

【研究区分：若手奨励研究】

研究テーマ：Teacher Student 型構造適応型深層学習による逐次的再学習方法の提案	
研究代表者：地域基盤研究機構 特命講師 鎌田真	連絡先：skamada@pu-hiroshima.ac.jp
共同研究者：	
【研究概要】 近時、人工知能を活用した産業応用が期待されており、この中でも深層学習は非常に高い画像認識の能力を持つことで知られている。本研究では、入力データの特徴に応じて深層学習のネットワーク構造を自動で構築する構造適応型深層学習法を独自開発し、既存の手法より高い分類精度を示している。さらなる分類精度の改善のため、Teacher-Student (T/S)モデルの仕組みを用いて、未知なデータに対する構造適応型深層学習法の再学習モデルを開発した。顔表情画像の感情分類や動画データに適用したところ、既存の手法よりも高い分類性能が得られた。	

【研究内容・成果】

1. 研究内容

深層学習の技術は、データの背後に潜む規則性や特異性を発見することで、人間と同程度あるいはそれ以上の学習能力を実現している。過去の事例・観測データをもとに学習システムを構築し、モノやコトの判別・分類、物体検出、時系列予測、異常検知等の知的な判断を実現している。

本研究では、入力データに応じて最適なネットワーク構造を学習中に自動で求める構造適応型深層学習法を開発している。具体的には、RBM(Restricted Boltzmann Machine)を階層的に積み上げた DBN(Deep Belief Network)において、RBM の最適なニューロン数を学習中に決定する構造適応型 RBM(Adaptive RBM)と、事前学習した Adaptive RBM を積み上げることで、自動で階層構造を構築する構造適応型 DBN(Adaptive DBN)を開発した(図1)。開発した手法を複数の画像ベンチマークテストに適用したところ、既存の深層学習手法(CNN)よりも高い分類精度が得られた。さらに、長期的かつ短期的な時系列データの予測を可能とするため、LSTM(Long Short Term Memory)の考えを導入したリカレント構造適応型 DBNを開発し、時系列データの学習モデルを開発した。

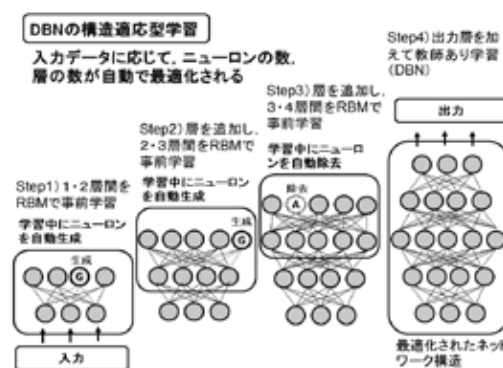


図1：構造適応型 DBN

2. IoT データに対する構造適応型深層学習の再学習法

開発した構造適応型深層学習法は未知なデータに対して高い分類精度は示しているものの、100%の精度までには至っていない。誤分類した事例を調査したところ、過学習(過度に学習しすぎる状態)ではなく、学習時には見られなかった特徴を持つデータが多く見られた。このような場合、一般的にはモデルを再構築するために未知なデータを訓練データに加え、再学習する必要がある。IoT等により時々刻々とデータが収集され続ける環境では、データを収集しながら、誤差が大きくなった場合、逐次的に再学習可能な手法が必要である。

市村の研究(JSPS 科研費, 19K12142)では、Teacher-Student(T/S)モデルの仕組みを用いた、未知なデータに対する構造適応型深層学習法の逐次的再学習モデルに関する研究が行われている。ここでは、画像分類に対して手法の評価が行われているが、本研究では、この考えをリカレント構造適応型 DBN に応用し、IoT等により収集される時系列データに対する有効性を検証した。

本研究では、時系列データとして、2010年から2020年までの広島市の毎日の平均気温データを使用した。このうち、最初の8年間を訓練データとし、残りの2年間をテストデータとした(図2)。7日間の気温データをリカレント構造適応型DBNに与え、次の日の気温を予測するように学習を行った。学習の結果、実測値と予測値の二乗和誤差は、訓練データに対して1.7、テストデータに対して10.4となった。テストデータに対して誤差が大きくなった理由は、訓練データには含まれていない特徴がテストデータに含まれていたことが原因だと考えられる。このため、市村の逐次的再学習モデルの考えを応用し、学習した親モデルに対して、誤差が大きくなったデータを子モデルで再学習し、子モデルで得られた特徴を親モデルに組み込むことで、精度の改善を試みた。このとき、モデル間の分布の違いを測定するためにKL情報量(Kullback-Leibler divergence)が使われ、また、与えられた入力に対する各層のニューロンの発火パターン(パス)を求め、ネットワーク全体のどこの部分で親モデルと子モデルが異なるのか調査した。親モデルにおいて不足しているニューロンを新たに生成し、再学習することで、テストデータの対する誤差が再学習前の10.4から2.1に改善できた。




図2：平均気温データ

3. 様々なデータに対する性能評価

上記の時系列データ以外にも、本手法を複数のベンチマークテストに適用し、手法の評価を行った。画像分類については、8種類の人間の感情と顔の表情画像の組が与えられている顔感情画像データベース Affect Net に適用した。特定の感情カテゴリについて再学習モデルを構築したところ、分類精度の改善が見られた。また、画像以外の多様なデータに対しても深層学習の適用が期待されていることから、動画ビッグデータ Moving MNIST への適用を試みた(JSPS 科研費, 19K24365)。Moving MNIST は、2つの数字が画像内をランダムに動く動画ベンチマークで、次の動きを90%以上の精度で予測が可能となり、既存の手法よりも高い予測性能を示した。得られた成果については、学会等で学術的な成果を発表するとともに[1,2]、ひろしま IT 総合展(2019年11月)等で発信し、産業界での有効性を示した。

4. 今後の課題

今後は、様々なビッグデータに対して開発した手法を検証し、精度の改良を行う。これまでの分析結果の中には、深層学習の出力結果を意図的に騙す敵対的事例(Adversarial Example)と考えられる事例が見つかっており、このようなデータが出現した場合でも適切に判別可能なシステムの開発が必要である。また、これまでは、単純な画像認識のように、1種類のデータを取り扱った学習モデルを構築したが、現実には、医療データのように、画像以外にも数値やテキストといった種類のデータもあり、これらが統合的に形成され、意味を成すマルチモーダルデータがある。今後は、このようなマルチモーダルデータに対する深層学習の学習法について研究を行う予定である。

[1] T.Ichimura and S.Kamada, "Re-learning of Child model for misclassified data by using KL Divergence in AffectNet: A Database for Facial Expression", Proc. of IEEE IWCI2019, pp.15-20 (2019)

[2] S.Kamada, T.Ichimura, "A Video Prediction Method by using Long Short Term Memory based Adaptive Structural Learning of Deep Belief Network and its Investigation of Input Sequence Length for Data Structure", Int. J. Computational Intelligence Studies (to appear in 2020)