



データ解析入門 19 <サポートベクター回帰>

キーワード：SVR、カーネルトリック、カーネル関数

はじめに

本稿では、サポートベクター回帰 (SVR; Support vector regression) と呼ばれる回帰モデルを紹介します。SVR は、カーネルトリックと呼ばれる技術を用いることで、非線形回帰モデルへと拡張することができます。カーネルトリックにより、表現力の高い予測モデルの構築が可能になります。

SVR の誤差関数

一般に、回帰モデルの構築では、何らかの損失関数を準備し、損失を最小にするパラメータを求めます。例えば、重回帰分析 (MLR) を行う場合、損失関数 $L(\beta)$ に残差平方和を用い、損失関数が最小になる回帰係数 β を求めます [式(1)]¹⁾。式(1)の N 、 y 、 X は、それぞれデータ数、目的変数ベクトル、データ行列です。

$$L(\beta) = \frac{1}{2N} \|y - X\beta\|_2^2 \quad (1)$$

ただし、MLR では多重共線性などに注意する必要があります。そのため、回帰係数の大きさにペナルティを課す Ridge 回帰などが提案されています。Ridge 回帰の誤差関数は、残差平方和に回帰係数ベクトルの L2 ノルムの 2 乗を加えた形をしており [式(2)]、予測モデルの当てはまりを大きく損なうことなく、絶対値が極端に大きな回帰係数が算出されることを防ぎます。なお、 λ は正則化パラメータです。

$$L_\lambda(\beta) = \frac{1}{2N} \|y - X\beta\|_2^2 + \lambda \|\beta\|_2^2 \quad (2)$$

一方、SVR では、式(2)を少し変形した損失関数を用います [式(3)]。ここで、 C および ε は SVR のハイパーパラメータ、添え字 i はサンプルインデックス、 $f(x_i)$ は i 番目の予測値です。

$$L_{C,\varepsilon}(\beta) = C \sum_{i=1}^N \max\{0, |y_i - f(x_i)| - \varepsilon\} + \|\beta\|_2^2 \quad (3)$$

式(2)、(3)の右辺第 1 項はいずれも予測誤差に関する項ですが、関数の形が異なります (図 1)。SVR の損失関数第 1 項 (誤差関数) には、原点付

近に平らな領域があり、原点から一定以上離れると直線的に誤差が増加します。一般的に、このような特徴を有する誤差関数は、残差平方和よりもノイズや外れ値に頑健であるといえます。また、この予測誤差をゼロとする範囲は ε チューブなどと呼ばれ、 ε はクロスバリデーションなどで決定します。

なお、SVR は、基本的に MLR や Ridge 回帰と同様の線形回帰モデルの仕組みを持っています。線形 SVR の回帰係数は制約付き最適化問題を解くことで算出可能です。SVR の数理的な導出などについては文献²⁾が参考になります。





図 1 損失関数第 1 項 (誤差関数)

カーネルトリック

目的変数と説明変数は必ずしも線形な相関を有するとは限らず、非線形性の強いデータを解析する場面も想定されます。線形回帰モデルは仕組みがシンプルであり、予測モデルを解釈しやすいといったメリットを持ちます。一方で、非線形回帰モデルの解釈性は必ずしも高くはないですが、高い予測性能を期待できます。

基本的に SVR は線形回帰モデルですが、非線形回帰モデルに拡張することが可能です。予測に非線形性を反映するため、まず何らかの関数 $\Phi(\cdot)$



- 予測精度向上を期待し、高次元空間で回帰分析
- カーネルトリックにより、計算量を削減

図 2 カーネルトリックについて

で説明変数を高次元空間に写像し、非線形に写像した説明変数を用いて予測モデルを構築します。ただし、写像先の高次元空間の次元が高すぎると、計算量が膨大になってしまいます。次に紹介するカーネルトリックという手法を用いると、写像先が無限次元であっても計算できることがあります(図 2)。

本来、非線形 SVR のモデル構築のためには、高次元ベクトルの内積計算をしなければならないのですが、カーネルトリックにより内積計算を、ある関数への元の説明変数の代入に置き換えることができます。つまり、カーネルトリックにより大幅な計算量削減が実現します。ただし、カーネルトリックを適用できる関数(カーネル関数)は次の条件を満たす関数に限られます。

1. 任意の x_i, x_j に関して $k(x_i, x_j) = k(x_j, x_i)$ である。
2. カーネル関数 $k(x_i, x_j)$ を成分とするグラム行列 K が半正定値行列³⁾である。

$$K = \begin{bmatrix} k(x_1, x_1) & \cdots & k(x_1, x_N) \\ \vdots & \ddots & \vdots \\ k(x_N, x_1) & \cdots & k(x_N, x_N) \end{bmatrix}$$

なお、機械学習モデルのユーザーの立場では、数学的背景をあまり気にすることなく、上記条件を満たすカーネル関数を利用することができます。よく用いられるカーネル関数として、RBF (Radial basis function) カーネルや多項式カーネルなどがあります[式(4), (5)]。なお、 i および j はサンプルインデックス、 γ および d は各カーネル関数のハイパーパラメータです。カーネル関数のハイパーパラメータはクロスバリデーションで調整できます。

$$k(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (4)$$

$$k(x_i, x_j) = (1 + x_i^T x_j)^d \quad (5)$$

SVR の適用例

図 3 に線形 SVR および非線形 SVR の適用例を示します。ここでは、sin カーブをもとに生成した人工データ(図中青点)を回帰分析します。図 3 に示すように、線形 SVR では上手く予測できていませんが、RBF カーネルを用いた非線形 SVR では良好に予測できています(図中赤線)。このようにカーネル関数を用いることで表現力の高い回帰モデルを構築できます。ただし、表現力の高い非線形回帰モデルは過剰適合しやすいため、予測モデルの適用範囲には注意しなければなりません。

図 4 に、コンクリートのスランプ試験に関するデータセット⁴⁾に各種回帰手法を適用した結果を示し




図 3 (a) 線形、(b) 非線形 SVR の適用例

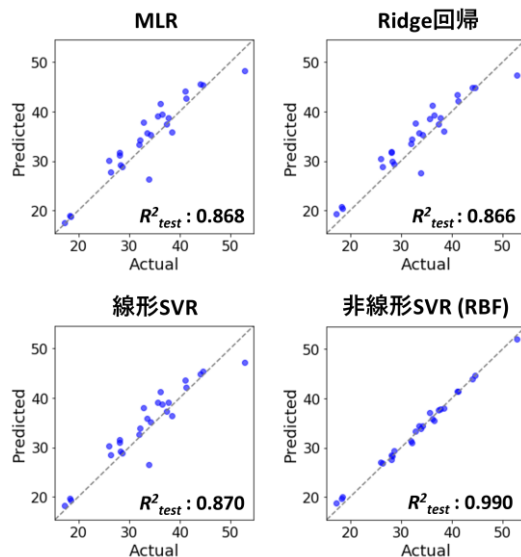


図 4 各種回帰手法の適用結果

ます。本データセットは 7 つの説明変数および 3 つの目的変数から構成されますが、今回はコンクリートの圧縮強度のみを目的変数として予測しました。検討した回帰モデルの中では、非線形 SVR の予測精度が良好でした。

おわりに

本稿で紹介した SVR は、非常に有用な回帰手法であり、便利な機械学習ライブラリも公開されています。また、SVR のハイパーパラメータを高速に最適化する方法も提案されています²⁾。

参考文献

- 1) 永廣卓哉: データ解析入門 17 <Lasso・Ridge・Elastic Net>, ORIST テクニカルシート, No. 23-06 (2023)
- 2) 金子弘昌, 化学のための Python によるデータ解析・機械学習入門, オーム社 (2019)
- 3) <https://ja.wikipedia.org/wiki/行列の定値性> (accessed on October 23rd, 2023)
- 4) http://archive.ics.uci.edu/ml/machine-learning-databases/concrete/s slump/s slump_test.data (accessed on March 20th, 2023)