

# 位相データ解析と機械学習手法を用いた 地下石油タンクからの漏洩検知

大伴 周也<sup>1,a)</sup> 原田 智広<sup>2,b)</sup> ターウォンマツ ラック<sup>3,c)</sup> 伊東 卓男<sup>4,d)</sup>

受付日 2019年12月6日, 採録日 2020年5月12日

**概要:** 近年施設の老朽化によるタンク, 配管施設等からの油漏れが深刻な問題となっている. 石油の漏洩は土壌汚染等の環境問題につながる恐れがあるため, 漏洩を早期に検知することが必要となる. 本論文では, この石油漏洩を早期に発見するための漏洩検知手法を提案し, その有効性を評価する. 提案手法は, 位相データ解析を用いた高水準データ解析で得られる時系列特徴量から, 機械学習を用いて漏洩の有無を判別するモデルを学習する. 実際の石油タンクから得られた液面計データを用いた性能評価実験の結果, 提案手法は非常に少ない漏洩量であっても, 高精度に漏洩判定が可能であることを確認した.

**キーワード:** 漏洩検知, 畳み込みニューラルネットワーク, サポートベクトルマシン, 位相的データ解析, 機械学習

## Oil Leak Detection with Machine Learning and Topological Data Analysis

SYUUYA OHTOMO<sup>1,a)</sup> TOMOHIRO HARADA<sup>2,b)</sup> RUCK THAWONMAS<sup>3,c)</sup> TAKUO ITO<sup>4,d)</sup>

Received: December 6, 2019, Accepted: May 12, 2020

**Abstract:** In recent years, oil leaks from tanks and piping facilities have become a serious problem caused by deteriorated facilities. Since oil leaks may lead to environmental problems such as soil pollution, it is necessary to detect them early. This paper proposes a novel oil leak detection method and evaluates its effectiveness. The proposed method obtains features of the sequential data with high-level data analysis, called Topological Data Analysis, and learns a model to detect oil leaks by using machine learning. This paper conducts experiments by using practical data obtained from actual oil tanks. The experimental result reveals that the proposed method can detect oil leaks with high accuracy even if the amount of leaks is small.

**Keywords:** leak detection, convolutional neural network, support vector machine, topological data analysis, machine learning

<sup>1</sup> 立命館大学情報理工学研究科  
Graduate School of Information Science and Engineering,  
Ritsumeikan University, Kusatsu, Shiga 525–8577, Japan

<sup>2</sup> 東京都立大学システムデザイン学部  
Faculty of System Design, Tokyo Metropolitan University,  
Hino, Tokyo 191–0065, Japan

<sup>3</sup> 立命館大学情報理工学部  
College of Information Science and Engineering,  
Ritsumeikan University, Kusatsu, Shiga 525–8577, Japan

<sup>4</sup> 伊東公業株式会社  
Ito Kogyo Corporation, Kyoto 600–8834, Japan

a) is0250kk@ed.ritsumeikan.ac.jp

b) harada@tmu.ac.jp

c) ruck@is.ritsumeikan.ac.jp

d) takuo@itokogyo.org

## 1. はじめに

近年, 施設の老朽化により, 地下石油タンクや配管から石油の漏洩が深刻化している. 石油漏洩は環境汚染につながることから, 総務省消防庁より老畜タンクの漏洩対策の義務化が制定された [1]. これにより設置から時間の経っているタンクに漏洩検知をする常時監視装置の設置義務づけられた. すでにある漏洩検知の仕組みとしては, 米国環境省 (EPA) が認定した統計学的在庫管理 (Statistical Inventory Reconciliation: SIR) [2] がある. これは日々の販売量, 受入量, 終業時在庫量を入力することで1カ月ご

とにタンクから漏洩があるかどうかの判定結果が通知されるシステムである。しかし、従来の SIR では検知には開始時に 3 カ月分のタンク内のデータが必要であり、さらに 1 カ月ごとに漏洩判定をするため、漏洩の発覚にまで時間を要するという問題がある。

そこで本論文では、少ないデータ数で、かつリアルタイムに漏洩検知が可能な手法を提案し、その有効性を検証することを目的とする。具体的には、時系列データ解析手法と機械学習手法を組み合わせ地下タンクの漏洩を自動検知可能なモデルを生成し、その有効性を実際の地下石油タンクのデータを用いて検証する。時系列データ解析手法には、時系列データ解析に対して用いられる位相データ解析 (Topological Data Analysis: TDA) [3] を用いる。石油地下タンクの液面計から得られる時系列データに対して TDA を適用し、時系列特徴量を抽出する。抽出した時系列特徴量を用いて機械学習モデルを学習し、自動漏洩検知モデルを生成する。

提案手法の有効性を検証するために、実際に産業に利用されている地下タンクデータを 2 種類用意し、作成した学習モデルを用いて漏洩が検知可能かを検証する実験を行う。実験では、EPA が設定した評価基準に従い、漏洩なしの正常な液面計データと、0.05 ガロン/時、0.10 ガロン/時、0.20 ガロン/時の疑似漏洩データを分類する。また、従来 SIR で実現されている 3 カ月分の液面計データを用いた検知に加え、少ないデータ数での検知に対する有効性を検証するために、1 カ月分のデータを用いた実験を行う。機械学習モデルとして、本研究では 1 次元畳み込みニューラルネットワーク (1 Dimensional Convolutional Neural Network: 1D-CNN) [4], [5], サポートベクトルマシン (Support Vector Machine: SVM) [6], ランダムフォレスト (Random Forest: RF) [7] を用い、それぞれの性能を比較する。

本論文の構成は以下のとおりである。最初に 2 章で本論文で参考にする漏洩検知の評価基準について述べる。3 章で、本論文で使用する TDA について説明する。4 章では本論文での提案手法を記す。5 章に本論文の実験方法、設定を示す。6 章にて実験結果を示し、7 章でそれに対する考察を述べる。最後に 8 章に本論文の総括と今後の課題を述べる。

## 2. 漏洩検知

### 2.1 漏洩対策義務

平成 22 年 7 月 8 日に総務省消防庁から危険物の規制に関する規則等の一部を改正する省令 [8], 危険物の規制に関する技術上の基準の細目を求める告示の一部を改正する件 [9] が公布され、平成 23 年 2 月 1 日から施行された [1]. これは地下に直接埋没された地下貯蔵タンクのうち、腐食した可能性の高いタンクの要件を明確化し、該当するタン

クに対する腐食防止策を講ずること、地下タンク等の規制の合理化を主な内容としたものである。要件には、タンクの設置年数、塗覆装の種類、設計板厚の 3 つがあり、要件を満たしたタンクはその内容に応じて「腐食のおそれが特に高い地下貯蔵タンク」と「腐食のおそれが高い地下貯蔵タンク」の 2 種類に区分される。区分によって講じられる防止措置が変わる。「腐食のおそれが特に高い地下貯蔵タンク」では、規定にのっとり腐食を防止するためにコーティング処理を講じなければならない。「腐食のおそれが高い地下貯蔵タンク」ではコーティング処理、または危険物の微小な漏れを検知するための設備の取り付けを講じなければならない。この微小な漏れを検知するための設備には、高い精度で液面を管理する高精度液面計があげられており、迅速な対応が求められるため、漏洩検知精度、発生発覚までの速度が高い設備が必要不可欠である。

### 2.2 EPA の漏洩検知評価基準

地下石油タンクの漏洩検知の評価方法の 1 つとして実際の正常データと漏洩データを用いて、それぞれを正確に判定できるかどうかを評価する方法が考えられる。しかし、この方法は、対象の地下石油タンクから実際に漏洩を発生させたデータが必要であり、現実的ではない。これに対し、EPA (米国環境保護省) は疑似漏洩データを用いた漏洩検知アルゴリズムの評価基準を提供している [10]. この評価基準は業界標準として用いられており、たとえば日本でもエンバイロ・テック・インターナショナル社が EPA の性能評価で認められた漏洩検知アルゴリズムを用いた SIR の事業展開を行っている。このことから、本論文では EPA が提供する評価基準を参考にする。

EPA での評価基準は以下のとおりである。評価基準には、漏洩が発生しているか有無を判定するもの、実際にどれだけの量が漏洩しているか漏洩量を判定するものの 2 種類がある。扱うデータとしては、まず気候と地域が異なり、気密であることが証明されている 41 施設のタンクについて、1 日ごとの「ローリー受入量」、「販売量」、「終業時在庫データ」を 1 カ月分を準備する。次にこの 41 個のデータから疑似漏洩データを作成するために 32 個を無作為に抽出し、以下の 4 つのグループに分ける。

- (1) グループのデータ 8 個には疑似漏洩期待値をゼロとし記録データをそのまま使用。
- (2) グループのデータ 8 個に 0.05 ガロン/時 (4.5L/日) の疑似漏洩値を減算し、疑似漏洩データを作成する。
- (3) グループのデータ 8 個に 0.1 ガロン/時 (9.0L/日) の疑似漏洩値を減算し、疑似漏洩データを作成する。
- (4) グループのデータ 8 個に 0.2 ガロン/時 (18.0L/日) の疑似漏洩値を減算し、疑似漏洩データを作成する。

この作成したデータ各々に対して漏洩の有無と漏洩量の両方に 95%以上の正解率で検知できることを求める。実際

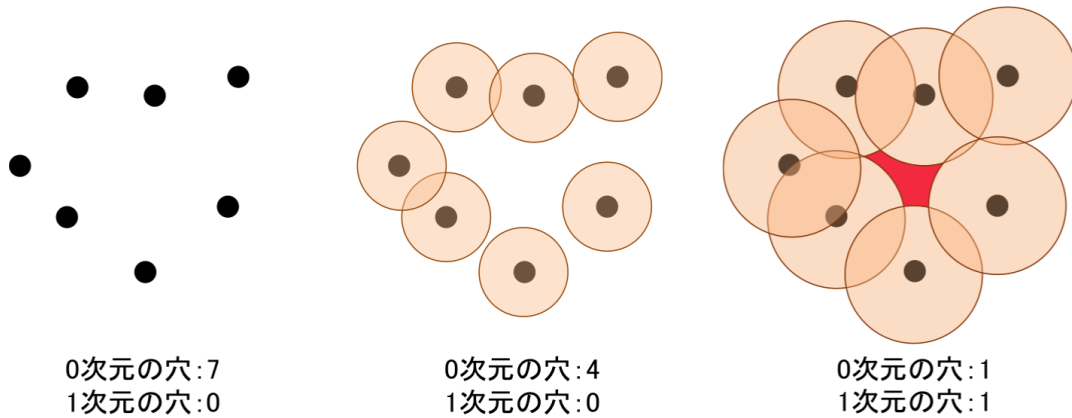


図 1 パーシステントホモロジーの概要図  
Fig. 1 An illustration of the parsistent homology.

の産業利用を考慮した場合、漏洩量を正確に見積もることよりも、漏洩を早期に正確に検知し、迅速に対処することが求められるため、本論文では特に漏洩の有無の判定のみに着目し、漏洩量の推定は行わない。

### 3. 位相データ解析

位相データ解析 (Topological Data Analysis: TDA) とは、位相幾何学 (Topology) の概念を用いたデータ解析手法の総称である。点群データの形状から位相情報を抽出し、データの特徴量を取得する。クラスタリング手法では見落としてしまうような複雑なデータであっても、TDA を用いた高水準データ解析によって明確に分析することが可能となる [11]。主に研究されている TDA には、データの重要部をノードとしてまとめ、そのノード間をエッジでつないだグラフでデータ分布を解析する Mapper [12]、データの分布形状を数値化して解析するパーシステントホモロジー [13] がある。

#### 3.1 パーシステントホモロジー

パーシステントホモロジー (Persistent homology) とは、位相情報を通して点群データの形状を数値として表す手法である。データ群によっては同じ平均、分散を持っていたとしても分布が異なる場合がある。パーシステントホモロジーではそういった分布特徴も反映させたデータ解析が可能になる。

パーシステントホモロジーでは対象の点群データの各点から半径  $a$  の球面を考え、半径  $a$  を徐々に増加させた場合の幾何的情報の時系列的変化に基づいて解析する [14], [15]。ある空間  $T$  の有限点集合  $X = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n)$  があるとき、この  $\mathbf{x}$  の各点を中心とした半径  $a$  の球の和集合を  $C(X; a) := \bigcup_{i=1}^n C(\mathbf{x}_i; a)$  と定義する。ここで、 $C(\mathbf{x}_i; a) = \{\mathbf{y} \in T \mid \|\mathbf{x} - \mathbf{y}\| \leq a\}$  とする。このとき、半径  $a$  の増加にともない、幾何学的な「穴」の発生と消滅が生じる。本論文では特に、独立したデータ点からなる 0 次

元の幾何学的な穴と、半径  $a$  の球がなす円からなる 1 次元の幾何学的な穴を考える。それぞれの穴の発生時の半径  $b_i$  と消滅時の半径  $d_i$  の組からなる集合

$$D_q(X) := \{(b_i, d_i) \mid i \in I\} \tag{1}$$

を  $X$  の  $q$  次元パーシステント図という。

パーシステントホモロジーの具体的な処理の例を図 1 に示す。1 番左は例として、データ数 7 のプロットされた 2 次元の点群データを表す。初期状態では、独立したデータ数、つまり 0 次元の穴の数が 7 となる。各点から円が発生し、次第に半径が大きくなると、円と円が重なる部分が出てくる。重なった円は 1 つのデータとして扱い、これによって 0 次元の穴の数が変化していく。図 1 では 0 次元の穴が 4 つとなる。時間が経過し、円の半径が十分に大きくなると円がすべて重なり、0 次元の穴の数が 1 となる。加えて、円で囲まれた領域が発生し、1 次元の穴の数が 1 となる。

#### 3.2 パーシステントホモロジーに基づく特徴抽出

パーシステント図を CNN の入力として用いるために、0 次元と 1 次元の穴の発生や消滅による個数の時系列的遷移を Betti sequence と呼ばれる特徴量に変換する方法が提案されている [16]。以下の図 2 が図 1 のパーシステントホモロジーによって抽出される特徴量の例を表す。横軸は半径のサイズ、縦軸は穴の数を表し、青線のグラフは 0 次元の穴の数の遷移、赤線のグラフは 1 次元の穴の数の遷移を表す。図 1 の初期の状態では、7 つの点データが存在するので 0 次元の穴の数は 7 からスタートし、1 次元の穴は発生していないので、0 からスタートする。ここから円の半径が大きくなるにつれ 0 次元の穴が減少していく。図 1 の右図の時点で 1 次元の穴が発生し、ここで 0 次元の穴の数が増加する。十分に円の半径が大きくなると、すべてのデータ点が重なり、1 次元の穴が消滅し、0 次元の穴の数が 1、1 次元の穴の数が 0 になる。

本論文で扱うデータは時系列データであり、TDA を適用するために、時系列データを点群データに変換する。時系列データ  $V = \{v_1, v_2, \dots, v_n\}$  を時間遅れの大きさ  $\tau$  として  $m$  次元の再構成状態空間における埋め込みベクトル (embedding vector) として  $\mathbf{x}_t = (v_t, v_{t+\tau}, \dots, v_{t+(d-1)\tau})$  表現すると、時系列データの遷移特徴を表現できることが知られている [17], [18]。従来研究 [16] ではこの特徴を用

い、埋め込み空間での幾何学的特徴量を TDA によって抽出する。具体的には、本研究では従来研究と同様に時間遅れ  $\tau = 1$ 、再構成状態空間の次元数  $m = 3$  とし、時系列データ  $V = \{v_1, v_2, \dots, v_n\}$  の隣り合った 3 データを各次元のパラメータとし、1つの 3次元データとする。この処理を元データの末尾まで行い、新たにデータ  $\mathbf{x}_i = (v_i, v_{i+1}, v_{i+2})$  ( $i = 1, 2, \dots, n-2$ ) を生成する。図 3 は時系列データから 3次元点群データへ変換する概念図を表す。

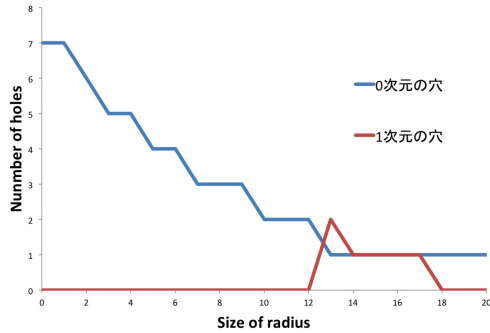


図 2 TDA によって抽出された Betti sequence  
Fig. 2 A Betti sequence extracted with TDA.




図 3 時系列データから点群データへの変換  
Fig. 3 Conversion of time-series data to point cloud data.

#### 4. 提案手法

本論文では、地下石油タンクの漏洩検知のために、TDA と機械学習手法を組み合わせた漏洩検知手法を提案する。図 4 に学習手法の全体の流れを示す。漏洩が発生していない正常な地下タンク内から得られる液面計データから擬似的な漏洩データを作成し、正常なデータと漏洩データの 2 種類の学習データを用意する。学習データの各計測データから、計測誤差量を算出し、新たな時系列データを作成する。作成した計測誤差量時系列データと TDA を用いて時系列特徴量を抽出する。抽出した特徴量から機械学習手法を用いて漏洩検知モデルを生成する。生成した検知モデルに未知のデータを入力することで、そのデータが漏洩しているかどうかを判定する。

##### 4.1 学習データ

本論文で扱うデータは実際に産業利用されている地下埋設石油タンク内にある液面計、および流量計によって取得した時系列データを使用する。得られる情報は液面計の瞬

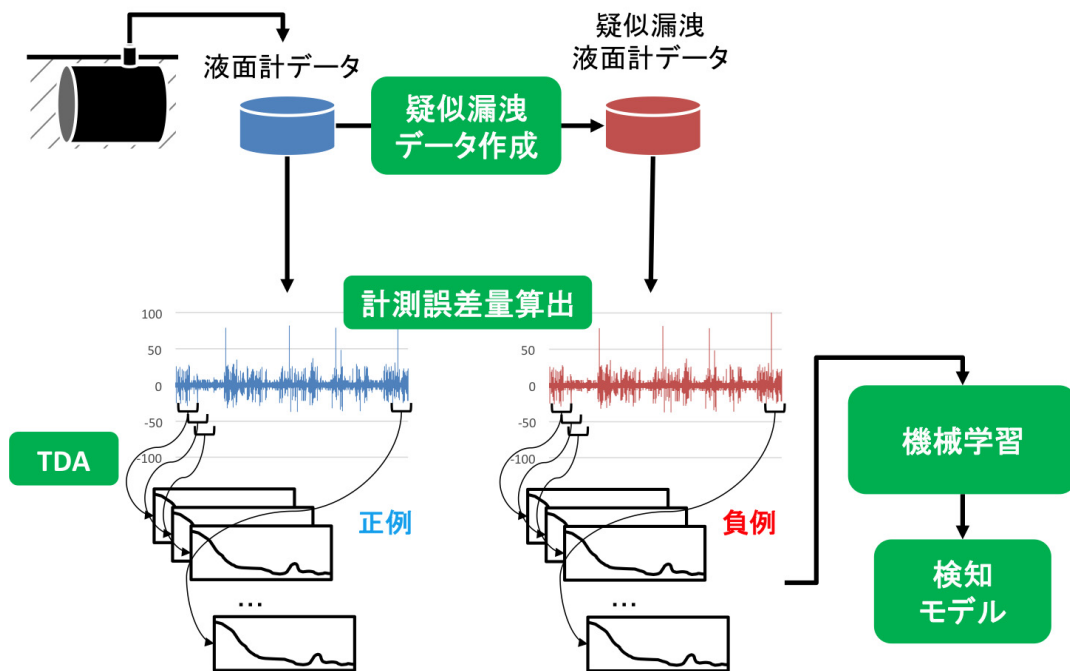


図 4 提案手法の学習の流れ  
Fig. 4 An illustration of the learning flow of the proposed method.

時値, 最大値, 最小値, 平均値と流量計積算量がある. 以上のデータが 10 分ごとに計測され, 記録される.

#### 4.1.1 疑似漏洩データ作成

一般的な機械学習手法では, 学習のために正例と負例のラベルの付いた学習データを用意し, それらを適切に判別可能なモデルを学習する必要がある. そのため, 漏洩検知モデルの学習の際には, 正例となる漏洩のないデータと, 負例となる漏洩のあるデータを用意する必要がある. しかし, 地下埋設石油タンクのデータでは, 漏洩のあるデータを取得することは現実的ではない. そこで本論文では, 負例となる漏洩のあるデータとして, 正常データから作成した疑似漏洩データを用いる. 本論文で作成する疑似漏洩データは EPA の評価基準に従い, 漏洩量が 0.05 ガロン/時の場合を想定する. 具体的には, 正常データの液面計最大値, 最小値, 平均値に対し, 1 時間あたり 0.05 ガロンに相当する値を差し引いたデータを作成する. ここで, 本論文で使用する液面計データは 10 分ごとの値となるため, 10 分ごとにデータに対して 0.05 ガロン/時に相当する漏洩量である  $3.15 \times 10^{-2} l/10$  分を差し引く. ただし, つねに一定量データを差し引くのではなく, 乱数により差引量にばらつきを持たせて漏洩するように設定する. 具体的には, 確率 0.9 で  $3.0 \times 10^{-2} l/10$  分, 確率 0.1 で  $4.0 \times 10^{-2} l/10$  分データから差し引く. これにより, 平均として  $3.1 \times 10^{-2} l/10$  分の漏洩を含む液面計データを擬似的に作成する.

#### 4.2 計測誤差算出

本来的にはタンクから得られる液面計と流量計の両データ間には誤差はなく, 液面計の変化量と流量計の数値の差は 0 になる. しかし, 実際のタンクデータは液面の揺れ等による誤差が発生する. これより漏洩のしていないのデータと漏洩のしているデータでは漏洩による誤差の特徴に違いがあると考えられる. よって本論文では液面計のデータをそのまま使用するのではなく, 液面計データと流量計のデータから累計誤差を誤差を求め, 計測誤差時系列データを作成する. 式に誤差  $\varepsilon$  を求める式を示す.

$$\varepsilon = E(t) - E(0) + (Q(t) - Q(0)) \quad (2)$$

式において,  $E(t)$  は  $t$  番目の液面計のデータ,  $Q(t)$  は  $t$  番目の流量計データを表す. 液面計と流量計の誤差がない場合は 0 となる. これにより, 液面時系列データを誤差時系列データに変換し, TDA の入力データとする.

基本的な液面計, 流量計の変化は人の手によるタンクからの石油の出し入れによって起こる. この人為的石油の流入出が発生した後は誤差が発生し, 人為的な流入出が頻繁に起こるようなデータでは, 誤差が大きくなる. 誤差が大きくなると漏洩による微少な誤差を認識しにくくなるため, 誤判定の原因となる. このような誤差を排除するため, 人為的な流入出が認められるデータ部分を考慮しない処理を

施す. 人為的な流入が見られた場合, 流入部分から一定期間のデータを無視し, 誤差 0 とする. 人為的な流出部分が認められる場合, そのデータ部分を無視する. このように流入出部分がある程度無視することによって, 液面が安定している時点での判別となり, より検知精度の向上を見込める.

#### 4.3 計測誤差量時系列データの 3 次元データへの変換

計測誤差量時系列データを TDA で扱うために, 3 次元点群データへ変換する. 3.2 節で述べた変換方法と同様に 3 つの隣り合った誤差データを各次元のパラメータとし, 1 つのデータにまとめあげる. これを誤差データ群  $\epsilon_i$  ( $i = 1, 2, \dots, n$ ) の末尾まで行い, 新たにデータ  $\mathbf{x}_i = (\epsilon_i, \epsilon_{i+1}, \epsilon_{i+2})$  ( $i = 1, 2, \dots, n-2$ ) を生成する. この変換された点群データを TDA に適用する.

#### 4.4 TDA 特徴量抽出

パースistentホモロジーに一度にすべてのデータを入力するのではなく, 1 日分のデータ (60 分/10 分  $\times$  24 時 = 144 データ) ごとに特徴量を抽出する. これは, 石油タンクの実運用を考慮した場合, 1 日単位で利用履歴の周期性が見られると想定されるためである. また, 入力データ数を増加させた場合, TDA 特徴量抽出に要する計算量が增大するため, 最小単位である 1 日分のデータを入力とする. 球の半径増加による 0 次元の穴の遷移, 1 次元の穴の遷移を各 300 データ計測し, 1 日あたり 600 データの時系列特徴量を抽出する. これを 10 分ずらしてデータの末端まで特徴量を抽出していき, 1 カ月あたり  $(N-2) \times 600$  次元 ( $N$  は元の入力データ数) の特徴量を生成する.

#### 4.5 機械学習手法によるモデル作成

TDA によって抽出された特徴量を入力とし, 機械学習手法を用いて漏洩検知モデルを生成する. 漏洩なしのデータには 0, 漏洩ありのデータに 1 とラベル付けをして学習する. 生成されたモデルは新たに入力されたデータに対し, 漏洩していないと判定したときは 0, 漏洩していると判定したときは 1 と出力する 2 値分類モデルとなる.

#### 4.6 未知データに対する漏洩判定

生成された検知モデルを用いて新たな未知データに対する漏洩の判定をする. 漏洩しているか判定をしたい未知のデータに対しても, 計測誤差算出し, TDA による特徴量抽出を行い, これを入力データとする. モデルにこのデータを入力し, 予測スコア (0 から 1) を算出し, 漏洩の有無を判定する. 入力データは 1 カ月分のデータを入力し, 各 Betti Sequence ごとに漏洩判定し, 全判定のうち多数になる判定をその月の判定とする.




図 5 本実験の 1D-CNN 構造

Fig. 5 1D-CNN structure in this experiment.

## 5. 実験

提案手法の地下石油タンク漏洩検知への有効性を検証するための実験を行う。本実験では、機械学習手法として 1 次元畳み込みニューラルネットワーク (1D-CNN), サポートベクトルマシン (SVM), ランダムフォレスト (RF) を用いる。

### 5.1 実験データ

本論文で扱うデータは伊東公業株式会社より提供された 2 種類の地下埋設石油タンクの液面計から 10 分ごとに取得したデータである。2 種類のデータにそれぞれを S データ, I データとする。2 種類のデータには違った特徴があり, 人為的な石油の入出が S データは少なく, I データは多くなっている。S データは 2016 年 11 月から 2017 年 12 月までの 14 カ月分, I データも同様に 2017 年 6 月から 2018 年 9 月までのうち, データが欠損していた 2017 年 10 月, 2018 年 3 月を除いた 14 カ月分で計測されたデータである。元々取得したデータは漏洩のしていない正常なデータのみであり, このデータを利用し EPA の評価基準に従って疑似的に漏洩データを作成する。

### 5.2 実験パラメータ

実験パラメータを表 1 に示す。TDA では, 球半径  $r$  は 0 から 20 になるまでのデータを計測する。その間 300 データ計測するため, 半径の増加量は  $20/300 \approx 0.067$  となる。一度に TDA に入力するのは 1 日分にあたる 144 データになる。TDA の実装には, CRAN から提供されている R 言語用の TDA パッケージ\*1 を用いた。

1D-CNN では, バッチサイズは 16, エポック数は 50 とする。最適化関数には Adam [19] を用い, 学習率は 0.001 とした。損失関数は Binary Cross entropy に設定した。1D-CNN の実装には, Keras ライブラリ\*2 を用いた。図 5 に本実験で扱う 1D-CNN の構造を示す。畳み込み層内の数字はフィルタサイズ  $\times$  フィルタ数/ストライドを表す。プーリング層内の数字はフィルタサイズ/ストライドを表

表 1 実験パラメータ

Table 1 Parameter settings.

TDA のパラメータ	
球半径範囲 $r$	$0 \leq r \leq 20$
半径増加量 $\Delta r$	0.067
入力データ数 $n$	144
1D-CNN のパラメータ	
バッチサイズ	16
エポック数	50
最適化関数	Adam
学習率	0.001
損失関数	Binary cross entropy
SVM のパラメータ	
ペナルティ	L2 正則化
損失関数	二乗ヒンジ
パラメータ $C$	1.0
RF のパラメータ	
決定木の個数	15
スレッド数	2
データ分割基準	gini
ノード分割のための最低サンプル数	2

す。全体の構成としては 1 次元畳み込み 4 層, 1 次元プーリング 4 層, バッチ正規化 [20], [21] 4 層, データ平滑化処理後に全結合層の構成となっている。1 次元畳み込み層の 1, 2, 3 層目はフィルタサイズは 3, フィルタの数は 64, ストライドは 1 としている。第 4 層の 1 次元畳み込み層のみ, フィルタの数が 32 となっている。1 次元プーリング層はすべて平均プーリングを用いており, ストライドは 1 と設定している。第 1 プーリング層のみフィルタサイズが 3, 第 2, 3, 4 プーリング層がフィルタサイズが 1 となっている。各 1 次元畳み込み層の後にバッチ正規化層を用いている。その後, 平滑化層を通し, 出力数 256 と 1 の全結合層の 2 層で構成している。

SVM と RF は scikit-learn [22] に用意されている実装を用いる。SVM では, ペナルティに使用される正規化手法として L2 正則化, 損失関数には二乗ヒンジを用いている。正則化パラメータ  $C$  は 1.0 とした。RF では, 決定木の数を 15, スレッドの数を 2, ノード分割に必要なサンプル数を 2 とした。決定木の深さはすべて葉ノードが純粋になるまで, または設定したサンプル数以下を含むまで深さを拡

\*1 <https://cran.r-project.org/web/packages/TDA/index.html>

\*2 <https://keras.io/>

張する設定である。データの分割基準には二乗ヒンジを用いている。

### 5.3 学習方法

SIR と同等の 3 カ月分のデータで学習するモデルパターンと 1 カ月分のデータで学習するモデルパターンの 2 パターンで学習する。3 カ月分のデータで学習するパターンは実験データのうち、隣り合った 3 カ月分のデータを選び出し学習データとする。各月に対して、漏洩していない正常データ、0.05 ガロン/時の漏洩を擬似的に再現したデータを使用し、1 モデルにつき 6 カ月分（正常データ 3 カ月分、漏洩データ 3 カ月分）のデータを使用する。S データと I データは混合せず、S データを使用するときは S データのみ、I データを使用する場合は I データのみとタンクごとに独立して学習する。S データの 2016 年 11 月から 2017 年 1 月、2016 年 12 月から 2017 年 2 月、のように 2017 年 10 月から 2017 年 12 月までの 12 通りすべての組合せで学習し、検知モデルを生成する。I データでは欠損したデータである 2017 年 10 月のデータ、2018 年 3 月のデータを含む学習データの組合せは除き、同様の操作をし、検知モデルを生成する。これによって S データを使ったモデルを 11 個、I データを使ったモデルを 7 個生成する。

1 カ月分のデータで学習するパターンは、各月ごとのデータで学習し、それぞれ検知モデルを生成する。S データは 2016 年 11 月から 2017 年 12 月までの 14 個、2017 年 6 月から 2018 年 9 月までの I データ 14 個（2017 年 10 月、2018 年 3 月を除く）のモデルを生成する。

### 5.4 評価方法

生成した検知モデルを用いて、未知データに対する漏洩検知を行い、検知モデルの性能を検証する。検知精度は対象データに対する検知正答率で見ると、生成したすべてのモデルで検知を行い、その正答数を合算し正答率を算出する。検証対象のデータは正常データ、0.05 ガロン/時漏洩データに加え、4.1.1 項と同様の方法で EPA の評価基準となる 0.10 ガロン/時、0.20 ガロン/時の漏洩データを作成する。実際に産業で利用する場合を想定し、モデルの学習データ 1 カ月後、2 カ月後のデータに対する検知精度を検証する。加えて S データで学習したモデルはすべての S データに対して、I データで学習したものはすべての I データに対して漏洩検知を行い、その精度を検証する。この 1 カ月後、2 カ月後、データ全体の漏洩ありデータ、漏洩なしデータそれぞれのパターンに分け正答率を算出する。最後に漏洩なし、ありのデータをすべて合算した正答率を算出し、評価する。

## 6. 実験結果

### 6.1 検知精度

表 2 と表 4 に S データと I データの 3 カ月分のデータに対して 1D-CNN, SVM, RF を用いて学習したモデルの検知結果を示す。表 3 と表 5 に S データと I データの 1 カ月分のデータに対して 1D-CNN, SVM, RF を用いて学習したモデルの検知結果を示す。表中の正常が漏洩をしていないデータに対しての結果、漏洩が各漏洩量の漏洩データに対する検知結果である。全データ合算は漏洩なし、あ

表 2 S タンクデータにおける 3 カ月分の学習データを用いて学習したモデルの実験結果  
Table 2 The result for the S tank data detected by the model learned with three months data.

	1D-CNN			SVM			RF		
	1 カ月後	2 カ月後	全 S データ	1 カ月後	2 カ月後	全 S データ	1 カ月後	2 カ月後	全 S データ
正常	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	0.0%	0.0%	0.0%
0.05 ガロン/時漏洩	100.0%	100.0%	94.8%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
0.10 ガロン/時漏洩	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
0.20 ガロン/時漏洩	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
全データ合算	100.0%	100.0%	98.7%	100.0%	100.0%	100.0%	75.0%	75.0%	75.0%

表 3 S タンクデータにおける 1 カ月分の学習データを用いて学習したモデルの実験結果  
Table 3 The result for the S tank data detected by the model learned with one month data.

	1D-CNN			SVM			RF		
	1 カ月後	2 カ月後	全 S データ	1 カ月後	2 カ月後	全 S データ	1 カ月後	2 カ月後	全 S データ
正常	100.0%	100.0%	99.5%	100.0%	100.0%	100.0%	0.0%	0.0%	0.0%
0.05 ガロン/時漏洩	100.0%	100.0%	95.4%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
0.10 ガロン/時漏洩	100.0%	100.0%	99.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
0.20 ガロン/時漏洩	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
全データ合算	100.0%	100.0%	98.3%	100.0%	100.0%	100.0%	75.0%	75.0%	75.0%

表 4 I タンクデータにおける 3 カ月分の学習データを用いて学習したモデルの実験結果

Table 4 The result for the I tank data detected by the model learned with three months data.

	1D-CNN			SVM			RF		
	1 カ月後	2 カ月後	全 S データ	1 カ月後	2 カ月後	全 S データ	1 カ月後	2 カ月後	全 S データ
正常	100.0%	100.0%	100.0%	100.0%	100.0%	99.0%	100.0%	100.0%	100.0%
0.05 ガロン/時漏洩	92.9%	100.0%	92.9%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
0.10 ガロン/時漏洩	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
0.20 ガロン/時漏洩	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
全データ合算	98.2%	100.0%	98.2%	100.0%	100.0%	99.75%	100.0%	100.0%	100.0%

表 5 I タンクデータにおける 1 カ月分の学習データを用いて学習したモデルの実験結果

Table 5 The result for the I tank data detected by the model learned with one month data.

	1D-CNN			SVM			RF		
	1 カ月後	2 カ月後	全 S データ	1 カ月後	2 カ月後	全 S データ	1 カ月後	2 カ月後	全 S データ
正常	100.0%	85.7%	94.4%	100.0%	92.9%	95.4%	100.0%	100.0%	99.0%
0.05 ガロン/時漏洩	92.9%	92.9%	94.9%	100.0%	100.0%	99.0%	100.0%	100.0%	99.0%
0.10 ガロン/時漏洩	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
0.20 ガロン/時漏洩	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
全データ合算	98.2%	94.6%	97.3%	100.0%	98.2%	98.6%	100.0%	100.0%	99.5%

りのデータをすべて合わせた正答率となっている。

3 カ月分の S データで学習した結果を見ると、1D-CNN と SVM を用いて学習したモデルは漏洩していないデータではすべてのデータに対して判定できている。0.10 ガロン/時、0.20 ガロン/時、漏洩しているデータに対しても同様に判定正答率が 100.0% になっている。0.05 ガロン/時漏洩しているデータに関しては、1D-CNN では、1 カ月後、2 カ月後のデータに対しては正答率は 100% となったが、全データを通しては判定正答率が 94.8% となっており、154 データ中 8 データ漏洩の判定に失敗した。判定に失敗したのは、いずれも 2016 年 11 月から 2017 年 1 月のデータを学習したモデルであり、2017 年 5 月から 2017 年 12 月の 0.05 ガロン/時に対するデータに対してであった。一方、SVM を用いたモデルでは、0.05 ガロン/時漏洩しているデータに対しても 100.0% の判定正答率となった。RF のモデルでは、全 S データに対して漏洩ありと判定し、漏洩なしのデータをまったく判定できない結果となった。

1 カ月分の S データで学習した結果では、1D-CNN と SVM を用いたモデルで 1 カ月後、2 カ月後の正常データに対して正答率 100.0% を記録した。全データを通しては、1D-CNN は正常データ、0.05 ガロン/時漏洩、0.10 ガロン/時漏洩のデータで誤判定をするデータがあり、それぞれ正答率は 99.5%、95.4%、99.0% となった。合算した結果では、正答率は 98.3% となり 3 カ月学習モデルより正答率が下がっているが 1 カ月分の学習データでも十分な精度を記録している。一方、SVM を用いた場合はいずれのデータも判定正答率が 100% となった。RF のモデルでは、3 カ月分のデータで学習した場合と同様にすべてのデータに対し

て漏洩と判定し、正常データに対する判定正答率が 0% であった。

I データの結果を見ると、3 カ月分の学習データでは S データの結果同様、1D-CNN と SVM を用いたモデルで正常データの判定は正答率 100.0% を記録し、RF でも 100% の判定正答率であった。また、0.10 ガロン/時、0.20 ガロン/時漏洩しているデータに対しても判定正答率はすべての手法で 100.0% であった。一方、0.05 ガロン/時漏洩しているデータでは、1D-CNN が 98 データ中、7 データの判定に誤りがあり、正答率は 92.9% となった。また、S データと異なり 0.05 ガロン/時漏洩データの判定結果で、1 カ月後に対するデータに判定誤りが 1 つ発生した。2018 年 6 月から 2018 年 8 月のデータで学習したモデルであり、2018 年 9 月に対しての誤判定であった。2018 年 6 月から 2018 年 8 月のモデルは I データモデルのなかで最も誤判定している (4 データ)。一方、SVM と RF を用いたモデルでは、0.05 ガロン/時漏洩しているデータに対しても 100% の判定正答率を達成し、全データに対しても SVM が正常データに対して 2 データのみ誤判定している以外は正しく判定できていることが分かる。

I データの 1 カ月分の学習結果では、正常データに対する正答率が低下しており、2 カ月後のデータに対して誤判定がいくつか発生していることが分かる。具体的には、全体データに対して、1D-CNN で学習したモデルの正常データに対する判定正答率が 94.4% に低下している。SVM で学習したモデルでも、正常データに対して 95.4%、0.05 ガロン/時漏洩データに対して 99.0% の判定正答率となり、3 カ月分のデータを用いた学習と比較して正答率は低下して



表 6 実験で使用した計算環境

Table 6 Computational environment used in the experiment.

OS	Windows 7 Professional 64 bit
CPU	Intel(R) Xeon(R) CPU E5-1650 x2 3.50 GHz
メモリ	16.0 GB

表 7 S タンクデータ計算時間

Table 7 Computing time for S tank data.

使用データ	実行時間 [秒]
2016/11	100.99
2016/12	86.40
2017/1	87.75
2017/2	62.40
2017/3	65.17
2017/4	68.68
2017/5	68.02
2017/6	69.00
2017/7	69.27
2017/8	76.70
2017/9	64.33
2017/10	74.85
2017/11	67.32
2017/12	70.82
平均時間	73.69

いる。一方、RF を用いて学習したモデルの判定正答率が最も高く、正常データ、0.05 ガロン/時漏洩データともに判定正答率 99.0% を達成した。このことから、他の 3 パターンの結果と比較すると、I データの 1 カ月分の学習では合算の正答率が低くなるのが分かる。しかし、いずれのモデルも全データでは判定正答率が EPA の定める基準である 95.0% 以上を達成可能であることが分かった。

以上の結果から、1D-CNN と SVM を用いて学習したモデルは漏洩検知をするうえで、いずれも十分な精度を持っているといえ、特に学習データ月に近い月に対しては高い正答率を実現できた。一方、RF を用いて学習したモデルは、I データでは最も精度の高いモデルであったが、S データではすべてを漏洩ありと判定する結果となり、特に変動の少ないデータに対して他の 2 手法と比較して性能が劣ることが分かった。このことから、TDA と 1D-CNN、または SVM を用いた漏洩検知の精度は 1 カ月分のデータで EPA の評価基準の正答率を満たしており、漏洩検知に有効な手法であるといえる。

## 6.2 計算時間

提案手法のリアルタイム性を評価するために、提案手法を用いる場合の判定に要する計算時間を計測する。具体的には、1 カ月分のデータを TDA を用いて特徴量を抽出し、生成した漏洩検知モデルで漏洩判定結果を出力するまでに要する時間を計測する。実験は、表 6 に示す計算環境で

表 8 I タンクデータ計算時間

Table 8 Computing time for I tank data.

使用データ	実行時間 [秒]
2017/6	48.72
2017/7	57.68
2017/8	64.52
2017/9	36.15
2017/11	44.95
2017/12	47.56
2017/1	61.03
2017/2	61.41
2017/4	33.97
2017/5	47.85
2017/6	40.50
2017/7	43.83
2017/8	38.90
2017/9	48.73
平均時間	52.66

実行し、機械学習手法としては最も計算量の多い 1D-CNN を用いる。

S タンクデータと I タンクデータを用いて計測した実行時間を表 7 と表 8 に示す。S データでは、平均で 73 秒、最長でも 100 秒程度で漏洩検知を実行できていることが分かる。一方、I データではいずれのデータでも 1 分ほどで漏洩検知を実行できていることが分かる。1 カ月ごとの漏洩検知結果を 1 分程度で得られることから、十分に実運用で利用可能であるといえる。また、1 カ月分のデータには約 500 データ含まれることから、10 分間隔で扱う 1 データ (60 分/10 分 × 24 時間 = 144 計測点) あたりの計算はすべて 1 秒以内に完了可能であり、リアルタイムな判定にも適用可能であるといえる。

## 7. 考察

S データと I データの正答率を比較すると、I データに対する正答率が低くなっている。ここで、I データと S データの液面計瞬時値のグラフを比較する。図 6、図 7 に S データ、I データそれぞれの液面計の例を示す。I データは S データに比べ、人為的な石油の出入機会が多く、非常に数値が安定していない。それに対し S データは液面計から見ると人為的な石油の出入が見分けやすいデータになっていると見ることができる。出入機会が多いことで、液面の上下が頻発し、液面計の小さな振幅がノイズとなり、漏洩検知の精度を下げる原因になると考えられる。さらに、液面計の最大値、最小値にも違いが見られる。S データは最大値はどれも 20,000 を超えており、最小値は 5,000 を下回ることではない。それに対して I データは最大値は最も高いもので約 13,000、最小値は 2,200 と S データと比べると取扱量が少ない。取扱量が少ないと人為的な流出量も少なくなることで、漏洩との誤差判別が難しくなり、漏洩と流出




図 6 S タンクデータにおける液面計の 1 カ月推移の例

Fig. 6 An example of the transition of the liquid level meter in one month data of S tank.



図 7 I タンクデータにおける液面計の 1 カ月推移の例

Fig. 7 An example of the transition of the liquid level meter in one month data of I tank.




図 8 S タンクデータの各月の液面瞬時値分布

Fig. 8 A box plot of liquid level meter in S tank data for each month.

の判定に影響を及ぼしている。

S データでは、一部の 0.05 ガロン/時漏洩データに対して誤判定を行ったが、ここで元の液面計データによって違いがないか検証する。S データでは 2016 年 11 月のデータを学習データに含むモデルの正答率が低く、このデータと他のデータを比較する。図 8 に S データの液面計瞬時値の箱ひげ図を示す。S201611 は S データの 2016 年 11 月の液面計瞬時値を表し、2017 年 12 月のデータまでの全 S データの箱ひげ図を比較している。11 月のデータでは他のデータと比べ、中央値が分布に対して低い位置にある。11 月の液面計瞬時値の推移では、人為的な流出と流入間の期間が長く、液面計瞬時値が大きく変わらない箇所が多いデータ

特徴を持っている。他のデータでは、人為的な流出が定期的に行われており、このようなデータ特徴の違いによって漏洩パターンに差が生まれ、誤判定の原因になっていると考えられる。

I データでは、各モデルごとに判定精度の高いデータ、低いデータがあり、2つの傾向が見られた。1つ目は、夏期のデータに対する検知精度が高く、冬期の月データの検知精度が低いモデルである。これは主に夏期のデータで学習したモデルであり、冬期のデータに対して漏洩ありデータに対する検知精度が低かった。2つ目は冬期のデータに対する検知精度が高く、夏期の月データに対して検知精度が低いモデルである。これは冬期の月データで学習したモデルであり、夏期の場合とは違い、正常データに対する検知精度が低かった。このような検知傾向の違いは、季節による石油の取り扱い方の違いからデータの傾向が異なるからだと考えられる。このことから、検知対象となる月から離れた月（異なる季節）のデータを学習に用いる場合、検知精度が低下する可能性が示唆される。一方、実験結果から、検知対象となる月の直前 3 カ月のデータを学習に用いることで 100.0% の検知精度が達成できている。そのため、提案手法の実運用を想定した場合は、長期間にわたるデータが蓄積された場合であっても判定対象となる月の直近 3 カ月データを用いて学習することが有効であるといえる。

## 8. おわりに

本論文では、TDA と機械学習を用いた地下タンク漏洩検知手法を提案し、その有効性を検証した。具体的には、TDA を用いて液面計データの特徴量を抽出し、抽出した特徴量と機械学習を用いて漏洩検知モデルを生成した。生成した検知モデルを用いて、学習データの 1 カ月後、2 カ月後データ、全データに対する漏洩検知正答率を検証した。実験では、機械学習手法として 1D-CNN, SVM, RF を用い、各手法の検知精度を比較した。本実験の結果、1D-CNN と SVM を用いて学習した検知モデルによる漏洩精度は、S データ、I データの各実データに対して 95.0% 以上の精度を記録した。実際に産業で利用することを想定した 1 カ月後、2 カ月後の精度検証では特に正答率が高い結果となった。これより、漏洩検知において TDA と機械学習を組み合わせた検知手法は有効であるといえる。

本論文では、提案手法により高い精度で漏洩判定をできているが、月日が離れたデータに対しては誤判定や、モデルの予測スコアの低下が見られた。このため、より様々なデータに対して頑健な検知モデルを生成する必要がある。データの季節や、油量によるデータのばらつきを考慮したデータ処理を活用することで、より精度の向上が期待できる。加えて検知する際に Betti Sequence ごとに漏洩判定しているため、一定期間での判定条件を設けることで、リアルタイムの漏洩検知への適用も可能であると考えられる。

一方、本研究では漏洩データとして実際の漏洩データではなく EPA の基準に基づく疑似漏洩データを用いて検証した。しかし、学習データと検証データで同一の疑似漏洩生成モデルを用いることから、疑似漏洩データを用いて学習したモデルが実際の漏洩データに対して有用かどうかは検証できていない。この点は提案手法の適用可能性に関する限界の 1 つであり、今後さらなる検証が必要である。

今後はリアルタイム漏洩検知システムへの適用、Recurrent Neural Network (RNN) 等の他機械学習手法等を調査し、さらなる精度の高い検知モデル生成手法を探求する。また、疑似漏洩データを用いない学習モデルを模索し、疑似漏洩データの生成モデルに依存しない漏洩検知手法を確立する。

謝辞 本論文は、平成 29 年度関西アーバン銀行共同研究助成金の助成を受けたものです。

### 参考文献

- [1] 消防庁：既設の地下貯蔵タンクに対する流出防止対策に係る運用について、消防危第 144 号，平成 22 年 7 月 8 日公布 (2010).
- [2] United States Environmental Protection Agency: Introduction to Statistical Inventory Reconciliation for Underground Storage Tanks, 5403W Washington, DC 20460, EPA 510-B-95-009 (1995).
- [3] Carlsson, G.: Topology and data, *Bulletin of the American Mathematical Society*, Vol.46, pp.255–308 (2009).
- [4] Lecun, Y., Bottou, L., Bengio, Y. and Haffner, P.: Gradient-based learning applied to document recognition, *Proc. IEEE*, Vol.10, pp.2278–2324 (1998).
- [5] Lecun, Y., Kavukcuoglu, K. and Farabet, C.: Convolutional Networks and Applications in Vision, *Proc. International Symposium on Circuits and Systems*, pp.253–256 (2010).
- [6] Cortes, C. and Vapnik, V.: Support-vector networks, *Machine Learning*, Vol.20, pp.273–297 (1995).
- [7] Breiman, L.: Random Forests, *Machine Learning*, Vol.45, pp.5–32 (2001).
- [8] 総務省：危険物の規制に関する規則等の一部を改正する省令，平成 22 年総務省令第 71 号，平成 22 年 6 月 28 日公布 (2010).
- [9] 総務省：危険物の規制に関する技術上の基準の細目を定める告示の一部を改正する件，平成 22 年総務告示第 246 号，平成 22 年 6 月 28 日公布 (2010).
- [10] Maresca, J.W., Smedfeld, R.M., Wise, R.F. and Starr, J.W.: Standard test procedures for evaluating leak-detection methods: Pipeline leak-detection systems, Final Report, Technical Report, Vista Research, Inc., Mountain View, CA (USA) (1990).
- [11] 梅田裕平：データの形が教えてくれること—トポロジカル・データ・アナリシスとその応用，*情報処理*, Vol.57, No.11, pp.1122–1127 (2016).
- [12] Singh, G., Memoli, F. and Carlsson, G.: Topological Methods for the Analysis of High Dimensional Data Sets and 3D Object Recognition, *Eurographics Symposium on Point-Based Graphics*, Botsch, M., Pajarola, R., Chen, B. and Zwicker, M. (Eds.), The Eurographics Association (online), DOI: 10.2312/SPBG/SPBG07/091-100 (2007).
- [13] Edelsbrunne, H., Letscher, D. and Zomorodian, A.: Topological Persistence and Simplification, *Discrete and Computational Geometry*, Vol.28, No.4, pp.511–533 (2002).
- [14] Zomorodian, A. and Carlsson, G.: Computing Persistent Homology, *Discrete and Computational Geometry*, Vol.33, No.2, pp.249–274 (2005).
- [15] 大林一平：パーシステントホモロジー—数学と情報科学の融合による「かたち」のデータ解析，*日本数学会秋期総合分科会* (2018).
- [16] Umeda, Y.: Time Series Classification via Topological Data Analysis, *人工知能学会論文誌*, Vol.32, No.3, pp.1–12 (2017).
- [17] 池口 徹，合原一幸：力学系の埋め込み定理と時系列データからのアトラクタ再構成，*応用数理*, Vol.7, No.4, pp.260–270 (オンライン), DOI: 10.11540/bjsiam.7.4.260 (1997).
- [18] Basharat, A. and Shah, M.: Time series prediction by chaotic modeling of nonlinear dynamical systems, *2009 IEEE 12th International Conference on Computer Vision (ICCV)*, pp.1941–1948, IEEE Computer Society (online), DOI: 10.1109/ICCV.2009.5459429 (2009).
- [19] Kingma, D.P. and Ba, J.L.: Adam: A Method for Stochastic Optimization, *CoRR*, Vol.abs/1412.6980 (2014).
- [20] Ioffe, S. and Szegedy, N.C.: Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, *International Conference on Machine Learning*, pp.448–456 (2015).
- [21] Shimodaira, H.: Improving predictive inference under covariate shift by weighting the log-likelihood function, *Journal of Statistical Planning and Inference*, Vol.90, No.2, pp.227–244 (2000).
- [22] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M. and Duchesnay, E.: Scikit-learn: Machine Learning in Python, *Journal of Machine Learning Research*, Vol.12, pp.2825–2830 (2011).



大伴 周也

2018 年立命館大学情報理工学部知能情報学科卒業。2020 年同大学大学院情報理工学研究科情報理工学専攻博士課程前期課程を修了。人工知能、進化計算の研究に従事。



原田 智広 (正会員)

2010年電気通信大学電気通信学部人間コミュニケーション学部卒業, 2012年同大学大学院情報理工学研究科総合情報学専攻博士前期課程終了, 2015年同博士後期課程修了. 博士(工学). 日本学術振興会特別研究員 DC1. 2015年より立命館大学情報理工学部助教. 2019年より東京都立大学(2020年4月に首都大学東京から改称)システムデザイン学部助教. 現在に至る. 2018年 University of Málaga (Spain) 客員研究員. 進化計算, 機械学習, ゲーム AI, 睡眠計測の研究に従事. 人工知能学会, 計測自動制御学会, 進化計算学会, IEEE, ACM 各会員.



ターウォンマツト ラック  
(正会員)

1994年東北大学大学院工学研究科情報工学専攻博士課程修了. 博士(工学). 2004年4月より立命館大学情報理工学部知能情報学科教授. 計算知能およびゲーム AI の研究に従事.



伊東 卓男

1970年3月甲南大学経済学部経済学科卒業. 同年4月伊東公業株式会社入社. 2010年同社代表取締役社長. 1985年10月通信を利用した石油販売における残量監視システム(テレメータネットワークシステム IK-600型)を開発. 危険物地下埋設施設における漏洩課題が浮上する中, 続いて IK-900型, IK-910型(漏洩の早期発見対策機)の開発. IK-600型, IK-900型, IK-910型の開発により特許取得. 2018年より IoT による AI を活用した漏洩対策による高精度の安全管理対策機を立命館大学と共同開発. 2019年, AI 活用による早期漏洩発見手法により立命館大学と共同特許取得.