

未知を知る確率的 AI チップの開発

研究代表者：横浜国立大学 島 圭介

【基本構想】

深層学習が牽引する第三次人工知能 (AI) ブームが到来し、めざましい進展を見せている。しかし、必ずしも AI は万能ではなく、対象の問題に適切かつ十分な設備や費用を投入し、AI を正しく学習させなければ想定した成果が出せない。また近年では AI が出力する結果の信頼性・妥当性・説明性が問題視され、高性能な AI 技術が身近な日常生活に十分に普及・定着しているとは言い難い。この背景には、従来の AI が学習時に想定していない未知の対象を“知らない”と理解できないという根本的な問題や、通信環境や装置の制約によって人間支援ロボットなどのハードウェアへの AI モデルの搭載が難しいという課題などが存在する。本プロジェクトでは未知事象の推定と自律的な AI 構造の再構築機能を有する新しい確率型 AI チップを創生することで、これらの問題解決を目指している。本稿では令和 4 年度の成果として、未知を知る AI の分類性能・汎用性向上、ハードウェア実装に成功したので報告する。

1. 研究目的

深層学習が牽引する第三次人工知能 (AI) ブームが到来し、めざましい進展を見せている。しかしながら、必ずしも AI は万能ではなく、対象の問題に適切かつ十分な設備や費用を投入し、AI を正しく学習させなければ想定した成果が出せない。これは、現行の AI のほとんどが単純な演算素子を多段 (深層) に組み合わせたモデルを基本としており、近年の IT 技術の高性能化に伴って容易に得られる大量のデータを、強力かつ高価な GPU (画像処理装置) を用いて学習させることで高い認識精度を実現していることに起因する。また近年では AI が出力する結果の信頼性・妥当性・説明性が問題視され、科学技術振興機構 (文部科学省) 戦略事業の令和 2 年度戦略目標に「信頼される AI」が策定されるなど、AI システムの限界を克服する新技術が求められている。

このような現状においては、ヒトの判断能力を超えるような高性能な AI 技術が身近な日常生活に十分に普及・定着しているとは言い難い。その背景には、従来の AI が①学習時に対象としていた問題しか取り扱うことができず、未知の対象を“知らない”と理解できないという根本的な問題がある。また、②数学的に表現された実空間の学習・識別モデルを人間支援ロボットなどのハードウェアに搭載することが困難な現状も存在する。つまり、ロボットや医療機器、検査装置などに AI 技術を導入する際には、通信環境や装置の制約 (使用できる回路の制約や実時間内で計算処理を終える必要があるなどの時間的制約) から、比較的簡単な学習モデルや近似モデルを用いるしかなく、理論的に構築された識別能力を十分に適用できないという大きな矛盾がある。

発展がめざましい深層学習などの高性能な AI 技術を社会に普及させるためには、人から発生する生体信号や人が取り扱う対象などの確率的な振る舞いをする認識対象に

対し、①学習していない未知の対象を“知らない”と AI 自身が高精度に認識できる新しい革新的なアイデアと、ベイズ推論に基づいて AI の判断の根拠・信頼性・妥当性を議論/検討し、AI そのものの構造を動的に変化できる基盤を整えること、さらにモデルに基づいて様々な対象に組み込み可能な②小型・高速な AI チップの実現が必要不可欠である。本研究では、AI を独自の確率モデルを用いて高性能化することにより、未知の事象の推定と自律的な AI 構造の再構築機能を有する新しい確率型 AI チップを創生することによってベイズ推論を進化させ、これらの問題解決を目指す。

本稿ではこれらの取り組みのうち、令和 4 年度に実現した未知を知る AI の分類性能・汎用性向上、ハードウェア実装について報告する。

2. 研究成果

2.1. 未知事象のパラメータを学習的に獲得可能な混合ガウス分布型ニューラルネット

学習データの存在するパターン識別問題では通常各学習サンプルに正解となる教師ラベルが付与されているが、教師ラベルが存在しない場合や教師ラベルの信頼性が低い場合には教師なし学習が採用される。一方、我々の研究グループが開発した未知を知る AI では、学習する際に分類対象とする事象 (クラス) の数などのハイパーパラメータを事前に決定する必要があり、教師データが存在しない場合に未知を知る AI を適用することはできない。この課題を解消するために、教師ラベルが付与されていない学習サンプルから分類モデルの構造を動的に獲得可能な新たな学習則を提案し、事前に教師ラベルが存在しない問題に適用可能な未知を知る AI を実現した。

提案法では学習データに対し、 k -means 法を用いて初期分布パラメータを獲得する (図 1-1 (b))。獲得した分布パラメータを未学習クラス推定確率ニューラルネットの

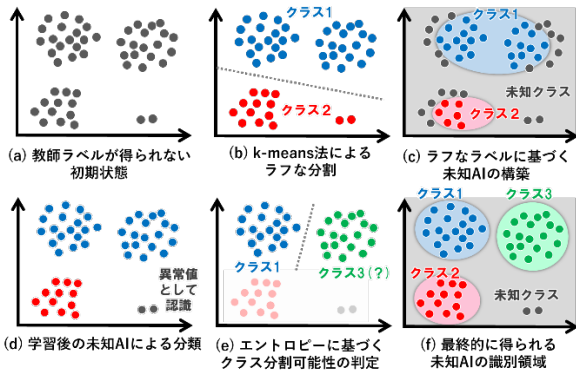


図 1-1：未知 AI に基づく自動クラスタリング手法

ネットワークパラメータに変換し、新学習則を用いてパラメータの学習を行う (図 1-1 (c)). 学習終了時のエントロピーに基づいて対象のクラスターの分割判定を行い、分割可能なら各クラスターに所属するデータに対し、 k -means 法を用いた初期分布パラメータの獲得を行う (図 1-1 (e)). クラスターの分割が終了後、未学習クラスに属するデータに対して、同様の分割を繰り返すことで未学習推定確率ニューラルネットの動的構造獲得を行う. これにより、未学習クラスを推定しながらクラス数を自動で獲得することが可能となる (図 1-1 (f)).

提案法の有効性・汎用性評価のために、筋電位信号を利用した前腕動作分類タスクにおける分類精度評価を実施した. 実験に参加した被験者は 7 名で、学習データ収集時には前腕の 4 動作を、テスト時には未学習動作を含む 6 動作を実施した (図 1-2). 図 1-3 には各手法、各被験者におけるテストデータの分類精度を示す. 結果では、提案法は全ての被験者に対して比較手法より優れた識別精度を記録し、提案法が高精度な教師なし学習による学習動作分類と未学習動作検知の両方を実現できることが示された.

2.2. 未知推定ニューラルネットへの拡張理論構築

2.2.1. 時系列データへの対応

時系列データに対するパターン識別手法は現在までに数多く提案されているが、それらは分類に用いる特徴量の性質によって、各時刻のデータに対して分類を行う静的な識別器と、任意の区間におけるデータの時間変化を考慮可能な識別器の 2 つに大別することができる. 一般的に後者の時系列型識別器の方が高い識別性能を有することが広く知られている一方、従来の未知を知る AI は時系列情報を考慮できない静的な識別手法として設計されている. 時系列データに対する識別精度向上を実現するためには、データの時間変化を考慮可能な未知を知る AI の改良モデルが必要となる.

そこで、本研究ではデータの時間変化を表現可能な確率モデルの 1 つである確率隠れマルコフモデル (Hidden Markov Model: HMM) に着目し、混合余事象分布 (Complementary Gaussian Mixture Model: CGMM) を内包した HMM に基づく未学習クラス推定確率リカレントニューラルネットを提案する. 提案法では学習対象クラスのデータ分類を混合正規分布 (Gaussian Mixture Model: GMM) を出力分布として有する HMM で、学習時に想定しない未



図 1-2：検出・分類対象とした 6 種類の前腕動作

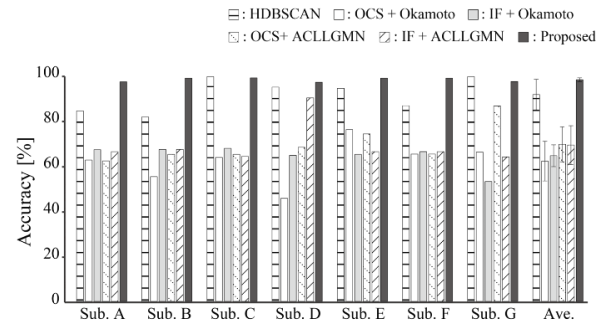


図 1-3：被験者ごとの分類精度比較




図 2-1：提案法のネットワーク構造 (リカレント型)

学習クラスのデータを出力分布として CGMM を有する 1 状態の HMM で表現し、2 種類の HMM の確率演算をネットワーク状に展開することで時間変化を考慮した多クラス識別と未学習クラス推定を単一のニューラルネットで実現する. また、通時誤差伝播法を適用することで内包する確率モデルのパラメータの学習的獲得を可能とする. 提案法のネットワーク構造を図 2-1 に示す.

実験では提案法を人工データおよび EMG 信号に基づく前腕動作の分類に応用し、提案法の有効性を検証した. EMG 信号に基づく動作分類実験では、図 2-2 に示す全 12 動作を実施し、動作分類精度評価を実施した. 比較手法には従来の未知を知る AI、2 つの時系列情報を考慮可能な識別器 (LSTM [1], R-LLGMN [2]) と 3 つの異常検知手法 (One-class SVM [3], Isolation Forest [4], DAGMM [5]) を組み合わせた 6 手法を利用した. 被験者は 5 名 (A-E) とし、評価実験では被験者が未学習クラスの動作を含む識別対象の 12 動作を M1 から順に M12 まで行う試行を 2 セット行い、テストデータとして利用した. 図 2-3 に各被験者に対して得られた平均識別率とその標準偏差を示す. 結果から、被験者 E を除く 4 名の被験者において提案法が最も優れた識別精度を記録し、全被験者の平均識別率 (図中の Ave.) では従来の未知を知る AI (図中の Comparative method) を除く 4 つの比較手法に対して有意差が確認できた. この結果から、新たに開発した時系列情報を考慮可能な未知を知る AI の有効性が示唆された.

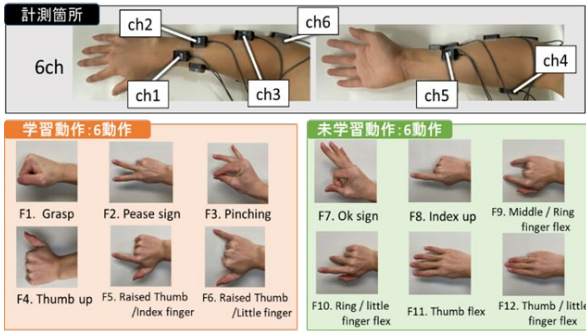


図 2-2: 実施した 12 種類の前腕動作




図 2-3: 被験者ごとの分類精度と有意差の検定結果

2.2.2. 画像データへの対応

前節内容に加えて、従来の未知を知る AI は画像データに対して十分な分類精度を得られないという課題も存在する。画像データは非常に高次元な情報を有しており、それらの分布を確率モデルで表現しようとした場合、統計的制約を満たす適切な GMM, CGMM のパラメータを求めることが難しい点が原因の 1 つとして考えられる。そこで、未知を知る AI に深層学習の知見を導入し、画像データに対する特徴抽出を可能にする畳込み層 (Convolution Neural Network: CNN) を有する新たな未知を知る AI を提案する。

図 2-4 に提案法のネットワーク構造を示す。提案法では CNN を利用した画像データに対する次元削減を実施し、CNN から抽出された低次元な特徴量に未知を知る AI を適用することで、画像データに対する未学習クラス推定を可能にする。ただし、未知を知る AI が内包する確率モデルの統計的な制約により、CNN と未知を知る AI を学習初期段階から結合して学習を実現することが困難となるため、提案法では Metric Learning 手法やフルコネクト層を導入した CNN の事前学習を実施する。さらに、事前学習後の特徴量マップから未知を知る AI のパラメータを初期化し、未知を知る AI と CNN を結合したネットワーク全体の学習を実施する。新たに開発した上記の 2 段階学習アルゴリズムにより、提案法のモデルパラメータの学習を実現できる。分類性能評価実験では MNIST (手書き文字データ, 2 値画像) と CIFAR-10 (動物や乗り物の画像を含む 10 クラス分類, カラー画像) というベンチマークデータを利用した。学習時にはデータ含まれる 10 個のクラスからランダムに抽出した 6 つを学習対象クラスとして設定し、その他のクラスを未学習クラスとして扱う。比較手法には提案モデルと同様に特徴抽出部と未学習クラスを考慮した多クラス識別部で構成される手法 (MLS [6]) を採用した。

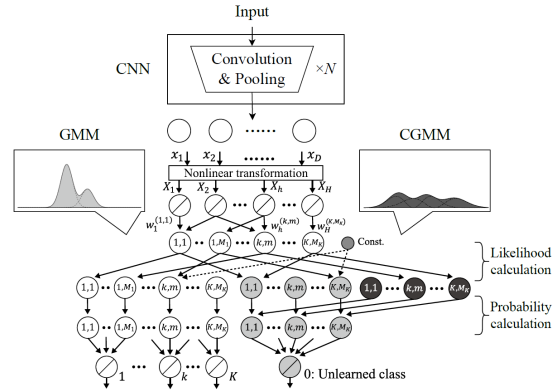


図 2-4: 提案法のネットワーク構造 (畳込み層と結合)

表 2-1: ベンチマークデータに対する分類精度

Metric	Accuracy				AUROC			
	MNIST		CIFAR-10		MNIST		CIFAR-10	
Dataset	500	100	500	100	500	100	500	100
# of data per class	500	100	500	100	500	100	500	100
MLS	98.5	95.9	83.4	70.2	97.9	92.2	80.5	71.7
Proposed	99.2	95.9	81.7	31.3	97.9	93.6	75.5	45.5
Proposed_noml	99.1	98.8	87.4	79.1	90.0	92.2	73.0	63.9

MLS では画像認識モデルで特徴抽出をした後、ソフトマックス関数の入力値であるロジットに閾値を設けて未学習クラス分類を行っている。また、本実験では学習時に使用するデータ数を制限し、それぞれのデータセットから学習データを 500 個/100 個抽出した 2 つの学習条件を設定した。

表 2-1 に提案法および比較手法の分類精度を示す。表中の MLS は比較手法を、Proposed は Metric Learning 手法による事前学習を用いた提案法、Proposed_noml はフルコネクト層を使用した事前学習を用いた提案法を表し、学習クラスに対する分類精度 (Accuracy) と未学習クラスの検知精度 (AUROC) をそれぞれ算出した。結果から、提案法は学習データ数を変更した両条件において比較手法と同等かそれ以上の識別精度を達成できたことが確認できる。ただし、MNIST と CIFAR-10 に対する 2 つの提案法の識別精度は大きく異なる結果となり、分類対象画像によって有効な事前学習方法が異なることが示唆された。

3. 未知を知る AI の FPGA 実装

クラウドコンピューティングを用いた高性能な AI による認識技術が発展してきているものの、医療や産業の現場では未だ高性能な計算機が完全に整備されているとは言い難く、技術を有効活用できていない。本研究では未知を知る AI のハードウェア実装を実現し、提案する AI チップによって高速通信環境や高性能 PC が導入できない現場での利用や未知を知る AI のウェアラブルシステムへの搭載を試みる。本研究では特に、高速な演算が可能な FPGA (Field Programmable Gate Array) に未知を知る AI を実装することを目的とする。

FPGA への実装では実装回路面積などのハードウェアの制限が存在し、未知を知る AI を単純に FPGA に実装すると多くの計算回路が必要となるため、実行コストの上昇や実装不可能となる問題が発生する。そこで、提案法では

未知を知る AI が内包する確率密度関数 (GMM & CGMM) が必要とする指数・対数演算をビットシフトと足し算で近似し、実装・演算コストを低減した近似 GMM (Approximated GMM:A-GMM) と近似 CGMM (A-CGMM) に基づく新たな近似型未知を知る AI を開発した。また、近似型未知を知る AI を複数使用し、任意の分類対象が複数のクラスに所属可能な非排他的な分類手法を検討した。非排他的な分類を容認することで複雑な分類タスクにおけるモデルサイズの削減が期待され、実装面積の削減と分類精度の維持を両立可能か検証した。

まず、EMG 信号に対する信号処理部や複数の未知を知る AI を一枚の FPGA に実装可能か検討し、実際に実装可能であることが確認できた。実験に使用した FPGA 評価ボード (DE10-standard, Terasic 製) は比較的安価なものであるが、信号処理から学習、分類までをワンチップで実現できる。また、FPGA 上に実装した提案法は、小型の演算デバイス (Edge2, Khadas 製や Jetson, Nvidia 製) に実装した従来の未知を知る AI と比較して 65 倍以上高速な演算が可能であることが明らかになった。

次に、実験では提案法を EMG 信号に基づく前腕動作分類へ応用し、事前に想定しない未学習動作、および複数の前腕動作の組み合わせで表現される複合作を含む複雑な分類問題に応用可能か検討した。ここでは、2つの未知を知る AI を FPGA 上に実装し、それぞれを手首動作の識別器、指動作の識別器として用いる。2つの未知を知る AI から得られる識別結果を合成することで、未学習動作を考慮した非排他的な分類を実現する。図 2-1 に分類対象とした前腕動作を示し、図 2-2 にそれらの動作に対する分類結果例を示す。図 2-2 では上から計測した EMG 信号、筋力情報、指動作識別器の分類結果 (F0-F2, F0: 未学習クラス)、手首動作識別器の分類結果 (W0-W2, W0: 未学習クラス) を表す。識別結果においては黒い箇所が識別に成功した箇所、白い箇所が識別に失敗した箇所を表す。結果から、F4 や W3, C7 に対する誤識別が見られるものの、提案法が概ね正確に未学習動作、および複合作を識別できたことが確認できる。誤識別の原因としては計測チャンネル数の少なさなどが考えられる。この結果に加えて、未知を知る AI を複数した提案法が実施した複合作を個別に学習対象とした未知を知る AI と比較して、実装回路面積を約 58% 削減できること、識別精度の著しい劣化が発生しなかったことを確認できた。以上の結果から、FPGA 実装を指向した提案法の有効性を実証した。

4. まとめと今後の展望

昨年度は、我々の研究グループで培ってきた学習時に想定しない未知事象を考慮できる“未知を知る AI”を發展させた技術の開発に取り組み、①教師ラベルが得られないケースにも使用可能な構造獲得型未知推定 NN の提案、②高次元な時系列データや画像データにも適用可能にする未知推定 NN の拡張理論構築、③エッジコンピューティングを実現するための未知推定 NN の FPGA 実装を実現した。次年度は、各手法のさらなる改良、および医療・福祉・産業分野での実用化を指向した実証実験に取り組んでいく。




図 3-1 : FPGA 実装された未知 AI によるインタフェース制御



図 3-2 : 分類対象とした前腕動作とその複合作

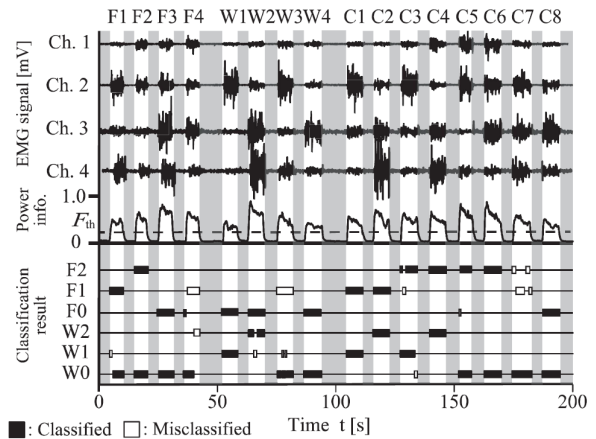


図 3-3 : 各動作に対する識別率の変化

【参考文献】

- [1] H. Abrishami, M. Campbell, C. Han, R. Czosek and X. Zho, “Supervised ECG Interval Segmentation Using LSTM Neural Network,” BIOCAMP, pp. 71-77 (2018).
- [2] T. Tsuji, N. Bu, O. Fukuda, and M. Kaneko, “A Recurrent Log-Linearized Gaussian Mixture Network,” IEEE Transaction on neural networks, VOL. 14, NO. 2, pp. 304-316 (2003).
- [3] C. M. Rocco S and E. Zio, “A support vector machine integrated system for the classification of operation anomalies in nuclear components and systems,” Reliability Engineering and System Safety, Vol. 92, pp. 593-600 (2007).
- [4] F. T. Liu, K. M. Ting and Z.-H. Zhou, “Isolation Forest,” IEEE Int. Conf. on Data Mining, pp. 413-422 (2008).
- [5] B. Zong, Q. Song, M. R. Min, W. Cheng, C. Lumezanu, D. Cho, and H. Chen, “Deep Autoencoding Gaussian Mixture Model for Unsupervised Anomaly Detection,” in Proceedings of the International Conference on Learning Representations (2018)
- [6] S. Vaze, K. Han, A. Vedaldi and A. Zisserman, “Open-Set Recognition: A Good Closed-Set Classifier is All You Need,” International Conference on Learning Representations (2022)

業績

【原著論文】

1. 迎田 隆幸, 島田 悠之介, 田中 孝之, 野口 宏明, 阿部 敏久: ウェアラブル・エンベデッドセンサを用いた作業姿勢分類と作業検知への応用, 計測自動制御学会論文集, 58 巻, 12 号, p. 558-567, 2022 年

【口頭発表】

1. 柏木 僚太, 迎田 隆幸, 小宮山 翼, 西原 翼, 島 圭介: FPGA 実装を指向した混合ガウス型識別モデルに基づく人間支援インタフェースの EMG 制御, 第 40 回日本ロボット学会学術講演会予稿集, RSJ2022AC2H2-06, 2022 年 9 月 5-8 日, 東京大学
2. 嘉山 敢太, 迎田 隆幸, 島 圭介: 適応的遷移確率を導入した隠れマルコフモデルに基づくリカレント確率ニューラルネット, 情報処理学会第 85 回全国大会講演論文集, pp.2-853--2-854, 2023 年 3 月 2-4 日, 電気通信大学
3. 小宮山 翼, 迎田 隆幸, 島 圭介: 混合余事象分布と隠れマルコフモデルを内包する未学習クラス推定確率リカレントニューラルネット, 情報処理学会第 85 回全国大会講演論文集, pp.2-831--2-832, 2023 年 3 月 2-4 日, 電気通信大学
4. 西原 翼, 富濱 啓伍, 迎田 隆幸, 島 圭介, 井上 真一, 小池 美和, 平野 明典, 神谷 昭勝, 南 重信: 実環境利用を指向した ECG 特徴に基づく感情推定アプリケーション, 情報処理学会第 85 回全国大会講演論文集, pp. 2-671--2-672, 2023 年 3 月 2-4 日, 電気通信大学
5. 三苫 凌, 迎田 隆幸, 島 圭介: 混合余事象分布に基づく未学習推定畳込みニューラルネット, 情報処理学会第 85 回全国大会講演論文集, pp.2-469--2-470, 2023 年 3 月 2-4 日, 電気通信大学
6. 清水 武史, 島 圭介, 迎田 隆幸: 未学習クラス推定確率ニューラルネットの動的構造獲得法, 第 28 回ロボティクスシンポジウム講演論文集, pp. 210-212, 2023 年 3 月 15-16 日, 和歌山
7. 柏木 僚太, 迎田 隆幸, 島圭介: 未学習クラス推定近似確率ニューラルネットの FPGA 実装, 第 28 回ロボティクスシンポジウム講演論文集, pp. 213-215, 2023 年 3 月 15-16, 和歌山

【特許】

- (1)国内特許出願 2 件