

博士論文審査結果報告書

論 文 題 目

複合型学習と脳の機能局在性を
考慮したニューラルネットワーク
に関する研究

申 請 者
笹川 隆史

情報生産システム工学専攻
ニューロコンピューティング研究

2011 年 2 月

人間の脳は極めて優れた情報処理装置であり、脳の巧妙な仕組みを知ることと利用することが非常に重要となっている。脳の高度な情報処理は、多数のニューロン（脳の神経細胞）が互いに結びついて、情報のやりとりをすることによって実現される。このような脳の構造や働きを模倣して開発された技術に、人工ニューラルネットワーク（Artificial Neural Network: ANN）がある。ANNには学習能力の他に非線形近似能力や処理の並列性といった特徴があり、工学上広く利用されている。しかしながら、一般的な ANN は脳機能に見られるいくつかの特性を実現している単純なモデルであり、神経科学の新しい知見を取り入れ、より脳に近い脳モデルを目指すことによって、ANN の性能の向上が期待できる。

本研究の目的は、一般的な ANN には取り入れられていない脳の機能や構造に関する知見を参考にすることによって、ANN の性能を向上させることである。本論文では2つの知見を参考にしている。1つは「脳の機能局在」、もう1つは「脳の部位と学習方式の関係」に関する知見である。

脳の機能局在とは、脳内の特定の部位が特定の機能を担うというモジュール的構造のことである。脳内では、ひとつの課題を複数の部分課題に分解して処理することによって、効率的に課題を解決していると考えられている。一方、一般的な ANN はネットワーク全体で1つの機能を形成する。したがって、ANN に機能局在型の構造を導入することによって、処理の効率化が期待できる。

脳の部位と学習方式に関しては、小脳は教師あり学習、大脳皮質は教師なし学習、大脳基底核は強化学習に特化していることが示唆されている。脳内では、これらの異なる学習方法が適切に組み合わせられて使用されており、それによって我々は高度な情報処理を実現していると考えられる。したがって、異なる学習方式を複合することによって、ANN の情報処理能力の向上が期待できる。

上述の背景・目的を踏まえ、本論文では、脳に関する知見を考慮した ANN アーキテクチャとして、自己組織化機能局在型ニューラルネットワーク（Self-Organizing Function Localization Neural Network: SOFLNN）と、教師あり学習・教師なし学習・強化学習を複合した学習システムを提案・構築している。また、SOFLNN の学習が局所解に陥りやすい問題があり、その対策として、SOFLNN の構造的特徴を利用した訓練方法を提案している。

以下に、本論文の構成と各章の概略と評価を述べる。

第1章は序論であり、ANN および、本研究で参考にしている2つの脳の知見について述べ、本研究の背景・目的を明らかにしている。

第2章では、SOFLNN の提案・構築について述べている。脳の基本的な働きについての2つの理論がヘップ（Hebb, 1949）によって提唱されている。1つはヘップの学習則、もう1つはセルアセンブリ（Cell Assembly）として知られる理論である。脳内のニューロンはヘップの学習則によって様々な回路を形成する。形成された回路はそれぞれが独立しているのではなく、複数の回路に重複したニューロンも存在する。そして、脳は受け取る情報に応じて特定回路

のニューロン群のみを活動させる。さらに、入力情報に応じて機能的シナプス結合の変化により回路自体が動的に変化している。本論文では、このようなセルアセンブリ仮説を参考にして、複数の回路のニューロン群を複数個のモジュールと想定して、「入力と特定のモジュールとの関連性」や「モジュールのオーバーラップ」などの動的な特徴を持った SOFLNN を構築している。SOFLNN の構成は、課題を解くためのメイン部と、機能局在化を実現するための制御部の階層的 2 部構成となっている。メイン部は、一般的な階層型 ANN と同様の構造を持つが、中間層ユニットの出力が制御部からの信号によって制御される。制御部は、自己組織化マップ (Self-Organizing Maps: SOM) ネットワークと制御信号生成器で構成される。SOM ネットワークは、出力層ユニットがメイン部の中間層ユニットと 1 対 1 で対応した構造を持ち、課題の分割と部分課題の選択を行う。信号生成器は、部分課題に応じてモジュールを制御するための信号を生成する。これによって、メイン部に、オーバーラップを有する複数個のモジュールネットワークが構成され、機能局在性を実現している。性能評価では、Two nested spirals 問題をベンチマークとして用いて、SOFLNN と同じネットワークサイズの一般的な ANN の表現能力と比較している。中間層ユニット数が 9 個の場合において二乗和誤差の最小値を比較した結果、二乗和誤差が制御信号のパラメータ値を適切に設定した SOFLNN では 0.51、3 層階層型 ANN では 7.41 となり、機能局在化によって ANN の表現能力が向上したことを明らかにしている。

第 3 章「教師あり学習・教師なし学習・強化学習を複合した brain-like 学習システム」では、異なる学習方式を複合することによって、課題が解けるだけでなく、システムの性能が自動的に最適化できる ANN アーキテクチャを提案している。提案システムは次のような 3 部構成になっている。教師あり学習により訓練される Supervised Learning (SL) part は、課題を解くための主要な部位である。教師なし学習により訓練される Unsupervised Learning (UL) part は、課題を分割して解きやすくするための部位である。強化学習によって訓練される Reinforcement Learning (RL) part は、試行錯誤学習によってシステムの性能を最適化するための部位である。本論文の SL part および UL part は、SOFLNN のメイン部と制御部をそれぞれ利用して実現されている。RL part では、具体的には、UL part における制御信号を求めるためのパラメータ値を最適化している。これは、SOFLNN の訓練には局所解の問題があるため、最適な制御信号を得るためには試行錯誤による探索が必要だからである。なお、RL part における学習は、提案システムの実現を単純化するために、完全な形の強化学習ではなく、強化比較と呼ばれる手法を採用している。性能評価では、第 2 章と同じベンチマークを用いて、提案システムの性能最適化能力について検証している。SL part の中間層ユニット数が 10 個の場合において、制御信号のパラメータ値をランダムに設定した場合と比較して、制御信号の最適値を学習した提案システムは、訓練の成功率が約 2 倍になり、提案システムの性能最適

化が適切に行われたことを明らかにしている。

第 4 章では、SOFLNN の訓練が局所解に陥りやすいという問題を軽減するために、「能動的な訓練」および「受動的な訓練」という 2 つの訓練方法を提案している。訓練が局所解に陥る要因として、一部のモジュールの訓練がうまくいっていない傾向が見られたが、SOFLNN はモジュールがオーバーラップしている構造上、個別にモジュールを訓練することは有効ではない。この問題に対し、本論文ではモジュールごとの誤差の分散（モジュール誤差分散）に着目している。つまり、訓練中のモジュール誤差分散が大きい場合は、局所解に陥る可能性が高いと考えられる。能動的な訓練は、二乗和誤差にペナルティ項としてモジュール誤差分散の項を付加することで、訓練中のモジュール誤差分散を抑制する訓練方法である。受動的な訓練は、訓練中のモジュール誤差分散を指標として、訓練が局所解に陥る可能性を早期に診断し、陥りそうなら脱出処理に移行する訓練方法である。性能評価には、これまでと同じベンチマークを用いている。通常の訓練と能動的な訓練の二乗和誤差を比較した結果、中間層ユニットが 10 個の場合において、通常の訓練の最小値および平均値がそれぞれ 1.93、4.11 であるのに対して、能動的な訓練の最小値および平均値が 0.88、3.31 と改善されている。通常の訓練と受動的な訓練の比較では、中間層ユニットが 9 個の場合において、通常の訓練の二乗和誤差の平均値が 4.26、訓練成功率が 3% に対し、受動的な訓練の誤差平均値は 3.01、成功率は 18% と改善されている。これにより、局所解問題に対する 2 つの提案した訓練方法の効果が明らかにされている。

第 5 章は結論として、本研究の成果について総括し、今後の研究課題を論じている。

以上を要約すると、本研究は、①脳のセルアセンブリ仮説をモデル化し、複数個のモジュールネットワークを動的にオーバーラップさせることにより ANN の機能局在を実現する技術、②脳の機能局在をモデル化し、メイン部と制御部の階層構成により ANN を構築する技術、③小脳、大脳皮質および大脳基底核における異なる学習モデルを統合し、ANN を知的に構築するための教師あり学習、教師なし学習および強化学習からなる brain-like 学習技術を開発し、シミュレーション実験によりその有効性を確認している。これらはニューロコンピューティング、計算論的神経科学分野に寄与するところ大である。よって、本論文は、博士（工学）の学位論文として価値あるものと認める。

2011 年 1 月 13 日

審査員

主査	早稲田大学	教授	博士(情報工学)(九州工業大学)	古月 敬之
副査	早稲田大学	教授	工学博士（九州大学）	平澤 宏太郎
	早稲田大学	教授	工学博士（早稲田大学）	吉江 修