ショートノート

未知クラスの継続的な学習を可能とする ファジィ遺伝的機械学習手法†

入江 勇斗*¹・増山 直輝*¹・能島 裕介*¹・石渕 久生*²

近年の情報技術の急速な発展はデータの継続的な収集を可能とした。蓄積されるデータは重要な経済資源とみなされており、種類・量ともに日々増加する膨大なデータから人が容易に理解できる形式で知識を獲得する手法が研究されている。ファジィ遺伝的機械学習 (GBML) は、言語的に解釈可能なファジィ識別器を設計する手法の一つである。しかし、ファジィ GBML の学習アルゴリズムは一括学習であり、未知のクラスに属するデータが継続的に与えられる状況での知識の獲得 (クラス増分学習) を行うことが困難である。そこで本研究では、従来のファジィ GBML をクラス増分学習可能なアルゴリズムに拡張する。具体的には、クラス増加時に、i) 未知クラスを識別するルールの再構成、ii) 学習済みのクラスに属するデータの削減の2つの操作を従来のファジィ GBML に加える。数値実験結果より、提案手法が未知クラスを効率的に学習可能であることを示す。

キーワード：ファジィ識別器、遺伝的機械学習、クラス増分学習

1. はじめに

近年の情報技術の発展は目覚ましく、日夜多様なデータを大量に生成することを可能としている。生成されるデータは種類・量ともに規模が増大しており、これらのデータを経済資源とみなして活用を図る企業は多い。したがって、種類・量ともに日々増加するデータから、継続的かつ効率的に知識を獲得する手法の需要は高い。また一方で、データの利活用の際に AI による意思決定の透明性が求められるなど、予測や識別の精度以外の観点も重要視されている [1]。

以上の背景から、i) 増加するデータの効率的な学習が可能であり、ii) 高い解釈性能を有する識別器を設計する機械学習手法の需要は高いと考えられる。本研究では、i) の観点からクラス増分学習について、そして ii) の観点からファジィ遺伝的機械学習 (Genetics-based Machine Learning: GBML) についてとりあげる。また、クラス増分学習の要件として、Rebuffi らの3つの定義に従う [2]: 1) 異なるクラスのデータが、異なる時点で与えられる場合に学習可能であり、2) 既存の全クラスのデータを識別可能なマルチクラス識別器を維持可能であり、3) クラス増加に伴う計算コストの増加が少ない学習である。ここで要件 1) について、本研究では継続的な学習という観点から、未知のクラスが与えられた際に事前の学習内容を破棄し、再度はじめてから学習を行うことは要件 1) を満たさないものとして考える。クラス増分学習の例としてセキュリティ対策が挙げられ

る。今日では未知の脅威が日々新たに出現しており、適切なセキュリティ構築のために、新たな脅威について日夜継続的に学習する必要がある。

ファジィ GBML は高い解釈性能を持つファジィ識別器を獲得する手法の1つである [3]。しかしながら、GBML における学習アルゴリズムは一括学習を想定している。そのため、従来のファジィ GBML では未知クラスが与えられた際に識別器を破棄し、再度はじめてから学習を行う必要がある。これは、先述のクラス増分学習の要件 1) および 3) を満たさない。そこで、本研究では、従来のファジィ GBML を拡張することで、クラス増分学習可能なファジィ遺伝的機械学習 (Class Incremental Fuzzy Genetics-based Machine Learning: CI-FGBML) を提案する。具体的には、未知クラスのデータが与えられた際に、重要度の低いルールを未知クラスを識別するルールへと再構成することで、識別器の破棄を回避する。これにより CI-FGBML は要件 1) を満たす。また、CI-FGBML ではクラス増加時に既存のクラスに属するデータに対し、クラスタリング手法に基づいたデータ削減を行う。データ削減によりクラス増加に伴う計算コストの増加を緩和し要件 3) を満たす。

本論文の構成は次の通りである。まず2章で一般的なファジィ GBML のアルゴリズムについて概説する。次に3章で提案手法である CI-FGBML の詳細について述べ、4章にて数値実験とその結果の考察を述べる。最後に5章で本論文の結論を述べる。

2. ファジィ遺伝的機械学習

一般にファジィ GBML は、個体が1つのルールを表現する Michigan 型と個体が1つの識別器を表現する Pittsburgh 型に分類される [3]。本研究では、計算コスト削減のために Michigan 型を用いる。以下に、Michigan 型ファジィ GBML の詳細を記述し、また、Algorithm 1 にその概略を示す。

† Fuzzy Genetics-Based Machine Learning to Handle Continually Increasing Unknown Classes

Yuto IRIE, Naoki MASUYAMA, Yusuke NOJIMA,
and Hisao ISHIBUCHI

*¹ 大阪府立大学
Osaka Prefecture University

*² 南方科技大学
Southern University of Science and Technology

Algorithm 1: Michigan-style Fuzzy GBML**Input:** Training data D , termination condition T **Output:** A fuzzy classifier

1. Initialize population P_0 from D by heuristic rule generation (detail in Algorithm 2).
2. Evaluate P_0 .
3. **for** $t = 1$ to T
4. Generate offspring fuzzy rules R from P_{t-1} by genetic operation and heuristic rule generation (detail in Algorithms 2, 3).
5. Evaluate offspring rules.
6. Make P_t from P_{t-1} and offspring rules.
7. **if** accuracy of P_{t-1} is higher than that of P_t **then**
8. $P_t \leftarrow P_{t-1}$
9. **end for**
10. Output a fuzzy classifier.

Algorithm 2: Heuristic rule generation (single pattern)**Input:** Data D **Output:** A fuzzy rule

1. Select single pattern $\mathbf{x} = (x_1, x_2, \dots, x_n)$ randomly from D .
2. **for** $i = 1$ to n
3. Calculate membership values of n_{fs} types fuzzy sets for x_{pi} .
4. Select a fuzzy set by roulette selection.
5. Replace the fuzzy set to “don’t care” with a pre-specified probability.
6. **end for**
7. Output a fuzzy rule.

2.1 初期個体群の生成

初期個体群 P_0 の生成にはヒューリスティックルール生成法を用いる。Algorithm 2 にその手順を示す。

Algorithm 2 の Line 4 について、ルールの条件部はルーレット選択に基づいて決定される。ここで、生成されるルールの i 番目の属性において、ファジィ集合 A_j ($j = 1, 2, \dots, n_{fs}$) が選択される確率は式 (1) に従う。 n_{fs} はファジィ集合の総数を表す。

$$P(A_j) = \frac{\mu_{A_j}(x_{pi})}{\sum_{k=1}^{n_{fs}} \mu_{A_k}(x_{pi})}, \quad (j = 1, 2, \dots, n_{fs}) \quad (1)$$

また、Algorithm 2 の Line 5 では、事前に定めた確率に従い条件部を “don’t care” に変更する。これは、生成したルールの覆う空間を広げることで、汎化性能を向上させるためである。

2.2 ルールの評価

ルール R_q の評価値は、クラスラベルを正しく推定したパターン数 $NCP(R_q)$ で与える。

$$fitness(R_q) = NCP(R_q). \quad (2)$$

また、本研究では、クラスラベルの推定に単一勝利ルールによる推論法 [3] を用いる。単一勝利ルールによる推論法では、あるパターンに対し、ただ 1 つのルールを選択し推論に用いる。ただし、推論に用いるルールを一意に決定できない場合

Algorithm 3: Michigan-style genetic operation**Input:** Current population P **Output:** A fuzzy rule

1. Select two fuzzy rules from P by binary tournament selection.
2. Generate a fuzzy rule through uniform crossover.
3. Replace each antecedent condition of the fuzzy rule to “don’t care” with a pre-specified probability.
4. Output a fuzzy rule.

は、そのパターンを識別不能とし誤識別したパターンとして扱う。

2.3 個体群の更新

本研究では、個体群の更新に (1+1) 進化戦略を用いる [3]。 (1+1) 進化戦略では、ある 1 つの個体群から新たな個体群を 1 つ生成し、識別精度の高い方を次世代に残す。以下にその手順を示す。

まず Algorithm 1 の Line 4 において、新規ルールの生成を行う。ここで、新たに生成するルールの 50% はヒューリスティックルール生成法を用いて、残りの 50% は遺伝的操作を用いて生成する (Algorithms 2, 3)。このとき、ヒューリスティックルール生成法における入力、現在の個体群 P_{t-1} が誤識別あるいは識別不能としたパターンの集合とする。

次に、 P_{t-1} 内の評価値の低いルールから順に新規ルールと置換し、個体群 P_t を生成する。そして、 P_{t-1} と P_t の識別精度を比較し、識別精度の高い方を次世代の個体群とする。

2.4 識別器の獲得

(1+1) 進化戦略では、常に現在の個体群が学習用データに対する最良の識別器となる。そのため、終了条件を満たした場合には、最終世代における現個体群を最終的な識別器として出力する。また、本研究では、学習の終了条件を世代数で決定する。

3. CI-FGBML のアルゴリズム

CI-FGBML は従来の Michigan 型ファジィ GBML をクラス増分学習に対応させたアルゴリズムであり、1 章で示したクラス増分学習の 3 つの要件を満たす。CI-FGBML は、クラス増加時の操作として以下の 2 つの操作を行う: i) 識別に不要なルールを破棄した後、未知クラスを識別するルールを生成し、ii) 既存クラスに属するパターンを削減する。Algorithms 4, 5 に 2 つの操作の概略を示し、以下にその詳細を記述する。

3.1 未知クラスを識別するルールの生成

Algorithm 4 では、識別に不要なルールの判定にルール重みを利用する [4]。これは単一勝利による推論法では、ルール重みの低いルールが選択される可能性が低く、識別に与える影響が小さいルールであると考えられるためである。Line 3 では、未知クラスを識別するルールのみが生成されるように、ヒューリスティックルール生成法の入力には、未知クラスのパターンの集合を与える。また、未知クラスの増加に伴いデータの分布は複雑化すると考えられる。したがって、適切な識別境界を表

Algorithm 4: Generate rules classifying new class

Input: Population P , population size N_p , # of increasing rules N_r , new class data D_{new} , old class data D_{old}

Output: Updated population P_{new}

1. Recalculate rule weights of all fuzzy rules in P with D_{new} and D_{old} .
2. Discard fuzzy rules in P whose rule weight is less than threshold γ .
3. Generate fuzzy rules from D_{new} by heuristic rule generation until the number of fuzzy rules is equal to $N_p + N_r$.
4. Update P .
5. Output P .

Algorithm 5: Instance reduction

Input: Trained class data D_{old}

Output: Reduced data D_{IR}

1. **for** $c = 1$ to m (m is the number of classes in D_{old}).
2. **if** patterns in class c are not removed **then**
3. Generate new patterns representing the distribution of class c through a clustering method.
4. Assign a weight to new patterns.
5. Add new patterns to D_{IR} .
6. **end for**
7. Output D_{IR} .

現するために必要なルールの数も増加すると推測される。そこで、Line 3 では未知クラスの増加に伴い、保持するファジィルールの総数も増加させる。

3.2 既存クラスに対するデータ削減

Algorithm 5 では、学習済みのクラスについて 1 度だけデータ削減を行う。データ削減に際して、Line 3 で学習済みのデータの分布を保持するために、代表点を生成可能な任意のクラスタリング手法（e.g., Growing Neural Gas: GNG [5]）を用いて、各クラスにおけるデータの代表点を抽出する。抽出した代表点は Line 5 で新しい学習用データとして D_{IR} に追加する。そのため、全ての D_{IR} のパターンは元々の学習用データ D_{old} に含まれない。

Line 4 では、新しく生成したパターンに対して重み付けを行う。これは、既存クラスのデータのみを削減することにより、クラス間のパターンの数の比率が変化し、学習に悪影響を与えることを防ぐためである。重み付けの比率にはデータの削減率 R_{IR} を用いる。

4. 数値実験

未知クラスのパターンが継続的に与えられる場合において、CI-FGBML が従来のファジィ GBML (FGBML) と比較して効率的な学習が可能であるか検証する。

まず、継続的な学習が可能であるかという観点から、識別に不要なルールを未知クラスを識別するルールに再構成するという操作が有効であることを確認する。具体的には、FGBML に Algorithm 4 のみを適用した場合 (CI-FGBML-N) と FGBML それぞれで獲得される識別器の識別精度の推移を比較する。た

表 1 数値実験パラメータ

Michigan-style Fuzzy GBML (Algorithms 1–3)		
N_{pop}	Initial population size	20
P_{dc}	“don’t care” probability	$(n - 5)/n$ (n : # of attributes)
P_C	Probability of applying crossover	0.9
P_M	Probability of applying mutation	$1/n$
C_{CI}	Class incremental condition	Every 500 generation elapsed.
Class Incremental Learning (Algorithms 4, 5)		
γ	Threshold of rule weight	0.0
R_{IR}	Reduction rate	0.8
N_r	# of increasing rules	10
	Clustering method	GNG

表 2 データセット緒元

Dataset	# of patterns	# of attributes	# of classes
Satimage	6,435	36	6
Penbased	10,992	16	10
Vowel	990	13	11
Letter	20,000	16	26

だし、一括学習を前提とする FGBML では、クラス増分学習が不可能なため、識別器を再設計することで未知クラスの学習を行う。以下にその手順を示す。まずクラス増加時に全てのルールを破棄する。次に、Algorithm 1 の手順に従い、未知クラスおよび既存クラスのデータを用いて一括学習を行う。この際、識別器を構成するルールの数の差が識別精度へ影響を与えることを防ぐため、FGBML においてもルールの数を N_r だけ増加させる。

また、計算コストの削減の観点から、CI-FGBML においてクラスタリングを用いたデータ削減が有用であることを確認する。具体的には、FGBML に Algorithms 4, 5 を適用した場合 (CI-FGBML-G), CI-FGBML-N, および従来手法において獲得される識別器の識別精度と実行時間を比較する。なお、CI-FGBML-G について、本研究では Algorithms 5 で適用するクラスタリング手法として GNG を用いる。

4.1 数値実験設定

本研究では、未知クラスのパターンが継続的に与えられる状況を擬似的に再現するために以下の操作を行う。まず、データセットから任意の 2 クラスを取り出し学習を行う。次に、一定世代経過後に任意の未学習のクラスを 1 つ学習用データに追加し学習を行う。これを M クラスになるまで、一定世代経過ごとに繰り返す。したがって、クラスの追加順は各試行で異なる。

数値実験の設定は表 1 のパラメータに従い、試行回数は 20 回 (10-fold cross-validation $\times$ 2 回) とする。ここで、ファジィ GBML のパラメータは CI-FGBML の Algorithms 1–3 に関するパラメータと共通の値とする。また、表 2 に数値実験で用いる 4 種類の実世界データセットを示す。これらのデータセット

図 1 評価用データに対する誤識別率の推移

図 2 評価用データに対する誤識別率と実行時間の比較

は全て KEEL-data set repository [6] により提供されている。

4.2 数値実験結果

4.2.1 未知クラスを識別するルールの生成

評価用データに対する誤識別率の推移を図 1 に示す。図 1 より、CI-FGBML-N は Satimage を除くデータに関し、従来手法よりも高い識別精度を獲得した。特に、クラス増加時の識別精度に着目した際、FGBML と比べて CI-FGBML-N は識別精度の悪化の程度が大きく緩和されていることがわかる。これは、クラス増加時に FGBML が学習したすべてのルールを破棄し学習が一度断絶する一方で、CI-FGBML-N が識別に与える影響が低いルールのみを選択的に破棄することで継続的な学習を行うためだと考えられる。したがって、CI-FGBML-N は Algorithm 4 により 1 章に示した要件 1) を満たすと考えられる。

また、全ての結果に共通する特徴として、CI-FGBML-N、CI-FGBML-G 共にクラス増加後の学習速度が FGBML よりも低下している点が挙げられる。この原因としては次のことが考えられる。クラスが継続的に増加する状況では特徴空間は細分化されると想定される。したがって、ルールはクラス増加前よりも狭い範囲を覆う必要がある。ここで、式 (2) よりルールの評価値は正答したパターン数のみから与えられる。そのため、クラス増加前に生成された広範囲を覆うルールの評価値が、クラス増加後に生成された狭い範囲を覆うルールよりも高くなる。その結果、細分化された特徴空間に適した狭い範囲を覆うルールの進捗が阻害され、学習速度が低下したと推測される。

4.2.2 既存クラスに対するデータ削減

評価用データに対する最終的な誤識別率と実行時間の比較を図 2 に示す。図 2 より、CI-FGBML-G は CI-FGBML-N および FGBML と比較して、いずれのデータに対しても実行時間の大幅な短縮に成功しており、Algorithm 5 により CI-FGBML-G が 1 章に示した要件 3) を満たしていることが窺える。さらに Letter に着目すると、CI-FGBML-G は CI-FGBML-N よりも高い識別精度を獲得している。これは、CI-FGBML-G が各クラスにおけるデータの代表点を抽出して学習に用いることにより、識別境界付近に存在するノイズに近いパターンが破棄されファジィルールの汎化性能が向上したためだと推測される。

また、CI-FGBML-G が FGBML と比較して識別精度が低い Vowel に着目すると、CI-FGBML-G の実行時間は FGBML の半分程度となっている (図 2)。ここで、図 1 に示した識別精度の推移を併せて比較すると、CI-FGBML-G は最終的な識別精度では FGBML よりも僅かに低い識別精度を獲得しつつも、学習途中での識別精度は FGBML よりも高いことが窺える。したがって世代数ではなく実行時間を揃えるという条件のもとで比較した場合には CI-FGBML-G が FGBML よりも高い識別精度を獲得する可能性があると考えられる。

5. おわりに

本論文では、Michigan 型ファジィ GBML をクラス増分学習に対応させた CI-FGBML を提案した。CI-FGBML では、クラス増加時の操作としてクラス増加時の操作として、識別に不要なルールを破棄、未知クラスを識別するルール、そしてクラスターリングに基づく既存クラスのデータ削減を行う。

また、数値実験結果より以下の内容が示された。

1. CI-FGBML-N は Satimage データを除いたすべてのデータに対して, FGBML よりも高い識別精度を獲得した.
2. CI-FGBML-G はすべてのデータに対して, CI-FGBML-N および FGBML と比較して実行時間を大幅に削減した.
3. CI-FGBML-G は一部のデータに対して, データ削減を行わない CI-FGBML-N よりも高い識別精度を獲得した.

今後の課題として, ファジィルールの評価関数に対して誤識別したパターンの数をペナルティとして与えるなどの変更を加え, 学習速度を向上させることが挙げられる.

謝辞

本研究の一部は, JSPS 二国間交流事業共同研究および日本学術振興会科学研究費助成事業 (課題番号: 19K20358) の助成を受けたものである.

参考文献

- [1] Parliament and Council of the European Union: "General Data Protection Regulation," *The Official J. of the European Union*, L119, pp. 1-88, 2016.
- [2] S.-A. Rebuffi, A. Kolesnikov, G. Sperl, and C. H. Lampert: "iCaRL: Incremental classifier and representation learning," *2017 IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*, pp. 5533-5542, 2017.
- [3] Y. Nojima, S. Takemura, K. Watanabe, and H. Ishibuchi: "Michigan-style fuzzy GBML with (1+1)-ES generation update and multi-pattern rule generation," *Proc. of 2017 Joint 17th World Congress of Int. Fuzzy Systems Association and 9th Int. Conf. on Soft Computing and Intelligent Systems*, June 27-30, Otsu, Japan, pp. 1-6, 2017.
- [4] H. Ishibuchi, T. Yamamoto, and T. Nakashima: "Hybridization of fuzzy GBML approaches for pattern classification problems," *IEEE Trans. on Systems, Man, and Cybernetics - Part B: Cybernetics*, Vol.35, No.2, pp. 359-365, 2005.
- [5] B. Fritzke: "A growing neural gas network learns topologies," *Adv. Neural Inform. Processing Syst.*, Vol.7, 1995.
- [6] <http://www.keel.es/> [Accessed Jan. 14, 2020]

(2019 年 9 月 30 日 受付)
(2019 年 10 月 16 日 採録)

[問い合わせ先]

〒599-8531 大阪府堺市中区学園町 1-1
大阪府立大学 大学院工学研究科
増山 直輝
TEL: 072-254-9198
FAX: 072-254-9825
E-mail: masuyama@cs.osakafu-u.ac.jp

著者紹介

いりま ゆうと
入江 勇斗 [非会員]

2018 年大阪府立大学工学部電気電子系学類情報工学課程卒業. 現在, 同大学大学院工学研究科電気・情報系専攻知能情報工学分野在学中. 進化型ファジィシステムに関する研究に従事.

ますやま なおき
増山 直輝 [正会員]

2010 年日本大学理工学部航空宇宙工学科卒業. 2012 年首都大学東京システムデザイン研究科ヒューマンメカトロニクスシステム学域 (現: 知能機械システム工学科) 博士前期課程修了. 2016 年マレーシア国マラヤ大学計算機科学・情報技術学部人工知能学科博士後期課程修了. 博士 (工学). 2016 年マラヤ大学計算機科学・情報科学部博士研究員. 2017 年より大阪府立大学工学研究科電気・情報系専攻知能情報工学分野助教, 現在に至る. 主にデータマイニングや教師なし学習の研究に従事. IEEE, 日本知能情報ファジィ学会の会員.

のじま ゆうすけ
能島 裕介 [正会員]

1999 年大阪工業大学工学部機械工学科卒業. 2001 年同大学大学院工学研究科博士前期課程機械工学専攻修了. 2004 年神戸大学大学院自然科学研究科博士後期課程システム機能科学専攻修了. 同年大阪府立大学大学院工学研究科助手, 2007 年同助教, 2013 年同准教授, 現在に至る. 博士 (工学). 進化型ファジィシステム, 多目的知識獲得, 進化型多目的最適化などの研究に従事.

いしづち ひさお
石淵 久生 [非会員]

1985 年京都大学工学部機械系精密工学科卒業. 1987 年同大学大学院工学研究科修士課程精密工学専攻修了. 同年大阪府立大学工学部助手, 1993 年同講師, 1994 年同助教, 1999 年同教授. 2017 年南方科技大学計算機科学工学科講座教授, 現在に至る. 博士 (工学). 進化型多目的最適化, ファジィ識別システム, ファジィ遺伝的機械学習などの研究に従事. IEEE Fellow.

Fuzzy Genetics-Based Machine Learning to Handle Continually Increasing Unknown Classes

by

Yuto IRIE, Naoki MASUYAMA, Yusuke NOJIMA, and Hisao ISHIBUCHI**Abstract:**

The recent rapid development of information technology has enabled us to collect data continually. The accumulated data is regarded as an important economic resource. Many researchers have studied techniques for extracting knowledge in an interpretable format from continually increasing data in view of quality and quantity. Fuzzy genetics-based machine learning (GBML) is one of the most effective methods to design a classifier to extract interpretable knowledge. By applying fuzzy GBML, we can obtain a fuzzy classifier composed of linguistically interpretable rules. However, fuzzy GBML cannot learn in a situation where training data with unknown class labels increases continually (i.e., class incremental situation) because its learning algorithm is batch learning. In this paper, we propose class incremental fuzzy GBML (CI-FGBML), which can learn in the class incremental situation. Specifically, when patterns in an unknown class obtains, CI-FGBML performs two operations: i) regeneration of rules for classifying the unknown class, and ii) reduction of training data belonging to trained classes. Experimental results show that the proposed method can learn efficiently in the class incremental situation from the viewpoint of computational cost.

Keywords: fuzzy classifier, genetics-based machine learning, class incremental learning

Contact Address: **Naoki MASUYAMA**

Osaka Prefecture University
1-1 Gakuen-cho, Naka-ku, Sakai, Osaka 599-8531, Japan
TEL: +81-72-254-9198
FAX: +81-72-254-9825
E-mail: masuyama@cs.osakafu-u.ac.jp