

アンサンブル学習を用いた木構造状画像変換の高精度化

安藤 淳^{†1} 矢田 紀子^{†1} 長尾 智晴^{†1}

筆者らは先に、数種類の画像処理フィルタの適用順序および総数を遺伝的プログラミング (GP; Genetic Programming) によって最適化することで目的の画像処理を近似する方式を提案した。これを木構造状画像変換自動生成システム (ACTIT; Automatic Construction of Tree-structural Image Transformation) と呼ぶ。しかし、大量・多様の実画像を学習させた場合、すべての画像に対して有効な、1つの画像処理を構築することは難しい。そこで、本論文では、アンサンブル学習法の一つである AdaBoost (Adaptive Boosting) を ACTIT に応用し、複数の木構造状画像変換を組み合わせることによって有効な処理を構築するシステム、ACTIT-Boost を提案する。本手法は AdaBoost の理論に基づいているため、十分な数の木構造状画像変換を構築することで、学習した画像に対しては目標となる画像に正しく変換が行える処理となることが期待される。

Automatic Construction of Accurate Tree-structural Image Transformation Using Ensemble Learning

JUN ANDO,^{†1} NORIKO YATA^{†1} and TOMOHARU NAGAO^{†1}

We have already proposed the system which automatically constructs image processing with Genetic Programming (GP). It was named Automatic Construction of Tree-structural Image Transformation (ACTIT). However, it is difficult to construct an accurate image processing for all training image sets in case there are many and various images. It is necessary to combine many sub-routines of image processing. In this paper, we propose ACTIT-Boost which automatically constructs an accurate image processing by employing Adaptive Boosting (AdaBoost) to ACTIT. If there are enough number of weak classifier, AdaBoost has been proved to be extremely successful in producing accurate classifiers. Therefore, ACTIT-Boost constructs a perfect image processing for training image sets.

1. はじめに

近年、画像処理・認識は多くの問題で必要とされているが、取り扱う問題に強く依存していることが多く、対象ごとに逐一画像処理を構築するのは非常に困難で手間がかかる。また、医用画像処理など、専門的知識が必要な場合も多い。

そこで、これらの問題を解決するために様々な手法が提案されている。筆者らは先に、あらかじめ数種類の画像処理フィルタを用意し、そのフィルタの適用順序および総数を遺伝的プログラミング (GP; Genetic Programming)¹⁾⁻³⁾ によって最適化することで目的の処理を近似する方式を提案した。この方式は木構造状画像変換自動生成システム (ACTIT; Automatic Construction of Tree-structural Image Transformation)^{4),5)} と呼ばれ、これまでに様々な問題に適用され、その有効性が示されている。しかし、多様な特徴を持つ大量の実画像を学習させた場合、すべての画像に対して有効な、1つの画像処理を構築することは難しい。

そこで、本論文では、アンサンブル学習法の一つである AdaBoost (Adaptive Boosting)⁶⁾ を ACTIT に応用し、複数の木構造状画像変換を組み合わせることによって有効な処理を構築するシステム、ACTIT-Boost を提案する。AdaBoost は弱識別器と呼ばれる分類率が低い識別器を多数組み合わせることで全体として分類率の高い識別器を構築する手法である。本手法は AdaBoost の理論に基づいているため、十分な数の木構造状画像変換を構築することで、学習した画像に対しては目標となる画像に正しく変換が行える処理となることが期待される。数種類の実画像を用いて従来の ACTIT との比較実験を行い、提案手法の有効性を示す。

本論文の構成は次のとおりである。まず2章では、ACTIT や AdaBoost などの従来手法に関する解説を行い、3章では提案手法である ACTIT-Boost について述べる。4章では、提案手法による実験・考察を行い、提案手法の有効性を示す。最後に5章で結論について述べる。

^{†1} 横浜国立大学大学院環境情報学府

Graduate School of Environment and Information Sciences, Yokohama National University

2. 本論文に関連する従来研究

2.1 ACTIT

ACTIT^{4),5)} は GP を画像処理に適用した研究の 1 つである．この手法では，1 つあるいは複数の入力画像から 1 つの出力画像への変換を，あらかじめ用意した数種類の画像処理フィルタを任意の形の木構造に組み合わせることによって実現する．

図 1 に ACTIT システムの処理過程を示す．まず，処理対象となる原画像，それらに対する理想的な画像処理の結果である目標画像，必要に応じて，適応度評価の重みをその階調値の大きさで表現した重み画像を教師画像セットとして用意する．ここで，重み画像はシステムの適応度評価を人間の直観的な評価に近づけるために用いる．たとえば，図 1 の細胞画像では，検出対象である細胞壁が途切れることのないように検出対象の重みを大きい値（白），多少のノイズがあってもかまわない背景の重みを小さい値（灰色），対象の膨張を許容するように対象の周囲の重みを 0（黒）としている．

そして，教師画像セットを ACTIT に入力し，GP による木構造状画像変換の最適化を行う．最適化の際に用いる適応度は，得られた木構造状画像変換を原画像に適用したときの出

力画像と目標画像との差分に重み画像を乗じることによって計算される．木構造状画像変換の構築，変換，評価の操作が繰り返し行われることによって，最終的に，出力として最大適応度を持つ木構造状画像変換を得る．

このようにして生成された木構造状画像変換は，教師画像セットと同様な特徴を持つ未知画像に対しても有効であることが期待される．ACTIT はこれまでに 2 次元欠陥抽出画像処理や 3 次元医用画像処理⁷⁾ など，様々な問題に適用され，その有効性が示されている．

2.2 AdaBoost

AdaBoost⁶⁾ は Freund らによって提案された機械学習アルゴリズムの 1 つである．AdaBoost は弱識別器と呼ばれる分類率が低い識別器を多数組み合わせることで全体として分類率の高い識別器を構築する．弱識別器には任意の識別器を指定することができる．

AdaBoost の学習では，まず，学習データセット（入力ベクトルと出力ラベルの組）と均一の値で初期化された学習データの重みを用意する．そして，学習データの重みをもとにした弱識別器の構築，学習誤差・信頼度の計算，重みの更新の操作を繰り返す．最終的な分類結果は，それぞれの弱識別器の出力値を信頼度で重み付けした投票によって計算される．

このように AdaBoost では間違えやすいデータを優先的に学習する．また，弱識別器の学習誤差が 0.5 未満である場合，有限個の弱識別器を構築することで，学習データに対しては 100% 正しく分類できる強識別器が構築できることが保証されている．

3. ACTIT-Boost

3.1 ACTIT へのアンサンブル学習の適用

本論文では，ACTIT を改良し，高精度な木構造状画像変換を構築するシステムを提案する．本提案手法は，AdaBoost アルゴリズムから着想を得ている．2.2 節で述べたように，AdaBoost では有限個の弱識別器を構築することで，学習データに対しては 100% 正しく分類できる強識別器が構築できることが保証されている．このため，AdaBoost の学習アルゴリズムを適用した提案手法である ACTIT-Boost は，十分な数の木構造状画像変換を構築することで，学習した画像に対しては目標となる画像に正しく変換が行える処理となることが期待される．

表 1 に AdaBoost と ACTIT-Boost の対応について示す．ACTIT-Boost では，AdaBoost における学習データが画像中の画素値，データの重みが重み画像，弱識別器が木構造状画像変換，分類率が画像処理の適応度，識別クラス（0 or 1）が出力階調値（黒 or 白）に対応する．なお，ACTIT-Boost は，2 値識別器である AdaBoost の学習アルゴリズムが適用さ

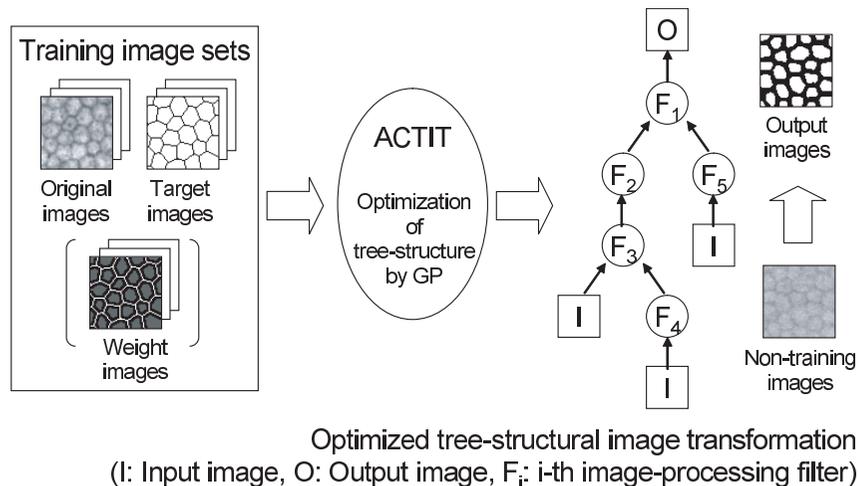


図 1 ACTIT システムの処理過程
Fig. 1 The processing flow of ACTIT system.

表 1 AdaBoost と ACTIT-Boost の対応
Table 1 The correspondence of AdaBoost and ACTIT-Boost.

AdaBoost	ACTIT-Boost
Data	Pixel values
Weight of data	Weight images
Weak classifier	Optimized tree-structural image transformation
Classifier rate	Fitness of image processing
Classes	Black or white as pixel values

れているため、最終的な出力画像が 2 値となる画像処理問題を対象としている。

3.2 ACTIT-Boost の学習アルゴリズム

ACTIT-Boost の基本的な学習過程は AdaBoost と同様である。ACTIT-Boost の学習過程について図 2 に、学習アルゴリズムの詳細について次に示す。

- (1) 教師画像セットとして、原画像と目標画像を K 組用意する。
- (2) 各教師画像セットに対応する重み画像を均一の階調値で初期化する。
- (3) 次の操作を N 回繰り返す。

For $n = 1$ to N

- (a) 教師画像セットをもとに、従来の ACTIT と同様の方法で、木構造状画像変換を構築する。これを弱木構造状画像変換と呼ぶ。
- (b) 次式から構築された弱木構造状画像変換の重み付き学習誤差 ε_n を計算する。

$$\varepsilon_n = \frac{1}{K} \sum_{k=1}^K \left\{ \frac{\sum_{i=1}^W \sum_{j=1}^H w_{n,k}(i,j) |o_{n,k}(i,j) - t_k(i,j)|}{\sum_{i=1}^W \sum_{j=1}^H w_{n,k}(i,j) V_{max}} \right\} \quad (1)$$

ここで、 $w_{n,k}(i,j)$ は重み画像、 $o_{n,k}(i,j)$ は原画像に木構造状画像変換を適用することで得られた出力画像、 $t_k(i,j)$ は目標画像である。また、各画像は i, j 方向の画素数を W, H とし、各画素は 0 から V_{max} までの整数値をとるものとする。 $\varepsilon_n < 0.5$ となる弱木構造状画像変換を構築できなかった場合はもう 1 度やり直す。

- (c) 次式から信頼度 α_n を計算する。

$$\alpha_n = \frac{1}{2} \log \frac{1 - \varepsilon_n}{\varepsilon_n} (> 0) \quad (2)$$

- (d) 重み画像 $w_k(i,j)$ を更新する。

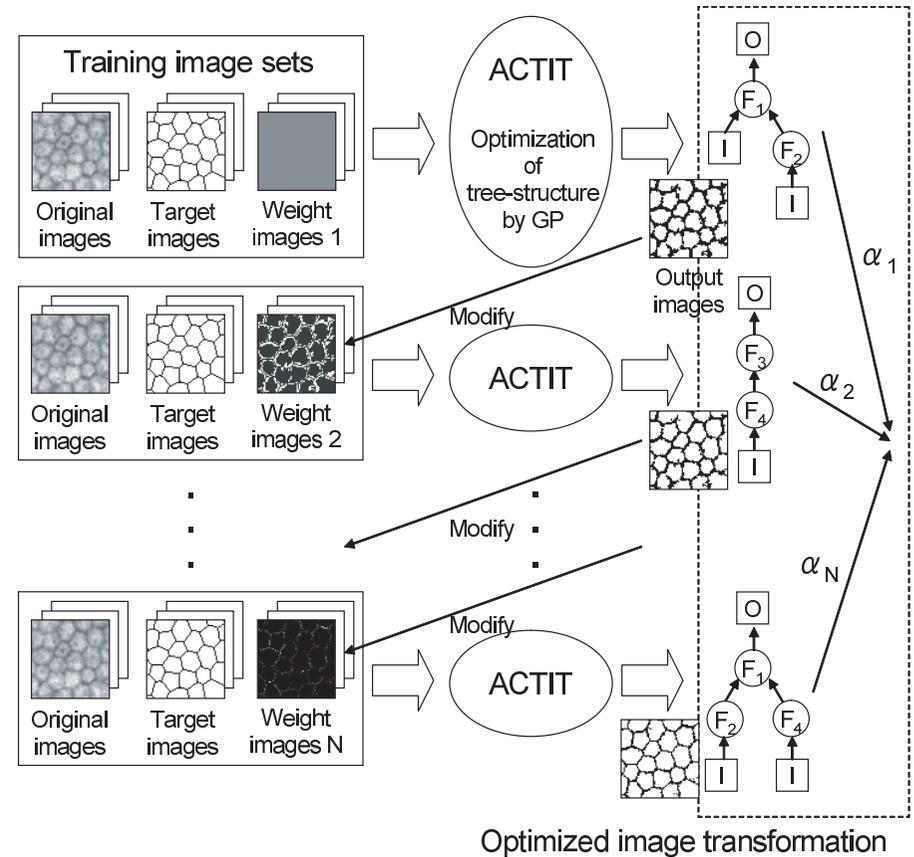


図 2 ACTIT-Boost の学習過程
Fig. 2 The processing flow of ACTIT-Boost.

$$w_{n+1,k}(i,j) = w_{n,k}(i,j) \exp \left\{ -\alpha_n \left(\frac{2t_k(i,j)}{V_{max}} - 1 \right) \left(\frac{2o_{n,k}(i,j)}{V_{max}} - 1 \right) \right\} \quad (3)$$

- (e) 重み画像 $w_k(i,j)$ を正規化する。
- (4) 以上の操作で N 個の弱木構造状画像変換が構築される。最終的な出力画像 $o_{N,k}(i,j)$ は次式で出力される。

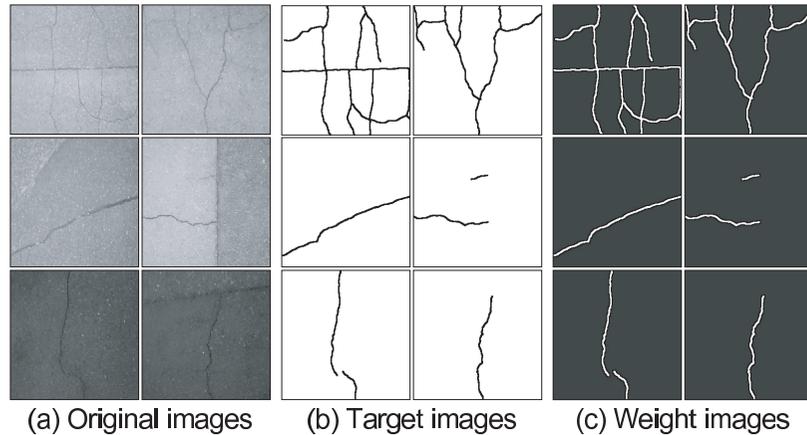


図 3 コンクリートクラック検出画像
Fig. 3 Concrete cracks detection images.

$$o_{N,k}(i,j) = \text{sign} \left\{ \sum_{n=1}^N \alpha_n \left(\frac{2o_{n,k}(i,j)}{V_{max}} - 1 \right) \right\} \quad (4)$$

このように、画像中の間違いやすい部分を重点的に学習することによって、高精度な画像処理が構築されることを期待する。なお、従来の ACTIT と同様に初期の重み画像を設定する場合は、初期の重み画像に更新された重み画像を掛けたものを用いる。

3.3 従来手法との相違点

従来の ACTIT では多様な特徴を持つ大量の教師画像セットを用いて学習を行った場合、1 本の木構造状画像変換ですべての教師画像セットに対して有効な画像処理を構築することは難しかった。しかし、本提案手法は AdaBoost の理論に基づいているため、十分な数の木構造状画像変換を構築することで、学習した画像に対しては目標となる画像に正しく変換が行える処理となることが期待される。加えて、大量・多様の教師画像セットを用いて学習することで、未知画像に強い、汎用性の高い画像処理が構築されることも期待される。

また、従来の ACTIT では、教師画像セットとして原画像、目標画像に加えて、適応度評価の重みをその階調値の大きさに表現した重み画像を用意する必要がある。木構造状画像変換の効率的な構築のためには適切な重み画像の設定が必要不可欠であるが、それを事前に求めることは難しい。一方、提案手法では重み画像の設定を自動で行うことができる。

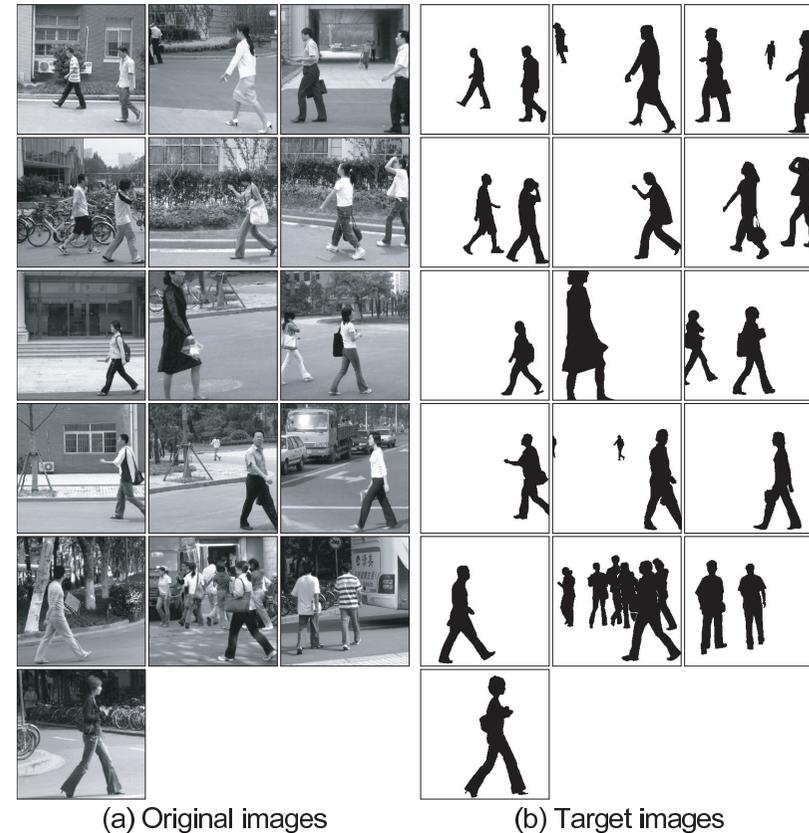


図 4 歩行者検出画像
Fig. 4 Pedestrians detection images.

4. 実験

4.1 実験設定

提案手法の有効性を確かめるために、従来の ACTIT との比較実験を行った。教師画像セットとしてコンクリートクラック検出を目的とした画像 6 セット、歩行者検出を目的とした画像 (Penn-Fudan Pedestrian Database)⁸⁾ 16 セットを用いる。これらの画像は、明る

表 2 GP のパラメータ設定
Table 2 GP parameters setting.

	ordinary ACTIT	ACTIT-Boost
Number of generations	30,000, 100,000	1,000
Population size	200	50
Maximum number of nodes	40, 100	10
Number of tree-structural image transformations	1	1,000, 3,000
Crossover rate	1.0	
Mutation rate (for individual)	0.9	
Alternation model	Minimal Generation Gap (MGG) ⁹⁾	
Selection	Tournament selection	
Number of MGG children	40	5
Tournament size	2	

さの違い、テクスチャ間の境界、検出すべきオブジェクトの数、さらに異なる背景などの多様な特徴を持っている。教師画像セット数は、対象となる画像の多様性を考慮し、主な特徴を持つ画像を網羅できるように定めた。図 3、図 4 に用いた教師画像セットについて示す。これらのカラー画像を RGB 色空間における Red, Green, Blue, L^*, a^*, b^* 色空間における L^*, a^*, b^* の 6 成分に分割し、入力画像とした。また、コンクリートクラック検出画像については従来の ACTIT、提案手法ともに、検出対象と背景の面積差から背景の重みを非常に小さくし、また対象の膨張を許容するように設定した初期の重み画像を与えた。重み画像について従来の ACTIT と提案手法で同様の設定にしたのは、両手法において同じ条件で適応度を算出するためである。

従来の ACTIT で使用した GP のパラメータは、どのような画像に対してもある程度の性能が期待できると考えられる一般的な数値を採用した。提案手法では、弱木構造状画像変換を構築するために、世代交代数、個体数、最大ノード数などを小さい値に設定した。世代交代数が設定値に達する、あるいは最良個体の適応度がしきい値（本実験では 0.6）以上になるとその弱木構造状画像変換の学習は終了する。表 2 に GP のパラメータ設定について示す。パラメータが 2 種類設定されているものについては、左側がコンクリートクラック検出画像用、右側が歩行者検出画像用である。歩行者検出画像はコンクリートクラック検出画像と比較して難しい問題であるため、いくつかのパラメータで大きめの値を設定している。

加えて、本実験では GPU (Graphics Processing Unit)^{10),11)} を用いた処理の高速化手法¹²⁾ を適用した。画像処理フィルタとして表 3 に示すような、注目画素、およびその近傍

表 3 GPU 上で実装された画像処理フィルタ
Table 3 Image-processing filters on GPU.

フィルタ名	記号	処理内容
1 入力 1 出力フィルタ		
Mean	Mea	平均値フィルタ
Maximum	Max	最大値フィルタ
Minimum	Min	最小値フィルタ
Median	Med	中央値フィルタ
Sobel	Sob	Sobel フィルタ
SobelH	SoH	水平方向 Sobel フィルタ
SobelV	SoV	垂直方向 Sobel フィルタ
Prewitt	Pre	Prewitt フィルタ
Range	Ran	レンジフィルタ
Laplacian	Lap	Laplacian フィルタ
Gaussian	Gau	Gaussian フィルタ
Vivid	Viv	鮮鋭化フィルタ
LightEdge	LiE	白エッジ検出
DarkEdge	DaE	黒エッジ検出
LightPixel	LiP	しきい値 (平均階調値) 未満の画素を黒にする
DarkPixel	DaP	しきい値 (平均階調値) 以上の画素を白にする
Inversion	Inv	反転フィルタ
BinarizationMean	BiM	平均階調値をしきい値とした 2 値化
LinearTransform	LTr	ヒストグラムの線形変換
Variance	Var	分散フィルタ
VarianceInversion	VIn	分散 × 反転フィルタ
Gamma	Gam	ガンマ補正フィルタ ($\gamma = 2.0$)
Square	Squ	2 乗変換フィルタ ($\gamma = 0.5$)
Opening	Ope	Opening フィルタ
Closing	Clo	Closing フィルタ
Mean9	Me9	平均値フィルタ (9 × 9)
BinarizationMean9	BM9	局所領域の平均階調値をしきい値とした 2 値化
AddConst	Add	定数加算フィルタ
SubConst	Sub	定数減算フィルタ
2 入力 1 出力フィルタ (f_1 : 入力画像 1, f_2 : 入力画像 2)		
LogicalSum	LoS	論理和 ($\max(f_1, f_2)$)
LogicalProd	LoP	論理積 ($\min(f_1, f_2)$)
AlgebraicSum	AlS	代数和 ($f_1 + f_2 - (f_1 \times f_2 \div V_{max})$)
AlgebraicProd	AlP	代数積 ($f_1 \times f_2 \div V_{max}$)
BoundedSum	BoS	限界和 ($f_1 + f_2$)
BoundedProd	BoP	限界積 ($f_1 + f_2 - V_{max}$)
DrasticSum	DrS	激烈和 ($f_1 = 0 \rightarrow f_2, f_2 = 0 \rightarrow f_1, f_1, f_2 \neq 0 \rightarrow V_{max}$)
DrasticProd	DrP	激烈積 ($f_1 = V_{max} \rightarrow f_2, f_2 = V_{max} \rightarrow f_1, f_1, f_2 \neq V_{max} \rightarrow 0$)
Difference	Dif	差分フィルタ ($\text{abs}(f_1, f_2)$)
Average	Ave	平均フィルタ ($(f_1 + f_2) \div 2$)

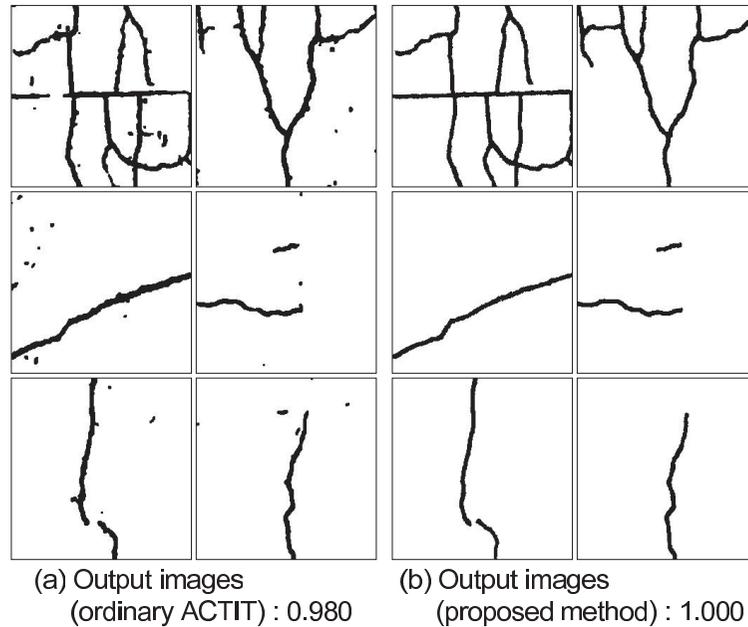


図5 コンクリートクラック検出画像における従来の ACTIT と提案手法の比較実験結果

Fig. 5 Experimental results of comparison of ordinary ACTIT and the proposed method in case of concrete cracks detection images.

画素の積和演算などを中心とした比較的単純なものを 39 種類用いた。

4.2 従来の ACTIT と提案手法の比較実験

最初に、構築された画像処理を教師画像セットに適用したときの出力画像について述べる。図 5、図 6 にそれぞれの出力画像と構築された画像処理の適応度（図の下部にある数字）を示す。なお、出力画像はそれぞれ 5 回の試行において最も適応度が高かったときの結果、適応度は平均値である。

コンクリートクラック検出画像に対しては、従来の ACTIT、提案手法ともに良好にクラック部分を検出できている。しかし、従来の ACTIT では、テクスチャ間の境界部分にノイズが残ってしまっている。一方、提案手法では、ノイズはまったく存在せず、出力画像を目標画像に完璧に近似できている。歩行者検出画像に対しては、教師画像セット数が多かったために、従来の ACTIT では十分な画像処理が構築できておらず、特に、背景が複雑なもの

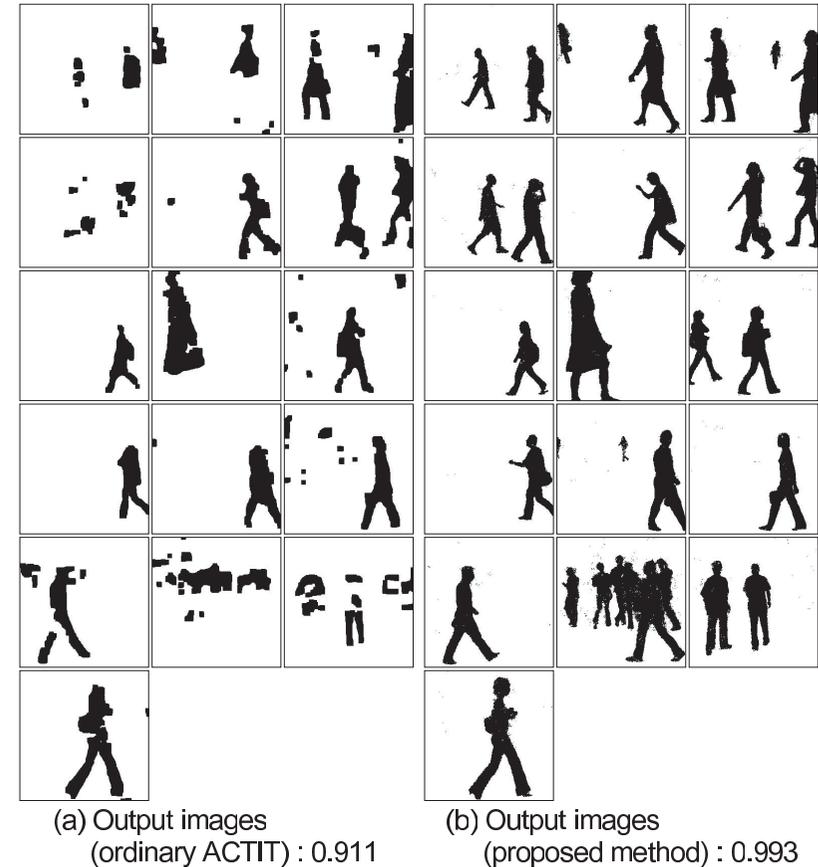


図 6 歩行者検出画像における従来の ACTIT と提案手法の比較実験結果

Fig. 6 Experimental results of comparison of ordinary ACTIT and the proposed method in case of pedestrians detection images.

や検出すべき歩行者が多く存在している画像については歩行者をうまく検出できていない。一方、提案手法では、わずかなノイズが存在するものの、教師画像セットに対してはほぼ完璧な画像処理が構築できている。

また、図 7 に横軸を処理時間 [秒] とした、従来の ACTIT と提案手法の学習過程における適応度変化のグラフを示す。従来の ACTIT では、適応度がある程度まで高くなると解

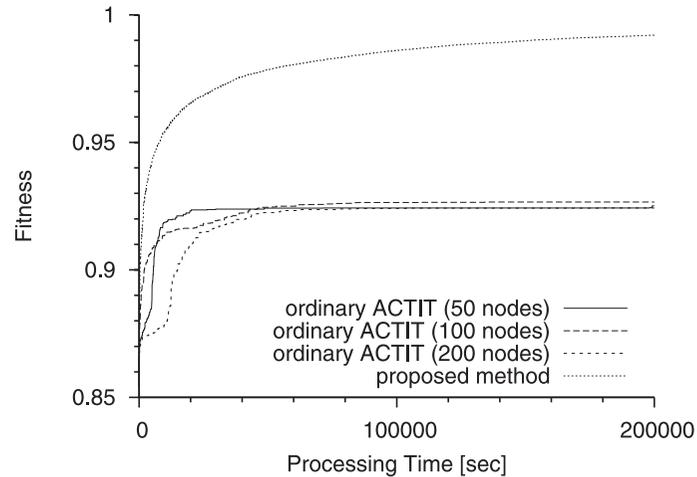


図7 学習過程における適応度変化
Fig. 7 Fitness of learning process.

が収束してしまい、世代交代数やノード数を大きくしてもそれ以上良い画像処理を構築できていない。一方、提案手法では、AdaBoostの学習アルゴリズムを用いているため、適応度が1.0付近に到達するまで効率的に学習できている。これによって、提案手法が従来のACTITと比較して高い学習能力を持っていることが示された。

4.3 未知画像への適用

次に、構築された画像処理を学習に用いていない未知画像に適用したときの出力画像について述べる。図8、図9にそれぞれの出力画像と未知画像に対する構築された画像処理の適応度を示す。加えて図9には、図中の6セットを含む100セットの未知歩行者検出画像に対する、構築された画像処理の適応度の平均値も合わせて示す。なお、未知画像に対する適応度は、出力画像と手動で作成した未知画像に対する目標画像と重み画像から計算されたものである。

コンクリートクラック検出画像に対しては、従来のACTIT、提案手法ともにクラック部分の検出が行えている。しかし、提案手法の方がクラック部分の検出漏れもなく、より良い出力画像が得られていることが分かる。歩行者検出画像に対しては、従来のACTITでは歩行者が検出できていなかったり、形状が大きく変形してしまったりしている。一方、提案手法では、検出された歩行者の一部が欠けているものの、形状は比較的保たれている。100

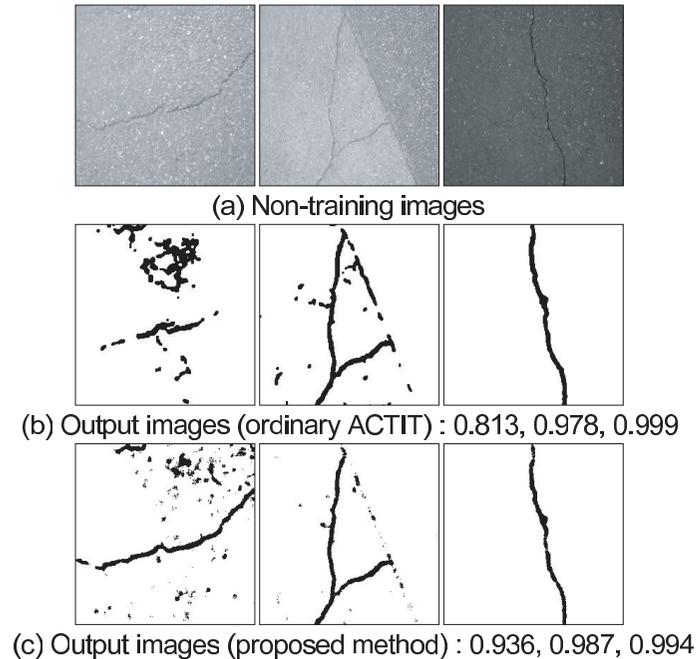


図8 コンクリートクラック検出画像における構築された画像処理を未知画像に適用したときの実験結果
Fig. 8 Application of optimized tree-structural image transformations to non-training images in case of concrete cracks detection images.

セットの未知画像に対する適応度においても、提案手法は従来のACTITを上回っている。実験結果から、未知画像に対して、提案手法によって構築された画像処理が従来のACTITのものよりも有効であることは明らかである。これは、大量・多様の教師画像セットに対して有効な画像処理を構築することで、未知画像に対しても有効な画像処理が得られたからであると考えられる。

4.4 構築された画像処理の構造

最後に、構築された画像処理の構造について考察する。図10に構築された弱木構造状画像変換の例を示す。

弱木構造状画像変換として、エッジ情報をもとに歩行者を大雑把に検出するフィルタ、色情情報をもとに歩行者の一部を検出するフィルタ、自転車などエッジを多く含む物体を検出

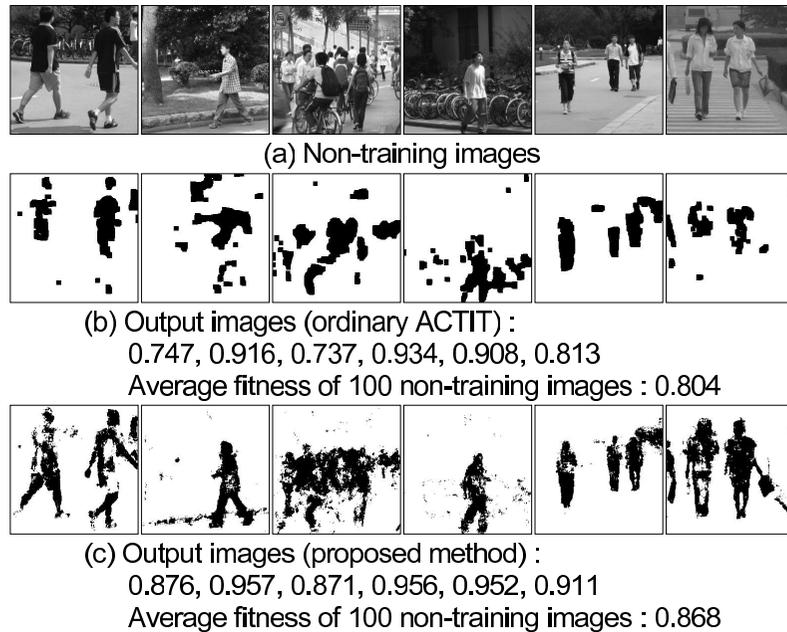


図 9 歩行者検出画像における構築された画像処理を未知画像に適用したときの実験結果

Fig. 9 Application of optimized tree-structural image transformations to non-training images in case of pedestrians detection images.

するフィルタなど、様々な役割を持つフィルタが見られた。このことから、ACTIT システムの中でアンサンブル学習の仕組みが有効に働いていることが分かる。一方、ノイズだけを出力するフィルタなど、一見どのような動きをしているのか分からないものも見られた。このようなフィルタは物体と背景の境界部分の微調整などの働きをしているのではないかと考えられる。

5. おわりに

本論文では、AdaBoost を ACTIT に応用し、複数の木構造状画像変換を組み合わせることによって有効な処理を構築するシステム、ACTIT-Boost を提案した。提案手法では、多様な特徴を持つ大量の教師画像セットに対して有効な画像処理を構築できることを示した。また、大量の教師画像セットを学習して構築した画像処理が未知画像にも有効であることを

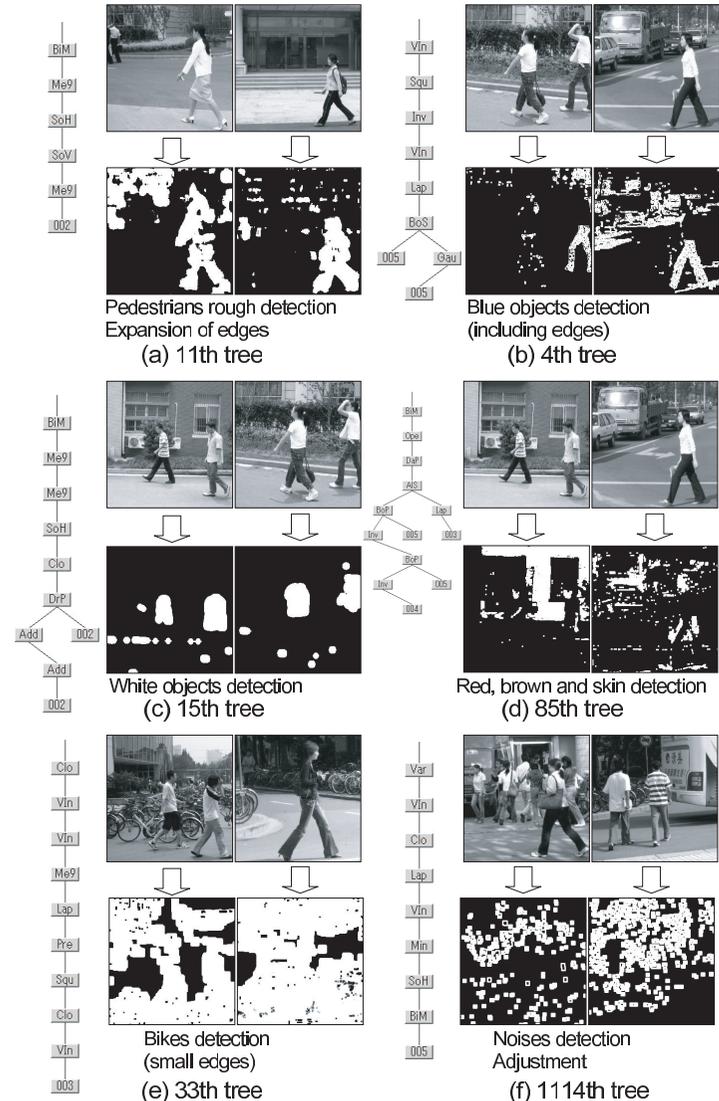


図 10 構築された弱木構造状画像変換の例

Fig. 10 Weak tree-structural image transformations.

示した。

本研究を発展させるためには、さらに考慮すべき要因がいくつか存在する。今回用いた画像以外にも本提案手法を適用し、評価することが必要である。また、より ACTIT に特化した新たな学習方法の提案も必要である。以上のことを考慮し、大量・多様の実画像に対応した超高速進化的画像処理システムの構築を目指す。

参 考 文 献

- 1) Holland, J.H.: *Adaptation in Natural and Artificial Systems*, University of Michigan Press (1975), MIT Press (1992).
- 2) Goldberg, D.E.: *Genetic Algorithms in Search, Optimization and Machine Learning*, Addison Wesley (1989).
- 3) Koza, J.R.: *Genetic Programming: On the Programming of Computers by Means of Natural Selection*, MIT Press (1992).
- 4) 青木紳也, 長尾智晴: 木構造状画像変換の自動構築法 ACTIT, 映像情報メディア学会誌, Vol.53, No.6, pp.888-894 (1999).
- 5) 長尾智晴: 進化的画像処理, 昭晃堂 (2002).
- 6) Freund, Y. and Schapire, R.E.: A decision-theoretic generalization of on-line learning and an application to boosting, *Journal of Computer and System Sciences*, Vol.55, No.1, pp.119-139 (1997).
- 7) Nakano, Y. and Nagao, T.: Automatic Extraction of Internal Organs Region from 3D PET Image Data using 3D-ACTIT, *Proc. International Workshop on Advanced Image Technology 2006 (IWAIT '06)*, Okinawa, Japan (2006).
- 8) Wang, L., Shi, J., Song, G. and fan Shen, I.: Object Detection Combining Recognition and Segmentation, *8th Asian Conference on Computer Vision 2007 (ACCV '07)*, Tokyo, Japan (2007).
- 9) 佐藤 浩, 小野 功, 小林重信: 遺伝的アルゴリズムにおける世代交代モデルの提案と評価, 人工知能学会誌, Vol.12, No.5, pp.734-744 (1997).
- 10) Fernando, R.: *GPU Gems: Programming Techniques, Tips and Tricks for Real-Time Graphics*, Addison Wesley (2004).
- 11) Pharr, M. and Fernando, R.: *GPU Gems 2: Programming Techniques for High-Performance Graphics and General-Purpose Computation*, Addison Wesley (2005).

- 12) 安藤 淳, 長尾智晴: 複数の GPU を用いた超高速進化的画像処理システム, 情報処理学会論文誌: 数理モデル化と応用 (TOM), Vol.2, No.2, pp.113-121 (2009).

(平成 21 年 11 月 18 日受付)

(平成 22 年 1 月 6 日再受付)

(平成 22 年 1 月 12 日採録)



安藤 淳

昭和 58 年生。平成 17 年横浜国立大学工学部電子情報工学科卒業。平成 19 年同大学大学院環境情報学府情報メディア環境学専攻博士前期課程修了。現在、同博士後期課程在学中。画像処理、進化計算法、GPGPU 等に関する研究に従事。



矢田 紀子

昭和 56 年生。平成 15 年横浜国立大学工学部電子情報工学科卒業。平成 17 年同大学大学院環境情報学府情報メディア環境学専攻博士前期課程修了。平成 20 年同博士後期課程修了。現在、同大学特任教員(研究教員)。博士(工学)。画像処理、神経回路網等に関する研究に従事。



長尾 智晴(正会員)

昭和 34 年生。昭和 60 年東京工業大学大学院博士後期課程中退。同年同大学工学部附属画像情報工学研究施設助手。同大学工学部助教授を経て、平成 13 年横浜国立大学大学院環境情報研究院教授、現在に至る。工学博士。画像処理、進化計算法、神経回路網、分散人工知能等に関する研究に従事。