

論文 機械学習による打音検査の定量評価法について

新保 弘^{*1}・尾関 智子^{*2}・溝渕 利明^{*3}・野嶋 潤一郎^{*4}

要旨: 打音検査の定量化・高度化は点検の自動化に必須の技術である。短時間フーリエ変換等により時間-周波数領域で画像化した打音データを CNN (Convolutional Neural Network) により教師あり学習させることで精度よく欠陥を分類することができるが、異なるサイトでの分類は難しい。ここでは CNN を特徴抽出器としてのみ利用し、テストサイトの健全データの特徴ベクトルから同サイトのテスト打音を定量的に評価する方法を提案・検証した。その結果、提案手法により条件の異なるサイトでも定量的に打音の健全・欠陥の評価できる可能性を示した。

キーワード: 打音検査, 機械学習, CNN, スカログラム, マハラノビス距離

1. はじめに

社会資本維持管理の担い手不足が懸念される一方、今後増大するコンクリート構造物の維持管理需要は一段と高まることが予想されている。構造物の定期点検で求められる打音診断を定量化することは、調査点検の合理化や自動化に向けた基礎的な技術として有用である。

打音検査の定量化についてはこれまでも打音のメカニズムに基づく検討や機械学習による方法が検討されている。鎌田ら¹⁾は打音応答の打音波形の最大振幅値比と周波数分布に着目し、実験及び解析により表層欠陥の大きさと深さが打音に与える影響について検討した。

Carino²⁾はコンクリート面に接触した電磁式ピックアップにより応答を得る弾性波探査を対象としているが、卓越周波数と内部欠陥の大きさの関係について、構造物表面と空隙の間で反射を繰り返すことにより生じる定在波から空隙が大きくなることにより卓越するたわみ振動への遷移について整理した。

打音検査の定量化に機械学習を用いる試みも多く行われている。園田ら³⁾は実橋および模擬空隙をもつ試験体について、周波数領域で分割した応答スペクトルを特徴量として SOM (Self-Organizing Map) を適用し、打音の分類が可能であることを示した。

Yeら⁴⁾は応答スペクトルを特徴量としてオンライン学習で予測モデルを更新することにより、対象や周辺環境の変化に対応する方法を検討した。竹谷ら⁵⁾は模擬空隙を持つ試験体の打音に対して、STFT(Short-Time Fourier Transform)によるスペクトログラムを含む様々な特徴量を用いたニューラルネットワークにより分類を行った。

機械学習手法に関しては、これまでのところ、教師なし学習によれば汎化的な分類が可能であるが、分類が可能となるまで相当程度の数のデータを処理する必要がある

ため、実用には課題が残る。教師あり学習によれば訓練データに対する分類精度は確保できるが、条件の異なるテストデータを分類することは難しく、何らかの形でオンサイトのリファレンスデータを用いてネットワークを更新するような方法が必要と考えられる。

特徴量のうち、応答の強度に関するパラメータについては打撃や録音の条件を統一するようなハードウェアの仕組みが必要となるが、応答周波数に関するものは環境や物性に影響を受けるものの、データ処理のみで対応できると考えられる。

これまでの筆者らの検討では、画像化した打音の CNN (Convolutional Neural Network) による画像分類手法を応用することで熟練打音技師と同等の精度で打音の健全/欠陥分類が可能であることを示した⁶⁾⁷⁾。

本稿では、画像化した打音データを CNN により分類する方法、また訓練された CNN を特徴抽出器としてのみ利用し、得られた特徴ベクトルをもとに少数のリファレンスデータのみで精度良く、かつ定量的に評価する方法について検討する。

2. 提案手法

2.1 打音の画像化

図-1に健全部打音と欠陥部打音の平均スカログラムを示す。これは健全部と欠陥部の塩害劣化でかぶりコンクリートの一部に剥離が生じているコンクリート構造物の健全部分と剥離が生じている欠陥部分で得られた複数の打音の初期 5ms を Amor 波形による CWT (Continuous Wavelet Transform: 連続ウェーブレット変換) で、それぞれ多数の打音を平均化したものである。いずれも画像内で正規化し、カラーコンターで表示している。これより欠陥部の打音はたわみ振動が卓越することから健全部の

*1 法政大学大学院 デザイン工学研究科 都市環境デザイン工学専攻 D3 工修 (学生会員)

*2 東海大学 情報理工学部 教授 博士(理学)

*3 法政大学 デザイン工学部 教授 博士(工学) (正会員)

*4 J-POWER 設計コンサルタント 茅ヶ崎技術事業本部 博士(工学) (正会員)

打音に比べてエネルギーの大きい領域が低周波数方向にシフトし、時間方向に長くなる傾向にあることがわかる。




図-1 健全部打音と欠陥部打音の平均スカログラム

2.2 CNNによる打音の分類方法

筆者らの既往研究⁹⁾では、このような画像上の特徴を前提として、STFTで得られた28pixel×28pixelグレイスケールという比較的小さなデータについて、畳み込み層3層の比較的単純な構成のCNNで教師あり学習を行い熟練打音技師と同程度の精度で分類が可能であること、同じサイトで得られたテスト打音であればCNNのスコアにより中間的な劣化部分も含めて、概ね適切に分類可能であることを示した。今回も畳み込み層3層に28pixel×28pixelのグレイスケールを入力データとするが、STFTよりも解像度が高められるCWTによる画像を用いた。ネットワークの構成を図-2に示す。




図-2 CNNのネットワーク構成

2.3 提案手法

教師データの特性に依存するCNNによる分類では、教師データとテストデータの特性（サイトや環境など）が変わった場合には必ずしも適切に分類できない。そこでサイト特性の変化を補正するため、ここではある打音の分類で学習したCNNを特徴抽出器としてのみ用い、テストサイトの健全打音データの特徴量とテストデータの距離によって健全度を求める方法を提案する。図-3に提案手法による判定フローを示す。

STEP1として、CNNによる特徴抽出器を作成する。特徴抽出器の作成では、画像化した健全部・欠陥部の打音を分類できるようにCNNを訓練する。CNNは画像の畳み込みと非線形処理を繰り返しながら、正しい分類結果が得られるように層間の重み付けを調整する。精度の高いCNNが作成されていれば、最終的に健全・欠陥の分類を行う全結合層への入力データはその画像の特徴を表現していると考えられる。したがって、この全結合層への入力データをその画像の特徴ベクトルとして採用し、画像入力から全結合層への入力までの一連の処理を特徴抽出器とする。

STEP2として、テストサイトの健全部打音を特徴抽出器に与え、その健全打音の特徴ベクトルを作成する。ある程度の数の健全部打音から特徴ベクトルを複数作成し、この特徴ベクトル群の平均と分散共分散行列にもとづいて多変量ガウス分布を作成する。

STEP3として、分類すべきテスト打音を特徴抽出器に与えてテスト打音の特徴ベクトルを作成し、これをSTEP2で作成した健全打音のガウス分布に対するマハラノビス距離（Mahalanobis' Distance）を算出する。

マハラノビス距離はデータの相関関係を考慮した距離である。一般に n 次元のベクトル $m = (m_1, m_2, m_3, \dots, m_n)^T$ が成す集団 M について、その次元ごとの平均を $\mu = (\mu_1,$

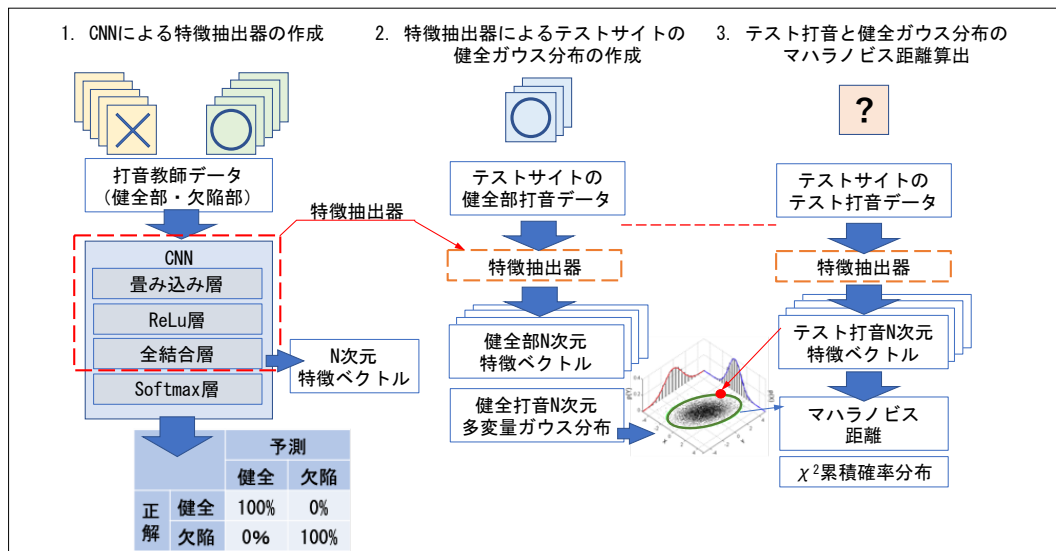


図-3 提案手法のフロー

$\mu_2, \mu_3, \dots, \mu_n)^T$, 次元間の分散共分散行列を Σ とした時, ある点 $x = (x_1, x_2, x_3, \dots, x_n)$ の集団 M に対するマハラノビス距離 $D_m(x)$ は式(1)で表される。

$$D_m(x) = \sqrt{(x - \mu)^T \Sigma^{-1} (x - \mu)} \quad (1)$$

ここに Σ^{-1} は逆共分散行列である。

マハラノビス距離の 2 次元での概念を図-4 に示す。ここに母集団は X_1 と X_2 のどちらに対しても平均 $\mu = 0$, 分散 σ^2 を持つ正規分布にあり, かつ X_1, X_2 に正の相関関係があるとす。この図中の点 p と点 q は母集団の平均 (ここでは原点) からのユークリッド距離は等価であるが, データの相関を考慮するマハラノビス距離で評価した場合, p よりも q の方が母集団に近いと評価される。




図-4 マハラノビス距離の概念図

また, 独立に標準正規分布に従う N 個の確率変数 X の二乗和である Z は式(2)に示すように自由度 N の χ^2 二乗分布となり, χ^2 二乗分布はその自由度のみで規定される。打音の特徴ベクトルの各次元が独立に正規分布に従うとすれば, その二乗和にあたるマハラノビス距離も自由度 N の χ^2 二乗分布に従うことになる。

$$Z = \sum_{i=1}^N X_i^2 \quad (2)$$

χ^2 二乗分布の累積確率分布によれば, あるマハラノビス距離のデータが母集団に属する確率が得られる。この母集団が健全部打音であるので, この値は健全度の指標として考えられる。本法では健全度が疑似的に確率として得られる点で構造物の劣化診断に有効である。

3. 実験データ

本稿では, 本手法の汎化性能を確認するため, 異なる 3 サイトの打音データによる相互検証を行う。

I サイトは日本国内で塩害劣化が進行した鉄筋コンクリート製海上栈橋である。N サイトは名古屋大学橋梁長寿命化推進室がさまざまな劣化・損傷が生じ撤去された

橋梁の部材を全国から集めた施設「N²u-Bridge」である。S サイトは自治体が管理する海岸付近に位置する小規模のコンクリート橋である。それぞれのデータの特徴として, I サイトは劣化の進んで大きな剥離が生じている箇所から欠陥部打音を採取したため健全と欠陥の違いが明瞭である。N サイトは様々な劣化度のものが混在している。S サイトは劣化度が小さく, 健全と欠陥の差が比較的小さいものである。ここではこれらのサイトにおいて, 打音技術者が打音から健全な部位, 欠陥があると明確に推定できる部位から既往研究⁶⁾と同様の機器, 手法とデータ仕様で打音を採取した。

それぞれのデータを CNN により学習した際の学習結果を表-1 に示す。ここでは前述のネットワークにより全データの 15% を検証データとして保留して学習をおこなった結果の分類精度を示している。分類が易しい I サイトに比べ, N サイトと S サイトでは若干精度が下がっていることがわかる。

表-1 CNN による学習結果 (検証精度)

サイト	精度	混同行列			
		正解	健全	欠陥	推定
I	1.0000	健全	38	0	
		欠陥	0	45	
		推定		健全	欠陥
N	0.9893	健全	327	4	
		欠陥	0	43	
		推定		健全	欠陥
S	0.9176	健全	99	6	
		欠陥	8	57	
		推定		健全	欠陥

4. 相互検証

4.1 CNN による分類

ここでは教師データとテストデータの組み合わせを入れ替えて CNN による分類の汎化性能を検証する。

図-5~図-7 に, 各サイトの打音を教師データとした場合の 3 サイトの分類スコアをヒストグラムで示す。横軸のスコアは 1.0 が健全, 0.0 が欠陥を意味し, 2 値分別の観点からは 0.5 が閾値となるものである。ここで, 上段のグラフは全ての打音を個別に分類した結果, 下段は打点 (打撃箇所) ごとにスコアの平均値をとったもの

である。ヒストグラムは青が健全部打音、橙が欠陥部打音を表しているため、青が左端に集まり、橙が右端に集まった状態が正しく分類できていることを意味する。なお2色のバーが重なる部分は暗い橙色で表示されている。

Iサイトの打音を教師データとしてCNNを学習させた場合の各サイトの打音データの分類スコアを図-5に示す。Iサイトは当然ながら、個別打音、打点平均とも明確に分類できている。Nサイトは個別打音で見ると欠陥部のスコアは広く散らばっているが打点平均すると、一部を除き概ね0.4以下で一応欠陥部が評価できている。Sサイトのデータは個別打音で見てもスコア1に近いものが多く、打点平均で見ても全て0.5を上回り、欠陥部が健全部と誤って評価されていることがわかる。




図-5 Iサイトを教師データとした場合

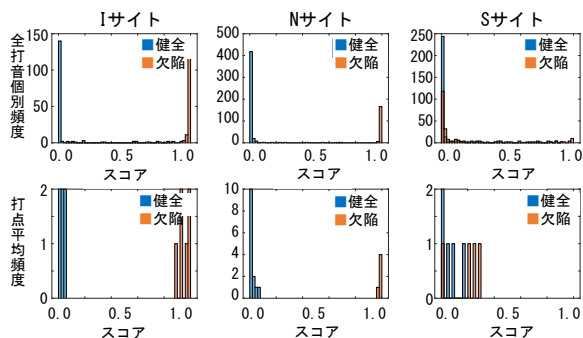


図-6 Nサイトを教師データとした場合




図-7 Sサイトを教師データとした場合

図-6にNサイト打音を教師データとした評価結果を示す。Iサイトの個別打音分布を見ると一部中間的なスコアがあるが、打点平均で見ると健全部・欠陥部とも正しく分類できていることがわかる。Sサイトのデータは個別打音で見てもスコア1に近いものが多く、打点平均で見ても全て0.5を上回り、欠陥部が健全部と誤って評価されている。

Sサイト打音を教師データとした図-7を見ると、Iサイトは個別打音分布で見ると健全部のばらつきが大きいが、打点平均すると0.5を上回るスコアとなっていることから、一応は正しく評価できているといえる。Nサイトのデータは個別打音で見ても非常にばらつきが大きいが、打点平均で見ると一部スコア0.5前後で混同しているが、結果としては概ね正しく評価できているといえる。

4.2 提案手法による分類

(1) 特徴ベクトルの次元ごとの分布

Iサイトデータにより作成したCNNの4次元特徴抽出器により得られた、各サイトの健全打音と欠陥打音の4次元特徴ベクトルの分布を図-8に示す。図中横軸は次元、縦軸がその次元の特徴量の値を示し、特徴ベクトルの次元ごとの値を棒グラフで示している。特徴ベクトルの傾向を見ると、Iサイト、Nサイト、Sサイトいずれのサイトでも健全打音では第1次元、第4次元の値が大きいことがわかる。一方、欠陥打音の特徴ベクトルを見ると、Iサイトでは第2次元、第3次元が大きくなっている。この次元間の傾向は相対的にはNサイト、Sサイトでも認められるが、健全打音と欠陥打音を比較した場合の差異は小さく、特徴をよく分類できていないであろうことがわかる。なお、この特徴ベクトルは画像の特徴を抽出したものの次元ごとの分布や値そのものに物理的な意味はなく、また得られた特徴抽出器に依存するため、CNNを実行するたびにその傾向は変わるものである。

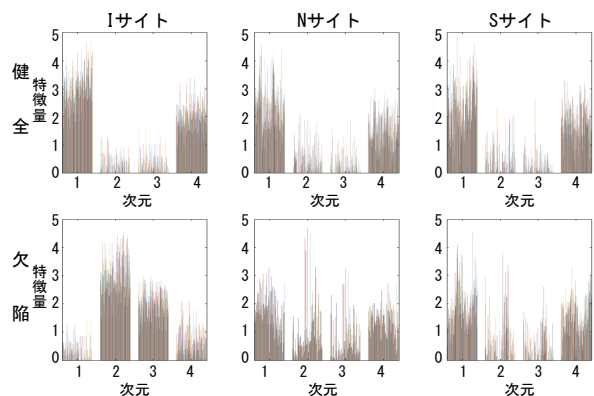


図-8 特徴ベクトルの分布 (4次元の場合)

(2) 特徴ベクトルの次元内の分布

CNN の教師データとして健全打音分類の基準に用いた I サイトの健全打音の次元ごとのヒストグラムを図-9 に示す。赤線でこれらのデータに対するガウス分布を併記している。これより特徴量の各次元のうち、今回の特徴抽出器で健全打音の寄与が大きい第 1 次元、第 4 次元のデータ分布は概ねガウス分布となっている。このガウス分布を現地健全打音から適切に定めることにより本手法の分類精度を高めることができる。母集団が未知であるため必要なサンプルサイズを求めることは不可能であるが、一般にガウス分布を再現するためのサンプルサイズ（ここでは打音数）は 6~10 程度で問題ないとされており⁸⁾、本手法によればテストサイトで少数のリファレンスデータが得られればサイト条件の影響を簡便に反映させることができる。




図-9 I サイトの健全打音の特徴量ヒストグラム

(3) マハラノビス距離の分布

表-2 に、I サイトのデータをもとに 4 次元、8 次元、16 次元の CNN 特徴抽出器を作成し、それぞれで各サイトの健全打音から作成したガウス分布からのマハラノビス距離をヒストグラムにした結果を示す。ここで横軸はマハラノビス距離、縦軸は正規化した度数である。青線で χ^2 乗確率分布を、赤線で $1-\chi^2$ 乗累積確率の分布を併記している。

図中に青線で示した χ^2 乗確率分布はいずれの次元でも健全打音のヒストグラムと概ね一致している。これは特徴量がガウス分布と見做せることを示している。

全打音で見た場合、特徴抽出器を作成した I サイトのデータは健全と欠陥が綺麗に分類できている一方で、N サイトと S サイトでは健全打音と欠陥打音の分布はかなり重なっている。マハラノビス距離を打点（打撃箇所）ごとに平均した場合の分布を表-2 の各次元の下段に示す。打音は同一の位置（打点）で 20 音程度採取している。打点ごとの平均値で見ると、I サイトはもとより、N サイト

と、S サイトにおいても健全打音と欠陥打音は概ね分類できていることがわかる。

打点ごとの平均で分類の傾向が明確になるのは、人による打撃のバラツキが一因と考えられる。すなわち、人の打撃には、その強さやハンマの当たり具合にはある程度のばらつきが生じることは避けられない。健全部は打撃対象が均質であるため、打音がハンマの当たり具合などに影響を受けにくく安定した打音が生じる一方で、欠陥部は打撃箇所と欠陥のわずかな位置関係やハンマの接触状態、コンクリート内部の状態などにより、人が同じ場所を同じように叩こうとしても打音に違いが生じやすい。これは打音の点検者も微妙な判断が求められる箇所では何回も打撃を繰り返してその状態を確認する傾向にあることから類推される。したがって、打点ごとのマハラノビス距離の平均値を取ることで安定した結果を得ることが適切であると考えられる。

(4) 特徴ベクトルの次元数の影響

特徴抽出器の次元数は分類の精度や傾向に影響を与える可能性がある。I サイトは特徴抽出器を作成したデータであるため、健全打音と欠陥打音は 1 打音で見ても、打点平均で見ても明確に分類できている。この傾向は特徴ベクトルの次元数が変わっても同じである。

表-2 において 4 次元の場合を見ると、N サイト、S サイトとも個別打音ではかなり錯綜している。これを打点平均することにより分類できる傾向は見られる。8 次元の場合、N サイトは個別打音、打点平均いずれもかなり明確に分類できている。S サイトでは個別打音は相当錯綜しているが、打点平均を取ることにより分類できている。16 次元の場合、個別打音では N サイト、S サイトいずれも錯綜しているものの、打点平均を取ることによって健全・欠陥はほぼ分類できている。

特徴抽出器の性能は CNN のランダム性に影響を受けるため断定できないが、本検討の範囲では特徴ベクトルとして 8 次元程度を確保すれば打点平均で健全と欠陥を分類可能なようである。なお、自由度 ν の χ^2 乗分布は平均値 ν 、分散 2ν となるため、次元数が高くなるほど外れ値に対して寛容になる。従って特徴ベクトルの次元数を増やせば精度が向上するとは言い切れない。

また、現状では十分なデータ数があるとは言いが、得られたマハラノビス距離のヒストグラムから健全欠陥の境界値を観察すると、表-2 中に赤の ∇ で示すように、特徴ベクトルが 4 次元の場合で 5.5、8 次元の場合で 10、16 次元の場合で 20 前後にあるように見える。これを図-10 に示すようにそれぞれの自由度 ν での $1-\chi^2$ 乗累積確率分布上にプロットすると、いずれの次元においても $1-\chi^2$ 乗累積確率分布において概ね 25% 付近が健全・欠陥の境界となっていることがわかる。

表-2 特徴ベクトルの次元数とマハラノビス距離の分布


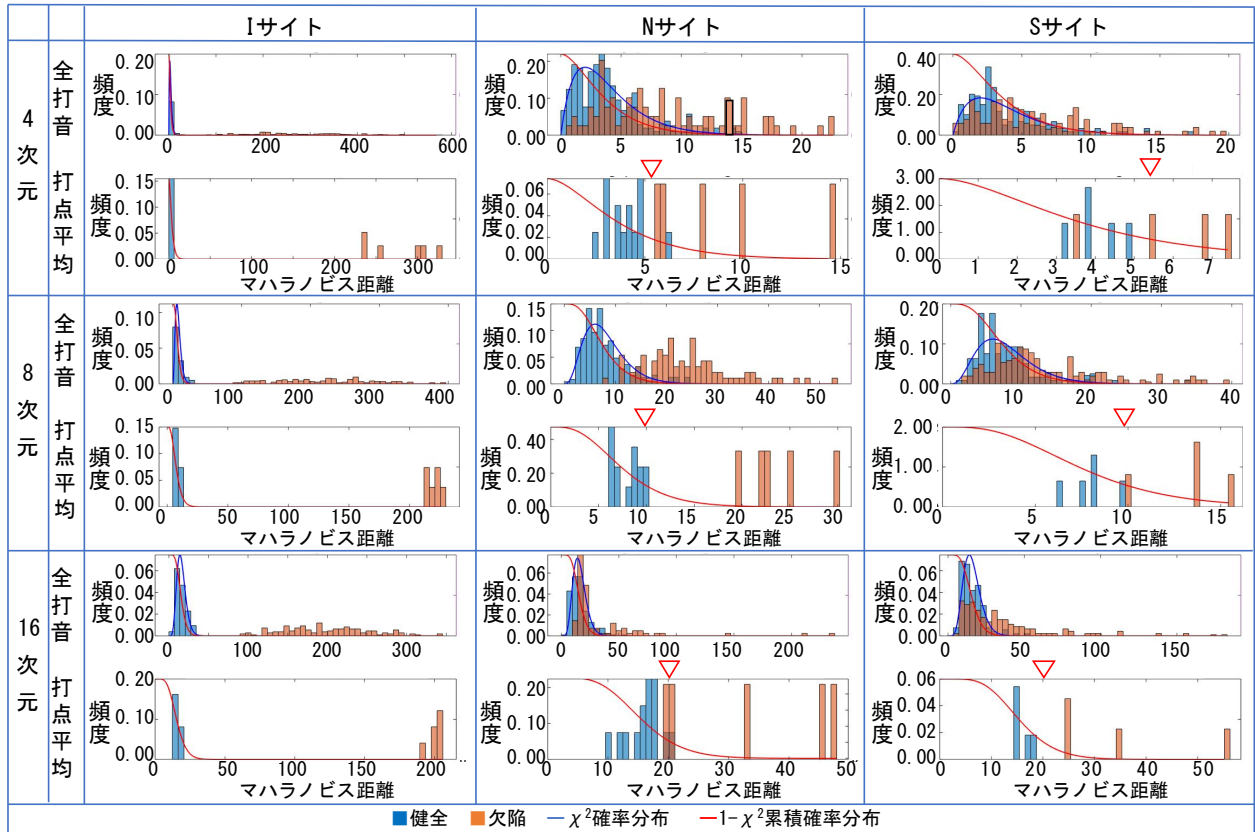


図-10 健全欠陥の閾値と1- χ^2 二乗累積確率分布

5. まとめ

異なる3サイトを対象とした現地打音データについて検討を行った結果、単純なCNNによる手法がサイト条件に依存し、学習サイト以外には適用性が低いのに比較し、提案手法によれば任意のサイトでも数少ないリファレンスデータが得られれば、精度良くかつ定量的に打音の分類評価が可能であることを示した。今後、本手法の適用性と実用性を確認するためには、様々な打音データによる検証を加えること、また精度向上のため特徴抽出器の性能向上を図ることや特徴ベクトル次元数の最適化すること等に検討の余地がある。

参考文献

1) 鎌田敏郎, 浅野雅則, 国枝稔, 六郷恵哲: コンクリー

ト表層部欠陥の定量的非破壊検査への打音法の適用, 土木学会論文集 No.704, V-55, pp.66-79, 2002.

2) Nicholas J. CARINO : Impact Echo: The Fundamentals, International Symposium Non-Destructive Testing in Civil Engineering (NDT-CE), September 15 - 17, 2015.
 3) 園田佳巨, 川端健太, 別府万寿博, 福井雄気: 打音データを用いたコンクリート内部欠陥の評価に関する基礎的考察土木学会構造工学論文集 Vol.57A, 2011.
 4) Ye, Jiaying, Takumi Kobayashi, Masaya Iwata, Hiroshi Tsuda, and Masahiro Murakawa: Computerized Hammer Sounding Interpretation for Concrete Assessment with Online Machine Learning, Sensors,18, no.3:833, 2018.
 5) 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, 2 巻, J2 号, p. 721-732, 2021.
 6) 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, Vol.41. No.1, pp.1829-1834, 2019.7
 7) 新保弘, 溝渕利明, 尾関智子, 野嶋潤一郎, 打音探査への機械学習の適用に関する検討, 土木情報学シンポジウム講演集, Vol.45, pp.61-65,2020.9
 8) 統計に必要なサンプルサイズ(サンプル数)の決め方・計算方法 <https://hatsudy.com/jp/samples.html> (accessed2023.1.9)