

特別講演

材料に入りて情報にテーマかえ併せまとめて結果となせり

徳高 平蔵

鳥取大学名誉教授、(有) SOM ジャパン SOM 工学研究センター
〒 680-8552 鳥取市湖山町南 4 丁目 101, 鳥取大学工学部
tokutaka@ele.tottori-u.ac.jp

(2003 年 7 月 3 日受理)

表面分析研究会が VAMAS 委員会と呼ばれて発足した第 1 回から参加している。本年 3 月に長らく勤務した鳥取大学を定年退職した。第 21 回研究会 (宇都宮) で特別講演をさせて頂いた。私は 40 年前に薄膜・表面の分野に入った。現在は、人間の脳のアルゴリズムに基づいた自己組織化マップ (SOM) の分野に入りデータの棲み分けにこの可視化情報処理の方法を使用している。ここではスペクトル分析も含め、我々の研究室で行った例をいろいろと紹介した。

**From material research to information processing, I have
shifted my research projects.**

After all, altogether, several useful results were drawn out there.

Heizo TOKUTAKA

*Tottori University Professor Emeritus
SOM Japan Co. Ltd. SOM Engineering Research Center, General Director*

(Received: July 3, 2003)

The surface analysis society was called VAMAS committee in the beginning. I was participating from the first. I have retired in March this year from Tottori University where I have worked for long 32 years. I have made a special lecture in the 21st research meeting (Utsunomiya, Japan). I entered the field on a thin film and the surface 40 years ago. Now, I belong to the field of Self-Organizing Maps (SOM) based on the algorithm of man's brain. This visible information processing method is a means which is very effective to classification of the obtained various data. Here, chemical spectrum analysis is also included. Moreover, the various examples carried out in our laboratory are introduced.

1. まえがき

私の薄膜、表面の研究生活は 1960 年に松下電器産業 (株) に入社したときから始まる。1965 年に

都島にあった旧阪大工学部でダヴィソン・ガーマーの電子波の発見で有名なガーマー先生が超高真空中での低速電子線回折 (LEED) の実験結果を発表された。Ni のガス反応表面の LEED 写真の見事さに大変に感銘を受けた。しばらくして私は松下電器を退

社し、英国のヨーク大学に留学したが、そこで、LEED の実験を開始した。1968年、米国に出張したブルトン先生が LEED-AES の実験が米国で始まったことを仕入れてきた。表面研究にとって 60 年代後半は大変な時代でそこに遭遇したことは私にとって正に幸運であった。1971年に鳥取大学にお世話になってからは表面研究に的を絞って LEED, AES 実験をテーマとして来た。そして AES の定量分析が縁で、ニューロコンピューティングの世界に入り、現在は自己組織化マップ (SOM) [1,2] による多次元情報の 2 次元可視化に研究テーマを移している。この SOM 法により、AES, XPS のスペクトルの分類ができることが明らかになった。ここでは、我々の研究室で応用した結果を述べる。色々な応用事例集は参考文献を参照されたい [3,4]。

2. は SOM アルゴリズムについて述べる。3. では SOM 法の化学スペクトルデータへの応用。4. では同じスペクトルデータの応用として脈波診断データへ適用した。5. ではエクセルデータの 2 次元可視化の例として健康診断マップについて述べる。6. では 1 次元 SOM の典型的な応用例として巡回セールスマン問題への適用。7. ではその応用としてチップマウンタの最適化である。8. では我々の結果ではないが遺伝子情報への応用例を述べる。9. はまとめである。

2. SOM アルゴリズム

2.1 アルゴリズム

コホネン [1,2] は、生物の神経細胞、主として脳の情報処理の仕方を以下のような簡単な式にまとめて整理した。

$$\mathbf{m}_i(t+1) = \mathbf{m}_i(t) + h_{ci}[\mathbf{x}(t) - \mathbf{m}_i(t)] \quad (1)$$

この式の意味は、いま神経細胞（ノード） i が時刻 t で処理している情報処理能力を $\mathbf{m}_i(t)$ とするとき、外部から入力信号 $\mathbf{x}(t)$ が入ってきた。細胞は、この入力信号を学習して次の時刻には入力信号により近い情報処理能力 $\mathbf{m}_i(t+1)$ を持つようになる。この時 $\mathbf{x}(t)$ が n 次元の入力ベクトルであれば、また、参照ベクトルとも呼ばれる $\mathbf{m}_i(t)$ は同じ n 次元の要素を持つ。そして、 $h_{ci}(t)$ は学習率係数を含めた近傍関数を意味し後で考察する。なお、 $t = 0, 1, 2, \dots$ は離散時間座標である。競合層のベクトルは参照ベクトル $\mathbf{m}_i(t)$ で表され、入力層の次元に合わせて n 個の要素を持っている。出力を

視覚的に見るため普通 2 次元に配列されている。この様子を図 1 に表す。

入力ベクトル $\mathbf{x}(t)$ は、ある測度、例えばユークリッド距離 $|\mathbf{x}(t) - \mathbf{m}_i(t)|$ を最小にするノード i を探し、それに添え字 c を付ける。

$$|\mathbf{x}(t) - \mathbf{m}_c(t)| = \min |\mathbf{x}(t) - \mathbf{m}_i(t)| \quad (2)$$

式 (2) で決められた参照ベクトル $\mathbf{m}_c(t)$ を持つユニットを勝者ユニットと呼ぶ。式 (1) 及び式 (2) での学習の様子を図 2 を用いて説明する。まず入力信号が提示されると、その信号に一番近いユニットが勝者となる。そして勝者の回りに囲った正方形の領域を近傍領域と定義する。その形は正方形でもよいが、基本のユニットの配列を 6 角形の形にとれば 6 角形近傍となる。式 (2) で決められた勝者の回りに近傍が定義される。近傍内の全てのユニットは入力ベクトルを学習するため、式 (1) に従って入力ベクトルの方向に少し動く。この学習を繰り返しあこなう。この時、近傍の大きさは最初大きく取っておき、徐々に学習と共にそのサイズを減らしていく。

さて、式 (1) による学習中、近傍 N_c 内のノードに関しては、 $h_{ci}(t) = \alpha(t)$ で、 N_c 外のノードに関しては、 $h_{ci}(t) = 0$ である。つまり、近傍の外側のユニットは学習しない。

結局、近傍関数は次式で表される。

$$i \in N_c \text{ では, } h_{ci}(t) = \alpha(t)$$

$$\text{以外では, } h_{ci}(t) = 0 \quad (3)$$

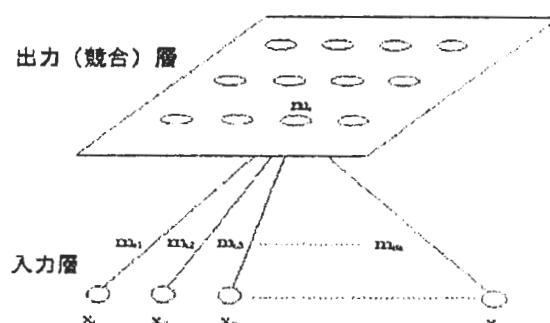


Fig.1 Appearance of uniting with single reference vector (unit) in two-dimensional competition layer from multi-dimensional input vector.

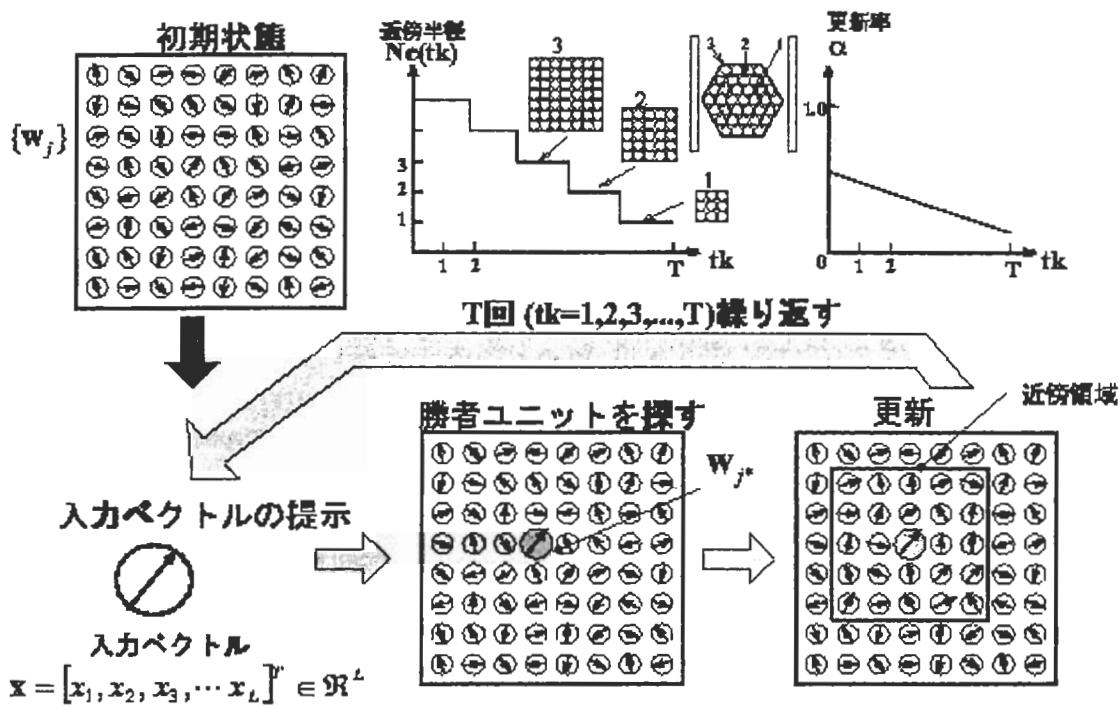


Fig.2 Explanation of the learning of Self-Organizing Maps.

この時、 $\alpha(t)$ の値を学習率係数と呼び、 $0 < \alpha(t) < 1$ で値を持つ。 $\alpha(t)$ と N_c の大きさは両方とも学習時間が経つにつれて普通、単調減少させる。 $\alpha(t)$ は例えば次の式で定義しても良い。

$$\alpha(t) = \alpha_0(1 - t/T) \quad (4)$$

ここで、 α_0 は、 α の初期値であり普通 $0.2 \sim 0.5$ の値を選ぶ。 T は行われるべき学習での予定された全更新学習回数である。ただし、式(1)中、比例係数の $\alpha(t)$ は、学習の始めでは大きな値を取るようにし、学習が進んでくるとだんだんと小さい値に設定する。又、近傍領域 $N_c = N_c(t)$ も式(3)と同様に減らしていくても良い。つまり、

$$N_c(t) = N_c(0)(1 - t/T) \quad (5)$$

ここで、 $N_c(0)$ は初期値である。

コホネンの SOM アルゴリズムを整理すると以下のようになる。

- 1 入力ベクトルと最も良く一致する競合層での勝者ユニット（参照ベクトル）を探す。
- 2 この勝者ユニットの近傍のユニットを式(1)に従って更新する。学習（更新回数）が進むにつ

れて、近傍のサイズを減らし、また学習率係数の値も例えば式(4)のようにして減らしていく。

以下に実際の例で上のアルゴリズムを調べて見よう。

2.2 動物マップの場合

多次元入力から 2 次元 SOM マップを作成する例として表 1 の例を考えて見よう。これは色々な動物をそれぞれ 16 次元の属性で区別する。各属性は有れば 1、無ければ 0 の値を持つ。つまり、各動物はそれぞれ 16 次元の入力ベクトルを持つ。このデータ集合を用いて作成した自己組織化マップの一例は図 3 に示される。図から分かるように 16 種類の動物は、一般的に知られている分類に従ってクラスタが形成されている。例えば、鳥類は右側に、狩猟者である「トラ (tiger)」、「ライオン (lion)」、「オオカミ (wolf)」は左側に、草食動物である「シマウマ (zebra)」、「ウマ (horse)」、「ウシ (cow)」は左上側にそのクラスタが形成されている。

Table 1. 16 kind of animals and the 16 attribute values.

	ハト	メドリ	アヒル	ガチョウ	クロウ	タカ	ワシ	キツネ	イヌ	オカミ	ネコ	トラ	ライオン	ウマ	シマウマ	ウシ
1小さい	1	1	1	1	1	1	0	0	0	0	1	0	0	0	0	0
2中くらい	0	0	0	0	0	0	1	1	1	1	0	0	0	0	0	0
状態 3大きい	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1
4夜行性	0	0	0	0	1	0	0	0.5	0	1	0.5	0.5	0	0	0	0
52本足	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0
64本足	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1
所有 7髪あり	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1
8有蹄類	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1
9タテガミ	0	0	0	0	0	0	0	0	0	1	0	0	1	1	1	0
10羽あり	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0
11縞あり	0	0	0	0	0	0	0	0	0	0	0	1	0	0	1	0
12狩猟	0	0	0	0	1	1	1	1	0	1	1	1	1	0	0	0
傾向 13走る	0	0	0	0	0	0	0	0	1	1	0	1	1	1	1	0
14飛ぶ	1	0	1	1	1	0	0	0	0	0	0	0	0	0	0	0
15泳ぐ	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0	0
食生活 16草食性	0.5	0.5	0.5	0.5	0	0	0	0	1	0	0	0	0	1	1	1

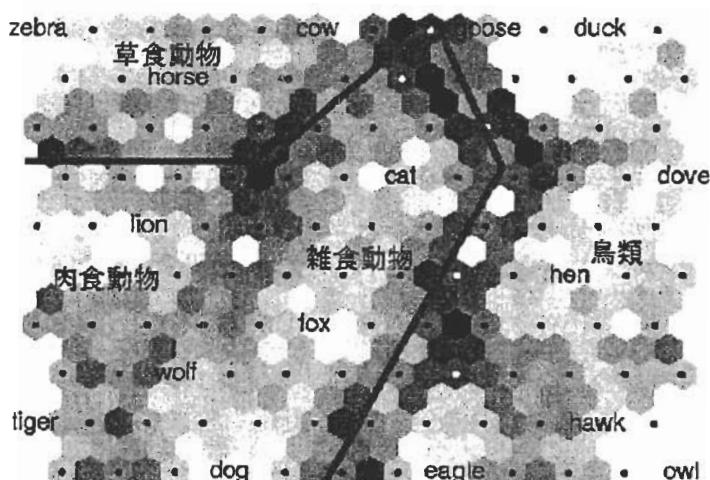


Fig.3 Animal map made by using a plane SOM.

3. 化学分析データへの応用

3.1 フルスキャンAESデータ分類へのSOMマップの応用 [5,6]

前節の動物マップの結果を図4のAESグラフに示される化学分析の問題に適用してみよう。前節の場合では、16次元の表であるが、AESでは、水平軸上のエネルギーステップが次元として考えられる。

ここでは、図4のすべてのAESデータは1eVステップで20eVから982eVまでの範囲で測定されている。したがって、各スペクトルは963次元の入力ベクトルである。ここではたまたま、10eVづつでデータをサ

ンプリングし、100次元のデータとした。垂直軸は0と1の間で正規化されているスペクトルデータであるので前節の動物マップの場合とは少し趣が異なる。前節と同じようにグレースケールで表されている。ここでも色が濃くなればなるほど、ノード間の距離が大きい。図から分かるようにCoNi合金は他の金属とはつきりと区別されており、また、Ni, 100%からCo100%まで系統的に変化していることが分かる。

3.2 ラウンド・ロビン・データを用いたSOMによる定量分析 [7]

図4のAESデータのCoNi合金の領域にSOM法を適用する。この場合、CoNi合金からのLMM信号感度を上げるために大きいバックグラウンドを高エネルギー領域から線形に差し引いた。バックグラウンドは590eVから890eVまでの間で差し引かれた。幸いにも、6個のCoNi合金のスペクトルが得られている。したがって、合金組成は正規化して0~1の間の数字で表し、これも、新しい次元として加えられている。例えば、CoNi合金で、Ni 50%で表わされるときは0.5である。結局最終的な次元は組成を表す1次元と590eVから890eVまでのAESスペクトルの1eVエネルギーステップでの301次元を併せて合計302次元になる。

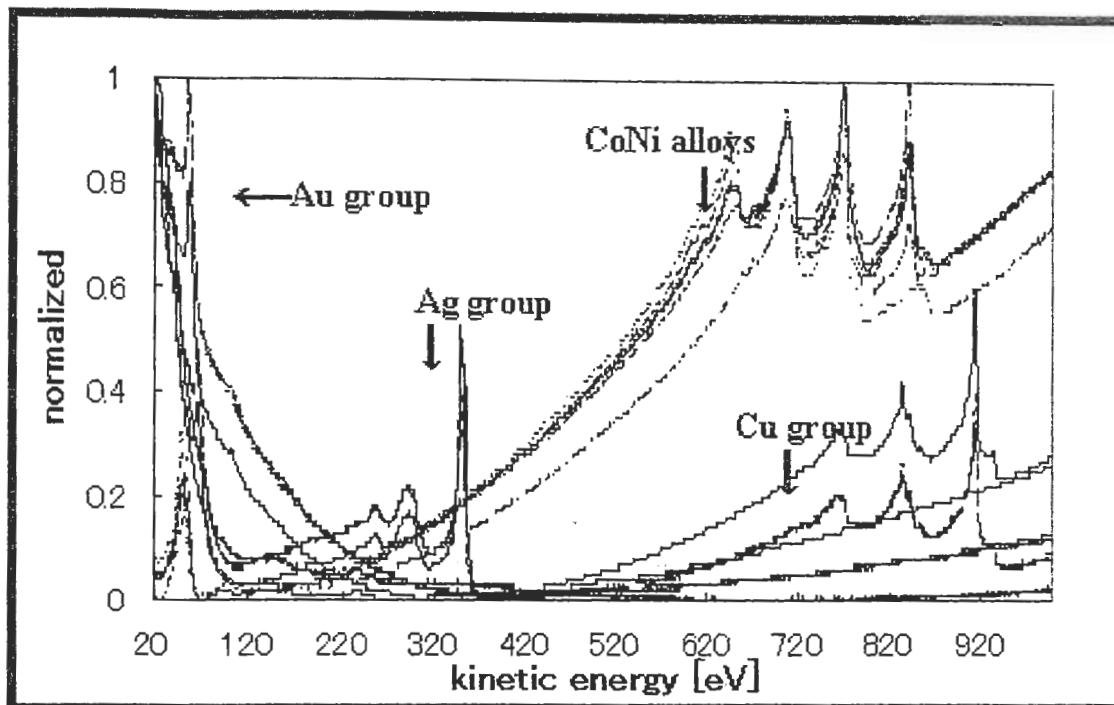


Fig. 4 AES data in the energy range of 20-982 eV from 15 samples.

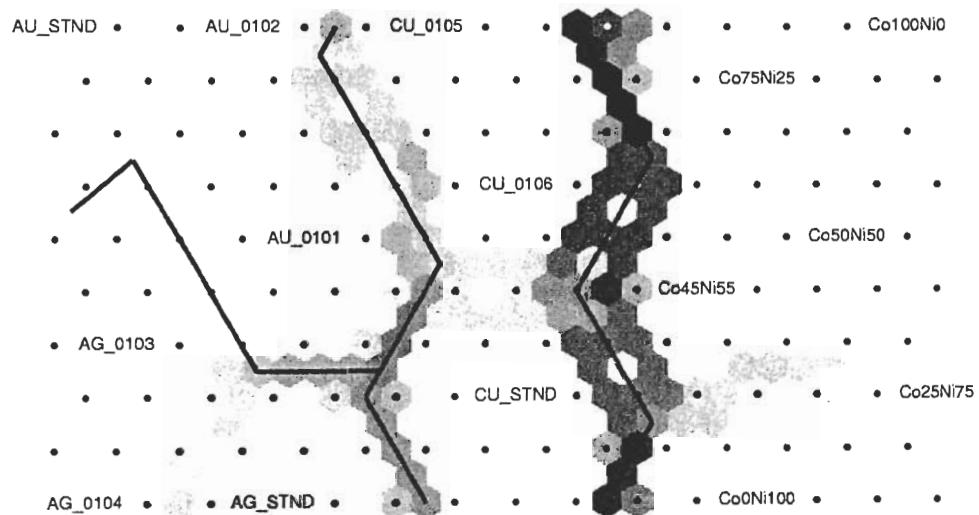


Fig.5 SOM map which was made using 15 AES data in Fig. 4

ここでは、同一のサンプルを使っての色々な研究所で得られた CoNi 合金のスペクトル、いわゆるラウンド・ロビンのデータを使用して前節で展開した議論及び実験が成り立つかどうかを調べた。同一のサンプルを使って、例えば、A, B, C の 3 つの研究所から得

られたスペクトルを Co45Ni55 の組成に限って 3 つの研究所のデータと一緒にしたものを見たところ、このように生のデータは見た目に非常に違つて見える。ここで、バックグラウンドを差し引き、信号の最大値、

Fig. 6 The data of the alloy of Co45Ni55 is used. AES spectrum data obtained by three laboratories (A, B, and C) are shown and compared.

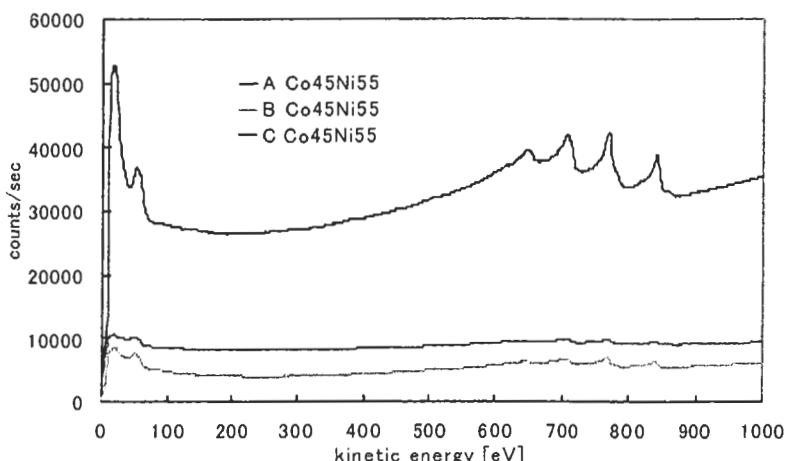


Fig. 7 The linear background is pulled from the data of Fig. 6. Then, the data is normalized and the obtained result is shown.

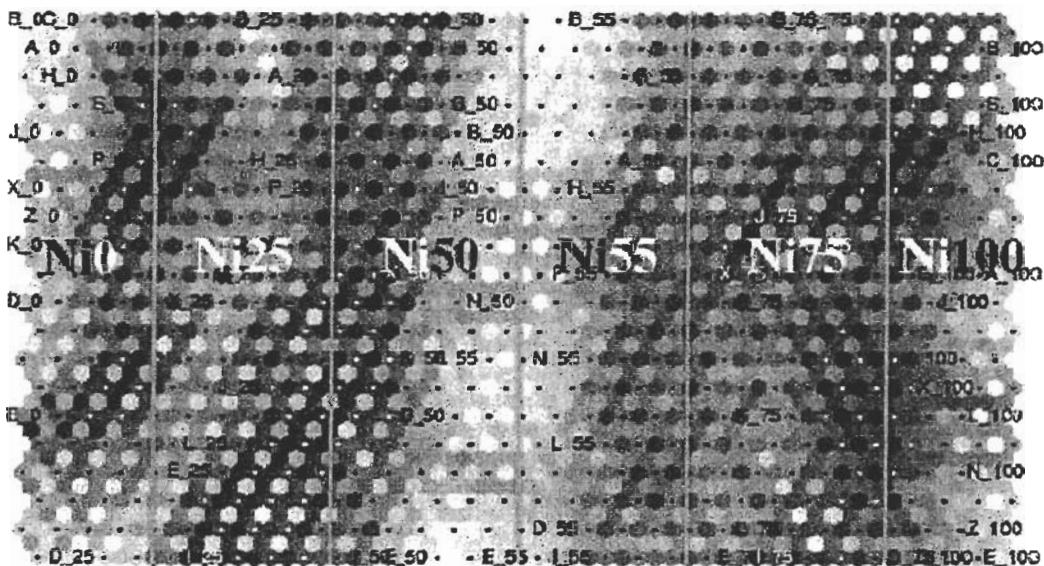
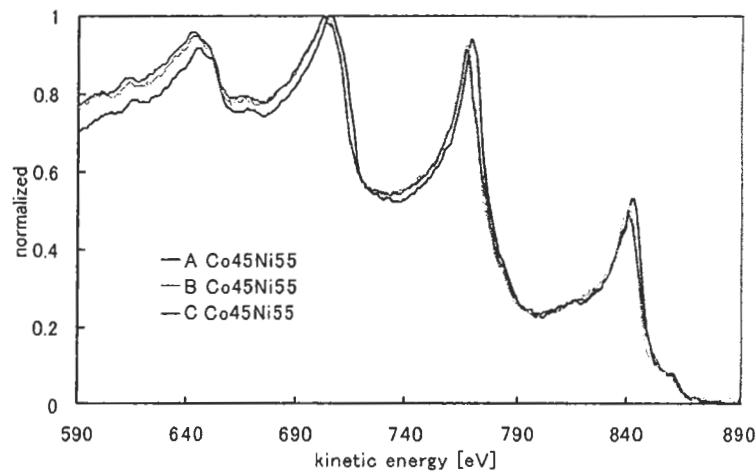


Fig. 8 SOM map made from 90 round robin data in total where six kinds of CoNi alloys (Ni 0, 25, 50, 55, 75, 100 %) from 15 laboratories were used. In the neighborhood function, the size of (bubble) was used. The map size was 20 x 30 and the study frequency were 20,000 times. It is horizontally separated from Ni0 to Ni100%. Moreover, each laboratory is separated to the vertical direction.

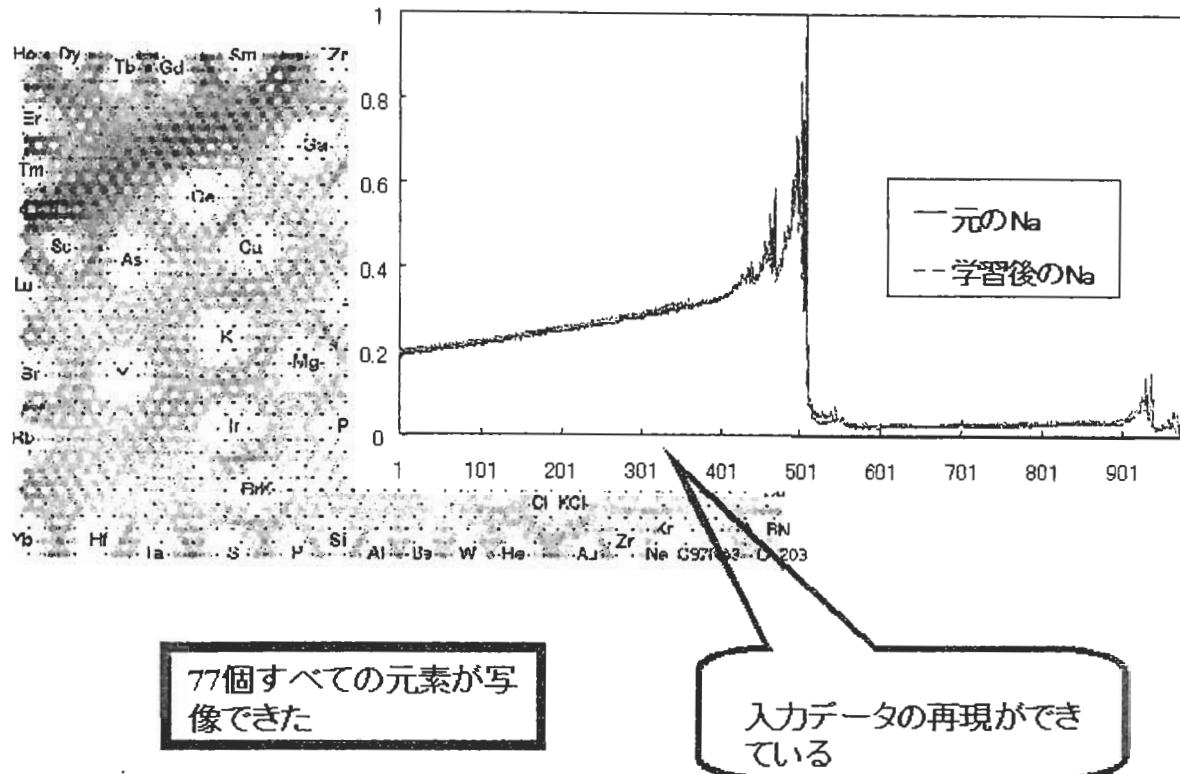


Fig.9 SOM map which uses XPS spectra from 77 elements. It is understood that the Na spectrum after learning is very close to the original Na spectrum as shown in the figure.

最小値を用いて規格化した結果を図7に示すが、ほぼ似通ったスペクトルを示すようになった。

さて、1研究所当たり6個の合金のデータを出し15研究所からのデータ合計90個でSOMマップを作成した。結果を図8に示す。図にガイドラインで示すように組成ごとに分類されていることが分かる。また、良く注意してみると、Bのラベルの研究所はマップの全て上側にあったが、D研究所はこれも組成を通して下側にありマップの上下で研究所ごとに分かれているのが観察される。

3.3 XPSデータへの応用

アルバックファイの田中氏より頂いた77個のXPSスペクトルを学習した。これも1eVづつで1~1000eVの1000次元のデータである。作成したマップを図9に示す。77元素がきれいに区分けされているのが分かる。ちなみにNa元素の入力スペクトルを代入するとマップから返された図はほぼ入力スペクトルと同じ形で、Naの領域からNaであると答えを返してきた。

4. 脈波解析への応用

脈波は、動脈の硬化度や老化度を簡単に測定できる方法として現在、注目されている。血管がふくらむことによって血管の内径は変化し、その波動を容積脈波という。容積脈波を1次微分形とした波形を速度脈波、更に速度脈波を微分して、2次微分形とした波形を加速度脈波[8,9]という(図10参照)。加速度脈波は、波形の起伏にとぼしい容積脈波に対して、波形の山が強調され、波形の評価が容易となる。現在、診断に用いる波形は、加速度脈波であり、医師は変曲点の位置により目視もしくは血管年齢算出式により脈波の評価分析をする。ここでは、脈波の時系列連続データを自己組織化マップを用いて分析するシステム[10]を提案する。

得られた加速度脈波の5周期について適切に前処理し(正規化など)、その加工後のデータを用いて自己組織化マップを作成した。これらの脈波は医師によりAからGの7種類の形状(佐野・小山内法[8,9]に

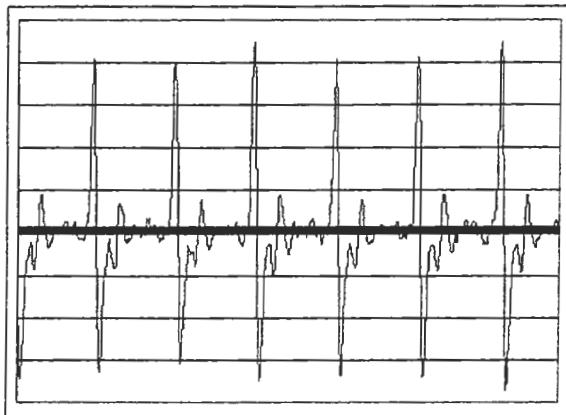


Fig. 10 One example of acceleration pulse wave which is made from the second differentiation of the original pulse wave.

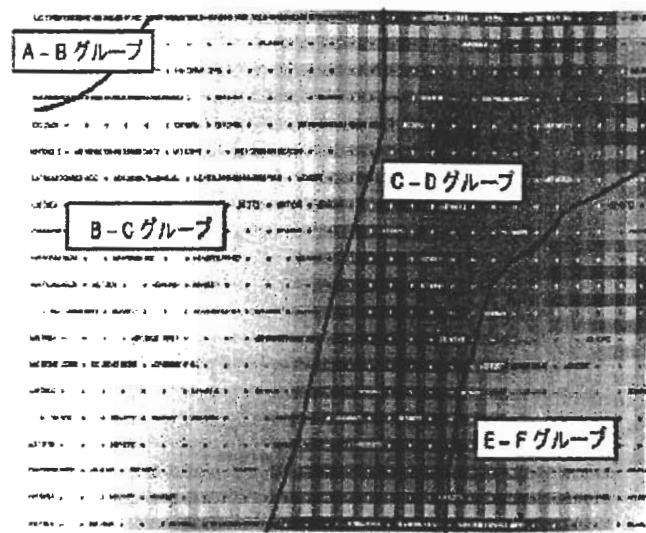


Fig. 11 A Self-Organizing Map of the first layer (the first layer pulse wave map).

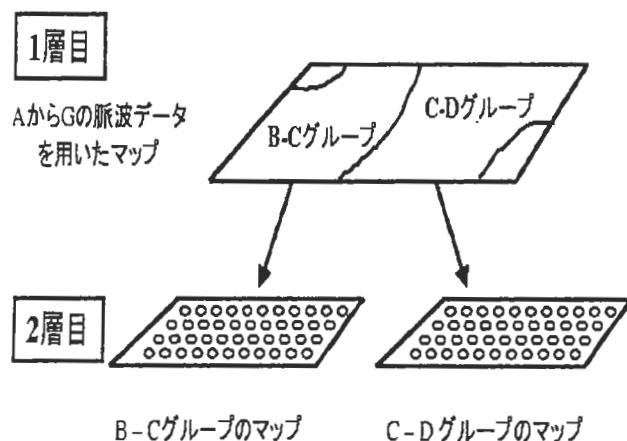


Fig. 12 System configuration of Self-Organizing Map with layered structure.

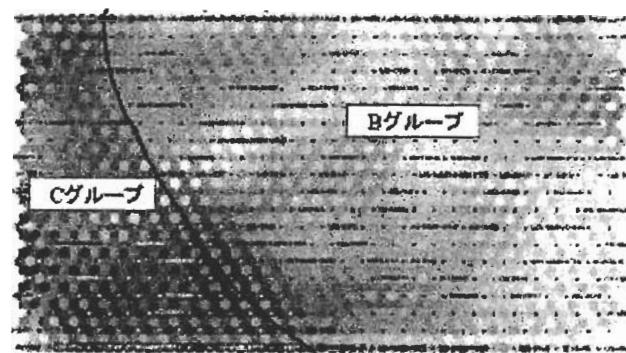


Fig. 13 Self-Organizing Map of the second layer (classified B-C pulse wave map)

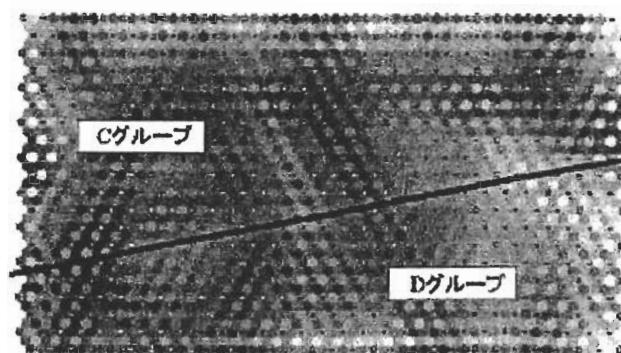


Fig. 14 Self-Organizing Map of the second layer (classified C-D pulse wave map).

よる分類)に判別されている。ラベルはAが最も健康状態が良く、Gが最も悪い波形とされている。

約300人分のデータを用いて加速度脈波分類のための自己組織化マップを作成した。作成したマップを図11に示す。得られたマップはA-Bグループ、B-Cグループ、C-Dグループ、E-Fグループの大まかな分類が可能であった。そこで、図12のようにBとCのデータのみから得られた自己組織化マップとCとDデータのみから得られた自己組織化マップから構成される階層構造を考えた。B-Cの細分類のために作成したマップは図13のようになり、完全ではないがBとCを分類することが可能である。また、C-Dの細分類のために作成したマップは図14のようになり、

同様に C と D を分類することができる。このように階層構造を用いることにより、A, B, C, D の4つの形状に分類することが可能となった。

5. 健康診断データの適用例 —平面と球面位相のSOM—

Table 2 Normal value according to each inspection item.

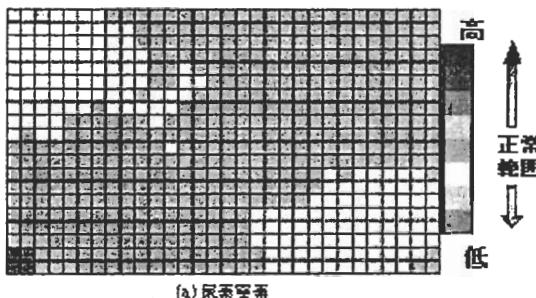
項目	正常値	項目	正常値
BMI	19.8~24.2	GOT	<39
血圧上	100~139	GPT	<39
血圧下	<89	γ -GTP	<34
総コレステロール	150~199	CHE	100~299
LDLコレステロール	<119	HbA _{1c}	<5.5
HDLコレステロール	40~99	尿素窒素	<25
中性脂肪	30~126	尿酸	<5.9
血色素量	11.5~15.9	CR	0.4~0.8
HT	34~49		

Table 3 Medical relations between inspection items.

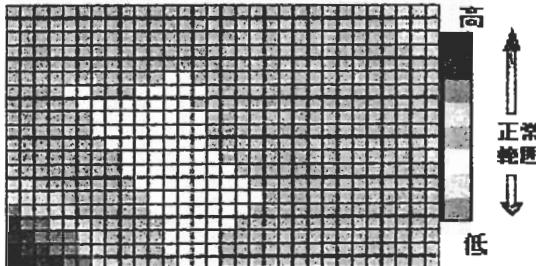
項目	危険因子
BMI, 中性脂肪	高値で肥満の恐れ
総コレステロール LDLコレステロール	高値で高脂血症の恐れ
総コレステロール CHE	低値で肝硬変の恐れ
GOT, GPT	高値で肝障害の恐れ
尿素窒素 クレアチニン	高値で腎障害の恐れ
血色素量, HT	低値で貧血の恐れ
HbA _{1c}	高値で糖尿病の恐れ
尿酸	高値で痛風の恐れ

健康診断データに自己組織化マップを適用した例を解説する。データの項目は、体重と身長から算出した BMI (Body Mass Index) を使った全 17 項目 (BMI, 血圧上, 血圧下, 総コレステロール, LDL コレステロール, HDL コレステロール, 中性脂肪, GOT, GPT, ChE (コリンエステラーゼ), HbA_{1c} (ヘモグロビン A_{1c}), γ -GTP, 尿酸, 尿素窒素, クレアチニン, 血色素量, Ht (ヘマトクリプト)) である。これらの検査項目は各項目ごとに正常値の範囲が示されている。また GOT, GPT は肝臓の逸脱酵素であり肝障害の指標であるといったような各項目ごとの医学的関連性がある程度決まっている。表 2 に項目別の正常値の一例と表 3 にその医学的関連性を示す。

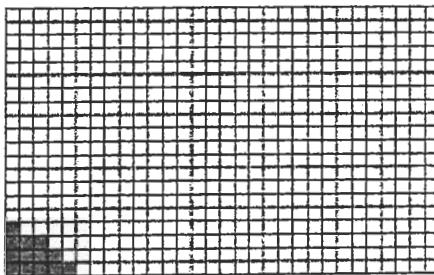
適切な正規化を施した前処理後のデータを使用して健康診断データのマップ化を行う。学習には幾つかの条件でマップを作成し、今回の目的であ



(a) 尿素窒素



(b) クレアチニン



(c) 腎障害の箇所

Fig. 15 (a), (b) element map which relates to Kidney trouble and (c) the map where Kidney trouble is shown.

る健康診断データの可視化に最も適した条件を探し、マップを作成した。

目的である健康評価では、クラス分けは病態ごとに分類し、境界もはっきりとさせなければならない。そこで、各検査項目の医学的関連性を用いて病態ごとのクラスタを決定する。例えば、腎障害の場合、関連する項目の要素マップと健康評価マップ上のクラスタの関係を図15に示す。この場合、尿素窒素とクレアチニンが高値なら腎障害の可能性があることを

示唆している。同様に、すべての医学的関連性を用いて各病態のクラスタを形成すると図16のような総合的な健康評価マップが完成する[11]。この作成した健康マップを利用して表4に5人の被験者の健康状態を表す。医者は異常値の関連性から「データからの見解」のように診断を下している。これを健康マップで診断を下した結果を図16上に表示する。尿酸値の高い原因が、数値データでは分かりにくかったが、マップで診断することによって、一目で原因が分かるようになった。こうして表4の5人の被験者のマップ

肝臓・糖尿・脂肪すべて危険域

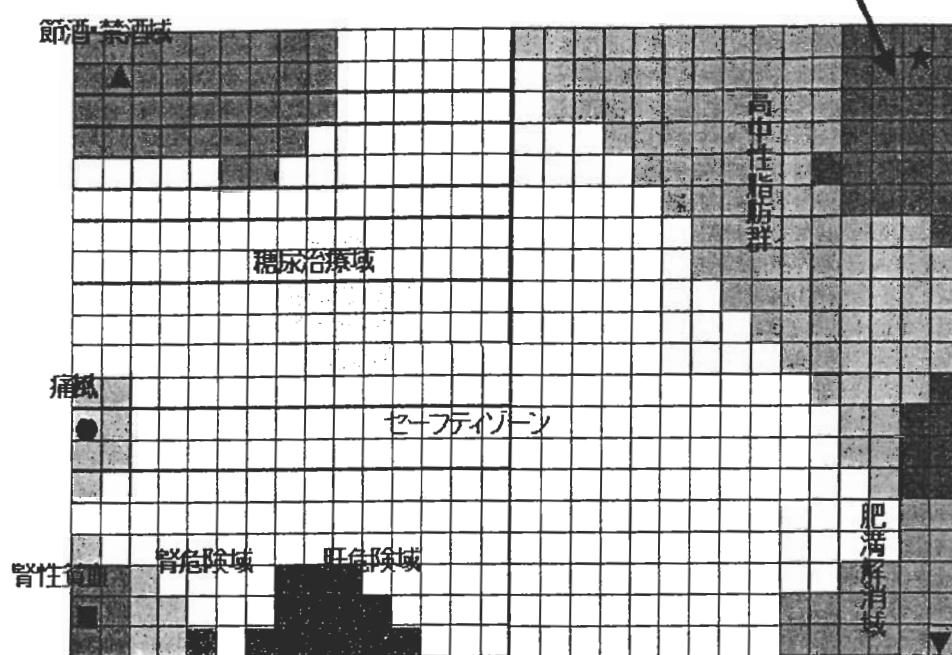


Fig.16 Checkup result of five subjects of Table 4 in the constructed healthy map.

上の診断は医師の診断結果と一致することが分かった。

コホネンによって開発された自己組織化マップ(SOM)は、一般的に視覚化に関して有利な2次元平面SOMで行われている。しかし、端が存在する2次元平面ではSOMの学習性質上、周縁に歪みが生じることがある。この歪みは、周縁の位相関係を知ることが重要な場合には大きな問題となる。特に健康評価マップの場合は、図16のようにクラスタ分類をした病態に関してほとんどすべてが周縁に配置されているので、病態間の関係(すなわち端と端との因果関係)が

Table 4 The result of the man dock of 5 subjects and 17 items (The painted place is higher than a normal value).

被験者	B	M	I	血圧上	血圧下	総コレステ	L	HDL	中性脂肪	G	G	C	H	A	T	G	尿酸	尿素窒素	クレアチニ	血色素量	H	T	データからの見解		
●																								痛風	
▲																								アルコール多飲者	
■																								腎障害	
★																								肥満	
▼																									

総コレステは総コレステロールの略、クレアチニはクレアチニンの略

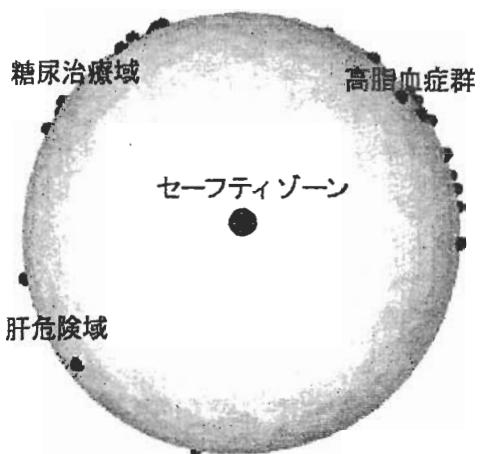


Fig.17 Spherical health evaluation map when safety zone (safety area) is put on the center.

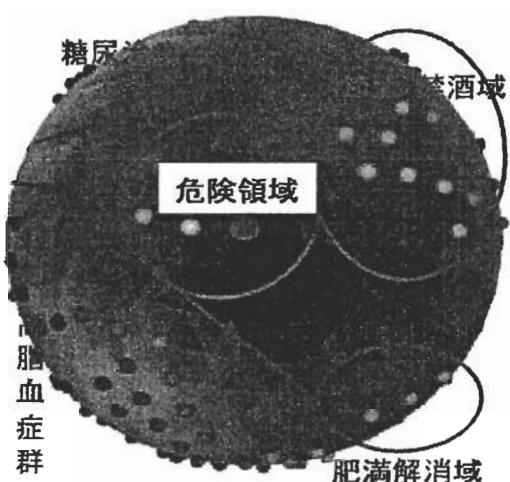


Fig. 18 Spherical health evaluation map when dangerous area is put on the center.

どのようになっているのかが分かりにくい。そこで、この解決策として、健康評価マップに周縁が存在しない球面 SOM [12] を利用することを考えた。

図 17, 18 に球面健康評価マップを示す。マップは健康優良者を白色に設定し、そのデータとの誤差が大きくなるにつれて、黒色になるようなグレースケールで表現している。図 17 のようにセーフティゾーンを中心を持ってくると、表示されている所がほぼ白色で病気のユニットがあまり表示されていないことが分か

る。図 18 は一番悪い危険領域を中心にしたもので、全く白色がなく黒色しか表示されていない。また、球面上でこの領域はセーフティゾーンの裏側に配置されていて、健康と病気は全く逆の関係になっていると言える。この領域に入る大きな流れとしては、アルコールの飲みすぎ、糖尿病、肥満や高脂血症が原因で陥る可能性を示唆している。

平面健康評価マップを球面に展開することによって、平面の周縁の関係が分かり易くなり、任意の症状を中心に配置することで、他の症状との関連性が理解しやすくなった。平面 SOM では全体を把握する可視化ができ、球面 SOM を用いた健康診断データの可視化は端の位相関係を正確に表現できるという点で、有効な手段である。

6. 巡回セールスマントロUBLE問題への応用

1 次元の競合層を用いた自己組織化マップを用いた巡回セールスマントロUBLE問題の解法について紹介する。元になつたと思われるアンジェニオールのアルゴリズム [13] を以下に簡単に説明する。

本アルゴリズムはコホネン [1] の自己組織化マップに基づくもので、この方法は、平面上に都市を与えたとき、経路は 1 次元のリング状に連結されたノードによって与えられる。この 1 次元のリングは連続的に発展する。その過程においてノードは平面上を動き、各都市がリング上の 1 つのノードを捕獲したとき、現実の解となる経路が得られる。

ある都市に最も近いノードが勝者となる。その都市にリング状の複数のノードが学習していく様子を図 19 に示す。すべてのノードはリングに沿って勝者から位相的距離が遠ざかるにつれ強度を弱めながら更新されていく。

一例として米国 532 都市配置問題を図 20 (a) に示す。同図の (b) はその理論上の最短経路で (c) は今回の実験で得られた中で一番経路長が短かった経路である。図から分かるように提案したアルゴリズムによって最短経路に比べ僅か 3.4 パーセント長い経路を持つ経路を得ることができた。

我々の研究グループでは計算時間の短縮に重点をおいた改善アルゴリズム [14,15] を提案しており、パラメータの選択により、ここで提案したアンジェニオールの方法に比べて計算時間を約 1/5 程度まで高速化することを実現している。

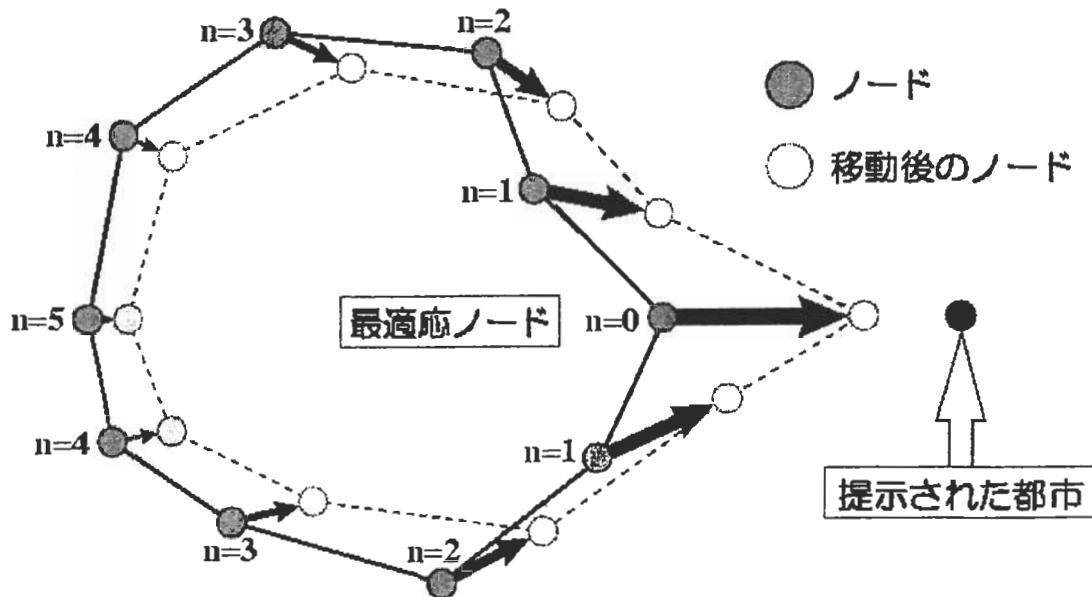


Fig. 19 Movement of node when city is presented.

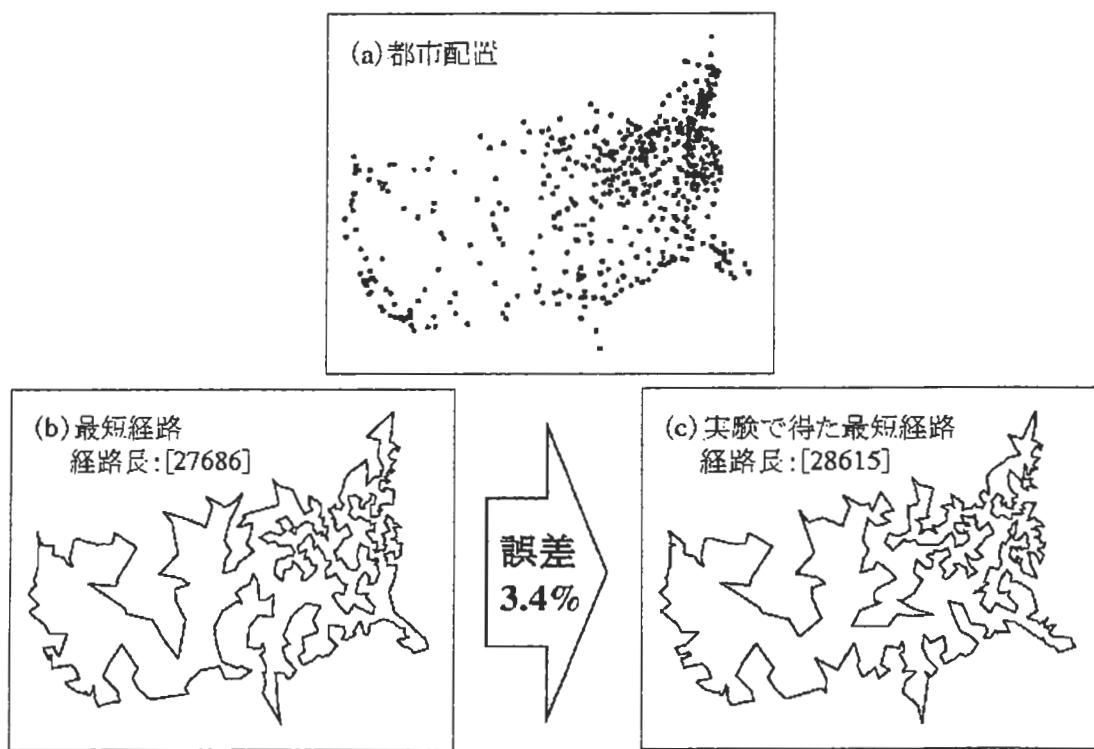


Fig. 20 (a) City arrangement of 532 city in the United States problem and (b) the theoretical shortest route and (c) the shortest route obtained from the experimental simulation.

7. チップマウンタへの応用

7.1 チップマウンタとは

チップマウンタとは、プリント基板上にチップ状の電子部品を高速に自動的に装着していく機械である[16]。プリント基板はカラーテレビやパソコンを始め様々な電気・電子製品に使われている。チップマウンタは以下のように作動して、プリント基板に電子部品を実装していく。

図21にチップマウンタの構成をイメージとして示す。上から、プリント基板搬送系、ロータリー型の回転ハンドラ、素子リール格納部から構成される。まず、プリント基板は装置のX-Yテーブル上に固定される。部品装着位置はX-Yテーブルの移動によりなされる。あらかじめ、素子リールの順序と部品の装着順が決められており、そのプログラムに従って部品の実装がなされる。ハンドラに付いているヘッド内に格納されたノズルに、ある素子リールの1つの部品が吸着により取り出され、それがハンドラの回転により基板のある場所まで運ばれ、装着位置をX-Yステージの移動により確定後、そこでノズルに吸着された部品が落とされる。プリント基板にはあらかじめ粘着性のある接着剤が塗布されており、基板上に部品を落とすだけで部品が固定されることになる。チップマウンタはこのような動作を高速でおこない、プリント基板に電子部品を実装していく。

素子リールを並べる順番と部品装着順のプログラムの出来次第で、実際に装着開始から完了までに要する時間（実際に装着開始から完了までに要する時間のことをタクト時間という。通常1枚のプリント基板当たりに要する時間をいうが、それを部品点数で割ったものを平均タクト時間という。平均タクト時間は2003年現在、高速なもので0.1秒/部品が得られている）はこのプログラムの影響を受ける。この部品を装着する時間をできる限り短くするプログラムを求めることが重要な問題となる。この問題を解くために必要となる巡回セールスマン問題の解法としてSOM-TSP法[14,15]を適用している。この問題解法のための基本的なアルゴリズムの詳細については我々の論文[17]を参照していただきたい。

7.2 実際の効果

提案手法の効果を実例で示す。図22は部品総数が354点・81種類のプリント基板、図23は部品総数が716点・109種類のプリント基板のシミュレーションの結果を示す。図中に示す経路はX-Yステージの移動を部品装着順に描いた軌跡である。単純にこの軌跡の総距離が短ければ時間の短縮ができるといえないが、長いよりは短い方が良いということは言える。それぞれに、従来法と本手法での1枚の基板の仕

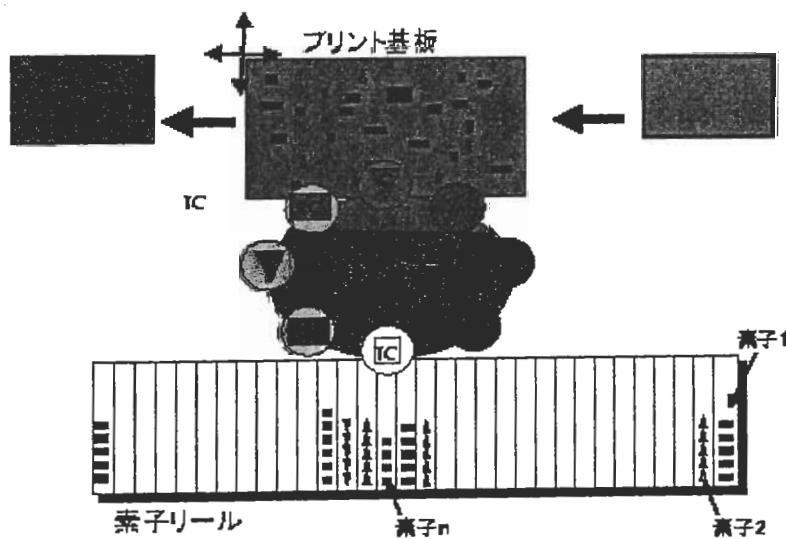


Fig. 21 Imitative chart of (chip-mounter).

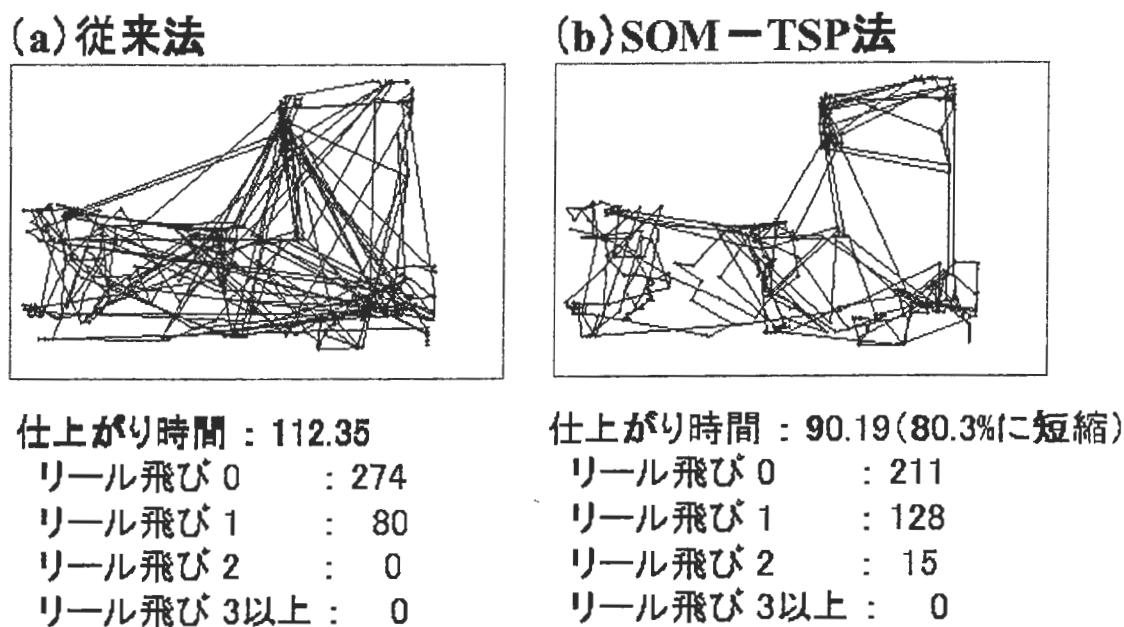


Fig. 22 Simulation result of 354 points and 81 kinds of parts on a printed substrate.

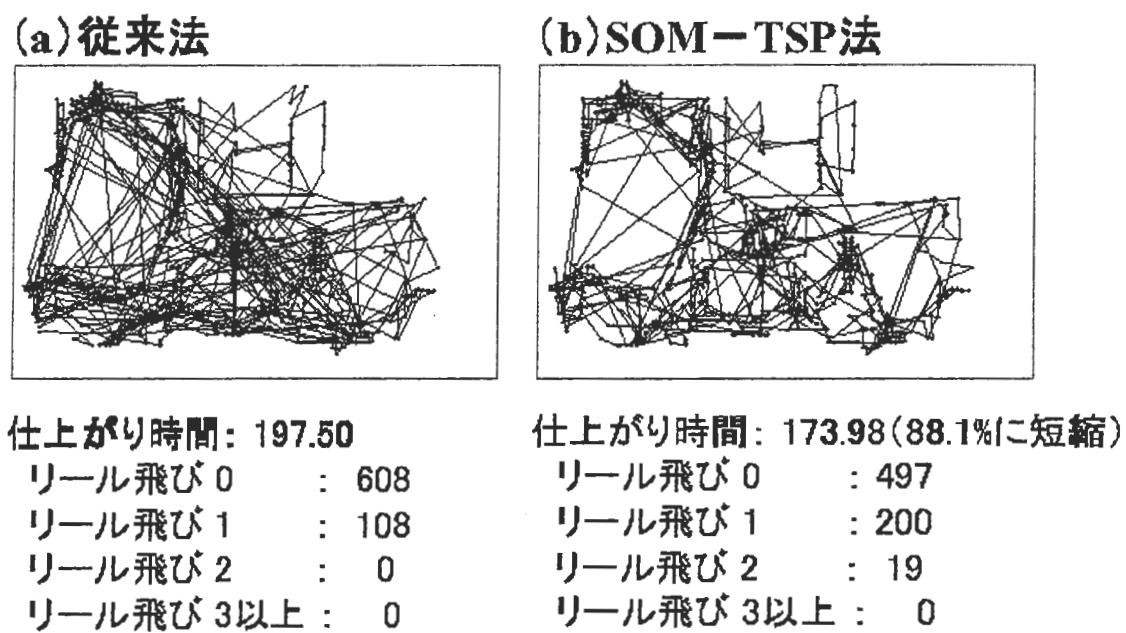


Fig. 23 Simulation result of 716 points and 109 kinds of parts on a printed substrate.

上がり時間（タクト時間）とリール飛びの数を示している。リール飛び0は現在の部品リールから部品を吸着したことを意味し、これが装置としての最速のタクト時間となる、リール飛びが増えるとタクト時間は遅くなる傾向にあるが、基板の動く速度との相対的な関係が存在し、必ずしもタクト時間が遅くなるとは限らない。軌跡はどちらの基板についても提案手法の方が総経路長が短いことが一目でわかる。タクト時間は従来法に比べ10～20%程度改善されている。このように、提案手法は部品点数の多いプリント基板で、タクト時間を短くするのに有用な方法であることが分かる。

8. 遺伝子解析

最近、池村らのグループは新たにバッチ型の自己組織化マップを開発し、遺伝子情報のような膨大な情報量を持つデータを従来の方法よりも効率よく処理できる方法を開発した [18]。図24に遺伝子データベースからのデータを基にして作成されたマップを示す。人、米、等の遺伝子がきれいに分類されていることがわかる。

また、ヘルシンキ工科大のカスキ（Kaski）らは自己組織化マップを用いて遺伝子情報のマイクロアレー

データを従来の木構造の分類法よりも効率よくまた、視覚的に分類できることを研究している [19]。

9. おわりに

XPS法が発明されて50年、LEEDとAESが世に出てからも既に40年が過ぎた。その頃の熱い熱気は既に去り、表面分析は今や現代の産業技術に無くてはならない手段になってきた。この分野に入ってくる若い人達には既に熟練の技術と化した表面分析にとまどう方々も多いであろう。しかし、表面を取り扱う分野は人間社会においては非常に広範囲であるので、時には異分野の人達にも入ってもらい、異文化交流の中で表面分析技術が益々発展して行くことを期待するものである。

ここでは、私が現在専門にしているコホネンの自己組織化マップに関する応用事例を中心にその概略を簡単に紹介した。紙面の都合で詳しく紹介できなかつたと思うので、説明不足であると思われるところには参考文献を示した。詳しく知りたい方はそれらの文献を参照していただきたい。自己組織化マップは人間社会の中で実際に役に立つニューラルネットワーク技術の一つであり、人間の脳内での情報処理に比較的近いものだと確信している。勿論、日頃、得られたスペクトルデータ、整理したエクセルデータ表を眺めながら思考に暮れている時にはここに述べた例のようにたちど

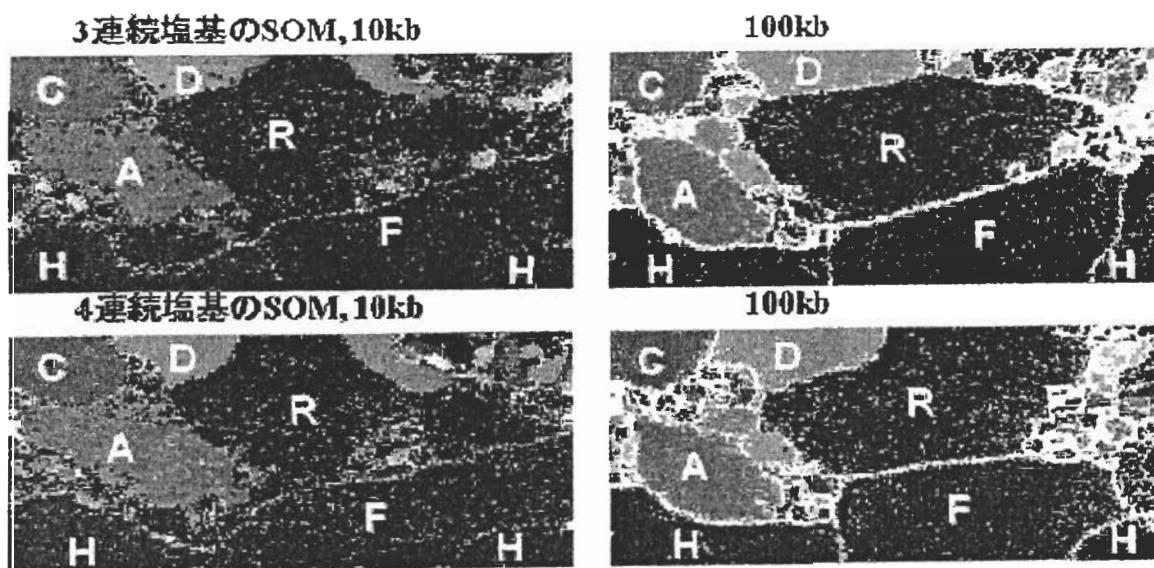


Fig. 24 Lattices that include 3 and 4 sequence bases from a single species are indicated with label as follows: human (H), *Fugu rubripes* (F), *melanogaster* (D), *elegans* (C), rice (R), *thaliana* (A), and 2 others and other 81 bacteria with different colors.

ころに解決してくれる便利で強力なツールである。今後、遺伝子の解析などの複雑で大量のデータ処理をする分野でも活躍が期待されている重要な手法である。

参考文献

- [1] T. Kohonen, *Self-Organization and Associative Memory* (Springer Series in Information Sciences, Volume 8, 1984).
T. コホネン, 自己組織化と連想記憶・中谷和夫監訳 (シュプリンガー・フェアラーク東京, 1993).
- [2] T. Kohonen, *Self-Organizing Maps*, (Springer Series in Information Sciences, Volume 30, 1995).
T. コホネン, 自己組織化マップ・徳高平蔵, 岸田悟, 藤村喜久郎 訳 (シュプリンガー・フェアラーク東京, 1996).
- [3] 徳高平蔵, 岸田悟, 藤村喜久郎, 自己組織化マップの応用 - 多次元情報の2次元可視化 - 海文堂出版(1999).
- [4] 徳高平蔵, 藤村喜久郎, 山川烈 監修, 自己組織化マップ応用事例集 -SOMによる可視化情報処理 - 海文堂出版(2002).
- [5] 徳高平蔵, *J. Surf. Anal.*, 3, 545 (1997).
- [6] H.Tokutaka, K.Yoshihara, K.Fujimura, K.Iwamoto, K.Obu-Cann, *Surf. Interface Anal.*, 27, 783 (1999).
- [7] 徳高平蔵, 藤村喜久郎, 吉原一紘, 表面科学, 20, 190 (1999).
- [8] 佐野祐司, 片岡幸雄ら, 労働科学, 61(3), 129 (1985).
- [9] 佐野祐司, 片岡幸雄ら, 体力研究, 68, 17 (1988).
- [10] 青柳健, 馬庭芳朗, 徳高平蔵, 藤村喜久郎, バイオメディカル・ファジィ・システム学会第15回年次大会講演論文集, 33 (2002).
- [11] 池田佳宏, 馬庭芳朗, 宇佐美眞, 徳高平蔵, 藤村喜久郎, 第18回ファジィシステムシンポジウム講演論文集, 547 (2002).
- [12] 中塚大輔, 大藪又茂, 第18回ファジィシステムシンポジウム講演論文集, 539 (2002).
- [13] B. Angeniol, G.de La C. Vaubois and J.Y. Le Texier, *Neural Networks*, 1, 289 (1988).
- [14] 藤村喜久郎, 徳高平蔵, 大島靖広, 田中慎一, 岸田悟, 電気学会論文誌C, 116-C, 350 (1996).
- [15] 藤村喜久郎, 徳高平蔵, 石川眞澄, 電気学会論文誌C, 119-C, 875 (1999).
- [16] 松下電器産業精機事業部, 部品搭載技術 表面実装ポケットブック・日刊工業新聞社, ISBN 4526043125, (1999).
- [17] 藤村喜久郎, 藤脇真一, 徳高平蔵, 電子情報通信学会論文誌D-II, J84-D-II, 1194 (2001).
- [18] 池村淑道, 学術月報, 55, 1134 (2002).
- [19] Samuel Kaski, Janne Nikkila, P. Toronen, E. Castren, G. Wong, *Workshop on Nonlinear Signal and Image Processing*, 2001. Proceedings on CD-ROM, C(2001).