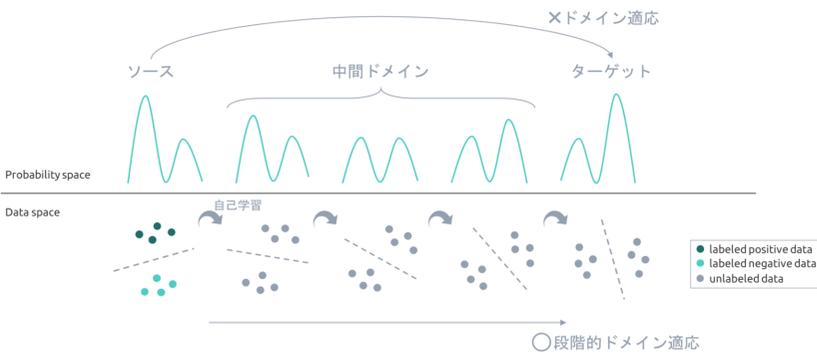


擬似中間ドメインによる段階的ドメイン適応

佐川 正悟

総合研究大学院大学 統計科学専攻 博士課程(5年一貫制)4年

【先行研究 | 段階的ドメイン適応】



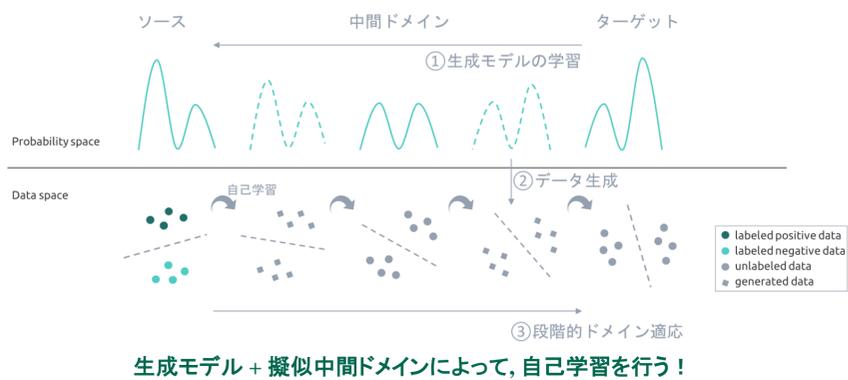
Kumar, Ananya, Tengyu Ma, and Percy Liang. "Understanding self-training for gradual domain adaptation." *International Conference on Machine Learning*. PMLR, 2020.

- Kumar et al. *ICML*. 2020. **GDAを提案**
- Abnar et al. *arXiv*. 2021. Zhang et al. *arXiv*. 2021. 中間ドメインが不要 中間ドメインのインデックスが不要
- Chen and Chao. *NeurIPS*. 2021. **中間ドメインのインデックスを必要としないGDAを提案**
- Zhou et al. *IEEE*. 2022. Sagawa and Hino. *arXiv*. 2022. 能動学習と組み合わせる Multifidelity学習と組み合わせる
- Wang et al. *ICML*. 2022. **Kumarの理論解析を改良**
- Dong et al. *arXiv*. 2022. He et al. 2023. 理論解析の改良 OTを用いて中間ドメインを生成する

ドメイン間の距離に着目した研究は1件のみ

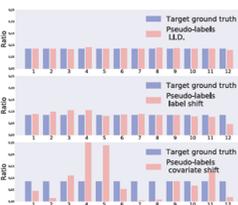
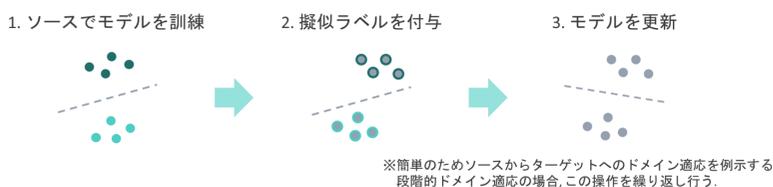
【研究目的】

◎研究目的
利用可能な中間ドメインに限られている場合でも、段階的ドメイン適応を可能とする！



【関連研究 | 自己学習による段階的ドメイン適応】

ドメイン間のシフトが小さい場合は自己学習によるドメイン適応が可能。段階的ドメイン適応では、この性質を利用しシフトが小さいドメイン適応を繰り返し行う。



ドメイン間のシフトが小さくない場合に、自己学習が機能しないことをLiu et al. らは実験的に示した。

Liu, Hong, Jianmin Wang, and Mingsheng Long. "Cycle self-training for domain adaptation." *Advances in Neural Information Processing Systems* 34 (2021).

【関連研究 | Continuous Normalizing Flow】

Normalizing Flowは生成モデルの1種。既知の確率分布(正規分布など)から未知の確率分布への変数変換を学習する。NNを複数層重ねることによって変数変換を達成する離散型(DNF)とNeural ODEを利用する連続型(CNF)に大別される。CNFは多数の中間表現を得ることができるため、本研究ではCNFを選択した。

DNFによる変数変換の例

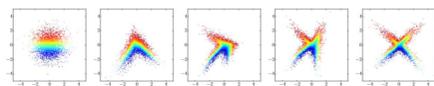


Figure 1: Example of a 4-step flow transforming samples from a standard-normal base density to a cross-shaped target density.

Papamakarios, George, et al. "Normalizing Flows for Probabilistic Modeling and Inference." *J. Mach. Learn. Res.* 22:57 (2021): 1-64.

Will Grathwohl, Ricky TQ Chen, Jesse Bettencourt, Ilya Sutskever, and David Duvenaud. Fjord: Free-form continuous dynamics for scalable reversible generative models. In *International Conference on Learning Representations*, 2018.

CNFによる変数変換の例

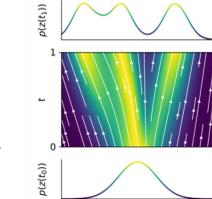


Figure 1: FJORD transforms a simple base distribution at t_0 into the target distribution at t_1 by integrating over learned continuous dynamics.

【関連研究 | Continuous Normalizing Flow】

Wang et al. らはソースとターゲットドメインを繋ぐ最適経路の存在を仮定し、その経路上に中間ドメインがあるべきとした。最適経路はデータ分布の幾何を考慮して決めるべきだが、今回はUMAPを前処理として用いることでユークリッドに限定した。さらにHuang et al. らの提案したCNFに対する正則化を利用することで、ドメイン間を直線で結ぶことを狙う。

最適経路の仮定

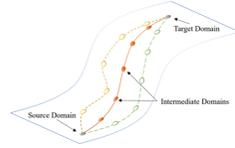


Figure 2: An illustration of the optimal path in gradual domain adaptation, with a detailed explanation in Sec. 4.4. The orange path is the geodesic connecting the source domain and target domain.

Haoxiang Wang, Bo Li, and Han Zhao. Understanding gradual domain adaptation: Improved analysis, optimal path and beyond. *Proceedings of the 39th International Conference on Machine Learning*

CNFの正則化

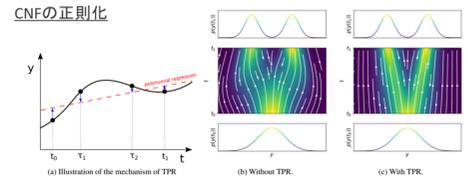


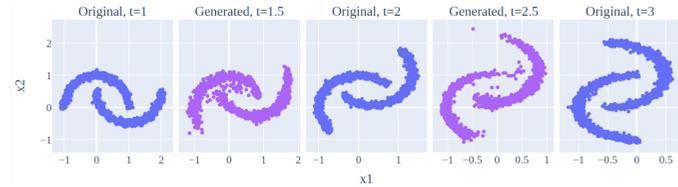
Figure 1: Illustration of our Trajectory Polynomial Regularization (TPR). (a): The illustrated mechanism of TPR. The solid curve represents trajectory of $y(t)$. The dashed line is a fitted polynomial regression on the four randomly sampled points. Polynomial regression of degree 1 is demonstrated here. The TPR loss L_p is designed to pull the points of y to the fitted polynomial. (b) and (c): Two transformations of ID distributions by CNF either with or without TPR. The input is a Gaussian distribution and the output is a mixture of two Gaussian distributions. The white streamlines represent the trajectories of $y(t)$ and the color represents the density $p(y(t))$.

Huang, Han-Hsien, and Mi-Yeh Yeh. "Accelerating continuous normalizing flow with trajectory polynomial regularization." *Proceedings of the AAAI Conference on Artificial Intelligence*, Vol. 35, No. 9, 2021.

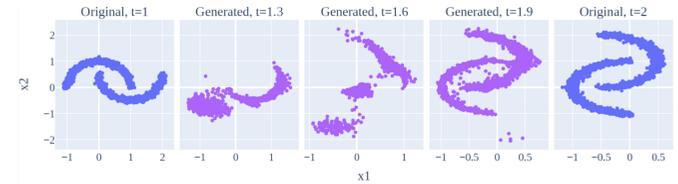
【提案手法 | CNFによる補間の例】

トイデータを用いてCNFによるドメインの補間が可能であることを示す。

ソース, 中間, ターゲットドメインの3つで学習した場合

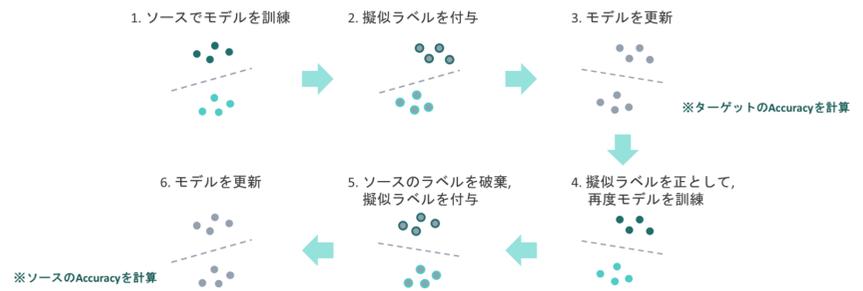


ソース, ターゲットドメインの2つで学習した場合



【提案手法 | Cycle Consistency】

提案手法はCNFを用いることで擬似中間ドメインを生成することが可能である。補間間隔はハイパラとして設定可能であり、適切な補間間隔を見積もる方法としてCycle Consistencyを用いることを提案する。

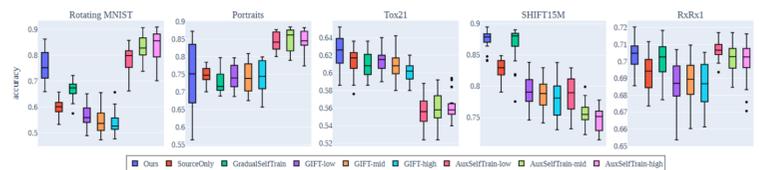


【提案手法 | 数値実験】

データセットの説明/Cycle Consistencyの評価結果

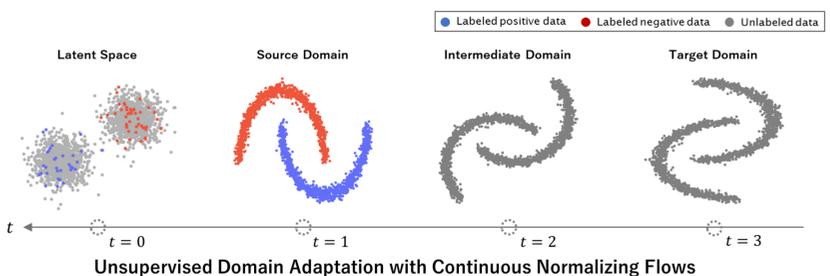
名称	概要	入力次元数	相関係数 (Cycle Consistencyの評価)
Rotating MNIST	MNISTに回転を加えたもの	28 × 28	0.535
Portraits	高校生の卒業写真を集めたデータセット。年代によるシフトがある。	32 × 32	0.032
Tox21	化合物の毒性評価結果。置換基の数でドメインを分割した。	5	0.775
SHIFT15M	ECサイトから収集したファッションに関するデータ。年代によるシフトがある。	4096	0.829
RxRx1	細胞画像のデータセット。実験バッチによるシフトがある。	32 × 32 × 3	0.700

ベースライン手法との精度の比較



【まとめ / 提案手法の限界 / 今後の予定】

- ・本研究は段階的ドメイン適応において、中間ドメイン間の距離が大きい場合を想定し、解決策としてCNFを用いる方法を提案した。
- ・CNFを用いているため、特に画像の取り扱いが困難。CNFの計算コストが改善されればモーフィングなどへの応用も期待される。
- ・提案手法はソース/ターゲット間に中間ドメインがあることを保証していない。ユーザーが年代などデータセットに関する情報から“中間”と思われるものを選択する必要がある。また、複数の中間ドメインを与えた場合に適切なものを選択するような機能もない。
- ・今後はCNFの訓練時にソースのラベル情報を取り入れ、自己学習を必要としない方法を検討予定。



・本発表に関する論文は <https://arxiv.org/abs/2206.11492> から取得可能です。

