

3.7 さまざまなカーネル法

3.8 カーネル法の性質

3.9 カーネル法の選択

## 3.7 さまざまなカーネル法

- カーネル **K-means** クラスタリング

- K-meansクラスタリングとは、N個のデータをK個のクラスター $C_1, \dots, C_K$ に分割する手法

$\mathbf{R}^m$ のデータ $\{X_i\}_{i=1}^N$ に対して、シード点 $\{z_a\}_{a=1}^K$ を用意し、データ $X_i$ に最も近いシード点が $z_a$ であるとき $X_i \in C_a$ とする。  
シード点は

$$\sum_{a=1}^K \sum_{X_i \in C_a} \|X_i - z_a\|^2$$

が最小になるように、繰り返し法によって求める。

- これを再生核ヒルベルト空間に変換したデータに拡張したもの

- **カーネルPLS**

- 回帰分析の1つ、PLS回帰をカーネル化したもの
- PLS回帰とは、 $m$ 次元説明変数 $X$ から $Y$ への線形回帰を行うさい、 $Y$ との相関が高くなるような $X$ の部分空間へデータを射影し、射影されたデータによって $Y$ への線形回帰を行う方法
- 説明変数 $X$ が共線性を持っている場合に有効
- 計量化学分野でよく用いられる

- サポートベクター回帰

- SVMを、連続値をとる応答変数の場合に拡張したもの


線形関数  $f(x, w, b) = w^T x + b$  をモデルとし、損失関数として  $\varepsilon$ -不反応損失 ( $\varepsilon$ -insensitive loss)

$$l_\varepsilon(y, f) = \max\{|y - f| - \varepsilon, 0\}$$

を用いて

$$\frac{1}{2} \|w\|^2 + C \sum_{i=1}^N l_\varepsilon(Y_i, f(X_i; w, b))$$

を最小化する  $f(x, w, b)$  を解として用いる



- カーネルロジスティック回帰

- 線形判別の手法の1つ、ロジスティック回帰をカーネル化したもの
- ロジスティック回帰は2値判別の場合、損失関数として

$$l(y, f) = \log(1 + \exp(-yf))$$

を用いる

- 確率を直接扱うことができ、また多クラスへの拡張も容易である
- データ数が多いと最適化の計算量が増大する

## 3.8 カーネル法の性質

- カーネル法はデータの非線形性や高次モーメントを扱うためのデータ変換の方法論
- 計算効率を重視した変換
- 正定値カーネルの定める特徴写像によって変換されたデータの内積は、正定値カーネルの値の評価によって計算可能(カーネルトリック)
- グラム行列を用いた計算によって、多くの線形手法が再生核ヒルベルト空間へ拡張可能

- 多くの場合、再生核ヒルベルト空間はデータの張る部分空間の元で解が与えられる(**Representer**定理)
- 計算量は基本的にデータ数に依存。データ数が非常に大きい場合は低ランク近似などの工夫が必要
- 正定値カーネルは任意の集合上に定義可能。いったん正定値カーネルが与えられれば、どのようなタイプのデータに対しても同じ方法論が適用可能。

## 3.9 カーネルの選択

カーネル法の性能は、選択した正定値カーネルに大きく依存する。そのため正定値カーネルの選択は重要なモデル選択の問題である

- **3.9.1 構造化データに対するカーネル**
  - 正定値カーネルは任意の集合上に定義できるため、さまざまな集合上のデータに応用可能
  - 特にシンボル列や代数構造などの、特定の構造をもったデータ(構造化データ)に対しては、その構造を反映した正定値カーネルを用いたほうが、より特徴を捉えた解析が期待できる

- **3.9.2 教師あり学習に対するクロスバリデーション**
  - SVMなどの識別や回帰の問題は、応答変数  $Y_i$  を  $X_i$  に対して正解を与える教師とみなし、教師あり学習と呼ぶことがある
  - これらの問題におけるカーネルの選択には、クロスバリデーションを用いることが多い
  - クロスバリデーションは、教師あり学習アルゴリズムが持つハイパーパラメータ（アルゴリズムの外的変数）を適切に決めるための方法
  - SVMでは、制約の破れに対する係数  $C$  やカーネルに含まれるパラメータ（ガウスRBFカーネルの  $\sigma$  など）がハイパーパラメータにあたる

- **Leave-one-out** クロスバリデーション (LOOCV) とは、ハイパーパラメータ  $\lambda$  のもとでの期待損失を

$$\frac{1}{N} \sum_{k=1}^N l(Y_k, \hat{f}_\lambda^{[-k]}(X_k))$$

によって推定する方法。すべての  $\lambda$  に対して上式を計算し、最小値となるハイパーパラメータを求める

- データ  $D = \{(X_1, Y_1), \dots, (X_n, Y_n)\}$
- $\hat{f}_\lambda$  :  $D$  に対して得られる関数
- $D^{[-k]}$  :  $D$  から  $k$  番目のデータを除いたデータ
- $\hat{f}_\lambda^{[-k]}$  :  $D^{[-k]}$  によってアルゴリズムが与える結果

- LOOCVでは各  $\lambda$  に対してデータ数  $N$  だけ  $\hat{f}_\lambda^{[-k]}$  を求める必要があり、計算上の困難が生じることがある
- そのため **K-fold** クロスバリデーションという手法もよく行われる

- これはデータをK分割し、

$$\frac{1}{K} \sum_{k=1}^K \frac{1}{|D_k|} \sum_{i \in D_k} l(Y_i, f_\lambda^{(-k)}(X_i))$$

によって期待損失を推定する

- $f_\lambda^{(-k)}$  : k 番目のグループ  $D_k$  以外のデータを用いた結果

- **3.9.3 教師なし学習に対するカーネル選択**
  - 主成分分析や正準相関分析などがこれ
  - カーネル選択に関する汎用的な方法で、理論的に性能が保証されたものはない
  - カーネル法の応用に依存して、カーネルを適切に選択することは可能
- **3.9.4 その他の方法**
  - ハイパーカーネル: 正定値カーネルを最適化する方法。正定値カーネルの族の上にさらに正定値カーネルを定義
  - Multiple Kernel Learning (MKL): いくつかの異なる正定値カーネルに対し線形結合や凸結合を行い、新しい正定値カーネルを定める。そしてその結合係数を最適化