

インクドロップスプレッド法における対象システムの逐次分割手法

A Gradual Partitioning Method for the Ink Drop Spread Method

尾崎 新斗[†] 内海 彰[†]

Yosito Ozaki Akira Utsumi

1 はじめに

Ink Drop Spread(IDS) 法はソフトコンピューティングの概念に基づく機械学習手法の1つであり, Shouraki, Honda[1] によって提案され, Murakami, Honda[2] によって有効性が示されている.

IDS 法は対象システムの入力空間を分割し, 分割された複数の空間毎にパターン情報を作成し, 作成されたパターン情報を組み合わせることによって, 対象システムの入出力関係の学習を行う. このため対象システムの入力空間の分割方法が変われば, 作成されるパターン情報も変わり, 学習結果にも影響が出る. より精度良く学習を行うために, 対象システムの分割手法として各入力を等分割し, 各入力の分割数の組み合わせを探索する手法 [3] や, GA をもちいて各入力の分割位置を探索する手法 [4] が提案されている. しかしこれらの手法は各入力毎に分割を行うため, 分割同士が影響し無駄な空間が作成され, 多くの計算資源を必要とする.

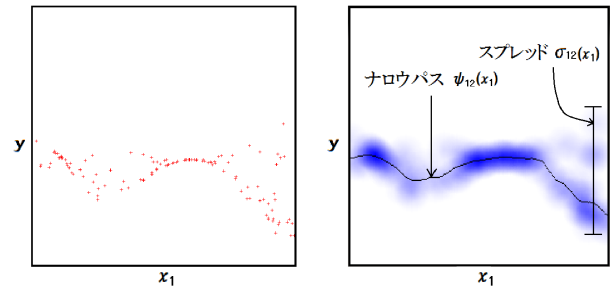
そこで我々は対象システムの分割を逐次行うことで, 他の分割を考慮して新しい分割を行う手法を提案する. この手法をもちいることで対象システムの分割数を減らし, 精度良く学習を行うことができることを示す.

2 IDS 法

IDS 法は多入力1出力の対象システムを複数の1入力1出力システムに分割し, 分割したシステム毎にパターン情報を作成し, そのパターン情報を統合することで対象システムの入出力関係を学習する. IDS 法は入力, モデリング, 推論層の3層構造となっている. ここでは2入力1出力 (x_1, x_2, y) の対象システムにおいて, 分割手法が各入力を2分割した場合を例として, 各層の説明を行う.

入力層では分割手法が決定した各入力の分割位置 (b_1, b_2) をもちいてデータを分類し, 複数の $x-y$ 平面にデータを射影する (図1(a)). x_2 が b_2 以上の場合の x_1-y 平面, x_2 が b_2 未満の場合の x_1-y 平面が作成され, x_2-y 平面についても同様のため, 4種の平面が作成される.

モデリング層では各平面に射影されたデータを受け取り, 各データをデータの中心を濃く, 離れるほど薄くなるように, 拡散させてインクをプロットする. こうする



(a) 射影されたデータ

(b) パターン情報

図1: $x_2 < b_2$ の場合の $x_1 - y$ 平面

ことで各平面毎にパターン情報を作成する (図1(b)). このパターン情報から, y 方向におけるインクの重心を繋いだナロウパス $\psi(x_i)$, y 方向におけるインクの広がり (最大位置と最小位置との差) であるスプレッド $\sigma(x_i)$ を抽出する.

推論層では各パターン情報から抽出されたナロウパスとスプレッドを, ファジィ推論をもちいて統合する. ファジィルールは以下ようになる.

$$R_{11} : \text{If } x_2 \text{ is } A_{21}, \text{ then } y \text{ is } \psi_{11}(x_1)$$

$$R_{12} : \text{If } x_2 \text{ is } A_{22}, \text{ then } y \text{ is } \psi_{12}(x_1)$$

$$R_{21} : \text{If } x_1 \text{ is } A_{11}, \text{ then } y \text{ is } \psi_{21}(x_2)$$

$$R_{22} : \text{If } x_1 \text{ is } A_{12}, \text{ then } y \text{ is } \psi_{22}(x_2)$$

ここで A はファジィ集合であり, これらのルールを以下のように統合する.

$$y \text{ is } \beta_{11}\psi_{11}(x_1) \text{ or } \beta_{12}\psi_{12}(x_1) \text{ or } \beta_{21}\psi_{21}(x_2) \text{ or } \beta_{22}\psi_{22}(x_2)$$

ここで β は適合度とスプレッドからもとめられる重みである.

3 逐次分割手法

既存の分割手法 [3], [4] では各入力毎に分割を決定するため, 3入力以上の対象システムの学習を行う場合, 無駄な空間が作成される. 例えば3入力の対象システム (x_1, x_2, x_3, y) において, x_1-y 平面のパターン情報を構成する $(x_2 < b_2, x_3 < b_3)$ 空間を作成する場合, $(x_2 \geq b_2, x_3 < b_3)$, $(x_2 < b_2, x_3 \geq b_3)$, $(x_2 \geq b_2, x_3 \geq b_3)$ の3種の空間も同時に作成されてしまう. そこで段階的に空間を分割, 統合することで $(x_2 < b_2, x_3 < b_3)$ のみを分割する手法を提案する. 以下に分割アルゴリズムを記載する.

[†]電気通信大学 大学院情報理工学研究所

1. パターン情報を入力空間を分割せずに作成する.
2. パターン情報上のスプレッドの最大値が, データ1つの拡散範囲の2倍以上ならば, そのパターン情報を構成する入力空間の内, 最も広い入力を2等分する.
3. 分割により作成された空間毎にパターン情報を作成する.
4. 2の条件を満たすパターン情報がなくなるか, 予め設定した各入力の最大分割回数(本論文では7回)となるまで, 2と3を繰り返す.

続いて統合アルゴリズムを記載する.

1. x 方向に対して, その入力範囲の1割以上インクが存在しないパターン情報の中で, 最もインクが存在しないパターン情報のナロウパスと, そのパターン情報を構成する入力空間と隣接する入力空間で作成されたパターン情報のナロウパスとの平均2乗誤差を計算する.
2. 誤差が出力範囲の1割以下である隣接入力空間の中で, 最も誤差の小さい入力空間を統合し, パターン情報を再度作成する.
3. 1, 2の条件を満たすパターン情報がなくなるまで, 1, 2を繰り返す.

4 比較実験

既存の分割手法である等分割 [3], GA 利用 [4] との比較を行う. また IDS 法以外の他手法として feed-forward neural network(FNN) との比較も行う. 比較には関数 (1) に示す 3 入力関数の近似問題をもちいる.

$$h(x_1, x_2, x_3) = \prod_{i=1}^3 e^{x_i} \sin(13(x_i - 0.6)^2) \quad (1)$$

関数 (1) からランダムに学習データを作成する. 学習データ数を 500, 1000, 1500 の 3 種とし, それぞれのデータ数毎に 100 セット用意し, 学習を 100 回行う. テストデータには各入力を等間隔に取った 1,000,000 データをもちいる. 近似精度には式 (2) に示す fraction of variance unexplained(FVU) をもちいる.

$$FVU = \frac{\sum_{l=1}^L (\hat{y}(x_l) - y_l)^2}{\sum_{l=1}^L (y_l - \bar{y})^2} \quad (2)$$

$$\bar{y} = (1/L) \sum_{l=1}^L y_l$$

表 1 は近似精度の平均, 表 2 は分割手法毎に作成されるパターン情報の総数の平均である. 各条件における最も良い精度, 及び最も少ないパターン情報数を太字で示す. これらの表より提案手法である逐次分割手法が, 他の分割手法よりも分割数を減らし, 精度良く学習できていることが分かる.

表 1: 近似精度

学習 データ数	手法			
	等分	GA 利用	逐次	FNN
500	0.296	0.394	0.259	0.802
1000	0.150	0.227	0.138	0.749
1500	0.102	0.155	0.102	0.707

表 2: IDS 法の総パターン情報数

学習 データ数	手法		
	等分	GA 利用	逐次
500	110.40	68.29	47.82
1000	152.45	102.10	73.53
1500	197.60	129.26	91.21

5 おわりに

段階的に対象システムの入力空間を分割, 統合することで分割数を減らし, 精度良く学習できることを示した. 今後の課題として, 逐次分割手法では分割を行う際に等分割となる分割位置しか探索していないため, より対象システムに適した分割位置を探索する手法を開発する必要がある.

参考文献

- [1] S.B.Shouraki and N.Honda: Recursive fuzzy modeling based on fuzzy interpolation, Journal of Advanced Computational Intelligence, Vol.3, No.2, pp.114-125, 1999.
- [2] M.Murakami and N.Honda: Performance of the IDS method as a soft computing tool, IEEE Transactions on Fuzzy Systems, Vol.16, No.6, pp.1582-1596, 2008.
- [3] M.Murakami and N.Honda: A fast structural optimization technique for IDS modeling, 2007 Annual Meeting of the North American Fuzzy Information Processing Society (NAFIPS 2007), pp.204-209, 2007.
- [4] H.Sagha, S.B.Shouraki, H.Beigy, H.Khasteh, and E.Enayati: Genetic Ink Drop Spread, Proceedings of Second International Symposium, on Intelligent Information Technology Application, IEEE computer society, pp.603-607, 2008.