

# AIによる音響・振動データからの知識発見と予測



特集1  
ハイテク推進  
セミナー

大阪大学産業科学研究所 第1研究部門 (情報・量子科学系)  
准教授 福井 健一 氏

## 1. 概要

損傷現象や身体活動により生じ物質中もしくは空气中を伝わる音波には、対象の現在の状態や予兆に関する多彩な情報が含まれており、in-situ (その場) 評価に有用である。本稿では各種音響・振動データに対してAI技術 (機械学習) により解析することで、事象間の相互作用の発見や一連の状態変化の可視化、また余寿命予測に関して著者がこれまで取り組んできた共同研究事例を紹介する。具体的には、(1) 固体酸化燃料電池の損傷評価、(2) 睡眠状態分析、(3) 転がり軸受の欠陥評価について紹介する。

## 2. 固体酸化燃料電池の損傷評価

### 2.1 背景

固体酸化燃料電池は高効率・低公害なエネルギー変換デバイスとして期待されているが、長期安定運転には還元膨張・熱膨張により、き裂やはく離などの物理的な劣化が生じる。運転環境下における損傷の過程を理解し、部材間の力学的関係を推定することで運転の指針や材料開発に役立てることができる。

### 自己組織化マップによる可視化

自己組織化マップ(Self-Organizing Map: SOM), (Kohonen, 1990)

- 元々は、視覚に関連する大脳皮質で行われる自己組織化過程のニューラルネットワークモデル
  - 類似パターンに発火するニューロンのモデル化
- 近年では、ベクトル量子化と低次元への写像を行うユニークな方法としてデータマイニングに応用

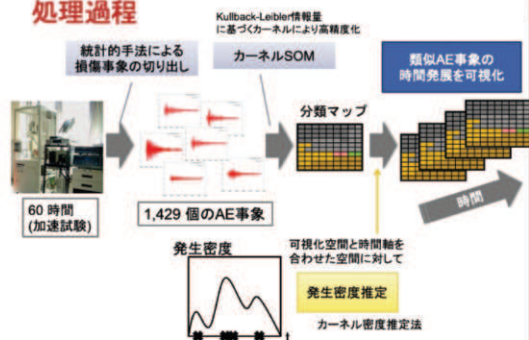


類似データが近傍に配置されるように自己組織化

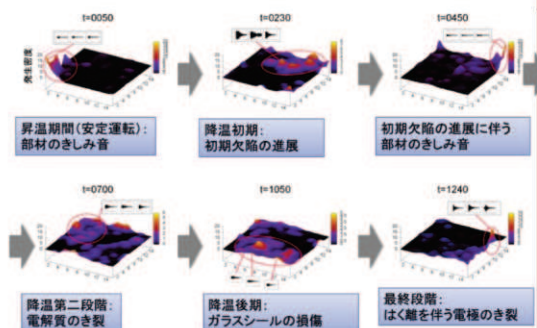


隣接ノードとのギャップ  
白→黒  
小→大

### 処理過程



### 損傷過程の解釈



講師 福井 健一 氏

## 2.2 損傷過程の可視化

ここでは教師なしニューラルネットワーク学習のひとつである自己組織化マップ (Self-Organizing Map) に基づく損傷過程の可視化法を紹介する。

まず、計測した AE 信号系列から損傷に起因する AE 事象を統計的手法により抽出する。そしてそれらの事象の周波数パワースペクトルを特徴ベクトルとして、自己組織化マップにより学習することで AE 事象の類似性を反映した分類マップが得られる。ここで Kullback-Leibler 情報量に基づくカーネルを利用することで AE 事象の分類性能を向上できる。そして、事象の発生確率密度を推定することで分類マップでの時間発展が可視化される。

SOM により可視化された損傷過程を解釈したところ、初期欠陥の進展から電解質のき裂、ガラスシール材の損傷、そして最後に電極材のはく離が起ることが確認された。


## 2.3 損傷パターン抽出

損傷事象の発生相関を分析する方法として、著者らは空間的近接性 (クラスタ性)、時間的近接性、頻出性の要件を満たすパターンを抽出するクラスタ系列マイニングを考案した。まず、クラスタリングにより候補パターンを生成し、時間的近接性と空間的近接性からなる評価関数を評価し、評価値の上位 K パターンもしくは閾値以上のパターンを抽出する。このとき、ベイズ推定により事象発生の前後関係と確率密度関数を推定している。

クラスタ系列マイニングにより抽出された複数の損傷パターンから、初期欠陥を起点として電解質のき裂やガラスシール材の損傷等に進展していることが示唆された。また、電極材と電解質は物理的には接しているにも関わらず損傷パターンが検出されなかった点は興味深い。

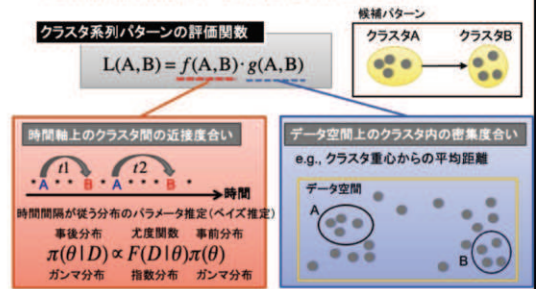
## 損傷事象の発生相関分析

高頻度で時間的に近接して共に起こる損傷事象を抽出  
 ・ 部材間の機械的關係が現れている可能性がある

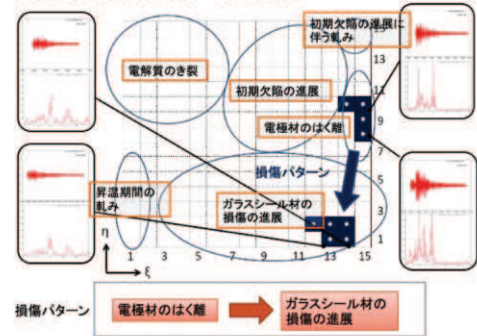


## クラスタ系列マイニング

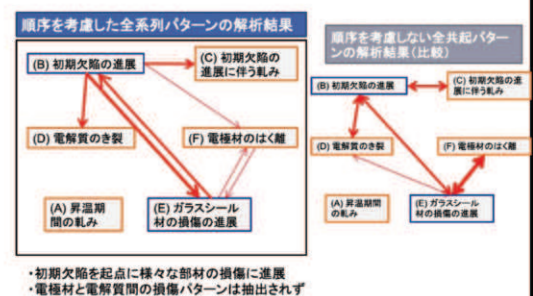
多数の候補から系列パターン評価値上位のパターンを列挙



## クラスタ系列パターンの例



## 全パターンのまとめ





### 3. 睡眠状態分析

#### 3.1 背景

睡眠は覚醒時における身体的、精神的、社会的、感情的な機能に影響を及ぼす生体现象であり、日常の睡眠状態を評価することは日々の健康を管理する上で重要である。本稿では、非接触かつ簡便な計測が可能な睡眠中の音響に基づく睡眠評価法を紹介する。睡眠音には睡眠を特徴付ける様々な生体活動(いびき、歯ぎしり、体動等)や周囲の環境音など多様な情報が含まれるため、従来のウェアラブルデバイスでは困難であった総合的な睡眠評価が可能になる。

#### 3.2 睡眠パターンの可視化

一晩の集音データから統計的手法により音イベントを検出し、その周波数パワースペクトルを入力として時系列カーネルSOMにより学習することで、一晩の睡眠パターンが可視化される。ここで、時系列SOMでは可視化される空間の一方向に時間軸を導入する拡張をしており、クラスタの時間変化を可視化することができる。

本手法により、ある被験者の一晩の音データからいびき音、体動音、歯ぎしり音のクラスタの時間変化が可視化される。つまり、一晩どのような睡眠のパターンであったかが視覚的に分かる。この可視化結果とポロソムノグラフィ (PSG) 検査に基づくレム・ノンレム睡眠などの睡眠ステージとの相関を調べたところ、これまで睡眠科学においても判明していた関係性が音からも確認された。このことから音のみから睡眠個性が把握できるといえる。

### 背景

睡眠は日中のパフォーマンスに大きく影響を与える  
日本人の5人に1人は睡眠不足を感じているという報告もある(厚生労働省平成27年度国民健康・栄養調査)

従来の睡眠評価

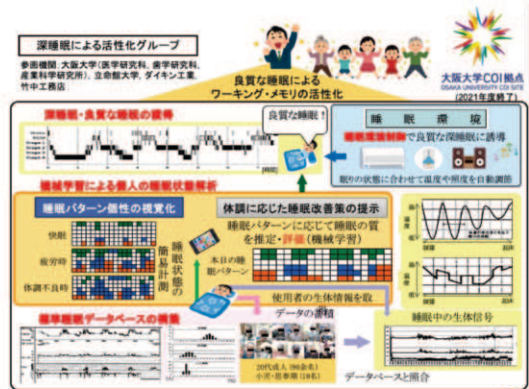
- 睡眠ポリソムノグラフィ検査(PSG)
- 専門の施設が必要
- 睡眠障害検査、睡眠科学研究向け



家庭環境で計測可能な非接触デバイスによる簡易的な睡眠評価手法が必要




17



19

### 睡眠パターン可視化法の概略




- 時系列カーネルSOM(Self-Organizing Map)
- SOM: 多次元のデータ間の類似性を反映した低次元射影
  - 時系列SOM<sup>[8]</sup>: クラスタ動態を可視化するようにSOMを拡張
  - カーネルSOM: カーネル法(KL情報量)により高精度化

[8] 稲井一、齊藤和巳、木村高弘、沼尾正行, "自己組織化ネットワークによる動的クラスタの可視化", 人工知能学術論文誌 Vol. 23, No. 5, pp.319-329, 2006.

20

### 睡眠パターン可視化例



睡眠関連音と睡眠ステージに高い関連性を確認

音から睡眠個性を把握可能

22

### 3.3 睡眠の良否判別

つづいて、睡眠の良否判別では、良い睡眠・悪い睡眠それぞれについて、検出した音イベントの系列から隠れマルコフモデル (HMM) により一晩の時系列パターンを学習する。そして、良否判別は良い睡眠と悪い睡眠の HMM の学習済みモデル (複数の隠れ状態数を含む) に当てはめた時の尤度を特徴ベクトルとして、別途 SVM により判別学習を行う。なお、睡眠の良否に関する教師データは被験者による主観評価 (アンケート) を用いた。

36名 (36晩) の被験者データに対してひとつ抜き交差検証により評価したところ、正答率 77.5% が得られた。被験者数が限られている事を考慮すると、期待が持てる結果であるといえる。また、睡眠ステージを入力とした場合の HMM では良否のモデル間において、状態遷移確率は大きな差は見られず、一方、音イベントに基づく本 HMM では差が確認された。このことから、睡眠ステージでは (主観的な) 良否判別は困難であることが示唆される。

### 3.4 想定される利用例

上記で紹介した睡眠パターンの可視化や良否判別は次のような利用が想定される。1. 空調、音環境、照明などの睡眠環境と連動し、より良い睡眠に導く睡眠環境制御、2. モバイル端末で日々の睡眠状態を管理する睡眠評価システム、3. 改善案の提示・評価を繰り返すことで行動変容を促す睡眠教育プログラム、等が考えられる。

### 睡眠良否判別法の概略

- ・ HMM(隠れマルコフモデル)により睡眠パターンをモデル化
- ・ 良い睡眠と悪い睡眠の尤度から識別器を構築



25

### 睡眠良否判別結果

- ・ 36名 (36夜) の被験者
  - ・ 1つ抜き交差検証により評価
- 学習に用いていない被験者に対して平均 **77.5%** の正答率を達成

Method	Mean accuracy		
	Total data	Good sleep quality data	Poor sleep quality data
SVM on likelihood	0.775	0.767	0.783
SVM on event count	0.483	0.531	0.435
Adaboost	0.615	0.583	0.647
Majority decision	0.722	0.757	0.687
Likelihood summations	0.694	0.667	0.722

状態数=4

Test data	Number of hidden states				
	2	3	4	5	Mean
Good quality data	0.583	0.722	0.746	<b>0.751</b>	
Poor quality data	0.722	<b>0.778</b>	0.659	0.667	
Mean	0.652	0.750	0.703	0.709	

26

### 睡眠ステージとの比較

状態遷移確率

	1	2	3	4	5
良い睡眠	0.0000	0.0000	0.0000	0.0000	0.0000
悪い睡眠	0.0000	0.0000	0.0000	0.0000	0.0000

音イベントに基づくHMM学習結果

	1	2	3	4	5
良い睡眠	0.0000	0.0000	0.0000	0.0000	0.0000
悪い睡眠	0.0000	0.0000	0.0000	0.0000	0.0000

睡眠ステージに基づくHMM学習結果

睡眠ステージでは睡眠の良否判別は困難

27

### 想定される利用例



28



## 4. 転がり軸受の欠陥評価

### 4.1 背景


転がり軸受は多くの回転機械において欠かせない重要な要素のひとつであり、自動車やプラント、航空機等使用される分野は非常に多岐にわたる。転がり軸受に損傷が発生した場合、回転機械の精度や運転効率に影響を与えるだけでなく、機械自体に致命的なダメージを与える場合もある。そのため、転がり軸受の欠陥を早期に検出し余寿命を推定することは機械保全において重要な課題である。

### 4.2 微小欠陥の早期検出

従来の異常検知法をそのまま適用しただけでは振動加速度データから微小の欠陥を検出するのは困難であった。欠陥の段階に応じて検出に有効な特徴が変化するため、欠陥の程度に応じた適切な特徴選択が必要となる。そこで、著者らは Random Forest に基づく特徴選択と、2段の異常検知を組み合わせた欠陥の早期検出法を提案した。1段目の異常検知では各欠陥状態に応じた特徴選択後の特徴量を用いて異常度を算出し、それらを異常ベクトルとして2段目の異常検知により総合評価を行う。なお、異常検知法としては事前検討により Local Outlier Factor (LOF) を用いた。特徴選択では、全 378 次元から上位 10 次元を選択した。

疲労はく離を想定した人工欠陥を設けた実験では、各欠陥サイズ 33 個の軸受に対して計測した。本手法は特に低速および高速域において、特徴選択を行わない場合と比較して微小欠陥の検出精度が大幅に向上することを確認した。

### 欠陥の早期検出の課題

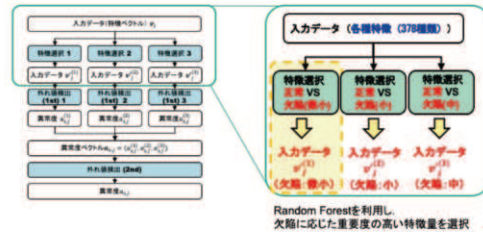


従来の異常検知法では微小な欠陥の検出が困難

32

### 欠陥の早期検出 - 提案手法(1)


- 欠陥の状態によって有用な特徴は変化
  - 欠陥の状態に応じた特徴選択



Random Forest を利用し、欠陥に応じた重要度の高い特徴量を選択

33


### 欠陥の早期検出 - 実験装置・入力データ



運転条件	
対象軸受	アンギュラ玉軸受(7216)
回転速度	1,000 min <sup>-1</sup> , 1,500 min <sup>-1</sup> , 2,000 min <sup>-1</sup>
測定データ	振動加速度(鉛直, 軸, 水平)
軸受サンプル数	33個 / 各欠陥サイズ (学習に24個, 評価に9個のサンプルを選択し、クロスバリデーションで評価)

37

### 欠陥の早期検出 - 提案手法による欠陥検出精度



Original : LOF(1段)のみによる評価  
Proposed : 提案手法(Random Forest)による特徴選択と2段のLOF)による外れ値検出  
Comparison : 比較手法(従来手法のRandom Forestの代わりにLaplacian Score[He 05]を使用)

提案手法により低速・高速域において微小欠陥検出性能が大幅に向上した

38

### 4.3 余寿命予測

次に、欠陥を検出した後、その後の余寿命を予測する方法を紹介する。余寿命予測における難しさは、同じ運転条件下であったとしてもサンプルによる余寿命の個体差が大きい（33 サンプルで3倍の開きがある）こと、また、特に末期において振動特徴の変動が大きいことが挙げられる。これらの課題に対して、著者らは畳み込みニューラルネットワーク（CNN）をベースとしてスペクトログラムから特徴抽出を行い、階層ベイズ回帰と組み合わせることで、個体差と不確実性を考慮して余寿命「曲線」を推定する手法を考案した。階層ベイズ回帰では、欠陥サイズ（推定値）と余寿命（推定値）の系列を入力として、余寿命曲線の予測分布を推定する。予測分布に個体差を表すパラメータを導入することで、個体差を軽減している。本手法は余寿命曲線を推定することで、余寿命の単調性を保証する。


33個の軸受に対して加速試験を行い、ひとつ抜き交差検証により評価を行った。計測が進むにつれて、推定余寿命曲線は真値に近づき、また確信度分布の幅も狭まり不確実性が小さくなる。また、CNNにより直接余寿命を推定する方法と比較して、本手法は特に損傷末期において大幅に推定精度が向上することを確認している。

### 謝辞

燃料電池の研究においては東北大学工学研究科・佐藤一永先生、また睡眠の研究においては大阪大学歯学研究科・加藤隆史先生には、ご助言、実験データ提供に感謝申し上げます。また、転がり軸受の研究はNTN（株）との共同研究であり、大阪大学NTN次世代協働研究所・北井正嗣氏により実施されたものです。また、睡眠に関する研究は大阪大学COI拠点（2013～2021年度）により支援を受けて行われました。


### 欠陥検出後の余寿命推定における課題

- 同じ運転条件下においても、サンプルによる余寿命の個体差が大きい。
- 欠陥の進展に伴う振動特徴の変動が大きく、正確な余寿命の推定が困難。




40

### 欠陥進展下の余寿命推定 - 提案手法(2)

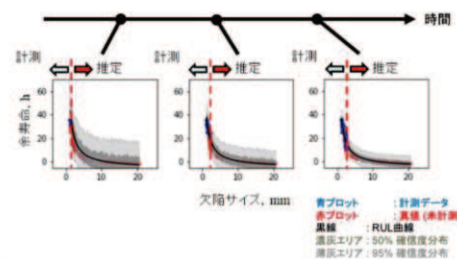


2. 余寿命曲線を推定することで、単調な予測が可能



42

### 余寿命曲線の進展



計測が進むにつれて、個体差パラメータの推定が正確になり、余寿命曲線（平均）は真値に近づき、確信度分布の幅も狭まる

45