

ファジイ領域の解析による特徴量の選択

3 K-2

Ruck Thawonmas

日立製作所

阿部重夫

日立研究所

1.はじめに

パターン認識の分野では最適な特徴量の決定は、最小規模で最も良の認識系を実現するうえから重要な課題である。特徴量を決定する方法としては元の入力を低次元の特徴量に変換する特徴抽出と元の入力から必要な特徴量を選択する特徴選択がある。本論文ではファジィルールを生成するときに行われるクラス間の重なりの度合いを定量化する指標により不要な特徴量を削除する方法を提案する。そのために以下ではまず数値データよりファジィルールを抽出する方法について述べ、ついで特徴量を選択する方式について述べる。

2. ファジィルールの抽出

まず、教師データから直接ファジィルールを抽出する方法を文献1)にしたがって述べる。

m 次元の教師データを用いて n 個のクラスに分離するファジィルールを生成するとする。 X_i をクラス*i*に属する教師データの集合とする。最初に X_i を用いて、レベル1の活性領域を次のように定義する。

$$A_{ii}(1) = \{x \mid v_{iik}(1) \leq x_k \leq V_{iik}(1), k = 1, \dots, m\} \quad (1)$$

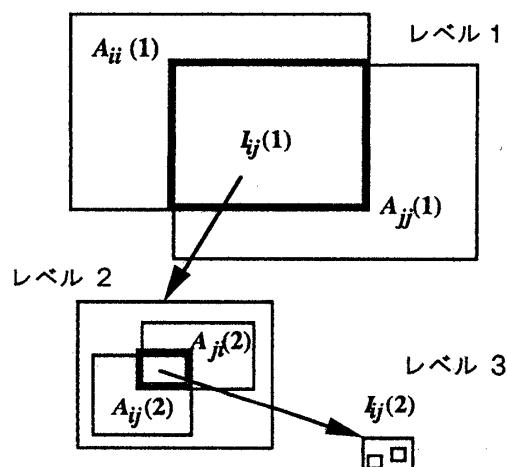


図1 ファジィルールの抽出

ただし x_k : 入力ベクトル x の k 番目の要素;

$$v_{iik}(1): x_k (x \in X_i) の最小値$$

$$V_{iik}(1): x_k (x \in X_i) の最大値 \quad (2)$$

このとき、クラス*i*と他のクラスの活性領域に重なりがないときは、次のレベル1のファジィルールをクラス*i*について定義する。

$$\text{If } x \text{ is } A_{ii}(1) \text{ then } x \text{ is class } i \quad (3)$$

もし、重なりがあるときはそれを、図1に示すように再帰的に解消する。図は、2変数のデータに対して、ファジィルールを定義する方法を示したものでありクラス*i*, *j*間のレベル1の禁止領域を次式で定義する。

$$I_{ij}(1) = \{x \mid w_{ijk}(1) \leq x_k \leq W_{ijk}(1), k = 1, \dots, m\} \quad (4)$$

$$\text{ただし } v_{iik}(1) \leq w_{ijk}(1) \leq W_{ijk}(1) \leq V_{iik}(1)$$

これより禁止領域を持ったレベル1のファジィルールは次のようになる。

$$\text{If } x \text{ is } A_{ii}(1) \text{ and } x \text{ is not } I_{ij}(1) \text{ then } x \text{ is class } i \quad (5)$$

もし、 $I_{ij}(1)$ の中に X_i に属するデータがあれば、レベル2の活性領域を次のように定義する。

$$A_{ij}(2) = \{x \mid v_{ijk}(2) \leq x_k \leq V_{ijk}(2), k = 1, \dots, m\} \quad (6)$$

ただし $x \in X_i$ で x は $I_{ij}(1)$ の中にあり次式が成立つ。

$$w_{ijk}(1) \leq v_{ijk}(2) \leq x_j \leq V_{ijk}(2) \leq W_{ijk}(1)$$

もしレベル2の活性領域に重なりがなければ、クラス*i*に対する次のレベル2のファジィルールが求まる。

$$\text{If } x \text{ is } A_{ij}(2) \text{ then } x \text{ is class } i \quad (7)$$

もし、 $A_{ij}(2)$ and $A_{ji}(2)$ の間に重なりがあると、次のようにレベル2の禁止領域を定義する。

$$I_{ij}(2) = \{x \mid w_{ijk}(2) \leq x_k \leq W_{ijk}(2), k = 1, \dots, m\} \quad (8)$$

$$\text{ただし } v_{ijk}(2) \leq w_{ijk}(2) \leq W_{ijk}(2) \leq V_{ijk}(2)$$

従って、禁止領域を持ったレベル2の次のファジィルールが得られたことになる。

$$\text{If } x \text{ is } A_{ij}(2) \text{ and } x \text{ is not } I_{ij}(2) \text{ then } x \text{ is class } i \quad (9)$$

同様にして、もし重なりが残っていればレベル3以上のファジィルールを定義できる。ここで、一

般にレベル l のファジィルールを次のように定義する。

$$\text{If } x \text{ is } A_{ij}(l) \text{ then } x \text{ is class } i \quad (10)$$

あるいは、禁止領域を持ったレベル l のファジィルールは

$$\text{If } x \text{ is } A_{ij}(l) \text{ and } x \text{ is not } I_{ij}(l) \text{ then } x \text{ is class } i \quad (11)$$

ただし $l=1$ のとき $i=j$ で $l \geq 2$ のとき $i \neq j$ である。

3. ファジィ領域に基づく特徴量の選択

3.1 分離の複雑度

ここで m 次元入力のときにクラス i, j の重なりがないとき、すなわち禁止領域 $I_{ij}(1)$ が定義されなかつたときは、クラス i, j の分離は $A_{ii}(1), A_{jj}(1)$ により、あるいはこれらの活性領域の間の任意に位置に超平面を設定することにより容易に実現できる。そこで、このときのクラス i のクラス j に対する複雑度を 0 と考える。このとき、ある入力を削除してもクラス i, j の間に禁止領域 $I_{ij}(1)$ が定義されなかつたときは、2つのクラスの分離のしやすさは m 次元入力のときと変わらず、この2つのクラスに関してはこの入力は削除可能な入力と考えるわけである。

つぎに、レベル l の活性領域 $A_{ij}(l)$ に対して禁止領域 $I_{ij}(l)$ が定義された場合は、活性領域 $A_{ij}(l)$ と禁止領域 $I_{ij}(l)$ の体積比をクラス i のクラス j に対するレベル l の複雑度と考える。レベルが深くなるにつれ、定義される領域の体積が減るから、レベル l の複雑度はレベル $l+1$ の複雑度より大きな重み（あるいは出現確率）をつける必要がある。複雑度は禁止領域の大きさに依存するからこの重みは禁止領域に比例したものとする必要がある。その一つの方法として、レベル l におけるクラス i のクラス j に対する重み $p_{ij}(l)$ を

$$p_{ij}(l) = (\text{禁止領域 } I_{ij}(l) \text{ におけるクラス } i \text{ のデータの数}) / (\text{全体のデータの数}) \quad (12)$$

とする。ここで全体のデータの数で割るのは、各々のクラスのデータの数が実際の出現確率に対応するを考えていることによる。もし、各々のクラスのデータ数が等しいときは(12)式はクラスのデータ数で割ったのと同じになる。(12)式の代わりに禁止領域の体積を重みとしてもよい。

以上より、入力の集合 F に対するクラス i のクラス j に対する複雑度 $o_{ij}(F)$ はつぎのように定義される。

$$o_{ij}(F) = \sum_l p_{ij}(l) \frac{B_{ij}(F, l)}{B_{Aij}(F, l)} \quad (13)$$

ただし

$$B_{Xij}(F, l) = \prod_{f \in F} b_{Xij}(f, l)$$

$$b_{Iij}(f, l) = \begin{cases} W_{ij}(l) - w_{ij}(l), & W_{ij}(l) - w_{ij}(l) > \varepsilon \\ \varepsilon, & W_{ij}(l) - w_{ij}(l) \leq \varepsilon \end{cases}$$

$$b_{Aij}(f, l) = \begin{cases} V_{ij}(l) - v_{ij}(l), & V_{ij}(l) - v_{ij}(l) > \varepsilon \\ \varepsilon, & V_{ij}(l) - v_{ij}(l) \leq \varepsilon \end{cases} \quad (14)$$

で ε は小さな正の数である。

これより入力の集合 F に対する複雑度 $O(F)$ は

$$O(F) = \sum_{\substack{i, j = 1, \dots, n \\ i \neq j}} o_{ij}(F) \quad (15)$$

で与えられる。

3.2 特徴選択

m 次元の入力の番号 $1, \dots, m$ を要素として含む集合を I として、 m 個全ての入力を用いたときの複雑度を求めこれを $O(I)$ とする。次に集合 I を集合 F に設定して、添字 i を I に初期化する。集合 F から i 番目の変数を削除した集合を $F(i)$ として、入力のうち集合 $F(i)$ に対する複雑度を計算し、 $O(F(1)), \dots, O(F(|I|))$ の最小値を求めそれを $O(F(k))$ とする。ただし $|I|$ は集合の要素数を示す。最小値をとるのは複雑度が最も増加しない入力を削除するためである。つぎに

$$|O(I) - O(F(k))| / O(I) \geq \alpha \quad (16)$$

を計算する。ここで、 α は入力の削除処理を打ち切るための正の数である。(16)式の左辺は全ての入力変数を使った場合からどの程度複雑度が相対的に増加したかを示す尺度になる。(16)式を満たすときは処理を終了し、満たさないときはさらに入力変数をへらす処理を行う。

4. 特徴量削減の効果

あやめのデータ、車番認識データ、サイロイドデータ、血球データで汎化能力を低下することなく特徴量が削減できた。詳細は講演時に示す。

5. 結言

クラス間のファジィ領域の重なりの複雑度を定量化して、複雑度が低下しない範囲で特徴量を選択する方式を述べた。

参考文献

- 1) S. Abe and M.-S. Lan, "A Method for Fuzzy Rules Extraction Directly from Numerical Data and Its Application to Pattern Classification," IEEE Trans. Fuzzy Systems, Vol. 3, No. 1, pp. 18-28, 1995.