

## 木材ヘルスマニタリングへ向けた機械学習を用いた振動データの識別 Identification of Vibration Data Using Machine Learning for Timber Health Monitoring

大岩 凌<sup>†</sup>  
Ryo Oiwa

伊藤 拓海<sup>‡</sup>  
Takumi Ito

河原 尊之<sup>†</sup>  
Takayuki Kawahara

### 1. はじめに

IoT の時代が到来し、全世界が 1 兆個ものセンサであふれるという「Trillion-sensor universe」という言葉や、プロセッサ、メモリ、通信機能を搭載した motes と呼ばれるセンサを随所に配置し、自然環境をモニタリングしようとする「Smart Dust」というプロジェクトがある。一方、これらの構想はインターネットに接続されるセンサ数が増大し、トラフィックの爆発的な増加が懸念されている。我々はこの問題を解決するため、人工知能 (AI) チップをセンサに取り付けることによりモノ側で情報を処理し、トラフィック量を減少させる研究を行っている[1][2]。

一方で社会の高齢化や人口減少に伴い、危険な空き家が増加している。従来は木材の内部状況を常にモニタリングする方法は無く、適時的なモニタリングの方法としては、細い棒を差し込みその深さから木の劣化を探る貫入法や、超音波を照射しその透過音から木材の内部状況を把握する超音波探傷法などがあった。いずれの方法も広く用いられているが、測定には多大な費用と訓練を積んだ技術者が必要になる。そこで我々は AI を埋め込んだセンサを木材に取り付けることを提案している。建物が有する常時微動を振動源として、木材の損傷・劣化に起因するこの振動伝達の微小な変化を少数のセンサで常に探知して、必要な情報のみを送信するものである。本論文では、通信量・センサ数の両方を削減するためのこの AI を用いた木材ヘルスマニタリングシステムに関する基礎的な検討結果を示す。

### 2. 木材ヘルスマニタリング

図 1 に提案するシステムの概略を示す。振動センサ、AI チップ、通信機能、発電機能を含むセンサモジュールを筋交いに取り付ける。このシステムにより建物が有する常時微動を利用して木材の損傷・劣化の早期発見が可能となる。また、常時微動による発電も意図している。地震の際には被害状況を直ちに診断することもできるようになる。最終的には木材の細かな内部状態(損傷・劣化)を少数の振動センサで見える化することを目指している [3][4]。




図 1 木材ヘルスマニタリングシステムの概念図

### 3. 実験方法

#### 3.1 モデル化

実験系は筋交いをモデルに構築した。筋交いの下部に、常時微動による建物の土台を始点とした振動が伝わり、筋交いの上端にて揺れを観測することを想定した。木材の損傷・劣化は重りを乗せることで疑似的に再現した。これにより、実際とモデルとの対応関係は表 1 のようになる。

表 1 実際と実験系との対応

| 実際        | モデル      |
|-----------|----------|
| 建物土台からの振動 | ボールによる衝撃 |
| 損傷・劣化の位置  | 重りの位置    |
| 損傷・劣化の程度  | 重りの重さ    |

#### 3.2 実験手順

図 2 に実験系を示す。高さ 3 cm、幅 4 cm、長さ 100 cm のアカマツを 10cm ごとに区切って箇所特定の単位 (クラス) とし、木の重量に対して 10%、20%、30% の 3 種類の重りを用意した。右端の区間は圧電センサを取り付け、左端の区間にボールを落下させた。そして以下の手順で振動波形を取得した。

- (1) 1 番目のブロックに木の重量の 10% の重りを乗せる
- (2) 木材から 2cm の高さからボールを落下させ、衝撃により振動を発生させる
- (3) オシロスコープにて圧電センサの振動波形を記録する
- (4) (2) と (3) を 30 回繰り返す
- (5) 重りの位置を 2 番目のブロックに移し、(2) ~ (4) を繰り返す
- (6) 重りを木の重さに対して 20%、30% と変え、(2) ~ (5) を繰り返す

重りの位置 8 箇所、重さ 3 種類の合計 24 パターンの振動波形を 30 回ずつ測定した。1 本の木に対して 720 回の測定を行ったこととなる。これを検証のため 5 本について行ったため、測定回数は全部で 3600 回に及ぶ。




図 2 実験系の概略図

<sup>†</sup> 東京理科大学工学部電気工学科

<sup>‡</sup> 東京理科大学工学部建築学科

### 3.3 取得したデータ

取得したデータは衝撃の前後 25ms を記録したものである。それぞれの波形は 2500 点の電圧値が記録されている。図 3 に波形の一例を示す。重りの位置・重さを揃えた 10 本の波形を重ねて表示している。




図 3 取得波形の例

## 4. 評価方法

取得した波形の識別に際し、2通りの識別を行った。

### 4.1 重りの位置 8 パターンの識別

重りの重さが一定のデータを用いて学習させ、重りの位置 8 箇所のみを識別対象とした。




図 4 8 クラス分類

### 4.2 重りの位置と重さ 24 パターンの識別

全てのデータを学習させ、重りの位置・重さの両方を識別対象とした。重りの位置 8 箇所、重さ 3 種類であるため、24 クラス分類となる。




図 5 24 クラス分類

## 5. 機械学習手法<sup>[5]</sup>

### 5.1 k 最近傍法 (k-NN)

k 最近傍法, k-Nearest Neighbor (k-NN) 法は図 6 のように識別したいデータから k 個の近傍点を求め、それらの多数決によりクラスの判定を行う方法である。アルゴリズムが単純であるという特徴がある。図 6 は k=3 の場合であり、図中の星印にある未知のデータは、クラス 2 に分類されることになる。




図 6 k-NN 法の概念図

### 5.2 サポートベクトルマシン (SVM)

Support Vector Machine (SVM) は学習データを最も大胆に区切る識別境界を学習する。図 10 のように各クラスのうち境界に最も近いデータ点 (Support Vector) と識別境界との間の距離を最大化する境界を求める。このため識別境界から遠い外れ値の影響を受けにくい、次元が大きくなっても識別精度が高いなどの特徴がある。SVM は 2 クラス分類のアルゴリズムではあるが、複数の SVM を用いることにより今回のような多クラス分類も可能となる。

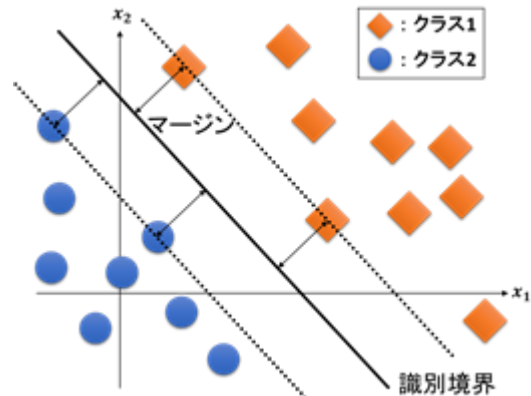


図 7 SVM の概念図

### 5.3 2 クラス分類器による多クラス分類

SVM のような 2 クラス分類器を多クラス分類に用いる場合、複数の 2 クラス分類器を組み合わせる。その典型的な手法として、1 対他法と 1 対 1 法がある。いま、 $c_1, c_2, \dots, c_M$  の M クラス分類を行うとする。

1 対他法は「あるクラス  $c_i$ 」と「それ以外」を分類する 2 クラス分類器を M 個用意し学習させる方法である。そして分類の際には、M 個の 2 クラス分類器の出力結果のうち最も信頼性の高い結果に分類することになる。M が大きい場合、学習データのうちクラス  $c_i$  に属するデータとそれ以外に属するデータの数がアンバランスになる問題がある。

1 対 1 法は 2 つのクラス  $c_i$  と  $c_j$  で 1 対 1 の二値分類を行う方法であり、 $M(M-1)/2$  個の分類機を用意する。これにより先程のアンバランス問題は解決されるが、比較的大きくない M に対しても、たくさんの 2 クラス分類器を用意しなければならない。本研究においては 1 対 1 法を採用し、以後単に SVM という記述がある場合には、SVM と 1 対 1 法を組み合わせることを意味する。

### 5.4 カーネル法

$D+1$  次元の特徴ベクトル  $\mathbf{x} = [1, x_1, x_2, \dots, x_d]^T$ , 重みベクトル  $\mathbf{w} = [w_0, w_1, w_2, \dots, w_d]^T$  を用いて, 線形識別関数は次式で表される.

$$g(\mathbf{x}) = \mathbf{w}^T \mathbf{x}$$

この識別関数は学習データ線形識別可能な場合には適用できるが, 線形識別不可能なデータに対しては適用できない. そこで線形識別不可能なデータを線形識別可能なデータに変換する関数  $\Phi(\mathbf{x})$  を導入する. 識別関数は以下のように表される.

$$g(\Phi(\mathbf{x})) = \mathbf{w}^T \Phi(\mathbf{x})^T \Phi(\mathbf{x}')$$

そして, 以下の式をカーネル関数と呼ぶ.

$$\kappa(\mathbf{x}, \mathbf{x}') = \Phi(\mathbf{x})^T \Phi(\mathbf{x}')$$

カーネル関数には, 線形カーネル, 正規化カーネル, 多項式カーネル等の種類がある. 本研究では 2 次および 3 次の線形カーネルを用いた. 線形カーネルは以下の式で表される.

$$\kappa(\mathbf{x}, \mathbf{x}') = (\mathbf{x}^T \mathbf{x}' + c)^m$$

ここで,  $m$  は多項式の次数である.

図 8 にカーネル関数の概念を示す.




図 8 カーネル関数の概念図

### 5.5 交差検証法

識別器の識別率を求める方法として交差検証法がある. 取得したデータを学習用のデータと検証用のデータに分け, 出来上がった識別器に検証用データを代入して正確に分類できたかを確認する方法である. 本研究では  $k$ -分割交差検証法を用いた. データを  $k$  個に分割しそのうちの 1 個を検証用データとし, 残りの  $k-1$  個を学習データとして識別率を求める. これを  $k$  回繰り返し, 各結果を平均して全体の識別率とした.

### 5.6 主成分分析

主成分分析は相関のある多数の変数から, 相関のない少数の主成分と呼ばれる全体のばらつきを最もよく表す変数を合成する多変量解析の一手法である. 本研究においては取得した振動データの削減に利用した.

図 9 に示すように, 点  $\mathbf{x} = [x_1, x_2, \dots, x_n]^T$  の主成分  $\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_n$  方向の軸への射影  $[y_1, y_2, \dots, y_n]^T$  は以下のように表される.

$$\begin{cases} y_1 = w_{11}x_1 + w_{12}x_2 + \dots + w_{1n}x_n = \mathbf{w}_1^T \mathbf{x} \\ y_2 = w_{21}x_1 + w_{22}x_2 + \dots + w_{2n}x_n = \mathbf{w}_2^T \mathbf{x} \\ \vdots \\ y_n = w_{n1}x_1 + w_{n2}x_2 + \dots + w_{nn}x_n = \mathbf{w}_n^T \mathbf{x} \end{cases}$$

ただし,

$$\mathbf{w}_i^T \mathbf{w}_j = \begin{cases} 1 & (i = j) \\ 0 & (i \neq j) \end{cases}$$

である. さらに変換行列を  $\mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_n]$  とすると,  $\mathbf{y}$  は以下のように表すことができる.

$$\mathbf{y} = \mathbf{W}^T \mathbf{x}$$

主成分分析は分散が最大となる  $\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_n$  を見つけ出す問題と言い換えることができる.

図 9 に示した通り, 第一主成分は観測値の変化を可能な限り説明できるよう, 分散が最大となるように選択される. 第二主成分以下はこれまでに決定された主成分と直交するという条件の下で分散を最大にするように選択される. 以上のようにして, 波形データの次元を削減した.




図 9 主成分分析の概念図

## 6. 結果

### 6.1 k-NN 法と SVM の比較

はじめに重りの位置 8 箇所のみ 8 クラス分類について, 図 10 に識別率の結果を示す. A, B, C および D は木につけた便宜上の名前であり, 材質・寸法は同一である.




図 10 k-NN と SVM の比較 (重り : 10%)

図 10 の通り, 木によって識別率にバラツキがある. そこでこれ以後は 4 つの木の平均値を用いて結果を示す.

表 2 に重りの重さごとに比較した結果を示す.

表 2 k-NN と SVM の比較

|     | k-NN | SVM  |
|-----|------|------|
| 10% | 91.5 | 92.3 |
| 20% | 86.3 | 92.4 |
| 30% | 94.3 | 94.4 |

重りの重さが木の重量に対して 20% のとき、SVM は k-NN に比べ識別率が 6% 高くなっている。また、全体としても SVM の方が k-NN よりもいづれか識別率が高いと言える。

## 6.2 SVM におけるカーネル法の適用

SVM においてカーネル関数を導入した場合の識別率を表 3 に示す。本研究においては 1~3 次元の線形カーネル関数を用いた。表中の  $d$  は次元数である。

表 3 カーネル法適用時の識別率

|     | $d=1$ | $d=2$ | $d=3$ |
|-----|-------|-------|-------|
| 10% | 92.3  | 95.3  | 94.8  |
| 20% | 92.4  | 93.4  | 92.4  |
| 30% | 94.4  | 96.9  | 96.8  |

重りの重さがいづれの場合でも、2次元の線形カーネル関数を用いた時に最も識別率が高くなった。

## 6.3 主成分分析による次元の削減

振動発生後の 1250 点のデータの相関係数は、図 11 に示す通りである。




図 11 相関係数

相関係数が 0 となっている箇所が見受けられ、次元削減の余地があることを示している。

次に、2次元多項式カーネル関数と SVM を用いて、主成分分析の有無による識別率の差を表 4 に示す。今回は主成分分析によりデータの次元を 1250 から 10 まで削減した。

表 4 主成分分析の有無と識別率

|     | no PCA | PCA  |
|-----|--------|------|
| 10% | 95.3   | 94.0 |
| 20% | 93.4   | 94.0 |
| 30% | 96.9   | 97.4 |

主成分分析を適用しデータの次元数を 10 次元に削減しても識別率はほとんど低下しないことが分かった。

## 6.4 重りの位置と重さ 24 パターンの識別

これまでの結果は重りの位置 8 箇所についての識別であった。本項では重りの位置と重さ 24 パターンを識別した場合の結果を示す。

表 5 24 クラス分類の結果

|             | SVM   |       |       | k-NN |
|-------------|-------|-------|-------|------|
|             | $d=1$ | $d=2$ | $d=3$ |      |
| without PCA | 88.9  | 92.4  | 92.0  | 89.4 |
| with PCA    | 88.2  | 91.5  | 91.3  | 88.6 |

8 クラス分類に比べ識別率は低下しているが、2次の多項式カーネルを用いた場合に識別率が最大となる等の傾向は 8 クラス分類と同様である。

以上の結果から、1つの圧電センサと機械学習により木材の損傷や劣化を 90% 以上の精度で特定できることが分かった。すなわち、木材ヘルスマニタリングシステムの実現可能性が明らかとなった。

## 7. おわりに

木造建築物を常時監視可能な IoT システムの実現に向け、第一歩として木材の損傷・劣化を重りによってモデル化し、振動波形から重りの位置と程度を特定を試みた。そして機械学習により解析した結果、2次の多項式カーネルを用いた SVM において最も高い識別率となることが分かった。また、主成分分析によりデータの次元数を 10 次元まで削減しても識別率はほとんど低下しないことが確かめられた。以上の結果から、図 12 に提案する木材ヘルスマニタリングにおけるセンサモジュールの実現可能性が明らかとなった。




図 12 センサモジュールのブロック図

## 参考文献

- [1] K. Someya, R. Ono, and T. Kawahara, "Novel Ising Model Using Dimension-Control for High-Speed Solver for Ising Machines," Paper ID 4137, Session B2P-F, IEEE NEWCAS, doi: 10.1109/NEWCAS.2016.7604797, June 2016.
- [2] 武藤陽子, 徐祖樂, 河原尊之, "ハイブリッド近似法による tanh 活性化関数回路を有する Deep Belief Network の効率的なハードウェア実装," 2017 信学総大, 講演論文集, no.A-1-27, Mar. 2017.
- [3] 大岩凌, 長谷川誉, 高橋徳明, 松井佐英子, 伊藤拓海, 河原尊之, "圧電センサと機械学習を用いた木材のヘルスマニタリング," 2016 信学ソ大, 講演論文集, no.A-19-18, Sept. 2016.
- [4] R. Oiwa, T. Ito, and T. Kawahara, "Timber Health Monitoring Using Piezoelectric Sensor and Machine Learning," 20th IEEE CIVEMSA, Annecy, France, June 2017.
- [5] 後藤正幸, 小林学, 入門パターン認識と機械学習, pp.21-41, コロナ社, 2014.