

## 1. はじめに

深層学習を用いて高精度な物体認識を実現するには、大量の教師付きデータが必要となる。しかし、手作業で大量のデータに教師ラベルを付与する必要がある、人的コストがかかる。この問題を解決する方法として、Domain Adversarial Neural Network[1] (DANN) によるドメイン適応が提案されている。DANN は、Gradient Reversal Layer (GRL) を通じて敵対的学習を行うことで、Target Domain の認識精度を向上させることができる。しかし、Source Domain の転移に寄与しないデータも学習することになる。そこで、本研究では DANN に共変量を導入することで、Source Domain の影響を抑制し、ドメイン適応の高精度化を実現する。

## 2. DANN によるドメイン適応

ドメイン適応とは、学習データは十分だが認識対象でないドメイン (Source Domain) と、学習データは不十分だが認識対象であるドメイン (Target Domain) の両データを用いる学習法である。DANN は、特徴抽出器  $G_f$  とラベル予測器  $G_l$  で構成されるクラス分類の DCNN に GRL とドメイン分類器  $G_d$  を導入してドメイン適応を行う。両ドメインデータを学習することで、ドメイン間の違いを吸収した特徴抽出器  $G_f$  の構築が可能となる。GRL は、特徴抽出器  $G_f$  とドメイン分類器  $G_d$  の間に導入する。GRL の順伝播は恒等関数として働き、逆伝播はドメイン分類器  $G_d$  の勾配を負にして逆伝播する。

## 3. 提案手法

Target Domain の性能向上に寄与しない Source Domain サンプルの影響を抑制するために、図 1 のようにドメイン分類誤差を共変量により重み付けする。提案手法は、事前に Source Domain データで学習した事前ネットワークを準備する。この事前ネットワークは、学習ネットワークと同じ特徴抽出器  $G_f$  とラベル予測器  $G_l$  で構成する。事前ネットワークに Source Domain のデータを入力し、学習ネットワークに Source Domain のデータと Target Domain を結合したデータを入力する。ここで、共変量  $\lambda_{cov_i}$  は事前ネットワークのクラス尤度  $P_a(c|\mathbf{x}_i)$  と、学習ネットワークのクラス尤度  $P_t(c|\mathbf{x}_i)$  から式 (1) のように求める。

$$\lambda_{cov_i} = \frac{e^{P_a(c|\mathbf{x}_i)}}{e^{P_t(c|\mathbf{x}_i)}} \quad (1)$$

GRL を  $R_\lambda$  とした時、ミニバッチの Source Domain サンプルを入力した時のドメイン分類誤差  $L_{d_i}^{source}$  は、式 (2) となる。

$$L_{d_i}^{source} = \lambda_{cov_i} L_{d_i}(G_d(R_\lambda(G_f(\mathbf{x}_i))), c) \quad (2)$$

これにより、Target Domain の性能向上に貢献しないサンプルによる学習を抑制することができるため、Target Domain の精度向上が期待できる。





図 1: 本研究のネットワーク構造

## 4. 評価実験

評価実験では GRL を導入しない単一 DCNN と従来の DANN, 提案手法を比較する。

### 4.1. 実験概要

本実験では、25 種類の日用品の分類を対象とし、各学習データは 3 種類のドメインで構成されている。ここで、Unreal Engine 4 で生成した画像を Source 画像、NVIDIA 社が提供する Iray レンダラによって生成した画像を Target 画像、実画像を評価画像とする。25 種類のアイテム画像に対してランダムに矩形を切り出したパッチ画像 (図 2) を用いる。



(a)Source 画像 (b)Target 画像 (c) 評価画像

図 2: パッチ画像セットの例

DANN 及び提案手法は、Source Domain に 1 クラスあたり 1,000 枚、Target Domain に 1 クラスあたり 500 枚の学習データを用いる。GRL を導入しない単一 DCNN は Source Domain のみで学習する。


### 4.2. 実験結果

単一 DCNN と DANN, 提案手法の認識精度の比較を表 1 に示す。提案手法は従来手法である DANN と比べて、Target Domain の認識精度が 5.3% 向上した。さらに、未学習ドメインである評価画像の認識精度が 2.5% 向上した。


表 1: 各ドメインの認識精度 [%]

手法	Source	Target	評価
単一 DCNN	98.6	82.8	81.8
DANN	98.2	92.8	89.5
提案手法	<b>99.4</b>	<b>98.1</b>	<b>92.0</b>

図 3 に、学習中の Source サンプルと共変量の推移を示す。ドメイン間の差異が小さい場合、ドメインの違いを考慮する必要が無いため、図 3(a) のように少ない更新回数で共変量が小さくなると考えられる。ドメイン間の差異が大きい場合、学習初期の  $P_t$  は Target の影響を受けた特徴抽出器により小さくなる。そのため、ドメイン間の差異を考慮して学習するため、図 3(b) のように共変量が小さくなるまでである程度の更新が必要だと考えられる。



(a) 共変量の収束が早いサンプル



(b) 共変量の収束が小さいサンプル

図 3: 学習サンプルと共変量の推移

## 5. おわりに

本研究では共変量を用いた DANN によるドメイン適応を提案し、その評価を行った。提案手法は、2 種の CG データで学習した結果、全てのドメインにおいて認識精度の向上を確認できた。今後は GRL の調整方法の検討とセグメンテーションへの応用を目指す。

## 参考文献

- [1] Y. Ganin, et al., “Unsupervised Domain Adaptation by Backpropagation”, ICML, pp.1180-1189, 2015.