

## 自己組織化マップに基づく類似画像検索の高速化手法

呉, 君錫

九州大学大学院システム情報科学府知能システム学専攻 : 博士後期課程

金子, 邦彦

九州大学大学院システム情報科学研究所知能システム学部門

牧之内, 顕文

九州大学大学院システム情報科学研究所知能システム学部門

<https://doi.org/10.15017/1515720>

---

出版情報 : 九州大学大学院システム情報科学紀要. 6 (1), pp.77-82, 2001-03-26. 九州大学大学院システム情報科学研究所

バージョン :

権利関係 :



## 自己組織化マップに基づく類似画像検索の高速化手法

呉 君 錫\*・金子邦彦\*\*・牧之内 顕文\*\*

### A Method of Highspeed Similarity Retrieval based on Self-Organizing Maps

Kun-Seok OH, Kunihiko KANEKO, Akifumi MAKINOCHI

(Received December 15, 2000)

**Abstract:** Feature-based similarity retrieval become an important research issue in image database systems. The features of image data are useful to discrimination of images. In this paper, we propose the highspeed  $k$ -Nearest Neighbor algorithm based on Self-Organizing Maps. Self-Organizing Maps(SOM) provides a mapping from high dimensional feature vectors onto a two-dimensional space. The mapping preserves the topology of the feature vectors. The map is called *topological feature map*. A topological feature map preserves the mutual relations( similarity) in feature spaces of input data, and clusters mutually similar feature vectors in a neighboring nodes. Each node of the topological feature map holds a node vector and similar images that is the closest to each node vector. In topological feature map, there are empty nodes in which no image is classified. We experiment on the performance of our algorithm using color feature vectors extracted from images. Promising results have been obtained in experiments.

**Keywords:** Self-organizing maps, Image database, Similarity retrieval, Content-based image retrieval

#### 1. はじめに

近年、マルチメディア技術の発達により、大量の画像データを蓄積し、様々な分野で活用するようになったことから、画像データベースの研究が盛んに進められてきた。画像データベースに格納された画像を効果的に活用するためには、ユーザが求める画像を効率的に検索するための画像検索機能を備える必要がある。画像検索を実現するには、大別して、画像に付与された属性(テキストによる注釈など)を用いる場合、画像自体の特徴を用いる場合、および、それらを組み合わせて用いる場合などのアプローチが存在する。我々は、画像自体が有する特徴に着目した、**内容に基づく画像検索**(content-based image retrieval, CBIR)<sup>5),8),9)</sup>に関して研究を行ってきた。

CBIRのアプローチでは、まず、データベースに登録された画像から、色・テクスチャ・形状のような、画像固有の視覚的特徴量を抽出する。特徴量は、画像の識別、すなわち、与えられた画像がどの類に属するかを決定するのに役立つ。次に、これらの特徴量をもとに、各画像に対して特徴ベクトルを生成し、各画像を特徴空間上の一点に対応づける。このような前処理により、画像データベースにおける類似検索は、特徴空間の問合せに対し、システムが提供する距離尺度を用いて、問合せに近い順に画像データをランクづける最近傍探索(nearest neighbor search, NN)が本質的な処理となっている<sup>10)</sup>。

画像データは一般に情報量が大きいため、大規模なデータベースから与えられた質問画像に類似した画像を検索するには実用的な時間で可能にすることが不可欠である。このような手法を用いた**CBIR**のアプローチは多くのシステムで実証され<sup>6),14),15)</sup>、**QBIC**<sup>7),6)</sup>のような一部のシステムは商用化されている。

本研究では、画像の類似性により自動分類を行なうために、Kohonenの自己組織化マップ(Self-Organizing Maps, SOM)<sup>2),4)</sup>を用いる。SOMは、複数の高次元特徴ベクトルから成るデータ集合を2次元上にマッピングし、特徴ベクトルとの位相関係を保った2次元の特徴マップ(位相特徴マップ)を生成する。この位相特徴マップの各ノード(マップ層のユニット)に生成されるベクトルのことを通常、コードブックベクトル<sup>2)</sup>というが、ここでは、各ノードが持つベクトルという意味でノードベクトルと呼ぶことにする。このように、SOMを用いて、特徴ベクトル間の類似性を見出し、互いに類似した特徴ベクトル同士をマップの近傍ノードにクラスタリングすることが可能である。このようにクラスタリングを行なうと、データベース内では互いに類似した画像が含まれているため、一般的に1ノードには複数の画像がマッピングされる。その結果、マップ層のノードには、画像が1つも分類されていない空きノード(empty nodes)が生じる。この空きノードは不必要なディスクアクセスを行なうので、全体の検索パフォーマンスを低下させる原因となる。

本研究では、このような点を考慮して、SOMにおける画像の類似検索を高速に行なえる  $k$ -NN探索アルゴリズムを提案する。 $k$ -NN探索とは、与えられた質問画像に最

平成12年12月15日受付

\* 知能システム学専攻博士後期課程

\*\* 知能システム学部門

も類似した画像(実際、距離尺度により質問画像に最も近い距離を持つ画像)を検索候補として $k$ 個探し、検索結果として返すことであり、GIS(Geographic Information System)で特に応用されてきた<sup>10)</sup>。我々は、マップ層の各ノードに対して、 $k$ -NN探索を実現するための探索方法を定義した。それらの定義に基づいて、探索アルゴリズムを実装しその有効性を実験を通して明らかにする。

本論文では、2.で関連研究について述べる。3.では類似画像の分類について述べ、4.では類似検索の高速化のための手法と、本研究で提案する $k$ -NNアルゴリズムについて述べる。5.でその有効性を検証するための実験と考察を行ない、6.でまとめる。

## 2. 関連研究

SOMは可視化情報検索に応用され、多くの研究結果が報告されている<sup>1)</sup>。特に、SOMを用いた類似画像検索には2つの形態がある。

1つは、マップのビジュアル化による検索である<sup>13),18)</sup>。マップ上を自由にナビゲートしながら情報検索を行なう方法で、このとき、ユーザの情報要求に対するインタラクティブな情報検索を行なう適合フィードバック(relevance feedback)<sup>11)</sup>を用いるのが一般的である。しかし、このようなシステムでは、ユーザが自由に任意の画像を質問画像として与え検索することはできない。もう1つの形態としては、例示画像による検索(Query by Examples)である<sup>20),17)</sup>。Netra<sup>17)</sup>では、教師なし学習と教師あり学習を行なうニューラルネットワークを組み合わせ、特徴空間を多くの部分領域に分割することで、視覚的に類似したパターンを表現する。我々は従来から、ウェーブレット変換<sup>12)</sup>とSOMを組み合わせ、類似検索に有効な特徴量抽出と分類手法を提案してきた<sup>20)</sup>。検索手法として、例示画像による検索や部分空間による検索手法を提案し、その性能評価を行なった。しかし、これらの検索手法ではマップ上の勝者ノードから取り出した画像を検索結果としたため、画像によっては他の検索手法(例えば、線形検索)と比較すると検索結果が一致しないのが現状である。

SOMの学習は、特徴ベクトル間の類似性を見出し、互いに類似した特徴ベクトル同士をマップの近傍ノードにクラスタリングすることが可能である<sup>3)</sup>。このような性質を持っているにも関わらず、他手法との検索結果の不一致といった問題点が生じる。このような問題点をなくすためにはマップの全ノードを検索しなければならないが、非常に検索時間がかかり、実用的ではない。本研究では、このような問題点を解決するために、SOMに基づいた画像の類似検索を高速に行なう $k$ -NN探索アルゴリズムを提案する。

## 3. SOMによる類似画像の分類

本研究では、画像データからHaar ウェーブレット変換を用いて、48次元の色特徴ベクトルを抽出し、画像の類似検索に用いた<sup>20)</sup>。色空間としてYIQ色空間<sup>16)</sup>を使い、色空間の各チャンネルに対して、5レベルの Haar ウェーブレット変換を行ない、ウェーブレット係数を求める。その結果、画像全体に対する平均的な色成分を表わす最も低域な成分 $4 \times 4$ を取り出し、色特徴ベクトルとする。

類似画像の分類は、ウェーブレット変換から得られた色の特徴ベクトル $F_{col}$ を用いて、SOMの学習により行なう。SOMは2層構造を持つニューラルネットワークである。第1層は $n$ 次元の入力層であり、そのノード数 $n$ は特徴ベクトルの次元数から $n = 48$ である。第2層は、複数のノードが2次元に配列されているマップ層(または競合層)で構成され、学習前にランダムな重み値が与えられ初期化される。

類似画像分類は、以下に示す位相特徴マップ生成過程と最整合画像リスト生成過程からなる。

**位相特徴マップ生成過程** 位相特徴マップを生成するために、学習に必要なパラメータ(学習率、近傍半径、マップ層のサイズ、近傍関数、学習回数)を与え、SOMの学習を行なう。位相特徴マップの生成過程は次の通りである。まず、入力として与えられた特徴ベクトルに最も近い重みベクトルを持つノードをマップ層から選ぶ。次に、そのノードと近傍領域内のノードを特徴ベクトルに近づけるように更新する。この処理を指定された学習回数だけ繰り返す。学習の結果、マップ層の各ノードに生成されるベクトルのことをノードベクトルといい、


$$CBV_i = [cv_{i1}, cv_{i2}, \dots, cv_{ij}, \dots, cv_{im}]^T$$

で表わす。ここで、 $i(1 \leq i \leq k)$ はマップ層のノード番号を示す。 $m$ は入力層のノード数(画像の特徴ベクトルの次元数)を、 $k$ はマップ層のノード数を表す。このように得られた位相特徴マップは、特徴ベクトル相互の類似関係が2次元上にマッピングされたものである。


**最整合画像リスト生成過程** 最整合画像リスト生成過程では、位相特徴マップを用いて、特徴ベクトルとノードベクトル間の距離計算を行ない、最も近いノード(勝者ノード)を求め類似画像を分類する。特徴ベクトルとノードベクトル間の類似度は、ユークリッド距離によって計算した。勝者ノード $BMN_i$ は、

$$BMN_i = \min_{1 \leq i \leq k} \{ \|F_{col} - CBV_i\| \}$$

を用いて求める。特徴ベクトルとノードベクトルとの関係をFig. 1に示す。この2つのベクトルは、距離の近さに



**Fig.1** The relationship between feature vector and node vector. (a)Feature vector generated by wavelet transform, (b)node vector generated by SOM.



**Fig.2** City block distance between  $a_c$  and  $a_i$ .

より多対一の対応関係にある。

以上の処理をデータベース内のすべての画像について、色特徴ベクトルを用いて行なうことで、色に対する位相特徴マップと最整合画像リストが生成される。

#### 4. SOMにおける最近傍検索の高速化

最近傍探索(nearest neighbor search)は、与えられた質問点に最も近い点を探す探索であり、画像などから得られた特徴ベクトルを使って類似検索を行なう場合など、マルチメディアアプリケーションによく用いられる手法である。 $k$ -NN探索の基本的な考え方は、質問点に近い領域から順に検索結果の候補  $k$ 個を集めながら探索し、集めた候補の最も遠い点よりも近い未探索領域がなくなった時点で探索処理を終え、探索処理を終えた時点での候補集合が検索結果となる。

このような考え方に基づいて、SOMの学習結果から得られた位相特徴マップと最整合画像リストに対して、効果的な  $k$ -NN 検索を実現する。そのために、従来の空間インデックス(spatial index)を構築するために広く用いられてきた最小包囲長方形(minimum bounding rectangle, MBR)<sup>10)</sup>を位相特徴マップの各ノードに対して適用する。

**勝者ノードを中心とした近傍領域での探索**  $k$ -NN探索では最初に訪問するノードを決定する必要がある。ここではそのノードを勝者ノードと呼ぶことにする。また、SOMは勝者ノードの近傍ノードが互いに類似している性質を持っている。したがって、勝者ノードを中心にその近傍ノードを探索していくことは、質問画像により近い画像を検索するのに有効である。マップ層の近傍領域を **Fig. 2**のように定義する。勝者ノードと近傍領域の半径  $\gamma$  内でノード間の距離は  $L_1$ 空間の都市ブロック距離(City block distance)<sup>2)</sup>によって計算する。探索時には、近傍領域の半径  $\gamma$  を拡大しながら、与えられた質問画像に類似した画像を順次取り出す。マップ上で探索すべき最大近傍領域の半径  $\Gamma$ は、

$$\Gamma = \max_{1 \leq i \leq 4} (\|a_c - a_i\|)$$

と定義する。ここで、 $a_c$ は勝者ノードの位置ベクトル、

$a_i$ は格子状の4点の位置ベクトルを表わす。

**各ノードのMBRの定義** マップ上の各ノードに対する MBR  $\mathcal{R}$ を定義するために、各ノードに分類されたオブジェクト(画像)  $\mathcal{O} = \{o_{ij} | 1 \leq i \leq N, 1 \leq j \leq n\}$ を用いる。ここで、 $N$ はノードに分類されたオブジェクト数、 $n$ は各オブジェクトが持つ特徴ベクトルの要素を表わす。MBR  $\mathcal{R}$ は、

$$\mathcal{R} = (S, T)$$

で定義する。ここで、 $S = \{s_j | 1 \leq j \leq n\}$ 、 $T = \{t_j | 1 \leq j \leq n\}$ は各々、MBR  $\mathcal{R}$ において最小となる点、最大となる点を表わし、

$$s_j = \min_{1 \leq i \leq N} (o_{ij}), \quad j = 1, 2, \dots, n$$

$$t_j = \max_{1 \leq i \leq N} (o_{ij}), \quad j = 1, 2, \dots, n$$

によって求まる。ここで、 $s_j \leq t_j$ である。このMBR  $\mathcal{R}$ の計算は空きノードを除いたマップ層のすべてのノードに対して行なう。

次に、与えられた質問点  $\mathcal{P}$ とMBR  $\mathcal{R}$ との最短距離は、

$$MINDIST(\mathcal{P}, \mathcal{R}) = \left( \sum_{i=1}^n |p_i - r_i|^2 \right)^{1/2}$$

で定義する。ここで、

$$r_i = \begin{cases} s_i & \text{if } p_i < s_i \\ t_i & \text{if } p_i > t_i \\ p_i & \text{otherwise} \end{cases}$$

である<sup>2)</sup>。すなわち、 $MINDIST$ は  $\mathcal{R}$ の包囲長方形上のすべての点と  $\mathcal{P}$ との距離が最小となる点である。 $MINDIST$ の距離計算は、特徴ベクトル間の距離尺度であるので、 $L_2$ 空間のユークリッド距離を用いる。この最短距離  $MINDIST(\mathcal{P}, \mathcal{R})$ は探索時に探索不要ノードの判断に用いる。

**Pruning Strategy** 大規模なデータを実用的な時間で扱うには最近傍探索の高速化が不可欠であると考えられる。ここで探索不要なノード(visiting unnecessary nodes)を判断するために、(i) マップのノードの中でオブジェクト(画像)を1つも持たない空きノード、(ii) 最短距

Phase 1: Compute Winner Node
Input : $q\_Object$
Output: WinnerNode, retrievedList
1: $Nearest = \infty$ ;
2: $q_{fv}$ : feature vector of $q\_Object$
3: $i$ : node number on the Map
4: forall Node on the Map do begin
5: $Dist_i = \ cbv_i - q_{fv}\ $ ;
6:   if( $Nearest > Dist_i$ ) then do begin
7: $Nearest = Dist_i$ ;
8: $WinnerNode = i$ ;
9:   end
10: $i = i + 1$ ;
11: end
12: /* initialize $k$ -retrieved Image List */
13: /* from WinnerNode */
14: update retrievedList with WinnerNode

Fig.3 Phase-1: Find Winner Node and initialize retrieval candidates.

離  $MINDIST(\mathcal{P}, \mathcal{R})$  が検索候補リストの中の最大距離より大きいノード, とした2つの pruning 処理を行なう。この処理により, 探索時間の高速化を図る。

**SOMにおける  $k$ -NN探索アルゴリズム** 本研究で提案する  $k$ -NN探索アルゴリズムは2つのPhaseからなる。探索アルゴリズムの疑似コードをFig. 3とFig. 4に示す。

**Phase-1 (Fig. 3)** では, まず, 位相特徴マップから与えられた質問画像に最も近い勝者ノード (WinnerNode) を求める (Step4-11)。この勝者ノードが  $k$ -NN探索において最初に訪問するノードとなる。そして, 勝者ノードに分類されている画像のうち, 質問画像に最も類似した  $k$  ( $k > 0$ ) 個を最初の検索候補として検索候補リスト (retrievedList) にソートして格納する (Step14)。検索候補リストは質問画像に最も近い候補から常にソートされて格納されているので, リストの中の  $k$  番目の候補は検索結果の中では質問画像に最も離れた候補を保っている。この処理で, マップ層の探索すべき最大近傍領域  $\Gamma$  が得られる。

**Phase-2 (Fig. 4)** では, 勝者ノードを中心に近傍領域の半径  $\gamma$  を拡大しながら最近傍探索を行なう。この処理では, 探索時に前述した2つの pruning strategy を適用する (Step11-19)。探索対象のノードに分類されている画像を持って検索候補リストを更新する (Step20)。この処理を  $\gamma \leq \Gamma$  である間に再帰的に行なう (Step24)。

## 5. 実験結果と考察

SOMにおけるNN探索アルゴリズムの有効性を検証するために, 提案した  $k$ -NNアルゴリズムを実装し, 画像の類似検索を例として評価実験を行なった。実験に用いた画像データは, スタンフォード大学で公開されている画

Phase 2: Search Nearest Neighbor
Input : $\gamma, q_{fv}, k\_NN$
Output: retrievedList
1: $\gamma$ : current NN radius
2: $\Gamma$ : maximum of NN radius
3: $q_{fv}$ : feature vector of $q\_Object$
4: $\mathcal{R} = (S, T)$ ; /* MBR */
5: $i$ : node number on the Map
6: if( $\gamma > \Gamma$ ) then do begin
7:   return
8: else
9:   for( $Node_i \in \gamma$ ) do begin
10:     /*prune empty Node*/
11:     if( $Node_i$ is emptyNode ) then do begin
12:       discard $Node_i$
13:     end
14:     /*prune visiting unnecessary Node*/
15: $Dist = MINDIST(q_{fv}, \mathcal{R})$
16:     if( $Dist > retrievedList[k\_NN].Dist$ )
17:       then do begin
18:         discard visiting unnecessary Node
19:     end
20:     update retrievedList with $Node_i$
21: $i = i + 1$ ;
22:   end
23: $\gamma = \gamma + 1$
24:   call SearchNearestNeighbor( $\gamma$ )
25: end

Fig.4 Phase-2: Similarity retrieval within  $\gamma$ .

像コレクション<sup>†1</sup>と, H<sup>2</sup>soft社の画像データ<sup>†2</sup>とを合わせて40000枚である。画像データベースのサイズは, Table-1(Data set)に示すように, 大きさの異なる6個のデータセットを作成して使用した。画像データのサイズはすべて128 × 128に固定する。各画像の特徴ベクトルは3で述べた48次元の色特徴ベクトルを用いる。各データベースに対して無作為で選んだ20枚の質問画像について検索実験を行ない, その平均値を測定結果とした。プログラミング言語にはC++を使用し, SUN Microsystems社のUltra 5(CPU:UltraSPARC-IIi, OS:Solaris 8, Memory:512MB)の上で測定した。

画像データの色特徴ベクトルを入力データとしてSOMの学習を行なった。SOMのマップ層のサイズはTable-1(Map size)に示すように, 各データセットの画像数とほぼ同様に設定した。マップ層の各ノードが持つ重みベクトルは, 特徴ベクトルの次元数と同じように, ランダム値で初期化された48次元のベクトルである。学習回数は  $T = 10000$  とし, 学習時の近傍集合の初期値  $\gamma_0 = 30$ , 学習率の初期値  $\alpha_0 = 0.9$  とした。近傍集合と学習率は学習が行なわれる間に更新され続ける。SOMの学習結果, マップ層の各ノードには一般的に1ノードには複

†1 <http://WWW-DB.Stanford.EDU/IMAGE/>.

†2 <http://www.h2soft.co.jp>.

数の画像がマッピングされる。その理由は、データベース内では互いに類似した画像が含まれているからである。したがって、マップ層のノード数をデータセットの画像数とほぼ同じように設定すると、マップ層のノードには、画像が1つも分類されていない空きノード(empty nodes)が生じる。今回学習を行なった6種類のデータセットから得られたマップ層における空きノードの比率を**Table-1(Empty nodes, (%))**に示す。この空きノードを除いて、マップ層の各ノードに対してMBRを求めた。

与えられた質問画像に対して  $k$ -NN 検索を行なう。検索候補  $k$  の値はそれぞれ、1, 5, 10, 20, 30, 40, 50, 100について検索実験を行なった。質問画像とデータベース内の画像との距離尺度は  $L_2$  空間のユークリッド距離を用いる。実験は、 $k$  の値とデータセットのサイズの増加にともなって  $k$ -NN探索アルゴリズムの動作について調べた。また、*MINDIST*の影響について検討を行なった。

**Fig. 5**は、各データセットに対して  $k$  の増加により探索不要となるノード数を示したものである。この測定結果には空きノードの数は含まれていない。その理由は、空きノードの数は既知のものであり、ここでは *MINDIST*の影響を調べることにその狙いがある。検索候補  $k$  が増えると、探索訪問のノード数は増加するが、全体のノード数からみると、38%(Data set=40000,  $k=100$ )から57%(Data set=1000,  $k=1$ )のノード数にとどまった。これは *MINDIST*による pruning効果 が得られたと考えられる。また、**Fig. 6**の  $k$  の増加に対する探索ノード数をみると、 $k=1$  のときは、データセット40000以外では勝者ノードのみが探索対象となった。 $k=100$  の場合、データセット40000では、全体のノードの2.7%に当る1084個のノードをアクセスした。この2つの実験により、SOMにおいて  $k$ -NN探索を行なうために定義した pruning strategyの有効性が明らかになった。


$k$ -NN探索アルゴリズムの探索時間を**Fig. 7**に示す。探索時間を20枚の質問画像に対して、 $k$ 個検索するのにかかる時間の平均値である。ここで、この探索アルゴリズムの特徴が観測された。すなわち、 $k$ の値が増加しても探索時間はほとんど変わらないことである(**Table-2**)。その理由は、(i) 検索候補  $k$ が増加しても、探索領域は勝者ノードを中心とした2次元マップに限定されるので、探索すべき近傍領域は変わらない、(ii) 訪問した各ノードに分類された画像と質問画像との類似度計算がメモリ上で行なわれるため、その計算時間はほとんど無視される、と考えられる。

6. ま と め


本研究では、SOMの学習結果から画像の類似検索を高速に行なう  $k$ -NN探索アルゴリズムを提案した。また、高速な探索アルゴリズムを実現するために、マップ層に各

**Table-1** Map size vs. empty nodes for each data set.


Data set	Map size	Empty nodes	(%)
1000	32×32	434	42
5000	70×70	2634	53
10000	100×100	5395	54
20000	140×140	10819	55
30000	175×175	18377	60
40000	200×200	23706	59



**Fig.5** Total number of visiting unnecessary nodes by pruning strategy( except empty nodes).



**Fig.6** Total number of visiting nodes for increasing  $k$ .



**Fig.7** Search time.

**Table-2** Retrieval time cost of each data set for increasing  $k$ (sec).

$k$	Data set( $\times 1000$ )					
	1	5	10	20	30	40
1	0.07	0.25	0.62	1.57	2.54	4.26
10	0.08	0.26	0.62	1.57	2.56	4.30
50	0.08	0.26	0.63	1.58	2.57	4.30
100	0.08	0.27	0.64	1.60	2.58	4.30

ノードに対するMBRの適用, 与えられた質問点とMBRとの最短距離関数 *MINDIST* を定義した。我々は, 提案したアルゴリズムを実装し, 画像データを用いて類似画像検索の実験を行ない, その有効性を評価した。今回の実験を通して, *MINDIST*による類似画像検索の高速化が実現されたことを明らかにした。また, 検索時間は検索候補  $k$ の増加に関係なく, ほとんど差が見られなかったことに意義があり, SOMにおける $k$ -NN探索の有効性が検証された。そして, 例示画像による検索手法を用いても実用的な時間で所望の類似画像を検索することが可能であることを明らかにした。問題点として考えられるのは, 検索候補 $k$ の数に対してアクセスする画像の数が多すぎることである。このため検索時間に影響を与える。このような点を考慮し, アルゴリズムの改良を行ないたい。また, 実際のアプリケーションとして実装を行ない動作確認と性能の評価を行ないたい。

### 謝 辞

本研究の一部は, 文部省科学研究費補助金(課題番号: 10308012, 「仮想空間内での「しぐさ」と「相互作用」による情報検索法の研究」)の援助を受けている。

### 参 考 文 献

- Deboeck, G. and Kohonen, T.: *Visual Explorations in Finance with Self-organizing Maps*, Springer-Verlag, London(1998); Japanese ed., Springer-Verlag, Tokyo (1999).
- Kohonen, T.: *Self-Organizing Maps*, Series in Information Sciences, vol.30, Springer-Verlag, second edition, Berlin (1997).
- 馬場 則夫, 小島 史男, 小沢 誠一:ニューラルネットの基礎と応用, 共立出版 (1994).
- Kohonen, T., Hynninen, J. and Laaksonen, J.: SOM.PAK:The Self-Organizing Map Program Package, *In Technical Report A31, Helsinki University of Technology, Laboratory of Computer and Information science* (1996).
- Gudivada, V. N. and Raghavan, V. V. eds.: Content-based Image Retrieval System, *IEEE Computer*, Vol. 28, No. 9, pp. 18-22 (1995).
- Flickner, M. et al.: Query by Image and Video Content: The QBIC System, *IEEE Computer*, Vol. 28, No. 9, pp. 23-32 (1995).
- Faloutsos, C. et al.: Efficient and Effective Query by Image Content, *J. Intell. Inform. Syst.*, Vol. 3, pp. 231-262 (1994).
- Eakins, J. P. and Graham, M. E.: Content-based image retrieval. *Report to the JISC Technology Applications Programme* (1999).
- Rui, Y., Huang, T. and Chang S.-F.:Image Retrieval:Current Techniques, Promising Directions, and Open Issues, *J. Visual Communication and Image Representation(JVCIR)*, Vol. 10, No. 1, pp. 39-62 (1999).
- Roussopoulos, N., Kelley, S. and Vincent, F.: "Nearest neighbor queries," *In Proceedings of the ACM SIGMOD Conference*, pp. 71-79, San Jose, CA, May (1995).
- Rui, Y., Huang, T. S., Ortega, M. and Mehrotra, S.: "Relevance Feedback: A Power Tool in Interactive Content-Based Image Retrieval," *IEEE Trans. on Circuits and Systems for Video Technology, Special Issue on Segmentation, Description, and Retrieval of Video Content*, pp. 644-655, Vol.8, No.5(1998).
- Mallat, S. G.: Multifrequency channel decompositions of images and wavelet models, *IEEE Trans., Acoust., Speech and Signal Proc.*, Vol. 37, No. 12, pp. 2091-2110 (1989).
- 上原 祐介, 遠藤 進, 指田 直毅, 増本 大器, 長田 茂美, 棚橋 純一: MIRACLES:マルチメディア情報のパノラミック検索システム-Web検索への応用, 電子情報通信学会技術研究報告(データ工学), Vol. 100, No. 31, pp. 17-24 (2000).
- Smith, J. R. and Chang, S.-F.: VisualSEEK: A Fully Automated Content-Based Image Query System, *Proc. ACM Intl. Conf. on Multimedia*, Boston, pp. 87-98 (1996).
- Pentland, A., Picard, R. W. and Schlaroff, S.: Photo-book: Tools for Content-Based Manipulation of Image Databases, *SPIE Storage and Retrieval for Image and Video Databases II*, San Joes, pp. 34-47 (1994).
- Jacobs, C. E., Finkelstein, A. and Salesin, D. H.: Fast multiresolution Image Querying, *Proc. SIGGRAPH95*, Los Angeles, California, pp. 6-11 (1995).
- Ma, W. Y.: "NETRA: A Toolbox for Navigating Large Image Databases," Ph.D. Dissertation, Dept. of Electrical and Computer Engineering, University of California at Santa Barbara (1997).
- Laaksonen, J., Koskela, M. and Oja, E.: Application of Tree Structured Self-Organizing Maps in Content-Based Image Retrieval, *Proc. ICANN'99*, Edinburgh, UK. September (1999).
- Oh, K. S., Kaneko K. and Makinouchi, A.: Image Classification and Retrieval based on Wavelete-SOM, *Proc. the 1999 Intl. Symp. on Database Applications in Non-Traditional Environments (DANTE'99)*, pp. 164-167 (1999).
- 呉君 錫, 金子 邦彦, 牧之内 顕文, Sang-Hyun Bae, "Wavelet-SOMに基づいた類似画像検索システムの設計・実装と性能評価", 情報処理学会論文誌: データベース (TOD 8), Vol.42, No.SIG-1, pp. 1-11(2001).
- Koikkalainen, P.: Progress with the Tree-Structured Self-Organizing Map, *Proc. ECAI'94*, (Cohn, A.(ed.)), John Wiley & Sons, pp. 211-215 (1994).