

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

福井 健一^{†1} 赤崎 省悟^{†2} 佐藤 一永^{†3}
水崎 純一郎^{†3} 森山 甲一^{†1}
栗原 聡^{†1} 沼尾 正行^{†1}

本稿では、き裂、摩擦や衝突音など損傷に関わる Acoustic Emission (AE) 信号に対して、カーネル SOM のマップ上での隣接性を考慮した分類性能を評価した。AE 信号群の周波数スペクトルの分布間の距離として、確率分布間の距離に基づく Kullback-Leibler (KL) カーネルを用いた。また、SOM のマップ上での隣接性を考慮して、クラスタ純度や F 値による通常のクラスタリング尺度を拡張した。複数の模擬データを用いて、いくつかの標準的なカーネルを用いた SOM や通常型 SOM と比較した結果、KL カーネルを用いた場合に F 値の観点で最も良い性能を示すことを確認した。また可視化結果とあわせて、クラス分離性と密集性について考察した。

Performance of Kernel SOM Considering Adjacency for Damage Evaluation

KEN-ICHI FUKUI,^{†1} SHOGO AKASAKI,^{†2} KAZUHISA SATO,^{†3}
JUNICHIRO MIZUSAKI,^{†3} KOICHI MORIYAMA,^{†1}
SATOSHI KURIHARA^{†1} and MASAYUKI NUMAO^{†1}

We evaluated clustering performance of Kernel SOM considering adjacency within the obtained map upon Acoustic Emission (AE) waves involved in damage such as crack, friction and collision. Here, we employed Kullback-Leibler (KL) kernel that is based on a distance between probability distributions as a distance between frequency spectrum distributions. Also standard clustering measures, e.g., cluster purity and F-measure, are extended so as to consider adjacency within the map obtained by SOM. Using simulated AE data sets, we confirmed the best among the several standard kernels in terms of F-measure. Also we discussed about separability and density of classes together with the visualized maps.

1. はじめに

Kohonen によって提案された自己組織化マップ (Self-Organizing Map: SOM)¹⁾ は、特徴空間内でのデータの分布構造を縮約したマップを生成するため、大規模データの全貌の直感的理解と利用者の探索的分析を助ける手法として工学をはじめ経済、医療など様々な分野で診断や監視、データマイニングに応用されている。一般には、大規模データの教師なしの分析手法として、種々のクラスタリング法²⁾ や、多次元尺度構成法 (Multi-Dimensional Scaling: MDS) に代表される低次元への様々な埋め込み法^{3),4)} が提案されている。クラスタリングと低次元への埋め込みの 2 段階を行うことも考えられるが、我々はこれらを自然に同時に行う方法として SOM に着目している。

我々は、固体型電池、特に固体酸化物燃料電池 (Solid Oxide Fuel Cell: SOFC) の損傷により生じる弾性波を計測した Acoustic Emission (AE) 信号データから、損傷タイプや損傷過程の分析支援や監視のための共通分析基盤として SOM を応用することを想定している。SOM はデータの分布構造を縮約したモデルとしてマップを生成するため、過去の蓄積データベースから得られたマップと現在の信号系列から現在の状態を視覚的に把握したり、その後どのような損傷過程をたどるのか予測を行ったりするのに適した手法と考えている。

ここで、AE 法は広く建造物や部材の非破壊検査法として用いられている⁵⁾。AE の分野では主として材料力学的な特性と AE 信号との関係に関する研究であり、AE 信号とクラス (損傷タイプ) を直接結び付けるパターン識別を扱った研究は数少ない。近年では、たとえば Rippengill らは、箱げた橋の損傷試験から得られた AE データに対して、主成分分析 (PCA) の第 1・第 2 主成分によって張られる平面でのデータの分布の可視化、および多層ニューラルネットワークによる分類を行っている⁶⁾。また、Godin らは、ポリエステル複合材の引張試験によって得られた AE データに対して、k-means と SOM を組み合わせてクラスタリングおよび可視化を行っている⁷⁾。また、近年注目されている群知能の一種であるアントコロニー最適化法 (Ant Colony Optimization: ACO) を応用し、AE 信号の模擬デー

^{†1} 大阪大学産業科学研究所

The Institute of Scientific and Industrial Research, Osaka University

^{†2} 大阪大学大学院情報科学研究科

Graduate School of Information Science and Technology, 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

タの分類⁸⁾もなされている。これらの研究において AE 波の類似度は、周波数スペクトル、もしくは持続時間や分散など時間領域の特徴量の単純な二乗ノルム（ユークリッド距離）に基づいている。しかし、二乗ノルムは成分間に独立を仮定しており、分布という構造を持つ周波数スペクトルの類似度として適切とはいえない。

一方、近年、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したり、既存の手法に適切な類似度を組み込んだりすることを可能にするカーネル法が注目されている⁹⁾。カーネル法を利用した識別器としてサポートベクタマシン（Support Vector Machine: SVM）が有名であるが、SOM においてもカーネル化したカーネル SOM が提案されている¹⁰⁾⁻¹²⁾。ここで、カーネル法では対象の特性に合わせて適切にカーネル関数を選択、もしくは設計することが重要となる。代表的なカーネル関数には、多項式カーネル、ガウシアンカーネル、シグモイドカーネルなどがある。一方、我々が応用を想定している弾性波は、材料や破壊モードに固有の周波数を含むため、周波数スペクトルの分布形状を考慮したカーネルを選択もしくは設計することが重要である。

それに対して本研究では、正規化周波数スペクトルにおいて、確率分布間の近さを測る Kullback-Leibler 情報量（Kullback-Leibler divergence）を基にした KL カーネルに着目した。石垣らは人工データにより KL カーネルを用いた SVM の分類性能を定量的に評価しており、KL カーネルを用いた場合、他のいくつかの標準的なカーネルと比較して良好な性能を示している¹³⁾。しかし、現在のところ、AE 信号の周波数スペクトルに対する KL カーネルを用いたカーネル SOM の性能評価はなされていない。

我々はこれまでに、実際の SOFC の損傷計測 AE データに対して、Sequence-based SOM による損傷過程の可視化¹⁴⁾や、KL カーネルを用いたカーネル SOM と通常の SOM の定性的な比較¹⁵⁾を行ってきた。しかし、実際の SOFC において損傷タイプを制御した実験は困難であり、また SOFC の分野において損傷メカニズムの大部分は現状では未知であるため、定量的な評価は行えていない。そこで本稿では、一般に生じるき裂、摩擦や衝突音など損傷に関わる AE 信号の模擬データを用意し、KL カーネルや標準的ないくつかのカーネルを用いた SOM、および通常型 SOM との定量的な比較評価を行い、KL カーネルを用いた SOM の AE 信号データに対する有効性を確かめた。

ここで SOM の特徴として、(1) クラスタ性：少数のニューロンによる縮約（ベクトル量子化）、(2) 隣接性：ニューロンのトポロジによってとらえられるデータの分布構造（位相順序）があげられる。SOM の分類性能を定量的に評価するにあたって、クラスタ純度や F 値などのクラスタリング尺度は、クラスタ間の隣接性は考慮されていないため SOM の評価

尺度としては不十分である。そこで、SOM により得られたマップ上での近傍データの隣接性を考慮するように評価尺度を拡張した。

2. カーネル SOM

2.1 カーネル法概説

形式的には、 N 個の入力データ $\mathbf{x}_1, \dots, \mathbf{x}_N \in \mathcal{G}$ に対して、カーネル関数 $K: \mathcal{G} \times \mathcal{G} \rightarrow \mathcal{R}$ は以下の性質を満たす関数である。

対称性 $K(\mathbf{x}_i, \mathbf{x}_j) = K(\mathbf{x}_j, \mathbf{x}_i)$ 。

半正定値性 全入力データ $\mathbf{x}_1, \dots, \mathbf{x}_N$ 、任意の実数 $\alpha_1, \dots, \alpha_N$ に対して次式が成り立つ。

$$\sum_i \sum_j \alpha_i \alpha_j K(\mathbf{x}_i, \mathbf{x}_j) \geq 0. \quad (1)$$

その場合、

$$K(\mathbf{x}_i, \mathbf{x}_j) = \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}_j) \rangle \quad (2)$$

なる関数 $\phi: \mathcal{G} \rightarrow \mathcal{H}$ （再生核ヒルベルト空間と呼ばれる空間へ写像する関数）が存在することが示されている⁹⁾。ここで \langle, \rangle は内積を表す。SOM をはじめとする学習手法の多くは、その学習過程ではデータ間の内積の形で現れるため、写像関数 ϕ の中身は陽に求まらなくても、その内積さえ定義できればよい。カーネル法はこの数学的性質を利用し、陰に高次元へ写像した空間で学習を行う。

2.2 Kullback-Leibler カーネル

v 個の離散点からなる周波数スペクトルを $\mathbf{x}_i = (x_{i,1}, \dots, x_{i,v})$ とすると、KL カーネルは次式で与えられる。

$$K_{\text{KL}}(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\beta \text{JS}(\mathbf{x}_i, \mathbf{x}_j)) \quad (3)$$

$$\begin{aligned} \text{JS}(\mathbf{x}_i, \mathbf{x}_j) &= \text{KL}(\mathbf{x}_i, \mathbf{x}_j) + \text{KL}(\mathbf{x}_j, \mathbf{x}_i), \\ &= \sum_{k=1}^v \left\{ x_{i,k} \log \frac{x_{i,k}}{x_{j,k}} + x_{j,k} \log \frac{x_{j,k}}{x_{i,k}} \right\}. \end{aligned} \quad (4)$$

ここで、 $\text{KL}(\mathbf{x}_i, \mathbf{x}_j)$ は KL 情報量と呼ばれる確率分布間の近さを表す尺度であるが、KL 情報量は非対称（すなわち、 $\text{KL}(\mathbf{x}_i, \mathbf{x}_j) \neq \text{KL}(\mathbf{x}_j, \mathbf{x}_i)$ ）であるため、KL 情報量を対称化した Jensen-Shannon 情報量 $\text{JS}(\mathbf{x}_i, \mathbf{x}_j)$ を用いている。また、 $\beta (> 0)$ 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。周波数スペクトルを確率分布と見なすことは、スペクトルのパワー（絶

対値)によらず、周波数成分の相対的な出現確率分布を意味する。

注意点としては、式(3)は半正定値性を満たさないため、厳密にはカーネル関数ではない。しかしながら、圧力調整器の故障診断¹³⁾や、音声や画像分類¹⁶⁾などに用いられており、実用上役に立つ例が存在する。本稿においても同様に式(3)をカーネル関数と見なして扱う。また、カーネル法を利用した代表である SVM においては、半正定値性を満たさないと大域的最適解が保障されなくなるが、本研究で用いるカーネル SOM は学習過程において半正定値性は要求されないため、重大な問題とはならない。

また、標準的なカーネル関数として本研究では次の3つのカーネルと比較した。ガウシアンカーネル(GS)

$$K_{GS}(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2}\right). \quad (5)$$

シグモイドカーネル(SG)

$$K_{SG}(\mathbf{x}_i, \mathbf{x}_j) = \tanh(a\mathbf{x}_i \mathbf{x}_j^t - b). \quad (6)$$

多項式カーネル(PL)

$$K_{PL}(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i \mathbf{x}_j^t + l)^p. \quad (7)$$

ここで、 σ, a, p (p は自然数) はパラメータである。また、本研究では $l = 0, b = 0$ に固定した。

2.3 KL カーネルの意味

まず、通常型 SOM やガウシアンカーネルが基づいている二乗ノルムと KL カーネルとの関係について述べる。2つの周波数スペクトル $\mathbf{x}_i, \mathbf{x}_j = \mathbf{x}_i + \Delta\mathbf{x}$ 間の二乗ノルム D は次式で与えられる。

$$D(\mathbf{x}_i, \mathbf{x}_j) = \sum_{k=1}^v \left(x_{i,k} - (x_{i,k} + \Delta x_k)\right)^2 = \sum_{k=1}^v \Delta x_k^2. \quad (8)$$

一方、KL カーネルの成分 JS は、

$$\begin{aligned} JS(\mathbf{x}_i, \mathbf{x}_j) &= \sum_{k=1}^v (x_{j,k} - x_{i,k}) \log \frac{x_{j,k}}{x_{i,k}} \\ &= \sum_{k=1}^v \Delta x_k \log \left(1 + \frac{\Delta x_k}{x_{i,k}}\right). \end{aligned} \quad (9)$$

となる。二乗ノルムは一律に差 $\Delta\mathbf{x}$ のみで評価するのに対して、式(9)の \log の中に着目

すると、KL カーネルは $x_{i,k}$ と Δx_k との比が影響する。スペクトルのパワー $x_{i,k}$ が大きくなるにつれて ($x_{i,k} \rightarrow 1$)、 Δx_k のみの評価に近づき、逆に $x_{i,k}$ が小さくなるにつれて、 Δx_k の影響を拡大する効果があると解釈できる。すなわち、スペクトルのピーク付近の多少の差よりも、パワーの低い周波数での差を大きく評価している。スペクトルは非常にピークの鋭い形状をしているため、ピーク付近での多少の差は過小評価するという意味でスペクトルの分布形状を考慮しているといえる。

一方、シグモイドカーネルや多項式カーネルが基づいている内積は、 $\mathbf{x}_{i,k}$ と $\mathbf{x}_{j,k}$ の両方の値が大きいときに内積の値も大きくなる。つまり、ピークの位置は考慮しているが、値の低い周波数における差は無視されてしまうと考えられる。

2.4 カーネル SOM アルゴリズム

本節では、バッチ型カーネル SOM¹²⁾の概略を説明する。一般の近傍関数 $h_{i,j}$ (i, j はニューロンのノード番号)を用いたカーネル SOM の目的関数は次式で与えられる。

$$\text{minimize } L_{ksom} = \sum_{i=1}^M \sum_{\mathbf{x}_n \in C_i} \sum_{j=1}^M h_{i,j} \|\phi(\mathbf{x}_n) - \mathbf{m}_j\|^2. \quad (10)$$

ここで、 M はニューロン数、 C_i は第 i ニューロンが勝者(最近傍)となるデータ点の集合、すなわち $C_i = \{\mathbf{x}_n | c(n) = i\}$ ($c(n)$ は \mathbf{x}_n の勝者ニューロンの番号)、また \mathbf{m}_j は第 j ニューロンに定義される参照ベクトルを表す。近傍関数としては次式のガウス関数がよく用いられる。

$$h_{i,j} = \exp\left(-\frac{\|\mathbf{r}_i - \mathbf{r}_j\|^2}{2\sigma^2}\right). \quad (11)$$

\mathbf{r}_i は第 i ニューロンの位置座標(通常2次元)であり、 σ は近傍の影響を表すパラメータ(近傍半径)である。ニューロンのトポロジは通常型 SOM と同じく、2次元の場合は正方形もしくは六角格子を用いることができる。

通常のバッチ型 SOM¹⁾の参照ベクトル更新式において \mathbf{x}_n を $\phi(\mathbf{x}_n)$ 置き換えると、カーネル SOM において次式の関係が成り立つ。

$$\mathbf{m}_i(t+1) := \gamma \sum_n h_{c(n),i} \phi(\mathbf{x}_n). \quad (12)$$

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。カーネル SOM では $\phi(\mathbf{x}_n)$ は求まらないため、参照ベクトル \mathbf{m}_i とデータ点 \mathbf{x}_n との非類似度 $d_{i,n}$ を更新することで、陰に参照ベクトルを更新する。

$$\begin{aligned}
d_{i,n}(t+1) &\equiv \|\phi(\mathbf{x}_n) - \mathbf{m}_i(t+1)\|^2 \\
&= K(\mathbf{x}_n, \mathbf{x}_n) - 2\gamma \sum_j h_{c(j),i} K(\mathbf{x}_n, \mathbf{x}_j) \\
&\quad + \gamma^2 \sum_k \sum_l h_{c(k),i} h_{c(l),i} K(\mathbf{x}_k, \mathbf{x}_l).
\end{aligned} \tag{13}$$

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。

Step 1. ランダムに参照ベクトルとデータ点との非類似度 $d_{i,n}$ を与える。

Step 2. 勝者ニューロンを更新する。

$$\forall n \ c(n) = \arg \min_i d_{i,n}. \tag{14}$$

Step 3. すべての参照ベクトルとデータ点との非類似度 $d_{i,n}$ を式 (13) により更新する。

Step 4. 近傍半径 σ を小さくし、収束するまで Step 2, 3 を繰り返す。

3. 隣接性を考慮した評価尺度

本稿では通常のクラスタリング尺度を基にして、トポロジ上の近傍関数を周辺化の重みとして利用することにより、マップ上の隣接性を考慮するように評価尺度を拡張する。クラスタリング尺度としては大きく集合に基づく尺度¹⁷⁾と、データ対に基づく尺度¹⁸⁾があり、それぞれ拡張する。

まず、集合に基づく尺度としてクラスタ純度、クラス F 値^{*1}、エントロピーを考える。 $C_i \in C$ はクラスタ (SOM では勝者ニューロンによる類似データ点集合に相当)、 N は総データ点数、 $t \in T$ は (正解) クラス番号、 N_i は第 i クラスタのデータ点数、 N_t は第 t クラスのデータ点数、 $N_{t,i}$ は第 i クラスタに含まれる第 t クラスのデータ点数を表すとする。ここで、 $N_{t,i}$ 、 N_i 、 N を近傍関数 $h_{i,j}$ により次式のように周辺化する。

$$N'_{t,i} = \sum_j h_{i,j} N_{t,j}. \tag{15}$$

$$N'_i = \sum_t N'_{t,i}. \tag{16}$$

$$N' = \sum_i N'_i. \tag{17}$$

*1 単に F 値と呼ばれることが多いが、データ対に基づく F 値と区別するためクラス F 値と呼ぶことにする。

これらを用いてクラスタ純度、クラス F 値、エントロピーを以下のように定義する。

クラスタ純度 (Cluster Purity: CP)

$$CP(C) = \frac{1}{N'} \sum_{C_i \in C} \max_{t \in T} N'_{t,i}. \tag{18}$$

クラスタ純度は、各クラスタ内で最多クラスが占める割合の平均値である。これに隣接性を考慮すると、周辺のクラスタも加味した最多クラスが占める割合の平均値となる。

クラス F 値 (Class F-measure: CF)

$$CF(C) = \sum_{t \in T} \frac{N_t}{N} \max_{C_i \in C} F(t, C_i), \tag{19}$$

$$F(t, C_i) = \frac{2 \cdot Prec(t, C_i) \cdot Rec(t, C_i)}{Prec(t, C_i) + Rec(t, C_i)}. \tag{20}$$

ここで、 $Prec(t, C_i) = N'_{t,i}/N'_i$ 、 $Rec(t, C_i) = N'_{t,i}/N'_t$ である。各クラスを中心を F 値が最大となるクラスタとし、クラス F 値はクラスごとの最大 F 値の平均値で与える。F 値は正解クラスによる集合とクラスタによる集合の Precision と Recall の調和平均である。拡張したクラス F 値では、周辺のクラスタ内のクラス分布も加味した Precision および Recall を用いている。Precision は個々のクラスタ内で異なるクラスの分離度合いを表し、一方 Recall は同じクラスの密集度合いを表している。

エントロピー (Entropy: EP)

$$EP(C) = \frac{1}{|C|} \sum_{C_i \in C} Entropy(C_i), \tag{21}$$

$$Entropy(C_i) = -\frac{1}{\log N'} \sum_{t \in T} \frac{N'_{t,i}}{N'_i} \log \frac{N'_{t,i}}{N'_i}. \tag{22}$$

エントロピーは、各クラスタ内のクラス分布のばらつき度合いの平均値である。拡張したエントロピーは、周辺のクラスタ内のデータ点も加味したクラス分布のばらつき度合いを表す。

次にデータ対に基づく尺度を考えるうえで、まず表 1 に示すペアワイズ分割表を拡張する。ここで、 a, b, c, d はデータのペアが同じクラス (クラスタ) に属している (属していない) 数である。SOM では同じクラスタに属するデータ対の数の代わりに、同じクラスタである尤度 $likelihood(c(\mathbf{x}_i) = c(\mathbf{x}_j))$ を考え、トポロジ上の距離に基づく近傍関数によって与える。

表 1 ペアワイズ分割表
Table 1 Cross table for pairwise of data.

	$t(\mathbf{x}_i) = t(\mathbf{x}_j)$	$t(\mathbf{x}_i) \neq t(\mathbf{x}_j)$
$c(\mathbf{x}_i) = c(\mathbf{x}_j)$	a	b
$c(\mathbf{x}_i) \neq c(\mathbf{x}_j)$	c	d

$$a' = \sum_{\{i,j|t(\mathbf{x}_i)=t(\mathbf{x}_j)\}} h_{c(\mathbf{x}_i),c(\mathbf{x}_j)}. \quad (23)$$

$$b' = \sum_{\{i,j|t(\mathbf{x}_i)\neq t(\mathbf{x}_j)\}} h_{c(\mathbf{x}_i),c(\mathbf{x}_j)}. \quad (24)$$

$$c' = \sum_{\{i,j|t(\mathbf{x}_i)=t(\mathbf{x}_j)\}} (1 - h_{c(\mathbf{x}_i),c(\mathbf{x}_j)}) = a + c - a'. \quad (25)$$

$$d' = \sum_{\{i,j|t(\mathbf{x}_i)\neq t(\mathbf{x}_j)\}} (1 - h_{c(\mathbf{x}_i),c(\mathbf{x}_j)}) = b + d - b'. \quad (26)$$

これら a', b', c', d' で与えられる拡張ペアワイズ分割表を用いて, ペアワイズ精度およびペアワイズ F 値を次式により定義する.

ペアワイズ精度 (Pairwise Accuracy: PA)

$$PA(C) = \frac{a' + d'}{a' + b' + c' + d'}. \quad (27)$$

ペアワイズ精度は, 同じクラスどうしのデータ対は同じクラスに属し, 異なるクラスどうしのデータ対は異なるクラスに属している数の割合である. これを拡張したペアワイズ精度は, 同じクラスどうしは近傍のクラスに属し, 異なるクラスどうしは遠いクラスに属する量の割合を示す尺度である.

ペアワイズ F 値 (Pairwise F-measure: PF)

$$PF(C) = \frac{2 \cdot P \cdot R}{P + R}. \quad (28)$$

ここで, $P = a' / (a' + b')$, $R = a' / (a' + c')$ である. ペアワイズ F 値は, 同じクラスに属するデータ対のうち同じクラスに属するデータ対の割合 (Precision) と, 同じクラスに属するデータ対のうち同じクラスに属するデータ対の割合 (Recall) の調和平均である. 拡張したペアワイズ F 値では, 同じクラスに属するデータ対の数の代わりに, 同じクラスに属する尤度を基に Precision と Recall を求める.




図 1 模擬データの収集 1

Fig. 1 Collection of simulated data 1.

補足として, 近傍関数が $h_{i,j} = \delta_{i,j}$ (δ はクロネッカーのデルタ) の場合, 上述のすべての尺度は通常の尺度に一致するため自然な拡張である. また, 近傍関数は $h_{i,j} \geq 0$ かつ距離に関する単調減少関数になっている限り, 隣接性を考慮した尺度になっているといえる. しかし, 近傍半径を大きくすると全体を平滑化してしまうため, 適度に小さくする必要がある. 本稿では近傍関数として式 (11) を用い, $\sigma = 1$ とした.

4. 分類性能評価

4.1 模擬データ

一般に破壊のモードには, き裂に代表される突発的な開口モードと, 横ずれによる連続的なせん断モードがある. 開口モードはひずみ速度が速く, 最初大きな振幅を持つ減衰波形が得られる. 一方, せん断モードはひずみ速度が遅く, 振幅は小さいが持続した波形が得られる⁵⁾. 本研究では, AE 信号の模擬データとして, き裂や摩擦, 衝突による音をコンクリートマイクにより集音した. 突発的な開口モードをき裂と衝突音によって, また連続的なせん断モードを摩擦音によって模擬している. サンプル周波数は 44.1 kHz であるため, 計測可能な最大周波数は約 22 kHz となる^{*1}. データセットは以下の 4 種類 (大きくは 2 種類) を用意した^{*2}.

データセット 1 図 1 (a) に示すように木片の片端をペンチで固定し, 他方の端に力を加えて割ったときに発生する音, また, 図 1 (b) に示すように割り箸の片方をペンチで固定

*1 本実験で用いるコンクリートマイクは可聴域しか集音できないため正しくは AE ではないが (AE は MHz オーダまで扱うが可聴域も含まれている), 信号として非可聴域と性質が異なるわけではない.

*2 これらのデータセットは, <http://www.ai.sanken.osaka-u.ac.jp/~fukui/wave-data/> で公開している.




図 2 模擬データの収集 2

Fig. 2 Collection of simulated data 2.

し割ったときの音を集音した．木片は 4 種類用意し，全 5 クラス，各クラス 25 サンプルずつ集音した．木片の種類と大きさは以下のとおりである．

- クラス 1 バルサ材 (小) 3 mm×3 mm×L=100 mm
- クラス 2 バルサ材 (大) 5 mm×5 mm×L=100 mm
- クラス 3 竹串 2 mm×3 mm×L=180 mm
- クラス 4 シナ材 3 mm×3 mm×L=100 mm
- クラス 5 割り箸 13 mm×4 mm×L=200 mm


全 5 クラスを用いたデータセット 1a と，クラス 4，5 を除いた 3 クラスのデータセット 1b を用意した．

データセット 2 図 2 (a) に示すように厚紙でできた箱を斜面を滑らせたときに発生する摩擦音，および図 2 (b) に示すよう箱を一定の高さから落としたときに発生する衝突音を集音した．滑降させる速さや箱の大きさを変えて，以下の全 5 クラス，各クラス 25 サンプルずつ集音した．

- クラス 1 摩擦音 (低速) h=16 cm, a=10 cm, b=15 cm, 重さ 21.0 g
- クラス 2 摩擦音 (中速) h=17 cm, a=10 cm, b=15 cm, 重さ 21.0 g
- クラス 3 摩擦音 (高速) h=18 cm, a=10 cm, b=15 cm, 重さ 21.0 g
- クラス 4 衝突音 (小) a=10 cm, b=20 cm, 重さ 25.5 g
- クラス 5 衝突音 (大) a=20 cm, b=30 cm, 重さ 50.0 g

データセット 1 と同じく，全 5 クラスを用いたデータセット 2a と，クラス 4，5 を除いた摩擦音 3 クラスのデータセット 2b を用意した．

各サンプルはあらかじめ設定したしきい値を超えてからデータセット 1 では 32,768 点，データセット 2 では 8,192 点記録し，周波数解析 (FFT) を行った．総和 1 に正規化後のクラスごとの平均周波数スペクトルを図 3 に示す．図よりデータセット 1 はデータセット



(a) データセット 1

(b) データセット 2

図 3 各クラスの平均周波数スペクトル

Fig. 3 Average frequency spectrum of each class.

表 2 クラス内分散 (σ_W^2) クラス間分散 (σ_B^2) 比

Table 2 Ratio of within-class variance and between-class variance.

	クラス数	サンプル数	σ_W^2	σ_B^2	σ_B^2/σ_W^2
データセット 1a	5	125	0.000783	0.000241	0.308279
データセット 1b	3	75	0.000961	0.000328	0.341387
データセット 2a	5	125	0.000611	0.000699	1.144993
データセット 2b	3	75	0.000669	0.000488	0.729451

2 に比べて，スペクトルのピークが近く分類の難しいデータセットであることが分かる．さらに，各データセットの複雑度の目安としてクラス内分散・クラス間分散比を表 2 に示す．クラス内分散が小さく，かつクラス間分散が大きい (つまりクラス間分散/クラス内分散が大きい) ほど，クラス内は密集し，かつクラス間の分離性が良い単純なデータセットであるといえる．表よりおおよそ，データセット 2a>2b>1b>1a の順で単純である．

4.2 パラメータ選択

カーネル SOM において，KL カーネル，ガウシアンカーネル，およびシグモイドカーネルを用いた場合について，パラメータを変化させたときの評価値の変化をそれぞれ図 4，図 5，図 6 に示す．すべての尺度は [0,1] の範囲であり，エントロピーは小さいほど良く，その他は大きいほど良い．各パラメータでカーネル SOM の初期値をランダムに変えて 100 回試行した平均値を示している．カーネル SOM のノード数は 10×10，12×12，15×15 の 3 種類を試した．図はデータセット 1a のみ示しているが，他のデータセットに関しても

42 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

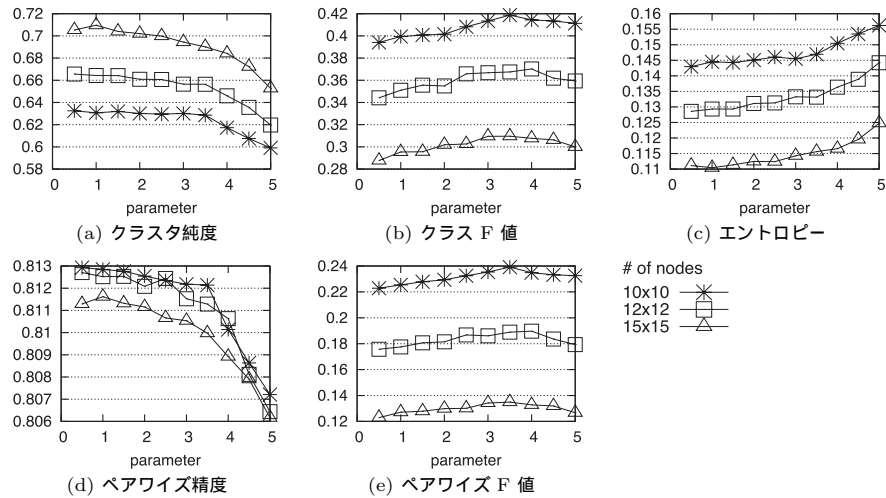


図 4 KL カーネルパラメータの影響 (データセット 1a)
Fig. 4 Effect of the KL kernel parameter (dataset 1a).

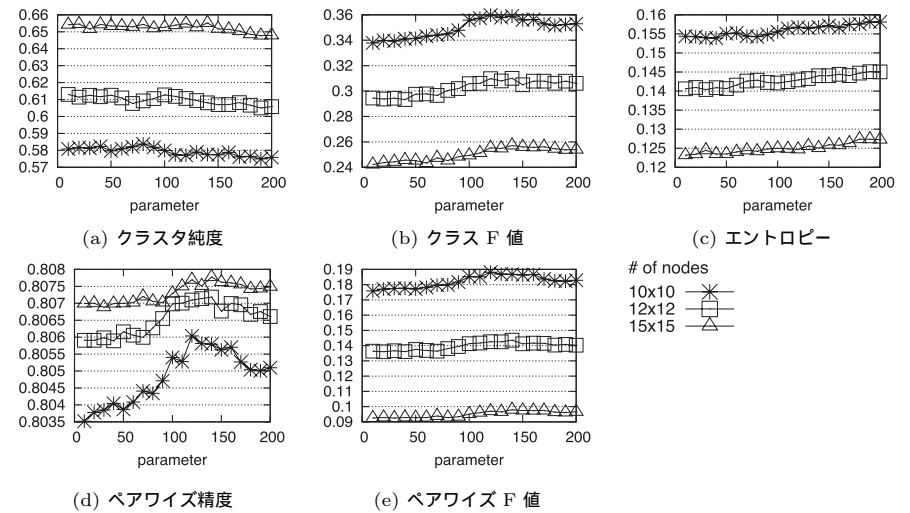


図 6 シグモイドカーネルパラメータの影響 (データセット 1a)
Fig. 6 Effect of the Sigmoid kernel parameter (dataset 1a).

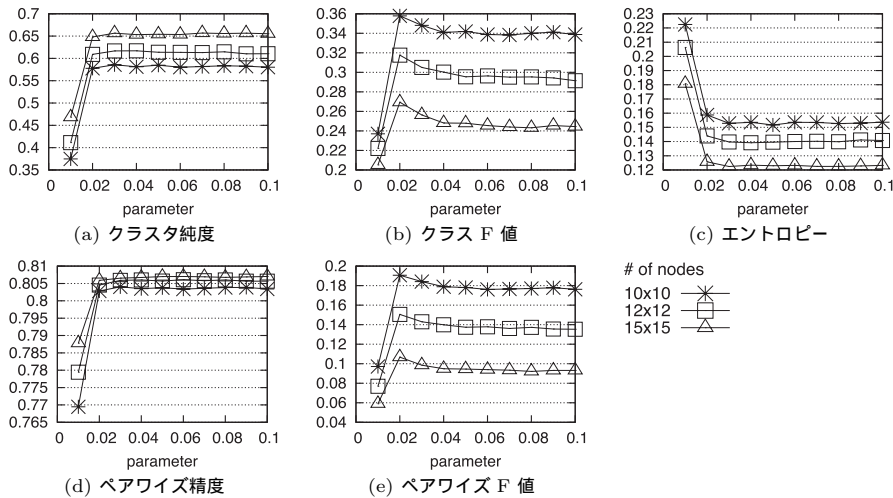


図 5 ガウシアンカーネルパラメータの影響 (データセット 1a)
Fig. 5 Effect of the Gaussian kernel parameter (dataset 1a).

同様の傾向であった。パラメータは、カーネル関数値の分散が大きくなるあたり、すなわちすべて 0 や 1 に偏っていない範囲で変化させた。

KL カーネルを用いた場合 (図 4), クラス F 値およびペアワイス F 値は増加している範囲であってもクラスタ純度, ペアワイス精度は減少し, エントロピーは増加しており, 尺度によって最適なパラメータは異なっている。そのため, 全尺度に対して最適なパラメータとして, 一般に厳しい尺度といわれる F 値を基準にしてクラスタ純度やペアワイス精度が大きく下がらない範囲でパラメータを決定した。ガウシアンカーネル, シグモイドカーネルについても同様の基準でパラメータを決定した。シグモイドカーネルを用いた場合 (図 6) は, あまり変化がなかったが, 若干 F 値の高いパラメータを採用した。このようにして決定したすべてのパラメータの一覧を表 3, 表 4 に示す。

4.3 隣接性を考慮した評価尺度の妥当性

SOM のマップ上での隣接性を考慮するように拡張したクラスタリング尺度の妥当性を検証した。よく学習された SOM はある程度隣接性が保たれていると仮定する。学習結果に対して, ニューロンごとの近傍データ点の集合は変えずに, 勝者ニューロンをランダムに入れ替えた。すなわち, クラスタ性は保ちつつ, クラスタ単位でマップ上の位置をランダムに重

表 3 データセット 1 のパラメータ設定
Table 3 Parameter settings for dataset 1.

カーネル/ノード数	データセット 1a			データセット 1b		
	10 × 10	12 × 12	15 × 15	10 × 10	12 × 12	15 × 15
KL	3.5	4.0	3.5	3.5	3.5	3.5
GS	0.02	0.02	0.02	0.02	0.02	0.02
SG	140	140	140	170	170	170

表 4 データセット 2 のパラメータ設定
Table 4 Parameter settings for dataset 2.

カーネル/ノード数	データセット 2a			データセット 2b		
	10 × 10	12 × 12	15 × 15	10 × 10	12 × 12	15 × 15
KL	4.0	4.0	3.0	2.5	3.0	3.0
GS	0.02	0.02	0.02	0.02	0.02	0.02
SG	130	130	90	70	50	30




図 7 隣接性あり/なしマップ間での評価値比較

Fig. 7 Comparison of evaluation value between a consistent and an inconsistent maps.

複なく替えることで隣接性を崩したマップを作成した。

このようにして作成した隣接性あり/なしのマップに対する拡張したクラスタリング評価値を図 7 に示す。データセット 2a に対して、KL カーネルを用いたカーネル SOM により得られた結果を用いた。隣接性を崩したマップについては、カーネル SOM によって得られた同じ結果に対して位置をランダムに替えて作成した 100 個のマップに対する評価値の平均をとった。図より隣接性を崩した場合に、すべての評価値が悪くなっていることが分かる。本実験では、クラスタ性は保ち隣接性のみを崩したことから、拡張した尺度は隣接性を

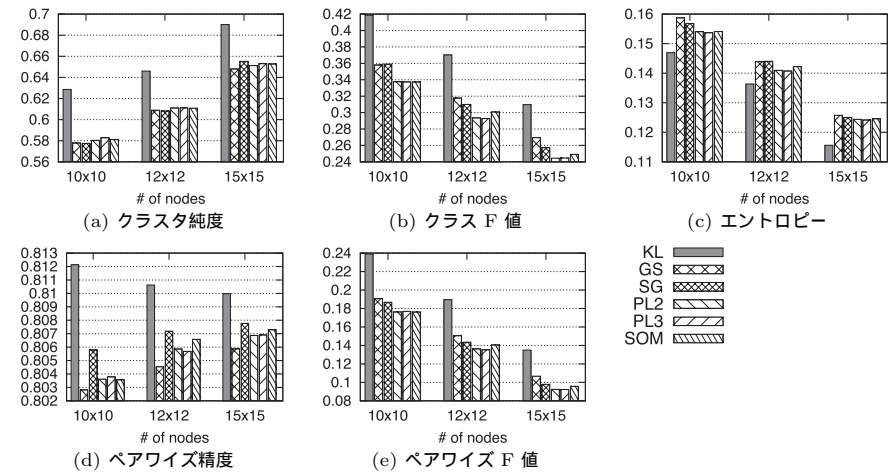


図 8 データセット 1a に対する性能評価比較

Fig. 8 Comparison of performance evaluation on dataset 1a.

とらえた尺度になっているといえる。

4.4 評価結果

各データセットに対する性能評価結果を図 8, 図 9, 図 10, 図 11 に示す。それぞれ初期値を変えた 100 回の試行の平均値を示している。GS はガウシアンカーネル, SG はシグモイドカーネル, PL2, PL3 はそれぞれ 2 次, 3 次の多項式カーネル ($p = 2, 3$) を表している。SOM のノード数が増加するに従ってクラスタ純度は増加, それ以外の尺度は減少傾向にあるため, これらの尺度は異なるノード数間で比較するものではないことに注意しておく。また, 図中の 印は同ノード数の KL カーネルを用いた場合の評価値の分布との t 検定の結果, 平均値に有意水準 5% で有意差が認められなかったことを示している。反対に 印の付いていない場合は, KL カーネルを用いた場合の平均値と有意差が認められたことを示している。

図 8~図 11 より, KL カーネル用いた SOM はクラスタ純度およびエントロピーについては, データセットによってはシグモイドカーネルおよび多項式カーネルを用いた SOM, および通常型 SOM とほぼ同等か若干下回ることもある。しかし, クラス F 値, ペアワイス精度, およびペアワイス F 値については, すべてのデータセットで最も良い性能を示している。

44 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

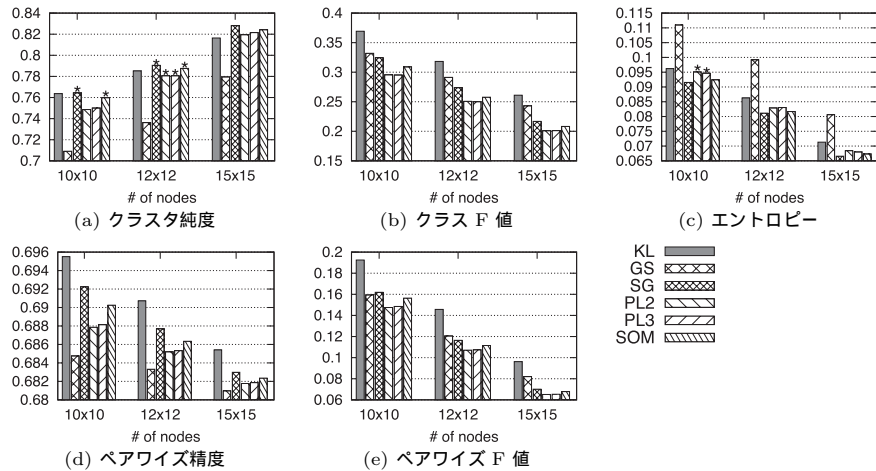


図 9 データセット 1b に対する性能評価比較
Fig. 9 Comparison of performance evaluation on dataset 1b.

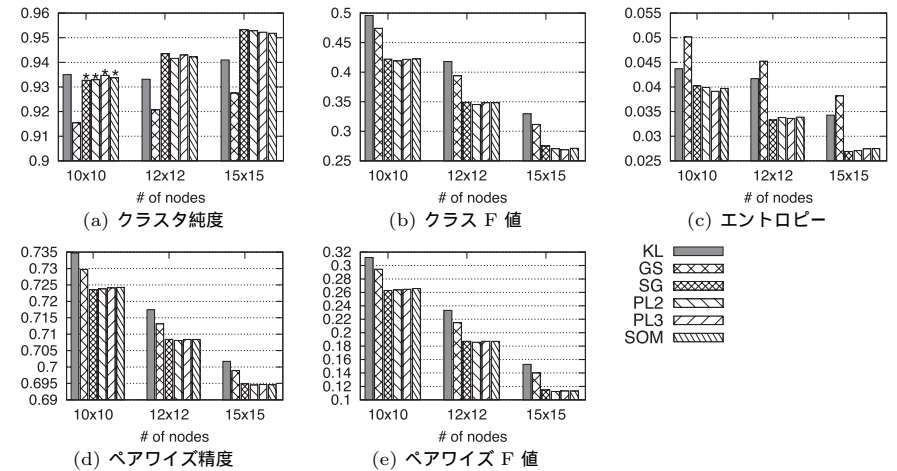


図 11 データセット 2b に対する性能評価比較
Fig. 11 Comparison of performance evaluation on dataset 2b.

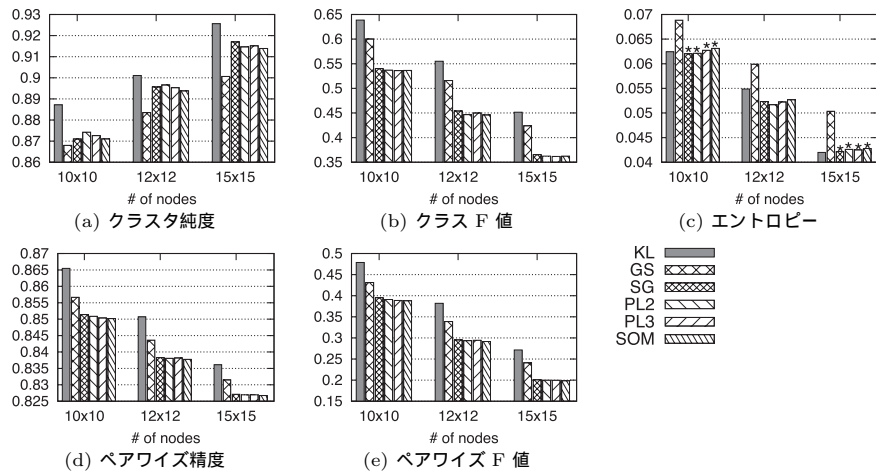


図 10 データセット 2a に対する性能評価比較
Fig. 10 Comparison of performance evaluation on dataset 2a.

4.5 可視化結果

データセット 1a およびデータセット 2a に対する可視化結果を図 12 および図 13 に示す。図はノード数 12×12 の場合のみ示しているが、 10×10 、 15×15 でも同様の傾向である。格子点は SOM のノードを表しており、また、格子点上の数字は、そのノードが勝者（最近傍）となるデータのクラスラベルの多数決により決定した代表クラスを表示している。数字が表示されていないノードは勝者となるデータがなかったことを意味している。

下段の 3 次元マップの z 軸方向は、SOM の表示法としてよく用いられる U-matrix¹⁹⁾ の考え方に基づく近傍ノードとの距離を反映した値となっている。すなわち、その値が高いほど特徴空間内で近傍ノードは分散（つまり周辺のデータも分散）しており、反対に値が低いほど近傍ノードは密集（周辺のデータも密集）していることを示している。上段の 2 次元マップはこれを上から見た図になっており濃淡と等高線で示されている。2 次元マップでは左上が (0,0)、右下が (11,11) に対応している。

通常 SOM の U-matrix 表示では、ノードに定義されている参照ベクトル間のユークリッド距離を用いるが、カーネル SOM では参照ベクトルが陽に定義されない。そのため本稿では、カーネル関数値に近傍関数を重みとして用いた次式によりノード i, j 間の距離 $ND_{i,j}$ を定義した。

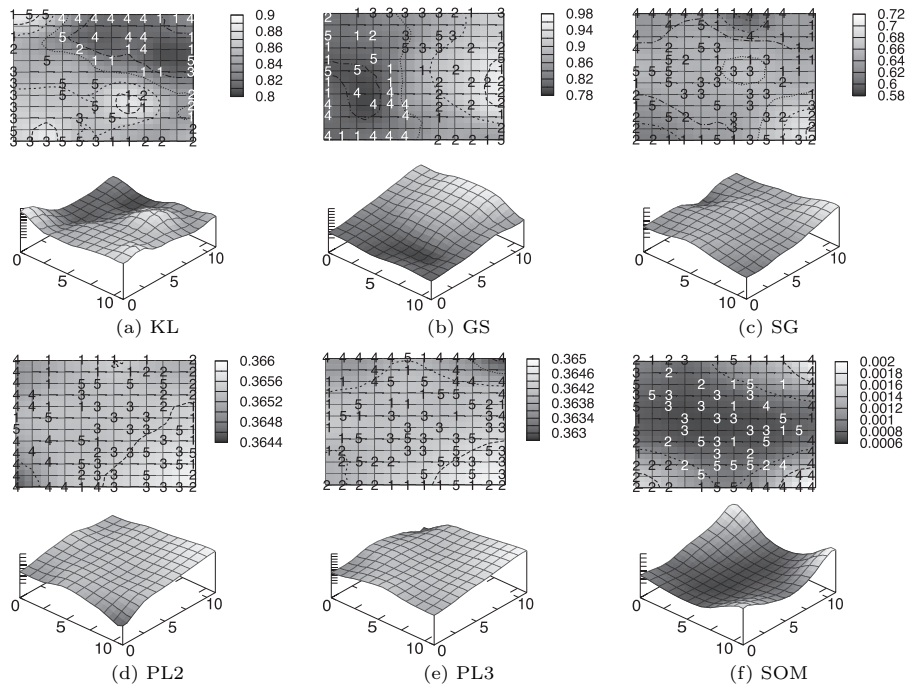


図 12 データセット 1a に対する可視化結果比較
Fig. 12 Comparison of visualized maps on dataset 1a.

$$ND_{i,j} = \sum_k \sum_l 0.25(h_{i,c(\mathbf{x}_k)} + h_{j,c(\mathbf{x}_k)} + h_{i,c(\mathbf{x}_l)} + h_{j,c(\mathbf{x}_l)})K(\mathbf{x}_k, \mathbf{x}_l). \quad (29)$$

ここで、近傍関数は式 (11) を用いたが、クラスタリング尺度の拡張のときと同様に近傍半径 σ を大きくすると全体を平滑化してしまう効果があるため、本稿では $\sigma = 1$ とした。

まず、データセット 1a の可視化結果 (図 12) については、KL カーネルおよびガウシアンカーネルを用いた SOM は、その他の場合に比べて、代表クラスが表示されているノード数が少ない。これは特徴空間内でのデータの分布に隔たりがあるためと考えられる。反対に、KL カーネルやガウシアンカーネルを用いた SOM 以外は、データが特徴空間内で隔たりが少なく満遍なく分布をしているといえる。このことは、U-matrix のノード間距離においても同様のことがうかがえる。すなわち、KL カーネルやガウシアンカーネルの場合は比

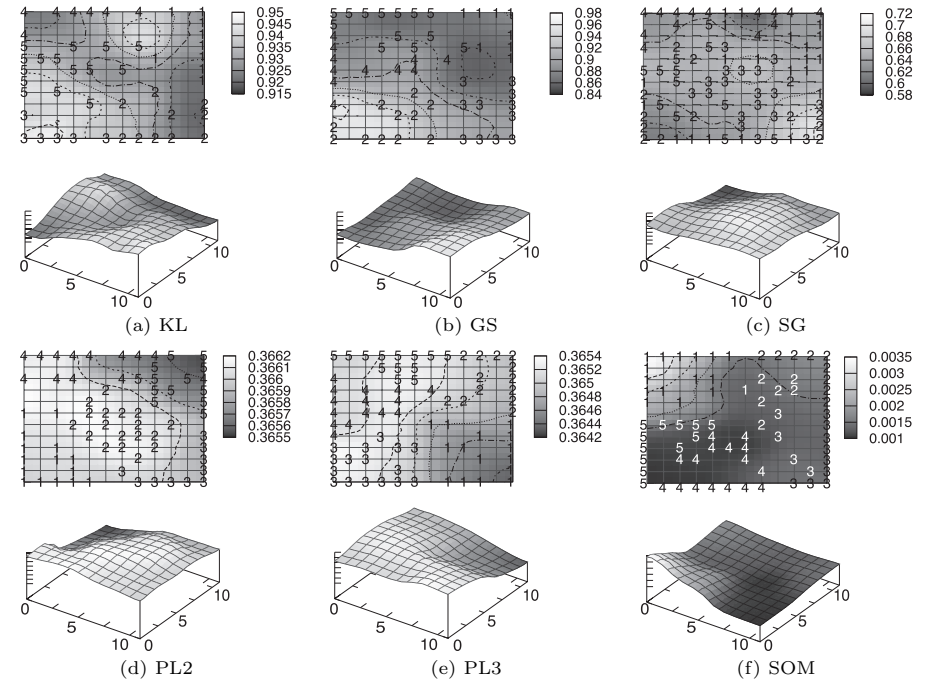


図 13 データセット 2a に対する可視化結果比較
Fig. 13 Comparison of visualized maps on dataset 2a.

較的起伏が多く、その他のカーネルの場合や通常型 SOM はなだらかな形状をしている。

データセット 2a の可視化結果 (図 13) についても同様の傾向がうかがえる。すなわち、KL カーネルやガウシアンカーネルを用いた SOM は、その他カーネルを用いた SOM や通常型 SOM に比べてデータが隔たりを持って分布している。その定量的な良さは 4.4 節で評価したところによる。

4.6 考 察

4.5 節の可視化結果からは、U-matrix 表示や代表クラスの密度から特徴空間内でのデータの分布状況を把握することができる。また、クラスの隣接性に関しては代表クラスから判断できる。しかし、代表クラスは多数決により決定した大まかな表示であるため、図 12・図 13 には明らかな違いとしては現れていないと考えられる。一方、4.4 節の定量的な評価

尺度は、代表クラスのみではなくすべてのデータ点の分布を考慮したより詳細な尺度である。また、実際の損傷評価への応用を考えた場合、SOM によって得られたマップを基盤として、対象領域の専門家は個別の AE 信号に関して領域固有の分析を行うことを想定している。その意味では、代表クラスのみでの評価では不十分である。ゆえに、隣接性を考慮した定量評価によりに精度が保証された可視化結果が図 12・図 13 であると考えられる。

また、4.4 節の定量評価では、データセット 1b および 2b に対して KL カーネルを用いた SOM は、クラスタ純度およびエントロピーに関して他より劣っている場合があった。しかしながら、クラスタ純度とエントロピーは、個別のクラスタの純度やエントロピーの平均（幾何平均）をとっている。そのため、通常型 SOM の結果のように満遍なく分布している場合、すなわち密集度合いが高くない場合でも、個々のクラスタの純度が高く、またエントロピーが低ければ、全体として良い値となってしまう。一方、F 値ベースのクラス F 値およびペアワイズ F 値は、クラスタ内での異なるクラスの分離度合い (Precision), ならびにマップ上での同じクラスの密集度合い (Recall) を同時に要求される尺度である。

クラス F 値ならびにペアワイズ F 値はともに、どのカーネルを用いた場合でも、また通常型 SOM の場合でも、Precision は 0.95 以上でありほとんど差が見られなかった。一方、クラスの密集度合いを表す Recall は KL カーネルとガウシアンカーネルを用いた場合に他と比べて高い傾向にあった。このことは、4.5 節の可視化結果において、同じ代表クラスが広く分布しておらず、その分密集していることにも現れている。しかし、ガウシアンカーネルを用いた場合は、クラスの密集度合いは良いため F 値ベースの指標では KL カーネルの場合に次いで高くなっているが、個々のクラスタの中身の純度およびエントロピーは総じて悪い傾向にあった。一方、KL カーネルを用いた SOM は、ガウシアンカーネルの場合ほど純度やエントロピーを落とすことなく、マップ上で同じクラスの高い密集性も実現しているといえる。

5. おわりに

本稿では、損傷に関わる AE 信号の模擬データに対する Kullback-Leibler カーネルを用いたカーネル SOM の性能評価を行った。複数の模擬データを用いて、一般に用いられているガウシアンカーネル、シグモイドカーネル、多項式カーネルを用いた SOM、および通常型 SOM と比較して以下の結果を得た。

- クラス F 値、ペアワイズ精度、ペアワイズ F 値の観点で KL カーネルを用いた SOM は最も良い性能を示した。特にクラス F 値、ペアワイズ F 値は他を大きく上回った。

- クラスタ純度およびエントロピーに関しては、シグモイドカーネルおよび多項式カーネルを用いた場合や通常型 SOM と同等もしくは若干劣る結果となったが、ガウシアンカーネルほど劣化はしていない。
- U-matrix 表示による可視化の結果、KL カーネルおよびガウシアンカーネルを用いた SOM は、特徴空間内でデータが隔たりを持って分布していることが分かった。

以上より、損傷に関係する音データに対して KL カーネルを用いた SOM は、他のカーネルを用いた場合や通常型 SOM と比較して、純度やエントロピーをそれほど落とすことなく F 値に基づく観点で精度が良い可視化を行うことができると結論付けられる。すなわち、個別のクラスタ内で異なるクラスの分離性が良く、かつ同じクラスが密集した可視化ができる。しかしながら、実際に正解ラベルのないデータに適用する場合、パラメータ選択の課題が残る。

また、新たに定義した隣接性を考慮した SOM の評価尺度は、損傷に関係する音データに限らず正解クラスラベルを持つデータセットであれば適用できる。本稿では、クラスタ性を保ち隣接性を崩した場合にすべての評価尺度が悪化することを示すことにより、隣接性を考慮した評価尺度の妥当性を検証した。しかしながら、公開データセットを用いたさらなる検証が必要である。

謝辞 本研究は文部科学省特別教育研究経費（新産業創造物質基盤技術研究センター）、関西エネルギー・リサイクル科学研究振興財団若手奨励研究（2008R020）、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) Kohonen, T.: *Self-Organizing Maps*, Springer-Verlag (1995).
- 2) Jain, A.K., Murty, M.N. and Flynn, P.J.: Data Clustering: A Review, *ACM Computing Surveys*, Vol.31, No.3, pp.264–322 (1999).
- 3) Tenenbaum, J.B., Silva, V. and Langford, J.C.: A Global Geometric Framework for Nonlinear Dimensionality Reduction, *Science*, Vol.290, pp.2319–2323 (2000).
- 4) Roweis, S. and Saul, L.: Nonlinear Dimensionality Reduction by Locally Linear Embedding, *Science*, Vol.290, pp.2323–2326 (2000).
- 5) 仲佐博裕：アコースティックエミッションの理論と実際，地人書館（1994）。
- 6) Rippengill, S., Worden, K., Holford, K.M. and Pullin, R.: Automatic Classification of Acoustic Emission Patterns, *Journal for Experimental Mechanics: Strain*, Vol.39, No.1, pp.31–41 (2003).
- 7) Godin, N., Hugué, 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).

- 8) Omkar, S.N. and Karanth, U.R.: Rule Extraction for classification of acoustic emission signals using Ant Colony Optimisation, *Engineering Applications of Artificial Intelligence*, Vol.21, pp.1381–1388 (2008).
- 9) 赤穂昭太郎：カーネル多変量解析，岩波書店 (2008)。
- 10) 井口 亮，宮本定明：カーネル関数を利用した LVQ クラスタリングと SOM，*日本知能情報ファジィ学会誌*，Vol.17, No.1, pp.88–94 (2005)。
- 11) Lau, K.W., Yin, H. and Hubbard, S.: Kernel Self-Organising Maps for Classification, *Neurocomputing*, Vol.69, pp.2033–2040 (2006).
- 12) 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).
- 13) 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.90, No.10, pp.2787–2797 (2007)。
- 14) Fukui, K., Sato, K., Mizusaki, J., Saito, K. and Numao, M.: Combining Burst Extraction Method and Sequence-based SOM for Evaluation of Fracture Dynamics in Solid Oxide Fuel Cell, *Proc. 19th IEEE International Conference on Tools with Artificial Intelligence (ICTAI)*, pp.193–196 (2007)。
- 15) 赤崎省悟，福井健一，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 を用いた波形信号のスペクトル形状を考慮したクラスタリングと可視化，第 21 回人工知能学会全国大会論文集 (2008)。
- 16) 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*, Vol.16, pp.1385–1392 (2003)。
- 17) Veenhuis, C. and Koppen, M.: Data Swarm Clustering, *Swarm Intelligence in Data Mining*, Abraham, A., Grosan, C. and Ramos, V., (Eds), Chapter 10, pp.221–241, Springer-Verlag (2006)。
- 18) Xu, R. and Wunsch II, D.C.: *CLUSTER VALIDITY, CLUSTERING*, Series on Computational Intelligence, Chapter 10, pp.263–278, IEEE Press (2008)。
- 19) Ultsch, A. and Siemon, H.P.: Self-Organizing Feature Maps for Exploratory Data Analysis, *Proc. International Neural Network Conference (INNC)* (1990)。

(平成 21 年 8 月 13 日受付)

(平成 21 年 9 月 30 日再受付)

(平成 21 年 10 月 22 日採録)



福井 健一 (正会員)

2001 年名古屋大学情報文化学部自然情報学科中退。2003 年名古屋大学大学院人間情報学研究所物質・生命情報学専攻修士課程修了。2005 年より大阪大学産業科学研究所新産業創造物質基盤技術研究センター特任助手。現在，同センター特任助教。IEEE International Conference on 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。



赤崎 省悟

2008 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修士課程在学中。人工知能学会学生会員。



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。



森山 甲一

1998年東京工業大学工学部情報工学科卒業。2003年同大学院情報理工学研究科計算工学専攻博士課程修了。博士(工学)。同年同専攻助手。2005年大阪大学産業科学研究所助手。2007年同助教。現在に至る。人工知能、特にマルチエージェントシステムにおける強化学習の研究に従事。人工知能学会、電子情報通信学会各会員。



栗原 聡

1992年慶應義塾大学大学院理工学研究科計算機科学専攻修士課程修了。同年日本電信電話株式会社入社。基礎研究所を経て未来ねっと研究所に所属。2004年から大阪大学産業科学研究所知能システム科学研究部門准教授(同大学大学院情報科学研究科情報数理学専攻准教授兼務)。マルチエージェント、ネットワーク科学等の研究に従事。著書『社会基盤としての情報通信』(共立出版,共著)。翻訳『スモールワールド』(東京電機大学出版局,共訳)等。博士(工学)。人工知能学会、日本ソフトウェア科学会、電子情報通信学会、ESHIA 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。