

# 論文 オートエンコーダの再構成誤差を用いた打音によるコンクリートの内部欠陥判定に及ぼす衝撃力の影響

福井 智大\*1・黒田 一郎\*2・歌川 紀之\*3・黒田 千歳\*3

**要旨:** 本研究は、オートエンコーダの再構成誤差（コサイン類似度）を用いた打音によるコンクリートの内部欠陥判定手法を提案し、その有用性とデータ収集時のハンマの衝撃力が判定結果に及ぼす影響について検討を行ったものである。人工欠陥を有する供試体を対象に打音データを収集し、教師データセットとテストデータセットでハンマの衝撃力が同一の条件や食い違う条件の判定を行った。その結果、提案手法によってコンクリートの内部欠陥の有無を正しく判定可能であり、その際、両データセット収集時のハンマの衝撃力を強く、かつ同程度に揃えることで判定性能が向上することがわかった。

**キーワード:** 非破壊検査, 打音, 衝撃力, 内部欠陥, オートエンコーダ, 再構成誤差, コサイン類似度

## 1. はじめに

近年、コンクリート構造物の非破壊検査手法の一つである打音検査に機会学習の導入を試みる研究<sup>1)2)</sup>が多く行われている。これらは打音データの分析・評価を機械化することで効率性や精度の向上が見込めるだけでなく、測定段階においても技能が不要となるなどの利点が挙げられ、将来的な検査に従事する技術者不足の解決策としても期待される。そのことから著者らもこれまでにニューラルネットワークを用いたコンクリートの内部欠陥や鉄筋腐食の判定手法を提案し、データセットの質が判定結果に及ぼす影響について検討を行ってきた<sup>3)~5)</sup>。

しかしながら、これまでの研究で用いてきた手法は陽性（異常有り）の教師データを必要とし、土木構造物の検査への適用を考えると、事前に多様な欠陥、損傷、劣化状態の教師データを網羅的に取得するのは非現実的であり、学習範囲外の状況には対応できないことが予想される。そのため、土木構造物を対象とする場合には、陽性データによる学習が不要で、陰性（正常）データのみで学習し、異常の有無を判定可能とする手法が有効であり、その需要も高いと考えられる。

そこで本研究では、これまでに各種検討を行ってきたニューラルネットワークの一種である、オートエンコーダ<sup>6)</sup>を用いた新たな内部欠陥の判定手法を提案する。オートエンコーダを用いた異常検知手法としては多くの分野で研究<sup>7)8)</sup>がなされているが、土木構造物の打音検査に適用した検討は充分になされていない。なお、オートエンコーダ以外のアルゴリズムとしては打音スペクトルの多次元特徴空間上での位置関係に基づいて学習を行う局所外れ値因子法やk近傍法などに基づく判定手法<sup>9)10)</sup>も提案されており、その有用性が確認されているが、著

者らが重点的に検討を進めてきたデータセットの質は特に考慮されていない。更にオートエンコーダはこれらの学習器に比べて、モデルの改良の余地が多いことから今後も発展性を有する学習アルゴリズムであると考えた。

本研究は、オートエンコーダを用いた打音によるコンクリートの内部欠陥判定手法の有用性と、データセットの質の影響としてデータ収集時のハンマの衝撃力が判定結果に及ぼす影響を、人工欠陥を有する供試体を用いた実験を通して明らかにせんとするものである。

## 2. 実験概要

### 2.1 打音データの収集

図-1に本研究で用いた欠陥供試体の諸元およびデータ収集箇所を、表-1にコンクリートの示方配合を示す。




図-1 欠陥供試体の諸元およびデータ収集箇所

表-1 コンクリートの示方配合

W/C (%)	s/a (%)	空気量 (%)	単位量 (kg/m <sup>3</sup> )				
			水	セメント	細骨材	粗骨材	混和剤
49.5	42.9	4.5	162	327	786	1061	3.27

\*1 防衛大学校 理工学研究科後期課程（学生会員）

\*2 防衛大学校 システム工学群建設環境工学科教授 博(工)（正会員）

\*3 佐藤工業株式会社

表-2 データ区分

区分	欠陥諸元		陽性・陰性 (欠陥の有無)	$P_{max}$ の階級 (範囲 (N))	データ数 (個)
	直径 (mm)	深さ (mm)			
n-S	—	—	陰性 (欠陥無し)	Soft (500~1000)	各60 (各箇所20)
n-H				Hard (1000~1500)	
100-S	100	60	陽性 (欠陥有り)	Soft (500~1000)	各20
100-H				Hard (1000~1500)	
150-S	150	60	陽性 (欠陥有り)	Soft (500~1000)	
150-H				Hard (1000~1500)	
200-S	200	60	陽性 (欠陥有り)	Soft (500~1000)	
200-H				Hard (1000~1500)	

※ $P_{max}$  : 打撃時の衝撃力の時刻歴波形のピーク値


この供試体の内部には、厚さ 25 mm の発泡スチロールでモデル化された円形の人工欠陥（コンクリート表面に平行な欠陥を模擬）が設けられており、本研究では直径 100 mm, 150 mm, 200 mm（いずれも深さ 60 mm）の 3 種類の人工欠陥を対象とした。

打撃は、インパクトハンマ（重さ 160 g, 感度 2.27 mV/N）によって行った。各欠陥箇所は円形全体を、また、供試体端部および人工欠陥から 100 mm 以上離れた 170 mm × 300 mm の健全な領域を 3 箇所設定し、それらの領域をまんべんなく打撃した（図-1）。この際、本研究では打撃時の衝撃力の影響を調べるため、打撃時の衝撃力の時刻歴波形のピーク値（最大衝撃力  $P_{max}$  と定義）を、Soft（500~1000 N）、Hard（1000~1500 N）からなる二つの階級に分類し打撃を行った（表-2）。なお、人工欠陥の中央付近と円の外側付近では打音の特性が異なることが考えられるが、本研究では打音データを人工欠陥上の打撃位置で区分せず、すべて混合させた状態でデータベース化しているため、打撃位置の影響については考慮できていない。打音は、各データ収集箇所から法線方向に 300 mm 離れた位置に設置したマイクロフォン（感度 45.8 mV/Pa, 測定レンジ ± 約 100 Pa, 周波数範囲 0.4 Hz~10 kHz）によって収録し、データレコーダを用いてサンプリングレート 100 kS/s（1 秒間で 10 万サンプル）で音圧時刻歴として記録した。


打音データは、表-2 に示す通り、欠陥の有無（陽性/陰性）、欠陥の直径（100 mm/150 mm/200 mm）、 $P_{max}$  の階級（Soft/Hard）によって八つの区分に分けられ、陰性（欠陥無し）データは各区分 60 個、陽性（欠陥有り）データは各区分 20 個のデータを用意した。

## 2.2 打音データの処理

収集した音圧時刻歴を離散フーリエ変換によって振幅



(a)  $P_{max}$  の階級 : Soft



(b)  $P_{max}$  の階級 : Hard

図-2 スペクトルの一例

スペクトルに（以下、スペクトル）変換した。その際の音圧時刻歴のサンプル長さは余韻を含めた 40 ms とし、窓関数として Hann 窓を適用して周波数分解能 25 Hz のスペクトルを得ている。本研究では、次節のオートエンコーダの入力データとして用いるスペクトルの周波数帯域を 100~10000 Hz に設定したため、入力データは 397 個のパラメータ（特徴量）を持つ 1 次元データとなる。

ここで一例として、図-2 にデータ区分ごとのスペクトルを示す。陰性データと直径 100 mm の陽性データが概ね似た特徴を示しているのに対し、直径 150 mm と 200 mm の陽性データは 2000~4500 Hz の範囲にかけて卓越周波数と振幅に大きな差異が生じていることがわかる。また、 $P_{max}$  の階級が Soft の波形は Hard に比べて、振幅がやや減衰するという特徴が認められる。これらのスペクトルの違いを定量的に評価して欠陥の有無を判定することも可能であるが、機械学習を用いることで個人の技量に依存することなく、かつ効率的な判定が可能となる。

## 2.3 オートエンコーダによる内部欠陥判定

### (1) オートエンコーダの概要

オートエンコーダは、ニューラルネットワークの一種であり、入力層と出力層が同じ数のノード持ち、中間層では入力層よりもノード数が少なく次元削減（特徴抽出）

※ ( ) 内の数値はノード数




図-3 オートエンコーダの概略図

が行われ、出力層では入力データの再構成が行われる。オートエンコーダに対し正常データのみを学習させると、学習済みオートエンコーダは正常データは正しく再構成できるが、異常データは再構成できない。本研究では、この再構成性を利用してコンクリートの内部欠陥判定を試みた。学習済みオートエンコーダに陰性・陽性が不明なテストデータを入力し、入力層と出力層の再構成誤差が設定した閾値  $T_h$  よりも小さければ正常（推定陰性）と判定され、大きければ異常（推定陽性）と判定される。なお、本研究では再構成誤差としてコサイン類似度を採用した。コサイン類似度はベクトルの類似性を表す指標であり、二つのベクトルがなす方向余弦として定義され、その値は-1~1の範囲の値をとり、1に近いほど類似性が高いことを示す。本手法では入力と出力（1次元データ）のコサイン類似度を基に欠陥の有無を判定する。

図-3 に本研究で用いたオートエンコーダの概略図を示す。2.2 節で前述のとおり、入力データは 397 個のパラメータを持つため、入力層および出力層ノード数は 397 である。中間層は 1 層の最小構成とし、4~128 の 6 通りのノード数を設定した。

#### (2) データセットとテストデータの判定・評価方法

40 個の陰性データを教師データとして用いてオートエンコーダを学習させ、学習済みのオートエンコーダによってテストデータ陰性 20 個、陽性 30 個（各直径 10 個）の判定を行った。これを  $P_{max}$  の階級ごとに用意した。なお、選択元のデータ群は 2.1 節で前述のとおり（表-2）、陰性データ各区分 60 個、陽性データ各区分 20 個であり、データの選択にあたっては Data Leakage を避ける観点から、教師データとテストデータ間の重複を避けた上で無作為に選択した。

テストデータの判定結果は、欠陥有りとして判定する推定

表-3 判定条件

判定条件		教師データセット		テストデータセット		中間層ノード数	試行数
		データ区分 (表-2)	データ数	データ区分 (表-2)	データ数		
S-S	教師データセットとテストデータセットの $P_{max}$ の階級が同一	n-S	40	n-S	20	4, 8, 16, 32, 64, 128	各10
				100-S	10		
				150-S	10		
				200-S	10		
H-H		n-H	40	n-H	20		
				100-H	10		
				150-H	10		
				200-H	10		
S-H	教師データセットとテストデータセットの $P_{max}$ の階級が食い違う	n-S	40	n-H	20		
				100-H	10		
				150-H	10		
				200-H	10		
H-S		n-H	40	n-S	20		
				100-S	10		
				150-S	10		
				200-S	10		

陽性と、欠陥無しと判定する推定陰性の二つである。50 個のテストデータはすべてどちらかに判定されるが、これらの推定陽性および推定陰性は、必ずしも実際の欠陥の有無と一致するわけではなく誤診が想定される。そのためテストデータは、真陽性、偽陽性、偽陰性、真陰性のいずれかに分類される。今回は評価指標として真陽性率と偽陽性率を採用し、テストデータの判定結果があらかじめ設定する閾値  $T_h$  の影響を受けることから、閾値  $T_h$  を 1.0~0.5 の範囲で少しずつ変化させた場合の真陽性率と偽陽性率の変化を受信者操作特性（以下、ROC）曲線で表し、その ROC 曲線と横軸に挟まれた部分の面積である AUC 値を用いて学習器の判定性能を評価することとした。なお、AUC 値が 1.0 の場合には、閾値を適切な値に設定すれば全てのテストデータを正しく判定可能であり、AUC 値が 0.5 の場合には、その判定結果はランダムな出力と同等の価値ということになる。

#### 2.4 判定条件

表-3 に本研究で行った判定条件を示す。データ収集時におけるハンマの衝撃力が判定結果に及ぼす影響について調べることを目的として、教師データセットとテストデータセットの  $P_{max}$  の階級を同一とした条件（判定条件 S-S と H-H）の判定と、食い違う条件（判定条件 S-H と H-S）の判定を行った。なお、いずれの条件においても中間層ノード数を 6 通り変化させており、判定条件は合計で 24 通りである。判定条件ごとに教師データセットおよびテストデータセットの無作為選択をやり直し、10 回の試行を行った。

### 3. 判定結果

#### 3.1 エポック数の決定

本研究ではオートエンコーダのパラメータとして 6 通

りの中間層ノード数を設定しているが、エポック数を一律とした場合には中間層ノード数によっては過学習や学習が不足することが考えられる。そのため、当初、各中間層ノード数での最適なエポック数を定めることとした。エポック数は1~10000までの8段階からなる学習曲線（縦軸は試行10回分のコサイン類似度の平均値）を基に決定した。ここで一例として、衝撃力の強い、区分n-Hで学習した場合の中間層ノード数8の学習曲線を図-4に示す。教師データはエポック数10と早い段階でコサイン類似度の平均値が1.0に達し学習が収束しているのに対し、テストデータは区分n-S、n-Hいずれも僅差ではあるものの、エポック数300でコサイン類似度の平均値が最大となり、エポック数1000から低下傾向が認められた。よって中間層ノード数8のエポック数は300とした。同様に他の中間層ノード数においても学習が収束しており、テストデータのコサイン類似度の平均値が最大で、かつ低下傾向を示す前の段階のエポック数を採用した。表-4に中間層ノード数ごとに採用した各エポック数を示す。

### 3.2 各種内部欠陥の判定

図-5に判定条件S-S（中間層ノード数16）におけるROC曲線の一例を示す。ROC曲線では、図中の左上の隅（偽陽性率0.0，真陽性率1.0）の位置が全てのテストデータを正しく判定可能であるという理想的な結果を表す。図より、直径が大きい欠陥ほど、ROC曲線が左上の隅の位置に近づいており、特に直径200mmの判定（図-5(c)）では学習器として優れた特性を示していることがわかる。

以降、ROC曲線と横軸に挟まれた部分の面積であるAUC値を用いて各判定条件における判定結果を評価する。なお、試行10回分のAUC値の平均をAUC期待値として定義した。図-6に各判定条件における中間層ノード数とAUC期待値の関係を、表-5にAUC値の試行10回分の変動係数を示す。




図-5 ROC曲線の一例（判定条件S-S（中間層ノード数16））

まず、教師データセットとテストデータセットの $P_{max}$ の階級が同一である判定条件S-S（図-6(a)）とH-H（図-6(b)）の結果を比較すると、全中間層ノード数において各直径いずれもハンマの衝撃力が強い判定条件H-HのAUC期待値が高いことがわかる。特に中間層ノード数が4, 8, 16と少ない場合には、ほぼ全てのテストデータを正しく判定できている。このことは強く打撃することでシグナルノイズ比が大きくなるとともに、振動が打撃を受けた点からより遠くに伝播し、その結果マイクロフォンが広い寸法範囲の振動特性を捉えたことが要






図-4 学習曲線の一例  
（区分n-Hで学習した場合（中間層ノード数8））

表-4 各中間層ノード数におけるエポック数


中間層ノード数	エポック数
4	10
8	300
16	1000
32	3000
64	3000
128	3000




(a) 判定条件 S-S



(b) 判定条件 H-H



(c) 判定条件 S-H



(d) 判定条件 H-S

図-6 中間層ノード数と AUC 期待値の関係

因として考えられる。一方で、判定条件 S-S では打撃時の衝撃力が弱いことでスペクトルに現れる欠陥の有無の影響が現れづらくノイズに紛れてしまい、特に、4、8 と

表-5 AUC 値の変動係数

判定条件	中間層ノード数	AUC 値の変動係数		
		直径 100 mm	直径 150 mm	直径 200 mm
S-S	4	0.164	0.198	0.203
	8	0.097	0.125	0.112
	16	0.121	0.073	0.056
	32	0.130	0.067	0.073
	64	0.216	0.081	0.023
	128	0.130	0.049	0.037
H-H	4	0.019	0.015	0.000
	8	0.023	0.011	0.007
	16	0.041	0.029	0.002
	32	0.069	0.037	0.016
	128	0.091	0.028	0.024
S-H	4	0.102	0.121	0.391
	8	0.069	0.042	0.102
	16	0.053	0.024	0.019
	32	0.125	0.042	0.046
	128	0.093	0.060	0.034
H-S	4	0.138	0.048	0.043
	8	0.091	0.041	0.013
	16	0.097	0.070	0.020
	32	0.174	0.060	0.022
	64	0.185	0.087	0.035
	128	0.204	0.164	0.047

少ない中間層ノード数では十分に学習・再構成を行うことができず、AUC 期待値が低調となったと考えられる。

次に、教師データセットとテストデータセットの  $P_{max}$  の階級が食い違う条件である判定条件 S-H (図-6(c)) および H-S (図-6(d)) の結果に着目する。前述の良好な判定結果が得られた判定条件 H-H (図-6(b)) の結果と比較すると、判定条件 S-H では全中間層ノード数における直径 100 mm ならびに中間層ノード数 4、8 における直径 150 mm、200 mm の AUC 期待値が、判定条件 H-S では全中間層ノード数における直径 100 mm、150 mm の AUC 期待値がそれぞれ低下する傾向が認められ、特に判定条件 H-S における低調な結果が目立つ。これは、入力したスペクトルの 100~1000 Hz、3000~4000 Hz の範囲にかけて区分 100-H、150-H に比べて区分 100-S、150-S の振幅が減衰していることなどが要因として考えられる (図-2)。また、各判定条件共通の傾向として中間層ノード数が 32 以上と多い場合には、AUC 期待値の低下が認められ、これはノード数が多い分、次元を削減することができず学習するパラメータが多くなることで過学習に陥っていると考えられる。

他方、表-5 の各判定条件における試行ごとの AUC 値のばらつきに着目すると、いずれも変動係数は小さいものの、教師データセット、テストデータセットのいずれ

か、あるいは両方のハンマの衝撃力が弱いと AUC 値のばらつきがやや大きくなる傾向が認められた。

上記の結果より、オートエンコーダの再構成誤差を用いることで陽性の教師データが無くともコンクリートの内部欠陥を正しく判定することが可能であり、その際、教師データセット収集時とテストデータセット収集時のハンマの衝撃力を強く、かつ同程度に揃えることで判定性能が向上する傾向を確認した。よって、データ収集時には打撃の管理・記録が必要であることが示唆される。なお、これらのハンマの衝撃力に関する結果は、これまでに著者らが行ってきた陽性の教師データを必要とする単純なニューラルネットワークモデルを用いた検討<sup>3),4)</sup>と概ね同様の傾向であった。ただし、本研究は供試体の諸元や欠陥の仕様など、特定の条件下での検討であるため、更なるデータの蓄積が必要である。今後の展望としては、引き続き本提案手法に関する検討を深化させるとともに、オートエンコーダを次元削減手法として用いることで、異常の有無の特性のみを抽出し、打撃時の衝撃力の違いによる影響を取り除く手法について検討を進めていく予定である。

#### 4. まとめ

本研究は、オートエンコーダの再構成誤差を用いた打音によるコンクリートの内部欠陥判定を試み、その有用性とデータ収集時のハンマの衝撃力の影響について検討を行ったものである。以下に得られた知見を示す。

- (1) 適切な閾値  $T_h$  (陰性データの cosine 類似度の平均値など) を設定すれば、オートエンコーダの再構成誤差を用いてコンクリートの内部欠陥 (直径 100 mm, 150mm, 200 mm) の有無を正しく判定可能であり、教師データセット収集時とテストデータセット収集時のハンマの衝撃力が強く、同程度に揃っている場合には AUC 期待値が向上する傾向を確認した。
- (2) 教師データセット収集時とテストデータセット収集時いずれか、あるいは両方においてハンマの衝撃力が弱い場合には、試行ごとの AUC 値のばらつきが大きくなるとともに、AUC 期待値が低調となることを確認した。

#### 参考文献

- 1) 江本久雄, 馬場那仰, 浅野寛元, 長瀬大和: AI 手法による打音検査の浮き判定の検討, AI データサイエンス論文集, Vol.1, No.J1, pp.514-521, 2020.
- 2) 竹谷晃一, 佐々木栄一, 范書舒, 伊藤裕一: 時間・周波数領域の特徴量評価とニューラルネットワークを用いた打音法の感度向上と効率化, AI データサイエンス論文集, Vol.2, No.J2, pp.721-732, 2021.
- 3) 福井智大, 黒田一郎: ニューラルネットワークを用いた腐食ひび割れの打音判定における打撃条件の影響, AI・データサイエンス論文集, Vol.3, No.J2, pp.35-46, 2022.
- 4) 福井智大, 黒田一郎: ニューラルネットワークを用いた打音による鉄筋腐食判定結果に及ぼすデータセットにおける衝撃力の整合性の影響, コンクリート工学年次論文集, Vol.46, No.1, pp.1651-1656, 2024.
- 5) 福井智大, 黒田一郎, 歌川紀之, 黒田千歳: ニューラルネットワークに基づく打音を用いたコンクリートの内部欠陥判定における欠陥諸元の影響, コンクリート構造物の補修,補強,アップグレード論文報告集, Vol.24, pp.27-32, 2024.
- 6) Rumelhart, D. E., Hinton, G. E. and Williams, R. J.: Learning internal representations by error propagation, Tech. Rep., DTIC Document, 1985.
- 7) 内田雅人, 石田秀一, 田原竜夫, 宮本弘之: 薄型 AE センサとオートエンコーダの再構成誤差を用いた回転式真空ポンプの異常検知, 計測自動制御学会論文集, Vol.54, No.7, pp.599-605, 2018.
- 8) 郭家寧, 造酒裕貴, 藤田康寛, 切通恵介, 伊藤浩二: オートエンコーダを用いた地震計の時系列異常検知, 第 34 回人工知能学会全国大会論文集, 4L2-GS-13-03, 2020.
- 9) 佐相駿実, 勝木太, 日比野克彦: 機械学習を利用した打音法のコンクリート浮き部検出への適用性に関する基礎研究, コンクリート構造物の非破壊検査シンポジウム論文集, Vol.6, pp.201-206, 2018.
- 10) 森藤優一, 黒田一郎: LOF 及び k 近傍法による RC 梁の損傷判定における周波数帯域の影響の検討, 構造工学論文集, Vol.69A, pp.757-767, 2023.