

# 変状検出安定化に向けた画像の共変量シフト抑制に関する分析

## Analysis of covariate shift reduction for stable damage detection in infrastructure images

吉田 龍人 都築 幸乃 藤井 純一郎 (八千代エンジニアリング) 山下 隆義 (中部大学)  
Ryuto YOSHIDA, Yachiyo Engineering Co., Ltd.  
Yukino TSUZUKI, Yachiyo Engineering Co., Ltd.  
Junichiro FUJII, Yachiyo Engineering Co., Ltd.  
Takayoshi YAMASHITA, Chubu University.  
E-mail: ry-yoshida@yachiyo-eng.co.jp

The covariate shift is a factor that reduces the accuracy of pattern recognition. Since the images of the infrastructure are mainly taken outdoors, the damage detection task influenced by a covariate shift. This study aim to establish a method to reduce covariate shifts in infrastructure images and to realize stable inference. This paper shows the results of analyzing the relationship between the distribution of input data and the distribution of the intermediate layer of the CNN model.

### 1. はじめに

豪雨災害の激甚化、労働者不足およびインフラの老朽化が深刻となっている<sup>1)</sup>。豪雨災害の被害を低減するには河川インフラの維持管理を徹底し、予防保全に努める必要がある。河岸の浸食防止を目的とする護岸は、長距離にわたる整備区間に対して目視を要する非効率な点検が実施されており<sup>2)</sup>、機械を使った省力化が期待される。これに対してインフラ維持管理の省力化を目的としたニューラルネットワークによる変状自動検出に関する研究が多方で行われている。研究の進捗に伴い点検ルールが改訂される動きもある。橋梁点検では近接目視と同等の健全度評価が可能な場合、目視以外の手法による点検も認可された<sup>3)</sup>。画像認識による維持管理を実現する上で高い汎化性を持つモデルの開発が求められるが、インフラを撮影した画像の多様なバリエーションが汎化性獲得の障壁となっている。特に屋外で撮影される画像は撮影条件の統一が困難で、撮影ごとに空間解像度や色合いなどが変化することが想定される。先行研究では藤井<sup>4)</sup>らが同時期に撮影した同区間の護岸画像に対して、ニューラルネットワークにてひび割れ検出を行った事例を示した。そこでは撮影日ごとに変化する画像の見かけによって、ひび割れ検出精度が低下する様子が実験的に示された。

同じモデルを用いた推論での精度が画像の見かけによって低下する現象は、共変量シフト<sup>5)</sup> (以下、CS と称する) が起因していると考えられる。共変量シフトとは学習ドメインと推論ドメインの持つ分布が異なる状態を指す。さらにニューラルネットワークを用いた画像認識では、モデルの中間出力分布が入力データによって異なる状態を指す内部共変量シフト<sup>6)</sup> (以下、ICS と称する) も推論精度に影響する。なお ICS は本来学習時のミニバッチごとの違いを指すが、本研究では推論時の入力ごとの違いも ICS として扱う。バリエーション豊富なインフラの画像から安定して変状を検出するためには、推論ドメインに対して CS を抑制する前処理が必要だが、適切な手法は明らかでない。そこで本研究は CS を抑制する前処理手法を確立し、ドメインに依らない安定した変状検出の達成を最終目標とする。本論文ではニューラルネットワークを使った護岸ひび割れ Segmentation タスクによって検証を行う。最初に入力データの分布の違いを分析する。さらに学習済みのひび割れ検出モデルによって複数ドメインの画像を推論し、中間層の分布より ICS の発生状況を評価する。これらの結果を元に安定した変状検出を実現する前処理手法を検討する。

### 2. 中間層分布の評価方法

Kullback–Leibler Divergence (以降、KLD と称する) は分布間の類似度を測る指標である。ICS は 2 つの分布間に違いが生じた状態であるため、KLD によって評価を試みる。分布が平均 $\mu_1$ 、標準偏差 $\sigma_1$ の $p$ と平均 $\mu_2$ 、標準偏差 $\sigma_2$ の $q$ が与えられたとき、KLD は(1)式で算出される。

$$D_{KL}(p \parallel q) = \int_{-\infty}^{\infty} p(x) \ln \frac{p(x)}{q(x)} dx \\ = \log \frac{\sigma_2}{\sigma_1} + \frac{\sigma_1^2 + (\mu_1 - \mu_2)^2}{2\sigma_2^2} - \frac{1}{2} \quad (1)$$

スケーリングは CS を抑制するデータの前処理手法で、最も一般的なものに標準化がある。標準化は(2)式に示す平均 $\mu$ および標準偏差 $\sigma$ を使って、分布を平均 0、標準偏差 1 に変換する処理である。本研究では 8bit デジタル画像に対して 255 で除算を行ったデータ (以下、標準化なしと称する) と標準化を行ったデータ (以下、標準化ありと称する) を作成し、推論時の中間 BN 層分布の変化を比較する。なお本研究では個別のデータ $x$ ではなく、ドメインごとの全データ $X$ から算出した $\mu$ および $\sigma$ を用いる。

$$x_i' = \frac{x_i - \mu}{\sigma} \quad (2)$$

Batch Normalization<sup>6)</sup> (以下、BN と称する) はニューラルネットワークにて適用される中間層の特徴量をスケーリングする手法である。学習時は各層・各チャンネルの出力がミニバッチごとに平均 0・標準偏差 1 となるよう、(2)式と同様の変換が実施される。推論時は学習の際に各ミニバッチで算出された $\mu$ と $\sigma$ の移動平均を変換に用いる。この仕組みに基づいて、本論文では推論時の中間層出力の分布と平均 0・標準偏差 1 の分布を KLD で評価し、入力データの分布と比較する。

### 3. 実験方法

学習済み CNN モデルを用いて、入力ドメインの分布と推論時の中間層分布の関係を実験を行う。分析は標準化あり・なしデータで行い、データに合わせてモデルを使い分ける。撮影日時が異なる画像を別ドメインとし、Fig. 1 の(b)~(d)に例示する 3 つのドメインで分析する。これらは Fig. 1(a)のような画像から一辺 224px で切り出したものである。撮影区間と機材は全ドメインで同一である。撮影時の天候に応じて、それぞれを晴れ・曇り・雨ドメインと呼ぶ。モデルは晴れデータで学習したもので、晴れデータのテストデータは未学習区間から作成する。

中間層分布はドメインごとにひび割れのない正常画像 100 枚とひび割れを含んだ異常画像 100 枚で評価する。異常画像のひび割れラベルと非ひび割れラベルの画素値の分布を Fig. 2 に示す。図よりひび割れラベルはドメイン間の類似度が高いが、非ひび割れラベルは類似度が低いことが定性的に判断できる。よって標準化なしではひび割れラベルの分布がドメイン間で類似した状態となる。一方で標準化ありでは、本研究で用いた画像の 99%以上が非ひび割れというインバランスな状態が影響して、非ひび割れピクセルの分布に合わせたスケールが実行されるため、非ひび割れラベルの分布が類似する。

以上の条件を踏まえて、ひび割れと非ひび割れの 2 クラス Segmentation において標準化が ICS に与える影響を分析する。テストデータの BN 層出力分布を  $p$  とし、BN 層の学習則に基づいて平均 0、標準偏差 1 の分布  $q$  との KLD を算出する。KLD は個々の画像に対して各層のチャンネルごとに算出する。複数枚の画像から算出した KLD の各層の平均を平均 KLD とする。さらに各ドメインの正常・異常データで平均 KLD を算出し、標準化あり・なしで比較する。標準化なしに比べて平均 KLD の推移がドメイン間で類似した場合は CS および ICS 抑制を達成したと判断する。

#### 4. 実験結果

はじめに異常データの mIoU をドメインごとに算出した。その結果、晴れ・曇り・雨ドメインに対して、標準化なしの場合は 0.584, 0.462, 0.581, ありの場合は 0.592, 0.485, 0.560 となり、モデルの性能差は小さいことを確認した。

Fig. 3 に推論時の各中間層での平均 KLD 算出結果を示す。(a) が正常画像での結果、(b) が異常画像での結果である。グラフの上段は標準化なし、下段は標準化ありの結果である。横軸は入力から数えた BN 層の数を示している。推移の類似度を定性的に評価すると、正常データでは標準化なし、異常データでは標準化ありが高い結果となった。

Fig. 2 と Fig. 3 より学習ドメインの分布と類似する画像を入力すると、かえってドメイン間の平均 KLD の推移に乱れが生じることが分かった。これは学習データと似た分布を持つデータを入力したことによって、畳み込みでより強く発火したためだと考えた。検出の安定性向上のためには、ひび割れピクセルおよび非ひび割れピクセルの分布を揃える前処理が必要であると判断した。

#### 5. 最後に

本論文では護岸のひび割れ Segmentation タスクにおける入力データと中間層分布の関係性に関する分析結果を示した。その結果、ひび割れと非ひび割れピクセルの分布の違いが中間層分布に影響を与えることが予測された。

今後の課題を列挙する。1 点目は新たな前処理手法の検討である。本実験データでは標準化のような一律な変換では、ドメイン間の CS を抑制できなかった。画素値に応じて変換するスケールを変更する手法を試行し再検証を行う。2 点目は正常・異常を混ぜたデータセットでの検証である。本実験では正常・異常の各データ集合に対するモデルの反応を確認した。一方で、BN 層は正常・異常が混合したデータが平均 0・標準偏差 1 になるスケールを実行する。よって混合データでの検証も行う必要がある。3 点目は入力と中間 BN 層分布の分析結果の一般性に関する検証である。本実験では 2 クラス segmentation データセット 1 種での検証しかできていないため、様々なデータセット、タスクにて同様の検証を行う。

#### 参考文献

- 1) 国土交通省: 令和 2 年版国土交通白書, pp.45-46, p.54 2020.
- 2) 国土交通省水管理・国土保全局河川環境課: 堤防等河川管理施設及び河道の点検・評価要領, p.5, 2019.
- 3) 国土交通省道路局: 道路橋定期点検要領, p.2, 2019.
- 4) 藤井純一郎ほか: 深層学習を活用した河川護岸の経年モニタリング手法の提案, 2021 年度人工知能学会全国大会, 2021.
- 5) H. Shimodaira: Improving predictive inference under covariate shift by weighting the log-likelihood function, JSPI 90(2):pp227-244, 2000.
- 6) S. Ioffe et al.: Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, the 32nd ICML, pp.448-456, 2015.

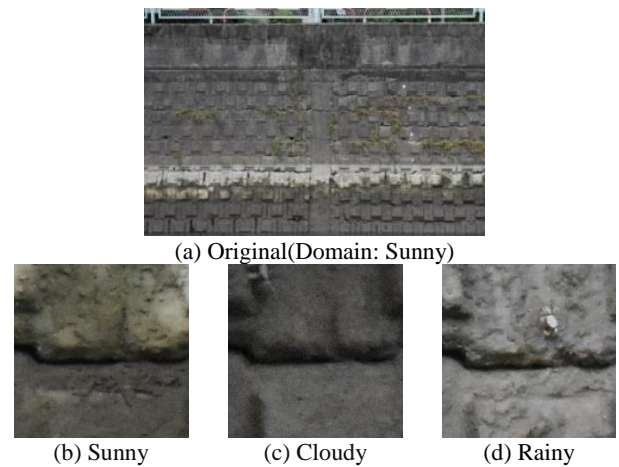


Fig. 1 Image examples





Fig. 2 Pixel value distribution



(a) Normal Image (b) Abnormal Image  
Fig. 3 KLD Transition in Intermediate layer