

非線形写像を用いた顔画像の想起と人物認識への応用

古谷俊太^{†1} 和田俊和^{‡2} 松村祐貴^{†1}

顔画像認識は、犯罪捜査からパーソナルデバイスの個人認証まで、様々な用途で用いられている。しかし、ある質問画像に対して得られた認識結果は、顔のどの部分が根拠となり、その認識結果が得られたのかが明白ではない場合が多い。本研究では、顔画像データベース（以下 DB）を用いて、質問画像に近い画像を「想起」することにより、顔画像のどの部分がどの認識結果に対応しているのかを明らかにする方法を提案する。提案手法では、DB 中の事例を用いた非線形写像を、画像の隣接ブロック間で定義しておき、これを質問画像に適用することにより、質問画像に近い画像を DB 中の画像から生成（想起）し、その際に DB 中の各画像の各部分に付与された重みから、人物同定を行う。この方式では、顔画像の各部分が DB 中のどの画像に最も近いのかを求めることができるため、目、鼻、口、髪型、輪郭、などどの部分に着目して認識が行われたのかを判断しやすいというメリットがある。また、ORDB を用いた顔の認識実験により、提案手法は高い認識性能を持つことを示し、有効性を明らかにした。

Face Image Recall by Nonlinear Mapping and Its Application To Human Identification

SHUNTA FURUTANI^{†1} TOSHIKAZU WADA^{‡2}
YUKI MATSUMURA^{†1}

Face image recognition is widely used for many applications from crime investigation to user identification for personal devices. Most face recognition systems, however, do not show the reason of recognition, i.e., by which part of the face, this image is recognized as the resulted person. This paper proposes a face image recognition method that provides the recognition result, as well as the reason of the result. This method is basically an image recall system using example based nonlinear mapping. This nonlinear mapping refers the image database and performs image-to-image mapping using the database so as to realize image recall, where the system generates the similar image with the input by partially linear combination of images in the database. As a by-product, weighting coefficients for images in the database are obtained at any locations on the recalled image. By applying this method to face images, we can recognize the person id by summing up the coefficients for ids. The coefficient distribution for the resulted person id, we can understand which part provides the evidence of the recognition result. Through experiments conducted on ORDB face database, we confirmed our method have high recognition rate.

1. はじめに

顔画像の認識による個人の同定は、セキュリティやヒューマンインターフェースといった重要な要素技術として注目されており、多種多様な方法が提案されている。大きな分類としては顔全体の見えに基づく方法と、部分の認識に基づくものがある。しかし、全体の見えを用いる顔画像認識のシステムでは、認識結果に対する理由付けが行いにくく、人間がその結果を妥当なものとして受け入れるか否かの判断に必要なアノテーション情報が生成しにくい。これに対して、部分の認識に基づく顔認識では、各顔器官のどこが誰に似ていたかを説明することができるため、認識の根拠を示す目的には向いていると言える。

そこで、本論文では、事例ベースの非線形写像を用いることによって、データベース内の顔画像の部分毎の線形和を求め、入力に近い画像を想起する手法を提案する。この手法では画像上の各部分で、個々の画像に対する重みが計

算されるため、重み係数を個人毎に合算すれば、人物認識が行える。このようなアプローチの長所は、係数の分布によって認識の根拠となる部分が可視化できることにある。

これまでに、画像の想起はニューラルネットによって実現可能であることが示されているが学習にかかる時間が長大であるという欠点がある。また、写像の不動点による画像の生成という点ではフラクタル圧縮の復号プロセスがあるが、引き込みの起きる画像は一つしか記憶させることができず、写像の学習にも時間がかかる。本手法では、事例に基づく非線形回帰計算を用いて、画像の想起を行うことでこの問題を解決した。

2. 関連研究

ここでは、関連研究として写像の不動点として画像を記憶しておき、写像の反復適用で画像を復元するフラクタル圧縮と、複数の画像を記憶しておき、入力に近い画像を生成するニューラルネットによる想起の例と、顔画像認識法全般に関して概観する。

2.1 フラクタル圧縮

Jacquin[1]によって提案されたフラクタル圧縮は、以下に記すように、画像をレンジブロックに分割し、より大きな

^{†1} 和歌山大学大学院システム工学研究科，和歌山市
Graduate School of Systems Engineering,
Wakayama University, 903 Sakaedani, Wakayama-shi, 640-8510 Japan

^{†2} 和歌山大学 システム工学部 情報通信システム学科
Graduate School of Systems Engineering,
Wakayama University, 903 Sakaedani, Wakayama-shi, 640-8510 Japan

ドメインブロックからの縮小写像を求めることで、写像の不動点として画像を記録する手法である。

レンジブロックとは、原画像を互いに重なり合わない画素のブロックに分割したものを指す。このレンジブロック内の画像を、より面積の大きいドメインブロック内の画像からの写像（縮小写像）で表現することで画像を符号化する。具体的には、各レンジブロックに対してドメインブロックからの縮小写像（面積が小さくなる方向の写像）を求め、画素値の誤差が指定した値以下になるドメインを探索する。ドメインが見つからない場合にはレンジブロックを再分割して再度ドメインの探索を行う。縮小写像の内容は、縮小変換、対称変換、輝度スケールリング、輝度シフト、などである。全レンジブロックに対して指定した誤差を下回る縮小写像が求められれば、そのときのドメインブロックと変換パラメータを記録して情報圧縮を行う。復号時には、保存した変換パラメータを任意の初期画像に反復適用する。

フラクタル圧縮では、符号化が終わると、全レンジブロックに対する写像さえ覚えておけば、元の画像は不要になり、任意の画像を与えて画像の復元が行えるという興味深い性質がある。しかし、ドメインブロックの探索に時間がかかる、一つの不動点しか扱えない、という制限がある。

2.2 ニューラルネットワーク

ニューラルネットを用いた連想記憶モデルは 1970 年代の初めに中野[2], Kohonen[3], Anderson[4]によって同時期、かつ、独立に提案された。特に記憶する入力パターンと出力パターンが一致している連想記憶のことを自己相関記憶という。自己相関記憶モデルにおいて、ネットワークの出力をそのまま入力とする相互結合型ニューラルネットにすることで、学習したパターンへ戻る性質（誤り訂正能力）を強くすることができる。また、Hopfield[5]によるホップフィールドネットワークは元々スピンの安定条件を求めるためのモデルとして発想されたが、現在は連想記憶モデルのひとつとしても利用されている。

2.3 部分と全体に基づく顔画像の認識

顔画像認識の研究はこれまで盛んに行われており、極めて多くの手法が提案されている。これらの手法は、大きく次の2つのアプローチに分類される。

1 つは、特徴ベースの方法である。これは、顔の部分的分析に基づくアプローチであり、人間にとって意味のある、目、鼻、口などの顔器官の抽出と特徴記述を行うものや、ブロック分割を行うもの、SIFT や SURF など画像からボトムアップ的に抽出される局所特徴量を用いる手法などがある。

もう1つのアプローチは画像全体の見えに基づく方法であり、顔画像の固有空間への写像を行う Eigenfaces [6]や、CLAFIC 法[7]に代表される部分空間法などがある。特に、部分空間法は陰影の変化しやすい顔画像にとって、優れた汎化性能を持つことが知られている。但し、個人毎に位置

合わせされた陰影の異なる複数のトレーニング画像が得られるというケースは少ないため、1枚の画像から複数の陰影の異なる画像が得られなければ、適用することができない。

本研究の目的となる「認識の根拠の説明」という観点から見ると、上記の手法について、次のことが言える。画像全体の見えに基づく方法は、似ているか似ていないかの結論を、より細かく説明することができない。これに対して、部分に基づく手法では、目、鼻、口、などの各部分について、誰に似ているという度合いを可視化できる可能性がある。しかし、部分に基づく方法で、認識の根拠となる各部分の類似の度合いを可視化した研究は、これまでに提案されてはいない。

3. 提案手法

3.1 画像の想起




図 1 力学系における想起のイメージ

想起とは記憶した数多くの画像を利用して一枚の画像から別の画像を連想することであり、未知の画像から自分の知っている画像を思い出すといったヒトの連想記憶の模倣と見なすこともできる。

このような想起の実現法として、次の二つが考えられる。

エネルギー最小化：図1に示すように、想起すべき複数の画像で極小化されるエネルギー関数を設計すれば、その山下り計算が想起に相当する画像変換になる。しかし、一般にこのような関数は複雑になり、計算コストも膨大になってしまうという欠点がある。

不動点の利用：フラクタル圧縮と同様に、写像の不動点としてターゲット画像を埋め込む方法がある。この手法のメリットは、複雑で大規模なエネルギー関数を求めることなく、写像適用による想起が行えることである。しかし、複数の画像を不動点として埋め込んだ写像を求める手法が存在しないという問題点がある。

本研究では、複数の不動点を埋め込んだ写像を求めることにより、画像の想起を実現する方法を模索する。具体的には、データベース(以下 DB)を参照する事例ベースの非線形

回帰手法を用いることで、DB 内の個々の画像を不動点とする非線形写像を求め、これを入力画像に適用することで画像の想起を実現する。これは、図 2 に示すように、注目するレンジブロックに対する周辺のドメインブロックからの写像を、事例ベースの非線形写像で実現するというものである。この写像の入力に画像を与えると、ドメインブロックの類似したデータベース内の複数の画像を参照し、それらから、レンジブロック内の画像が生成される。

この手法では、入力が DB 内のいずれかの画像と完全に一致する場合には、非線形写像を何回適用しても入力画像は全く変化しない。つまり、その画像は写像の不動点になっていると言える。しかも、ドメインブロックはレンジブロックの周辺ブロックと固定しておいても、この性質は保たれる。

この事例ベースの非線形写像として Gaussian Process Regression を用いれば、出力は DB 内の画像ブロックに対する重み付けとして計算される。このため、その重みを DB 内の画像毎、あるいは、画像に関連づけられた人物 ID 毎に合算すれば、個人識別が行える。また、各レンジブロック毎に、どの人物 ID に対する重みが大きかったかなどを表示すれば、どここの部分が根拠になって識別が行われたのかを可視化することもできる。




図 2 本研究でのドメインとレンジブロック

3.2 Gaussian Process Regression

本節では本研究の非線形写像に用いる Gaussian Process Regression (以下 GPR とする) についての説明を行う。GPR は非線形の回帰計算手法であり、入力を非線形高次元写像である ϕ によって高次元化し、そのベクトルに対し線形回帰を行う手法の一つである。その線形モデルは式(1)で表される。

$$y(x) = \omega^T \phi(x) \quad (1)$$

x は入力ベクトル、 ω は回帰係数ベクトルであり高次元化された $\phi(x)$ とのとの内積によりスカラー値の出力 y を計算するものである。GPR ではまず ω の事前分布を、平均 0、分散 $\sigma^2 I$ のガウシアンと仮定する。すなわち式(2)となり、以下で表される。

$$p(\omega) = N(0, \sigma^2 I) \quad (2)$$

次に、入力ベクトル x の学習データが N 個与えられていると

き、 $\phi^T(x_n) (n = 1, \dots, N)$ を縦に並べた行列 $\Phi = (\phi(x_1), \dots, \phi(x_N))^T$ と、各 x_n に対応する出力 $y_n = y(x_n)$ を要素に持つベクトル $y = (y_1, \dots, y_N)^T$ を考えると、式(2)より式(3)と表される。

$$y = \Phi \omega \quad (3)$$

y は ω の線形変換なので、式(3)から y もまた Gaussian $p(y) = N(0, K)$ に従うはずである。これは、 y の平均と共分散がそれぞれ式(4)(5)になる為である。

$$E[y] = \Phi E[\omega] = 0 \quad (4)$$

$$\text{cov}[y] = E[yy^T] = \Phi E[\omega \omega^T] \Phi^T = \sigma^2 \omega \omega^T = K \quad (5)$$

ただし、 $K = [K_{nm}]$ は

$$[K_{nm}] = k(x_n, x_m) = \sigma^2 \phi^T(x_n) \phi(x_m) \quad (6)$$

を要素に持つグラム行列であり、 $k(x_n, x_m)$ は非線形写像 ϕ により高次元化したベクトル $\phi(x_n)$ と $\phi(x_m)$ 間の内積を与えるカーネル関数である (式(6))。このカーネル関数は Mercer[8] の条件を満たすものに限定されるが GPR では以下、式(7)の RBF カーネルがよく用いられる。

$$k(x_n, x_m) = \exp\left(-\frac{\|x_n - x_m\|^2}{\sigma_h^2}\right) \quad (7)$$

なお、 σ_h^2 は RBF カーネルの広がりを表す分散パラメータ。 y の平均値は式(5)式(6)に示す様に平均 0 共分散 K の正規分布であるが、実測された出力 $t = (t_1, \dots, t_N)^T$ が与えられている場合には、入力ベクトル x に対する出力を次の平均 μ_{GP} (式(8))、分散 σ_{GP}^2 (式(9)) を持つ正規分布として推定することができる。

$$\mu_{GP}(x) = k^T(x) K^{-1} t \quad (8)$$

$$\sigma_{GP}^2(x) = k(x, x) - k^T(x) K^{-1} t \quad (9)$$

ただし、 $k(x)$ は学習データ x_i と入力ベクトル x を引数とするカーネル関数を要素に持つベクトルであり、式(10)のように表される。

$$k(x) = (k(x_1, x), \dots, k(x_N, x))^T \quad (10)$$

なお、実際の観測値には式(11)に示す様にノイズも含まれる。

$$t_n = y_n + \varepsilon_n \quad (11)$$

ノイズ ε_n はそれぞれの y_n に対して、独立であり、平均 0、分散 β の Gaussian に従うと仮定する。この仮定の下では、式(8)(9)の K を、式(12) を要素とする行列 C に置き換え、式(6)の $k(x, x)$ を $k(x, x) + \beta$ とすればよい。

$$C_{mn} = k(x_n, x_m) + \beta I_{mn} \quad (12)$$

つまり、GPR とは、入力ベクトルの学習データとそれに対応する出力の学習データの組が与えられている時、新たに観測された x に対する出力を平均 μ_{GP} 、分散 σ_{GP}^2 の正規分布の形で推定出来る手法である。

3.3 動的 ActiveSet を用いた GPR

GPR におけるグラム行列 K のサイズは学習データの数に依存しており、学習データが大きくなれば、より正確な出力が得られる。しかし計算上 K の逆行列を求める必要があり、そのオーダーは $O(N^3)$ となり、計算負荷が非常に大

さい。そこで尾崎ら[9]は、学習データとしては多くのサンプルを保持しておき、実際の計算に際しては学習データの一部を選択して取り出すことで計算量の削減を行う方法を提案している。選択の基準としては、入力データと似ているもの、つまり観測データと学習データとのカーネル関数の値が大きいものから選ぶ。理由は以下に述べる。カーネル関数については以下の不等式(13)が成立する。

$$k(\mathbf{x}_i, \mathbf{x}_i) > k(\mathbf{x}_i, \mathbf{x}_j), i \neq j \quad (13)$$

式(13)は RBF カーネルにおいても、もちろん成立する条件である。この場合、式(10)では入力 $\mathbf{x}$ に最も似た $\mathbf{x}_i$ 応じて、カーネル関数の値 $k(\mathbf{x}_i, \mathbf{x})$ が最大になり、似ていない部分の値は小さくなる。ここで、GPR の計算の意味について考えると学習データ（出力）の事例 $\mathbf{t} = (t_1, \dots, t_N)^T$ に $\mathbf{k}^T(\mathbf{x})\mathbf{K}^{-1}$ というベクトルで重み付けをして出力が推定される。 $\mathbf{k}^T(\mathbf{x})$ に $\mathbf{K}^{-1}$ が掛けられている理由は、学習済みの $\mathbf{x}_i$ を与えたとき、その出力が t_i になるという関係性を満足させるためである（式(14)）。

$$\mathbf{k}^T(\mathbf{x}_i)\mathbf{K}^{-1} = \begin{pmatrix} 0, \dots, 0, & 1, & 0, \dots, 0 \\ & i\text{番目} \end{pmatrix} \quad (14)$$

この式(14)が成立することは式(15)、式(16)から示される事実から分かる。

$$\mathbf{K}\mathbf{K}^{-1} = \mathbf{I} \quad (15)$$

$$\mathbf{K} = (\mathbf{k}(\mathbf{x}_1), \dots, \mathbf{k}(\mathbf{x}_N))^T \quad (16)$$

以上より、GPR は事例に基づく計算であり、ある入力に対する出力を推定する場合、 $k(\mathbf{x}_i, \mathbf{x})$ の値が小さければ、出力の計算にほとんど影響を及ぼさないとと言える。よって図 3 のように観測データと類似している学習データ（カーネル関数の大きいデータ）を選択し、計算に用いることで大量のデータから $\mathbf{K}^{-1}$ の計算量が大きくなる問題を解決できる。また、通常の GPR のように巨大な逆行列を保持している場合に比べてメモリの消費量が少ない。




図 3 動的 ActiveSet を用いた GPR

本研究でもこの手法を用いて計算負荷を削減する。

3.4 GPR のベクトルへの拡張

GPR の結果である平均値 μ_{GP} は、本来スカラー値であるためベクトル値を求めることは出来ない。しかし、これは単純に式(9)における $\mathbf{t}$ を $\mathbf{T} = (t_1, \dots, t_N)^T$ とすればよい（松村ら[10]による）。

$$\mu_{GP}^T(\mathbf{x}) = \mathbf{k}^T(\mathbf{x})\mathbf{K}^{-1}\mathbf{T} \quad (17)$$

この式によってベクトルである平均値が求められる。

4. 実験

4.1 実験の準備

実験においては前述の説明で述べたように GPR を用いて部分ごとに非線形回帰計算を行う。そこに与える変数は図 4 に示すようにタイル状に画像をブロック分割したものを利用する。




図 4 画像をタイル状に分割

ブロックに分割して画像を扱うわけであるが、このままでは次元数が多い。PCA を利用して同じ位置のブロックごとに次元圧縮し、扱いやすい形にすることで効率よく計算を行うことができる。

以下に PCA とその利用による圧縮を簡単に説明する。

- (1) 変数が P 個あるサンプルが N 個ある場合を考え、個々のサンプルをベクトルとして扱う。この実験において変数 $\mathbf{x}$ は画素値を表し、 N は学習画像の枚数である。

$$\mathbf{v}_n = (x_{n1}, x_{n2}, \dots, x_{nP})^T \quad (n = 1, 2, \dots, N) \quad (18)$$

- (2) 各変数についてその平均値を求める。

$$\bar{\mathbf{v}}_n = \frac{1}{N} \sum_{n=1}^N \mathbf{v}_n = (\bar{x}_{n1}, \bar{x}_{n2}, \dots, \bar{x}_{nP})^T \quad (19)$$

- (3) それぞれの偏差から共分散行列 $\mathbf{S}$ を求める。

$$\mathbf{S} = \sum_{n=1}^N (\mathbf{v}_n - \bar{\mathbf{v}}_n)(\mathbf{v}_n - \bar{\mathbf{v}}_n)^T \quad (20)$$

- (4) 共分散行列について固有値問題を解き、固有値と固有ベクトルを算出する

$$\mathbf{S}\mathbf{e}(p) = \lambda(p)\mathbf{e}(p) \quad (p = 1, 2, \dots, P) \quad (21)$$

- (5) 固有値が大きいほうから任意（ただし、 $K < P$ ）の K 個の固有ベクトルを取り出し、それを基底とした固有空間を作る。

$$\mathbf{E} = (\mathbf{e}(1), \mathbf{e}(2), \dots, \mathbf{e}(K)) \quad (22)$$

- (6) 全サンプルの偏差を固有空間上に投影し、固有空間上の点を記録する。

$$\mathbf{z}_n = \mathbf{E}^T(\mathbf{v}_n - \bar{\mathbf{v}}_n) \quad (23)$$

以上の操作によって、個々のサンプルが P 次元から K 次元へと効率よく次元圧縮されたことになる。実際の実験においてはこの値を画像ブロックの代表として利用する。

4.2 学習データの組

ブロックを表すデータを実際に GPR へ渡すとき、その説明変数と目的変数は次の図 5 のように与える。




図 5 学習データの組

つまり分割したそれぞれのブロックをレンジブロックとして、その周辺8ブロックをドメインブロックとして与える。

4.3 実験に用いたデータ

実験に用いた顔画像は Olivetti-AT&T-ORL の”The Database of Faces”[11]である。112×92画素の濃淡画像であり40人の顔画像がそれぞれ10枚ずつ計400枚保持されている。実験では画像を4×4画素のブロックに重なり合わないように敷き詰めて分割した。用いた画像のうち40人9枚ずつ、計360枚の画像を学習に、残りの40人の画像1枚ずつ（図13）を観測画像として与えた。

4.4 実験結果

それぞれの観測画像に提案手法を適用し、生成された結果画像を図14に示す。画像右下の数字は、図13で割り振られた同じ個人IDの観測データから出力された結果であることを示している。下に示す図6は一例であるが、他の多くの場合でも目口鼻などの特徴的な構造物は十分に再現できないが多かった。



図 6 ID2番の観測画像（左）とその結果画像（右）

4.5 重みによる個人同定

GPRを事例ベースの計算とみなすことができることは3章で述べた。 $\mathbf{k}^T(\mathbf{x})\mathbf{K}^{-1}\mathbf{w}(\mathbf{x}) = (w_1, w_2, \dots, w_N)$ とすれば拡張GPRの推定値である式(17)は式(24)で表す事ができる。

$$\mu_{GP}^T(\mathbf{x}) = w_1 t_1 + w_2 t_2, \dots, w_N t_N \quad (24)$$

つまり、目的変数の線形結合で表す事ができる。この $\mathbf{w}(\mathbf{x})$ の要素を重みとしてみなし、最も重み係数が大きい要素を調べることで、どの学習データ(t_k)が主となって結果が生成されたかがわかる。図7は一枚の生成画像における全てのブロックの重み係数を個人ごとに分けて合算したグラフである。




図 7 ID27の重み合計

このグラフからIDが27番である学習画像を主として画像を生成したことがわかる。実際に観測画像はID27番の人物であった。なので、観測画像と主だった学習画像のIDは一致している。この結果は実験に使用した人物のほとんどの場合において同じであった（40人中39人）。個人毎に合算した重みを調べ、最も重みが高い人物を回答とすることによって個人を同定することが可能である。

4.6 部位ごとの重みによる認識

画像の生成はブロック単位で行われるため、ブロックごとに主として用いた学習データが存在することになる。それをIDごとに分類し、各ブロックに色別表示する。さらに、前述の個人同定に使われた人物がどの画像部分にまわっているかを調べる。全体として最も重みの大きいIDを画像の個人としたのであるから、そのIDがまわっている部分は認識の理由であると判断できる。

図8はID27番における観測データの結果画像とその生成時のブロックごとの最大の重みを持つIDを色別に分けて表した画像である。




図 8 ID27番における結果画像（左）と各ブロックの最大の重みを持つIDの色別表示（右）

図9は21番の人物における結果画像とその重み画像である。



図 9 ID21番における結果画像（左）と各ブロックの最大の重みを持つIDの色別表示（右）

二つを見比べると前者の画像は顔の右側や鼻の部分が認識の理由となっている。対して後者は頭の部分が認識の理由である。例えば、髪形や額の部分は個人を識別する理由としては弱いことから、前者に比べて後者の個人同定の評価は低くなる、ということが出来る。このように個人同定の根拠となった画像の部分を明確にすることで、人間による評価がしやすくなる。

4.7 考察

提案手法において個人の同定に誤りがある観測画像がひとつあった。図 13 における ID40 番の画像である。その観測画像と結果画像を以下の図 10 に示す。




図 10 ID40 番の観測画像 (左) とその結果画像 (右)

以下の図 11 は図 7 と同様のグラフを ID40 番について表したものである。




図 11 ID40 の重み合計

本来 40 番の重み合計が最も大きくなるべきだが、23 番と誤った結果を示している。また、ID5 番も十分に大きく無視できる値ではない。以下にそれぞれの 27 番と 5 番の学習画像から最も重みが大きかった画像を示す。



図 12 5 番 (左) と 27 番 (右) の学習画像

観測画像とこれらの学習画像を見比べると、似通った部分があることがわかる。このため重みを用いた個人同定に誤りが生じたものと思われる。

5. まとめ

本研究では、顔画像に対して部分領域ごとに想起を行なった。この結果を利用することで、認識の根拠を示しつつ個人同定を行うことが出来た。

5.1 今後の展望と課題

想起のために用いた GPR は本来、推定値とその分散を求めることが出来るものだが、本研究では分散を利用しなかった。これは GPR をベクトルに拡張したときにその分散を算出すると、分散の要素に負の値が発生し扱いにくいいためである。負の分散を利用できるようになるか、あるいは非負の分散を算出できるようになれば、想起における確信度のようなものが得られる。これによって個人認識に対する、より詳しい評価を期待できる。

また、写像変換の組は注目部分とその周辺、としていたがその周辺でなくとも、強い相関関係、つまり共起性の高い部分[12]であれば、より精度の高い想起結果が出る可能性がある。

謝辞 本研究は科研費 24300072 の助成を受けたものである。

参考文献

- 1) A.E.Jacquin: Image Coding Based on a Fractal Theory of Iterated Contractive Image Transformations. IEEE Trans. on image processing, Vol.1, No.1, pp.18-30 (1992).
- 2) 中野 馨: アソシエートロンとその応用—連想記憶装置に関する研究, 信学インホメーション理論研究, IT69-27 (1969).
- 3) Teuvo Kohonen: Correlation matrix memories. IEEE Trans. on computers, Vol.c-21, No.4, pp.353-359 (1972.4).
- 4) Anderson, J.A.: A simple neural network generation an associative memory. Math. Bioscience, Vol.14, pp.197-220 (1972).
- 5) Hopfield, J.J.: Neural networks and physical systems with emergent collective computational abilities. Proc. Natl. Acad. Sui. USA, 79, 2554-2558 (1982).
- 6) Matthew Turk and Alex Paul Pentland: Eigenface for recognition, Journal of Cognitive Neuroscience, Vol.3, pp.71-86 (1991).
- 7) Watanabe Satoshi: Kowing and Guessing, a quantitative study of inference and information, New York, John Wiley & Sons (1969).
- 8) Mercer, J.: Functions of positive and negative type and their connection with the theory of integral equations. Philosophical transactions of the royal society of London. Series A, containing papers of a mathematical or physical character, pp.415-446 (1909).
- 9) 和田俊和, 尾崎晋作, 前田俊二, 渋谷久恵: Gaussian Process Regression に基づく時系列データの異常モニタリング, 信学論 (D-II), vol.J96-D-II, no.12, pp.3068-3078, (2013.12).
- 10) Toshikazu Wada, Yuki Matsumura, Shunji Maeda and Hisae Shibuya: Gaussian Process Regression with Dynamic Active Set and Its Application to Anomaly Detection, The 9th International Conference on Data Mining (DMIN'13) (2013.7).
- 11) F.S. Samaria and A. Harter: Parameterisation of a stochastic model for human face identification. In Proc. 2nd IEEE WACV94, Sarasota, FL, USA, pp.138-142 (1994.12).
- 12) Makito Seki, Toshikazu Wada, Hideto Fujiwara and Kazuhiko Sumi: Background subtraction based on cooccurrence of image variations, Proc. IEEE Conf. CVPR, Madison, Wisconsin (2003).

付録



図 13 観測画像




図 14 提案手法の適用により生成された結果画像