

深層学習を用いたセンサベース行動認識における クラス拡張を用いた転移学習手法

近藤和真[†]福井大学大学院工学研究科[†]長谷川達人[‡]福井大学大学院工学研究科[‡]

1 はじめに

転移学習は深層学習を用いたセンサベース行動認識において挑戦的な課題である。センサベース行動認識では、画像認識における ImageNet のように、データ数やクラス数の多いオープンデータセットは提供されていない。そのため、既存研究では、ターゲットタスクに対して有効なソースタスクを選択して知識転移を行う転移学習手法が提案されている[1]。しかし、この手法は、ターゲットタスクに対して有効なソースタスクが存在しない場合、ターゲットタスクの性能を向上させることは難しい。そこで本研究では、ソースタスクの分類クラス数を拡張することで、ターゲットタスクの性能を向上させる転移学習手法を提案する。本研究は、ソースタスクから得られる知識の幅を広げ、様々なタスクに対して効果的な知識転移を行うことを目的としている。

2 提案手法

提案する転移手法は、クラス数を拡張したソースタスクで事前訓練したネットワークをターゲットタスクで微調整することにより、ソースタスクの知識をターゲットタスクへ伝達させる。分類クラスの拡張方法には様々なものが考えられるが、本稿では、メタ情報による拡張と Data Augmentation (DA) による拡張の2種類を示す。

2.1 メタ情報を用いたクラス拡張

メタ情報を用いたクラス拡張は分類クラスとメタ情報を組み合わせて行う拡張方法である。分類クラス集合を Y_{class} 、メタ情報集合を Y_{meta} とすると、

張分類クラス Y_{aug} は下式のように定義される。

$$Y_{aug} = Y_{class} \times Y_{meta} \quad (1)$$

つまり、メタ情報を用いたクラス拡張では、 Y_{class} と Y_{meta} の間のユニークな要素ペアを一つのラベルとして扱うことで分類クラスを拡張する。本研究では、被検者の性別とセンサの位置の2種類のメタ情報を用いる。

2.2 Data Augmentation を用いたクラス拡張

DA を用いたクラス拡張は、単一データを変換する DA 手法 (変換 DA) を用いる。変換 DA を用いたクラス拡張は、データに施された DA の種類をメタ情報とすることで、メタ情報を用いたクラス拡張と同様に定式化することができる。入力データ集合を X 、分類クラス集合を Y_{class} とする。そして、 X に対して K 種類の変換 $DA\{\phi_1, \phi_2, \dots, \phi_K\}$ をそれぞれ独立に施すことで、拡張データセット ($\tilde{X} = X \cup \bigcup_{i=1}^K \phi_i(X), Y$) と各データに施された変換 DA の種類を表すラベル集合を Y_{da} を得る。ここで、 Y_{da} をメタ情報として扱い、2.1 節と同様に拡張することで、クラス拡張されたデータセット (\tilde{X}, Y_{aug}) が得られる。本研究では、センサデータを時間軸に対して反転させる flipping とセンサデータのチャンネルを入れ替える swapping を変換 DA として用いている。

3 検証実験

3.1 実験設定

本研究では、転移学習を行わないベースライン (Scratch)、ソースタスクの分類クラスをそのまま利用する転移モデル Transfer(Plain)、提案手法を用いた転移モデル Transfer(CA)、変換 DA を予測する表現学習手法 Transfer(TPN)[2] を比較し提案手法の有効性を検証する。Transfer(TPN) は、変換 DA の種類のみを予測する分類タスクを用いて事前訓練を行う自己教師あり学習であり、行動ラベルを用いない

Deep Transfer Learning using Class Augmentation for Sensor-based Human Activity Recognition

[†] Kazuma Kondo, Graduate School of Engineering, University of Fukui

[‡] Tatsuhito Hasegawa, Graduate School of Engineering, University of Fukui

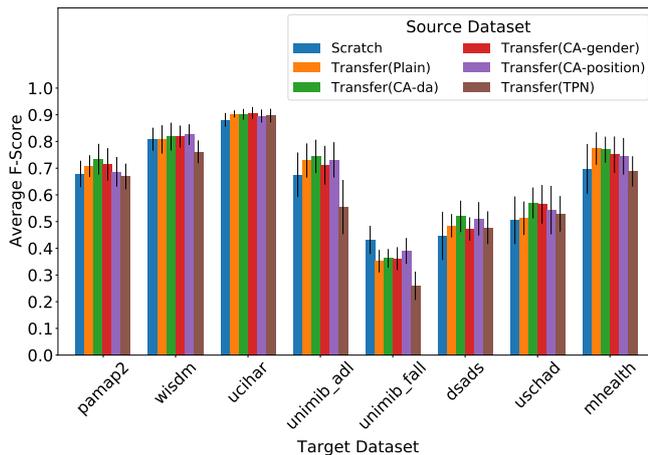


図1 各ターゲットデータセットに対する転移手法の比較結果

DA による Transfer(CA) に相当する。

転移モデルでは、HASC をソースとして利用し、各ターゲットごとにソースモデルのパラメータを作成する。これはターゲットによってサンプリング周波数が異なることに対応するためである。そして、訓練済みのソースモデルのパラメータを各ターゲットモデルに転送し、ターゲットタスクでモデル全体の再訓練を行う。本稿では、7種類のデータセットをターゲットとして利用し、各データセットの3軸加速度センサデータを検証に使用している。

検証では、既存研究で有効性が確認されている VGG 構造をベースとしたモデルを使用する。モデルの評価は被験者単位の Hold-out 法を用いて行い、評価に用いる指標は平均 F-Score とする。各モデルは、データセットの分割とモデルの訓練・評価を1試行として、10試行の平均で評価される。

3.2 実験結果

検証結果を図1に示す。図1では、unimib データセットを日常行動クラスで構成された unimib_adl と転倒クラスで構成された unimib_fall に分割して示している。まずこの結果から、unimib_fall 以外のすべてのターゲットタスクにおいて、Transfer(Plain) モデルは Scratch モデルよりも性能が向上している。特に、pamap2, unimib_adl, dsads, mhealth では、転移学習により大幅に性能が向上している。これらのターゲットタスクは、多様な行動を含むタスクであるが、1クラスあたりの訓練データは多くて数百インスタンス程度であり、十分とは言えない。そのため、HASC の知識を転移せさせることで、データ不足を補うことができ、認識性能が大幅に向上し

たとえられる。一方で、unimib_fall は転移学習によって性能が大きく低下している。これは、HASC と unimib_fall のドメインの違いに起因するものであり、HASC から得られる知識が unimib_fall のタスクに対して有効ではないことを示している。

提案するクラス拡張手法を用いた Transfer(CA) モデルは、Transfer(Plain) よりも良好な性能を達成している。pamap2, unimib_adl, dsads, uschad では、Transfer(CA-da) モデルの性能は Transfer(Plain) モデルよりも向上しており、関連手法である Transfer(TPN) よりも高い性能を達成している。従って、Transfer(CA-da) は、ソースタスクの行動クラスを DA によって拡張することで、ソースモデルが獲得する表現の幅を拡張することができ、これらのターゲットタスクで転移性能を向上させることができたと考えられる。wisdm や unimib_fall では、Transfer(CA-position) の分類性能が Transfer モデルの中で最も高い。特に、unimib_fall では、Transfer(CA-position) モデルは Scratch モデルよりも性能が低いものの、Transfer(Plain) から大幅に性能が向上している。一方で、ucihar, mhealth では、提案手法による性能向上は見られない。これは、本稿で検証したクラス拡張方法がこれらのターゲットタスクで有効ではなかった可能性を示唆している。

4 まとめ

本研究では、クラス拡張を用いた転移学習手法を提案しその有効性を検証した。その結果、提案手法は、ソースモデルが獲得する表現の幅を広げることができ、ターゲットタスクに対する転移性能を向上させることが明らかとなった。ただし、有効なクラス拡張方法はターゲットタスクによって異なるため、クラス拡張方法にはまだ検討の余地がある。

参考文献

- [1] J. Wang, V. W. Zheng, Y. Chen, and M. Huang. Deep transfer learning for cross-domain activity recognition. In *Proc. of the 3rd ICCSE*, New York, USA, 2018.
- [2] A. Saeed, T. Ozcelebi, and J. Lukkien. Multi-task self-supervised learning for human activity detection. *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, Vol. 3, No. 2, Jun 2019.