

Wavelet 変換と t-SNE に基づく力覚信号のクラスタリングによる コンクリート構造物の欠陥検知

Defect Detection in Concrete Structures through Force Signal Clustering Based on Wavelet Transformation and t-SNE

○ 正田 晃己 (東大) 正 ルイ笠原 純ユネス (東大)
正 浅間 一 (東大) 正 安琪 (東大) 正 山下 淳 (東大)

Koki Shoda, The University of Tokyo, shoda@robot.t.u-tokyo.ac.jp

Jun Younes Louhi Kasahara, The University of Tokyo, louhi@robot.t.u-tokyo.ac.jp

Hajime Asama, The University of Tokyo, asama@robot.t.u-tokyo.ac.jp

Qi An, The University of Tokyo, anqi@robot.t.u-tokyo.ac.jp

Atsushi Yamashita, The University of Tokyo, yamashita@robot.t.u-tokyo.ac.jp

In this paper, we propose a new force signal clustering method for defect detection in concrete structures. With the rapid aging of concrete social infrastructure, the maintenance and management of concrete structures have emerged as critical challenges. An impact method that utilizes the force signals obtained from an impact hammer for detecting defects in concrete has been proposed to overcome the noise robustness issues of hammering acoustic inspection. However, it has been reported that impact method significantly underperforms in defect discrimination accuracy compared to the hammering acoustic method. The reason for the low defect discrimination accuracy of conventional impact method is that, compared to hammering sounds, force signals have shorter waveforms and the waveforms between healthy and defective conditions are similar. In this study, to address this issue, we introduce a clustering framework that incorporates wavelet transformation and t-SNE, proposing an impact method with defect detection accuracy comparable to the hammering acoustic method. Experimental results demonstrated that the proposed impact method can discriminate defects with high accuracy.

Key Words: Infrastructure inspection, Force sensor, Hammering, Machine learning, Signal processing

1 序論


近年、社会インフラストラクチャーであるコンクリートの老朽化が加速度的に進行している。現在日本においてはトンネルの 27%、道路橋の 39%が耐用年数を迎えており [1]、その保守点検が極めて重要な課題となっている。打音検査は、簡便かつ非破壊的に構造物内部の点検が可能であり、国土交通省により定期点検での実施が義務化されている [2]。少子高齢化により熟練点検員が不足している背景から、ロボットによる自動化により持続可能な点検を目指す研究が幅広くなされている [3, 4, 5]。

Louhi Kasahara ら [6] は、打叩位置を考慮しつつ打叩音の特徴をクラスタリングをすることで、教師データなしにコンクリートの欠陥検知をする手法を提案している。打叩音の特徴から欠陥検知を行う手法は打音法と呼ばれる。しかし、点検ロボット自身の駆動音や行き交う車両など、点検の現場では様々な騒音が発生していることが想定される。そのような騒音中では、教師データを使わずに打叩音から高い精度で欠陥識別をすることは難しい。

そこで、Nishimura ら [4] は Deep Neural Network (DNN) の高い表現力を利用し、教師あり学習によって騒音に頑健な欠陥検知手法を提案している。しかし、騒音を含む打叩音から DNN を訓練するには、多量のラベル付きデータが必要である。打叩音のラベリングは熟練の点検員が行う必要があるため、人的リソースへの依存度が高い。さらに、未訓練の騒音に対して識別性能が低下する可能性が高い。

別のアプローチとして、湊ら [7] はインパクトハンマーで計測される力覚信号をクラスタリングすることで、教師なし欠陥検知を行うインパクト法を提案している。インパクト法は騒音の影響を受けず、打音法と同様に検査対象にセンサ設置が不要であるため、ロボットによる自動化に適している。しかし、打音法に比べ欠陥識別精度が非常に低いことが報告されている。

そのため、ルイ笠原ら [8] はカメラから得られたコンクリートの割れと打叩位置を組み込んだインパクト法を提案している。この手法は、コンクリートの亀裂を境界として打叩サンプルをグルーピングし、グループ内でクラスタへの帰属度の平滑化をすることで欠陥識別精度を向上させる。したがって、層間剥離などの



(a) Force signals.

(b) Acoustic signals.

Fig. 1: Samples of healthy and defective signals.

表面に現れず視認できない欠陥に対しては、この手法による精度向上は見込めない。

インパクト法の欠陥識別精度が低い原因として、音信号と比較した力覚信号の特徴が主に 2 つ挙げられる。1 つ目は、短時間で解析に有効なデータ量が時間換算で 1/100 以下 [9] である。2 つ目は、健康と欠陥の波形が類似しており、欠陥の検出が難しい。Figure 1 に示すように、音信号と比較して力覚信号は健康と欠陥の波形が類似している。

このような力覚信号の特徴からインパクト法は欠陥識別精度が低いものの、騒音に影響されないという多大な利点がある。そこで本研究の目的を、打音法と同等の精度で欠陥識別が可能なインパクト法の開発とする。本稿では、力覚信号のクラスタリングに適した処理の枠組みを提案することで、インパクト法の欠陥識別精度向上を目指す。

2 提案手法

2.1 コンセプト

本研究では、インパクト法の精度が低い原因となっている、力覚信号の 2 つの特徴に対処するための手法を提案する。提案するクラスタリングフレームワークを Fig. 2 に示す。まず、取得した




Fig. 2: Processing framework for proposed method.

力覚信号群はそれぞれの信号についてエネルギーを正規化して打叩強度によるばらつきをなくす。次に、Wavelet 変換により、1 つ目の特徴である短時間の力覚信号を、解析に有効な時間-周波数特徴量に変換する。更に、t-distributed Stochastic Neighbor Embedding (t-SNE) により、2 つ目の特徴である健康信号と欠陥信号の類似に対処する。最後に、先行研究 [7] と同じく Fuzzy C-means によりクラスタリングを行い、力覚信号から打叩位置の欠陥確率を算出する。

クラスタリングによって分割されたデータは、どちらが欠陥であるかは特定できない。しかし、実際の点検現場で集められる欠陥部の信号は、健康部の信号に比べて少ないと考えられる。したがって、実際はクラスタのサンプル数からどちらが欠陥であるかは分かるものとする [6, 7]。以降の節では、各構成要素の役割や詳細について説明する。

2.2 エネルギー正規化

力覚信号 $s(t)$ は叩く強さによって信号にばらつきが発生し、クラスタリングに悪影響を及ぼす。そのため、以下の式に従い信号のエネルギーを正規化する。

$$s'(t) = \frac{s(t)}{\int_0^T s(t)^2 dt}, \quad (1)$$

ここで、 $s(t)$ と $s'(t)$ はそれぞれ時刻 t での正規化前後の力覚信号、 T は力覚信号を切り取る窓幅である。

2.3 Wavelet 変換

力覚信号を機械学習モデルが扱いやすい特徴量に変換する必要がある。先行研究 [7] では、力覚信号の特徴量として Fourier 変換が使われていた。しかし、Fourier 変換は信号の定常性を仮定しているため、非定常な力覚信号に対しては適切でない。Wavelet 変換はもともと石油探査を目的として、爆発によって引き起こされた寿命の短い人工地震波の解析のために考案された手法であり [10]、非定常な信号解析に対する有効性が知られている。

Wavelet 変換は Fourier 変換と同様に、解析対象の信号を基底関数の線形結合で表現することを目指す。基底関数の重み係数 c は、各基底関数と解析対象の信号の内積で求められる。

$$c(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} f(t) \psi^* \left(\frac{t-b}{a} \right) dt, \quad (2)$$

ここで、 $f(t)$ は解析対象の信号、 $\psi^*(t)$ は複素共役をとった基底関数 (マザーウェーブレット)、 a はスケールパラメータ、 b は時刻パラメータである。 a は基底関数を伸縮させることで、周波数方向の特徴を抽出する役割を持つ。 b は基底関数を時間軸に沿ってスライドさせることで、時間方向の特徴を抽出する役割を持つ。

同じ時間-周波数解析手法として、Short Time Fourier Transform (STFT) があるが、時間分解能と周波数分解能のトレード

オフが存在する。この問題を解決した Wavelet 変換のアイデアは、基底関数を伸縮させることで、低周波成分の解析には長い基底関数を使い、高周波成分の解析には短い基底関数を使うことである。これにより、変化の速い高周波成分に対しては高い時間分解能を持ち、変化の遅い低周波信号に対しては高い周波数分解能を持つ。本研究では、Wavelet 変換を用いることで、短時間の力覚信号を時間-周波数領域の特徴量に変換する。

2.4 t-SNE 次元削減

力覚信号のもう 1 つの特徴である、健康と欠陥の波形が類似していることに対処する必要がある。原信号の波形が互いに類似している場合、Wavelet 変換によって得られる特徴量もまた、類似した特性を持つ。これは、健康と欠陥の力覚信号を効果的に区別するために必要な、パターンや特徴の識別を困難にする。そこで t-SNE を使うことで、健康と欠陥の力覚信号の細かな距離関係を忠実に低次元に埋め込むことで、高次元空間での距離均一化によるクラスタリングの精度低下を抑える。

t-SNE は van der Maaten ら [11] によって提案された次元削減手法であり、高次元空間におけるデータポイントの類似度と、低次元空間に埋め込んだ後のデータポイントの類似度を近づけることで次元圧縮を行う。高次元空間における i 番目のデータポイント \mathbf{x}_i と j 番目のデータポイント \mathbf{x}_j の関係は、 \mathbf{x}_i が選択されたもとの \mathbf{x}_j が正規分布に従い選択される条件付き確率として、以下のように定義する。

$$p_{ji|i} = \frac{\exp(-d_{ji}^2/2\sigma_i^2)}{\sum_{k \neq i} \exp(-d_{ki}^2/2\sigma_i^2)}, \quad (3)$$

ここで、 d_{ji} は \mathbf{x}_i と \mathbf{x}_j のユークリッド距離であり、 σ_i はハイパーパラメータであり、 \mathbf{x}_i における周辺確率分布の標準偏差を表す。これを類似度として扱うため、以下のように対称化した同時確率 p_{ji} を定義する。

$$p_{ji} = \frac{p_{ji|i} + p_{ij|j}}{2n}, \quad (4)$$

ここで、 n はデータ数である。 \mathbf{x}_i と \mathbf{x}_j が近いほど同時確率 p_{ji} は大きくなり、遠いほど小さくなる。

次に、低次元空間における i 番目のデータポイント \mathbf{y}_i と j 番目のデータポイント \mathbf{y}_j の類似度 q_{ji} を、以下のように定義する。

$$q_{ji} = \frac{(1 + d_{ji}^2)^{-1}}{\sum_{k \neq l} (1 + d_{kl}^2)^{-1}}, \quad (5)$$

ここで、 d_{ji} は \mathbf{y}_j と \mathbf{y}_i のユークリッド距離である。低次元空間でのデータポイントの類似度 q_{ji} を表現するにあたり、正規分布ではなく自由度 1 の t 分布を使っている。

t-SNE は高次元での類似度 p_{ji} と低次元での類似度 q_{ji} を、全てのデータポイントの組み合わせについて近づけることを目的として、カルバックライブラ情報量をコスト関数 C としている。コスト関数を勾配法により最小化することで、低次元での埋め込み表現を求める。

$$C = \sum_j \sum_i p_{ji} \log \frac{p_{ji}}{q_{ji}}. \quad (6)$$

カルバックライブラ情報量は非対称であり、 p_{ji} と q_{ji} は等価に扱われない。高次元でのデータが近いが、低次元でのデータが離れている場合 ($p_{ji} \gg q_{ji}$)、このコスト関数は非常に大きな値を取る。一方、高次元でのデータが離れているが、低次元でのデータが近い場合 ($p_{ji} \ll q_{ji}$)、コスト関数は小さな値を取る。つまり、高次元の近傍データを低次元でも忠実に近傍に配置することを重要視する設計となっている。

本研究では、t-SNE の近傍データを保持する能力を利用する。力覚信号の時間-周波数特徴量は全体的には類似しており近傍に配置されるが、健康部と欠陥部の信号は細かい特徴が異なることが期待される。t-SNE によって、高次元での近傍データの細かな距離関係を低次元で忠実に保持することで、高次元空間での距離均一化によるクラスタリングの精度低下を抑える。

一般に t-SNE の前処理として標準化を行うが、本研究では以下の理由からあえて標準化を行わない。1 つ目は、今回 t-SNE に




Fig. 3: Side view of concrete specimen. The green numbers indicate two healthy areas subjected to hammering, whereas the red numbers identify five areas with defects. The depths of these defects, measured from the surface, are as follows: ①17 mm, ②27 mm, ③36 mm, ④43 mm, and ⑤50 mm.

入力する特徴量の変数は全て同じ物理次元であるため、標準化の必要性が低い。2つ目は、標準化により平均と分散の情報が失われ、全ての特徴量の変数が等価に扱われるためである。ただし、特徴量にはばらつき大きい変数と小さい変数が混在し、ばらつき大きい変数は距離計算の過程で過大評価される。本研究では Wavelet 変換で得られた特徴量を対数変換してダイナミックレンジを広げることで、ばらつき大きい変数が与える効果を低減する。

2.5 Fuzzy C-means クラスタリング

Fuzzy C-means は Dunn[12] が提案したクラスタリング手法であり、各データポイントが複数のクラスに所属できるファジィな帰属度を持つことが特徴である。Fuzzy C-means は、クラスタ中心と各データポイントとの距離を考慮した以下の目的関数 J を最小化することにより、クラスタリングを行う。

$$J = \sum_{i=1}^N \sum_{j=1}^C u_{ij}^m \|z_i - c_j\|^2, \quad (7)$$

ここで、 N はデータ数、 C はクラスタ数、 z_i は i 番目のデータポイント、 u_{ij} は z_i のクラスタ j への帰属度、 m はファジィネスパラメータ、 c_j はクラスタ j の中心、 $\|z_i - c_j\|$ は z_i と c_j のユークリッド距離である。

現実で得られる打叩信号は健全と欠陥の2クラスに明確な分類境界が存在するわけではなく、連続的な欠陥の程度を持つ。打叩音による欠陥検知もこれは同様であり、先行研究ではクラスタリングのために Fuzzy C-means が用いられている [7, 13]。本研究でも、Fuzzy C-means によってクラスタリングを行い、各信号が健全と欠陥のどちらに属するかを確率的に算出する。

3 実験

提案手法の有効性を検証するため、既存手法 [7] と欠陥識別精度を比較する実験を行った。インパクトハンマーによってコンクリート試験体の健全部と欠陥部を叩き、取得した力覚信号から欠陥の識別をする。コンクリートの構造物の代表的な欠陥は割れであるため、本研究では割れのあるコンクリート試験体を実験に用いた。先行研究 [7] では、打叩位置から欠陥まで遠いほど打叩の特徴が健全に近づくため、深い欠陥ほど識別精度が低下することが報告されている。そこで、本実験では Fig. 3 のように、健全領域は2箇所、欠陥領域は割れまでの深さの異なる5箇所を、すべて512回ずつ叩き力覚信号のサンプルを収集した。

更に本研究では、打叩法と同等の精度で欠陥識別が可能なインパクト法の開発を目的としているため、Fig. 4 のように実験装置をセットアップした。スタンドにはマイク (PCB 社 377B02) が設置されており、インパクトハンマー (PCB 社 086C03) によって発生した打叩音を、力覚信号と同時にデータロガー (MC 社 DT9837B) によって取得する。同じインパクト法である既存手法 [7] との比較と共に、打叩法による欠陥識別との比較も行う。

サンプリング周波数はデータロガーの限界値である 100 kHz、力覚信号の窓幅は先行研究 [7] と同じく 5.12 ms (512 サンプル) とし、音信号の窓幅は 40.96 ms (4096 サンプル) とした。Wavelet 変換におけるマザーウェーブレットは Morlet を使い、t-SNE で



Fig. 4: Experimental setup.

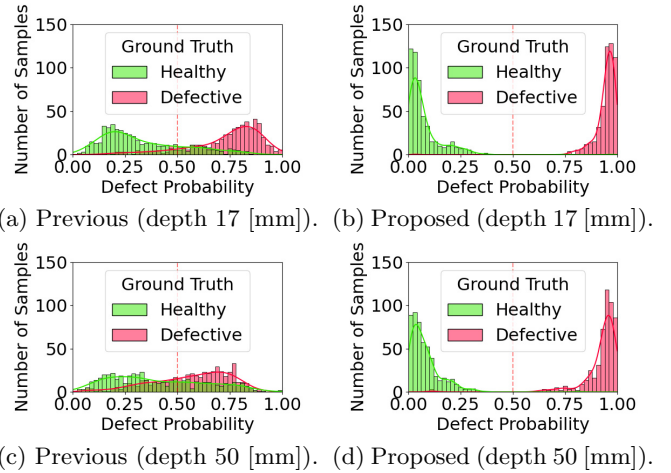


Fig. 5: Histograms of clustering results.

は perplexity を 30 に設定し、2次元まで特徴量を次元削減した。Fuzzy C-means によるクラスタリングでは、健全と欠陥の2値分類をするためクラスタ数は2に、ファジィネスパラメータ m は先行研究 [7] と同じく2に設定した。

4 結果

健全領域と欠陥領域の1箇所ずつの力覚信号のサンプルを用いて、健全と欠陥の2値分類の精度を既存手法 [7] と比較した。既存手法は力覚信号を Fourier 変換し、その周波数成分を特徴量として Fuzzy C-means によりクラスタリングを行う手法である。最も欠陥まで浅い箇所 (17 mm) と最も深い箇所 (50 mm) のクラスタリング結果を Fig. 5 に示す。健全と欠陥の各512サンプルの力覚信号それぞれについて算出された欠陥率の分布を、ヒストグラムと Kernel Density Estimation (KDE) で表している。赤い点線は欠陥を判定するしきい値 (0.5) である。

既存手法は深い欠陥ほど誤判定するデータが増え、分布のピークはしきい値に近づき、欠陥識別の確信度が顕著に低下している。一方、提案手法は欠陥までの深さ 50 mm であっても、しきい値を超え誤判定されるデータはほとんど存在しない。

インパクト法である既存手法と提案手法の比較に加え、打叩法による欠陥識別精度を Fig. 6 に示す。打叩法を緑色破線で、提案手法を紫線で、t-SNE 次元削減を省いた提案手法を赤線で、




Fig. 6: Average accuracy of defect discrimination.

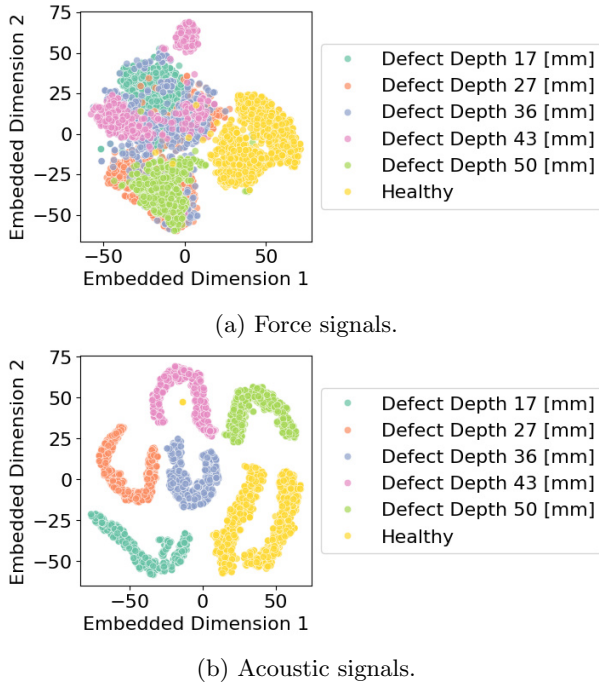


Fig. 7: Scatter plot of embedded signals.

Wavelet 変換を省いた提案手法を青線で、既存手法 [7] を黒線で示している。打音法では、取得した打叩音を STFT により特徴量に変換し t-SNE 次元圧縮をした後、Fuzzy C-means により欠陥識別を行った。t-SNE と Fuzzy C-means は初期値依存性があるため、それぞれの手法を 10 回実行した。全ての手法において、精度の標準偏差は 0.1 未満でありばらつきは小さかったため、Fig. 6 では平均値のみ示している。

既存手法は、打叩位置から欠陥まで深くなるほど識別精度が低下する傾向がみられる。一方、提案手法は欠陥までの深さに依らず精度が安定しており、打音法に匹敵する高い識別精度を示した。

最後に、今回取得したすべての打叩サンプルについて、インパクト法と打音法を t-SNE まで実行した結果を Fig. 7 に示す。力覚信号の埋め込み空間では、健全と欠陥の間に明確な境界が存在するため、インパクト法は精度よく欠陥を識別できる。しかし、欠陥のクラスターは混ざり合っており、欠陥種類の分類は難しいことが示唆される。

音信号の埋め込み空間では欠陥種類ごとにクラスターが形成されている。t-SNE は非線形な次元削減手法であるためクラスターの形が歪になっているが、欠陥種類ごとにまとまっている。HDBSCAN [14] などのデータの粗密を利用したクラスタリング手法を用いることで、打音法は欠陥種類数の自動決定や欠陥種類の分類が教師なく可能であると考えられる。

5 結論

本研究では、従来のインパクト法 [7] の限界を克服するため、力覚信号に適したクラスタリングフレームワークを提案し、実験

によってその有効性を実証した。提案手法は、従来のインパクト法から著しく欠陥識別精度を向上させ、打音法と同等の性能を実現すること確認された。本研究で取り組んだ、信号の短さや類似性に起因する分類の課題は、広範な実世界アプリケーションにおいて共通しているため、提案したクラスタリングフレームワークの応用可能性は広い。

インパクト法は、騒音の影響を受けないため点検現場での高い信頼性が期待できるが、打音法であれば可能な教師なし欠陥種類分類は難しいことが実験によって示唆された。このように、インパクト法と打音法の長所と短所は補完関係にあるため、今後の研究ではインパクト法と打音法を統合した新しい欠陥検知手法の開発に焦点を当てる予定である。

謝辞

本研究の一部は JSPS 科研費 JP21K17829 の助成を受けた。

参考文献

- [1] 国土交通省: 国土交通白書 2018, p.133, 2018.
- [2] 国土交通省: 平成 20 年度国土交通省告示第 282 号, 2007.
- [3] Pangjo Chun, Ji Dang, Shunsuke Hamasaki, Ryosuke Yamajima, Toshihiro Kameda, Hideki Wada, Tatsuro Yamane, Shota Izumi and Keiji Nagatani: "Utilization of Unmanned Aerial Vehicle, Artificial Intelligence, and Remote Measurement Technology for Bridge Inspections", *Journal of Robotics and Mechatronics*, vol. 32, no. 6, pp. 1244–1258, 2020.
- [4] Yuki Nishimura, Shuki Takahashi, Hiromi Mochiyama and Tomoyuki Yamaguchi: "Automated Hammering Inspection System with Multi-Copter Type Mobile Robot for Concrete Structures", *IEEE Robotics and Automation Letters*, vol. 7, no. 4, pp. 9993–10000, 2022.
- [5] Hiromitsu Fujii, Atsushi Yamashita and Hajime Asama: "Automated diagnosis of material condition in hammering test using a boosting algorithm", *Proceedings of the 2014 IEEE International Workshop on Advanced Robotics and its Social Impacts*, pp. 101–107, 2014.
- [6] Jun Younes Louhi Kasahara, Hiromitsu Fujii, Atsushi Yamashita and Hajime Asama: "Clustering of Spatially Relevant Audio Data Using Mel-frequency Cepstrum for Diagnosis of Concrete Structure by Hammering Test", *Proceedings of the 2017 IEEE/SICE International Symposium on System Integration*, pp. 787–792, 2017.
- [7] 湊 真司, ルイ笠原 純ユネス, 禹 ハンウル, 藤井 浩光, 山下 淳, 浅間一: "力センサを用いたコンクリート構造物の変状検出", 第 36 回日本ロボット学会学術講演会予稿集 (RSJ2018), RSJ2018AC3F1-04, pp. 1–3, 2018.
- [8] ルイ笠原 純ユネス, 湊 真司, モロ アレッサンドロ, 禹 ハンウル, 山下 淳, 浅間一: "力センサとカメラのセンサフュージョンに基づいたコンクリート構造物の欠陥検出", *精密工学会誌*, vol. 86, no. 12, pp. 975–981, 2020.
- [9] 湊 真司, ルイ笠原 純ユネス, モロ アレッサンドロ, 禹 ハンウル, 藤井 浩光, 山下 淳, 浅間一: "力センサとカメラからのマルチモーダルデータに基づいたコンクリート構造物の変状検出", *動的画像処理実用化ワークショップ 2020 講演論文集 (DIA2020)*, pp. 261–267, 沖繩, March 2020.
- [10] Alex Grossmann and Jean Morlet: "Decomposition of Hardy Functions into Square Integrable Wavelets of Constant Shape", *SIAM Journal on Mathematical Analysis*, vol. 15, no. 4, pp. 723–736, 1984.
- [11] Laurens van der Maaten and Geoffrey Hinton: "Visualizing Data using t-SNE", *Journal of Machine Learning Research*, vol. 9, pp. 2579–2605, 2008.
- [12] James Churchill Dunn: "A Fuzzy Relative of the ISODATA Process and Its Use in Detecting Compact Well-Separated Clusters", *Journal of Cybernetics*, vol. 3, no. 3, pp. 32–57, 1973.
- [13] Jun Younes Louhi Kasahara, Hiromitsu Fujii, Atsushi Yamashita and Hajime Asama: "Fuzzy Clustering of Spatially Relevant Acoustic Data for Defect Detection", *IEEE Robotics and Automation Letters*, vol. 3, no. 3, pp. 2616–2623, 2018.
- [14] Campello Richard, Moulavi Davoud, Zimek Arthur and Sander Jörg: "Hierarchical density estimates for data clustering, visualization, and outlier detection", *ACM Transactions on Knowledge Discovery from Data*, vol. 10, no. 1, pp. 1–51, 2015.