

# クラスタ型コンピュータを用いた Genetic Image Network for Image Classification の 並列処理による高速化

山森 一人<sup>a)</sup>・吉田 卓矢<sup>b)</sup>・相川 勝<sup>c)</sup>

## Accelerating of Genetic Image Network for Image Classification by Parallel Computation using Computer Cluster

Kunihito YAMAMORI, Takuya YOSHIDA, Masaru AIKAWA

### Abstract

Recently, the number of digital images we have is increasing as popularizing cellular phone with digital camera. To manage these digital images, some researches investigate new technologies for automatic image classification. Since image classification technologies depends on target images, it is difficult to decide what kinds of techniques and classification threshold should be used. To solve this problem, a technique, called as Genetic Image Network for Image Classification (GIN-IC), has been proposed that builds an image classification algorithm automatically. However, GIN-IC requires a huge computation time. In this paper, we propose a high-speed GIN-IC with master-worker parallel computation model. A master broadcasts an individual to all workers, then workers compute the fitness in parallel by using a part of training images. These fitnesses are collected to the master, and the master calculates final fitness by summing up all the collected fitness. We implement our method in a cluster computer, and evaluate computation time until building suitable algorithm that classifies digital images into two classes. Our method achieved four times faster than that of serial model with a master and six workers.

**Keywords:** Genetic programming, Image classification, Parallel processing, Cluster computer

## 1. はじめに

近年、カメラ付携帯電話の普及などにより、大量のデジタル画像を個人が所有することが多くなってきた。こうした未分類の画像を自動で分類するための様々な研究が行われているが、一般に画像の分類は対象とする画像に大きく依存することから、使用する分類アルゴリズムの選択や分類の基準となる特徴量の決定は困難な問題の一つとされる<sup>1)</sup>。

この問題に対し、進化計算を取り入れることで画像分類アルゴリズムの構築や特徴量の決定を自律的に行う GIN-IC ( Genetic Image Network for Image Classification )<sup>2)</sup> が提案されている。GIN-ICは、単純なフィルタをネットワーク状に組み合わせることで画像分類アルゴリズムを表現し、その組み合わせ方を遺伝的プログラミング( GP)<sup>3)</sup> によって最適化することで目的の画像分類アルゴリズムを自動構築する手法である。また、多クラス分類問題への適応が可能であることや、2クラス分類問題において優秀な分類精度を示すSVM ( Support Vector Machine ) と

同等以上の分類精度が得られるなど有効性が示されている。しかし、GIN-ICには、いくつかの課題が残っており、その一つに処理時間の問題がある。これは、GIN-ICのベースとなっているGPでしばしば問題に挙げられるため、様々な高速化の研究が行われている<sup>4)</sup>。

GPの高速化手法では、個体集団を複数の部分集団に分割して並列に処理を行うことで高速化する島モデルが良く用いられる。しかし、GIN-ICでは次世代に1個体しか残さない進化戦略を採用しており、部分集団に分割できないため島モデルは適用できない。別の並列化手法としては、唯一のMasterが全体の制御を行い、Masterの指揮の下で複数のWorkerが処理を分担し、並列に処理を行うことで高速化するMaster-Workerモデルがある。

本研究では、GIN-ICの処理時間短縮を目的とし、Master-Workerモデルを用いて並列化したGIN-ICをクラスタ型並列計算機上に実装して処理時間を計測することで、並列化による効果を定量的に評価する。

## 2. Genetic Image Network for Image Classification (GIN-IC)

### 2.1 GIN-ICの概要

GIN-ICでは、複数のフィルタをフィードフォワード型

a) 工学教育研究部 准教授

b) 情報システム工学科学部生

c) 宮崎大学 工学部 教育研究支援技術センター技術職員

ネットワーク状に組み合わせることで画像分類アルゴリズムを表現し、GPを用いて組み合わせ方の最適化を行う。図1にGIN-ICのフローチャートを示し、以下に各操作を説明する。

1. 初期個体生成  
ランダムに個体を生成する。
2. 子個体生成  
遺伝的操作を行い、子個体を生成する。
3. 評価値計算  
教師画像サンプルに対する分類正解率によって子個体の評価値を決定する。
4. 選択・淘汰  
評価値を基に、次の親個体を1個体選択する。
5. 汎用性評価  
最終的に得られた個体の汎用性を評価する。

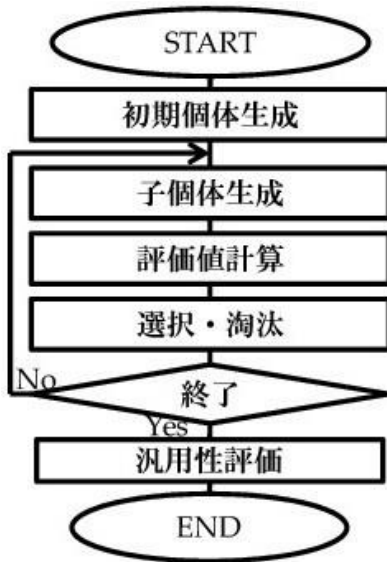


図1. 逐次処理のGIN-ICフローチャート

## 2.2 個体構造

GIN-ICによって構築される画像分類アルゴリズムは、入力ノード、画像変換ノード、特徴量抽出ノード、演算ノード、出力ノードの5種類のノードによって構成されるフィードフォワード型のネットワークとして表現される。

GIN-ICによって構築される画像分類アルゴリズムは、原画像に対して画像変換を行い、画像から特徴量を抽出した後、演算処理によって得られた数値を基に分類を行うという流れで行われる。また、各種ノードには入力ノード、画像変換ノード、特徴量抽出ノード、演算ノード、出力ノードの順にノード番号がNo.0から順に割り振られる。

各種ノードの入出力を表1に示す。なお、表1の「画像」とは、入力ノードに対応する原画像、もしくは画像変換ノードによる処理で生成された画像のことを指し、「数値」とは、特徴量抽出ノードによる処理で得られた

特徴量、もしくは演算ノードによる処理で算出された数値のことを指す

表1. ネットワークを構成するノード

ノード	入力	出力
入力ノード	画像	画像
画像変換ノード	画像	画像
特徴量抽出ノード	画像	数値
演算ノード	数値	数値
出力ノード	数値	数値

GIN-ICのノードには、表1で示すように、画像を入力とするノードと数値を入力とするノードが存在するため、ノード間の接続に対し制限を設ける必要が出てくる。具体的には以下のような接続の制限がある。

- 画像変換ノードへの入力  
入力ノード、画像変換ノードのみ接続可能。
- 特徴量抽出ノードへの入力  
入力ノード、画像変換ノードのみ接続可能。
- 演算ノードへの入力  
特徴量抽出ノード、演算ノードのみ接続可能。
- 出力ノードへの入力  
特徴量抽出ノード、演算ノードのみ接続可能。

入出力関係による接続の制限のほかに、フィードフォワード型ネットワークであるため、ノードへの入力は「自身のノード番号よりノード番号の小さいノード」に制限される。ここで、入力ノード数を $I$ 、画像変換ノード数を $T$ 、特徴量抽出ノード数を $F$ 、演算ノード数を $A$ とし、遺伝的操作によって各種ノードの数が変わることはないとした場合、 $N$ 番目のノードへの入力元のノード番号 $G$ を以下に示す範囲内に収めることで、前述した接続の制限を実現することができる。

- $N$ 番目のノードが画像変換ノードであった場合  
 $0 \leq G < N$
- $N$ 番目のノードが特徴量抽出ノードであった場合  
 $0 \leq G < I + T$
- $N$ 番目のノードが演算ノードであった場合  
 $I + T \leq G < N$
- $N$ 番目のノードが出力ノードであった場合  
 $I + T \leq G < I + T + F + A$

GIN-ICでは、生成した画像分類アルゴリズムを一次元の文字列に変換して遺伝子型とし、その遺伝子型に対して遺伝的操作を行う。遺伝子型は、入力ノードを除くすべてのノードについて、ノードの処理内容を表すコードと入力元のノード番号を順に記述することで表現する。

ノードの総数とノードへの入力数は固定であるため、遺伝子型は固定長の文字列で表現される。

ノード間の接続は、前述した制限を基にランダムに決定されるため、遺伝子型の上では、出力結果に影響を与えるノード (Active node) と影響を与えないノード (Inactive node) が混在する。また、フィルタには入力なし、1 入力、2 入力のものが存在するため、余剰な接続も存在する。そのため、遺伝子型をネットワークとして表す際には、Inactive node や余剰な接続は省略する。遺伝子型の例を図 2 に示し、その遺伝子型によって表現されるネットワーク構造を図 3 に示す。図 2 では、No.1、2、3、5、7 のノードは 1 入力フィルタと対応しているため、2 番目の入力は図 3 では省略されている。また、No. 8、11 のノードは Inactive node なので同様に省略されている。



図 2. 遺伝子型の例




図 3. 遺伝子型のネットワーク構造表現

### 2.3 遺伝的操作と世代交代モデル

GIN-IC では、世代交代モデルとして (1+4) ES と呼ばれる進化戦略を採用しており、遺伝的操作には突然変異のみを用いている。

まず突然変異について説明する。突然変異は、突然変異率  $P_m$  に従い、遺伝子座 (遺伝子型の一文字) 単位で発生する。突然変異が発生した場合、接続を示す遺伝子座であれば、その遺伝子座が取り得る範囲で一様乱数に従って変更される。ノードの処理内容を示す遺伝子座であれば、画像処理ノード、特徴量抽出ノード、演算ノードの各カテゴリ内で一様乱数に従って変更される。そのため、「画像変換ノードが特徴量抽出ノードに変わる」といった突然変異は発生せず、各カテゴリのノード数は一定に保たれる。

次に世代交代モデルについて説明する。GIN-IC で用いられている世代交代モデル (1+4) ES の処理手順を以下に示す。

1. 親個体としてランダムに1 個体生成する。
2. 親個体に対し突然変異操作を行い、子個体を4 個体生成する。
3. 全個体の内、最良個体を1 個体選択する。ただし、最良個体が複数存在する場合は子個体を優先する。それ以外の個体を淘汰する。
4. 終了条件を満たしていれば終了し、そうでない場合は最良個体を次の親個体として 2. へ戻る。

この世代交代モデルの利点は、GP を用いる際の問題としてよく挙げられる初期収束や局所最適解による進化の停滞が発生しにくいことである。(1+4) ES では、前述の 3. で子個体を優先して選択・淘汰を行うため、適応度に変化がなかった場合でも個体構造に変化が起こり得る。そのため、少ない個体数でも進化の停滞が発生しにくく、効率的な探索が行うことができる。また、この (1+4) ES は GIN-IC と同様なフィードフォワード型ネットワーク構造の表現をもつ CGP (Cartesian Genetic Programming) <sup>5)</sup> でも採用されており、実験的にその有効性が示されている。

### 3. GIN-ICの並列化

#### 3.1 Master-Workerモデル

Master-Workerモデルは、唯一のMasterが全体の処理の管理を行い、複数のWorkerはMasterの管理の下、処理を分担することで高速化を目指す並列処理手法である。処理の流れは以下の手順で行われる。

1. MasterはWorkerに対し処理を1つ割り当てる。
2. 各Workerは与えられた処理を行い、その結果をMasterへ返す。
3. MasterはWorkerから結果を受け取る。割り当てていない処理が残っている場合 1. へ戻る。

この手法の利点は、Workerの性能や分担する処理の計算量が均一でなくても動的に負荷分散が行われることである。低性能なWorkerや計算量の多い処理を任されたWorkerは、処理完了までの時間が長いため処理を割り当てられる回数は少なくなる。逆に高性能なWorkerや計算量の少ない処理を任されたWorkerは、処理完了までの時間が短いため処理を割り当てられる回数は多くなる。

欠点としては、複数のWorkerに対し、Masterは唯一という点である。Workerが増えるほど、全体の制御を行うMasterへの負荷が大きくなり、全体の性能が低下する恐れがある。

### 3.2 並列GIN-IC

予備実験により、GIN-IC全体の処理時間に対する各処理の処理時間の計測を行ったところ、処理時間の大半が評価値計算に費やされていることが分かった。図4にて各処理の処理時間の計測結果を示す。




図 4. GIN-IC の処理時間の割合 (世代数: 1000)

そのため本研究では、評価値計算に対しMaster-Workerモデルによる並列処理を適用することで高速化を図る並列GIN-ICを提案する。

並列GIN-ICでは、処理開始時に教師画像をWorker数分のグループに分けて各Workerに割り当てた上で、以下の手順に従い個体の評価値計算を行う。また、図5に提案手法のフローチャートを示す。

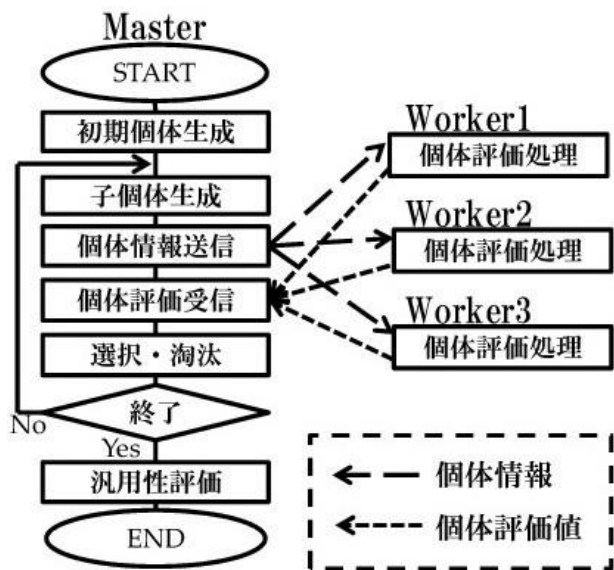


図 5. 並列 GIN-IC のフローチャート

1. Masterは全Workerに個体情報をブロードキャストする。
2. 各Workerは割り当てられた教師画像で評価値を求めた後、その結果をMasterに送信する。
3. Masterはそれらの総和を求め、最終的な個体の評価値を得る。

## 4. 実験と考察

### 4.1 実験環境とパラメータ設定

本研究では、GIN-ICの評価実験で用いられた人物画像と非人物画像を分類する2クラス分類問題を使用し、逐次処理のGIN-ICと並列GIN-ICの処理時間を比較する。なお、人物画像にはMIT Pedestrian Database <sup>a)</sup>の歩行者画像を、非人物画像にはVision Texture <sup>b)</sup>のテクスチャ画像とworld-space.com <sup>c)</sup>の風景画像を用いる。サンプル画像はクラス毎に800枚用意し、その中から100枚を教師画像、残り700枚を汎用性の評価値計算用画像として使用する。また、画像のサイズは64×128[pixels]で統一し、グレースケールに変換している。使用する画像の例を図6に示す。

評価実験を行うクラスタ型コンピュータの諸元を表2に、GIN-ICのパラメータを表3にそれぞれ示す。また、実験に使用するフィルタについてはカテゴリ別の総数、及びフィルタの一例を表4に示す



(a) 人物画像



(b) 非人物画像

図 6. サンプル画像の一例

表 2. クラスタ型コンピュータの諸元

計算ノード数	12台
プロセッサ数	2個/ノード
プロセッサ	Intel (R)Xeon (R)3060 @ 2.4GHz
コア数	4コア/プロセッサ
メインメモリ	16.0GB/ノード
メッセージ通信ライブラリ	Mpich2 ver.1.2.1p1

- a) <http://cbcl.mit.edu/software-datasets/PedestrianData.html>
- b) <http://vismod.media.mit.edu/vismod/imagery/VisionTexture>
- c) <http://www.pn-planet.co.jp/pn-photo/index.htm>

表 3. 評価実験でのパラメータ

パラメータ名	設定値
世代数	100,000
画像変換ノード数	100
特徴量抽出ノード数	100
演算ノード数	100
突然変異率	0.02

表 4. 使用するフィルタの一例

カテゴリ	総数	フィルタ名
画像変換	25	平滑化、Sobel、 2値化、線形変換、 差分、論理和 など
特徴量抽出	17	最大値、平均値、 中央値、最頻値、 範囲、尖度 など
演算	18	加算、逆数、 シグモイド変換、 閾値、定数 など

## 4.2 実験結果と考察

Worker 数を変化させたときの処理時間の変化を図7に示す。なお、図7に示す処理時間は、10回試行した結果の平均値を示している。

図7から、Worker 数を増やすことで処理時間が短縮できることが確認できる。特にWorker 数が6の時には、逐次処理のGIN-IC に比べ処理時間が約1/4に短縮されている。しかし、Worker 数を2から3にした時に比べ、5から6にした時の処理時間の短縮率は小さくなっている。また、Worker 数が1の時には逐次処理のGIN-IC よりも処理時間が増加している。

これらの原因として、Master-Worker 間の通信時間が考えられる。個体の評価値計算を行う際、Master-Worker 間で個体情報や評価値の送受信が行われる。評価値計算の処理は、Worker 数が増えるほど各Workerが担当する計算処理量は少なくなる。その反面、Master-Worker間の通信回数は多くなり、全体の通信時間は増加する。そのため、Worker 数を増やすほど処理時間の短縮率が小さくなったと考えられる。また、Worker数が1の時には、Workerの担当する計算量が逐次処理の時と変わらないため、通信時間の分、処理時間が増加したと考えられる。

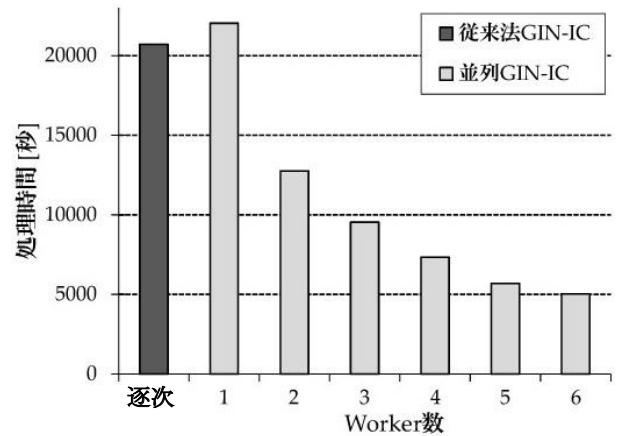


図 7. Worker 数に対する処理時間

## 5. おわりに

GIN-IC は、画像分類アルゴリズムの構築手法の一つであり、フィルタを追加することで機能の拡張や異なる分野への応用も期待できる。しかし、アルゴリズムの構築完了までに莫大な処理時間が必要という問題がある。

本研究では、GIN-ICの高速化を目的として、並列化手法の一つであるMaster-Workerモデルを適用し、教師画像をWorkerごとに分けることで、評価値計算処理を全Workerが分担して行う並列GIN-ICを提案した。また、逐次処理のGIN-ICと並列GIN-ICをクラスタ型コンピュータ上に実装し、処理時間を比較することで高速化の検証を行った。

実験の結果から、逐次処理でのGIN-ICと比較して、Worker数が6の並列GIN-ICでは処理時間を約76%短縮することができた。このことから、本研究の提案手法は有効であるといえる。しかし、Master-Worker間の通信時間の影響から、Worker数に見合った処理時間の短縮には至らなかった。

今後の課題としては、非同期通信による通信の待ち時間の削減や他の分類問題を使用した際の処理時間の検証が挙げられる。

## 参考文献

- 1) 柳井 啓司: 一般物体認識の現状と今後, 情報処理学会論文誌, Vol. 48, pp. 1-24, 2007.
- 2) 白川 真一, 中山 史郎, 矢田 紀子, 長尾 智晴: Genetic Image Networkに基づく画像分類アルゴリズムの自動構築, 人工知能学会誌, Vol. 25, pp. 262-271, 2010.
- 3) 伊庭 斉志: 遺伝的プログラミング, 東京電機大学出版局, 2001.
- 4) 黒瀬 慎吾: 簡易型係数探索と非同期移住による並列実数値型遺伝的プログラミングの高速化, 宮崎大学大学院 修士論文, 2012.
- 5) J. F. Miller: Cartesian Genetic Programming, Natural Computing Series. Springer, 2011.