

## 共振周波数解析と機械学習を用いた固定性補綴装置の固定状態の異常検知 ： *in vitro* study

Sara Reda Sammour<sup>a,b</sup>, 内藤英樹<sup>c</sup>, 木本智幸<sup>d</sup>, 佐々木啓一<sup>a</sup>, 小川 徹<sup>a</sup>

Anomaly detection of retention loss in fixed partial dentures using resonance frequency analysis and machine learning: An *in vitro* study

Sara Reda Sammour<sup>a,b</sup>, Hideki Naito<sup>c</sup>, Tomoyuki Kimoto<sup>d</sup>, Keiichi Sasaki<sup>a</sup> and Toru Ogawa<sup>a</sup>

本論文は、Journal of Prosthodontic Research の同名の出版物の翻訳を邦文論文として出版するものである。引用の際には原出版物の「Sammour SR et al. J Prosthodont Res, 2024; 68(4): 568-577」を記載すること。

### 抄 録

本研究は、共振周波数解析（RFA）と機械学習を組み合わせることで、固定性補綴装置（FPD）の支台歯とのセメント固定状態を評価し、その固定状態の異常を早期に検出することを目的とした。単冠および3ユニットブリッジを製作した下顎模型を用い、セメント固定の有無に応じた複数の条件下で振動刺激を加え、3軸加速度センサによりその周波数応答を測定した。取得データは、教師あり学習および教師なし学習により解析した。その結果、セメント固定状態に応じて特有の周波数帯域に違いが見られ、異常スコアによって高い精度でセメント固定状態の不良を検出することが可能であった。これらの結果から、RFA と機械学習を組み合わせた本法は、固定性補綴装置のセメント固定状態の異常を非侵襲的かつ早期に評価可能な新たな診断法となりうることが示唆された。

### キーワード

機械学習, 共振周波数解析, セメントロス, 固定性補綴装置

### ABSTRACT

**Purpose:** This study aimed to determine the usefulness of machine learning techniques, specifically supervised and unsupervised learning, for assessing the cementation condition between a fixed partial denture (FPD) and its abutment using a resonance frequency analysis (RFA) system.

**Methods:** An *in vitro* mandibular model was used with a single crown and three-unit bridge made of a high-gold alloy. Two cementation conditions for the single crown and its abutment were set: cemented and uncemented. Four cementation conditions were set for the bridge and abutments: both crowns were firmly cemented, only the premolar crown was cemented, only the molar crown was cemented, and both crowns were uncemented. For RFA under cementation conditions, 16 impulsive forces were directly applied to the buccal side of the tested tooth at a frequency of 4 Hz using a Periotest device. Frequency responses were measured using a 3D accelerometer mounted on the occlusal surface of the tested tooth. Both supervised and unsupervised learning methods were used to analyze the datasets.

**Results:** Using supervised learning, the fully cemented condition had the highest feature importance scores at approximately 3000 Hz; the partially cemented condition had the highest scores between 1000 and 2000 Hz; and the highest scores for the uncemented condition were observed between 0 and 500 Hz. Using unsupervised learning, the uncemented and partially cemented conditions exhibited the highest anomaly scores.

**Conclusions:** Machine learning combined with RFA exhibits good potential to assess the cementation condition of an FPD and hence facilitate the early diagnosis of FPD retention loss.

### Key words:

Machine learning, Resonance frequency analysis, Cement loss, Fixed partial denture

<sup>a</sup> 東北大学大学院歯学研究科

<sup>b</sup> Prosthodontic Department, Faculty of Dentistry, Tanta University, Tanta, Egypt

<sup>c</sup> 東北大学大学院工学研究科

<sup>d</sup> 大分工業高等専門学校電気電子工学科

<sup>a</sup> Division of Advanced Prosthetic Dentistry, Tohoku University Graduate School of Dentistry, Sendai, Japan

<sup>b</sup> Prosthodontic Department, Faculty of Dentistry, Tanta University, Tanta, Egypt

<sup>c</sup> Department of Civil and Environmental Engineering, Tohoku University Graduate School of Engineering, Sendai, Japan

<sup>d</sup> Department of Electrical and Electronic Engineering, National Institute of Technology, Oita College, Oita, Japan

## I. 緒 言

固定性補綴装置 (fixed partial denture : FPD) は、天然歯またはインプラントを支台として口腔内に固定され、欠損歯質あるいは欠損歯の機能的・審美的回復を目的とした補綴装置である。しかし、不適切な治療計画や支台歯条件などによっては、早期に脱離や破損などの臨床的な合併症を生じることがある<sup>1)</sup>。FPD の失敗の主な原因は、セメントによる維持力の喪失とされ、その他にも接合部やポーセレンの破損、支台歯の破折が挙げられ、それによる支台装置内部の空隙から齶蝕の発生、さらには支台歯の喪失につながる可能性がある<sup>2,3)</sup>。

このようなセメントの維持力の喪失は、多くの場合徐々に進行し、初期段階では明確な臨床的徴候が現れないことも多い。特に、複数の支台歯を有する FPD において、一部のリテーナーのみが脱離し、他の支台歯がしっかりと維持されている場合には、補綴装置は機能し続けるために異常が見逃されやすい。このような状態が長期間にわたって放置されると、二次齶蝕の発生や支台歯への過度な咬合力による歯の破折、歯周疾患の進行などを引き起こし、最終的には支台歯の喪失に至る可能性がある<sup>4)</sup>。したがって、早期にセメント固定状態を適切に診断・評価する方法の確立は、临床上極めて重要であると考えられる。現在、セメント固定状態の異常を診断する手段としては、視診、探針による触診、エックス線検査のほか、レーザー干渉法、動揺度測定、咬合力解析法などが用いられているが、これらの手法はいずれも精度や定量性に限界があり、微細なセメント固定状態の変化を検知するには不十分である<sup>1,5)</sup>。

共振周波数解析 (resonance frequency analysis : RFA) は、非侵襲的かつ定量的に構造物の安定性を評価できる技術として注目され、歯科領域では特にインプラントの初期固定の評価に広く用いられている<sup>6)</sup>。1996 年、Meredith らは RFA を用いてインプ

ラントと骨との界面の安定性を定量的に測定し、その後、Osstell Mentor (Integration Diagnostics 社) と SmartPeg を組み合わせた測定システムが臨床で応用されてきた。当該方法は、計測した共振周波数を解析、1 ~ 100 のインプラント安定指数 (implant stability quotient : ISQ) として表現し、この ISQ 値は高いほどインプラントの安定性が高いことを示す<sup>6)</sup>。

Omer らは、この RFA システムが支台歯と FPD との固定状態の評価にも応用可能であることを報告した<sup>5)</sup>。しかしながら、臨床の現場において、測定のたびにスマートペグをクラウンに強固に固定するあるいは連結することは煩雑であり、現実的とはいえない。そこで筆者らは、補綴装置にスクリー固定を行うことなくオッセオインテグレーションの程度やスクリーの緩み等の上部構造の異常を検出可能な、小型の三軸加速度センサを支台歯に設置 (貼付) した RFA 装置を報告した<sup>7)</sup>。さらにその後の筆者らの先行研究において、RFA と有限要素解析を組み合わせることで、歯牙支持型 FPD におけるセメント固定状態を定量的に評価する可能性を示した<sup>8)</sup>。しかし、周波数応答の特徴量は複数のさまざまな要因に影響されるため、セメントによる固定状態の異常を周波数応答から簡便かつ正確に判別することは依然として困難であった。

近年、機械学習 (machine learning) 技術は歯科分野においても応用が進み、齶蝕、歯周病、口腔がんなどの病変の検出に利用されている<sup>9,10)</sup>。これらの技術は、従来の診断方法と比較して、診断精度の向上、解析速度の短縮、効率性の改善といった多くの利点を有している。つまり機械学習は、複雑かつ大量のデータを解析・理解するための有力な手段であり、医療を含む多くの分野で活用されている。

コンピュータによる学習の手法は大きく「教師あり学習 (supervised learning)」と「教師なし学習 (unsupervised learning)」に分類される。機械学習では、データに潜むパターンを自動的に学習することで、将来的な結果や状態を予測するモデルを構築する。例え

ば、循環器内科領域では、心電図（EKG）の波形に対して既知の心疾患に関するラベル付きデータを用いてモデルを訓練し、異常波形を自動的に認識・診断するシステムがすでに臨床応用されている<sup>11,12)</sup>。放射線画像診断の分野では、胸部エックス線写真における肺結節の検出などにおいても、あらかじめ結節部がマーキングされた多数の画像を使ってモデルを訓練し、新たな画像における結節の自動認識が可能となっている。いずれの場合も、熟練した医師が行っていたパターン認識や判断を、機械学習によって代替あるいは補完することが可能になりつつある。

一方、脳画像などの医用画像解析においては、従来は統計モデルやクラスタリングといった手法が異常検出に用いられてきたが、近年では深層学習（deep learning）の発展に伴い、より高精度なアプローチが実現されている。特にオートエンコーダ（autoencoder：AE）と呼ばれるニューラルネットワークモデルは、非線形な特徴変換を学習する能力に優れ、脳 CT や MRI 画像における異常領域の検出・局在・セグメンテーションに有効であることが報告されている<sup>13)</sup>。

本研究は、小型の三軸加速度センサを用いた RFA によって得られた観測データをもとに、固定性補綴装置のセメント固定状態の異常を検出可能な機械学習モデルを構築することを目的とした。将来的には、このモデルを臨床応用することで、固定性補綴装置のセメント固定状態を迅速かつ定量的に評価することが可能となり、診断精度の向上、またその標準化さらには省力化につながることを期待される。著者らの知る限り、本研究のように機械学習を用いて FPD のセメント固定状態を評価した報告はこれまでになく、FPD の異常検知に対して RFA システムを活用した教師あり・教師なし機械学習アルゴリズムの有効性を初めて追究するものである。

## II. 材料および方法

本研究は、以下の四つのフェーズに分けて実施した：①試料の準備、②実験手順、③データ取得、④機械学習アルゴリズムを用いたデータ解析（図 1）。

### 1. 試料の準備

下顎の歯列模型を用いた（Mandibular E50-512, Nissin Dental Products 社、京都、日本）。左側第一大臼歯部に単冠、右側第二大臼歯から第二小臼歯にかけて 3 ユニットブリッジを、それぞれ高カラット白金加金を用いて製作した（図 2）。支台歯は、歯根膜

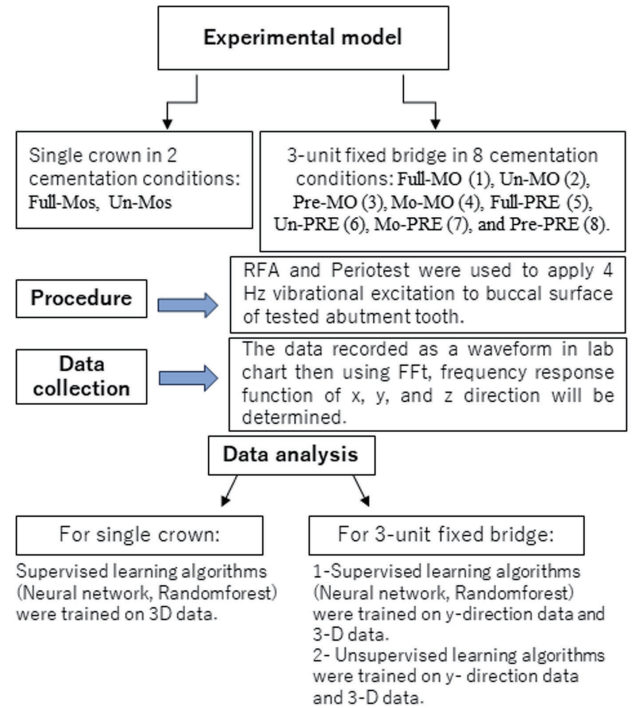


図 1 実験プロセスをまとめた概略図。Full：セメント固定されたもの、Mos：単冠、Un：未固定（大白歯および小白歯の両方が未固定）、MO：大白歯にて測定、Pre：小白歯のみが固定、Mo：大白歯のみが固定、PRE：小白歯にて測定、RFA：共振周波数解析。



図 2 単冠および 3 ユニットブリッジを有する実験用下顎模型。

の弾性を模擬するために、シリコーン印象材（Fusion II Extra Wash Type, ジーシー社、東京、日本）を介して支台窩に装着した。

セメント固定条件は、単冠については「完全固定（Full）」および「未固定（Un）」の 2 条件、3 ユニットブリッジについては以下の 4 条件を設定した：①両支台歯固定（Full）、②小白歯のみ固定（Pre）、③大白歯のみ固定（Mo）、④両支台歯未固定（Un）<sup>8)</sup>。

### 2. 振動刺激およびデータ取得

共振周波数解析（RFA）のために、以下の装置を使用した：データ収集システム（PowerLab ML880；ADInstruments 社、英国オックスフォード）、定電流



図3 実験用下顎模型での振動刺激の方向。

源 (Power Unit 4114B1 ; Dytran Instruments 社, 米国カリフォルニア州), 3 軸加速度センサ (3133A1 ; Dytran Instruments 社), およびデータ解析ソフトウェア (LabChart 7 for Windows ; ADInstruments 社)<sup>8)</sup>. 測定に際しては, 厚さ 0.15 mm の強力両面テープ (NICETACK NW-K15, ニチバン社, 東京, 日本) を用いて, 3 軸加速度センサを被験歯の咬合面に接着した. 振動刺激として, 支台歯の頬側に対して 4 Hz のインパルス刺激を 4 秒間, 計 16 回の打振を加えた (Periotest Classic, Medizintechnik Gulden 社, ドイツ) (図 3).

単冠における測定 (Mos) は, 当該歯にセンサを接着し, 完全固定状態 (Full) および未固定状態 (Un) の 2 条件で実施した. 3 ユニットブリッジについては, 第二大臼歯 (MO) もしくは第二小臼歯 (PRE) いずれかにセンサを接着し, 各測定支台歯毎に 4 条件 (Full, Pre, Mo, Un) でそれぞれ測定を行った.

各条件の表記は, セメント固定状態 (X) と測定部位 (Y) を組み合わせ, 「X-Y」として表した. たとえば, 単冠の完全固定状態は Full-Mos, 未固定状態は Un-Mos (図 4A) とした. 3 ユニットブリッジでは, 大白歯側の測定で Full-MO, Mo-MO, Pre-MO, Un-MO, 小臼歯側の測定で Full-PRE, Mo-PRE, Pre-PRE, Un-PRE と分類した (図 4B).

### 3. 信号処理および特徴量の抽出

振動刺激に対して, 3 軸加速度センサにより加速度信号が記録された. 振動応答は, 各軸 (x, y, z 方向) についてそれぞれ 128 点の時間データを高速フーリエ変換 (fast Fourier transform : FFT) により周波数領域に変換した. 変換後の周波数応答関数は, 0 ~ 4920 Hz の範囲をカバーし, 分解能は 78.1 Hz であった. これにより, 各軸につき 64 個, 計 192 個 (64 × 3 軸) の一次元データを特徴量 (feature) として抽出した. これらの周波数応答関数は, 振動入力強度のばらつきを抑制するため, 最大振幅に基づき正規化を行った (図 5).

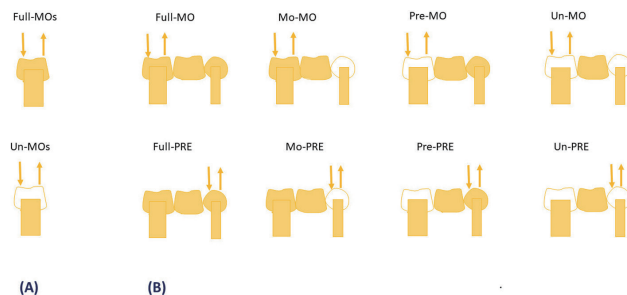


図4 A) セメント固定された (Full) または未装着 (Un) の単冠 (Mos), B) 3 ユニットブリッジの大白歯での測定 (MO) または小臼歯での測定 (PRE). 条件としては, 大白歯および小臼歯の両方を固定 (Full), 小臼歯のみ固定 (Pre), 大白歯のみ固定 (Mo), および両者未固定 (Un) である. 白いクラウンは未固定を示す.

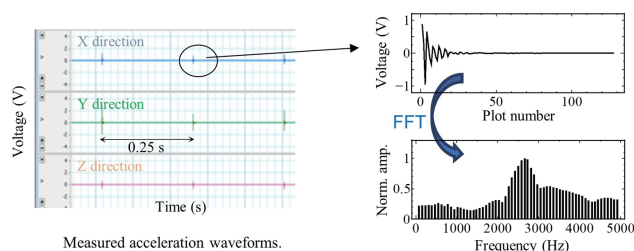


図5 各加速度計の波形に対して高速フーリエ変換を行って得られた周波数応答関数の例。

## 4. 教師あり学習による分類

訓練データの増強 (augmentation) には, 周波数応答関数を周波数軸方向にシフトさせる手法を用いた. 具体的には, 元の応答関数を  $\pm 2$  パラメータ (-156.2 Hz ~ +156.2 Hz) の範囲でシフトさせることで, 一つの元データから五つのデータを生成し, 訓練データ数を 5 倍に増加させた. シフトにより端部に生じる空白部分にはゼロ値を代入し, 波形の変形やノイズの影響を排除した. 訓練データの増強は特に教師なし学習 (unsupervised learning) において効果的である. 実験条件や測定設定が同一であっても, 歯の周波数応答には共振周波数付近でばらつきが生じる傾向がある. そのため, 周波数応答関数を少しずつシフトさせたデータを訓練に用いることで, よりロバストなモデルの構築が可能となる. 大量の学習データを確保することは, 教師なし学習アルゴリズムの性能向上に極めて重要である.

なお, 各セメント固定条件は以下のように 1 ~ 8 のラベルを付けて管理した: Full-MO (1), Un-MO (2), Pre-MO (3), Mo-MO (4), Full-PRE (5), Un-PRE (6), Mo-PRE (7), Pre-PRE (8).

セメント固定状態の分類には, 2 種類の教師あり学

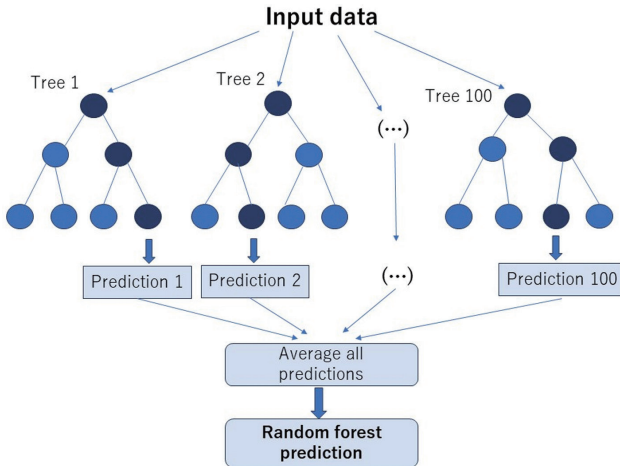


図6 ランダムフォレストの概略図。

習アルゴリズムを適用した。ひとつはランダムフォレスト法であり、Scikit-learn (version 0.24.1) のRandomForestClassifier モジュールを使用して実装した。モデルパラメータにはデフォルト設定を使用し、決定木の本数は100とした（図6）。ニューラルネットワークによる分類には、Scikit-learn (version 0.24.1) に含まれるMLPClassifier モジュールを使用して多層パーセプトロン（multi-layer perceptron: MLP）モデルを構築した。ネットワークは4層の隠れ層を有し、それぞれのノード数は入力層から出力層にかけて順に96, 48, 24, 12と設定した（図7）。それ以外のパラメータはScikit-learnにおけるデフォルト設定を用い、最適化手法にはAdamを採用し、学習率は0.001、エポック数は200とした<sup>14)</sup>。データセットは各セメント固定条件につき80個の周波数応答関数から構成され、全体の70%を訓練データ、残り30%をテストデータとして使用した。この分割はScikit-learnのtrain\_test\_split モジュールを用いてランダムに行い、1条件あたり約56個の応答関数を訓練データに、残りの約24個をテストデータに割り当てた。

機械学習モデルの性能評価には、混同行列（confusion matrix）および正解率（accuracy）を用いた。混同行列は、真陽性（true positive）、偽陽性（false positive）、真陰性（true negative）、偽陰性（false negative）の件数を集計することで、モデルの予測結果と実際のラベルとの一致度を視覚的かつ定量的に把握するために使用される。正解率は、テストデータに対するモデルの予測結果と実際のラベルを比較し、一致した件数の割合として算出した<sup>15)</sup>。

本研究では、ランダムフォレストアルゴリズムを用

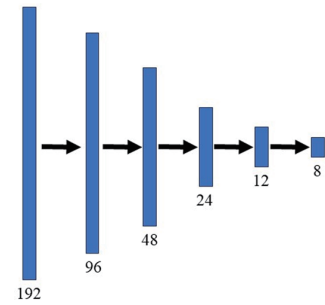


図7 教師あり学習におけるニューラルネットワークの概略図。

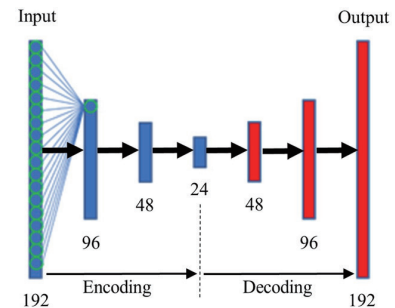


図8 固定状態の評価のために使用したオートエンコーダの概略図。

いて、特徴量の重要度（feature importance）スコアを算出し、各特徴量が予測に与える影響を評価した。重要度スコアの高い特徴量は、予測結果に強く影響する要素であるとみなされ、逆にスコアが低い特徴量はモデルの判定に与える影響が小さいと解釈される。特徴量の重要度をグラフまたは順位表として可視化することにより、モデルがどのような情報に基づいて判断を下しているかを明確に把握することが可能となった。こうした情報は、疾患診断における重要因子の特定、製品設計の最適化、データ駆動型の意思決定プロセスにおける主要変数の抽出などにおいて、極めて有用である<sup>16)</sup>。

本研究においては、特にy軸方向の振動特性に注目し、異なるセメント固定条件が固定性補綴装置（FPD）における振動特性に与える影響を評価した。特徴量重要度のグラフは、各周波数帯域の寄与を視覚的に示すものであり、単冠およびブリッジ構造における三次元的な複雑な振動挙動の解析に資するものである。

## 5. 教師なし学習による異常検出（Autoencoder）

本研究では、ラベル付き異常データを網羅的に集めることが困難であることを踏まえ、データに含まれる潜在的なパターンを抽出し、類似性に基づいてグループ化する教師なし学習アルゴリズムを用いた。具体的には、オートエンコーダ（Autoencoder: AE）を構

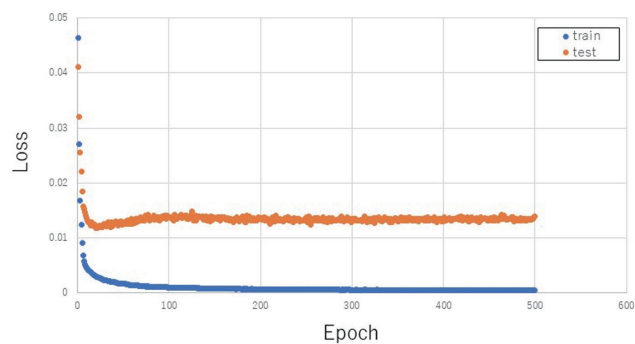


図9 損失値とエポックの関係.

表1 単冠での各セメント条件における 3D 加速度データを用いて, A) ニューラルネットワークおよび B) ランダムフォレストアルゴリズムにて訓練し算出した混同行列の比較.

A			
		Predicted value	
Real value		1	2
	1	23	0
	2	0	25

B			
		Predicted value	
Real value		1	2
	1	23	0
	2	1	25

築し, 周波数応答関数の異常検出に応用した. 構築した AE のネットワークは, 192 個の入力ノードを持ち, これをそれぞれ 96, 48, 24 ノードの 3 層のエンコーディング層を通じて圧縮した後, 対称的な構造でデコーディングして出力を再構成するものである (図 8)<sup>17)</sup>. 活性化関数には ReLU (rectified linear unit) を, 出力層には Sigmoid 関数を使用した. モデルの構築と学習には TensorFlow (version 2.3.0) を用い, 損失関数には平均二乗誤差 (mean squared error) を適用した. 最適化手法には Adam を使用し, 学習率は 0.001, エポック数は 500, バッチサイズは 32 とした (図 9). AE は, 入力と出力が一致するように自己符号化的に学習し, 再構成誤差の大きさに基づいて異常を判定する.

入力および出力には, 前述の周波数応答関数を特徴量として使用した. FPD のセメント接着状態の異常を検出するために, AE の入力と出力との差異に基づいて異常スコア (anomaly score) を算出した. なお, 教師なし学習に使用した訓練データは, 教師あり学習で使用したデータとは異なり, Full-Mo および Full-Pre といった完全接着状態の条件に限定し, それぞれ 3 回ずつ打撃試験を行って得られた計 240 個の周波数応答関数を用いた. 教師なし学習の性能を向上さ

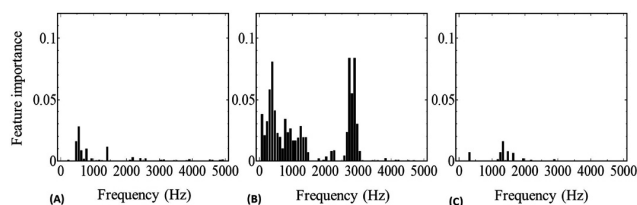


図10 単冠の固定条件において, A) x 方向, B) y 方向, C) z 方向の周波数応答に基づいて算出された特徴重要度のグラフ.

せ, セメント異常の検出精度を高めるには, 訓練データ量を十分に確保することが重要である.

異常検出の精度をさらに高めるために, 以下の二つの信号処理を行った. 第一に, 入力および出力の周波数応答関数に対して, 10 パラメータ幅の移動平均処理を施し, 信号の平滑化を図った. 第二に, 応答振幅が極めて小さく, ノイズのみが含まれていると判断される周波数領域の影響を抑制するため, すべての入力および出力の振幅から定数 0.2 を減算し, 減算後に得られた値が負となる場合は 0 に置き換えた<sup>18)</sup>.

これらの前処理の後, 異常スコア  $e$  は以下の式により算出した:

$$e = \frac{\sum_{i=1}^{192} |f_i - g_i|}{\sum_{i=1}^{192} g_i}$$

$f_i$  は入力された周波数応答関数の第  $i$  成分,  $g_i$  は AE によって再構成された出力の第  $i$  成分を示す ( $1 \leq i \leq 192$ ).

### III. 結 果

#### 1. 単冠

ニューラルネットワークおよびランダムフォレストは, それぞれ  $x \cdot y \cdot z$  軸方向の加速度データセットを用いて訓練を行った. その結果 (表 1), いずれの手法においても良好な混同行列が得られ, 正解率はニューラルネットワークで 100%, ランダムフォレストで 99% と非常に高かった.

セメント接着条件に対するランダムフォレスト法による特徴量重要度のグラフを図 10 に示す. これは,  $x \cdot y \cdot z$  各方向の周波数応答に対する重要度を視覚化したものであり, 特に  $y$  軸方向の動的応答が他の軸 ( $x \cdot z$ ) に比べて大きいことが明らかとなった.

#### 2. 3 ユニットブリッジ

1)  $y$  軸加速度データのみを用いた教師あり学習の訓練

ニューラルネットワークおよびランダムフォレスト

表2 3ユニットブリッジでの各セメント条件におけるy軸加速度データを用いて、A) ニューラルネットワークおよびB) ランダムフォレストアルゴリズムにより訓練し算出された混同行列の比較。

A		Predicted value							
Real value		1	2	3	4	5	6	7	8
	1	23	0	0	0	0	0	0	0
	2	0	23	0	0	0	0	1	0
	3	0	0	28	0	0	0	0	0
	4	0	0	0	27	0	0	0	0
	5	0	0	0	0	30	0	0	0
	6	1	0	0	0	0	19	2	0
	7	0	0	0	0	0	0	19	0
	8	0	0	0	0	0	0	0	18

B		Predicted value							
Real value		1	2	3	4	5	6	7	8
	1	23	0	0	0	0	0	0	0
	2	0	22	0	0	0	2	0	0
	3	0	0	28	0	0	0	0	0
	4	0	0	0	27	0	0	0	0
	5	5	0	0	0	25	0	0	0
	6	0	0	0	0	0	22	0	0
	7	0	0	0	0	0	0	19	0
	8	0	0	0	0	0	0	0	18

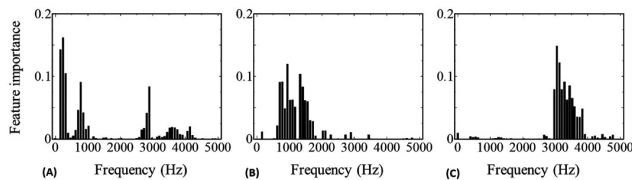


図11 第二大臼歯を測定部位とする3ユニットブリッジについて、y軸加速度データを用いて計算された周波数応答関数の特徴重要度のグラフ。

- A) Full-MO と Un-MO の比較により、0-500 Hz の周波数帯の重要性を示す。  
 B) Full-MO と Pre-MO の比較により、約 1000 Hz の周波数の重要性を示す。  
 C) Full-MO と Mo-MO の比較により、約 3000 Hz の周波数の重要性を示す。

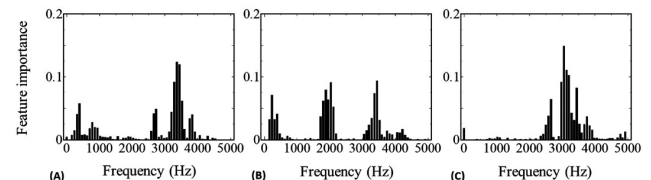


図12 第二小臼歯を測定部位とする3ユニットブリッジについて、y軸加速度データを用いて計算された周波数応答関数の特徴重要度のグラフ。

- A) Full-PRE と Un-PRE の比較により、0-500 Hz の周波数帯の重要性を示す。  
 B) Full-PRE と Mo-PRE の比較により、約 2000 Hz の周波数の重要性を示す。  
 C) Full-PRE と Pre-PRE の比較により、約 3000 Hz の周波数の重要性を示す。

による訓練結果（表2）では、いずれのアルゴリズムも良好な混同行列と高い精度を示し、ニューラルネットワークで97%、ランダムフォレストで96%の正解率が得られた。

ランダムフォレストを用いて得られた特徴量重要度のグラフを図11および図12に示す。図11は大臼歯部で測定を行った際の特徴量重要度の分布を、図12は小臼歯部で測定を行った際の分布を示している。

これらの図から、Un-MO および Un-PRE といった完全に未接着な条件では、0～500 Hz の周波数帯域が重要であることがわかる。一方で、Pre-MO および Mo-PRE といった部分的固定条件では、1000～

2000 Hz の帯域が分類において重要であった。

なお、Full-MO、Full-PRE、Mo-MO、Pre-PRE といったその他の条件では、共振周波数はおよそ 3000 Hz 付近に位置していた。

2) 3次元加速度データ（x・y・z）を用いた教師あり学習の訓練

3次元加速度データセットを用いてニューラルネットワークおよびランダムフォレストで訓練を行った結果（表3）、いずれの手法も良好な混同行列と高精度な分類結果を示した。ニューラルネットワークで98%、ランダムフォレストで99%の正解率が得られた。

表 3 3 ユニットブリッジでの各セメント条件における 3D 加速度データを用いて, A) ニューラルネットワークおよび B) ランダムフォレストアルゴリズムにより訓練し算出された混同行列の比較.

A		Predicted value							
Real value		1	2	3	4	5	6	7	8
	1	23	0	0	0	0	0	0	0
	2	0	32	0	0	0	0	0	0
	3	0	0	18	0	0	0	0	0
	4	0	0	0	27	0	0	0	0
	5	0	0	0	0	25	0	0	0
	6	0	0	2	0	0	19	0	0
	7	0	0	1	0	0	1	26	0
	8	0	0	0	0	0	0	0	19

B		Predicted value							
Real value		1	2	3	4	5	6	7	8
	1	23	0	0	0	0	0	0	0
	2	0	32	0	0	0	0	0	0
	3	0	0	18	0	0	0	0	0
	4	0	0	0	27	0	0	0	0
	5	0	0	0	0	25	0	0	0
	6	0	0	2	0	0	19	0	0
	7	0	0	1	0	0	4	23	0
	8	0	0	0	0	0	0	0	19

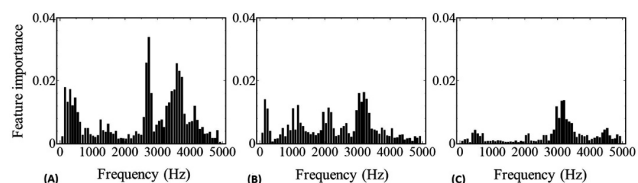


図 13 FPD 装着条件における A) x 軸方向, B) y 軸方向, C) z 軸方向の周波数応答に基づき算出された特徴重要度グラフ.

ランダムフォレストによる特徴量重要度の可視化を図 13 に示す. この図では, 各セメント接着条件に対して, x・y・z 軸方向の周波数応答に基づく特徴量の寄与度が表示されている. 特に, x 軸方向の加速度が他の軸 (y・z) よりも高い重要度を示すことが明らかとなった.

### 3) 教師なし学習アルゴリズムの訓練

教師なし学習のモデル評価として, Autoencoder (AE) により訓練されたモデルを用いて, Full-MO と Un-MO 条件での y 軸方向の入力・出力の比較を行った (図 14).

図 14A では, Full-MO 条件の標準データを用いた場合, 入力信号が適切に再構成されたのに対し, 図 14B では Un-MO 条件の異常データを用いた場合, 入力信号の再構成が失敗している様子が確認された.

全セメント固定条件に対して, 1 軸 (y) および 3 軸 (x, y, z) の加速度データを使用し, Full-MO (表

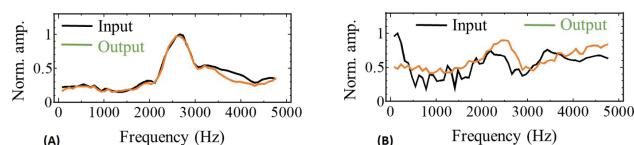


図 14 オートエンコーダにより訓練されたモデルを用いた y 軸方向の入力データと出力データの比較. A) Full-MO 条件, B) Un-MO 条件.

4A), Full-PRE (表 4B), および Full-MO/Full-PRE (表 4C) を訓練データとしたそれぞれのモデルによる異常スコアを算出した.

その結果, 3 次元加速度データを用いることで異常スコアの変動係数 (CV) が改善され, 異常検出の能力が向上する傾向が示された.

各表から明らかなように, 完全固定条件のデータは異常スコアが最も低く, 最も安定した状態であることが示唆された. 一方で, 未固定あるいは部分的固定条件では異常スコアが高く, 異常に対してより感受性が高い状態であることが示された.

## IV. 考 察

近年, 教師あり学習や教師なし学習といった機械学習アルゴリズムの活用は急速に拡大しており, 本研究においては, FPD と支台歯とのセメント固定状態を迅

表4 y 軸加速度および 3D 加速度データセットを用いて、  
A) Full-MO, B) Full-PRE, C) Full-MO および Full-PRE  
の条件で訓練を行い得られた異常スコアの比較. Full-MO  
および Full-PRE は、3 ユニットブリッジにおいて大白歯お  
よび小白歯の両方が装着された状態で、それぞれ大白歯お  
よび小白歯から取得された測定データを示す.

## (A)

Cementa- tion condition	Number of measured data	Anomaly scores mean value		Coefficient of variation %	
		1D	3D	1D	3D
Full-MO	240	0.021	0.028	35.1	24.1
Un-MO	78	0.634	0.731	23.7	13.4
Pre-MO	80	0.622	0.682	11.6	16.1
Mo-MO	80	0.454	0.503	17.8	14.3
Full-PRE	240	0.427	0.523	34.1	15.6
Un-PRE	78	0.965	0.886	25.1	19.9
Mo-PRE	80	1.050	1.101	12.4	19.9
Pre-PRE	80	0.608	0.525	14.5	7.3

## (B)

Cementa- tion condition	Number of measured data	Anomaly scores mean value		Coefficient of variation %	
		1D	3D	1D	3D
Full-MO	240	0.292	0.413	31.6	16.5
Un-MO	78	0.599	0.533	25.2	16.1
Pre-MO	80	0.480	0.430	19.9	17.2
Mo-MO	80	0.647	0.466	20.4	9.6
Full-PRE	240	0.014	0.026	42.0	22.8
Un-PRE	78	0.482	0.641	24.6	13.0
Mo-PRE	80	0.508	0.586	24.7	12.8
Pre-PRE	80	0.391	0.389	18.9	15.2

## (C)

Cementa- tion condition	Number of measured data	Anomaly scores mean value		Coefficient of variation %	
		1D	3D	1D	3D
Full-MO	240	0.03	0.03	28.6	22.9
Un-MO	78	0.57	0.60	28.8	18.7
Pre-MO	80	0.44	0.47	26.1	11.3
Mo-MO	80	0.42	0.42	14.9	16.1
Full-PRE	240	0.02	0.03	34.2	23.7
Un-PRE	78	0.53	0.72	26.6	15.1
Mo-PRE	80	0.38	0.70	31.0	24.0
Pre-PRE	80	0.47	0.40	12.0	15.6

Un: uncemented, Pre: only the premolar cemented, Mo: only the molar cemented

速かつ高精度に判別する可能性を検討した。提案する方法は、臨床医や臨床研究者による治療方針の判断や合併症の予防に資する技術となることが示唆された。

ランダムフォレストは、データセット内の各特徴量の重要性を定量的に評価できる有効なアルゴリズムである。特徴量重要度スコアは、決定木の分岐時に各特徴量がもたらす「不純度の減少」をもとに算出され、これを複数の木で平均化することで最終スコアが得られ

る<sup>19)</sup>。こうしたスコアは、データ中で最も意味のある変数を明らかにすることに寄与し、モデルの予測性能向上やデータ構造の理解にもつながるものである<sup>20)</sup>。

本研究では、下顎模型上の完全固定された 3 ユニットブリッジにおいて、大白歯冠の共振周波数は約 3000 Hz であった (図 11)。これは著者らの先行研究と一致しており<sup>8)</sup>、補綴装置が支台歯に強固に固定されていたことを示している。一般に、剛性の高い物体は変形に抵抗し、外部からの振動に対して高い周波数で共振する。これに対し、未固定ブリッジでは 0 ~ 500 Hz の低周波帯で共振が見られ、わずかなエネルギーでも振動しやすい状態であることを示している。部分的固定条件では、最も重要な特徴量が約 1000 Hz 付近に集中しており、完全固定状態よりも剛性が低いことが示唆された。一方、大白歯がセメントで固定されている場合、共振周波数は 3000 Hz に近く、完全固定と類似する挙動を示した。

同様の傾向は、小白歯部での測定 (図 12) においても観察された。未固定状態では 0 ~ 500 Hz で共振が確認されたが、クラウン接着により最大周波数は約 3000 Hz まで上昇した。一方、Mo-PRE 条件では 2000 Hz、Pre-MO 条件では 1000 Hz の周波数が支配的であった。これは、歯の種類 (大白歯と小白歯) の違いや形態・質量差に起因すると考えられる。一般に、大きく重い物体は低い周波数で共振し、小さく軽い物体は高い周波数で共振する傾向がある。また、固定端条件や境界条件の違いも共振特性に大きな影響を与える。

さらに、図 10 および図 13 の特徴量重要度から、単冠モデルでは y 軸方向の加速度が重要性をもつのにに対し、ブリッジモデルでは x 軸方向の寄与が最も大きいことが示された。これは、単冠が x・y 方向に自由に動ける構造である一方、ブリッジは x 方向に拘束されていたことによる違いである。ブリッジモデルでは拘束条件により x 軸方向の動きが制限され、より複雑な 3 次元的振動を引き起こし、その結果として x 軸や z 軸方向の情報も重要性を増す傾向がみられた。これらの結果は、機械学習が 3 次元的な複雑な振動挙動の解析にも有効であることを示している。

教師なし学習アルゴリズムは、ラベル付けされたデータを必要とせずにデータ中のパターンや構造を抽出する手法である<sup>21)</sup>。本研究では、入力を低次元に圧縮・再構成する AE (Autoencoder) を用いた<sup>22)</sup>。AE は、完全固定条件のデータは高精度で再構成できたのに対し、未固定条件では入力データの再構成が困難であった (図 14)。これは、未固定状態が訓練デー

タとは異なる異常なパターンを含んでいるためであり、AE の訓練済モデルではうまくデータを再構成できなかったと考えられる。

異常検出 (anomaly detection) は、通常のパターンから逸脱した外れ値や異常なデータ点を特定する機械学習技術である<sup>23)</sup>。異常スコアはデータの逸脱度合いを数値化したものであり、高スコアほど異常の可能性が高いことを示す<sup>24)</sup>。また、変動係数 (CV) は標準偏差と平均値の比であり、データのばらつきを表す尺度である。

本研究の解析結果から、3次元加速度データを用いることで異常スコアのばらつき (CV) が改善され、異常検出精度が向上することが示唆された。3軸方向のデータを統合的に活用することで、異常の出現方向にかかわらず高精度な検出が可能になる。特に、完全固定条件では異常スコアが低く安定した挙動を示した一方で、未固定および部分的固定条件では異常スコアが高く、不安定な傾向が確認された。

## 1. 限界と今後の課題

本研究にはいくつかの制限がある。使用した FPD は第二小臼歯から第二大臼歯の3ユニット構成に限定されており、他の設計 (より長いスパンや異なる支台歯の組み合わせ) には一般化できない可能性がある。また、使用材料およびセメントの種類も限定されており、異なる材料では異なる挙動が得られる可能性がある。

本研究は模型を用いた基礎的検討であり、生体内環境における影響 (骨密度、軟組織の状態など) は考慮されていない。RFA 測定や機械学習モデルの入力において、個体差の影響は大きく、これが予測精度に影響する可能性がある。また、機械学習モデルの構築には大量かつ多様な訓練データが不可欠であるが、今回のデータ量は限定的であり、モデルの過学習や汎化性能への影響が懸念される。

今後は、より多様な FPD 設計・材料・セメント条件での検討、実際の患者群を対象とした研究を進める必要がある。これにより、FPD の長期的予後に関与する因子についての包括的な理解が深まり、臨床医が妥当かつ実用的な方法に基づいて、適切な治療指針を提供できるようになることが期待される。

## V. 結 論

本研究では、FPD と支台歯間のセメント固定状態を評価するために、教師あり・教師なし機械学習アル

ゴリズムを共振周波数解析 (RFA) と組み合わせて適用し、その有効性を検討した。その結果、以下の知見が得られた。

教師あり学習を用いたブリッジモデルの解析では、

- ・完全固定条件：3000 Hz 付近に特徴量重要度のピーク
- ・部分的固定条件：1000 ～ 2000 Hz
- ・未固定条件：0 ～ 500 Hz にピークが集中した。

ブリッジモデルにおいては、複雑な3次元振動 (x, y, z 軸) を含めることで、1軸 (1D) 振動のみを用いた解析よりも分類精度が向上した。

教師なし学習を用いた異常検出では、完全固定条件における異常スコアが最も低く、未固定および部分的固定条件では高いスコアを示した。

測定部位・条件・加速度方向により、モデル化された剛性および振動特性に差異が生じることが確認された。

以上より、RFA データに基づいた教師あり・教師なし学習手法を FPD モデルに応用することは、セメント固定状態の判定および保持力喪失の早期検出に有効な手段となりうることを示唆された。

## 文 献

- 1) Pjetursson BE, Sailer I, Zwahlen M, Hammerle CHF. A systematic review of the survival and complication rates of all-ceramic and metal-ceramic reconstructions after an observation period of at least 3 years. Part I: Single crowns. Clin Oral Implants Res 2007; 18(S3): 73-85. <http://dx.doi.org/10.1111/j.1600-0501.2007.01467.x>
- 2) Cheung GSP, Dimmer A, Mellor R, Gale M. A clinical evaluation of conventional bridgework. J Oral Rehabil 1990; 17: 131-6. <http://dx.doi.org/10.1111/j.1365-2842.1990.tb01401.x>
- 3) Manappallil JJ. Classification system for conventional crown and fixed partial denture failures. J Prosthet Dent 2008; 99: 293-8. [http://dx.doi.org/10.1016/S0022-3913\(08\)60064-5](http://dx.doi.org/10.1016/S0022-3913(08)60064-5)
- 4) Verrett RG, Mansueto MA. Removal of a metal-ceramic fixed partial denture with a loose retainer. J Prosthodont 2003; 12: 13-6. <http://dx.doi.org/10.1053/jpro.2003.5>
- 5) Omer K, Fox K, Palermo D, Boyle L, Youngson C. An in vitro evaluation of resonant frequency analysis to measure fixed bridge stability. BDJ Open 2015; 1: 15001. <http://dx.doi.org/10.1038/bdjopen.2015.1>
- 6) Meredith N, Alleyne D, Cawley P. Quantitative determination of the stability of the implant-tissue interface using resonance frequency analysis. Clin Oral Implants Res 1996; 7: 261-7. <http://dx.doi.org/10.1034/j.1600-0501.1996.070308.x>
- 7) Miyashita M, Ogawa T, Naito H, Shibamoto A, Wang

- AS, Shobara K et al. Evaluation of implant screw loosening by resonance frequency analysis with tri-axial piezoelectric pick-up: in vitro model and in vivo animal study. *Clin Oral Investig* 2018; 22: 2129-34. <http://dx.doi.org/10.1007/s00784-018-2467-1>
- 8) Qi J, Miyashita M, Ogawa T, Naito H, Sasaki K. Resonance frequency analysis for evaluation of the connecting condition between fixed prostheses and their abutment teeth: An in vitro and finite element analysis study. *J Prosthet Dent* 2022 Apr 28; S0022-3913(22)00150-0. <https://doi.org/10.1016/j.prosdent.2022.03.005>
  - 9) Kang IA, Njimboum SN, Lee KO, Kim JD. DCP: Prediction of dental caries using machine learning in personalized medicine. *Appl Sci* 2022; 12: 3043. <http://dx.doi.org/10.3390/app12063043>
  - 10) Kim EH, Kim S, Kim HJ, Jeong HO, Lee J, Jang J et al. Prediction of chronic periodontitis severity using machine learning models based on salivary bacterial copy number. *Front Cell Infect Microbiol* 2020; 10: 571515. <http://dx.doi.org/10.3389/fcimb.2020.571515>
  - 11) Sidey-Gibbons JAM, Sidey-Gibbons CJ. Machine learning in medicine: a practical introduction. *BMC Med Res Methodol* 2019; 19: 64. <https://doi.org/10.1186/s12874-019-0681-4>
  - 12) Deo RC. Machine learning in medicine. *Circulation* 2015; 132: 1920-30. <https://doi.org/10.1161/circulationaha.115.001593>
  - 13) Baur C, Denner S, Wiestler B, Albarqouni S, Navab N. Autoencoders for unsupervised anomaly segmentation in brain mr images: A comparative study. 2020. <https://doi.org/10.48550/arXiv.2004.03271>
  - 14) Pedregosa F, Varoquaux G, Gramfort A, Michel V, Thirion B, Grisel O et al. Scikit-learn: Machine learning in Python. *J Mach Learn Res* 2011; 12: 2825-30. <https://www.researchgate.net/publication/51969319>
  - 15) Saito T, Rehmsmeier M. The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. *PLoS One* 2015; 10(3): e0118432. <http://dx.doi.org/10.1371/journal.pone.0118432>
  - 16) Rengasamy D, Mase JM, Kumar A, Rothwell B, Torres MT, Alexander MR et al. Feature importance in machine learning models: A fuzzy information fusion approach. *Neurocomputing* 2022; 511: 163-74. <https://doi.org/10.1016/j.neucom.2022.09.053>
  - 17) Suryawati E, Pardede HF, Zilvan V, Ramdan A, Krisnandi D, Heryana A et al. Unsupervised feature learning-based encoder and adversarial networks. *J Big Data* 2021; 8(1): 118. <http://dx.doi.org/10.1186/s40537-021-00508-9>
  - 18) Zavrak S, Iskefiyeli M. Anomaly-based intrusion detection from network flow features using variational autoencoder. *IEEE Access* 2020; 8: 108346-58. <http://dx.doi.org/10.1109/ACCESS.2020.3001350>
  - 19) Scornet E. Trees, forests, and impurity-based variable importance in regression. *Ann Inst H Poincaré Probab Statist* 2023; 59: 21-52. <http://dx.doi.org/10.1214/21-AIHP1240>
  - 20) Brownlee J. Feature importance and feature selection with XGBoost in python. *Machine Learning Mastery* 2016. <https://machinelearningmastery.com/feature-importance-and-feature-selection-with-xgboost-in-python/>
  - 21) Li N, Shepperd M, Guo Y. A systematic review of unsupervised learning techniques for software defect prediction. *Inf Softw Technol* 2020; 122: 106287. <http://dx.doi.org/10.1016/j.infsof.2020.106287>
  - 22) Janiesch C, Zschech P, Heinrich K. Machine learning and deep learning. *Electron Mark* 2021; 31(3): 685-95. <https://doi.org/10.1007/s12525-021-00475-2>
  - 23) Nassif AB, Talib MA, Nasir Q, Dakalbab FM. Machine learning for anomaly detection: A systematic review. *IEEE Access* 2021; 9: 78658-700. <http://dx.doi.org/10.1109/ACCESS.2021.3083060>
  - 24) Belay MA, Blakseth SS, Rasheed A, Salvo Rossi P. Unsupervised anomaly detection for iot-based multivariate time series: Existing solutions, performance analysis and future directions. *Sensors* 2023; 23: 2844. <http://dx.doi.org/10.3390/s23052844>

---

著者連絡先：小川 徹

〒980-8575 宮城県仙台市青葉区星陵町 4-1  
東北大学大学院歯学研究科総合歯科学分野  
E-mail: toru.ogawa.d7@tohoku.ac.jp