

キーグラフと SOM を用いた稀な重要 事象の抽出-燃料電池の損傷評価を例に-

北川 哲平^{†1} 福井 健一^{†2} 佐藤 一永^{†3}
水崎 純一郎^{†3} 沼尾 正行^{†2}

複雑系において、事象過程の急激な遷移は潜在的に重要な相互作用の表れであるが、そのような事象の発生頻度は低い。本研究では、事象系列において比較的稀であるが、状態が遷移するときに共起する事象を抽出する Essential Event Extractor(E³) 法を提案した。E³ 法では、自己組織化マップ (SOM) を符号化のためにベクトル量子化 (VQ) として、また共起グラフを生成するためにキーグラフを用いる。そして、VQ のトポロジーマップにおける発生密度推定を参照することで、共起グラフ上で事象遷移を得る。本論文では、燃料電池の損傷試験で観測される AE 事象系列に対して E³ 法を適用し、燃料電池の損傷メカニズムを解明するために、有用な損傷事象系列を得た。

Extraction of Essential Events Using SOM and KeyGraph : Application to Damage Analysis on of Fuel Cells

TEPPEI KITAGAWA,^{†1} KEN-ICHI FUKUI,^{†2}
KAZUHISA SATO,^{†3} JUNICHIRO MIZUSAKI^{†3}
and MASAYUKI NUMAO ^{†2}

Although sudden changes of the event phase in complex system may indicate potential essential forces, such events are rare. In the present paper, we propose an essential event extractor (E³) scheme to extract relatively rare but co-occurring event sequences in event transitions. In E³, the self-organizing map (SOM) is used as vector quantization (VQ) and KeyGraph as a co-occurrence graph. Afterwards, event transitions on the KeyGraph can be obtained by using occurrence density estimation on the topology map of VQ. We demonstrate the E³ using an acoustic emission (AE) event sequence observed during a damage test of fuel cells and obtain essential co-occurring damage sequences.

1. はじめに

Apriori をはじめ時系列データマイニング研究の多くは、頻出パターン抽出に焦点をあてている^{1),2)}。しかしながら、稀な事象は、経済危機、複合材における損傷、地震などの複雑系において、潜在的な相互作用を発見するために重要な役割を果たす。複雑系では、稀で急激な変化を起こす事象があり、その変化はそれまでの進展に比べて極めて短い時間で起こる。Sornette³⁾ は、このような極端な事象の変化は、通常、均衡により表面上に表れていない潜在的な相互作用の表れであり、複雑系を科学的に理解できる可能性があると主張している。本研究では、複雑系において観測される事象系列を対象としており、重要事象を以下のように定義する。

定義 1 (重要事象). 重要事象とは系の状態が遷移するときに起きる事象であり、潜在的な相互作用表れである。そして、その遷移は、蓄積された内部の力が解放されることで、それまでの進展に比べて非常に短い時間で起こる。

従来の稀な事象に関する研究は、順序をもった記号化されたデータを対象としている⁴⁾⁻⁸⁾。つまり、対象としているデータは事前に分類されたデータである。しかしながら、実世界には画像、文書、センサデータなどの未分類のデータは多数存在する。未分類のデータの特徴量や(非)類似度によって記号化し、稀で重要な事象を抽出することは大切である。

本論文で、順序をもった非記号の事象を対象とした Essential Event Extractor(E³) 法を提案する。この手法では、非記号の事象を扱うためにベクトル量子化 (Vector Quantization:VQ) を用いている。VQ の性質は、データを意味をもったクラスタに分類するのではなく、いくつかのベクトルによりデータの全体像を把握できることである。多くのクラスタリング手法は、事前のクラスタ数やクラスタを併合する閾値の設定、チェーン効果などにより結果が大きく変わってしまうが⁹⁾、VQ は事前に適度な数のベクトルを用意するだけでよい。

†1 大阪大学大学院情報科学研究科
Graduate School of Information Science and Technology, Osaka University

†2 大阪大学産業科学研究所
The Institute of Scientific and Industrial Research, Osaka University

†3 東北大学多元物質科学研究所
Institute of Multidisciplinary Research for Advanced Materials, Tohoku University

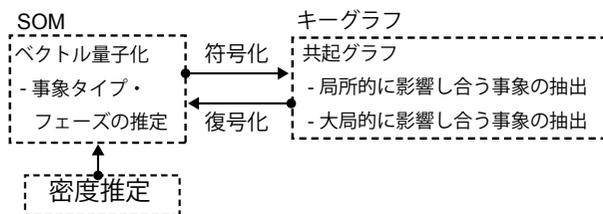


図 1 E³ 法の枠組み
Fig. 1 Overview of essential event extractor (E³).

このため、VQ は未知の領域に対して適した手法であると考えられる。

本論文では、事象の記号化のための VQ として自己組織化マップ (Self-Organizing Map:SOM)¹⁰⁾ と、共起グラフを生成するためにキーグラフ⁵⁾ を組み合わせて用いた。どちらの手法も、ユーザのデータ解析を補助するための探索的データ解析手法 (Exploratory Data Analysis:EDA)¹¹⁾ であるため、SOM とキーグラフは非常に適合性が良い。関連研究として、大澤はキーグラフを用いて危険断層の予測を行った¹²⁾。しかし、各地震事象は事前に震源から最も近い活断層が割り当てられており、各活断層は事前に記号化されたデータである。本研究では、順序をもった未分類のデータを対象としており、事象間の (非) 類似度によって事象を記号化し、共起関係を解析する。

本研究では、固体酸化燃料電池 (Solid Oxide Fuel Cell:SOFC) 損傷試験で得られた AE(Acoustic Emission) 事象系列を用いて、E³ 法を用いて重要な AE 事象を抽出できることを示す。E³ 法により抽出された事象から SOFC の構成部材間の潜在的な力学的関係を明らかにする。

2. E³ 法を用いた重要事象の抽出

2.1 概 説

本論文では、非記号事象系列を扱っている。我々は、非記号事象および事象系列を以下のように定義する。

定義 2 (非記号事象). 事象 X_i は、他の事象との (非) 類似度、すなわち、 $\forall j d(X_i, X_j)$ によって特徴付けられる。

定義 3 (事象系列). 事象系列は、 $D = X_1, \dots, X_T$ で定められる順序を持つ事象集合であ

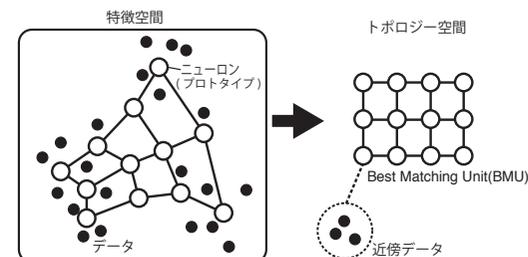


図 2 SOM の概念図
Fig. 2 Conceptual diagram of the SOM.

る。ここで、 X_T は t 番目の事象である。

E³ 法の概略を図 1 に示す。E³ 法において、SOM はベクトル量子化と高次元データの低次元表現の役割を果たしている。データを低次元表現することで、各事象を解析したり、データの全体像を直感的に理解する (図 2)。さらに、SOM は全データ分布を参照ベクトルによって記号化することで、非記号の事象系列をキーグラフに適用している。キーグラフでは、2 種類の事象を抽出する。まず、個々の事象間において高共起度である基礎的な事象集合を抽出する。そして、比較的稀ではあるが、基礎的な事象集合と共起度が高く、相互作用する事象を抽出する。

また、SOM のトポロジーマップから得られる発生確率密度分布の変化と最適事象群に基づいて、ユーザは事象のタイプやフェーズを推定することが可能である。さらに、密度分布の時間変化から事象間遷移の方向を推定し、共起グラフ上で事象遷移と関連がある短い事象系列に分割することができる。そして、フェーズが遷移するとき共起する事象系列を低次元のトポロジーマップ上で得ることで、潜在的な相互作用を示す重要事象を抽出する。

2.2 カーネル SOM

2.2.1 概 説

SOM¹⁰⁾ は教師なしの競合型ニューラルネットワーク学習であり、文書群の探索的分析支援、機械装置の監視、さらには医療・経済など様々な分野に応用がなされている¹³⁾。従来研究で用いられていたカーネル SOM¹⁴⁾ は、陰に高次元へ写像するカーネル関数を用いること

で、線形の解析手法を非線形手法に拡張するカーネル法を利用している。元々SOMは非線形の解析手法であるが、燃料電池の損傷評価において適切な非類似度関数を導入するためにカーネルSOMを用いた。カーネル関数の詳細については3.3.1項で述べる。

ここで、入力データ空間 Ω を高次元特徴空間 \mathcal{H} へ写像する関数を $\phi: \Omega \rightarrow \mathcal{H}$ とすると、カーネル関数は半正定値性をもつグラム行列である。すなわち、 $K(\mathbf{x}_i, \mathbf{x}_j) \equiv \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}_j) \rangle$ である。

2.2.2 カーネルSOMのアルゴリズム

N 個の入力データを $\{\mathbf{x}_1, \dots, \mathbf{x}_N\}$ 、プロトタイプとなる M 個のニューロンに対する参照ベクトルを $\{\mathbf{m}_1, \dots, \mathbf{m}_M\}$ とする。ここで、入力データ \mathbf{x}_i は $\mathbf{x}_i = (x_{i,1}, \dots, x_{i,v})$ の v 次元データ、参照ベクトル \mathbf{m}_j を $\mathbf{m}_j = (m_{j,1}, \dots, m_{j,v})$ 、ニューロンの位置座標 \mathbf{r}_j を $\mathbf{r}_j = (x_j, y_j): j = 1, \dots, M$ とする。ニューロンの数とトポロジーの配置は事前に設定されており、通常二次元の正方格子上に配置する。以下に、バッチ型カーネルSOMのアルゴリズムの概略を示す。

- S1. (初期設定)** ランダムに参照ベクトル $\{\mathbf{m}_1(t), \dots, \mathbf{m}_M(t)\}$ を与える。ここで、 t は更新ステップ回数であり、 $t = 1$ として初期化しておく。カーネルSOMでは、特徴空間 \mathcal{H} において参照ベクトル $\mathbf{m}_i(t)$ は求まらないので、 $\mathbf{m}_i(t)$ のかわりに参照ベクトル $\mathbf{m}_i(t)$ と入力データ \mathbf{x}_n の非類似度 $\{d_{i,n}(t): n = 1, \dots, N\}$ を用いる。
- S2. (BMU探索)** 最適ユニット(Best Matching Units:BMU)、すなわち、各入力データに対して最も近いニューロンとなる勝者ニューロン $\{c(\mathbf{x}_1), \dots, c(\mathbf{x}_N)\}$ を全入力データについて探索する。

$$c(n) = \arg \min_{i=1, \dots, M} d_{i,n}(t) \quad (2.1)$$

- S3. (収束条件)** 勝者ニューロン $\{c(\mathbf{x}_1), \dots, c(\mathbf{x}_N)\}$ が変化しない、もしくは、更新ステップ回数 t が $t = t_{max}$ になると学習を停止する。
- S4. (ニューロンの更新)** 参照ベクトル $\{\mathbf{m}_1(t), \dots, \mathbf{m}_M(t)\}$ を次式により更新する。

$$\begin{aligned} d_{i,n}(t+1) &\equiv \|\phi(\mathbf{x}_n) - \mathbf{m}_i(t+1)\|^2 \\ &= K(\mathbf{x}_n, \mathbf{x}_n) - 2\gamma \sum_j h_{c(j),i} K(\mathbf{x}_n, \mathbf{x}_j) \\ &\quad + \gamma^2 \sum_k \sum_l h_{c(k),i} h_{c(l),i} K(\mathbf{x}_k, \mathbf{x}_l) \end{aligned} \quad (2.2)$$

ここで、 $\|\cdot\|$ はL2ノルム、 $\gamma = 1/\sum_n h_{c(n),i}$ は正規化項である。カーネルSOMで

は $\phi(\mathbf{x}_n)$ は求まらないため、カーネル関数を用いて陰に参照ベクトルを更新する。このとき、近傍関数 $h_{i,j}$ により近傍の勝者ニューロンの影響を受ける。通常、近傍関数には次式のガウス関数が用いられる。

$$h_{i,j} = \exp\left(-\frac{\|\mathbf{r}_i - \mathbf{r}_j\|^2}{2\sigma^2}\right) \quad (2.3)$$

- S5. (反復過程)** 近接半径 σ を小さくし、更新ステップ数 $t \leftarrow t + 1$ として、step S2へ戻る。

2.3 密度推定

本研究では、SOMのトポロジーマップにおける事象の発生密度を推定するために密度推定を用いる。単純なヒストグラムでは適切な間隔を設定する必要があるが、密度推定では間隔を決める必要がない。また、燃料電池の損傷評価のように事前知識がないデータの分布を得るには、ノンパラメトリックな方法が適している。以上から、本研究ではカーネル密度推定(Kernel Density Estimation:KDE)¹⁵⁾を用いる。

任意の点 $\mathbf{x} \in \mathcal{R}^v$ 上のKDEによる確率密度は、次式で与えられる。

$$P_{\text{KDE}}(\mathbf{x}) = \frac{1}{Nb^v} \sum_{i=1}^N K\left(\frac{\mathbf{x} - \mathbf{x}_i}{b}\right) \quad (2.4)$$

ここで、 b はバンド幅、 N はデータ数、 v はデータの次元数である。 b の値が大きくなるに従って、得られる分布がより滑らかになる。本研究では、カーネル関数 $^*1 K(\mathbf{x})$ は次式で与えられるガウシアンカーネルを用いた。

$$K(\mathbf{x}) = \frac{1}{2\pi^{-v/2}} \exp\left(-\frac{\|\mathbf{x}\|^2}{2}\right) \quad (2.5)$$

2.4 キーグラフ

元来キーグラフ⁵⁾は、文書データからキーワードを抽出するために提案された手法であるが、現在では共起事象の抽出手法として拡張されている。任意の記号系列 \mathcal{D} をバスケット“[]”に分割し、 $\mathcal{D} = [e_1, \dots, e_i][e_{i+1}, \dots, e_j] \dots [e_k, \dots, e_l]$ ($i < j < k < l$)とする。ここで、バスケットとは事象系列を意味のある事象ごとに分割した集合である(たとえば、文書データでは1文)。キーグラフの生成は、以下の2ステップで行われる。

- K1. (局所的に影響し合う事象の抽出)** まず、記号系列 \mathcal{D} から頻度の高い事象を抽出し、頂点集合 \mathcal{V}_l とする。頂点集合 \mathcal{V}_l の中で共起度が高い事象対を連結し、辺集合 \mathcal{E}_l とする。以上から、基礎的要因を表す局所的に影響し合う事象のグラフ $\mathcal{G}_l(\mathcal{V}_l, \mathcal{E}_l)$ を得る。本研究では、共起度の算出にはバスケットにに含まれる事象のJaccard係数を用いた。

*1 カーネルSOMにおけるカーネル関数はデータ点間の距離を表す関数であるが、密度推定においてはデータ点の確率密度を表す関数である。

K2. (大局的に影響し合う事象の抽出) s をバスケット, $|e|_s$ をバスケット s に含まれる事象 e の発生回数, g を G_l で連結された頂点の集合, $|g|_s$ をバスケット s に含まれる事象 $e' \in g$ の発生回数とする. 事象群 $g \in \mathcal{V}_l$ が発生したときに, 事象 $e \in \mathcal{D}$ が起こる条件付き確率 $global(e, g)$ を次式で定義する.

$$global(e, g) = \frac{\sum_{s \in \mathcal{D}} |e|_s |g - e|_s}{\sum_{s \in \mathcal{D}} \sum_{e' (\neq e) \in g} |e'|_s |e|_s} \quad (2.6)$$

ただし, $|g - e|_s$ は以下のように定義する.

$$|g - e|_s = \begin{cases} |g|_s - |e|_s & e \in g \\ |g|_s & e \notin g \end{cases} \quad (2.7)$$

まず, 全ての g に対する $global(e, g)$ の総和で定義される $key(e)$ 値が高い事象を抽出し, 頂点集合 \mathcal{V}_g とする. そして, $global(e, g)$ の値が上位となる事象 e と g の組み合わせに対して, Jaccard 係数により共起度が高い事象 e と $e' \in g$ の事象対を連結し, 辺集合 \mathcal{E}_g とする. 以上から, 大局的に影響し合う事象のグラフ $G_g(\mathcal{V}_g, \mathcal{E}_g)$ を得る. さらに, 条件付き確率の式 (2.6) から, これらの事象は頻度は高くはないが重要な事象の候補となる. そして, グラフ G_l とグラフ G_g を併合することで全体の共起グラフ G を得る.

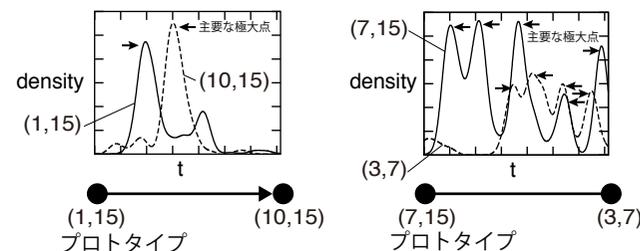
なお, 本研究では, キーグラフの出力に Polaris^{*2}を用いた.

2.5 E³ 法のアルゴリズム

E³ 法は, 以下の 5 ステップで行われる.

- E1. (符号化)** SOM を用いて, 事象系列 $\mathcal{D} = X_1, X_2, \dots, X_T$ の全ての事象に対する BMU を得る. すなわち, 各事象に最も近い参照ニューロンの座標 $(x_1, y_1), \dots, (x_T, y_T)$ と表される.
- E2. (バスケット分割)** \mathcal{D} をバスケット $s = [X_t, \dots, X_{t+1}]$ に分割する. キーグラフをキーワード抽出として用いるときは, 1 文を単語の集合としてみなし, 1 つのバスケットとして扱っている. バスケットへの分割方法は適用するデータに依存しており, AE 事象系列への適用方法は 3.3.2 項で説明する.
- E3. (共起グラフ生成)** \mathcal{D} をキーグラフに適用することで, グラフ G を得る.
- E4. (事象遷移抽出)** 時空間のデータ $(x_t, y_t, t) : t = 1, \dots, T$, すなわち, SOM のトポロ

*2 <http://www.chokkan.org/software/polaris/>



(a) 主要な極大点に順序が存在する例 (b) 主要な極大点に順序が存在しない例

図 3 密度分布の主要な極大点の順序およびキーグラフ上で BMU 間に事象遷移の矢印を加える例
 Fig. 3 A transition arrow is added between the BMUs in a KeyGraph if there exist an order of major peaks of the density distributions pair.

ジーマップから得られる BMU と時間のデータについて, 事象の生起密度を推定する. もし, 2 つのプロトタイプの密度分布について, 主要な極大点の時間順序が存在すれば (図 3), キーグラフ G 上で BMU 間に矢印を加える.

- E5. (復号化)** ステップ E4 で事象遷移としてキーグラフ G に加えられた辺と頂点は, 参照ベクトルの座標により SOM のトポロジーマップ上にマッピングする.

ここで, SOM から意味の解釈が可能であるトポロジーマップが得られることを前提としている. さらに, ステップ E4 は手動で行われているが, キーグラフから抽出できる共起事象の数が少ないため, 大きな負担にはならない.

3. 燃料電池への適用

3.1 燃料電池の課題

燃料電池は低公害性, 静音性, 高い発電効率をもつ発電機として注目されている. その中でも固体酸化燃料電池 (SOFC) は, ガスタービンと併用することで 70% 近い発電効率を有し注目を集めている発電機である. しかしながら, SOFC の実用化において, SOFC 稼働時の損傷評価手法の開発が大きな課題となっている¹⁶⁾⁻¹⁸⁾.

SOFC は非常に厳しい環境下 (高温環境・酸化還元環境) で稼働しているため, 長時間稼働すると, き裂・はく離・変形などの物理的損傷が生じる. 特に, はく離が起こると化学反応領域が減少し, 燃料電池の起電力低下につながる. 従来は, 電気化学的手法により劣化の

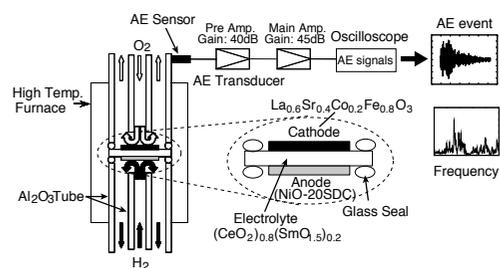


図4 SOFC 損傷試験装置

Fig. 4 SOFC damage test apparatus.

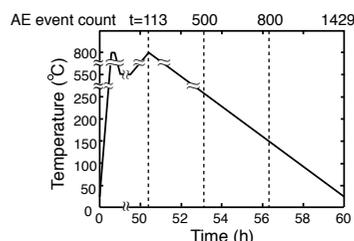


図5 温度履歴および AE 事象の検出カウント
Fig. 5 Controlled temperature change and observed AE event count.

程度が評価されていたが、近年では、非破壊検査法であるアコースティック・エミッション (AE) 法によって物理的損傷の計測に成功している¹⁹⁾。AE 法は、破壊や損傷の際に生じる微弱な弾性波 (すなわち、振動、超音波も含めた音波) を計測している。AE 波形は、破壊モード (せん断か開口)、材料の特性、損傷のエネルギーなどの要因に大きく依存している²⁰⁾。

我々は、これまでに SOM やネットワーク分析を用いて AE 事象に対応する SOFC の損傷タイプの特徴および大局的な損傷過程の把握が可能であることを示した^{21),22)}。また、これらの先行研究から Sornette³⁾ が述べていた損傷フェーズの急激な遷移が確認できた。本研究では、AE 事象系列から SOFC の損傷メカニズムを解明することが目標である。ここで、SOFC の損傷評価に限らず AE 事象に関する研究のほとんどは、AE 事象をクラスに分類する研究であり^{23)–26)}、AE 事象の共起分析を扱った研究は行われていない。

3.2 燃料電池の損傷評価試験

SOFC 模擬稼働試験における実際の装置の概略図を図 4 に示す。まず、この試験ではガラスシールを融解させるために 800°C まで上昇させた。その後、徐々に室温まで降下させた (図 5)。AE の計測は広帯域圧電型トランスデューサ³⁾を用いている。このトランスデューサは電気炉の外側にある Al₂O₃ 管上部に接触しており、サンプリングレートは 1MHz で、観測可能周波数は最大 500kHz である。計測時間 60 時間の間にバースト抽出法^{21),27)}により 1429 個の AE 事象が得られた。

ここで、この損傷評価試験では意図的に温度を下げることで損傷を起こしたことに注意しておく。そのため、この実験から得られた知識は SOFC の実用化に直接はつながらず、し

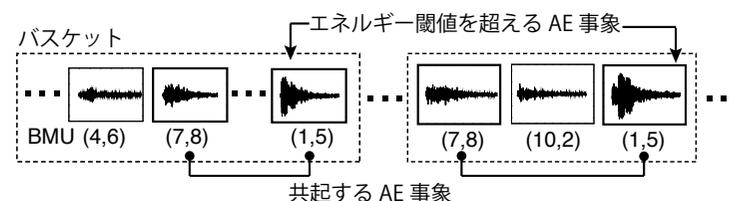


図6 AE 事象系列のバスケットへの分割

Fig. 6 Partition of an AE event sequence into baskets.

かし、提案手法の有用性を示すには十分な実験である。

3.3 E³ 法の AE 事象系列への適用

3.3.1 カーネル関数

Kullback-Leibler (KL) 情報量は確率分布間の距離として広く用いられており、本研究では、AE 事象間の周波数スペクトルの類似度として用いる。同様に KL 情報量を用いた研究として、Moreno ら²⁸⁾ は画像スペクトルの分類のために KL 情報量を SVM に導入している。

離散化された v 点の周波数スペクトルを $\mathbf{x}_i = (x_{i,1}, \dots, x_{i,v})$ とすると、KL カーネル関数は次式で定義される。

$$K_{KL}(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\alpha JS(\mathbf{x}_i, \mathbf{x}_j)) \quad (3.1)$$

$$JS(\mathbf{x}_i, \mathbf{x}_j) = KL(\mathbf{x}_i, \mathbf{x}_j) + KL(\mathbf{x}_j, \mathbf{x}_i) \\ = \sum_{k=1}^v \left\{ x_{i,k} \log \frac{x_{i,k}}{x_{j,k}} + x_{j,k} \log \frac{x_{j,k}}{x_{i,k}} \right\} \quad (3.2)$$

ここで、 $JS(\mathbf{x}_i, \mathbf{x}_j)$ は KL 情報量を対称化した Jensen-Shanon 情報量、 $\alpha (> 0)$ はスケールパラメータである。ただし、KL 情報量は確率分布に対する量であるため $\sum_k x_{i,k} = 1$ に正規化する必要がある。

我々は、木片のき裂音など損傷による音波データに対して、KL カーネルを導入した SOM は、一般的に用いられるガウシアンカーネルやシグモイドカーネルを用いた SOM、また通常 SOM と比較して高い分類性能を示すことを確認している²⁹⁾。よって、SOFC の AE 事象に対しても高い分類性能が期待できる。

3.3.2 AE 事象系列のバスケット分割

複合材である SOFC は、内部で相互作用を及ぼし合っており、その相互作用により潜在的にストレスが蓄積されていく。そこで、大きなエネルギーをもつ損傷が起こると蓄積されて

*3 PAC UT-1000, URL: <http://www.pacndt.com>

いたストレスが解放されることで、内部の相互作用の状態が変化し、損傷過程が遷移すると考えられる。本研究では、大澤が行った地震の危険断層予測¹²⁾を参考にして、一定閾値以上のエネルギーをもつ損傷が起こるまでを一連の損傷過程であると仮定し、AE 事象系列をバスケットに分割し、キーグラフに適用した(図 6)。

まず、各 AE 事象のエネルギー E_1, E_2, \dots, E_T を $E_i = \sum_j x_{i,j}^2$ により算出する。次に AE 事象系列を以下の条件に従ってバスケット $s = [X_i, \dots, X_{i+l}]$ に分割する。

$$E_{t+i} \leq E_\sigma \text{ and } E_{t+i} > E_\sigma \quad (i = 0, \dots, l-1) \quad (3.3)$$

ここで、 E_σ はエネルギー閾値である。また、AE 事象系列は、たとえば、 $D = [\dots(4, 6), (7, 8), \dots, (1, 5)] \dots [(7, 8), (10, 2), (1, 5)] \dots$ のように表記される(図 6)。

3.4 トポロジーマップを用いた損傷評価

SOM のノードは 15×15 の正方格子を用いた。ここで、データ分布を把握するために十分なノード数があれば、ノード数は結果に影響を与えない。KL カーネルのスケールパラメータは従来研究でクラスタ間距離が最も現れていた $\alpha = 0.95$ とした。SOM のトポロジーマップにおける各時間ごとの発生密度分布の変化を図 7 に示す。10 分割のクロスバリデーションの結果から、KDE におけるバンド幅は $b = 0.34$ とした。

AE 事象の発生頻度が高い領域は、図 7 のように動的に変化していく。発生頻度が高い領域の推移と各領域の AE 波形および周波数スペクトルの代表例を図 8 に示す。また、燃料電池と破壊力学の専門家である 2 人の共著者の助言により、トポロジーマップを用いて AE 事象の物理的な意味の解釈を行った。このとき、トポロジーマップだけではなく、AE 波形・周波数スペクトル・頻出領域における温度履歴も参考にした。このようにして、損傷タイプとフェーズの遷移を推定し、以下のようにまとめた。

- (A) 図 8 の領域 (A) の AE 事象は図 7 の昇温期間に発生している。さらに、発生している AE 事象は一箇所に集まっており、エネルギーも比較的小さく大きな損傷も起こっていないため、昇温期間に生じる部材の軋みであると推定される。
- (B) この領域に含まれている AE 事象は、非常に大きな波形で高周波も含まれている。また、降温が開始した期間に頻出している。つまり、領域 (B) で生じている AE 事象は、材料の収縮に伴う初期欠陥や不均一性による小さな割れが進展したと推定される。
- (C) 領域 (B) の AE 事象の周波数スペクトルに類似した連続型の AE 事象が見られる。そのため、領域 (B) の進展に伴う部材の軋みと推定される。
- (D) この領域の AE 事象は高周波をもつ AE 事象であり、SOFC の部材で比較的固い部材である電解質のき裂が生じた可能性が高い。

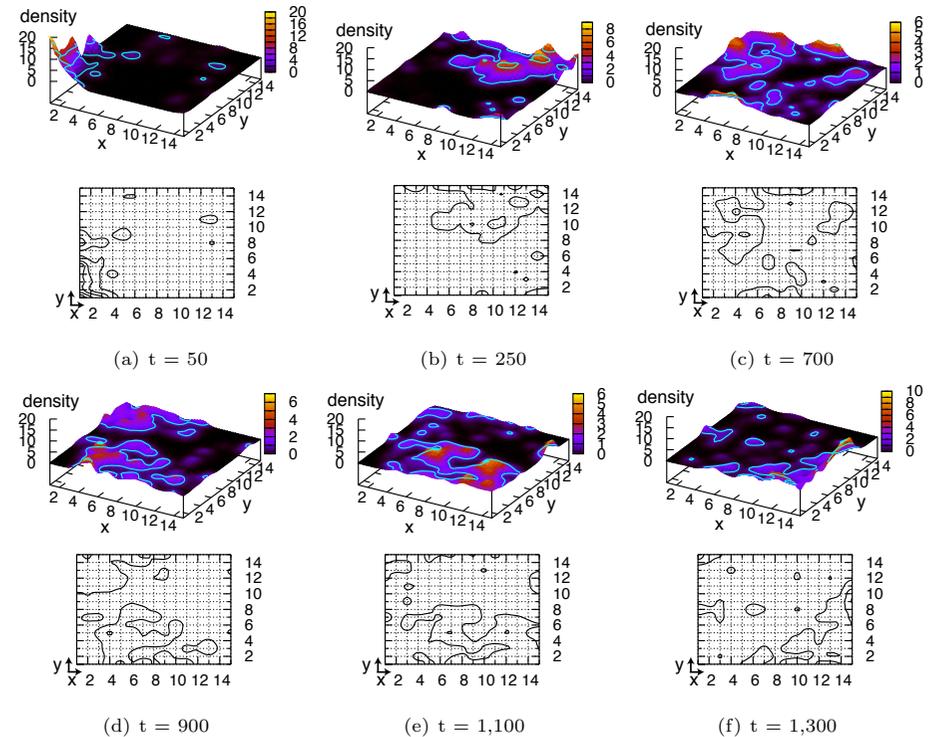


図 7 カーネル SOM と密度推定を用いた SOFC の損傷遷移 (上部:三次元表示, 下部:等高線表示)
Fig.7 Damage transition of SOFC by the kernel SOM with density estimation. (upper: 3D representation, lower: 2D contour representation)

- (E) ガラスシールが凝固しはじめる 100°C 付近で、領域 (E) の AE 事象が頻出している。さらに、AE 事象の頻出領域は左から右に遷移しており(図 7(d) から 7(f)), 周波数スペクトルも徐々に変化している。SOFC の部材では、ガラスシールのみが温度に依存して状態が変化する部材であるため、領域 (E) はガラスシールの損傷と推定される。
- (F) 発生する AE 事象は低周波かつ突発型であり、電極材のき裂を伴うはく離であると推定される。

3.5 E^3 法による機械的影響の推定

キーグラフの出力結果を図 10 に示す。本論文ではエネルギー閾値 $E_\sigma = 1,500$ として E^3

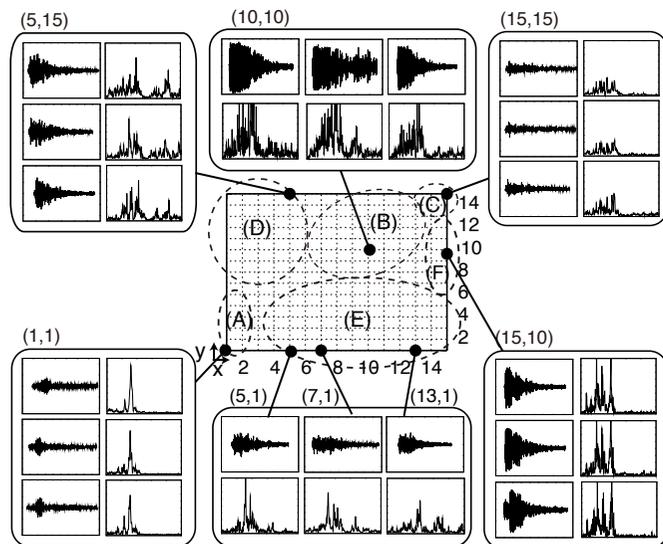


図 8 カーネル SOM のトポロジーマップ上における AE 事象頻出領域と各領域の AE 事象サンプル
Fig. 8 Frequent occurring regions and sample AE events on the topology map by the kernel SOM.

表 1 カーネル SOM と密度分布により推定された損傷タイプ

Table 1 Inferred damage type from the kernel SOM with the density distribution.

領域	頻出期間	損傷タイプ
(A)	t = 1 - 180	昇温期間に生じる構成部材の軋み
(B)	t = 100 - 400	初期欠陥や不均一性による小さな割れの進展
(C)	t = 220 - 600	領域 (B) の進展に伴う構成部材の軋み
(D)	t = 550 - 1,100	電解質のき裂
(E)	t = 900 - 1,350	ガラスシールの損傷
(F)	t = 1,000 - 1,429	電極材のき裂を伴うはく離

法を適用した。次に、キーグラフから得られる共起グラフの見方について説明する。キーグラフにおいて、黒丸は局所的に影響し合っている事象、つまり、基礎的要因の事象である。赤丸は大局的に影響し合っている事象である。また、実線は点線よりも共起度が高いことを表す。プロトタイプ間の発生密度の変化により事象遷移が抽出され、キーグラフにおいてプロトタイプ間の矢印として表される (図 9)。また、遷移の終端事象は、二重丸で表す。

抽出された事象遷移をトポロジーマップにマッピングした結果を図 11 に示す。図 11(a)

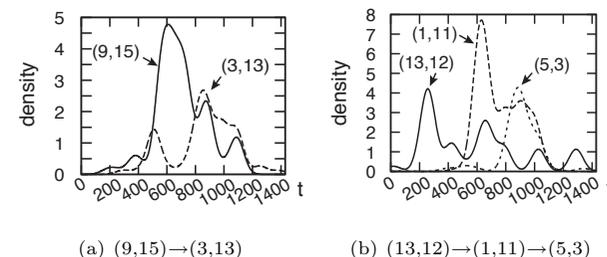


図 9 プロトタイプの発生密度変化の主要な極大点に時間順序が存在するときの遷移
Fig. 9 An order of major peaks on occurrence density change of the prototypes.

領域 (B) から領域 (C) への遷移を表しており、これは、初期欠陥による小さな割れの進展が電解質に影響を及ぼしていることを示している。一方、図 11(b) は領域 (D) から領域 (B) への遷移で、図 11(a) の遷移と反対向きである。つまり、初期欠陥の進展と電解質には相互作用が存在すると推定される。そして、図 11(c) は領域 (D) を介して領域 (B) から領域 (E) の遷移を表している。図 11(a) の遷移と同様に、初期欠陥の進展から電解質のき裂に遷移し、その電解質のき裂の影響を受けてガラスシールの損傷が進行していると考えられる。さらに、図 11(c) と図 11(f) の遷移から、電解質のき裂 (領域 (D)) と電極材のはく離 (領域 (F)) の影響により領域 (E) のガラスシールの損傷が生じていると推定される。一方、領域 (A) と領域 (C) は他の領域の損傷に全く影響を与えないことがわかる。また、ガラスシールの損傷は他の損傷に影響を与えず、ガラスシールのみが他の部材の損傷の影響を受けていることがわかる。さらに電解質と電極材は燃料電池の構造上つながっているが、電解質と電極材の損傷に相互作用が抽出されないという、燃料電池の専門家の観点からも興味深い結果が得られた。

条件付き確率により抽出された赤丸のプロトタイプに含まれる事象について説明する。これらの事象は単なる数え上げでは抽出することができない事象である。そのため、図 11(a) から図 11(e) において、矢印の始点はほとんど基礎的要因である。この結果から、比較的稀ではあるが事象の遷移にとって共起する重要な事象の抽出が可能であることを示している。

4. ま と め

我々は、非記号事象系列から比較的稀であるが過程が遷移するときに共起する事象を抽出するための Essential Event Extractor(E³) 法を提案した。自己組織化マップ (SOM) を非記号事象を符号化するためのベクトル量子化 (VQ) として、また共起グラフとしてキーグラ

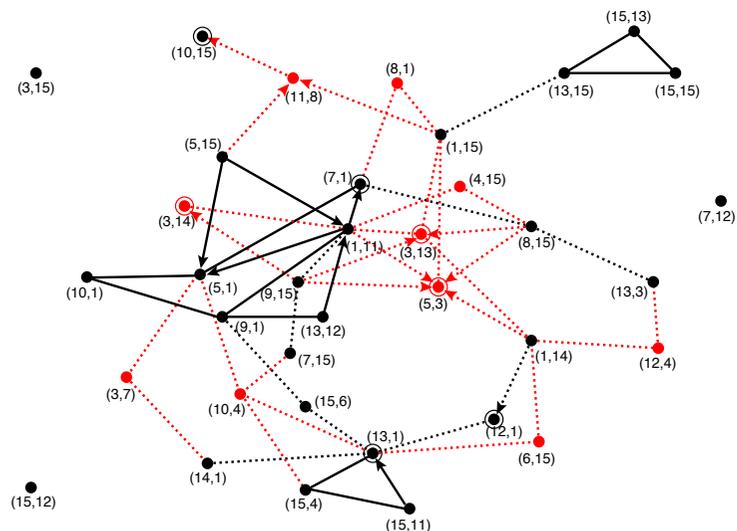


図 10 キーグラフおよび事象遷移の出力結果 (黒丸は高頻度な事象, 赤丸は稀であるが重要な事象を表している。ノード番号は、カーネル SOM 上のプロトタイプ座標である。)

Fig.10 Output of KeyGraph with event transition. Black nodes denote high frequent fundamental events and red nodes denote rare essential events. Node labels are the coordinates of prototypes by the kernel SOM.

フを用いた、SOM のトポロジーマップにおける密度推定を併用することで、共起する事象系列を得ることができる。

本研究では、燃料電池の損傷試験から得られるアコースティック・エミッション (AE) 事象系列に (E³) 法を適用した。その結果から、燃料電池の損傷フェーズが遷移しているときに起こる、潜在的な力の表れである部材間の機械的影響を推定することができた。

謝 辞

本研究は、科学研究費補助金若手研究 (B)(21700165) の支援を受けて行われた。

参 考 文 献

1) Agrawal, R. and Srikant, R.: Fast Algorithms for Mining Association Rules, *Proc. of the 20th Int'l Conference on Very Large Databases*, pp.487-499 (1994).

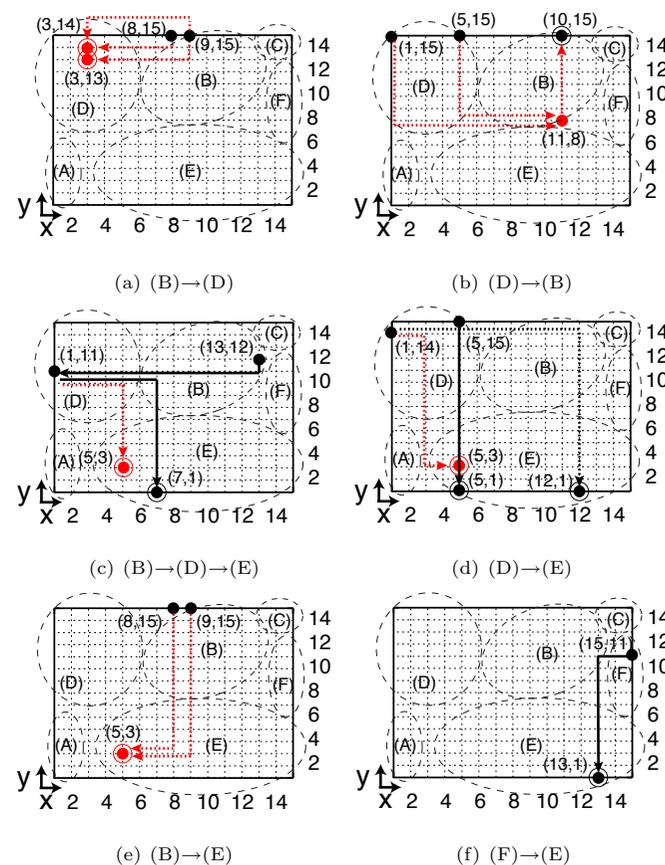


図 11 キーグラフにより得られた共起する遷移事象のマッピング結果
 Fig.11 Mapped co-occurring event transitions from KeyGraph onto the topology map.

2) Han, J., Kamber, M. and Pei, J.: *Data Mining, Second Edition: Concepts and Techniques*, Morgan Kaufmann (2006).
 3) Sornette, D.: Predictability of Catastrophic Events: Material Rupture, Earthquakes, Turbulence, Financial Crashes, and Human Birth, *Proc. the National Academy of Sciences of the United States of America*, Vol.99, No.suppl. 1, pp.2522-2529 (2002).

- 4) Weiss, G.M. and Hirsh, H.: Learning to Predict Rare Events in Event Sequences, *Proc. of the 4th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp.359–363 (1998).
- 5) 大澤幸生, Benson, N.E., 谷内田正彦: KeyGraph:語の共起グラフの分割・統合によるキーワード抽出, 電子情報通信学会論文誌, Vol.J82-D-I, No.2, pp.12–18 (1999).
- 6) Vilalta, R. and Ma, S.: Predicting Rare Events In Temporal Domains, *Proc. of the 2002 IEEE International Conference on Data Mining (ICDM)*, pp.474–481 (2002).
- 7) Phan, X.-H., Nguyen, L.-M., Ho, T.-B. and Horiguchi, S.: Improving Discriminative Sequential Learning with Rare-but-important Associations, *Proc. of the 11th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp.304–313 (2005).
- 8) Agarwal, D., Broder, A., Chakrabarti, D., Diklic, D., Josifovski, V. and Sayyadian, M.: Estimating Rates of Rare Events at Multiple Resolutions, *Proc. of the 13th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp.16–25 (2007).
- 9) Xu, R. and Wunsch, D.C.: *CLUSTERING*, IEEE Press Series on Computational Intelligence (2008).
- 10) Kohonen, T.: *Self-Organizing Maps*, Springer-Verlag (1995).
- 11) Tukey, J.W.: *Exploratory Data Analysis*, Addison-Wesley (1977).
- 12) Ohsawa, Y.: KeyGraph as Risk Explorer from Earthquake Sequence, *Journal of Contingencies and Crisis Management*, Vol.10, No.3, pp.119–128 (2002).
- 13) Oja, M., Kaski, S. and Kohonen, T.: Bibliography of Self-Organizing Map (SOM) Papers: 1998-2001 Addendum, *Neural Computing Surveys*, Vol.3, pp.1–156 (2002).
- 14) Boulet, R., Jouve, B., Rossi, F. and Villa, N.: Batch Kernel SOM and Related Laplacian Methods for Social Network Analysis, *Neurocomputing*, Vol.71, pp.1257–1273 (2008).
- 15) Silverman, B.: *Density Estimation for Statistics and Data Analysis*, Chapman & Hall (1986).
- 16) Yasuda, I. and Hishinuma, M.: Lattice expansion of acceptor-doped lanthanum chromites under high-temperature reducing atmospheres, *ELECTRO-CHEMISTRY*, Vol.68, No.6, pp.526–530 (2000).
- 17) Atkinson, R. and Ramos, T. M. G.M.: Chemically-induced stresses in ceramic oxygen ion-conducting membranes, *Journal of Solid State Ionics*, Vol.129, pp.259–269 (2000).
- 18) Krishnamurthy, R. and Sheldon, B.W.: Stresses due to oxygen potential gradients in non-stoichiometric oxides, *Journal of Acta Materialia*, Vol.52, pp.1807–1822 (2004).
- 19) Sato, K., Omura, H., Hashida, T., Yashiro, K., Kawada, T., Mizusaki, J. and Yugami, H.: Tracking the Onset of Damage Mechanism in Ceria-based Solid Oxide Fuel Cells under Simulated Operating Conditions, *Journal of Testing and Evaluation*, Vol.34, No.3, pp.246–250 (2006).
- 20) Miller, R.K., Kill, E. V.K., Moore, P.O. and Hill, E.V.: *Acoustic Emission Testing*, American Society for Nondestructive (2005).
- 21) 福井健一, 赤崎省悟, 佐藤一永, 水崎純一郎, 森山甲一, 栗原聡, 沼尾正行: 固体酸化物燃料電池における損傷過程の可視化, 日本機械学会論文集 A 編, Vol.76, No.762, pp.223–232 (2010).
- 22) Fukui, K., Sato, K., Mizusaki, J., Saito, K., Kimura, M. and Numao, M.: Growth Analysis of Neighbor Network for Evaluation of Damage Progress, *Proc. the 13th Pacific-Asia Conference on Knowledge Discovery and Data Mining (PAKDD'09) (Lecture Notes in Artificial Intelligence 5476)*, pp.933–940 (2009).
- 23) Emamian, V., Kaveh, M., Tewfik, A.H., Shi, Z., Jacobs, L.J. and Jarzynski, J.: Robust Clustering of Acoustic Emission Signals Using Neural Networks and Signal Subspace Projections, *Journal on Applied Signal Processing*, Vol.2003, No.3, pp.276–286 (2003).
- 24) Rippengill, S., Worden, K., Holford, K. and Pullin, R.: Automatic Classification of Acoustic Emission Patterns, *Journal for Experimental Mechanics: Strain*, Vol.39, No.1, pp.31–41 (2003).
- 25) Godin, N., Huguet, S. and Gaertner, R.: Influence of hydrolytic ageing on the acoustic emission signatures of damage mechanisms occurring during tensile tests on a polyester composite: Application of a Kohonen's map, *Composite Structures*, Vol.72, No.1, pp.79–85 (2006).
- 26) Omkar, S. and U, R.K.: Rule Extraction for classification of acoustic emission signals using Ant Colony Optimisation, *Engineering Applications of Artificial Intelligence*, Vol.21, pp.1381–1388 (2008).
- 27) Kleinberg, J.: Bursty and hierarchical structure in streams, *Proc. the 8th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD'02)*, pp.1–25 (2002).
- 28) Moreno, P.J., Ho, P.P. and Vasconcelos, N.: A Kullback-Leibler Divergence Based Kernel for SVM Classification in Multimedia Applications, *In Advances in Neural Information Processing Systems 16* (2003).
- 29) 福井健一, 赤崎省悟, 佐藤一永, 水崎純一郎, 森山甲一, 栗原聡, 沼尾正行: カーネル SOM による損傷評価のための隣接性を考慮した分類性能評価, 情報処理学会論文誌:数理モデル化と応用, Vol.3, No.1, pp.36–48 (2010).