

# 深層学習を用いた E C T 信号からのキズ深さ同定

Flaw Depth Identification from ECT Signal Using Deep Learning

東京大学  
東京大学

出町 和之  
堀 智之

Kazuyuki DEMACHI Member  
Tomoyuki HORI Non-Member

A deep learning model has been proposed to estimate flaw depth from ECT signals. The applicability of deep learning to data mixed with unknown parameters for defects was verified. The applicability of deep learning to data assuming lift-off fluctuation during measurement was verified.

**Keywords:** Deep Learning, Eddy Current Testing, Lift-off Fluctuation, Convolutional Neural Network

## 1. はじめに

加圧水型軽水炉(Pressurized Water Reactor, PWR)における蒸気発生器伝熱管の破損は一次冷却水の二次系への急速な漏洩をもたらし、漏洩量が多い場合には原子炉緊急炉心冷却システム (Emergency Core Cooling System, ECCS) の作動もあり得る。このような事態を防止するために、日本では定期検査の実施によって伝熱管にひび割れや欠陥が無いことを確認している。渦電流探傷試験(Eddy Current Testing, ECT) [1, 2]は導電性材料のき裂や欠陥を検出するための非破壊検査方法であり、とくに伝熱管など厚みの薄い構造物に対して有効な手法である。ECT は欠陥形状推定に逆問題解析を用いるが、多くの場合において大きな CPU 時間とメモリを必要とする。そこで本研究では、深層学習(Deep Learning, DL) [3, 4]モデルの適用を提案し、キズ深さの高速推定の可能性を示した。また、学習データに未知のパラメータが多数混合する場合は、測定中にリフトオフが変動する場合など、一般的な逆問題解析では困難とされる場合に対する適用性を検証した。

## 2. 手法

### 2.1 渦電流探傷信号の取得

#### 2.1.1 シミュレーション体系

加圧水型原子炉の伝熱管に対して渦電流探傷試験を行うとき、実際には以下の Fig. 1 のように伝熱管内部を通すことで試験を行う。

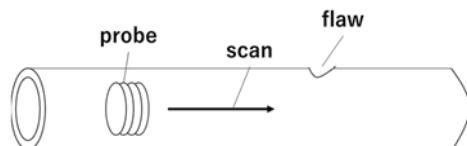


Fig. 1 Schematic of ECT for heat transfer tubes

また今回使用したデータの渦電流探傷試験の数値シミュレーションの構成を Fig. 2 に示す。今回は日本保全学会のベンチマーク問題のデータ[5]を使用させていただいた。試験片は Ni ベースの平板であり、比透磁率及び導電率はそれぞれ 1 及び 1MS / m に設定されている。

キズは幅と深さが一定の十分に長い長方形の領域としてモデル化されており、キズ領域では等価導電率は均一とされている。渦電流プローブの走査方向はキズを垂直に横切るものとし、信号収集範囲はキズの直上( $x = 0\text{mm}$ )から  $x = 30\text{mm}$  までとされている。また、渦電流プローブにはプラスポイントプローブが用いられている。

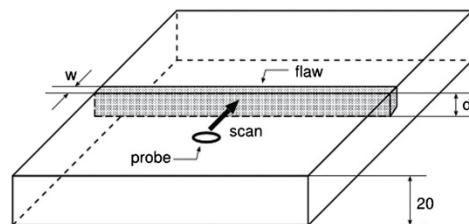


Fig. 2 Configuration of numerical simulation of ECT

#### 2.1.2 欠陥とプローブのパラメータ

ベンチマーク問題では、キズ深さ( $d$ )、キズ幅( $w$ )、キズ領域の母材に対する等価導電率( $S_r$ )、コイル径( $ID$ )、リフトオフ( $L$ )、励磁周波数( $f$ )の 6 種の条件を Table 1 に示す値のすべてについて組み合わせた場合のコイル測定信

連絡先:出町和之、〒113-8654 東京都文京区本郷 7-3-1,  
東京大学大学院工学系研究科原子力専攻,  
E-mail: demachi@n.t.u-tokyo.ac.jp

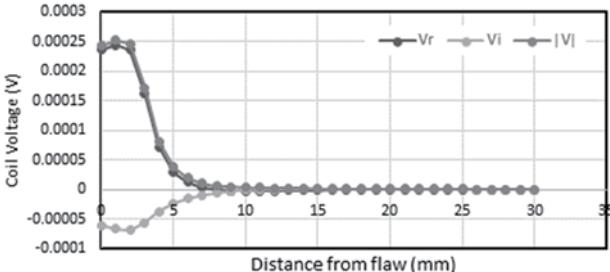
号が計算されている。

**Table 1 Condition of the flaw and coil used in the benchmark test [3]**

Flaw	Depth, d[mm]	0.2, 0.4, 0.6, 0.8, 1.0, 1.5, 2.0, 2.5, 3.0
	Width, w[mm]	0.001, 0.002, 0.005, 0.010, 0.020, 0.050, 0.100, 0.200, 0.500
	Relative conductivity, $s_r$	0.000, 0.0100, 0.0125, 0.0167, 0.0250, 0.0500 ... 0.5000
Probe	Frequency, f [kHz]	25, 100, 400
	Coil diameter, ID [mm]	1, 3, 5, 7
	Lift-off, L [mm]	1, 3, 5

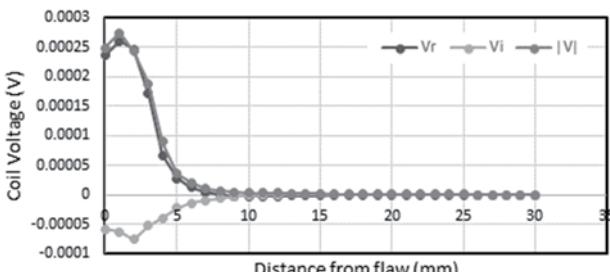
### 2.1.3 涡電流探傷信号と学習用データ

ベンチマーク問題における数値シミュレーションでは、出力はコイル電圧  $V$  の実数成分  $V_r$ 、虚数成分  $V_i$ 、絶対値  $|V|$  の3値が計算されている。その一例を Fig. 3 に示す。



**Fig. 3 Voltage of the probe when  $L=1\text{mm}$ ,  $ID=1\text{mm}$ ,  $f = 25\text{kHz}$  and  $Sr = 0$  by numerical simulation. [3]**

また、深層学習において過学習を避け、汎化性能を上げるために、これらの信号データを測定点ごとに最大 10%の範囲でランダムに変化させたものを作成し、これを学習用データとした。その一例を Fig. 4 に示す。



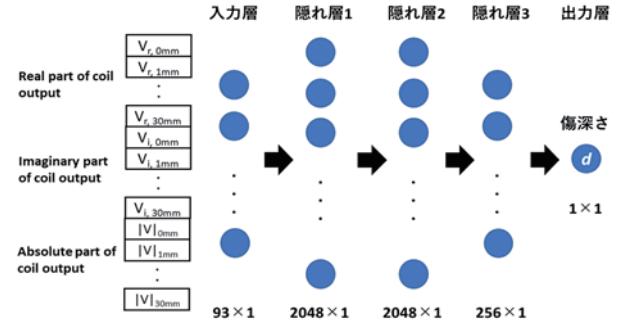
**Fig. 4 Voltage of the probe with random noise up to 10% when  $L = 1\text{mm}$ ,  $ID = 1\text{mm}$ ,  $f = 25\text{kHz}$  and  $Sr = 0$  by numerical simulation.**

## 2.2 深層学習による学習

### 2.2.1 全結合型(FCNN, Full Connected Neural Network)[4]

全結合型はニューラルネットワークの構造で最もシンプルなものである。ここでは 31 測定点における ECT 信

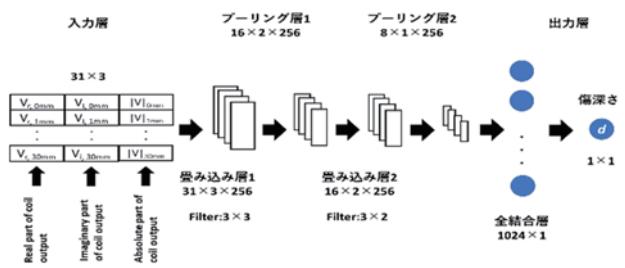
号  $V_r, V_i, |V|$  を Fig. 5 のように  $93 \times 1$  の 1 次元ベクトルとして入力し、キズ深さ  $d$  を出力させた。隠れ層は 3 層あり、各々のノード数は 2048, 2048, 256 とした。



**Fig. 5 Network Structure of FCNN.**

### 2.2.2 畳み込みニューラルネットワーク(CNN, Convolutional Neural Network)[5]

CNN は画像認識に多用されているモデルであり、畳み込み層で局所的な特徴を捉え、プーリング層で位置普遍性を確保している。ここで 31 測定点における ECT 信号  $V_r, V_i, |V|$  を  $31 \times 3$  の 2 次元配列の画像の様にして CNN の入力とし、キズ深さ  $d$  を出力させた。また、畳み込み層、プーリング層がそれぞれ 2 層あり、全結合 1 層という構造をしている。



**Fig. 6 Network Structure of CNN.**

### 2.2.3 段階的な条件設定

Table 2 に深層学習におけるリフトオフ  $L$  と等価導電率  $Sr$  の 5 段階の学習条件を示す。段階 1 で深層学習の実装の確認を目的とし、 $L(=1,3 \text{ or } 5\text{mm})$  は既知として混合せず、また  $Sr=0\%$  に固定して学習を行った。段階 2 では  $L$  が未知である場合を想定して  $L=1, 3, 5\text{mm}$  の場合の ECT 信号を混合した学習用データを用いた。段階 3 ではさらに  $Sr$  が未知であることを想定し、 $Sr = 0\text{~}50\%$  の場合の ECT 信号を混合して学習用データとした。段階 4 では  $L$  が走査中に変動することを考慮して、測定点毎に  $L=1,3 \text{ or } 5\text{mm}$  の場合の ECT 信号からランダムに選択した学習用データを作成した。段階 5 では  $L$  の変動幅を土

1mm に限定し、測定点毎に  $L=1$  or  $3\text{mm}$  のときの ECT 信号からランダムに選択した学習用データと、 $L=3$  or  $5\text{mm}$  のときの ECT 信号からランダムに選択した学習用データを作成した。

**Table 2 Training Condition of L and Sr, and its aim**

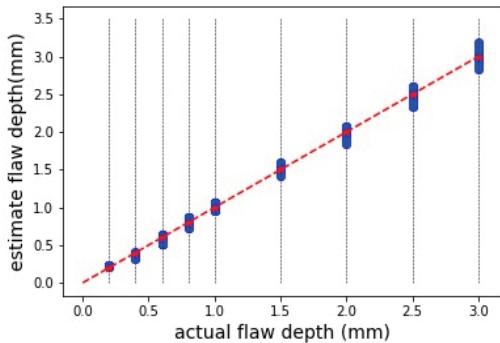
段階	ねらい	L	Sr
1	基本的条件で実装確認	固定	0 %
2	リフトオフが未知	1, 3, 5mm を混合	0 %
3	透過導電率が未知	1, 3, 5mm を混合	0~50 %
4	リフトオフ変動を想定	測定点毎に1, 3, 5mm よりランダム選択	0~50 %
5	リフトオフ変動幅を±1mmに限定	測定点毎に $L=1, 3\text{mm}$ 、及び $L=3, 5\text{mm}$ よりランダム選択	0~50 %

### 3. キズ深さ推定結果

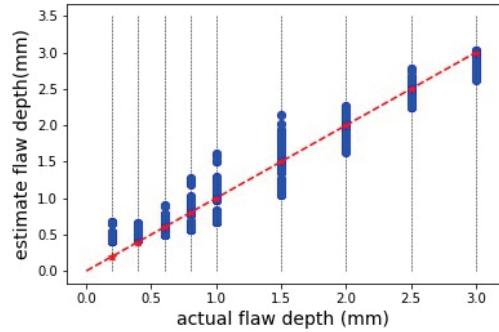
#### 3.1 FCNN を用いたキズ深さ推定

以下のグラフは横軸が正解のキズ深さ(actual flaw depth)、縦軸は学習済みモデルが推定したキズ深さ(estimate flaw depth)である。1データの推定結果は青い点1点に相当し、赤い破線は正解の傷深さと推定した傷深さが一致する場合の理想的な結果を意味する。Fig. 7 と Fig.8 は、ID=1mm,  $L=1\text{mm}$ ,  $f=25\text{kHz}$  の場合の FCNN を用いた段階1と段階2における結果である。

リフトオフ  $L$  と透過導電率  $Sr$  を固定した段階1では推定結果は真のキズ深さと良く一定しているが、 $L$  が未知であることを想定した段階2では誤差が大きくなってしまった。このことより、段階3以降ではFCNNによるキズ深さ推定は行わず、CNNのみを採用した。



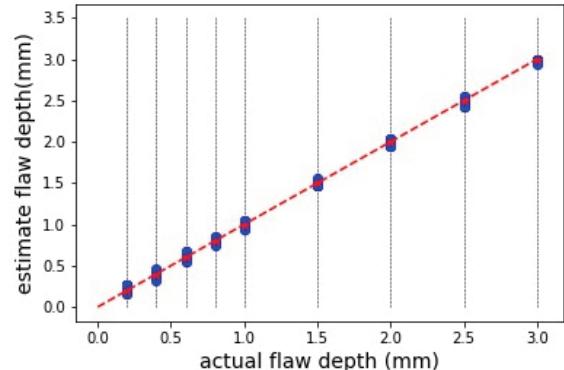
**Fig. 7 Flaw Depth Estimation Result by FNN. ID=1mm,  $L=1\text{mm}$ ,  $f=25\text{kHz}$ . The training condition is step 1.**



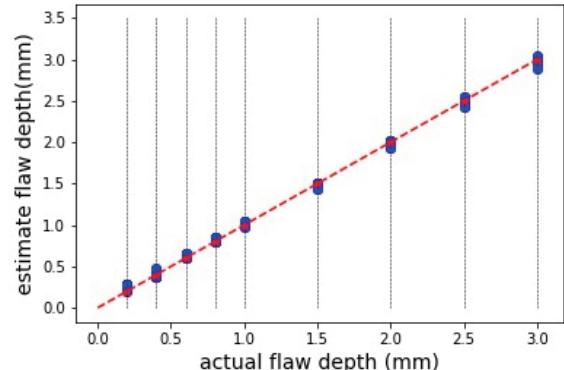
**Fig. 8 Flaw Depth Estimation Result by FNN. ID=1mm,  $L=1\text{mm}$ ,  $f=25\text{kHz}$ . The training condition is step 2.**

#### 3.2 CNN を用いたキズ深さ推定

Fig. 9 は、CNN を用いた段階2のキズ深さ推定結果である。リフトオフ  $L=1,3,5\text{mm}$  の学習データを混合して学習し、 $L$  が未知である条件でキズ深さを推定したが、いずれの場合にも高精度での推定結果が得られた。



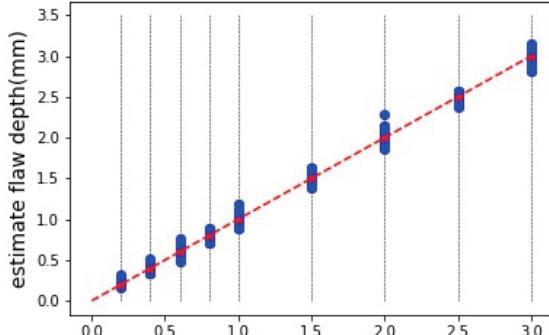
**(a) ID = 1mm,  $f = 25\text{kHz}$**



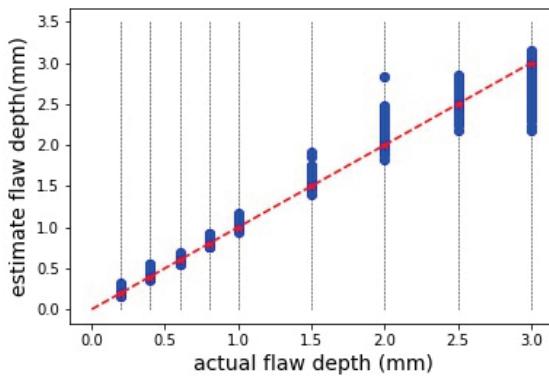
**Fig. 9 Flaw depth estimation results by CNN in the case the lift-off ( $L$ ) were mixed assuming unknown. The flaw depth could be accurately estimated with small error for all cases.**

Fig. 10 は、段階3のキズ深さ推定結果である。リフトオフ  $L=1,3,5\text{mm}$  と等価導電率比  $Sr=0\sim50\%$  の学習データを混合して学習し、 $L$  と  $Sr$  が未知である条件でキズ

深さを推定したが、いずれの場合にも高精度での推定結果が得られた。段階 2 に比べて推定誤差が拡大していることが分かる。



(a) ID = 1mm, f = 25kHz

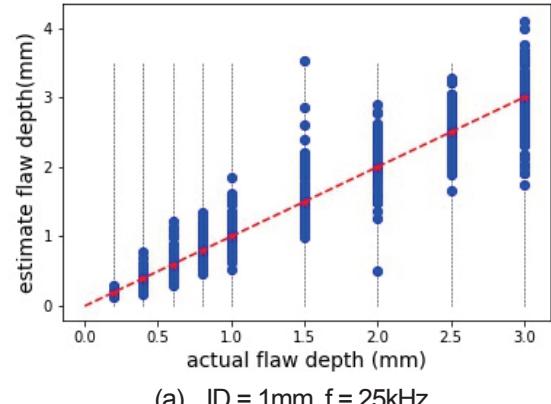


(b) ID = 7mm, f = 400kHz

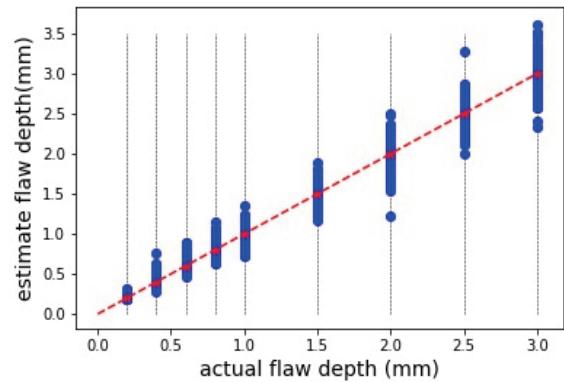
Fig. 10 Flaw depth estimation results by CNN under the conditions that the equivalent conductivity ratio  $S_r$  were mixed in the range of 0 to 50%. The flaw depth estimation error is larger for the larger flaw depth.

Fig. 11 は、段階4のキズ深さ推定結果である。リフトオフ  $L=1,3,5\text{mm}$  が一定ではなく、測定時に変動することを想定して学習データを作成し、推定時のテストデータでもリフトオフが変動する場合のECT信号を用いた。これにより、推定誤差の大きさがさらに拡大している。この原因としては、測定点毎に  $L=1\sim 5\text{mm}$  の範囲で変動するリフトオフを想定したこと、学習データのECT信号がFig. 12 のように強い揺動成分を有してしまい、元のECT信号の特徴が大きく損なわれたためだと考えられる。

そこで次に、段階5においては、リフトオフ変動幅を  $\pm 1\text{mm}$  に限定して測定点毎に  $L=1$  or  $3\text{mm}$ 、及び  $L=3$  or  $5\text{mm}$  よりランダム選択して学習データおよびテストデータを作成した場合の結果をFig. 13に示す。段階4の場合に比べてキズ深さ推定誤差が縮小した。



(a) ID = 1mm, f = 25kHz



(b) ID = 7mm, f = 25kHz

Fig. 11 Flaw depth estimation results by CNN under the conditions that the equivalent conductivity ratio  $S_r$  were mixed in the range of 0 to 50%, and  $V_r$ ,  $V_i$ , and  $|V|$  when the liftoff were randomly selected from  $L = 1, 3, 5\text{ mm}$  at each measurement position.

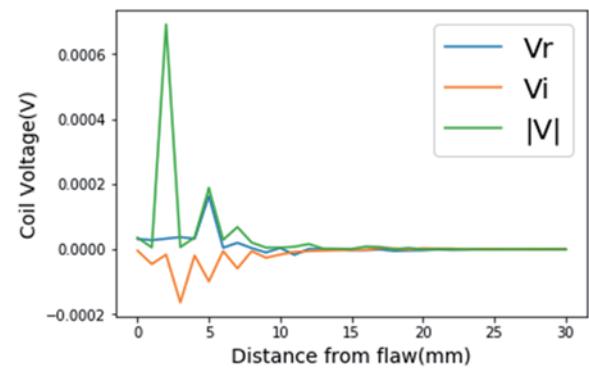
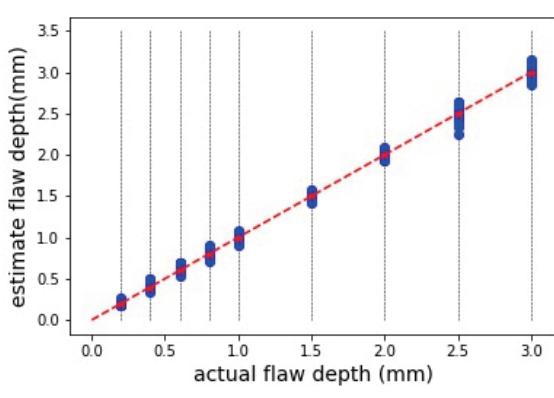
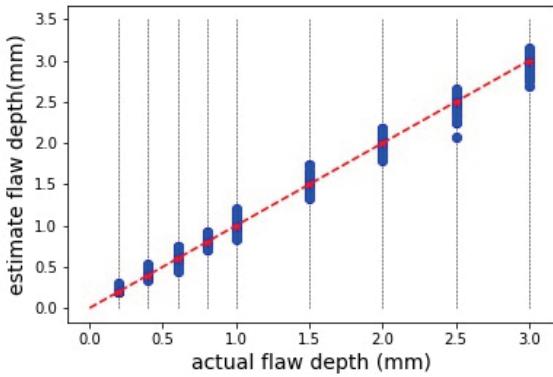


Fig. 12 An example of input data of  $V_r$ ,  $V_i$  and  $|V|$  for step 4. The values of  $V_r$ ,  $V_i$  and  $|V|$  greatly fluctuated at every measurement position of 1 mm, because the liftoff were randomly selected from  $L = 1, 3, 5\text{ mm}$  for each measurement position.

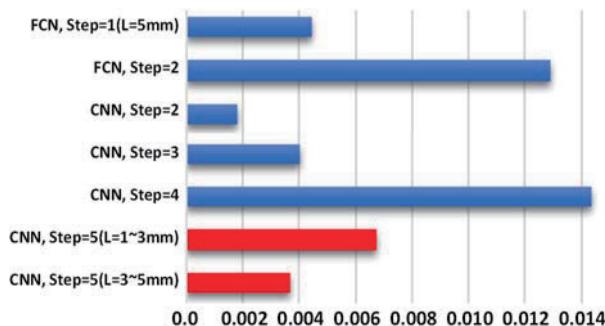


**Fig. 13 Flaw depth estimation results by CNN under the conditions that the equivalent conductivity ratio  $S_r$  were mixed in the range of 0 to 50%, and  $V_r$ ,  $V_i$ , and  $|V|$  when the liftoff were randomly selected from  $L = 1\text{-}3\text{mm}$  and  $L = 3\text{-}5\text{mm}$  at each measurement position.**

## 4. 考察

### 4.1 キズ深さ推定誤差の比較

Table 2 のすべての条件のに対する欠陥深さ推定の二乗平均平方根誤差(RMSE)を Fig. 14 に示す。実際の走査状況に最も近い段階 5 における CNN による RMSE は約 0.07 と 0.4 に抑制されており、欠陥深さ推定方法としての CNN モデルの有用性が示された。

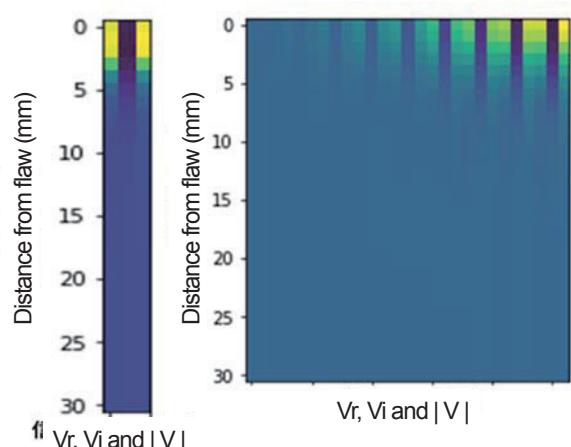


**Figure 14. Root mean square error of flaw depth estimation for step 1-5 by FCNN or CNN.**

### 4.2 FCNN と CNN の比較

30mm 分の測定データ 1000 個(30m 分)のキズ深さ推定時の計算時間は FCNN, CNN でそれぞれ 0.04, 0.23 秒であった。FCNN の方が短いが、いずれも十分に短時間で推定を行えたといえる。

段階 2 の結果を比較すると、CNN の方が高い精度であった。Fig. 15 左は CNN の入力の一例であり、縦が測定点 x、横が ECT 信号のチャンネルとして二次元配列として画像化したものである。Fig. 12 右は左の画像を傷深さ 0.2~3.0mm までのデータを横に結合して表示したものである。このように信号の大きさだけではなく、信号の増減、同じ測定点における他のチャンネルの信号データとの関係性のような情報も重要であり、CNN はこの情報をそのネットワークの構造から適切に捉えることができたものと考える。



**Fig. 15 Two-dimensional array representation of ECT signal when ID = 1 mm, w = 0.001 mm, L = 1 mm, f = 25 kHz,  $S_r = 0\%$  and d = 0.2 mm (left) and ID = 1 mm, w = 0.001 mm, L = 1 mm, f = 25 kHz,  $S_r = 0\%$  and d = 0.2 ~ 3.0 mm (right).**

### 4.3 プローブ周波数と推定精度

Table 2 の全ての学習段階の結果において  $f=25\text{kHz}$  の低周波の場合に高い推定精度が得られた。ECT 信号の表皮深さ :

$$\rho = \frac{1}{\sqrt{\pi\sigma f\mu}}$$

は  $f=25, 100, 400\text{kHz}$  でそれぞれ約 3.2, 1.6, 0.8mm であり、キズの表皮深さ以上に深い部分からの ECT 信号が影響が捉えられていないためである。

## 5. 結論

ECT 信号を用いた欠陥深さ推定モデルの学習を行った。

FCNN と CNN の比較では CNN が推定精度の面でより優れたモデルであるといえる。また、不明な欠陥に関するパラメータである母材に対する傷領域の等価導電率を全てまとめて学習を行い、推定を行った場合もプローブのパラメータを適切に固定することで十分良い推定結果を得られた。また、リフトオフ変動を推定した問題においても、リフトオフ変動を 2mm とした場合、十分に良い推定結果を得ることができた。

## 6. 今後の課題

今後は、応力腐食割れなど欠陥部分の等価導電率が一様ではない欠陥に対する本手法の適用を試みる。

## 参考文献

- [1] Z. Chen, K. Miya and M. Kurokawa, "Rapid prediction of eddy current testing signals using A- $\varphi$  method and database", NDT & E International, Vol. 32, No. 1, pp. 29-36 (1999)
- [2] T. Takagi, H. Huang, H. Fukutomi and J. Tnani, "Numerical evaluation of correlation between crack size and eddy current testing signal by a very fast simulator", IEEE Transactions on Magnetics, Vol. 34, No. 5 pp. 2581-2584 (1998)
- [3] Y. Lecun, L. Bottou, Y. Bengio and P. Haffner, "Gradient-based learning applied to document recognition", Proc. IEEE 86, November 11, pp. 2278-2324, (1998).
- [4] A. Krizhevsky, I. Sutskever and G. E. Hinton "ImageNet Classification with Deep Convolutional Neural Networks", Neural Information Processing Systems (NIPS2012)
- [5] N. Yusa and H. Hashizume, "Numerical investigation of the ability of eddy current testing to size surface breaking cracks", Nondestructive Testing and Evaluation, Vol. 32, No. 1, pp. 50-58 (2017)

## 謝辞

渦電流探傷試験の数値シミュレーション結果を、ベンチマーク問題としてご提供頂きました東北大学の遊佐訓孝先生には、心より感謝を申し上げます。