

第二章

識別規則と学習法の概要

11T4066Y

松村 拓真

本章の内容

券売機を例として...

- 同じ100円硬貨でも特徴ベクトル(重さ、透磁率、サイズ)に違いがあるため、同じ100円に対応付けるため、多量の100円硬貨を用いてデータを収集する⇒**学習データ**
- 学習データには含まれない100円硬貨や、怪しげな100円硬貨が使われても正しく識別する能力⇒**汎化能力**

識別規則と学習法の概要の解説後、
学習データを用いた汎化能力について推定する方法を述べる

2.1 識別規則と学習法の分類

2.1.1 識別規則の構成法

識別規則...入力データ x からクラス $C_i \in \Omega = \{C_1, \dots, C_k\}$ への写像

写像の実現方法 \Rightarrow 関数値の正負、ダミー変数表現、事後確率の最大値、
決定木の終端ノードなど様々

2.1 識別規則と学習法の分類

代表的な識別規則の構成法

- 事後確率による方法: パターン空間に確率分布を仮定し、事後確率が最大のクラスに分類(ベイズの最大事後確率法)
- 距離による方法: 入力ベクトル x と各クラスの代表ベクトルとの距離を計算し、一番近い代表ベクトルのクラスに分類(最近傍法)
- 関数値による方法: 関数 $f(x)$ (識別関数という)の正負、又は最大値でクラスを決定(パーセプトロン型学習回路、サポートベクトルマシン)
- 決定木による方法: 識別規則の真偽に応じて次の識別規則を順次適応し、決定木の形でクラスを決定

2.1 識別規則と学習法の分類

2.1.2 教師付き学習

識別規則は入力データからクラスへの写像を関数 $y=f(x)$ を用いて表現する写像の性質を決めるパラメータを w で表すとする

ex) 第六章で述べる2クラス問題の線形識別関数の場合、識別規則は

$$y = f(x; w) = w_1x_1 + \dots + w_dx_d = w^T x \dots (2.1)$$

上式のように、パラメータ w と入力ベクトル x の線形計画(内積)を用いて表現される

2.1 識別規則と学習法の分類

識別規則の学習は、この $f()$ を学習データを用いて決めることであり、その目的は、パラメータ w を調節して入力データが正しいクラスに対応する関数値を出すようにすること

学習するためには、入力データとそのクラスを指定したデータ(教師データ)を対にした学習データが必要

2クラスの場合(識別クラスは関数値 y の正負で決めるとする)

$$(x_i, t_i) \in \{-1, +1\} \dots (2.2)$$

3クラス以上の場合にはダミー変数表現を用いて、例えば

$$t = (0, 1, 0, 0, 0, 0, 0, 0, 0)^T$$

のような教師データにする(K対1符号化という)

2.1 識別規則と学習法の分類

入力データと教師データの対を、 (x_i, t_i) ($i = 1, \dots, N$) の様に表す
学習に用いられる全ての対の集合を学習データセットといい、 D_L で表す

学習データセットの関数として w を得る方法や、学習データセット中の学習
学習データを一つずつ用いて、 w を少しずつ修正していく方法などがある
修正が完了した識別関数は、テストデータセットを用いて性能評価を行う

⇒ 以上のような学習法を教師付き学習と呼ぶ

2.1 識別規則と学習法の分類

2.1.3 教師付き学習と線形回帰

教師は、入力が所属するクラスを2値($\{-1, +1\}$ 等)で指定する

2値でなく、任意の関数値が与えられる場合、識別関数は入力 x に対して与えられた関数値を出力するように学習が行われ、そのために、識別関数 $f(x)$ は与えられた関数値を近似できるだけの能力を持つ必要がある

⇒このような問題を関数近似(回帰)という(線形関数の場合は線形回帰)

ex)ある月の平均降雨量と作物の収量の関係

→統計データを元に線形回帰で求めておくと、その年の平均降雨量から収量を予測可能(与えられる作物の収量は被説明変数、関数の引数として与えられる平均降雨量は説明変数と呼ばれる)

2.1 識別規則と学習法の分類

2.1.4 教師なし学習

入力データ間の距離や類似度、統計的な性質に基づいて、クラスを自動的に生成(クラスタリング)することが主目的になる

⇒教師なし学習、もしくは自己組織型学習という(詳細は10章で述べる)

最近では一部のデータのみ教師をつけ、他は教師なしで学習を行う形質導入学習という学習法も提案されている

2.2汎化能力

学習⇒学習データに対する識別関数の出力値と教師データとの誤差を最小にするように、識別関数のパラメータを調節すること

しかし...未知データに対してうまくはたらくか分からない

↓そこで

未知データに対する動作をテストデータに対する誤り確率という形で予測する

未知のデータに対する識別能力...汎化能力

汎化能力の誤差...汎化誤差

2.2汎化能力

2.2.1学習データとテストデータの作り方

手元のデータを分割し、学習データセット D_L とテストデータセット D_T を作成
ex)券売機的设计...10000枚の100円硬貨を

$D_L = 8000, D_T = 2000$ に分割する

- d次元空間内(dは特徴)の分布を p_L と p_T で表す
⇒平均値や分散などが計算可能
- D_L で設計し、 D_T でテストしたときの誤り率を $\varepsilon(p_L, p_T)$ で表すと
する

2.2汎化能力

- 国内すべての100円硬貨の集合を母集合、そのd次元特徴の分布を p で表し、**真の分布**と呼ぶ
- p_L と p_T の各特徴の平均値や分散が p と同じになるとは限らない。
→**偏り(バイアス)**という
- 真の分布を元に学習データを設計し、テストしたときの誤り率を**真の誤り率** $\varepsilon(p, p)$ とする
- 学習データとテストデータに同じデータを用いてテストをしたときの誤り率を**再代入誤り率** $\varepsilon(p_L, p_L)$ で表す

2.2汎化能力

- 学習用とテスト用に分割する代表的な方法

(1)ホールドアウト法

データを二つに分割し、一方を学習(p_L)、もう一方をテストに使用(p_T)

⇒ホールドアウト誤り率 $\varepsilon(p_L, p_T)$

- 有限のデータを分割するため、互いの割合によって、学習精度と性能評価の精度に偏りが発生する可能性...
 - 手元に大量にデータがないと、高い性能評価を得られない

2.2汎化能力

(2)交差確認法(交差検証法、交差妥当化法)

- ホールドアウト法を補う方法
- 手元の各クラスデータをそれぞれ m 個のグループに分割し、 $m - 1$ 個のグループのデータで学習、残りの一つのデータでテスト
↑これを m 回繰り返し、誤り率の平均を性能予測値とする
- i 番目のグループ以外で学習し、 i 番目のグループでテストしたときの誤り率 ε_{-i} は

$$\frac{1}{m} \sum_{i=1}^m \varepsilon_{-i}$$

となる

⇒ 全てのデータを学習とテストに用いるため、良い性能予測を行える

(分割によっては偏りが出るので、分割を変えて繰り返し、平均から 誤識別率を予測する必要がある)

2.2汎化能力

(3)一つ抜き法(ジャックナイフ法)

- 交差確認法を、データの数=グループの数にしたもの
- 一つを除いたすべてのデータで学習、除いた一つでテスト(データの数だけ繰り返す)
- 組み合わせは一つのため、1回で十分

2.2汎化能力

(4)ブートストラップ法

- 再代入誤り率のバイアスを補正するために利用
- N 個のデータを用いて再代入誤り率 $\varepsilon(N, N)$ を得る
 - 誤識別率は真の誤識別率より低く出るはず(差をバイアスとする)
 - ⇒バイアスを N 個のデータから N 回復元抽出を行って作ったブートストラップサンプル(N^*)を用いて修正

2.2汎化能力

- N^* を学習データ、テストデータに用いて得られた誤識別率を $\varepsilon(N^*, N^*)$ で表すとすると、バイアスは

$$\text{bias} = \varepsilon(N^*, N^*) - \varepsilon(N, N)$$

で推定

- 複数のブートストラップサンプル(最低で50程度)を生成し、得られる誤識別率の差の平均値で、バイアスを推定する

→このときの推定値は

$$\varepsilon = \varepsilon(N, N) - \text{bias}$$

⇒クラスが複数ある場合はブートストラップサンプルを作成し、バイアスを推定するのが良い

2.2汎化能力

2.2.2汎化能力の評価法とモデル選択

学習データによるパラメータ調整とテストデータによる誤り率の評価でも誤りが目標を下回らない→識別関数を変更する

誤り率が最少となるパラメータの選択方法...モデル選択

2.2汎化能力

1次,3次,6次,10次の多項式で近似した場合...

- 1次関数の近似はデータから大きく外れている(バイアスが大きい)が、近似した直線はほとんど同じ(分散が小さい)
- 3次の多項式は信号線分を正確に近似(バイアス、分散ともに小)
- 6次の多項式ではノイズを追うようになる
- 10次の多項式は完全にノイズに追従する

→関数が複雑になるほど学習データに対する近似能力は上がるが、ノイズ部分を近似するようになってしまう(バイアスは小さくなるが、分散は大きくなる)

バイアスと分散の反比例の関係...バイアス・分散トレードオフ

⇒汎化能力を決める大きな要因

2.2 汎化能力

多項式の次数を大きくするにつれ、学習誤差は単調に減少するが、テストデータに対する誤差は3次から少しずつ増加している(過学習という)

→汎化能力は3次の多項式が最も高い
(バイアスと分散が均衡している)

2.2汎化能力

- 識別関数の構成でもモデル選択と同様に考えられる
 - 式(2,1)より、 $y = f(x; w)$ の $f()$ の形や w の要素の数を変更しながら、交差確認法やブートストラップ法により汎化誤差を推定する(データの分布を統計モデルで記述しなくてもいい)
- データの分布に統計モデルを仮定する場合...
 - 解析的に汎化誤差を評価でき、その結果を利用してモデル選択が可能
 - 具体的な手法
 - ◆ 赤池の情報量基準(AIC)
 - ◆ ベイズ情報量基準(BIC)
 - ◆ 最小距離基準(MDL) etc.