

メタ学習を用いた行動認識モデルの個人適応

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

1. はじめに

センサデータを用いた行動認識に関して深層学習の有効性が示されている[1]. 行動時のセンサデータを学習することにより行動認識モデルの構築が可能だが, 学習に含まれないユーザに対する汎化性能の獲得が課題の1つである.

本研究では汎用モデルを個人に特化させる手法として, メタ学習を用いて課題の解決を試みる. 一般に深層学習モデルの構築には適応対象者のデータを含む大量のラベル付きデータが必要になるため, 適応対象者に負担がかかる. そこで本研究では, 適応対象者のラベル付きデータが少量である場合にも効果的に学習を行うために, Few-shot 学習手法の一種であるメタ学習手法に着目した. 特に本稿では, 既存のメタ学習手法とその他の適応手法の比較, およびメタ学習手法における Dropout の影響について考察を行い, その結果を報告する.

2. 関連研究

Lane らの研究[2]では, 20, 30代と65歳以上の2グループ間で歩行時の加速度センサデータの次元削減後の分布が異なっており, グループ間での行動認識の推定精度には大きな差があることを報告している. これよりセンサデータを用いた行動認識モデルでは, 動作の個人差に影響を受けることが分かる.

少数のラベル付きデータで学習を行う Few-shot 学習の一種にメタ学習がある. メタ学習とは学習方法を学習する手法であり, 代表的なアルゴリズムの1つとして Model-Agnostic Meta-Learning (MAML)[3]が挙げられる. MAML とは, 複数の学習用タスクからそれらのタスクが素早く学習できるような初期パラメータを探索することを目的にしたアルゴリズムである.

センサデータを用いた深層学習ベースの行動認識モデルの個人適応に関する研究には Gong らの研究[4]がある. Gong らの研究では, メタ学習アルゴリズムである MAML を改良した個人適応手法である MetaSense を提案している. この手法は MAML のメタ学習時に用いるタスクを個人の行動

User Adaptation for Human Activity Recognition with Meta-learning

[†]Daisuke Hamazaki, Kazuma Kondo, Tatsuhito Hasegawa
Graduate school of University of Fukui

表1 比較対象手法一覧

手法	概要
*MAML[3]	D_{rest} の複数タスクから初期パラメータの探索
*MetaSense[4]	MAML を個人適応用に改良
*Prototypical Network (PN)[5]	D_{rest} から埋め込み空間に各クラスの代表点を計算
Src	D_{rest} で学習 (ベースライン)
Tgt	D_{user}^{adapt} で学習
FT	Src を D_{user}^{adapt} で再学習
TrC	Src を D_{user}^{adapt} で転移学習
Src_Tgt	$D_{rest} + D_{user}^{adapt}$ で学習

*はメタ学習手法

$$D_{rest} = D_{all} - D_{user}, \quad D_{user} = D_{user}^{adapt} + D_{user}^{test}$$

分類問題としており, 複数の個人が素早く適応できる初期パラメータを探索することができる. この得られた初期パラメータを用いることで, 少数の学習データでも個人に適応できるモデル構築が可能となる.

3. 評価実験

既存のメタ学習手法とその他の手法を用いた行動認識モデルの個人適応の比較とメタ学習を用いた行動認識モデルの個人適応手法に関して過学習を抑える効果を持つ Dropout 層の有無による影響の考察を行う.

個人適応手法の実験として, 適応対象者を含まないデータセット $D_{rest} = \{(\mathbf{x}_1, \mathbf{y}_1), \dots, (\mathbf{x}_N, \mathbf{y}_N)\}$ と少量の適応対象者データセット $D_{user}^{adapt} = \{(\mathbf{x}_1, \mathbf{y}_1), \dots, (\mathbf{x}_M, \mathbf{y}_M)\}, M \ll N$ が与えられる環境を想定し, D_{user}^{test} に対する推定精度の評価を行う.

比較に用いる手法と概要を表1に示す. 評価に使用するデータセットには HASC データセット[6]を用いた. HASC データセットは, スマートフォンから得られる加速度センサデータを含む行動認識用のベンチマークデータセットである. HASC のセンサデータには「静止」, 「歩行」, 「走行」, 「階段上り」, 「階段下り」の6種類に基本行動ラベルが付与されている. 今回は HASC データセットの中からサンプリング周波数が 100Hz であるものを使用した. また, サンプル数が条件に満たないユーザや計測値が異常であ

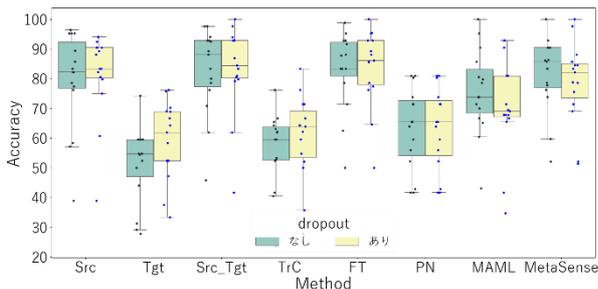


図1 各手法間の推定精度の比較

るユーザのデータは排除した。モデルの入力には sliding-window 方式で作成したフレームサイズ256, スライド幅256, 3チャンネル (x, y, z 軸) のフレームを用いた。

50 人分の HASC データセット全体を D_{all} , 適応用ユーザの各行動クラスから 5 インスタンスずつ含むデータセットを D_{user}^{adapt} , 評価用を D_{user}^{test} とし, 表 1 の概要をもとに学習・評価を行う。

今回個人適応手法の比較においてベースとする行動認識モデルには畳み込み層 5 層, プーリング層 2 層, 全結合層 3 層, 正規化層 7 層の CNN モデルを用いた。また, 過学習を抑える目的で全結合層の手前に Dropout 率 0.5 の Dropout を追加したモデルも用意し, Dropout 追加による影響を考察する。全学習手法で最適化手法は Adam に統一した。

4. 考察

評価実験の結果を図 1 に示す。箱ひげは検証者 15 人分の Accuracy の分布, 横軸は学習手法を示している。箱ひげ図の中央値から Dropout なしの場合, MAML や PN, Tgt, TrC は Src と比べて認識精度が低く, FT や MetaSense, Src_Tgt は Src と比べて若干の認識精度向上が見られることが分かる。また, ほとんどの手法で Dropout の有無で精度が異なることが分かる。Dropout は FT や Tgt, TrC では認識精度向上に寄与するが, MAML や MetaSense 等のメタ学習手法では認識精度が低下していることが分かる。これは, Dropout は一般に特定のタスクに関してモデルを学習する際にモデルの過学習を抑制する手法であり, MAML や MetaSense のような複数のタスクに素早く適応できる初期値を探索する手法では Dropout の効果が悪影響を与えてしまう可能性があることが考えられる。PN が Dropout の有無で精度変化が起きないのは, PN が全結合層を使用しない学習手法のため, Dropout ありのモデルを使用しても Dropout を含む全結合層を使用しないためである。

次に 5 人のユーザに対して Dropout 率を 0.0 から 0.9 まで 0.1 刻みで変化させながら実験を行った。結果を図 2 示す。この結果から Dropout 率が

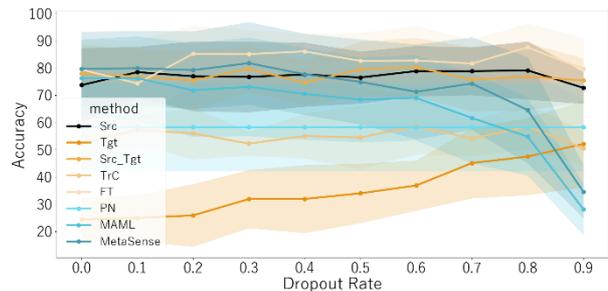


図2 Dropout 率による精度の変化

大きくなるほど MAML や MetaSense 等のメタ学習手法の精度が悪化し, その他の手法ではほぼ変化がないことが分かる。また, Tgt では Dropout 率が大きくなると精度が向上していることも分かる。これは適応対象者のみの少数データのため Dropout 率が低いと過学習しやすく精度が悪化しているためより大きな Dropout 率を設定することで改善できたためだと考えられる。

5. おわりに

今回は, HASC データセットを用いて行動認識におけるメタ学習手法の検証と他の手法との比較, メタ学習手法の Dropout に関する問題点を確認した。その結果, 行動認識モデルの個人適応にメタ学習手法を用いる場合では, Dropout の追加がモデルの性能に悪影響を与えることが明らかとなった。

今後は, Dropout を含む場合でも有効に働く学習手法の開発, 他のデータセットにおける有効性と違いによる影響の検証, Dropout が与える影響の検証, 他のメタ学習を用いた個人適応, 教師なしデータを用いた個人適応手法の探索を行う予定である。

参考文献

- [1] Yang, Jianbo, et al. "Deep convolutional neural networks on multichannel time series for human activity recognition." *Ijcai*. Vol. 15. 2015.
- [2] Lane, Nicholas D., et al. "Enabling large-scale human activity inference on smartphones using community similarity networks (csn)." In *Proc. of UbiComp 2011*. Beijing China, 2011.
- [3] Finn, Chelsea, et al. "Model-agnostic meta-learning for fast adaptation of deep networks." In *Proc. of ICML 2017*. 2017.
- [4] Gong, Taesik, et al. "MetaSense: Few-Shot Adaptation to Untrained Conditions in Deep Mobile Sensing." In *Proc. of ACM SenSys 2019*. 2019
- [5] Snell, Jake, et al. "Prototypical Networks for Few-shot Learning." In *Proc. of NIPS2017*. 2017
- [6] Kawaguchi, Nobuo, et al. "HASC Challenge: gathering large scale human activity corpus for the real-world activity understandings." In *Proc. of the AH2011*. 2011.