

$$L(\mathbf{w}) \leq \|\Phi\mathbf{w} - \mathbf{y}\|_2^2 + \lambda \left(\sum_{d=1}^D \beta_d + \sum_{d=1}^D \frac{w_d^2}{\beta_d} \right) \equiv \tilde{L}(\mathbf{w}, \beta)$$

- 最適なパラメータ (\mathbf{w}^*, β^*) は、

$$(\mathbf{w}^*, \beta^*) = \underset{\mathbf{w}, \beta}{\operatorname{argmin}} \tilde{L}(\mathbf{w}, \beta)$$

によって求まることになる

アルゴリズム： \mathbf{w} と β の推定を交互に行います

- アルゴリズムとしては、以下の2ステップを繰り返す
 - A) (β を現在の値で固定しておいて) \mathbf{w} についての最小化
 - B) (\mathbf{w} を現在の値で固定しておいて) β についての最小化

$$(\mathbf{w}^*, \beta^*) = \operatorname{argmin}_{\mathbf{w}, \beta} \tilde{L}(\mathbf{w}, \beta)$$

$$\tilde{L}(\mathbf{w}, \beta) \equiv \|\Phi \mathbf{w} - \mathbf{y}\|_2^2 + \lambda \left(\sum_{d=1}^D \beta_d + \sum_{d=1}^D \frac{w_d^2}{\beta_d} \right)$$

ステップ A:

β についての最小化は簡単です

- w を固定したうえで、 β についての最小化を行う

- 相加相乗平均

$$\sqrt{ab} \leq \frac{a+b}{2}$$

の等号が成り立つのは、 $a=b$ のときである

- したがって、 $\beta_d = w_d^2 / \beta_d$ のとき、すなわち $\beta_d = |w_d|$ のときに
上界

$$|w_d| \leq \frac{1}{2} \left(\beta_d + \frac{w_d^2}{\beta_d} \right)$$


は最小化される

ステップ B :

\mathbf{w} についての最小化はリッジ回帰によって行えます

- 目的関数は
$$\tilde{L}(\mathbf{w}, \boldsymbol{\beta}) \equiv \|\Phi \mathbf{w} - \mathbf{y}\|_2^2 + \lambda \left(\sum_{d=1}^D \beta_d + \sum_{d=1}^D \frac{w_d^2}{\beta_d} \right)$$

$$\tilde{w}_d \equiv \frac{w_d}{\sqrt{\beta_d}} \text{ と置く}$$



$$\tilde{L}(\mathbf{w}, \boldsymbol{\beta}) = \|\Phi \text{diag}(\sqrt{\boldsymbol{\beta}}) \tilde{\mathbf{w}} - \mathbf{y}\|_2^2 + \lambda \left(\sum_{d=1}^D \beta_d + \sum_{d=1}^D \tilde{w}_d^2 \right)$$

- $\text{diag}(\cdot)$ は、引数のベクトルを対角成分に持つような行列
- $\tilde{\mathbf{w}} \equiv (\tilde{w}_1, \tilde{w}_2, \dots, \tilde{w}_D)$
- $\Phi \text{diag}(\sqrt{\boldsymbol{\beta}})$ を新たなデザイン行列と見ることによって、 $\tilde{\mathbf{w}}$ についてのリッジ回帰として捉えることができる
- $\tilde{\mathbf{w}}$ について最適化を行い、 \mathbf{w} に戻せば、
$$\mathbf{w} = \text{diag}(\sqrt{\boldsymbol{\beta}}) \left(\text{diag}(\sqrt{\boldsymbol{\beta}}) \Phi^\top \Phi \text{diag}(\sqrt{\boldsymbol{\beta}}) + \lambda \mathbf{I} \right)^{-1} \Phi^\top \mathbf{y}$$