

# 護岸ひび割れ画像の特徴量分布とKLダイバージェンスによる 中間層出力の分析

Analysis of feature distribution using KLD between inputs and  
intermediate layer outputs in revetment image.

吉田 龍人\*<sup>1</sup>  
Ryuto Yoshida

都築 幸乃\*<sup>1</sup>  
Yukino Tsuzuki

大久保 順一\*<sup>1</sup>  
Junichi Okubo

藤井 純一郎\*<sup>1</sup>  
Junichiro Fujii

山下 隆義\*<sup>2</sup>  
Takayoshi Yamashita

\*<sup>1</sup> 八千代エンジニアリング株式会社  
Yachiyo Engineering Co.,Ltd.

\*<sup>2</sup> 中部大学  
Chubu University.

Scaling input data such as standardization and regularization is a common technique in machine learning. Scaling reduces the difference in the distribution of the input data. Batch Normalization has the purpose of scaling the distribution of features after convolution. Generally, the output of the Batch Normalization layer is converted non-linearly by the activation function. Therefore, the distribution of features through the Batch Normalization layer affects the propagation of features. The task of this study is the crack segmentation of the revetment. The Batch Normalization layer output is evaluated using KL divergence, which is an index for measuring the difference in probability distribution. Then, the relationship between the feature distribution of the input image and KL divergence is analyzed.

## 1. はじめに

学習データと異なるドメインデータでの推論精度の向上は、ドメイン適応における最大目標である。異なるドメインデータでの認識精度が低下する要因には、データの Covariate Shift (以下、CS と称する) の発生がある[shimodaira 00]。CS とは入出力の生成則は同じだが、学習時と推論時で入力データの分布が異なる状況を指す。さらにニューラルネットワークにてパターン認識を行う場合、各中間出力における入力データごとの分布の変化を意味する Internal Covariate Shift (以下、ICS と称する) の発生も精度低下の要因であると考えられる[Ioffe 15]。なお ICS は本来学習時における入力バッチごとの分布が変化する状況を指すが、本研究では推論時における分布の変化も ICS の一環であるとする。一般的なニューラルネットワークは入力層から出力層にかけて非線形変換を繰り返して特徴を伝播するため、入力データの CS が ICS を連鎖的に引き起こし、最終出力にまで影響を与えることが想定される。

本研究の最終目標はドメイン適応タスクにおける CS 抑制手法の確立である。つまり、テストドメインの分布を学習ドメインの分布に近似させるデータスケールング手法の確立を目指す。目標達成の前段として、本論文では河川護岸画像のひび割れ Segmentation タスクを通じて、CS と ICS の関係性を分析した結果を示す。

## 2. CS・ICS 評価手法と分布のスケールング

### 2.1 Kullback-Leibler Divergence

本論文で評価の対象とする CS および ICS は、いずれもある分布とある分布の差異が生じる状態を指す。したがって、確率分布間の類似度によって発生状況を評価できると考える。そこで 2 つの分布間の類似度を測る指標である Kullback-Leibler Divergence (以降、KLD と称する) によって評価を行う。平均  $\mu_1$ ,

標準偏差  $\sigma_1$  の分布を持つ  $p$  と平均  $\mu_2$ 、標準偏差  $\sigma_2$  の分布を持つ  $q$  が与えられたときに KLD は(1)式で算出される。なお本研究で KLD 算出に用いる標準偏差は標本分散の平方根ではなく、不偏分散の平方根とする。

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

### 2.2 画像データのスケールング

CS の影響でテストドメインの推論精度が低下する場合、何らかの手法によってデータのスケールングを行い、学習データと分布を揃えることが望ましい。機械学習におけるスケールングの一般的な手法に標準化がある。標準化はデータ  $x$  に対して平均  $\mu$  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。変換は(2)式によって行われる。データの分布が正規分布に従う場合は、標準化によってドメイン間の分布を揃えることができる。

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

データの範囲を  $[0,1]$  に収める正規化も広く利用される手法である。正規化にはデータの最大値・最小値を  $[0,1]$  に収める Min-Max Normalization があるが、データの外れ値の影響を受けやすい。8bit デジタル画像の場合、255 で除算するだけでもデータ範囲を  $[0,1]$  に収めることができる。255 での除算はコンピュータ演算での計算効率向上が目的であり、変換前のデータが持つドメイン間の分布の違いは変換後も保持される。

以上の手法を踏まえて、8bit デジタル画像を 255 で除算した場合 (以下、標準化なしと称する) と標準化した場合 (以下、標準化ありと称する) でのドメイン間データ分布の比較を行う。さらにドメイン間分布の違いが ICS に及ぼす影響を分析する。

### 2.3 Batch Normalization

Batch Normalization はニューラルネットワークにて適用される特徴量のスケールングを行う手法である[Ioffe 15]。学習時はミニバッチの出力が平均 0・標準偏差 1 となる平均  $\mu$  と標準偏差  $\sigma$

連絡先: 吉田龍人, 八千代エンジニアリング株式会社, 東京都台東区浅草橋 5-20-8 CS タワー3F 技術創発研究所, TEL: 03-5822-6843, Mail: ry-yoshida@yachiyo-eng.co.jp

によって、(2)式と同様の変換が実施される。推論の際は学習時に各バッチで算出された  $\mu$  と  $\sigma$  の移動平均を変換に用いる。

Ioffe らは、BN が学習時の入力バッチごとに発生する ICS を抑制する効果を持つと示した。これに対して Santurkar らは BN が ICS の抑制に寄与せず、損失関数の安定をもたらすためのものだという実験的な結果を示した。BN に関する従来研究では学習の安定化を目的とした BN の機構に関して言及されている。一方で推論時の BN 層によるスケールが推論精度に与える影響については言及されていない。そこで本研究では、学習データ推論時の BN 層出力の分布が平均 0、標準偏差 1 に従うというルールに基づき、学習と異なるドメインデータ推論時の BN 層出力の分布を KLD で評価することによって、ICS の発生状況を分析する。

### 3. 実験内容

#### 3.1 対象データとモデルの作成

実験に用いるデータの例を図-1(a)に示す。対象は河川の対岸から正対して撮影した画像である。解像度は縦 4000px、横 6000px である。ある区間の撮影を同一カメラで異なる日時に計 3 回行った。各回で天候が晴れ・曇り・雨と分かっている。図-1の(b)~(d)は各天候で撮影された同地点の画像を 1 辺 224px の正方形に切り出したものである。天気や撮影時間など様々な要因が重なり、各ドメインにおける画像の色合いが変化している。対岸との距離感や、レンズとブロックが成す角なども人手による撮影の影響で微小な誤差を含んでいる。本研究では各撮影回の画像を別ドメインと見なして実験を行った。各ドメインで概ね同じ位置で撮影された画像を選び、各ドメイン 20 枚の画像に対してひび割れに該当するピクセルのラベル付けをした。

学習に用いるモデルを図-2 に示す。本モデルは ResNet[He 16] および U-Net[Ronneberger 15] の機構を兼ね備えた FusionNet[Quan 16] に対して、long-skip の結合方法を残差結合からスキップ結合に変更したものである。推論時はこれらの結合の機構が特徴量の順伝播に影響を与えることが予測される。本モデルにおいて BN 層は入力から出力にかけて計 55 層存在する。BN 層の後は必ず Relu 層が配置されており、(3)式による変換が実施される[Xavier 11]。よって BN 層出力の分布によって、特徴量が過度に伝播するケースと特徴量がほとんど伝播しないケースが考えられる。

$$\varphi(x) = \max(0, x) \quad (3)$$

モデルの入力サイズは縦横 224px であるため、元画像をメッシュで区切った画像によって以後の分析を行った。メッシュ画像作成の際は、齋藤らの手法に従って護岸領域を物体検出によって大まかに検出し、護岸以外の範囲を対象に含まないようにした。

モデルの学習は晴れデータのみで行った。学習データの諸元を表-1 に示す。表-1 に示す  $\mu$  と  $\sigma$  は標準化のパラメータである。学習実施時のハイパーパラメータを表-2 に示す。学習は標準化なしデータと標準化ありデータで 1 回ずつ行った。学習ではエポックごとに Validation Loss を取り、Loss が最低値を示したときの重みをベストモデルとして採用した。テストデータには各ドメインのひび割れのない正常画像 100 枚とひび割れのある異常画像 100 枚を用いた。モデルの中間層分布はひび割れラベルの量が影響すると想定し、各ドメインのひび割れラベルの合計値が同程度となるように選出した。テストデータでの標準化パラメータを表-3 に示す。標準化のパラメータは各ドメインのメッシュ画像 200 枚ではなく、齋藤らの手法によって 20 枚の元画像から切り出した全てのメッシュ画像で算出した。




図-1 対象護岸画像例

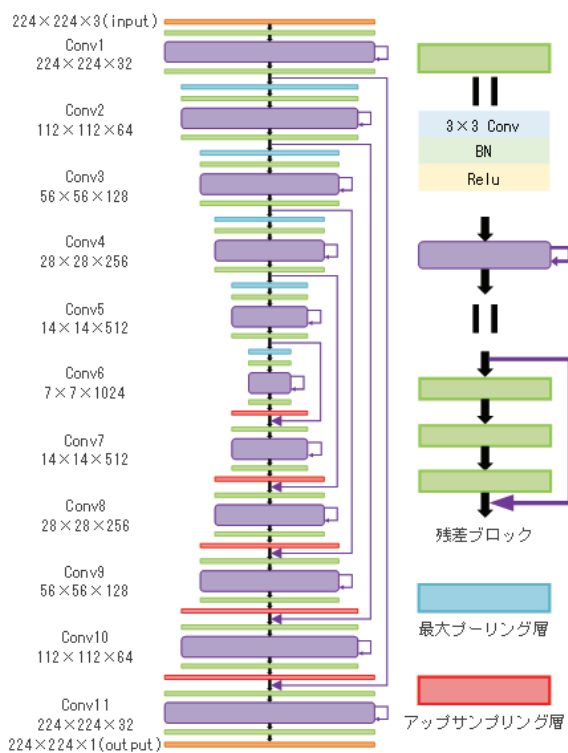


図-2 Segmentation モデル

表-1 学習データ諸元

$\mu$	R	103.16
	G	102.29
	B	101.61
$\sigma$	R	24.18
	G	23.98
	B	23.76
train	5700 枚	
validation	1424 枚	

表-2 ハイパーパラメータ

Epoch	30
Loss	Dice Loss
Optimizer	momentum SGD
Learning Rate	0.01
Batch size	16

表-3 テストデータの標準化パラメータ

		R	G	B
Sunny	$\mu$	103.16	102.29	101.61
	$\sigma$	24.18	23.98	23.76
Cloudy	$\mu$	88.52	88.57	86.77
	$\sigma$	18.56	18.39	18.45
Rainy	$\mu$	94.90	93.93	92.04
	$\sigma$	22.25	22.03	21.74

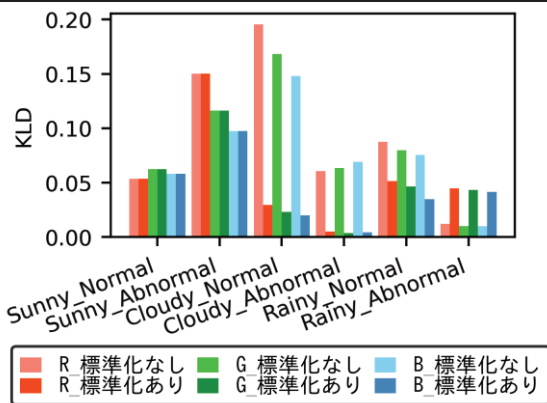


図-4 標準化前後でのチャンネル別 KLD

### 3.2 分析内容

本実験では大きく分けて 3 つの分析を行った。1 つ目は標準化によるドメイン間 KLD の分析である。目的は護岸画像においてドメイン間の分布の差を低減する標準化の効果を評価することである。ここでは標準化なしデータと標準化ありデータのそれぞれで、テストドメイン分布  $p$  に対する学習ドメイン分布  $q$  の KLD によって評価を行った。

2 つ目は標準化がドメイン間の ICS に与える影響の分析である。目的は学習・テストドメイン間の KLD が ICS の抑制に寄与するかを評価することである。よってドメイン間 KLD と中間層分布の分析結果の比較を行った。ここではテストデータの BN 層出力分布を  $p$  とし、BN 層の学習則に基づき平均 0、標準偏差 1 の分布  $q$  との KLD を算出した。KLD は個々の画像に対して各層のチャンネルごとに算出した。複数枚の画像から算出した KLD の各層の平均を平均 KLD とした。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・なしで比較した。ICS 抑制効果の判定は平均 KLD 分布のドメイン間類似度によって行い、類似度が高くなるほど抑制できていると見なす。

3 つ目は標準化のパラメータが同一画像推論時の ICS に与える影響の分析である。目的は標準化パラメータの妥当性を評価することと、異質な分布が ICS に与える影響を明らかにすることである。ここではある 1 枚の画像に対して、人為的に分布を変更させた画像を作成し、各画像で中間 BN 層の KLD を算出した。なお対象画像は図-1(d)とし、標準化ありモデルで検証を行った。分布は適当な値域を持つ等差数列を作成し、元の分布に加算することで変化させた。

## 4. 実験結果

### 4.1 学習・テストドメイン間の KLD 評価

図-4 にテストデータと学習データ間の KLD を示す。KLD は RGB のチャンネルごとに算出した結果を示している。図-4 より曇りのデータに対して大きく KLD が低減したことが分かる。雨の

データについては異常データにおいて KLD が若干増加したものの、正常データの KLD が低減したことが確認できた。

以上より標準化によってドメイン間の KLD が低下する傾向が見られることが分かる。なお晴れデータについては、学習データおよびテストデータに対していずれも同じパラメータを用いているため同じ KLD となっている。

### 4.2 ドメイン間における ICS の評価

モデルの性能差を確認するため、各ドメインの異常データに対して推論を行い、mIoU を算出した。その結果、晴れ・曇り・雨のドメインに対して、標準化なしの場合は 0.584, 0.462, 0.581 となり、ありの場合は 0.592, 0.485, 0.560 となった。よってモデルの性能差は小さい。

図-5 にテスト画像推論時の各中間層における平均 KLD 算出結果を示す。(a)が正常画像 100 枚を入力したときの結果で、(b)が異常画像 100 枚を入力したときの結果である。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、縦軸に平均 KLD を示している。グラフ背景の薄い青線および赤線はモデルの pooling 層および Deconvolution 層の位置を示している。なお学習ドメインでの分布を確認する目的で、学習データから正常・異常データを 100 枚ずつ抜粋し、テストドメインと同様に分析した結果も破線で示している。

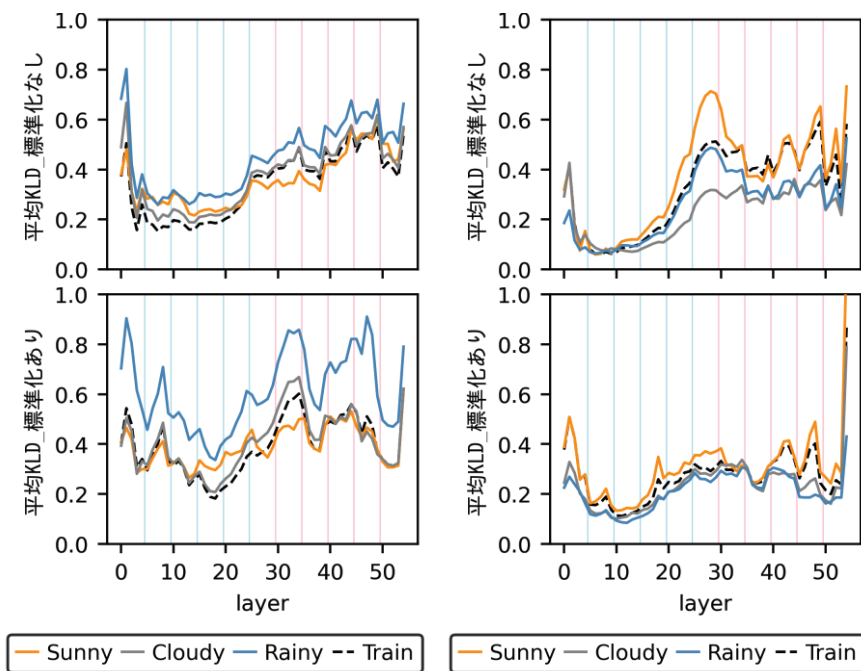
各ドメインにおける平均 KLD 分布の類似性を定性的に評価すると、正常データにおいては標準化なしの類似度が高く、標準化ありの類似度が低い結果となった。異常データにおいては標準化なしの類似度が低く、標準化ありの類似度が高い結果となった。よって標準化によって平均 KLD の類似度が一貫して高まるといった効果は見られなかった。さらに図-4 に示す学習・テストドメイン間の KLD と図-5 の平均 KLD においても相関性が無いことが確認できた。

### 4.3 分布の異なる同一画像における ICS の評価


図-6 に分布を変化させた同一画像推論時の各中間層における平均 KLD 算出結果を示す。図-6(a)は標準偏差を固定し、平均値を変化させた結果で、図-6(b)は平均値を固定し、標準偏差の分布を変化させた結果である。線の色は mIoU をグラデーションで示しており、青色が低 mIoU、桃色が高 mIoU である。凡例の数値は変化させた量を示している。実線がプラスに変化させた結果で、破線がマイナスに変化させた結果である。図-6 より変位量が 0 に近いほど mIoU が大きくなっていることが分かる。よって本研究で用いたパラメータは図-1(d)の推論に関して概ね妥当だったと判断した。さらに標準化のパラメータが元のパラメータから遠ざかるほど、平均 KLD 分布が乱れることが分かった。

### 4.4 考察

図-5 より標準化を実施してもドメイン間で平均 KLD の類似度が一貫して向上する傾向はなかった。したがって、本研究で用いた画像において、標準化が CS および ICS の抑制に繋がる前処理ではないと判断した。より細かく分布の違いを評価すべく、異常データにおける陽性ラベルと陰性ラベルの画素値の分布を調べた。図-7 に陽性ラベルと陰性ラベルにおける画素値の相対度数分布を示す。ここで陽性ラベルはひび割れを指し、陰性ラベルはひび割れ以外のピクセルを指す。図より陽性ラベルの分布はドメイン間の差異が小さいが、陰性ラベルの分布はドメイン間の差異が大きいことが明らかとなった。したがって標準化ではクラス間の分布が揃わず、CS の抑制に至らなかった。



(a) 正常画像入力時 (b) 異常画像入力時  
図-5 BN層出力における平均KLDの推移



(a) 標準偏差変更時  
図-6 分布変更時の平均KLDの推移

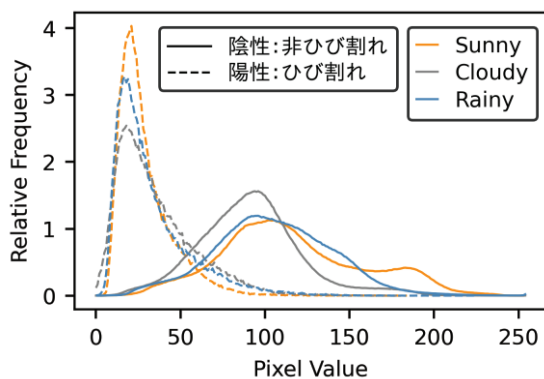


図-7 陽性ラベルと陰性ラベルの相対度数分布

この結果より2クラス分類でICS抑制を目指す場合、陽性と陰性、両者の分布を揃える必要があると推察する。

図-5, 図-7より、標準化をしない場合は陽性ラベルの分布が類似するが、陽性ラベルを含む異常データを入力した際の中間層平均KLD分布の類似度が低下することが分かる。標準化をした場合は陰性ラベルの分布が類似するが、陰性ラベルだけで構成される正常データを入力した際の中間層平均KLD分布の類似度が低下することが分かる。これらはモデルの挙動を理解する上で重要な結果であると考え、2クラス分類の場合、ラベルが陽性か陰性かを分ける決定境界を引くことが目的となるため、必ずしも陽性の特徴を抽出する必要はない。学習データにおいてデータ空間がまとまると、決定境界の形成が容易となる。よって図-5ではまとまったクラスの分布において畳み込みで強く発火し、平均KLDが大きくなったのだと推察した。

図-6よりIoUが最大となるパラメータを境に平均KLDの分布が切り替わる様相が見受けられる。このことから正解ラベルを与えていないデータに関しても、前処理の適切なパラメータが平均KLDの分布から推定できる可能性が示唆された。

## 5. 最後に

本論文では学習・推論データ間のCSがCNNモデルにおけるICSに与える影響を評価すべく、データおよびBN層出力をKLDによって評価した。その結果、ICSの低減のためには、標準化による大域的な分布の統制だけでなく、分類するクラスごとに分布を統制する必要があることが推察された。今後の研究ではクラス間分布の統制を行った際のICS発生状況を評価する。本研究ではクラスごとの分布の類似度が高い2クラス分類タスクというシンプルな条件で実験を行ったため、類似性の低い多クラス分類問題など、より複雑な問題設定での実験も行う。

## 参考文献

- [He 16] K. He et al.: Deep residual learning for image recognition, 2016 IEEE Conference on CVPR, pp.770-778, 2016.
- [Ioffe 15] S. Ioffe et al.: Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, the 32nd ICML, pp.448-456, 2015.
- [Quan 16] T. M. Quan et al. Fusionnet: A deep fully residual convolutional neural network for image segmentation in connectomics, arXiv: 1612. 05360, 2016.
- [Ronneberger 15] O. Ronneberger et al.: U-Net: Convolutional Networks for Biomedical Image Segmentation, MICCAI, Springer, LNCS, Vol.9351: 234-241, 2015
- [Santurkar 19] S. Santurkar et al.: How Does Batch Normalization Help Optimization?, arXiv:1506.01497, 2019.
- [Shimodaira 00] H. Shimodaira: Improving predictive inference under covariate shift by weighting the log-likelihood function, JSPI 90(2):pp227-244, 2000.
- [Xavier 11] G. Xavier et al.: Deep Sparse Rectifier Neural Networks, 14th AISTATS, pp315-323, 2011.
- [齋藤 19] 齋藤彰儀, 上総虎智, 平木悠太, 天方匡純, 吉田武司: 深層学習によるコンクリート護岸劣化領域検出システムの開発, デジタルプラクティス Vol.10 No.2, 情報処理学会, 2019.