

## DCGAN を用いた不定形画像の Data Augmentation 手法の検討

A Study of Data Augmentation Method to Focus on Unstructured Shape of Images Using DCGAN

松川 義秋<sup>†</sup>

Yoshiaki Matsukawa

鈴木 昭弘<sup>†</sup>

Akihiro Suzuki

川上 敬<sup>†</sup>

Takashi Kawakami

竹沢 恵<sup>†</sup>

Megumi Takezawa

大江 亮介<sup>†</sup>

Ryosuke Ooe

## 1. はじめに

近年, Convolutional Neural Network(CNN)による, 画像認識技術が発展している. AlexNet, VGGNet, Residual Networks (ResNet)などの様々な深層ネットワークモデルが, 画像認識技術の発展に貢献している. しかし, 深層学習では, 正確にクラス分類された大量の画像が必要であることが課題となっている. そこで, データ不足の解決策として, Data Augmentation がある.

Data Augmentation とは, 回転, 反転, シフト移動, および階調処理などを施すことでデータの水増しを行なうことである. しかしながら, この従来手法では, すべてに適応するには不十分である. よって, 適応範囲を広げるために, Data Augmentation 手法を増やしていく必要がある.

最近では, 敵対的生成ネットワーク(GAN)[1]による Data Augmentation 手法がみられており, 精度の向上が確認されている[2][3]. GAN は深層ネットワークを利用した画像生成技術である.

本研究では, Data Augmentation の対象とする画像として, 化学反応物, 気象画像などの形状が定まっていない画像に注目した. このような画像を不定形画像と定義する. 不定形画像においては, 形状が定まっていないことから, ランダムな画像生成との相性が良いと推測した. そこで, ランダムノイズを入力することで画像を生成する Noise-to-Image 手法がある. その手法の一つである DCGAN[4]を利用した. DCGAN を用いて不定形画像の Data Augmentation 手法の検討を行なう.

## 2. 方法

## 2.1 データセット

データは, 河川水の浄水処理において行なわれる凝集処理の際に生じたフロックという凝集物の画像である.

データセットは水濁度の濃度により GROUP1, 2, 3 の 3 パターンに分割をした. フロック画像の特徴は不定形の様子を表していることが見て取れる. そして, 水濁度によって, フロックの形状が




図 1 フロックの画像

表 1 水濁度の分類の表

分類	水濁度(NTU)
GROUP 1	0.1 - 0.5(未満)
GROUP 2	0.5 - 1.0(未満)
GROUP 3	1.0 以上

異なることが確認されている. フロックの画像を図 1 に示す. 表 1 は水濁度による分類の表である.

## 2.2 実験の概要

本研究では, 不定形画像における DCGAN を用いた Data Augmentation 手法の有効性を示すことを目的とする.

実験 1: DCGAN のハイパーパラメータの調整を施し, 画像生成を行なう

実験 2: 実験 1 で生成された画像をデータセットに追加し, 調整済み分類ネットワークを使用して精度の検証を行なう

実験 1 は目視判断で利用可能であると判断した画像が生成された段階で調整を終了する. 調整終了した時点の重みを保存し Generator のみを取り出す. 実験 2 の CNN ネットワークは AlexNet を利用した. 実験の構成を図 2 に示す.

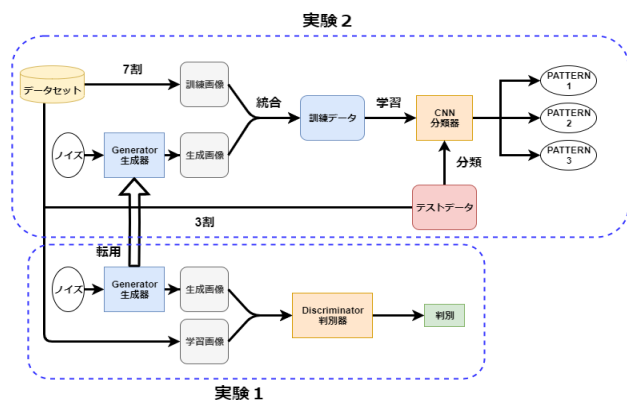


図 2 本研究における実験の構成

<sup>†</sup> 北海道科学大学 Hokkaido University of Science

### 3. 実験 1 : DCGAN のハイパーパラメータ調整

実験 1 では、深層ネットワークの構成と最適化アルゴリズムの調整を施し、目視で利用可能であると判断できるまで DCGAN の画像生成の試行をした。画像の生成結果を図 3 に示す。最も良かった調整結果として、DCGAN の Generator(G)と Discriminator(D)の最適化アルゴリズムは G を (Adam=学習率: 0.00008), D を (SGD=学習率: 0.00006, momentum: 0.5)と設定した。Batch Normalization の momentum は 0.8, 学習回数は 100,025epoch 行なった。調整を施した Discriminator と Generator のネットワークの構成を表 2, 3 に示す。




図 3 DCGAN の生成画像の結果

表 2 Discriminator の構成

層	処理・操作
1	Dense/Reshape/Batch Normlization(BN)
2	Upsampling/Convolution(1024)/LeakyRelu/BN
3	Upsampling/Convolution(512)/LeakyRelu/BN
4	Upsampling/Convolution(256)/LeakyRelu/BN
5	Upsampling/Convolution(128)/LeakyRelu/BN
6	Upsampling/Convolution(64)/LeakyRelu/BN
7	Upsampling/Convolution(32)/LeakyRelu/BN
8	Convolution(chanel)/Activation(tanh)

表 3 Generator の構成

層	処理・操作
1	Convolution(32)/LeakyRelu/BN
2	Convolution(64)/LeakyRelu/BN
3	Convolution(128)/LeakyRelu/BN
4	Convolution(256)/LeakyRelu/BN
5	Convolution(512)/LeakyRelu/BN
6	Convolution(1024)/LeakyRelu/BN
7	Flatten/Dense/Activation(sigmoid)

### 4. 実験 2 : 有効性の検証

実験 2 では、Data Augmentation 手法の比較対象として、回転・反転処理を挙げた。データセット数は 882 枚で学習を行なった。AlexNet から分類の accuracy を算出した(表 4)。

表 4 各手法の精度の表

手法	Accuracy (%)	拡張なしとの差
拡張なし	58.37	-
回転・反転	64.63	+6.26
DCGAN	63.80	+5.43

True Label	Predicted Label			Predicted Label			Predicted Label		
	G1	G2	G3	G1	G2	G3	G1	G2	G3
G1	54.5%	34.8%	10.6%	60.6%	37.9%	1.56%	69.7%	25.8%	4.55%
G2	16.7%	71.7%	11.7%	28.3%	53.3%	18.3%	33.3%	45.0%	21.7%
G3	7.78%	43.3%	48.9%	6.67%	13.3%	80.0%	7.78%	15.6%	76.7%
	拡張なし			回転・反転 拡張			DCGAN 拡張		

図 4 各手法の混同行列

回転・反転による拡張が約 6%, DCGAN による拡張が約 5%の精度の向上が確認された。このことから、回転・反転による拡張と同等の効果があることを確認できた。

さらに、各手法を混同行列により精度の確認を行なった(図 4)。拡張なしの場合と Data Augmentation 手法を施した場合を比較すると、GROUP1, 3 の精度向上がみられた。しかし、GROUP2 の精度の低下がみられ、特徴の捉え方が変わっていることがわかる。

これは、Data Augmentation によって GROUP1, 3 の特徴を捉えやすくなり、GROUP1, 3 の中間の特徴を持つ GROUP2 が他の GROUP の特徴に影響されたと推測する。

この結果から、特徴の曖昧性が助長されたと考えられる。したがって、各 GROUP の特徴が強い画像を選別しデータの拡張を行なうことで精度向上が見込めるはずである。

### 5. まとめ

本研究では DCGAN を用いた Data Augmentation 手法の有効性を検証した。従来の Data Augmentation 手法と同等の効果を得られることを示した。しかし、大幅な精度向上がみられなかった。今後は、特徴の強い画像の選別を施し、Data Augmentation 手法の有効性を高めていきたい。

#### 参考文献

- [1] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio, "Generative Adversarial Nets," Advances in Neural Information Processing Systems, pp.2672-2680, Dec. 2014.
- [2] Fabio Henrique Kiyotiti dos Santos Tanaka, Claus Aranha, "Data Augmentation Using GANs," 19 Apr 2019
- [3] Veit Sandfort, Ke Yan, Perry J. Pickhardt, Ronald M., "Data augmentation using generative adversarial networks (CycleGAN) to improve generalizability in CT segmentation tasks," 15 November 2019
- [4] Alec Radford, Luke Metz, Soumith Chintala, "Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks," 7 Jan 2016