

# 遺伝的アルゴリズム・深層生成モデルを用いた打音の生成 および打音探査の定量的評価精度の向上

岡本 誠史<sup>†</sup> 新保 弘<sup>‡</sup> 佐野 俊介<sup>‡</sup> 溝渕 利明<sup>‡</sup> 野嶋 潤一郎<sup>§</sup> 尾関 智子<sup>†</sup>  
東海大学<sup>†</sup> 法政大学<sup>‡</sup> J-POWER 設計コンサルタント<sup>§</sup>

## 1. はじめに

コンクリート構造物の内部の劣化状態を評価する方法に打音探査がある。これは、コンクリートをハンマーで叩いたときの音により、コンクリート内部に欠陥がないか調査する方法である。新保ら[1]などにより、打音の特性を定量化する試みは行われているが、打音は劣化状態だけでなく構造物の状態や環境にも影響を受け、採取するサイトによって打音の性質にも差異が生じることから、汎化性能のある特徴抽出が難しい。

本研究では、機械学習による判別モデルの精度を向上させるため、多サイト間における打音の性質の差異を考慮する多目的遺伝的アルゴリズムを用いた打音波形のスカログラムを得る際の最適化方法と、深層生成モデルによるデータ拡張方法を提案する。

## 2. 打音データセットと特徴抽出

特徴抽出方法の最適化、生成モデルの作成、生成データによるデータ拡張の評価を行うにあたり、新保ら[1]による、塩害劣化した鉄筋コンクリート製橋脚(劣化度大)の打音のデータセットIと、名古屋大学のN2U-BRIDGE [2](さまざまな劣化度)の打音のデータセットN, 地方自治体管理の沿岸部小規模橋梁[3]で採取した打音のデータセットSを用いる。なお、全てのデータはサンプリング周波数44,100Hzで5msの波形である。

多目的遺伝的アルゴリズムのNSGA-III[4]を用いて打音波形をスカログラム変換する際の最適なパラメータを探索する。最適化においては、健全(N)・欠陥(D)のニューラルネットワーク内の潜在表現およびスカログラム画像の見た目の差異がより大きくなるようにする。最適化に用いる健全・欠陥それぞれのデータ数 $n_N, n_D$ は、データセットI・N・D全てから健全・欠陥それぞれ20個ランダムに抽出し、 $n_N, n_D = 60$ とする。

従属変数 $x$ は4種類とする。 $x_1, x_2$ はそれぞれComplex Morlet Waveletのbandwidthとcenter frequencyとし、スカログラム変換の基底関数を式(1)のように定義する。

$$\psi(t) = \frac{1}{\sqrt{\pi x_1}} e^{-\frac{t^2}{x_1}} e^{j2\pi x_2 t} \quad \dots(1)$$

また、 $x_3, x_4$ はスカログラム変換後の周波数方向におけるクロップ範囲のパラメータであり、 $x_3$ はクロップ範囲の下限周波数 $f_{min}$ である。 $x_4$ は式(2)に示すクロップ範囲の上限周波数 $f_{max}$ を決定する。

$$f_{max} = f_{min} + x_4(f_n - f_{min}) \quad \dots(2)$$

なお、打音波形のナイキスト周波数を $f_n$ とする。

式(3)に示すように、目的関数 $F$ を4種類定義する。

$$F(x) = \begin{cases} F_1(x) = \frac{1}{n_N} \sum_{i=1}^{n_N} [\|V\{|W|_{(N,i)}^x\} - \mu_N\|_2]^2 \\ F_2(x) = -\sqrt{\frac{(\mu_D - \mu_N)^T \Sigma_N^{-1} (\mu_D - \mu_N)}{(\mu_N - \mu_D)^T \Sigma_D^{-1} (\mu_N - \mu_D)}} \\ F_3(x) = -\sqrt{\frac{(\mu_N - \mu_D)^T \Sigma_D^{-1} (\mu_N - \mu_D)}{(\mu_D - \mu_N)^T \Sigma_N^{-1} (\mu_D - \mu_N)}} \\ F_4(x) = SSIM \left\{ \frac{1}{n_N} \sum_{i=1}^{n_N} |W|_{(N,i)}^x, \frac{1}{n_D} \sum_{i=1}^{n_D} |W|_{(D,i)}^x \right\} \end{cases} \quad \dots(3)$$

$F_1(x), F_2(x), F_3(x)$ はSqueezeNet[5]の特徴ベクトル空間 $V$ を用いた関数であり、 $F_4(x)$ は健全・欠陥スカログラムの平均画像同士のSSIMである。ただし、ある健全・欠陥打音波形を変換したスカログラム画像をそれぞれ $|W|_{(N,i)}^x$ と $|W|_{(D,i)}^x$ 、 $V$ における健全・欠陥特徴ベクトルのそれぞれの平均を $\mu_N$ と $\mu_D$ 、健全・欠陥特徴ベクトルのそれぞれの分散共分散行列を $\Sigma_N$ と $\Sigma_D$ とする。

制約条件を $2^{-2} \leq x_1 \leq 2^2, 2^{-2} \leq x_2 \leq 2^2,$

$500 \leq x_3 \leq f_n - 50, \frac{50}{f_n - 500} \leq x_4 \leq 1$ として最適化を行う。初期個体数1,024で128世代目の目的関数空間におけるパレート解重心から最もユークリッド距離に近い個体の従属変数空間のパラメータにより、スカログラムによる打音の特徴抽出を行う。また、変換後のスカログラムは、時間方向が線形スケール、周波数方向が対数スケールで、22x22のグレースケール画像とする。

## 3. 深層生成モデルによる打音データの生成

表1にしたがって、データセットIにより、打音の健全・欠陥のFakeデータをそれぞれ生成するCGAN[6]とVAE[7]の作成を行う。それぞれ健全・欠陥各100のRealデータをもとに10000epochまで訓練させる。その中のReal健全・Fake健全間のFID[8]が最低値となったepoch数で、健全・欠陥各100のFakeデータ生成を行う。

## 4. データ拡張の精度検証方法

特徴抽出方法の最適化と生成データによるデータ拡張の精度を、図1のCNNと図2のLSTMのK-分割交差検証法( $k=4$ )による訓練・テストによって検証する。深層生成モデルによるデータ生成を経て、新たに作成したデータセットのうち、CNNとLSTMの訓練データとして用いるデータセットを表2に、テストデータについては表3に示す。なお、訓練データはデータセットI, テストデータはデータセットIまたはSに属する。

表1. 生成モデルの詳細

モデル	訓練に用いる データセット内訳	訓練 epoch	生成する Fakeデータ内訳
CGAN	I(N:100, D:100)	9000	I(N:100, D:100)
VAE	I(N:100, D:100)	5500	I(N:100, D:100)

Improvement Accuracy on Impact-Echo Monitoring by Generation of Impact-Echo Using Deep Generative Model and Genetic Algorithm Masafumi Okamoto<sup>†</sup>, Hiroshi Shimbo<sup>‡</sup>, Shunsuke Sano<sup>‡</sup>, Toshiaki Mizobuchi<sup>‡</sup>, Junichiro Nojima<sup>§</sup>, Tomoko Ozeki<sup>†</sup>

<sup>†</sup> Tokai University, <sup>‡</sup> Hosei University, <sup>§</sup> J-Power Design Co., Ltd.

5. 実験結果と今後の展望

特徴抽出の最適化前・後における、それぞれの訓練データによる K-分割交差検証のテスト精度平均をそれぞれ表 4, 表 5 に示す。訓練・テストともに Real Only(I) である場合は精度が最適化前後でそれぞれ 0.9 以上となっている。一方で訓練データがデータセット I に属し、テストデータがデータセット S に属す場合は、全体的に 0.5 から 0.6 前後の精度となっているが、最適化後では精度が高くなる傾向がある。さらに、最適化後のデータ拡張後では、精度が高い傾向があり、最適化のみでデータ拡張を行っていない場合と比べても精度が高い傾向がある。したがって、異なるサイト間における判別において、特徴抽出方法の最適化と生成モデルによるデータ拡張の有効性が示された。

今後の展望として、特徴抽出方法の最適化においては Earth Mover's Distance や cos 類似度などの類似度指標を導入することが考えられる。さらに、生成モデルによるデータ拡張においては Flow-based モデルの導入により、判別精度の向上を試みる。

謝辞

データ採取および提供にご協力いただいた名古屋大学 N2U-BRIDGE に感謝申し上げます。

参考文献

[1] 新保 弘, 溝渕 利明, 野嶋 潤一郎, “打音探査への機械学習の適用に関する基礎的検討”, コンクリート工学年次論文集, vol141, No.1, 2019

[2] 名古屋大学, N2U-BRIDGE, 橋梁長寿命化推進室, Web ページ, <https://www.n2u-bridge.jp>

[3] H. Shimbo, T. Mizobuchi, T. Ozeki, J. Nojima, S. Sano, M. Okamoto, and T. Shizuno, “Improved generalization capability in machine learning approaches for impact-echo test”, submitted to SynerCreate' 23, 2023

[4] K. Deb, and H. Jain, “An Evolutionary Many-Objective Optimization Algorithm Using Reference-point Based Non-dominated Sorting Approach, Part I: Solving Problems with Box Constraints”, IEEE Transactions on Evolutionary Computation, 18(4), 2014

[5] F. N. Iandola, S. Han, M. W. Moskewicz, K. Ashraf, W. J. Dally, and K. Keutzer, “SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size”, <https://arxiv.org/abs/1602.07360>, 2016

[6] M. Mirza, and S. Osindero, “Conditional Generative Adversarial Nets”, <https://arxiv.org/abs/1411.1784>, 2014

[7] D. P. Kingma, and M. Welling, “Auto-Encoding Variational Bayes”, <https://arxiv.org/abs/1312.6114>, 2013

[8] M. Heusel, H. Ramsauer, T. Unterthiner, B. Nessler, and S. Hochreiter, “GANs Trained by a Two Time-Scale Update Rule Converge to a Local Nash Equilibrium”, <https://arxiv.org/abs/1706.08500>, 2017

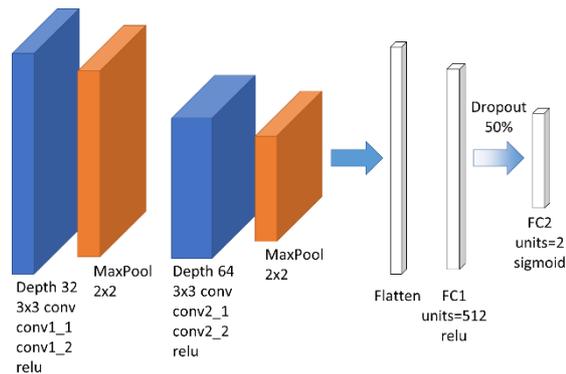


図 1. CNN の構造

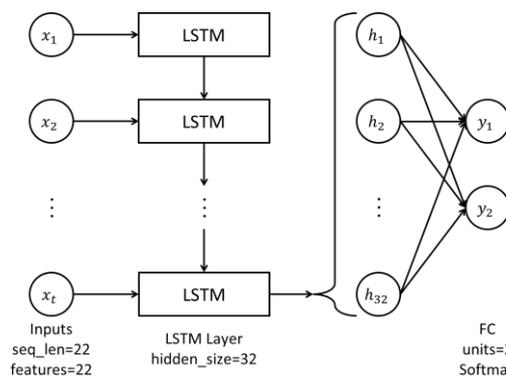


図 2. LSTM の構造

表 2. CNN と LSTM の訓練データとして用いるデータセット

データセット名	Real		Fake	
	F	D	F	D
Real Only (I)	100	100	-	-
Real + CGAN Fake (I)	100	100	100	100
Real + VAE Fake (I)	100	100	100	100

表 3. CNN と LSTM のテストデータとして用いるデータセット

データセット名	Real		Fake	
	F	D	F	D
Real Only (I)	52	52	-	-
Real Only (S)	60	60	-	-

表 4. テスト精度平均(特徴抽出最適化前)

訓練データ	テストデータ	テスト精度平均	
		CNN	LSTM
Real Only (I)	Real Only (I)	1.000	0.978
Real Only (I)	Real Only (S)	0.519	0.496

表 5. テスト精度平均(特徴抽出最適化後)

訓練データ	テストデータ	テスト精度平均	
		CNN	LSTM
Real Only (I)	Real Only (I)	0.990	0.964
Real Only (I)	Real Only (S)	0.581	0.504
Real + CGAN Fake (I)	Real Only (S)	0.615	0.517
Real + VAE Fake (I)	Real Only (S)	0.623	0.515