

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、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




図 1：未知 AI 未知を知る AI 搭載型筋電義手

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。

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。また、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）のプロトタイプ（図 1）の作成に至っている。

本稿では令和 7 年度の成果として、未知を知る AI の理論拡張、ならびに応用事例の創出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. 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

パターン識別問題においては学習時に想定しない未知クラスのサンプルは異常値として扱われ、未知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知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、未知クラスの内部構造推定は実運用上、必要不可欠となる。

令和6年度までにディリクレ過程混合正規分布(DPGMM) [1]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。特に、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)という課題の解消に取り組み、CRP による大域的な構造推定と棒折り過程 (SBP: Stick Breaking Process) による詳細構造の獲得を組み合わせた新たな学習則を提案してきた。昨年度は未知から知識を得ながら動的に AI 構造を適応・再構築する方法論を実装した筋電義手制御システムの構築を試み、詳細構造を取得するための SBP+GMM の学習則について再検討も行った。

まず、SBP+GMM に対する学習則についての再検討結果について述べる。これまでは CRP と SBP の両方においてもクラシカルなギブスサンプリングを採用していたが、SBP では変分ベイズ法による学習則 [5]も存在する。変分ベイズ法では事後分布からパラメータをサンプリングせず、変分下限 (ELBO) を最大化するように各パラメータの最適化を実施するもので、集中パラメータ (コンポーネントの発生しやすさ) とコンポーネント数の上限数を定めることで、より高速かつ安定的な学習が可能となる。

ギブスサンプリングによる CRP と変分ベイズ法による SBP を組み合わせた提案法の性能を評価するために、複雑な2次元データに対する教師なし学習を実施した。図2に各手法による人工データのクラスタリング結果と得られた GMM の例を、図3に交差検証を行った際の平均尤度に関する比較結果を示す。これらの結果から、CRP+SBP (変分ベイズ法) を適用した場合に最も高い尤度を記録し、適当な数の正規分布で各クラスタのデータ分布を表現できていることが確認できる。ただ、一部のクラスタ (オレンジや赤) では、過剰にコンポーネントが設定されていることが目視で確認でき、SBP の集中パラメータについても学習対象に設定すべきであることも示された。

2.2. 未知クラス推定確率ニューラルネットのライブラリ化

未知 AI は学習クラスに対応する正規分布と未知クラス




図2: 人工データに対するクラスタリング結果




図3:各学習法に対する交差検証尤度の比較

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。また、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 (Energy-based model (EBM) [2,3]) 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してきた。

昨年度は未知クラス推定確率ニューラルネットの学習則を改良し、ネットワーク構造とともにライブラリ化することで、既存の深層学習ライブラリの枠組みの中での運用を可能にした。また、ライブラリ化の過程で誤差逆伝播演算を改良し、従来と同等の学習時間で優れた識別領域を獲得することを実現した。

学習則をライブラリ化する上で特に重要な点は、統計的制約機構の簡素化とサンプリング演算の高速化の2つである。まず、前述したように本手法で学習対象となる重み係数 $w_{k,m}$, $w_{\epsilon}^{(k,m)}$ は共分散行列などに由来する統計的制約が含まれており、それらを担保した学習を行う必要がある。L2 正則化などとは異なり、より厳密な値域の制限が必要となるため、提案法では対応する重み係数を

$$w = \text{sigmoid}(r) = \frac{1}{1 + \exp(-r)} \quad \dots (1)$$

$$w = A \tanh(r) = A \cdot \frac{\exp(r) - \exp(-r)}{\exp(r) + \exp(-r)} \quad \dots (2)$$

$$w = \text{softplus}(r) = \log[1 + \exp(r)] \quad \dots (3)$$

と再定義した．ここで，式 1 は値域を 0 から 1 までに，式 2 は値域を $-A$ から A までに，式 3 は値域を正に制限する機能を有する．自動微分機能を使用し，置換変数 r に対する微分を算出するよう実装すれば容易に統計的制約の担保が可能となる．

次に，EBM に関する評価値 $\mathcal{L}_{\text{JEBM}}$ を算出する際に必要となるサンプリング操作の高速化を行った．提案法では， $\mathbf{z} = \mathcal{N}(\mathbf{0}, \mathbf{I})$ となる標準正規乱数を変換し，任意の疑似データ $\tilde{\mathbf{x}} = \mathcal{N}(\boldsymbol{\mu}_{k,m}, \boldsymbol{\Sigma}_{k,m})$ を生成する．また， $\mathbf{w}_{k,m}$ の要素を並び替えるだけで抽出できる精度行列 $\mathbf{S}_{k,m} = \boldsymbol{\Sigma}_{k,m}^{-1}$ ，および $\mathbf{v}_{k,m} = \mathbf{S}_{k,m} \boldsymbol{\mu}_{k,m}$ を利用し， $\mathbf{z}$ と $\tilde{\mathbf{x}}$ の関係性を記述すると次式のようになる．

$$\tilde{\mathbf{x}} = (\sigma^{-1})^T (\mathbf{z} + \sigma^{-1} \mathbf{v}_{k,m})$$

ここで， σ^{-1} は $\mathbf{S}_{k,m}$ を Cholesky 分解して得られる下三角行列である．上記の式を使用すれば，統計的なパラメータの可逆抽出処理なしに， $\mathbf{w}_{k,m}$ を使用した行列演算によって高速なサンプリングを実現できる．ここまで述べた操作も含め，繰り返し処理 (for 文) や条件分岐 (if 文) をほとんど使用しないようコーディングを実施し，学習速度低下を抑制したカスタムレイヤ (MATLAB 版) を作成した．

【検証 1：人工データ分類】 まず，提案法の基礎的な有効性を確認するために，GMM から生成した 2 次元データに対する OSR を MATLAB 上で実施した．生成時には 8 個の学習対象クラス (GMM) を設定し，コンポーネント数を $M_k = 6$ とした各 GMM から 500 個 / class の学習データを生成した．また，提案法において $M_k = 3$ ，あるいは $M_k = 8$ ($k = 1, \dots, 8$) とした条件で学習を実施した．比較対象として， $\mathcal{L}_{\text{JEBM}}$ の算出，ならびにサンプリングを行わない条件での従来法と同様の学習 ($M_k = 8$) も実施した．両条件で重み係数の初期化には k -means 法を使用した．図 4 に生成した学習データ (2 次元) を示す．

まず，提案法と従来法の各条件で獲得した識別領域と内包される GMM からサンプリングしたデータを図 3 に示す．図 5 (a) は $M_k = 3$ とした提案法，(b) は $M_k = 8$ とした提案法，(c) は $M_k = 8$ とした従来法のもので，図中の濃紺部分は未知クラスに分類される領域を，それ以外は各学習対象クラスに分類される領域を表している．結果から，提案法ではどちらの場合でも適当な識別領域を獲得できており，分類精度もそれぞれ 0.90 ± 0.06 ($M_k = 3$)， 0.91 ± 0.05 ($M_k = 8$) と高い分類精度を記録している．一方，従来法でも 0.92 ± 0.05 という高い分類精度を記録したものの，必要以上に学習対象クラスの識別領域が拡大していることが確認できる．加えて，サンプリング結果を見ても，提案法の方が正しく学習サンプルの分布を獲得できていることがわかる．

【検証 2：前腕動作分類】 図 6 に実施動作を表す．実施動作は 22 種類で，手首動作は掌屈(E1)，背屈(E2)，撓屈(E3)，尺屈(E4)，回内(E5)，回外(E6) の 6 動作，手指動作は E7-







図 4：GMM から生成した人工データ



(a) 提案法 ($M_k = 3$) の識別領域とサンプリング結果



(b) 提案法 ($M_k = 8$) の識別領域とサンプリング結果



(c) 従来法 ($M_k = 8$) の識別領域とサンプリング結果

図 5：各条件における学習結果の可視化

22 の 16 動作とした．電極数は 4 対で，示指伸筋，尺側手根屈筋，指伸筋，長掌筋に貼付した．各動作の実施時間は 10 秒 (サンプリング周波数：100 Hz) で，全動作を 3 回ずつ実施した．提案法のコンポーネント数は 3 個として，2 試行分 (E1-6) は学習データに，残りの 1 試行分をテストデータとして使用した．

図 7 にテストデータに対する混同行列を示す．また，適合率 (Precision)，再現率 (Recall)，F1-score の平均値はそれぞれ 0.91 ± 0.05 ， 0.72 ± 0.21 ， 0.79 ± 0.13 となった．結果から，提案法によって学習対象動作は正しく分類された一方，大量に存在する未知動作の一部が学習対象クラスに誤分類されたことが確認できる．これは，提案法が学習対象動作の EMG 分布を正しく獲得できたこと，学習対象動




図 6：実施した前腕・手指動作（22 種）

		提案法の分類結果						
		E1	E2	E3	E4	E5	E6	未知
ラベル 教師（正解）	E1	2011				186		17
	E2		1980			1	19	61
	E3	13		1784		9		244
	E4	2	50		1786		135	102
	E5	28				1911		101
	E6		24			1	1888	
	未知	1053		190	2135	815	2012	28672

図 7：提案法の分類結果（混同行列）

作と同様の EMG パターンを有する未知動作が複数存在することが示している。分類結果を詳細に分析すると、E7 が回内（E5）に、E18 と E20 が掌屈（E1）に、E22 が掌屈（E4）に誤分類されていて、EMG センサの貼付位置の変更やセンサ追加によって分離性能を向上させるための指針を得ることができる。以上の結果より、提案法の有用性が示された。

2.3. 福祉応用：爪郭部毛細血管画像の評価に基づく疾病検知システムの開発

神奈川県取り組みとして未病改善が健康づくりの柱として設定されている。未病の中でもサルコペニア（筋減少症）は加齢により筋肉量・筋力が低下し、要介護リスクが高まる「未病（病気ではないが健康でもない状態）」の代表的な病態の 1 つで、サルコペニアに対する予防措置・早期介入の重要性が指摘されている。一方、サルコペニアのスクリーニング・診断指標（SARC-F、下腿周囲長など）は筋萎縮や筋力低下がすでに顕在化した段階での評価にとどまっており、「サルコペニア発症前の前兆」を捉える信頼性の高いバイオマーカーの確立には至っていない。そこで本年度では、新たなバイオマーカーとして爪郭部毛細血管（NFC）[4]に着目し、広島県立大学の研究グループとともに新たな未病検知手法に開発に取り組んだ。




図 8：爪郭部毛細血管画像の例




図 9：健常な SFC 画像に対する検出結果例

図 8 に示される爪郭部毛細血管（NFC）は、爪の根元（爪郭部）に存在する毛細血管である。体の内部から表皮方向に発達する一般的な毛細血管とは異なり、NFC は爪の根元から指先に向けて発達する血管で、毛細血管形状の観察が容易であるという特徴を有する。従来研究 [5]では毛細血管の退縮が分子レベルで示され、NFC に対する異常評価の重要性は非常に高い。また、サルコペニアだけでなく、糖尿病などの様々な疾患に対する応用可能性が指摘されており[6, 7]、未知 AI の応用先として非常に適している。

本年度の検討では、小型顕微鏡を利用した非侵襲かつ、安価、容易な未病評価システムを構築するべく、まず NFC 画像から特徴量抽出法の検討を実施した。提案法では、従来研究 [7]で示される毛細血管の解析項目の中でも毛細管の密度、ねじれの有無を自動的に抽出する。特徴抽出のフローは、①先端部にある解析対象の毛細血管のみを検出し、②検出された領域内での血管領域を推定、③検知された血管領域からパスを抽出⇒ねじれの有無を判定するというものである。

まず、①の毛細血管の検出手法について検証を行った。今回の検討では、研究の初期段階ということもあり、ラベル付きデータが少量しか存在しなかったため、提案法の検出手法として、2 種類のオブジェクト認識モデル：Ultralytics 社の YOLOv11-seg と Meta 社の SAM を選定した。YOLOv11-seg については少量のラベル付き SFC 画像でファインチューニングしたものを利用し、モデルが巨大な SAM については調整なしに適用する。図 9 に健常な SFC 画像に対する毛細血管の検出結果例を示す。この結果から、汎用的なモデルである SAM では通常の学習データに含まれないであろう毛細血管を正しく認識できておらず、ファインチューニングを施した YOLO では概ね解析対象血管を検出できていることがわかる。また、図 10 に示される悪条件化での検出結果を見ても、YOLO の方が比較的高い検出精度を記録しており、実験全体を通してファインチューニングの重要性が強く示された。

次の②血管領域の推定では、検出された血管フレーム内での血管領域がどこか、セグメンテーションを実施した。正解ラベルに対するセグメンテーションの精度（IoU: Intersection over Union）は、YOLO と SAM でそれぞれ、約 0.55 と約 0.25（全血管に対して）、両方とも約 0.65（正し




図 10：悪条件下での検出結果例




図 11：ねじれ検出の結果例

く検出できた血管のみに対して)となった。いずれの場合においても、①の段階でどれだけ正しく血管を検出できたか、という要素が支配的で、正しく検出できた血管の領域推定性能に大きな差はなかった。

最後に、③のねじれ検出結果については、YOLO と SAM でそれぞれの Accuracy (検出精度) が、0.6 と 0.2 程度となった。どちらの手法でも十分実用的な検出精度には至らなかったものの、この結果でもファインチューニングの有効性が示された。SAM で検出精度が低下した要因として、血管領域の推定結果が強く影響したことが推察される。図 11 にねじれ検出結果の成功例と失敗例を示す。この例から、SAM では血管の隙間の背景領域まで塗りつぶされており、血管のパスおよびその閉路が正しく認識しにくいものになっている。一方、YOLO の背景が正しく抜かれている場合では、閉路(ねじれ)を正しく認識できている。

以上の結果より、提案法によってラフなラベリングは可能なものの、正しい血管領域がラベリングされた学習データによるさらなるファインチューニングが必要不可欠であることが示された。

3. まとめと今後の展望

令和 7 年度では、前年度開発した未知 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 の応用事例創出に継続的に取り組んできた。

まず、動的に構造を再構成する未知 AI の学習理論を改良し、従来法より詳細かつ正確な分布形状および未知 AI 構造を獲得することが可能になった。提案法を筋電義手システムに適用した場合には、切断初期の筋電発揮が熟達していない状況でも制御信号として使用可能なクラスタの

抽出を実現できる。さらに、未知クラス推定確率ニューラルネットワークを深層学習における出力レイヤーとして捉え、MATLAB で利用可能な未知 AI 層を開発した。開発したライブラリは繰り返し処理 (for 文) や条件分岐 (if 文) をほとんど使用しないように設計されており、従来の実装法より高速な動作を期待できる。また、他の特徴抽出層やリカレント層と結合した学習が可能になり、未知 AI を様々なオープンセット認識タスクに適用可能になった。以上の基礎理論検討に加え、福祉分野への未知 AI 適用を目標に爪郭部毛細血管 (NFC) 画像に対する特徴抽出手法に関する検討を実施した。今回の検討では NFC 画像に含まれる毛細血管を個別に検出し、その形状異常を検知することを試みたが、学習データの少なさから形状異常の検知精度には課題が残る結果となった。

今後も未知を知る確率的 AI チップの産業・医療・福祉応用に関する検討を継続的に実施していき、事業化を見据えた共同研究の促進に取り組んでいく。特にウェアラブル計測デバイスとの統合による未病評価システムや、化学プラントや工作機械の中で運用可能な異常検知システムの開発・実現を試みる。また、様々な応用事例を創出する上で、学習データに対するアノテーションコストの高さが大きな課題となっており、ラベル無しデータを活用した半教師あり自動アノテーション手法の研究にも取り組んでいく。

【参考文献】

- [1] D. Görür *et al.*, “Dirichlet Process Gaussian Mixture Models: Choice of the Base Distribution,” *Journal of Computer Science and Technology*, 25, 653–664 (2010).
- [2] 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).
- [3] Y. LeCun *et al.*, “A tutorial on energy-based learning.” *Predicting structured data*, 1(0) (2006).
- [4] E. H. Serné *et al.*, “Microvascular function relates to insulin sensitivity and blood pressure in normal subjects,” *Circulation*, 99(7):896-902 (1999).
- [5] J. Chen *et al.*, “High-resolution 3D imaging uncovers organ-specific vascular control of tissue aging,” *Science Advances*, Vol. 7, No. 6, eabd7819 (2021).
- [6] G. Maldonado *et al.*, “Nailfold capillaroscopy in diabetes mellitus,” *Microvasc Res*, 112:41-46 (2017).
- [7] J. Ciaffi *et al.*, “Nailfold capillaroscopy in common non-rheumatic conditions: A systematic review and applications for clinical practice,” *Microvasc*, 131:104036 (2020).

業績

【原著論文】

なし

【総説】

なし

【書籍】

なし

【口頭発表】

〔国際会議〕

1. Sougo Horimatsu, Kensuke Takenaka, Takayuki Mukaeda and Keisuke Shima: Estimating Wrist Joint Angle using Electromyography and Cepstral Coefficients, The 2026 IEEE/SICE International Symposium on System Integration (SII 2026, 査読あり), 2026 年 1 月, カンクン (メキシコ)

〔国内会議〕

2. 柏木僚太, 迎田隆幸, 島圭介: FPGA 実装された近似 GMM 型オープンセット認識手法による筋電義手制御システム, 第 43 回日本ロボット学会学術講演会 (RSJ2025), 2025 年 9 月, 東京都目黒区
3. 迎田隆幸, 柏木僚太, 三苫凌, 北原丈大, 島圭介: 未知クラス推定確率ニューラルネットのライブラリ化と前腕動作分類への適用, 第 30 回知能メカトロニクスワークショップ (iMec2025), 2025 年 9 月, 北海道札幌市
4. 南部穰汰, 迎田隆幸, 柏木僚太, 島圭介: 並列棒折り過程を導入した対数線形化 IGMM による筋電義手インタフェース, インテリジェント・システム・シンポジウム 2025 (FAN2025), 2025 年 9 月, 愛知県長久手市
5. 長濱和輝, 三苫凌, 迎田隆幸, 金指美帆, 島圭介, 島谷康司: 爪郭部の毛細血管異常の簡易評価に関する基礎的検討, 第 26 回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 (SI2025), 2025 年 12 月, 広島県広島市
6. 三苫凌, 迎田隆幸, 島圭介: Data Shapley 理論に基づくアンサンブル型疑似ラベル推定法, 情報処理学会 第 88 回全国大会 (IPSJ 2026), 2026 年 3 月, 愛媛県松山市

【特許】

- (1)国内特許出願 0 件