

キーグラフとSOMを用いた稀な重要事象抽出による 燃料電池の損傷評価

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、潜在的な相互作用により稀に急激な事象遷移を起こすことがある。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 (E^3) 法を提案する。 E^3 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 のトポロジマップから得られ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抽出する。本論文では、燃料電池の損傷試験で観測される Acoustic Emission (AE) 事象系列に対して E^3 法を適用し、燃料電池の損傷メカニズムの解明に向けた、有用な損傷事象系列を得た。

Damage Evaluation on Fuel Cells by Extraction of Essential Events Using KeyGraph and SOM

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 (E^3) scheme to extract relatively rare but co-occurring event sequences in event transitions. In E^3 , 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 E^3 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、稀に急激な変化を起こすことがあり、その変化はそれまでの進展に比べてきわ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、潜在的な相互作用の表れである。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、順序を持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が多数存在する。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重要である。

本論文では、順序を持った非記号の事象を対象とした Essential Event Extractor (E^3) 法を提案する。本手法は、まず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 の特長は、データを意味を持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。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、VQ として自己組織化マップ (Self-Organizing Map: SOM)¹⁰⁾ により事象

†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

を記号化し、その後、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、Ohsawa らはキーグラフを用いて危険断層の予測を行っている^{12),13)}。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、順序を持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、固体酸化物燃料電池 (Solid Oxide Fuel Cell: SOFC) の損傷試験で得られた AE (Acoustic Emission) 事象系列に対して、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

本論文で扱う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 e_i は、他の事象との (非) 類似度、すなわち、 $\forall j d(e_i, e_j)$ によって特徴付けられる。

定義 3 (事象系列). 事象系列は、 $D = e_1, \dots, e_T$ で定められる順序を持つ事象集合である。ここで、 e_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したりすることができる (図 2)。さらに、SOM により全データ分布をプロトタイプ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頻度・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 のトポロジマップから得られる発生確率密度分布の変化と近傍データ集合に基づいて、ユーザは事象のタイプや大局的な発生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することで、事象遷移の系列に分割することができる。そして、発生フェーズが遷移するときに共起する事象系列を解釈可能な




図 1 E³ 法の枠組み

Fig. 1 Overview of the essential event extractor (E³).

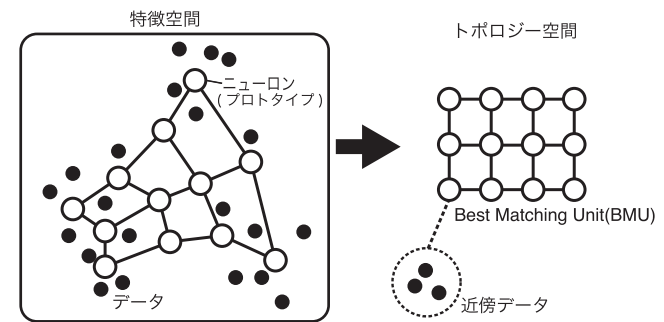


図 2 SOM の概念図

Fig. 2 A conceptual diagram of the SOM.

低次元のトポロジマップ上に復号化することで、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¹⁴⁾。従来研究で用いられていたカーネル SOM¹⁵⁾ は、高次元へ写像す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。一般に高次元に写像することでデータの表現力が向上し、データの特性に適した写像を行うことで分類やクラスタリングの精度向上が期待できる。そのような対象に適した写像関数を求めることは難しいが、対象の特性に合わせた距離定義を与える方がやさしい。カーネル法は、写像後の空間での距離を定義するカーネル関数を与えることで、写像関数が直接求められなくても写像後の空間で分類やクラスタ

リングを可能にする方法である．本論文が応用として対象とする AE 事象に適したカーネル関数の詳細については，3.3.1 項で述べる．

具体的には， v 次元の入力データ空間 \mathcal{R}^v を高次元特徴空間 \mathcal{H} へ写像する関数を $\phi: \mathcal{R}^v \rightarrow \mathcal{H}$ とすると，点 $\mathbf{x}_i, \mathbf{x}_j \in \mathcal{R}^v$ に対するカーネル関数は次式により定義される．

$$K(\mathbf{x}_i, \mathbf{x}_j) \equiv \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}_j) \rangle \quad (1)$$

ここで， \langle, \rangle は内積を表している．式 (1) が対称かつ半正定値であるとき，写像関数 ϕ の存在が示されている (Mercer の定理)¹⁶⁾．

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 は $\mathbf{m}_j = (m_{j,1}, \dots, m_{j,v})$ ，ニューロンの位置座標 \mathbf{r}_j は $\mathbf{r}_j = (\xi_j, \eta_j): j = 1, \dots, M$ とする．ニューロンの数とトポロジの配置は事前に設定されており，本研究では二次元の正方格子上に配置する．この低次元空間はトポロジ空間と呼ばれ，データ点の分布状況がこの空間に視覚化される．

カーネル SOM は次式に示す目的関数を最小化するように，写像後の空間で参照ベクトル $\phi(\mathbf{m}_j)$ を更新することで学習が行われる．

$$L_{\text{ksom}} = \sum_{i=1}^M \sum_{\mathbf{x}_n \in C_i} \sum_{j=1}^M h_{i,j} \|\phi(\mathbf{x}_n) - \phi(\mathbf{m}_j)\|^2 \quad (2)$$

ここで， C_i は第 i ニューロンが最適ユニット (Best Matching Unit: BMU) (勝者ニューロンとも呼ばれる) となるデータ点の集合を表す．データ点 \mathbf{x}_n に対する BMU の番号を $c(n)$ とすると， $C_i = \{\mathbf{x}_n | c(n) = i\}$ と表される．また， $h_{i,j}$ はトポロジ空間上に定義される近傍関数であり，次式のガウス関数がよく用いられる．

$$h_{i,j} = \exp\left(-\frac{\|\mathbf{r}_i - \mathbf{r}_j\|^2}{2\sigma^2}\right) \quad (3)$$

ここで， σ は近傍の影響を表すパラメータ (近傍半径) である．式 (2) は量子化誤差の最小化と同時に，近傍関数によってプロトタイプ間の類似関係を保存すること意味している．

また，通常のバッチ型 SOM¹⁰⁾ の参照ベクトル更新式における \mathbf{x} ， \mathbf{m} を写像後の $\phi(\mathbf{x})$ ， $\phi(\mathbf{m})$ に置き換えると次式となる．

$$\phi(\mathbf{m}_i^{(t+1)}) := \gamma \sum_n h_{c(n),i} \phi(\mathbf{x}_n) \quad (4)$$

ここで， t は更新ステップ数， γ は正規化項 $\gamma = 1 / \sum_n h_{c(n),i}$ である．

以下にバッチ型カーネル SOM のアルゴリズムを示す．ここで，カーネル SOM では，特徴空間 \mathcal{H} において参照ベクトル $\phi(\mathbf{m}_i^{(t)})$ は求まらないので， $\phi(\mathbf{m}_i^{(t)})$ の代わりに $\phi(\mathbf{m}_i^{(t)})$ と全入力データ $\phi(\mathbf{x}_n)$ との非類似度 $\{d_{i,n}^{(t)}: n = 1, \dots, N\}$ を用いて，間接的に参照ベクトルを定義していることに注意しておく．

S1. (初期設定) 全参照ベクトルについて，参照ベクトルと入力データ間の非類似度 $\{d_{i,n}^{(t)}: n = 1, \dots, N\}$ をランダムに与える．また，更新ステップ数を $t = 1$ として初期化しておく．

S2. (BMU 探索) 最適ユニット $\{c(1), \dots, c(N)\}$ を全入力データについて探索する．

$$c(n) = \arg \min_{i=1, \dots, M} d_{i,n}^{(t)} \quad (5)$$

S3. (収束条件) 勝者ニューロン $\{c(1), \dots, c(N)\}$ が前回のステップから変化しない，もしくは更新ステップ回数 t が t_{max} に達した時点で終了する．

S4. (ニューロンの更新) 全参照ベクトル $\{\phi(\mathbf{m}_1^{(t)}), \dots, \phi(\mathbf{m}_M^{(t)})\}$ について，全入力データに対する非類似度 $\{d_{i,n}^{(t)}: n = 1, \dots, N\}$ を次式により更新する．

$$\begin{aligned} d_{i,n}^{(t+1)} &\equiv \|\phi(\mathbf{x}_n) - \phi(\mathbf{m}_i^{(t+1)})\|^2 \\ &= K(\mathbf{x}_n, \mathbf{x}_n) - 2\gamma \sum_j h_{c(j),i} K(\mathbf{x}_n, \mathbf{x}_j) \\ &\quad + \gamma^2 \sum_k \sum_l h_{c(k),i} h_{c(l),i} K(\mathbf{x}_k, \mathbf{x}_l) \end{aligned} \quad (6)$$

S5. (反復過程) 近接半径 σ を小さくし，更新ステップ数 $t \rightarrow t + 1$ 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による表示では，事象数をカウントするための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)¹⁷⁾ 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．

$$P_{\text{KDE}}(\mathbf{x}) = \frac{1}{Nbv} \sum_{i=1}^N K\left(\frac{\mathbf{x} - \mathbf{x}_i}{b}\right) \quad (7)$$

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} $K(x)$ は次式で与えられるガウス関数を用いた。

$$K(x) = \frac{1}{2\pi^{-v/2}} \exp\left(-\frac{\|\mathbf{x}\|^2}{2}\right) \quad (8)$$

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、 $\mathcal{D} = [e_1, \dots, e_i][e_{i+1}, \dots, e_j] \dots [e_k, \dots, e_T]$ ($i < j < k < T$) 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. (高頻度・高共起度の島の抽出) 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}_1 とする。頂点集合 \mathcal{V}_1 の中で共起度が高い事象対を連結し、辺集合 \mathcal{E}_1 とする。以上から、基礎的要因を表す事象のグラフ $\mathcal{G}_1(\mathcal{V}_1, \mathcal{E}_1)$ 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。この基礎的要因を表す高頻度・高共起度のグラフは島と呼ばれる。

K2. (島と島を結ぶ橋の抽出) 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 \mathcal{G}_1 で連結された頂点の集合（島を構成する事象）、 $|g|_s$ 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。島を構成する事象群 $g \subset \mathcal{V}_1$ 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。

$$global(e, g) = \frac{\sum_{s \in \mathcal{D}} |e|_s |g - e|_s}{\sum_{s \in \mathcal{D}} \sum_{e' (\neq e) \in g} |e'|_s |e|_s} \quad (9)$$

ただし、 $|g - e|_s$ は以下のように定義する。

$$|g - e|_s = \begin{cases} |g|_s - |e|_s & e \in g \\ |g|_s & e \notin g \end{cases} \quad (10)$$

まず、すべての 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 の組合せに対して、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、グラフ $\mathcal{G}_2(\mathcal{V}_2, \mathcal{E}_2)$ を得る。条件付き確率の式 (9) 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 \mathcal{G}_1 とグラフ \mathcal{G}_2 を併合することで全体の共起グラフ \mathcal{G} を得る。ここで、島を結ぶエッジは橋と呼ばれる。

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 $\mathcal{D} = e_1, e_2, \dots, e_T$ のすべての事象に対する 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 $(\xi_{c(1)}, \eta_{c(1)}), \dots, (\xi_{c(T)}, \eta_{c(T)})$ を得る。
- E2.** (バスケット分割) \mathcal{D} をバスケット $s = [e_t, \dots, e_{t+i}]$ の集合に分割する。キーグラフをキーワード抽出として用いるときは、1 文を単語の集合と見なし、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、共起グラフ \mathcal{G} を得る。
- E4.** (事象遷移抽出) 時空間のデータ $(\xi_{c(t)}, \eta_{c(t)}, t) : t = 1, \dots, T$ 、すなわち、SOM のトポロジ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、キーグラフ \mathcal{G} 上で BMU 間に矢印を加える (図 3)。
- E5.** (復号化) ステップ E4 で事象遷移としてキーグラフ \mathcal{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マップが得られることを前提として

*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。

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

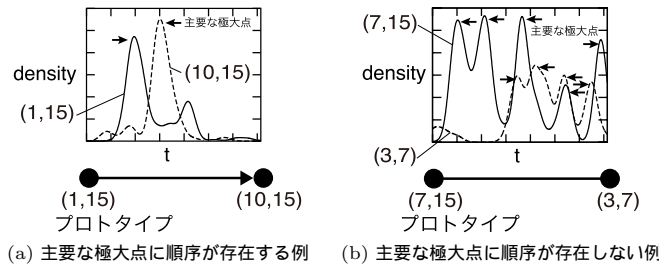


図 3 密度分布の主要な極大点の順序およびキーグラフ上で BMU 間に事象遷移の矢印を加える例
 Fig. 3 A transition arrow is added between the BMUs in a KeyGraph if there exist an order of major peaks of the density distributions pair.

いる。さらに、本論文ではステップ 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、高い発電効率を持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。しかしながら、SOFC の実用化において、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¹⁸⁾⁻²⁰⁾。

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²¹⁾。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²²⁾。

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 の損傷タイプの特定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^{23),24)}。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された。本




図 4 SOFC 損傷試験装置
 Fig. 4 The 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 The controlled temperature change and the observed AE event count.

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²⁵⁾⁻²⁸⁾、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)。また、AE の計測は広帯域圧電型トランスデューサ^{*1}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 管上部に接触している。サンプリングレートは 1 MHz であるため、観測可能周波数は最大 500 kHz である。計測時間 60 時間の間に統計的抽出法^{24),29)}により 1,429 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ない。しかし、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非類似度として用いている。同様に KL 情報量を用いた研究として、Moreno ら³⁰⁾ 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。通常の SOM は、データ点間の非類似度はベクトル要素のユークリッド距離より定義されているが、要素間の独立を仮定しているため、周波数スペクトルの分布が全体的

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

に 1 Hz ずれただけでユークリッド距離は大きくなってしまふ。一方、本研究で用いる KL 情報量は、横方向のずれに対して頑健な距離定義であることが示されている³¹⁾。

離散化された v 点からなる周波数スペクトル(パワースペクトル)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。

$$K_{KL}(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\alpha JS(\mathbf{x}_i, \mathbf{x}_j)) \quad (11)$$

$$\begin{aligned} JS(\mathbf{x}_i, \mathbf{x}_j) &= KL(\mathbf{x}_i, \mathbf{x}_j) + KL(\mathbf{x}_j, \mathbf{x}_i) \\ &= \sum_{k=1}^v \left\{ x_{i,k} \log \frac{x_{i,k}}{x_{j,k}} + x_{j,k} \log \frac{x_{j,k}}{x_{i,k}} \right\} \end{aligned} \quad (12)$$

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、 $\alpha (> 0)$ はスケールリングパラメータである。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。これは損傷の程度(エネルギー)は無視して、破壊モードや材料の特性による周波数スペクトルの違いを測っているといえる。

先行研究において、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³²⁾。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持つ損傷が起こると蓄積されて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、Ohsawa らが行った地震の危険断層予測^{12),13)}と同様に、一定閾値以上のエネルギーを持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、統計的抽出法により切り出された各 AE 事象の計測値(単位: V)を $\mathbf{z}_i = (z_{i,1}, \dots, z_{i,J(i)})$ (持続時間 $J(i)$ はそれぞれの事象により異なる)とすると、各 AE 事象のエネルギー E_1, E_2, \dots, E_T は $E_i = \sum_j z_{i,j}^2$ により算出される。次に AE 事象系列を以下の条件に従ってバスケット $s = [e_t, \dots, e_{t+l}]$ に分割する。

$$E_{t+i} \leq E_\sigma \text{ and } E_{t+l} > E_\sigma \quad (i = 0, \dots, l-1) \quad (13)$$

ここで、 E_σ はエネルギー閾値である。図 6 の例では、AE 事象系列は $\mathcal{D} = [\dots(4,6), (7,8), \dots, (1,5)] \dots [(7,8), (10,2), (1,5)] \dots$ と表記される。




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.

3.4 トポロジ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、最終的に視覚化される結果はほぼスケールした結果になることに注意しておく。本実験データの場合、 12×12 以上でほぼ同じ結果になった。初期参照ベクトルについては、初期値を変えて 100 回実行し、式 (2) の目的関数値が最小になる結果を採用した。近傍関数の初期半径 σ はトポロジマップの 1 辺と同じ長さに設定し、100 ステップごとに半径を 1 ずつ減少させた。また、KL カーネルのスケールリングパラメータは従来研究²⁴⁾ でクラスタ間距離が最も現れていた $\alpha = 0.95$ とした。

本研究では、まずデータ点の分布状況を把握するため、時系列は考慮せず全データを用いてカーネル SOM によりトポロジマップを得る。その後、BMU の発生時系列から各時点におけるトポロジマップ上での発生確率密度分布を推定することで、事象の大局的な発生過程を得る。

SOM のトポロジ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。なお、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。著者のうち 2 名の燃料電池と破壊力学の専門家により、トポロジマップを用いて AE 事象の物理的な意味の解釈を行った。このとき、トポロジマップ上の発生密度分布のみでなく、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て総合的に判断した。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。エネルギーが小さく、マップ上で局在していることから多様性は小さい。これらのことから、昇温期間に生じる部材の軋みであると推定される。




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 the SOFC by the kernel SOM with density estimation (upper: 3D representation, lower: 2D contour representation).

- (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、材料の収縮にともな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*1。そのため、領域 (B) の進展にともなう部材の軋みと推定される。
- (D) この領域の AE 事象は高周波を持つ 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。

*1 本研究では、KL カーネルに適用するために各周波数スペクトルは積分して 1、すなわち離散点のパワーの総和が 1 になるように正規化している。そのため、絶対値によらず同じ周波数帯にピークが存在すれば、KL 情報量の観点では類似した AE 事象と判断される。

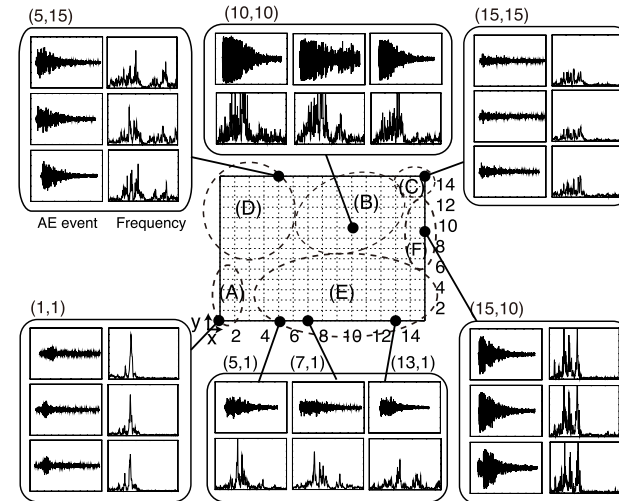


図 8 カーネル SOM のトポロジマップ上における AE 事象頻出領域と各領域の AE 事象サンプル

Fig. 8 Frequent occurring regions and sample AE events on the topology map by the kernel SOM.

- (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、電極材のき裂をともなうはく離であると推定される。

3.5 キーグラフによる共起分析結果

キーグラフの出力結果を図 10 に示す。エネルギー閾値 E_σ は、1,000, 1,250, 1,500, 1,750, 2,000, として E³ 法を適用し、本論文では $E_\sigma = 1,500$ を用いた。エネルギー閾値の影響については、3.7 節で詳しく述べる。図の黒丸は高頻度な基礎的要因である島を構成する事象を表しており、赤丸は島を結ぶ橋を構成する事象を表している。また、実線は点線よりも共起度が高いことを表している。

● 島を構成する事象

高頻度かつ高共起事象の集合である島、つまり黒の実線で連結した集合に着目すると、大きく 3 つに分けられる。中央の大きな島 (1) は、SOM のトポロジマップ図 8 の領域

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 The inferred damage types 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) の進展にともなう構成部材の軋み
(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	電極材のき裂をともなうはく離

(B), (D), (E) の左側に対応する事象群である。これは損傷フェーズが初期欠陥や不均一性による小さな割れの進展の終盤から、電解質のき裂を経て、ガラスシールの損傷の序盤にかけて発生している。右上の島 (2) は、領域 (C) に対応する事象群であり、これは初期欠陥の進展にともなう軋み音である。下方の島 (3) は、(E) の右側と (F) で共起している事象群であり、これはガラスシールの損傷の終盤と電極材のき裂とはく離が起こっているフェーズに対応している。

● 橋に対応する事象

島どうしをつなぐ橋の役割をする事象、つまり赤丸の事象に着目する。(10,4) は島 (1) と島 (3) の条件付き確率の下で抽出された事象である。(10,4) はガラスシールの損傷に関する事象であり、島 (1) はガラスシールの損傷初期、島 (3) はガラスシールの損傷後期を含んでいるため、両方に共起して現れるのは妥当である。また、島 (1) と島 (2) をつないでいるのは、(11,8), (8,1), (3,13), (5,3) である。これらの事象は領域 (B), (D), (E) の事象である。島 (2) は初期欠陥の進展にともなう軋み音であるが、(1,15) の電解質のき裂と共起しているため、表 1 より頻出期間が被っている (B), (D), (E) と共起して現れていると考えられる。

以上から、損傷フェーズと対応させて解釈可能な結果が得られているといえる。ただし、事象遷移を考慮していないため、この結果から機械的影響の方向は分からない。

3.6 E³ 法による機械的影響の推定

プロトタイプ間の発生密度の変化により事象遷移 (図 9) を抽出し、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 10)。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マップにマッピングした結果を図 11 に示す。これらと専門家の持っている知識と照らし合わせて妥当な結果と、これまで気付いていなかったが妥当な結果を分けて以下に示す。




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.

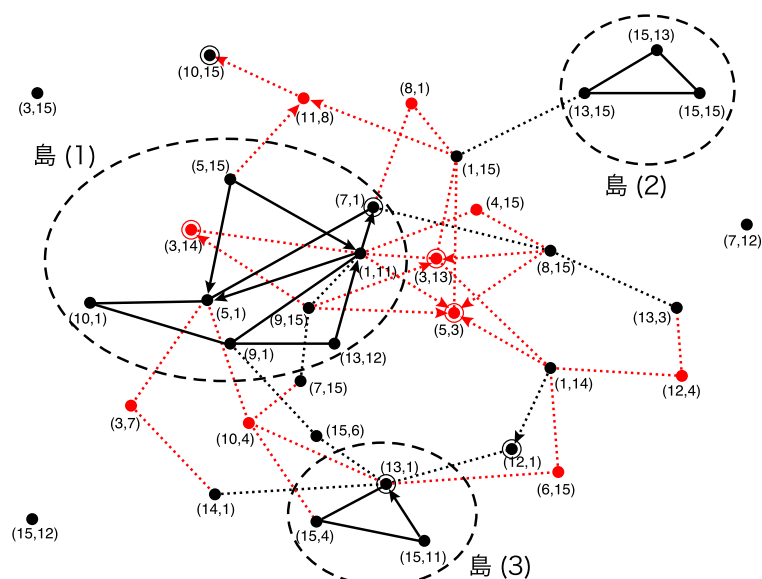


図 10 キーグラフおよび事象遷移の出力結果 (黒丸は高頻度な事象、赤丸は稀であるが重要な事象を表しているノード番号は、カーネル SOM 上のプロトタイプの座標である)
Fig. 10 Output of the KeyGraph with event transition. Black nodes denote high frequent fundamental events and red nodes denote rare essential events. Node labels are the coordinates of prototypes by the kernel SOM.

● 専門家の持っている知識と照らし合わせて妥当な結果

図 11 (a) は領域 (B) から (D) 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。図 11 (c) は、領域 (B)

から領域 (D) を経て領域 (E) へ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．

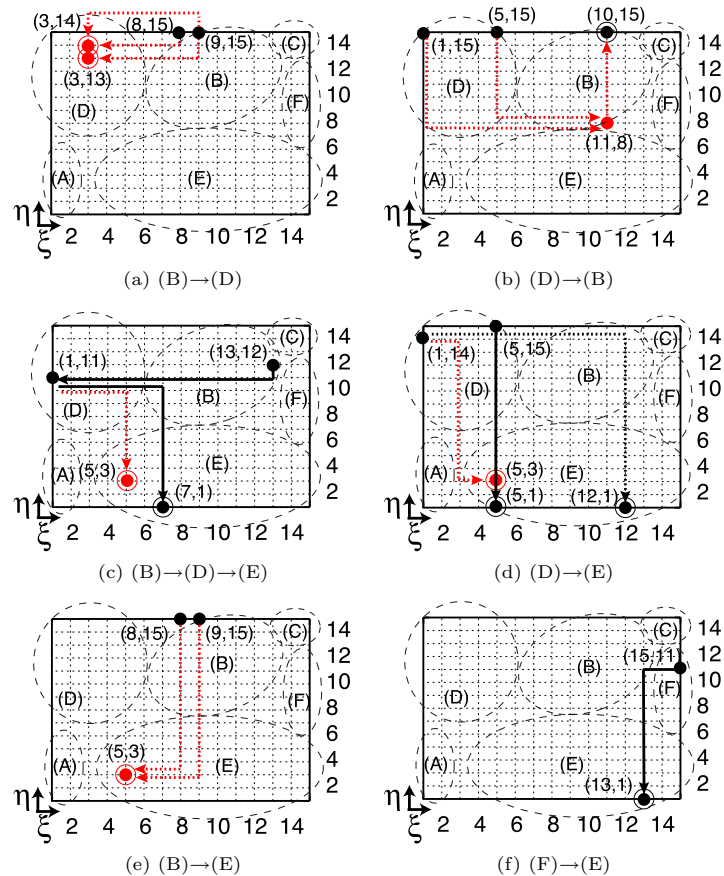


図 11 キーグラフにより得られた共起する遷移事象のマッピング結果

Fig. 11 Mapped co-occurring event transitions from KeyGraph onto the topology map.

一方，エネルギーの小さな領域 (A) と領域 (C) の AE 事象は他の領域の損傷にまったく影響を与えないことが分かる．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分かる．

● これまで気付いていなかったが妥当な結果

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．また，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かった．これらの結果は，燃料電池の専門家の観点から興味深い結果であった．

ここで，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は単なる数え上げでは抽出することができない．図 11 (a) から図 11 (e) において，矢印の終点もしくは途中で赤丸を含んでいる．このことから，事象の遷移過程の重要事象が抽出されているといえる．

3.7 エネルギー閾値の影響

この節では，AE 事象系列をバスケットに分割する際に用いるエネルギー閾値 E_σ の影響について議論する． E_σ をより大きくすると 1 つのバスケットに含まれる事象数は増加し，総バスケット数は減少する．

各 E_σ においてキーグラフを生成するときに設定した各パラメータを表 2 に示す．本研究の SOM の学習結果では，1 つのプロトタイプに含まれる AE 事象数が 10 個以上となる数は少なく，また，8 個以下のプロトタイプ数は多すぎるため，いずれの E_σ についても AE 事象を 9 個以上含むプロトタイプを基礎的要因の対象とした．その結果，島のノード数は 24~30 となった．また，島のエッジ数は事象数と同程度に設定した．島の数が 3~4 であったため，橋のノード数は 10 に設定した．

次に，SOFC の機械的特性を抽出するのに最適な E_σ を探索するために， E^3 法によって抽出された事象遷移の数を比較し，結果を表 3 にまとめた．(B)→(E) の遷移は閾値 1,750

表 2 キーグラフのパラメータ設定
Table 2 Parameter settings of the KeyGraph.

閾値 \ E_σ	1,000	1,250	1,500	1,750	2,000
島のノード数	30	28	26	26	24
島のエッジ数	32	35	26	25	26
橋のノード数	10	10	10	10	10
橋のエッジ数	27	28	29	24	23

表 3 エネルギー閾値の影響
Table 3 Effect of the energy threshold.

遷移 \ E_σ	1,000	1,250	1,500	1,750	2,000
(B) → (D)	3	8	4	4	4
(D) → (B)	3	1	2	1	0
(B) → (E)	1	1	2	0	0
(D) → (E)	4	3	5	4	5
(E) → (D)	1	0	0	0	1
(F) → (E)	1	1	1	1	1
総遷移回数	13	14	14	10	11

以上, (D)→(B) の遷移は 2,000 で消滅している. 一方, (E)→(D) の遷移は 1,000 と 2,000 で出現している. この遷移はガラスシールの損傷から電解質のき裂への遷移であるが, 材料力学の観点からガラスシール材が電解質に影響を及ぼすとは考えにくい. キーグラフは共起度を上位から視覚化する手法であるため, 閾値が低すぎる場合と高すぎる場合で相対的な共起度が上がってきた事象ではないかと推測しているが, 詳細な分析が必要である. それぞれ損傷の種類により最もよく遷移が抽出できる閾値は異なると考えられるが, 遷移の出現回数の全体のバランスを考えると, 最適な閾値は $E_\sigma = 1,500$ と考えられる.

ここで, E_σ によりキーグラフの出力結果が変化しても, 抽出された遷移の傾向に大きな変化はなく, SOFC 損傷の機械的影響の推定に大きな影響を与えないことに注意しておく. E_σ によりバスケットに含まれる事象群が変化するため, キーグラフ上に現れる SOM のプロタイプは変化する. しかし, それらプロタイプはトポロジマップ上では同じ領域に位置しており, 表 3 の $E_\sigma = 1,250$ の (B)→(D) を除いて最終的に得たい領域の遷移は閾値の変化に対して頑健であるに抽出できているといえる.

4. 展 望

専門家は E^3 法を用いることで, 結果から機械的な影響を矛盾なく説明し, 新しい情報を得ることができた. このように専門家が仮説を立てることができるのは非常に有用である. 仮説の信頼性は, 損傷試験を繰り返し行い, 遷移事象の再現性を確認することで高められるであろう. E^3 法は損傷メカニズムの解明, 損傷フェーズの遷移や致命的な損傷のモニタリングに貢献できる. 将来, 異なる条件下での損傷の比較実験やコンピュータによる物理シミュレーションにより, SOFC の損傷メカニズムが解明されていくものと考えられる.

今後の課題として, 現状の E^3 法では, ユーザがプロトタイプの発生密度の変化を参照す

ることによって手動で事象遷移を抽出している. そのため, PAI (priming activation indexing)³³⁾ のように動的な伝搬機構を E^3 法に導入する必要がある. また, 本論文ではデータ空間のベクトル量子化と視覚化に SOM を用いたが, 他の量子化や視覚化技術とベンチマークデータを用いた比較実験, もしくはユーザの探索的分析の被験者実験による比較が必要である.

5. ま と め

我々は, 非記号事象系列から比較的稀であるが事象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 (E^3) 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フを用いた. SOM のトポロジマップから得られる密度推定を併用することで, 事象遷移にともなう共起事象を得た. 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 E^3 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, 「附置研究所間アライアンスによるナノとマクロをつなぐ物質・デバイス・システム創製戦略プロジェクト」特別経費 (文部科学省), および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. 20th Int'l. Conference on Very Large Databases*, pp.487-499 (1994).
- 2) Han, J., Kamber, M. and Pei, J.: *Data Mining, 2nd Edition: Concepts and Techniques*, Morgan Kaufmann (2006).
- 3) Sornette, D.: Predictability of Catastrophic Events: Material Rupture, Earthquakes, Turbulence, Financial Crashes, and Human Birth, *Proc. 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. 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. 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. 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. 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. and Yachida, M.: Discover Risky Active Faults by Indexing an Earthquake Sequence, *Proc. Discovery Science (DS'99)*, pp.208–219 (1999).
- 13) Ohsawa, Y.: KeyGraph as Risk Explorer from Earthquake Sequence, *Journal of Contingencies and Crisis Management*, Vol.10, No.3, pp.119–128 (2002).
- 14) 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).
- 15) 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).
- 16) 赤穂昭太郎：カーネル多変量解析，岩波書店 (2008)。
- 17) Silverman, B.: *Density Estimation for Statistics and Data Analysis*, Chapman & Hall (1986).
- 18) 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).
- 19) 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).
- 20) 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).
- 21) 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).
- 22) Miller, R.K., Kill, E.V.K., Moore, P.O. and Hill, E.V.: *Acoustic Emission Testing*, American Society for Nondestructive (2005).
- 23) Fukui, K., Sato, K., Mizusaki, J., Saito, K., Kimura, M. and Numao, M.: Growth Analysis of Neighbor Network for Evaluation of Damage Progress, *Proc. 13th Pacific-Asia Conference on Knowledge Discovery and Data Mining (PAKDD'09), Lecture Notes in Artificial Intelligence 5476*, pp.933–940 (2009).
- 24) 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)。
- 25) 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).
- 26) 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).
- 27) 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).
- 28) 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).
- 29) Kleinberg, J.: Bursty and hierarchical structure in streams, *Proc. 8th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD'02)*, pp.1–25 (2002).
- 30) Moreno, P.J., Ho, P.P. and Vasconcelos, N.: A Kullback-Leibler Divergence Based Kernel for SVM Classification in Multimedia Applications, *Advances in Neural Information Processing Systems 16* (2003).
- 31) 石垣 司，樋口知之，渡辺嘉二郎：Kullback-Leibler カーネルによる正規化周波数スペクトル判別とその圧力調整器劣化診断への応用，電子情報通信学会論文誌 D，Vol.J90-D, No.10, pp.2787–2797 (2007)。
- 32) 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)。
- 33) Matsumura, N., Ohsawa, Y. and Ishizuka, M.: PAI: Automatic Indexing for Extracting Asserted Keywords from a Document, *New Generation Computing*, Vol.21,

(平成 22 年 8 月 31 日受付)
(平成 22 年 10 月 20 日再受付)
(平成 22 年 11 月 17 日採録)



北川 哲平

2010 年大阪大学工学部応用自然科学科卒業。同年より大阪大学大学院情報科学研究科情報数理学専攻博士前期課程在学中。



福井 健一 (正会員)

2003 年名古屋大学大学院人間情報学研究科物質・生命情報学専攻博士前期課程修了。博士 (情報科学)。大阪大学特任助手を経て、2010 年より大阪大学産業科学研究所助教。IEEE Computer & Information Technology 2008 Best Paper Award 受賞。データマイニング、機械学習に関する研究に従事。人工知能学会会員。



佐藤 一永

2005 年東北大学大学院工学研究科地球工学専攻博士課程修了。博士 (工学)。東北大学 21COE フェロー、東北大学多元物質科学研究所助手を経て、2008 年より東北大学多元物質科学研究所助教。燃料電池やリチウムイオン電池の信頼性・耐久性向上に向けた研究を行う。日本機械学会、固体イオニクス学会、SOFC 研究会、日本複合材料学会各会員。



水崎純一郎

1975 年東京大学大学院工学研究科博士課程修了。工学博士。東京大学助手、横浜国立大学助教授を経て、1994 年より東北大学多元物質科学研究所教授。機能性材料の物性と熱力学的性質の基礎研究を中心に行っている。また、各種センサやエネルギー変換デバイスに応用する研究を行う。固体イオニクス学会会長、SOFC 研究会会長、米国電気化学会、電気化学協会、日本セラミックス協会等各会員。



沼尾 正行

1982 年東京工業大学工学部電気電子工学科卒業。1987 年同大学院情報理工学専攻博士課程修了。工学博士。東京工業大学大学院情報理工学研究科計算工学専攻助教授を経て、2003 年より大阪大学産業科学研究所教授。1989~1990 年スタンフォード大学 CSLI 客員研究員。人工知能、機械学習、関数型言語等の研究に従事。人工知能学会、日本認知科学会、日本ソフトウェア科学会、電子情報通信学会、AAAI、ACM 各会員。