

機能を融合する発達型人工神経回路網構築への取り組み

理学専攻・情報科学コース
2240642
岩井 遥

1 はじめに

従来のディープラーニングのファインチューニングや転移学習においては、タスクを解決するために転移される機能は単一の目的とするタスクに類似したものである。この背景を踏まえて本研究は、ネットワークの結合荷重ではなくトポロジーを進化的に獲得する手法を用いて、個別の問題解決機能を学習したニューラルネットワークを融合し、複数機能の転移学習が可能な新しいニューラルネットワークアーキテクチャの構築を目指す。研究1では、ロボット制御タスクについて、目的の高次元の動作を行うネットワークの入力と、既に学習済みの基底動作の構造を接続し、係数のノードを介して基底動作の出力と目的動作のネットワークの出力を結ぶ。研究2においては画像分類タスクを対象として、WANNによって得られたトポロジーを行列表現に変換し、変分自己符号化器の入力とする。モデル1では構文木との間でエンコード・デコードを行うVAEを参考として、生成規則によって行列表現に変換した。モデル2ではモデル1からデータ効率を改善するため、グラフ畳み込みを利用した。

2 提案手法

本研究では特定機能を持つネットワーク構造を融合したネットワーク構造を初期値とすることで、複数機能を組み合わせ合わせた新規機能の学習効率の改善を目標とするものである。本章では提案手法の概要を順に説明する。

2.1 特定機能を持つネットワークの獲得

Weight Agnostic Neural Networks (WANN) [1] は生物が生得的に有している行動知識を発達させていく過程を模して、ニューラルネットワークにおいて明示的な結合荷重の学習を行わずとも、与えられたタスクを遂行可能なネットワークトポロジーを遺伝的アルゴリズムおよび強化学習を用いて獲得する手法である。本研究では、このWANNを提案手法におけるニューラルネットワーク学習のための基盤技術として採用する。

2.2 研究1 - 機能の並列接続による新規機能の形成




図1: 研究1概要図

研究1の概要図を図1に示した。研究1では、目的とする高次元の動作を行うネットワークの入力と、既に学習済みの基底動作の構造と接続し係数のノードを介して基底動作の出力と目的動作のネットワークの出力を結ぶ。このネットワークをさらに発達させ、基底動作の構造を一部として持つ高次機能を実現するネットワーク構造を獲得する。

2.3 研究2 - 複数機能を転移する変分自己符号化器




図2: 研究2概要図

研究2の概要図を図2に示した。研究2では各機能ネットワークの行列表現を Variational Autoencoder の入力とすることで、多機能潜在空間へ圧縮し、この潜在空間からネットワーク構造へ復元する。これによって複数の機能が融合されることで新しい機能が顕現する、機能の階層性をともなう知識の発達を実現する人工神経回路網を構築する。

モデル1 ニューラルネットワークの構造という離散データの解析を行うにあたり、構文木の間でエンコード・デコードを行う Grammar Variational Autoencoder (GVAE) [2] の手法を基礎としている。本研究ではニューラルネットワーク構造を扱うため、まずニューラルネットワーク構造を活性化関数を要素に含む生成規則で表現し、この一連の生成規則をベクトル表現にすることでグラフ全体の行列表現とする。

モデル2 本モデルにおいては、ニューラルネットワークの構造を有向グラフと捉え、グラフ畳み込み [3] レイヤーを用いてノードの埋め込み表現を獲得し、そのノードの埋め込み表現を次元削減をすることでグラフ全体の埋め込み表現を得る。

3 実験

3.1 研究1 - 機能の並列接続による新規機能の形成

実験設定 この実験では、大きく前方に飛んで進む動作 (jump forward) を獲得対象の高次機能動作とした。低次機能の動作とみなす学習済みの walk と jump の NN を組み合わせて作成したネットワークと、同じサイズのランダムに生成したネットワーク 300 個の jump forward における精度を比較する。ネットワークを融合する際の重み係数には、WANN の 6 種の共通結合荷重の内それぞれのタスクにおいて最も精度の高かった値を用いた。ランダム生成のネットワークは、合成ネットワークと同数のノード数を有し、エッジも同程度の数になるよう確率で無作為に接続した。いずれのネットワークも WANN を用いた構造学習のみを行い、結合荷重については未学習のものを使用した。

結果 300 個の合成ネットワークのうち、137 個が合成ネットワークを上回る評価となった。この 300 個のネットワークの評価の分布を図3に示した。図中の黒破線は合成ネットワークでのスコアである。ランダム生成ネットワークの約4割が合成ネットワークよりも評価が高くなる結果となった。これは高次機能の低次機能での表現において表現が十分ではないこと、また、

高次機能と低次機能の組み合わせにおいても再検討の必要があることを示唆していると考える。

3.2 研究 2 - 複数機能を転移する変分自己符号化器

3.2.1 手法 1 - 接続規則を用いた手法

本研究では、GVAE に倣い生成規則の表現に 1-hot ベクトルを用いたモデル 1 と、計算量の削減を目的として埋め込み表現を用いたモデル 2 の比較を行う。ここで、生成規則の埋め込み表現の獲得には、Word2Vec[4] の Skip-gram model を参考に行っている。今実験では各モデルごとに潜在表現の表現能力が復元された個体に与える影響を検証するため、潜在表現のベクトル長を 2,3,10,100,400 の 5 種類に変化させて性能を比較した。

実験設定 色の分類と数字の分類の二種類の画像分類タスクについて WANN で個別に 960 個体ずつ学習を行い、これを入力として潜在空間を構築した。ここで、色の分類は赤・青・緑の 3 色で描かれた図形の画像データセット [5] を入力とし赤・青・緑のいずれかに分類するタスク (Multi Color) であり、数字の分類は手書きの 0-9 の数字の画像データセット [6] を入力とし 0 から 9 のいずれかに分類するタスク (MNIST) である。この潜在空間上において、入力としたネットワークの潜在表現を各タスクごとに平均しこれを重心とした。一方のタスクの重心から他方のタスクの重心を結んだ区間に等間隔に並んだ 16 の点から個体を復元し、その精度を計測した。ここで、色の分類と数字の分類の要素を分類した色付き数字の分類タスク (Colored MNIST) においても評価した。




図 3: 合成ネットワークの評価分布




図 4: 生成規則のベクトル表現方法別の精度比較

結果 実験結果を図 4 に示した。図中橙色で示した箱ひげ図が 1-Hot 表現を用いた行列表現を入力とした場合の結果であり、緑色で示した箱ひげ図が埋め込みを用いた行列表現を入力とした場合の結果である。埋め込みを用いたモデルはベクトル長の影響を大きく受けているのに対し、1-Hot 表現を用いたモデルはほとんど影響を受けておらず、いずれのベクトル長においても性能が同じような値域にある。また、多くの場合においてその性能の最大値は埋め込み表現を用いたモデルの方が優れている。このことから、埋め込み表現を用いたモデルの方が、その潜在表現のタスクにおけるパフォーマンスと良い対応関係が存在するのではないかと考える。これらの結果の違いは VAE に入力するデータの効率によるものと考え、モデル 2 においてさらなる計算効率の向上を目指した。

3.2.2 手法 2 - グラフ畳み込みを用いた手法

今実験では、Inner Product Decoder[3] に加え、Gravity-inspired Graph Autoencoders [7] で提案され

た有向グラフに特化した Source Target Inner Product Decoder と Gravity-inspired Decoder の 3 種のデコーダを比較する。

実験設定 先の実験同様、色の分類と数字の分類の二種類の画像分類タスクについて学習した集団を入力として潜在空間を構築した。入力としたネットワーク集団が構築した潜在空間上でどの程度タスクごとに分かれて分布しているかの指標として、QR 分解に基づくスペクトラルクラスタリング手法 [8] を用いて、クラスタリングを行なった。クラスタリング結果の評価には Completeness スコア [9] を用いた。これは、正解データに対してモデルの予測がどの程度正確かを表す評価指標であり、[0, 1] の値をとり、1 に近いほどより正しく予測できているということを表す。

結果 結果を表 1 に示した。最もタスクごとに分かれたクラスタリング結果が得られたのは Gravity-inspired

表 1: クラスタリングスコア

Decoder	スコア
Inner Product	9.7e-3
Source Target	4.6e-2
Gravity-inspired	0.77

Decoder であった。これはこのデコーダを導入したモデルによって得られる分布が、他のデコーダのモデルで得られる分布に比べ、タスクごとにより分かれているためであり、よって本研究の提案手法に適しているのはこの Gravity-inspired Decoder を含むアーキテクチャであると考えられる。

4 まとめ

本研究では、既に獲得した機能のトポロジーから複数の機能を融合した新たな機能を持つ構造を獲得する発達型人工神経回路網の構築を提案した。研究 1 においては提示機能の構造を係数を介して高次機能の構造の部分として埋め込み、ランダム生成のネットワーク構造と性能の比較を行った。研究 2 においては、ネットワーク構造の数値表現を入力として VAE によってエンコードとデコードを行うとした。実験においては、融合の基礎となるネットワーク集団の性能が良い必要があること、またそのネットワーク集団の行列表現のデータ効率が重要であることがわかった。今後は Gravity-inspired Decoder を組み込んだモデルで作成した潜在空間と性能の対応について検証を行っていきたい。

参考文献

- [1] Adam Gaier and David Ha. Weight agnostic neural networks. 2019.
- [2] Matt J. Kusner, Brooks Paige, and José Miguel Hernández-Lobato. Grammar variational autoencoder, 2017.
- [3] M. Schlichtkrull, Thomas Kipf, Peter Bloem, Rianne van den Berg, Ivan Titov, and Max Welling. Modeling relational data with graph convolutional networks. 2017.
- [4] Tomas Mikolov, Ilya Sutskever, Kai Chen, Greg S Corrado, and Jeff Dean. Distributed representations of words and phrases and their compositionality. 2013.
- [5] AdityaDutt. Multicolor-shapes-database, 2021.
- [6] Li Deng. The mnist database of handwritten digit images for machine learning research. 2012.
- [7] Guillaume Salha, Stratis Limnios, Romain Hennequin, Viet-Anh Tran, and Michalis Vazirgiannis. Gravity-inspired graph autoencoders for directed link prediction. 2019.
- [8] Anil Damle, Victor Minden, and Lexing Ying. Simple, direct and efficient multi-way spectral clustering. 2018.
- [9] Andrew Rosenberg and Julia Hirschberg. V-measure: A conditional entropy-based external cluster evaluation measure. 2007.