

未知を知る AI 搭載型ハードウェアの開発

研究代表者：横浜国立大学 島 圭介

【基本構想】

深層学習や ChatGPT などが牽引する人工知能（AI）ブームはもはや第 4 次を迎え、日々めざましい進展を見せている。ただし、AI が万能ではないことは周知の事実であり、対象の問題に適切かつ十分な設備や費用を投入し、適切なモデルや多くの学習サンプルを用いて 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、AI の高性能化に伴って、出力結果の信頼性・妥当性・説明性や AI と人の共存法が問題視されている。このような背景から AI 技術を身近な日常生活に十分に普及・定着させる新たな工夫が求められ、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を解消する必要がある。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。

1. 研究目的

深層学習や ChatGPT が牽引している人工知能（AI）ブームはもはや第 4 次を迎えたともいわれており、いまだに日々めざましい進展を見せている。ただし、このような現状においても AI が万能ではないことは周知の事実であり、対象の問題に適切かつ十分な設備や費用を投入し、適切なモデルや多くの学習サンプルを用いて 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 の高性能化に伴って AI が出力する結果の信頼性・妥当性・説明性や、AI 活用や AI と人の共存法が問題視され、AI 技術を身近な日常生活に十分に普及・定着させる新たな工夫が求められる。その実現のヒントには大きな 2 つの課題、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点、さらに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である点を打破するアイデアが必要となる。

ロボットや工業用加工機、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。発展がめざましい高性能な AI 技術を人間社会に普及させるためには、確率的な振る舞いをする認識対象・データに対し、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／検討して、②AI 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んで適応・進化可能な③小型・高速な AI 搭載型ハードウェア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。

本稿では令和 6 年度の成果として、未知を知る AI の理論拡張、ならびに応用事例について検討した内容について報告する。

2. 研究成果

2.1. 近似 GMM 型未知推定ニューラルネットの FPGA 実装と健常者用筋電義手制御への応用

昨年度までに、本研究では FPGA（Field Programmable Gate Array）に実装可能な近似 GMM 型未知推定ニューラルネットを提案し、前向き演算（推論）部分および誤差逆伝播演算（学習）部分の実装に成功していた。しかしながら、検証には検証用に周辺回路が整備された FPGA 評価ボードを使用しており、ボードの大きさや価格、演算リソースなどを考慮するとそれらを単純に筋電義手の開発へ適用することは非常に冗長であった。そこで、本研究ではより小型かつ安価な FPGA に実装された実用的な未知 AI チップの作成に取り組み、その応用例として未知 AI チップを搭載した健常者用筋電義手（筋電位（EMG）信号によって制御可能な五指駆動型ロボットハンド）の開発を試みた。

まず、開発した筋電義手制御システムの概略図を図 1-1 に示す。本システムは EMG 信号の入力のための A/D コンバータの制御部、信号処理部、未知 AI のパラメータ保管部、未知 AI による推論部、インタフェース制御部からなる。信号処理部で処理された EMG 信号の特徴ベクトルを未知 AI に入力することで、実施された手指動作の分類を実現できる。さらに、インタフェース制御部において、動作分類の結果に基づきサーボモータの回転量を制御し、任意の動作の再現を可能にする。実装時の言語には SystemVerilog を採用し、FPGA チップ（AP68-06Z-A4、




図 1-1: 義手制御システムの概略図




図 1-2: 作成した FPGA 周辺回路と健常者用筋電義




図 1-3: 健常者用筋電義手によるボールの
把持タスクの実施例

HuMANDATA 製) を利用して作成した独自の FPGA ボードに実装した。また、公開データのロボットハンド(Flexy-hand、Gyrobot 製) を健常者に装着可能な筋電義手に加工したものを作成し、実応用のタスクとしてボールの把持を行った。作成した FPGA ボードと筋電義手を図 1-2 に示す。

次に、FPGA チップへの実装結果について述べる。本検証では Digital signal processing を使用せずに Adaptive logic module (ALM) のみを用いて実装を行い、提案システムの実装に必要な回路資源量を正確に把握した。分析結果から、ロボットハンド制御システムの実装に必要な ALM の数は 40、574 個であり、その中で学習部を含む未知 AI が占める ALM の数は 26、595 個であった。また、未知 AI を構成する ALM のうち、近似指数演算は 0.16% を、近似対数演算は 3.00% を占めていることが確認され、未知 AI 実装時のボトルネックにならないことが示された。さらに、近似した 2 つの関数に必要な ALM の数においては、1 つの近似指数関数演算器で 7 個、近似対数関数演算器で 133 個であった。近似を適用しない場合(FPGA Intellectual Property コア、Intel 社)の実装コストと比較すると、提案法の実装コストは指数関数と対数関数でそれぞれ従来法の 0.91%、13.2% に相当し、標準的な実装方法と比較して大幅な回路資源量の削減が可能になった。

最後に、作成した健常者用筋電義手について述べる。作

成した義手を用いてボールをピンチングによって把持する様子を図 1-3 に示す。図 1-3 (a)はボールを把持、図 1-3 (b)はボールの保持と移動、図 1-3 (c)はボールを特定の位置で離す動作を行った様子を表す。ボールの操作者の意思に従ったボールの把持と設置を実現できたことから、提案法を用いたシステムを搭載した筋電義手の実応用可能であることが確認された。ただし、アクチュエータの大きさやバッテリー、FPGA 基板の大きさにより、義手本体に提案システムを格納することは困難であったため、基板の多層化や義手の再設計により、システムのさらなる小型化が必要である。

2.2. 未知 AI の産業分野への応用: 切削加工における加工面粗さ推定

近年の機械学習分野の急激な発展に伴って、産業分野では生産性向上や高品位化を目的として AI を活用した製造工程の自動化が積極的に進められている。一方、人の手を必要とする加工工程も依然として存在しており、切削加工はその一例である。任意の被削材に対して切削加工を行う際、より滑らかな加工面を実現するために加工条件を適切に設定することが求められる。ただし、加工条件設定に十分な経験が必要であり、加工条件の適応的調整には加工中の面粗さの自動的評価法が求められている [1]。一昨年度では未知 AI を加工面粗さ判別問題へ適用し、その有効性を示した。提案法では正常な加工面のデータを正規分布でモデル化し、時系列データに対する異常度を評価するために未知 AI の後段に Gated Recurrent Unit (GRU) [2] を導入した分類モデルを構築した (図 2-2)。未知 AI には前処理を行ったエンドミルの主軸加速度 (3 次元)、切削抵抗 (3 次元) のみを入力とし、提案法では煩雑な特徴抽出処理は必要なく、面粗さ推定に必要な時系列長を従来法より大幅に短くできるということを明らかにした。

昨年度も同課題に対する検討を継続し、判別に使用する特徴量の削減や、図 2-2 のモデルを切削機器内部に導入することを志向した近似分類モデルの構築などを検討した。

実験では様々な加工条件で切削加工された 200 種類のサンプルに対して面粗さ判別を行い、各種学習条件における分類精度を比較した。使用したデータは、100 mm の被削体の内、加工の最初と最後の 6 mm を除いた 94mm 分を抽出したものであり、真値である面粗さの計測値から分類対象区間となる 1 mm ごとの面粗さラベルを作成した。また、学習用データセットを構築する際には 200 条件の中から 120 条件をランダムに選択し、先頭の 12 mm の区間のみを学習に使用した。加えて、残りの 80 条件から作成したテストデータセット① (TS1)、学習対象条件の 12mm 以降から作成したテストデータセット② (TS2) に対する分類精度を評価した。

実験 I では、一昨年度に作成した図 2-2 のモデルに含まれる複雑な演算 (指数関数など) を独自の近似関数に置き換えた近似モデルの分類精度評価を実施した。FPGA などに代表されるハードウェアデバイスに実装する際には演算高速化が必要不可欠である一方、近似演算に起因する分類精度低下が懸念される。図 2-3 に各近似条件における分




図 2-1：切削データの計測環境：3 軸加速度＋切削抵抗 [1]




図 2-2：提案法のネットワーク構造（未知 AI+GRU [2]）




図 2-3：実験 I 近似条件による判別精度の変化




図 2-4：実験 II 入力特徴量を変更した際の分類精度変化

類精度を示す。図中の Standard は近似演算を導入しない条件を、Hard は単純に Hard-Sigmoid 関数を導入した場合を、Custom はビット幅などを調整した提案法を意味する。この結果から、近似関数を適切に設定することで演算コストを低減しつつ、同等かそれ以上の分類精度を実現できることが示された。

実験 II では、2 値分類を行う際の特徴量削減が可能か検討した。切削抵抗センサは高価かつ既存の機器への導入が困難であるという課題を有しており、入力特徴量を 3 軸加速度のみとした条件（入力：3 次元）と、加速度と切削抵抗の両方を入力する条件（入力：7 次元）の間で分類精度を比較する。提案法の近似手法には実験 I の Hard を採用し、従来法 [1] で提案された 3 軸加速度のみを使用するランダムフォレスト (RF 3) を比較対象として導入した。図

2-4 に各条件における分類精度を示す。結果から、入力特徴量を 3 軸加速度のみに限定した場合でも高い分類精度を発揮できることが示された。一方、学習対象に含まれない条件 (TS1) に対しては、切削抵抗のデータを使用した場合に分類精度が向上しており、使用環境に応じて適当な学習条件を設定する必要がある。

2.3. 未知から知識を得ながら動的に AI 構造を適応・再構築する方法論の開発

本節では未知を知る AI が運用され、未学習クラスのサンプルが十分に集まった後の処理について考える。パターン識別問題においては学習時に想定しない未学習クラスのサンプルは異常値として扱われ、未学習クラスを分類できる異常検知手法は数多く存在する。一方、それらの手法では異常を検知のみで異常値の特徴やデータ構造など未学習クラスに関する情報は一切得られないという問題が存在する。未知を知る AI のような異常検知を病症の診断支援や機器の故障検知に応用する場合、異常値に関する情報にも関心があり、未学習クラスの内部構造推定は実運用上、必要不可欠となる。本研究では未学習クラスの内部構造の解析だけ留まらず、異常値の情報を自動的に獲得し、進化する“未知を知る AI”を実現する。

昨年度までにディリクレ過程混合正規分布 (DPGMM) [2] を利用した未知クラスの内部構造推定、推定結果を未知 AI に反映するための分類対象とするクラスを追加/削除する方法論の確立、未知 AI のネットワークの重み係数を直接サンプリングする学習則の提案などを行ってきた。上記のように基礎理論の有効性を示してきた一方、DPGMM の学習時に使用する中華料理店過程 (CRP: Chinese Restaurant Process) に起因し、学習時間が非常に長くなってしまう（数時間から長い場合には数日）という課題が存在する。また、CRP では未知クラス内部に存在するクラス数数を事前に設定する必要がない代わりに、ざっくりとしたデータのまとまりを検出することに留まってしまう。上記の課題を解消するために、本研究では CRP による大まかな構造の取得と、棒折り過程 (SBP: Stick Breaking Process) による各クラスの詳細な構造の取得を組み合わせた新たな学習則を提案する。SBP は存在するクラス数の上限を設定する必要があるものの、無限のクラス数数を仮定できる CRP より早く学習が収束することが期待される。また、CRP で検出された複数の大まかなクラスに対して、それぞれに SBP を並列に適用することで、GPU の並列演算を利用した高速な学習が可能になる。CRP と SBP の配分を調整することで、より高速に、より詳細な未知クラスの内部構造推定を実現できる。

実験では、まず CRP の学習終了条件（後段の SBP へ移行するタイミング）についての検証を実施した。検証に使用したデータは前腕から取得した 4 チャンルの筋電位 (EMG) 信号で、22 動作分の学習サンプルが含まれている (200 サンプル/動作)。本研究では CRP の終了条件を“尤度の変化量”と定義し、対数尤度の変化が 1%、5%、10% 以下で終了とする 3 つの終了条件を設けた。各条件での終了時間と学習によって獲得した確率モデルの尤もら




図 3-1: 終了条件を変更した際の対数尤度、学習時間の変化




図 3-2: SBP の導入による尤度と識別精度の変化




図 3-3: SBP の演算並列化による実行時間の変化

しさ（対数尤度）を図 3-1 に示す。この結果から、CRP の学習が終わりやすくなればなるほど、最終的に獲得した混合正規分布（GMM）の尤度が低下してしまうことがわかる。また、学習時間もそれに伴って短縮され、10%とした場合には学習時間が 20 分（従来の 1/15）程度となっている。最終的に獲得したクラス数だけ見ても従来の条件と大差はなく、早期に打ち切られた CRP でもクラスタの大局的な検知に成功していることが示唆される。さらに、今回の学習条件では多くの動作（学習サンプル）が含まれていたことで学習が延びたと推察され、扱う動作数が減少すれば学習時間の短縮はより顕著になると予想される。

次に、SBP の導入に関する検証結果について説明する。本検証では、前述の EMG データに対して CRP だけで学習した場合と、CRP の後に SBP を実施した場合の対数尤度や動作分類精度を比較した。その結果を図 3-2 に示す。得られた分類精度の結果を見ると、両条件でほとんど差はなく、どちらの条件でも動作分類に適用可能な GMM を獲得できていることがわかる。一方、対数尤度の差は歴然で、CRP と SBP を組み合わせた提案法のほうがより高い尤度に到達できている。GMM のコンポーネント数も大きく異

なり、22 動作分の EMG 信号を学習した際のそれぞれの GMM のコンポーネント数は、CRP のみの場合には 23 個、CRP+SBP の場合には 40 個となっている。以上により、CRP と SBP を組み合わせた提案法の有効性が示された。

最後に、後段の学習にあたる SBP の演算を並列化した場合の学習時間の変化についても調査した。図 3-3 に並列化した場合の SBP の学習時間の変化を示す。図中の α は新規クラスの出来やすさを調整するハイパーパラメータで、 α が大きくなると検出されるクラス数が増える傾向になる。図中の結果を見ても、 α を 10 とした場合に最も多くのクラスが検知されている。実行時間について見ると、 α の大きさによらず、並列化によって SBP の学習時間を大幅に短縮できていることが確認できる。GPU による並列演算を導入したことで、20 分程度の従来の学習時間が、1.2 分程度まで短くなった。

以上の結果から、最も学習時間を短縮したい場合には SBP のみによる学習が推奨され、クラス数の上限を設定したくない場合には尤度変化による終了条件を設けた CRP による事前学習の実行が推奨されることが明らかになった。

2.4. クラス分類の誤差とデータの生起確率の両方を考慮した未知 AI 学習則の提案

未知 AI は学習クラスに対応する正規分布と未知クラスの分布を仮定した余事象分布を内包した識別モデルであり、ベイズの定理に基づき、事後確率が最大となるクラスを選択することでオープンセット認識（未知クラスを含む多クラス分類）が可能になる。しかしながら、未知 AI の学習では学習データに対する分類精度のみが考慮され、学習データの分布を学習によって適切に獲得できることが保証されない。その問題に起因し、学習時に分布パラメータが変化しにくいことや、他の特徴抽出を可能とする深層ニューラルネットと未知 AI を結合し、統合的学習を行うことができないという致命的な課題が存在する。この課題を解消するために、本研究では未知 AI の出力である事後確率に基づく学習に加え、学習データに対する尤度も考慮可能な学習方法を提案する。提案法では識別精度と学習データに対する GMM の尤度を組み合わせた同時確率を高める新たな学習則を適用し、学習データの分布を正確に獲得することで、分類精度の向上と、内包される確率分布のパラメータの誤差の低減を実現する。

提案する学習則では分類精度（事後確率の誤差）を考慮したクロスエントロピー誤差に加え、Energy-based model (EBM) [3]で提案されたエネルギー関数をアレンジして導入する。EBM の重要なコンセプトは、“学習データと、ニューラルネットの内部からサンプリングしたデータの分布が一致するように学習する”ことであり、未知 AI の学習則にもこの概念を導入した。新しい学習則では、未知 AI に内包される GMM から都度ランダムにデータをサンプリングし、学習データの分布との差異を近似的に算出する。この差異を分布形状の誤差として定義し、最小化することで、未知 AI 内部の GMM からサンプリングされるデータの分布が学習データの分布に徐々に近づいていく。このエ



図 4-1: MNIST のデータ例






図 4-2: 利用した未知 AI のネットワーク構造



(a) 学習対象クラスをランダムに変更した交差検証における各ケースの分類精度



(b) 未知クラスに対する判別精度（異常検知精度）の平均
値図 4-3: MNIST データセットに対する分類性能

エネルギー関数に基づく学習則を導入することで、“学習データの分布形状と未知 AI 内部の GMM の一致”を担保できるように、従来の“学習時に分布パラメータが変化しにくい”ことに起因する課題を一度に解消することが可能になる。実験では、提案法の有効性を検証するために、画像分類のベンチマークデータ (MNIST) の分類に新たな学習則を導入した未知 AI を適用した。

本実験では他の深層ニューラルネットと未知 AI の統合モデルの性能を評価するために、高次元データである手書き数字画像データである MNIST データセットを使用した。図 4-1 に MNIST データの一例を示す。訓練データ 60,000 枚のうち、学習クラスとして 6 クラスを設定し、その 1% に相当する 600 枚を使用して少数データ環境での性能を評価した。テストデータには学習クラス 6 クラスと未知クラス 4 クラスを含む 10,000 枚を用い、学習クラスと未知クラスの組み合わせを学習対象動作の組み合わせを変更した交差検証を実施した。また、ネットワーク構造は図 4-2 のようになっており、畳み込みニューラルネット

(CNN) から抽出された中間層特徴量を未知 AI に入力することで画像データに対するオープンセット認識を実現した。比較手法には分類誤差のみから学習された未知 AI (従来法)、OpenMax [4] と CNN を組み合わせたオープンセット認識手法を用いた。

図 4-3 に学習対象クラスをランダムに変更した各ケースにおける分類精度を示す。この結果から、すべてのケースにおいて提案法が優れた分類精度を実現しており、学習サンプルが限られるケースでもエネルギー関数に基づく学習が有効であることが示された。また、図 4-4 には交差検証から得られた適合度、再現度、AUROC (Area Under the ROC Curve) の平均値を示す。どの指標も異常検知の性能を表し、値が高い程、検知精度が優れていることを示している。提案法は他の手法と比較し、特に再現度が優れていることがわかる。これは学習クラスに誤識別される未知データが大幅に減ったことを表しており、新学習則によって未知 AI の分類結果の信頼性を向上させることができた。

上記の結果から、従来は困難だった深層ニューラルネットと未知 AI 結合した分類モデルの構築が可能になり、未知 AI の適用範囲のさらなる拡大が期待される。

3. まとめと今後の展望

令和 6 年度では、主に未知 AI 搭載型の健常者用義手の実証や、未知 AI の学習理論の改善、未知 AI の応用事例創出に取り組んできた。未知 AI 搭載型の健常者用義手の実証においては、未知 AI の推論ネットワークと学習アルゴリズムの両方を FPGA に搭載できることを確認できた。また、未知 AI の学習理論を改善したことで、未知 AI に内包される確率モデルと学習サンプルの分布が一致するように学習できるようになった。新しい学習則の導入は分類精度や妥当性の向上を実現するだけでなく、従来は困難だった既存の深層学習ライブラリの併用も可能にした。

今後は汎用性の向上した新しい未知 AI を各種異常検知、オープンセット認識問題に適用し、さらなる応用事例の創出に努める。また、FPGA 上に構築する未知 AI の演算リソースと分類精度の間発生するトレードオフの最適化や新しく開発した学習則の FPGA 搭載を通して、最終的にエッジコンピューティングに特化した未知 AI 搭載型ハードウェアを実現する。

【参考文献】

- [1] 横田知宏ら、“機械学習を用いたエンドミル加工のびびり振動判定”、2022 年度砥粒加工学会学術講演会 (ABTEC2022)、pp.345–346 (2022).
- [2] K.Cho *et al.*, “Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation,” Proceedings of EMNLP 2014, pp.1724–1734(2014).
- [3] D.Görür *et al.*, “Choice of the Base Distribution,” J.Comput.Sci.Technol.25, pp.653–664 (2010).
- [4] W.Grathwohl *et al.*, “Your classifier is secretly an energy based model and you should treat it like one,” arXiv preprint arXiv:1912.03263 (2017).
- [5] A.Bendale *et al.*, “Towards open set deep networks,” Proceedings of the IEEE conference on computer vision and pattern recognition (2016).

業績

【原著論文】

1. 柏木 僚太, 迎田 隆幸, 島 圭介, FPGA 実装を指向した未学習クラス推定混合ガウス型識別モデルと複合動作の識別, 計測自動制御学会論文集, 60 巻 6 号 p. 397-406, 2024 年

【総説】

なし

【書籍】

なし

【口頭発表】

〔国際会議〕

1. Ryota Kashiwagi, Takayuki Mukaeda, Keisuke Shima: FPGA Implementation of An Approximated Gaussian Mixture Open-Set Recognition Model Application to Interface Control, 2024 IEEE Int. Conf. on Control, Decision and Information Technologies (CoDIT 2024, 査読有り), 2024 年 7 月, マルタ島 (イタリア)
2. Ryota Kashiwagi, Takayuki Mukaeda, Keisuke Shima: EMG Control of Prosthetic Hand on FPGA with Approximate Gaussian Mixture Open-Set Recognition, JSME The 8th Int. Conf. on Advanced Mechatronics (ICAM 2024, 査読有り), 2024 年 11 月, 福岡県北九州市
3. Adwait Rawat, Takayuki Mukaeda, Keisuke Shima: Application of OSR for hardware accelerated intelligent manufacturing machines, Int. Symposium on System Integration 2025 (SII 2025, 査読有り), 2025 年 1 月, ミュンヘン (ドイツ)

〔国内会議〕

4. 齋藤 凜, 柏木 僚太, 迎田 隆幸, 島 圭介: 関節インピーダンス制御を可能とするワイヤ駆動型指機構の設計, 第 25 回計測自動制御学会システムインテグレーション部門講演会 (SI 2024), 2024 年 12 月, 岩手県盛岡市
5. 北原 丈大, 柏木 僚太, 迎田 隆幸, 島 圭介: Energy-based model を導入した学習則による未知クラス推定確率ニューラルネットの最適化, 情報処理学会 第 87 回全国大会 (IPSJ 2025), 2025 年 3 月, 大阪府茨木市

【特許】

- (1)国内特許出願 0 件