

ファジィ回帰転移学習のドメイン間マッピングの最適化の検討

清水 歩武† 謝 孟春† 村田 充利† 森 徹†

1. はじめに

人工知能には様々な形態があるが、現在広く活用されているものは機械学習である。その中でもある問題を効果的かつ、効率的に解くために、別の関連した問題のデータや学習結果を再利用する転移学習が注目されている[1]。転移学習は分類問題の分野に広く応用されているが、回帰問題への応用例は少ない。

先行研究ではファジィ回帰転移学習において、差分進化法や粒子群最適化法による回帰転移学習のドメイン間マッピングの最適化に一定の精度が得られた[2]。しかし、転移学習は同じ特徴量と次元のドメイン間のみで行われた。本研究では異なる特徴量や次元をもったドメイン間での転移学習を試みる。また、遺伝的アルゴリズムを用いて、ファジィ回帰転移学習のドメイン間のマッピングの最適化を行い、高精度、高効率な転移学習を目指す。

2. ファジィ回帰転移学習

ファジィ回帰転移学習とは高木-菅野ファジィ回帰モデルに転移学習を組み合わせたものである[2]。高木-菅野ファジィ回帰モデルに基づきソースドメインで作成されたモデルをM、ターゲットドメインのk番目の入力データを x'_k とすると、ファジィ回帰転移学習は図1のような流れで出力 y_k を予測する。




図1 ファジィ回帰転移学習

ここで Φ はマッピング関数であり、ターゲットドメインの入力データの特徴量をソースドメインの特徴量に対応させるといった役割である。また、マッピング関数 Φ はP個の隠れ層を持つニューラルネットで構成される。隠れ層は二つのパラメータを持つシグモイド関数であり、シグモイド関数 z_{kip} とマッピングの出力は式(1)、(2)で表される。

$$z_{kip} = \frac{1}{1 + e^{-\alpha_{ip}(x'_{ki} - \beta_{ip})}} \quad p = 1, 2, \dots, P \quad (1)$$

$$\Phi(x'_{ki}) = \sum_{i=1}^c w_{ki} z_{kip} \quad (2)$$

マッピング関数のパラメータ α 、 β 、 w は図2で示すようなD個の特徴量とP個のノード数からなる行列で表現できる。

$$\begin{bmatrix} \alpha_{11} & \alpha_{12} & \dots & \alpha_{1P} \\ \alpha_{21} & \alpha_{22} & \dots & \alpha_{2P} \\ \vdots & \vdots & \ddots & \vdots \\ \alpha_{D1} & \alpha_{D2} & \dots & \alpha_{DP} \end{bmatrix}$$

図2 マッピング関数パラメータ α の行列

3. GAによるマッピングの最適化

ファジィ回帰転移学習において、マッピング関数の最適化によってターゲットドメインの特徴量をソースドメインの特徴量にうまく対応させることで、より高精度な予測できると考えられる。

本研究ではマッピング関数のパラメータである α 、 β 、 w に対して、遺伝的アルゴリズム(Genetic algorithm, GA)を用いて最適化を行う。

GAにおける個体は図2で示す行列とする。個体の評価は式(3)で示している適応度を用いる。これはトレーニングデータによる予測値と真値の平均二乗誤差である。ここでのトレーニングデータはファジィ回帰転移学習のモデルの学習に用いるデータで、予測値はGAで最適化されたマッピング関数を通して得られた予測値である。

$$f = \frac{1}{N} \sum_{k=1}^N (y_k - y'_k)^2 \quad (3)$$

GAにおける遺伝的操作は交叉、突然変異、選択である。本研究では二点交叉(図3)、一定の確率で個体の一部をランダムで書き換える突然変異、ルーレット選択、エリート保存戦略を採用した。




図3 二点交叉

†和歌山工業高等専門学校
National Institute of Technology(Kosen), Wakayama College

4. 実験と結果

本研究では分布の異なるソースドメインとソースドメインを持つ合成データと実データに対して、GA を用いてファジィ回帰転移学習のドメイン間マッピングの最適化を行った。実験で用いたファジィ回帰モデルと GA のハイパーパラメータを表 1 に示す。

表 1 ハイパーパラメータ

ファジィ回帰		GA	
クラスタC	3	解集団	100
ファジィ度m	1.8	世代	100
マッピング	エリート選択割合		0.05
ノード数P	3	突然変異率	0.01

4.1. 合成データ

合成データは3つの属性を持つ2つのドメインによって構成される(図 4)。各属性は表 2 に示される重心と共分散行列により生成された。各属性のデータ数を 100 とした。

表 2 合成データ分布

(a) 属性の重心

source data	target data
$\mu_1 = [5,3,3]$	$\mu'_1 = [6,6,5,2]$
$\mu_2 = [1,2,4]$	$\mu'_2 = [4,2,2]$
$\mu_3 = [3,5,1]$	$\mu'_3 = [2,6,4]$

(b) 共分散行列

$$\begin{bmatrix} 0.5^2 & 0 & 0 \\ 0 & 0.5^2 & 0 \\ 0 & 0 & 0.5^2 \end{bmatrix}$$

300 個のソースドメインのデータを用いてファジィ回帰モデルを作成し、ターゲットドメインからランダムに選ばれた 15 個のデータをトレーニングデータとし、マッピングの最適化を行った。ファジィ回帰転移学習による予測結果を図 5 に示す。

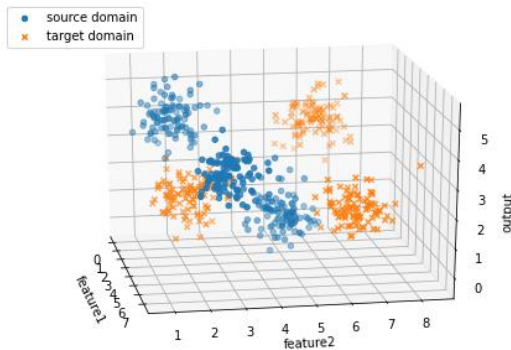


図 4 ソースドメインとターゲットドメイン

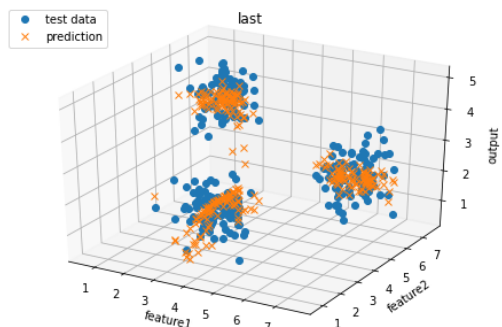


図 5 合成データの予測結果

図 5 からファジィ回帰転移学習の予測結果の分布はターゲットドメインの分布とほぼ一致した。分布が異なるソースドメインのデータで構築した学習モデルと最適化されたマッピング関数により、ターゲットドメインの予測ができ、テストデータと予測値の平均二乗誤差は 0.61 であった。

4.2. 実データ

実データセットとして、Auto MPG データセットを使用した[3]。このデータセットは複数の特徴量と自動車の消費燃料というラベルからなる。本研究では、特徴量は気筒数、排気量、馬力、車体の重さとし、データを可視化するために主成分分析によって特徴量を 2 つに統合した。

ソースドメインは、1982 年以前に製造された自動車データ 362 個で(図 6)、ターゲットドメインは 1982 年に製造された自動車データ 30 個とした(図 7)。なお、テストデータとトレーニングデータはターゲットドメインを使用した。ソースドメインのデータとターゲットデータをを用いて、自動車燃費予測を行い、その結果を図 8 に示す。




図 6 ソースドメイン 図 7 トレーニングとテストデータ




図 8 実データの予測結果

1982 以前に作られた自動車データセットによって学習されたモデルと、1982 年に作られた自動車データセットによって 1982 年の自動車の燃費が予測できた。その予測結果とテストデータの分布がほぼ一致となった。

5. まとめ

本研究では GA を用いてファジィ回帰転移学習におけるドメイン間マッピングの最適化を行った。合成データと実データに対してソースドメインにおけるファジィ回帰モデルと最適化されたマッピング関数により一定精度の予測ができた。今後の課題は、次元数や特徴量の異なるドメイン間でのマッピングの手法の提案などが挙げられる。

参考文献

- [1] 神嵐 敏弘 転移学習 人工知能学会誌 2010, 25 巻 4 号
- [2] Zuo, H., Zhang, G., Pedrycz, W., et al., Fuzzy Regression Transfer Learning in Takagi-Sugeno Fuzzy Models, IEEE Transactions on Fuzzy System vol. 25 no. 6
- [3] <https://archive.ics.uci.edu/ml/datasets/auto+mpg>