

Group DRO による行動分節化モデルの 堅牢性能改善の実証的評価

鈴木 健太[†] 山本 泰生[†]

静岡大学大学院 総合科学技術研究科[†]

1. はじめに

一般的な機械学習モデルは学習、テストデータが独立同分布に従う仮定の下で経験損失最小化の戦略で学習を行う。しかし現実には学習、テストデータの従う分布が異なる現象、すなわち、**分布シフト (distribution shift)** によりこの仮定は破綻する。

本研究は、製造業における人手での部品組立作業を対象としたシフトに焦点を当てる。作業には、作業経験や利き腕等による作業動作の違いを含む。このため、学習、テストデータの分布が必ずしも一致しない課題を有する。本稿では、この課題を解決するため、分布シフトに堅牢な学習法として知られる **Group DRO**[1]を導入する。これにより行動分節化モデルの汎化性能がどの程度改善するかを実証的に評価する。

2. 先行研究

作業分節化タスクは、ある一連の工程からなる作業のデジタルデータを入力とし、入力データを工程ごとに分節化 (*segmentation*) する事である。動画データを対象とする一般行動の分節化モデルとしては **MS-TCN**[2]が知られる。これは、系列データに対する時間畳み込みネットワーク (*Temporal Convolutional Network, TCN*) を多段に積層化したモデルである。近年、MS-TCN を用いた作業分節化の研究[3]が進められている。しかし、作業員や作業工程によって精度低下が見られる事がある。学習では複数の作業員データを与えるが、テストデータは作業員単位で与えられる事が多いためである。例えば、少数派である左利き作業員をテストデータとした際、右利きが多数派を占める学習データとの分布シフトが起こり得る。

これは**部分母集団シフト (subpopulation shift)** [4]と呼ばれる問題に相当する。データの出現分布をドメインの集合 \mathcal{D} を用いて表現する。 \mathcal{D} 中の各ドメインは固有の出現分布を持つものとする。例えば、本稿では作業員個々のドメイン d に対し、出現分布 P_d を持つと仮定する。学習データのドメイン

集合を \mathcal{D}_{train} とし、その出現分布を $P_{train} = \sum_{d \in \mathcal{D}_{train}} q_d^{train} P_d$ とする。ただし、 q_d^{train} は学習データにおけるドメイン d の重要度とする。同様に、テストデータのドメイン集合を \mathcal{D}_{test} 、分布を $P_{test} = \sum_{d \in \mathcal{D}_{test}} q_d^{test} P_d$ と表し、 q_d^{test} をテストデータにおけるドメイン d の重要度とする。部分母集団シフトは、 $\mathcal{D}_{test} \subseteq \mathcal{D}_{train}$ であり、かつ $q_d^{train} \neq q_d^{test}$ の場合に相当する。

部分母集団シフトに対する学習法として **Group DRO** が知られている。本稿では、MS-TCN の学習フローに **Group DRO** を組み込む事で、作業分節化タスクに対して堅牢なモデルの構築を目指す。

3. Group DRO

まず、経験損失最小化に基づく問題設定を説明する。入力特徴量 $x \in \mathcal{X}$ からラベル $y \in \mathcal{Y}$ を予測するタスクを考える。モデル集合 Θ 、損失 $\ell: \Theta \times (\mathcal{X} \times \mathcal{Y}) \rightarrow \mathbb{R}_+$ 、入力分布を P とすると、分布 P の下で期待損失 $\mathbb{E}_P[\ell(\theta; (x, y))]$ を最小化するモデル $\theta \in \Theta$ のパラメータを見つける事が目標である。しかし、真の分布 P は未知であり、有限の観測データのみで期待損失を最小化する必要がある。期待損失を観測データから評価する上で最も大きな手がかりは経験損失である。その経験損失を最小化するモデル $\hat{\theta}_{ERM}$ を導く。

$$\hat{\theta}_{ERM} := \arg \min_{\theta \in \Theta} \mathbb{E}_{(x, y) \sim \hat{P}}[\ell(\theta; (x, y))]$$

ただし、 \hat{P} は学習データに対する経験分布である。

これに対し、**Group DRO** ではグループ間での経験損失を良好にするモデル $\hat{\theta}_{DRO}$ を学習する。具体的には、事前知識により学習データを G 個のグループに分割し、そのグループ毎に経験損失最小化の戦略で学習を実施する。本手法では、各ドメインを1つのグループとして学習データを分割している。そのグループ毎に計算された損失の中で最大となったグループの経験損失 $\hat{\mathcal{R}}(\theta)$ を最小化するアルゴリズムである。

$$\begin{aligned} \hat{\theta}_{DRO} &:= \arg \min_{\theta \in \Theta} \left\{ \hat{\mathcal{R}}(\theta) \right. \\ &:= \left. \max_{g \in \mathcal{G}} \mathbb{E}_{(x, y) \sim \hat{P}_g}[\ell(\theta; (x, y))] \right\} \end{aligned}$$

Empirical Evaluation of Robust Performance Improvement of Behavioral Segmentation Models with Group DRO

[†] Kenta SUZUKI, [†] Yoshitaka YAMAMOTO

[†] Department of Informatics, Graduate School of Integrated Science and Technology, Shizuoka University

\hat{P}_g は、特定のグループ $g \in \mathcal{G}$ の経験分布である。このプロセスにより、損失が大きくなり、すなわち、既存モデルの予測値と大きく離れたデータに対して汎化性能を向上させる事が出来る。

4. 実験

4.1 使用するデータ

対象とする作業は、オイルクーラー取付作業と呼ばれる実際の現場で教育用に実施される作業である。作業の一連は、12 工程により構成される。この試行を作業員 6 人 (A~F) それぞれ 50 回 (計 300 回) 実施し、動画を撮影する。この中で、作業員 B が左利きの作業員である。また、作業員が 6 人であることから 6 つのグループを定義する。動画から OpenPose[5]により上半身 7 つの関節点 (図 1) の x, y 座標を抽出し[6]、正規化した上で動作認識の特徴量として使用する。作業は右前、正面、左前の 3 視点で撮影する。また、動画の各フレームには、人手により正解工程番号を付与しており、合計 43 特徴量の時系列データをモデル学習の入力としている。




図 1: 骨格情報抽出箇所

4.2 実験設定

実験の評価として交差検証を実施する。具体的には、テストデータを作業員 A と割り当てた場合、50 動画のうち 10 動画を学習データ、残りの 40 動画をテストデータとして割り当てる。他の作業員の動画 5 人分と A の学習データ 10 動画の計 260 動画で学習を行い、A の残りの 40 動画でテストを実施して精度を測定する。精度とは「正解率」の事であり、動画の全フレームのうち予測工程番号と正解工程番号の一致率を工程毎に算出する。これを作業員 A~F 毎に実施する。この一連を先行研究の手法である ①Vanilla MS-TCN と本提案手法である ②MS-TCN + Group DRO の 2 種類で実験する。なお、②の方にはモデルの過学習を避ける目的で L2 正則化を導入している。

5. 結果

本実験の目的は、Vanilla MS-TCN と比較し、MS-TCN + Group DRO の方が左利き作業員をテストデータとした際の精度が上昇し、かつ、左利きに適応しながらも他の作業員をテストデータとした際も含んだ全体としての平均精度も高く維

表 1: Group DRO 導入の有無での結果の比較

実験	作業員 (事前知識により分けられたグループ)						
	A	B	C	D	E	F	
一連の作業の平均正解率	①	0.90	0.69	0.91	0.92	0.91	0.91
	②	0.87	0.74	0.90	0.90	0.89	0.88

持する事である。左利きに過度に対応すると、右利きでの精度が低下する危険があると考えられる。

表 1 がそれぞれ作業員ごとの実験結果である。ここで、正解率は 0~1 の値を取り、値が大きい程正しく認識出来ている事を示す。また、②の実験での L2 正則化パラメータは $\lambda=1.0$ である。この結果から分かる通り、左利きである B の結果が 0.05 改善している事が分かる。全体としての平均精度は、①Vanilla MS-TCN で 0.87、②MS-TCN + Group DRO で 0.86 となっている。Group DRO 導入後の方が精度の低下が見られるが、精度は一定維持されたと考えている。

6. まとめと今後の課題

①Vanilla MS-TCN に Group DRO (+ L2 正則化) を導入した事で一定の改善は見られた。ただ、表 1 の結果から分かる様に、B の精度は他の作業員と比較するとまだ低い。更に、B 以外の作業員だけの正解率で見ると、0.91 から 0.89 と低下している。現状の手法であると、モデルの重み更新時に単純に最悪の損失を選択するため、他の選択されなかったグループの損失が加味されていない。重み更新時の損失選択にて、選ばれなかったグループの損失も取り入れた重み更新が出来る手法への改善を検討している。

謝辞

本研究においてデータ提供、貴重なアドバイスを頂いた静岡大学 中村圭佑様、西村雅史先生、ならびに、ヤマハ発動機株式会社 塩野由紀様、白澤怜樹様、中野貴行様、青木崇浩様に厚く御礼申し上げます。

参考文献

- [1] S. Sagawa et al., "Distributionally robust neural networks for group shifts: On the importance of regularization for worst-case generalization", International Conference on Learning Representations (ICLR), 2020.
- [2] Y. A. Farha et al., "MS-TCN: Multi-stage temporal convolutional network for action segmentation", IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2019.
- [3] K. Nakamura, et al., "Tackling Over-smoothing on Temporal Convolutional Networks for Operating Work Segmentation", RISP International Workshop on Nonlinear Circuits, Communications and Signal Processing (NCSP), 2023.
- [4] P. W. Koh, et al., "Wilds: A benchmark of in-the-wild distribution shifts." International Conference on Machine Learning. PMLR, 2021.
- [5] Z. Cao, et al., "OpenPose: Realtime Multi-Person 2D Pose Estimation using Part Affinity Fields", IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019.
- [6] 中村圭佑 他, "姿勢推定による作業同一作業偏差の定量化に向けて", 2021 年度人工知能学会全国大会 (第 35 回), 2021.