

# 適応的遺伝的アルゴリズムに基づく VLSIフロアプランニングの一手法

中 矢 真 吾<sup>†</sup> 小 出 哲 士<sup>††</sup> 若 林 真 一<sup>†</sup>

本論文では VLSI レイアウト設計におけるフロアプランニング問題に対し、適応的遺伝的アルゴリズムに基づくフロアプランニング手法を提案する。提案手法では、問題の解をシーケンスペアを用いて染色体（個体）にコーディングし、フロアプラン問題用に新たに提案した複数の交差手法と突然変異確率を各染色体の適応度に応じて適応的に選択して適用することにより、短い計算時間で優良解を求めることを可能にしている。シミュレーティッドアニーリング（SA）と従来の非適応的遺伝的アルゴリズムに基づくフロアプランニング手法との比較実験の結果、適応的遺伝的アルゴリズムに基づく提案手法の有効性を示す。

## A VLSI Floorplanning Method Based on an Adaptive Genetic Algorithm

SHINGO NAKAYA,<sup>†</sup> TETSUSHI KOIDE<sup>††</sup> and SHIN'ICHI WAKABAYASHI<sup>†</sup>

This paper presents a floorplanning method based on an adaptive genetic algorithm (GA) for a floorplanning problem in VLSI layout design. In the proposed algorithm, a solution of the problem is coded as a chromosome (individual) with a sequence-pair representation. For each chromosome, the adaptive genetic algorithm selects an appropriate crossover operator among newly proposed crossover operators for the floorplanning problem as well as a mutation rate according to the fitness of the chromosome. A good solution can be produced in a short computation time with the adaptive strategy. Experimental results show the effectiveness of the proposed floorplanning method based on the adaptive GA compared with both a simulated annealing (SA) based and a non-adaptive GA based methods.

### 1. ま え が き

超大規模集積回路（VLSI）のレイアウト設計において重要な設計工程の 1 つに、論理機能を持つモジュールの集合をタイミングなどの与えられた制約を満足し、かつ、面積が最小となるようにチップ上に配置するフロアプランニングがある。フロアプランニング問題は矩形モジュールを互いに重なることなく、チップ面積を最小化するように配置する矩形パッキング問題に帰着できる。しかしながら、この矩形パッキング問題は NP 困難であることが知られており<sup>12)</sup>、そのため、従来より様々なヒューリスティック手法が提案されている<sup>9),10),12)</sup>。

近年、この矩形パッキング問題の解の表現方法の 1

つとして非スライシング構造<sup>12)</sup>も表現可能なシーケンスペア（Sequence-Pair,  $SP$ ）<sup>9)</sup>が提案されている。この解表現を用いると、与えられた矩形の集合に対し、有限な解空間に最適なフロアプランを含むことが保証されるため、この解表現に基づくシミュレーティッドアニーリング（SA）を解探索手法に用いたフロアプランニング手法が提案され良好な結果を得ている<sup>9)</sup>。そこで、本論文では SA と同様に複雑な組合せ最適化問題を解くアルゴリズムとして知られている遺伝的アルゴリズムに基づいて、 $SP$  表現を用いたフロアプランニング手法を提案し、解探索手法としての有効性を検証する。

遺伝的アルゴリズム（GA）<sup>3)</sup>は、自然界の進化モデルに基づいて考案された確率的アルゴリズムであり、問題の許容解を 1 つの個体と見なし、複数の個体からなる集団（個体群、あるいは人口）に対して、遺伝操作を繰り返し適用することにより解空間を探索する。しかし、GA は優れた解探索能力を持つ一方で、交差・突然変異の選択やそれらの適用確率などのパラメータ

<sup>†</sup> 広島大学大学院工学研究科  
Graduate School of Engineering, Hiroshima University

<sup>††</sup> 広島大学ナノデバイス・システム研究センター  
Research Center for Nanodevices and Systems, Hiroshima University

の設定を問題ごとに調整する必要がある。この GA の問題点を解決するため、著者らは問題のインスタスに於いて GA パラメータを自動的に設定する適応的 GA (EAGA) を提案している<sup>5),6)</sup>。EAGA では、エリート度と呼ばれる先祖にどれくらい優れた個体を持つかによって定義される個体の潜在的な優劣度を表す指標を用いて交差手法と突然変異確率を動的に選択することにより、解空間を効果的に探索し、質の良い解を得ることが可能である。

本論文では、この EAGA をフロアプランニング問題の解探索手法として適用する。提案手法では、*SP* を用いて問題の解をコーディングし、フロアプランニング問題のために本論文で新たに提案する交差・突然変異手法を適応的に適用することで解集合の更新を行い、解空間を探索する。

ベンチマークデータを用いたシミュレーション実験により従来手法である SA に基づくフロアプランニング手法と従来の GA である非適応的 GA に基づく手法との比較を行った結果、EAGA がフロアプランニング問題に対して SA に基づく手法と同等に解探索手法として有効な手法であることを示す。

本論文の構成は以下のとおりである。まず、2 章で問題の定式化、シーケンスペア、および適応的遺伝的アルゴリズムについて述べる。次に 3 章で今回新しく提案する EAGA のための遺伝オペレータとスケーリングについて説明する。4 章では計算機上での実験結果に基づいて提案手法の有効性を示す。最後に 5 章で本論文のまとめを行い、今後の課題について述べる。

## 2. 準備

### 2.1 フロアプランニング問題

本論文では適応的遺伝的アルゴリズム (EAGA<sup>5)</sup>) をフロアプランニング問題へ適用し、従来から解探索手法として使用されているシミュレーテッドアニーリング (SA) と同様にフロアプランニング手法の解探索手法として有効であるか検証することを目的としている。そこで、本論文で取り扱うフロアプランニング問題は、配置問題を一般化したものとして、与えられたモジュールの大まかな位置を決定する問題として取り扱う<sup>12)</sup>。各モジュール  $m_i \in M_{all} (0 \leq i < n)$  は矩形であり、あらかじめ高さ<sup>1)</sup>と幅<sup>2)</sup>が与えられている。与えられたモジュールの集合  $M_{all}$  の互いに重ならない配置をフロアプランと呼び、すべてのモジュールを囲む最小矩形をチップと呼ぶ。各モジュールはモジュールの周辺や内部に複数の端子を持ち、それらは入力<sup>3)</sup>と与えられるネットリストに基づいてモジュールの上の

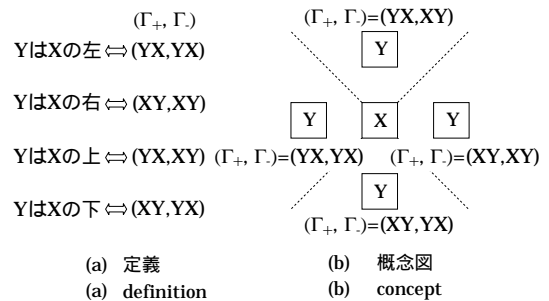


図 1 シーケンスペアの概念  
Fig. 1 A concept of a sequence-pair.

配線層を用いて配線されるものと仮定する。各ネットの配線長は、ネットのすべての端子を囲む最小矩形の半周長で評価する。本論文におけるフロアプランニング問題は、モジュールの集合  $M_{all}$  に対して、チップ面積とネットの総配線長の重み付き和が最小となるモジュールの配置を求めることである。この問題は NP 困難<sup>12)</sup> であることが知られており、一般に効率の良いヒューリスティックアルゴリズムが必要である。

### 2.2 シーケンスペア

シーケンスペア (Sequence-Pair, *SP*) は配置の対象となるモジュール名から構成される系列  $(\Gamma_+, \Gamma_-)$  によりモジュール配置を表現する方法である<sup>9)</sup>。各モジュール名は  $(\Gamma_+, \Gamma_-)$  のそれぞれの系列において 1 個ずつ含まれ、 $(\Gamma_+, \Gamma_-)$  の順列に基づいて任意の 2 つのモジュールの相対的な位置関係が指定される。

図 1 に概念図を示す。図 1 (a) は、任意の 2 つのモジュール  $X, Y$  が与えられたときの *SP* におけるモジュール名の前後関係と配置におけるモジュールどうしの上下左右の相対位置との関係を表しており、図 1 (b) は図 1 (a) を視覚的に示したものである。与えられた *SP* により、すべてのモジュールに対して図 1 のような相対位置を決定すれば、垂直、水平方向で互いに干渉せずにパッキングを行うことができる。

モジュールの相対位置が決まると、全モジュールの相対位置により作成される水平、垂直制約グラフ<sup>9)</sup> (それぞれ  $G_H, G_V$  とする) を用いてモジュール配置のパッキングを求め、チップ面積を計算する (図 2)。 $G_H, G_V$  に対し、対応するモジュールの幅、高さを辺の重みとして与え、始点から終点までの最長経路を

モジュール間に配線領域が必要な場合には、文献 11) などを用いられている配線領域の見積り手法を用いることにより対応することができる。

ここでは、問題を単純化するためにチップのアスペクト比に関する制約を与えていないが、後述の適応度関数においてペナルティとして取り扱うことで対応が可能である。

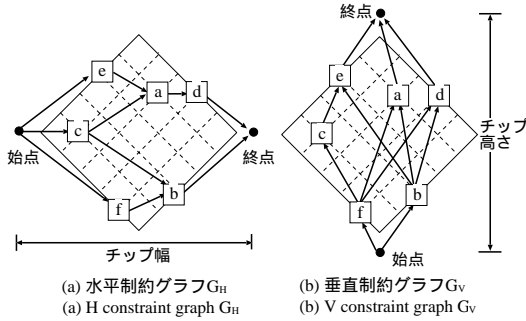


図 2 水平・垂直制約グラフ  
Fig. 2 H/V constraint graphs.

求める．各々の最長経路上の辺の重みの総和をチップ幅，チップ高さとして，その積を計算することによりチップ面積を求める．各モジュールの位置は，対応する節点にラベル付けされた値に基づいて 1 次元コンパクト化を行うことにより，モジュール間の隙間をなくした配置を決定する．その後，各ネットの配線長を半周近似により求め，全ネットの配線長の和をとることによりチップの総配線長を決定する．

2.3 適応的遺伝的アルゴリズム

GA は生物の進化の概念を模倣した確率的アルゴリズムで，問題の許容解を個体と見なし，個体の集団である人口に対して交差，突然変異などの遺伝オペレータを適用することにより解空間の探索を行う<sup>3)</sup>．GA は複雑な最適化問題に対しても質の良い解を生成可能であり，多くの分野で使われているが，その一方で，パラメータが多く，最適なパラメータ値の調整には多くの試行回数を必要とするという問題点がある．この問題点を解消するために，GA 実行中に GA で用いられるパラメータ値を適応的に調整する適応的 GA が提案されている．これまでに多くの適応的パラメータ値調整手法が提案されているが，それらの多くは個体集合全体に対するパラメータ値の調整のみを行っている．また，個体ごとに適用するパラメータ値を調整する場合においても，個体の適応度 (fitness) を個体の状態と見なすことにより調整を行うのが一般的であるが<sup>2)</sup>，個体の適応度は世代の経過により大きく変化するため個体の状態の推定には適さないと考えられる．

そこで，著者らは計算時間の短縮と解の質の向上を目的として，個体の潜在的な優劣の度合を示す指標としてエリート度 ( $E\_deg$ ) を提案し，GA 実行中に個々の個体について適用する遺伝オペレータやパラメータ値を動的に調整する適応的遺伝的アルゴリズム (EAGA) を提案している<sup>5),6)</sup>．エリート度は個体の生成過程に基づいて定義されるため，従来の適応度の




図 3 エリート度の計算例  
Fig. 3 An example of calculation of the elite degree.

みに基づいてパラメータ値を調整する場合と比較して，個体の潜在的な優劣を推定できるので性能の向上が期待できる．以下では EAGA のエリート度の定義について説明する．詳細については文献 5), 6) を参照されたい．

まず，初期解の世代を 0 として，現在の世代を  $T (\geq 0)$  とする． $x_i^T (0 \leq i < P)$ ，ここで  $P$  は個体数) を世代  $T$  における  $i$  番目の個体とし， $f(x_i^T)$  を  $x_i^T$  の適応度とする．さらに， $Anc(x_i^T, j)$  を  $T-j$  世代の  $x_i^T$  の祖先の集合とする．以下では最大化問題に対するエリート度を定義する．最小化問題に対しても同様に定義することができる．世代  $T$  中の個体の適応度の分布を正規分布と仮定して，世代  $T$  の適応度の平均値を  $\mu_T$ ，適応度の標準偏差を  $\sigma_T$  とする．このとき，世代  $T$  における  $i$  番目の個体  $x_i^T$  のエリート度  $E\_deg(x_i^T)$  を式 (1) のように定義する．

$$E\_deg(x_i^T) = \frac{\sum_{j=0}^{\min(T, l_{max})} \{ |Elite(x_i^T, j)| \cdot \beta^j \}}{\sum_{j=0}^{\min(T, l_{max})} \{ |Anc(x_i^T, j)| \cdot \beta^j \}} \quad (1)$$

ここで， $Elite(x_i^T, j)$  は個体  $x_i^T$  に対する世代  $T-j$  でのエリートである先祖の集合で，式 (2) で表される．

$$Elite(x_i^T, j) = \{ x_k^{T-j} \mid x_k^{T-j} \in Anc(x_i^T, j), \mu_{T-j} + \alpha \times \sigma_{T-j} \leq f(x_k^{T-j}) \} \quad (2)$$

ここで， $\alpha$  は非負の実数でエリート決定係数， $\beta$  はエリート度影響度係数と呼ばれる．また， $l_{max}$  をエリート度の定義のために過去にさかのぼる世代数の上限とする． $\min(T, l_{max})$  は  $T$  と  $l_{max}$  のうち小さい方を返す関数である．エリート度を求める計算例を図 3 に示す．図 3 において節点は個体を表し，枝は

文献 5), 6) では， $\alpha, \beta$  の設定値について実験的検証を行っており，その結果とフロアプランニング問題に対する予備実験から  $\alpha = 0.2, \beta = 0.5$  の値を採用した．

個体の親という関係を表す．ハッチのついた節点はエリート個体を表す． $l_{max} = 3$ とした場合の世代  $T$  の  $i$  番目の個体  $x_i^T$  のエリート度は，その個体から先祖をたどることにより図 3 のように計算できる．

提案 EAGA では，交差する親のエリート度の和に基づいて適用する交差手法と突然変異確率を適応的に選択する．交差においては，エリート度の高い個体には親の性質を多く残す交差手法，エリート度の低い個体には解空間を広く探索する交差手法を用いる．突然変異確率についても同様の考えで，エリート度の高い個体には低い突然変異確率，エリート度の低い個体には高い突然変異確率で突然変異を行い，エリート度の高い個体の良い性質を壊さないようにする．このように，エリート度により個体の潜在的な優劣を判別できるため，解空間の効果的な探索が可能となる．

### 3. 適応的遺伝的アルゴリズムに基づく提案フロアプランニング手法

#### 3.1 個体表現

提案手法では解(個体)のコーディング方法としてシーケンスペア  $SP$  を用いる．モジュール数  $n$  の場合，個体の染色体は長さ  $2n$  のシーケンスペア  $(\Gamma_+, \Gamma_-)$  と長さ  $n$  のモジュールの向き  $\Theta$  により構成され，染色体長を  $3n$  としてコーディングする．世代  $T$  の  $i(0 \leq i < P)$  番目の個体を  $x_i^T = (\Gamma_+^i, \Gamma_-^i, \Theta^i)$  で表す．ここで， $(\Gamma_+^i, \Gamma_-^i)$  は  $SP$  であり，それぞれ  $\Gamma_+^i = (\gamma_{+0}^i, \gamma_{+1}^i, \dots, \gamma_{+j}^i, \dots, \gamma_{+n-1}^i)$ ， $\Gamma_-^i = (\gamma_{-n}^i, \gamma_{-n+1}^i, \dots, \gamma_{-n+j}^i, \dots, \gamma_{-2n-1}^i)$  とする．また， $\Theta^i$  は各モジュールの向きを表し， $90^\circ$  ずつ回転させた場合と表裏の場合により， $\theta_j^i \in \{0, \dots, 7\}$ ， $(2n \leq j < 3n)$  の 8 種類とする．以下では， $x_i^T$  の各要素の位置を遺伝子座と呼ぶ．

図 4 は個体表現の一例を表している．図 4(a) のフロアプランは，対応する  $SP$  により図 4(b) のようにオブリークグリッド上で表すことができる．また，提案手法ではフロアプランを図 4(c) の個体により表す．

#### 3.2 適応度関数

GA では次世代に残すべき個体を選択するため，各個体の適応度を計算する．フロアプランニング問題では，個体  $x_i^T$  のコスト  $g(x_i^T)$  をチップ面積と総配線長の和で表す．個体  $x_i^T$  のチップ面積を  $A_i[mm^2]$  とし，総配線長を  $W_i[mm]$  とすると，

$$g(x_i^T) = A_i + k \times W_i. \tag{3}$$

ここで  $k$  は定数である(予備実験より，面積  $A_i$  と総配線長  $W_i$  の値から，面積の割合が総配線長より大きくなるように  $k$  を 0.005 として実験を行った)．各個




図 4 オブリークグリッド表現と個体表現の例(モジュール数 6)  
 Fig. 4 An example of oblique-grid notation and chromosome (the number of modules: 6).

体のコスト  $g(x_i^T)$  に基づき，個体の適応度  $f(x_i^T)$  を以下のように定義する．

$$f(x_i^T) = g_{max}^T - g(x_i^T). \tag{4}$$

ここで， $g_{max}^T$  は世代  $T$  における人口中の個体のコストの最大値，すなわち， $g_{max}^T = \max_{0 \leq i < P} (x_i^T)$  である．提案手法では，各個体の適応度  $f(x_i^T)$  を計算し，ルール選択<sup>3)</sup> とエリート保存戦略<sup>3)</sup> に基づいて選択を行う．

#### 3.3 交差手法

著者らはこれまでに  $SP$  を解表現とする GA に基づくフロアプランニング手法に対して複数の交差手法を提案し，予備実験を行っている<sup>7),8)</sup>．その結果，提案手法では人口中の個体の多様性の維持のため，共通トポロジ保存交差(Common Topology Preserving Crossover, CTPX)，配置依存部分交換交差(Placement-based Partially Exchanging Crossover, PPEX)の 2 種類の交差手法をそれぞれエリート交差，非エリート交差として用いる．CTPX は親の共通する性質を子に多く保存することを，また，PPEX は解空間を広く効果的に探索することを目的としている．

以下の交差手法の説明では簡単のため，交差の対象となる 2 つの親 1, 2 をそれぞれ  $x_{p1} = (\Gamma_+^{p1}, \Gamma_-^{p1}, \Theta^{p1})$ ， $x_{p2} = (\Gamma_+^{p2}, \Gamma_-^{p2}, \Theta^{p2})$  で表す．また，交差の結果，生成される 2 つの子 1, 2 をそれぞれ  $x_{c1} = (\Gamma_+^{c1}, \Gamma_-^{c1}, \Theta^{c1})$ ， $x_{c2} = (\Gamma_+^{c2}, \Gamma_-^{c2}, \Theta^{c2})$  で表す．

#### 3.4 共通トポロジ保存交差(CTPX)

エリート交差として用いる共通トポロジ保存交差

(CTPX)は、2つの親に共通するモジュールの相対位置関係をできるだけ多く保存する交差手法である。具体的には、 $SP$ でのモジュールの順序はそれらのモジュールの上下左右の相対位置関係を表していることから、2つの親のシーケンスペア  $(\Gamma_+, \Gamma_-)$  の中で最長共通部分系列 (Longest Common Subsequence, LCS) <sup>1)</sup> を求め、それを子に受け継ぐように交差を行う。

以下で用いる記号を定義する。LCS( $S_1, S_2$ )を2つの系列  $S_1, S_2$  のLCS、 $M(S)$ を系列  $S$  に含まれるモジュールの集合、Sub( $S, M$ )をモジュール集合  $M$  に含まれるモジュールのみから構成される  $S$  の部分系列とする。また、 $M(S)$  に対し、 $M(S)$  に含まれないモジュールの集合を  $\overline{M(S)} = M_{all} - M(S)$  とする。ただし、 $M_{all}$  はモジュール全体の集合である。また、 $M(S)$  に含まれるモジュールの個数を  $|M(S)|$  とする。LCSに含まれるモジュールは両方の親で同じ順序で含まれているため、同じ相対位置を持つことになり、これらのモジュールの順序が親に共通する性質であると考えることができる。そこで、LCSに含まれるモジュールは交差の対象から外し、系列内の位置と向きを交差時に固定する。逆にLCS以外のモジュールは系列の順序と向きを交差の相手の親の順に変更する。以下にCTPXを示す。

**交差手法：CTPX**

**Step1:** 2つの親  $x_{p1}, x_{p2}$  の  $SP$  の各系列  $\Gamma_+, \Gamma_-$  に対してLCSを求め、それぞれ、 $S_+ = \text{LCS}(\Gamma_+^{p1}, \Gamma_+^{p2}), S_- = \text{LCS}(\Gamma_-^{p1}, \Gamma_-^{p2})$  とする。さらに、 $S_{+-}^{p1} = \text{Sub}(\Gamma_+^{p1}, M(S_-)), S_{+-}^{p2} = \text{Sub}(\Gamma_+^{p2}, M(S_-)), S_{-+}^{p1} = \text{Sub}(\Gamma_-^{p1}, M(S_+)), S_{-+}^{p2} = \text{Sub}(\Gamma_-^{p2}, M(S_+))$  により4つの部分系列を求める。

**Step2:** 2つの部分系列  $S_{+-} = \text{LCS}(S_{+-}^{p1}, S_{+-}^{p2}), S_{-+} = \text{LCS}(S_{-+}^{p1}, S_{-+}^{p2})$  を求める。

**Step3:** もし  $|M(S_{+-})| > |M(S_{-+})|$  ならば、 $S_i = S_{+-}$  とし、そうでなければ、 $S_i = S_{-+}$  とする。モジュール数を  $n$  とした場合、 $S_i$  のモジュール数が少なく、 $|M(S_i)| \leq r \cdot n$  ならば、交差による大幅な変更を防ぐために、 $|M(S_i)| > r \cdot n$  となるようにランダムに  $\overline{M(S_i)}$  からモジュール

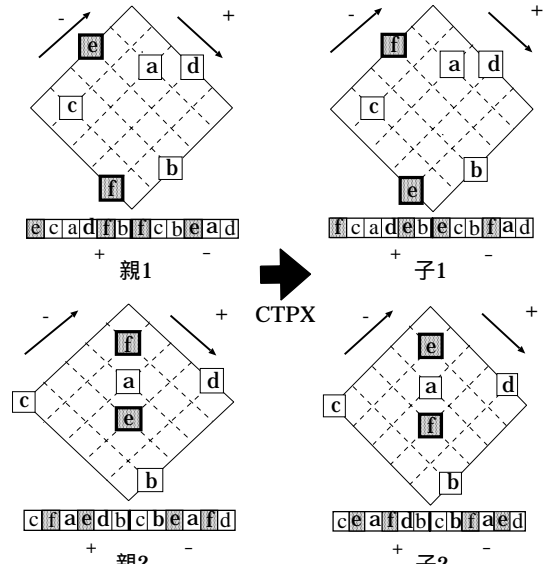


図5 CTPXの例  
Fig. 5 An example of CTPX.

を選択して  $M(S_i)$  に加える。予備実験の結果より  $r = 0.2$  を採用した。

**Step4:**  $M(S_i)$  のモジュールの  $SP$  と向きを保存するように、 $x_{p1}$  から  $x_{c1}$  に同じ遺伝子座にコピーする。同様に、 $x_{p2}$  から  $x_{c2}$  にコピーする。

**Step5:**  $\overline{M(S_i)}$  のモジュールは相手の親  $(\Gamma_+^{p2}, \Gamma_-^{p2})$  で出現する順序で  $x_{p1}$  から  $x_{c1}$  にコピーする。向きは  $\Theta^{p2}$  をそのままコピーする。同様に、 $x_{p2}$  から  $x_{c2}$  にコピーする。 □

図5にCTPXの例を示す。例ではモジュールの向きを省略している。まず、 $S_+ = (c, a, d, b)$  と  $S_- = (c, b, a, d)$  を見つける。これから、 $S_{+-} = (c, a, d, b), S_{-+} = (c, b, a, d), M(S_i) = \{a, b, c, d\}, \overline{M(S_i)} = \{e, f\}$  を決定する。さらに、 $r = 0.2, n = 6$  より  $\frac{|M(S_i)|}{n} > r$  であるので、 $M(S_i), \overline{M(S_i)}$  はそのままである。そして、 $M(S_i) = \{a, b, c, d\}$  を  $x_{p1}, x_{p2}$  から各々  $x_{c1}, x_{c2}$  に同じ位置にコピーし、 $\overline{M(S_i)} = \{e, f\}$  を  $x_{p1}, x_{p2}$  の  $SP$  における出現順序で各々  $x_{c2}, x_{c1}$  にコピーする。向きについては  $M(S_i)$  に含まれるモジュールの向きは変更しないように、 $\overline{M(S_i)}$  に含まれるモジュールの向きは他の親と同じになるようにコピーする。

**3.5 配置依存部分交換交差 (PPEX)**

非エリート交差として用いる配置依存部分交換交差 (PPEX) は、 $SP$  で定義されるモジュールの相対位置を表すオブリークグリッド (図4(b)) 上のランダムに選択されたグリッドを中心にあらかじめユーザが指定

2つの系列  $A = (a_1, a_2, \dots, a_m)$  と  $B = (b_1, b_2, \dots, b_n)$  の最長共通部分系列  $C = (c_1, c_2, \dots, c_k)$  とは、2つの系列  $A, B$  において共通に含まれる文字列の中で最長のものである。たとえば、2つの系列を  $A = (a, b, c, d, e, f, g)$  と  $B = (d, e, a, f, g, c, b)$  とすると、LCSは長さ4の  $(d, e, f, g)$  となる。提案手法では最長のものが複数ある場合にはランダムに1つを選択している。

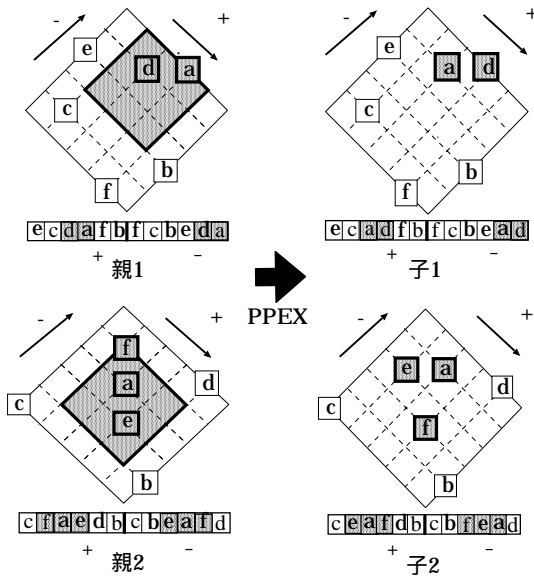


図 6 PPEX の例  
Fig. 6 An example of PPEX.

した大きさの窓領域を作成し、窓に含まれたモジュールを対象として交差を行う。ここで窓とは、オブリークグリッド上の連続した四辺形の部分領域を意味する。これにより、配置上で近いモジュールに関して局所的な交差を行うことが可能となる。

親  $x_{p1}$  に対し、窓領域  $W_{p1}$  に含まれるモジュールの集合を  $M(W_{p1})$  とし、それ以外のモジュールの集合を  $\overline{M(W_{p1})}$  と定義する。親 2 についても同様に定義する。PPEX を以下に示す。

**交差手法：PPEX**

- Step1: 親  $x_{p1}, x_{p2}$  に対し、オブリークグリッド上のそれぞれランダムな位置を中心に窓領域  $W_{p1}, W_{p2}$  を生成し、 $M(W_{p1}), \overline{M(W_{p1})}, M(W_{p2}), \overline{M(W_{p2})}$  を求める。
- Step2:  $x_{p1}, x_{p2}$  のそれぞれの遺伝子座に対し、 $\overline{M(W_{p1})}, \overline{M(W_{p2})}$  のモジュールを  $x_{c1}, x_{c2}$  のそれぞれの  $SP$ , 向きの対応する遺伝子座にコピーする。
- Step3:  $M(W_{p1})$  と  $M(W_{p2})$  のモジュールに対し、 $x_{p1}, x_{p2}$  の  $SP$  における出現順序で  $x_{c2}, x_{c1}$  の遺伝子座にそれぞれコピーし、向きも同様にコピーする。 □

予備実験による考察の結果、窓のサイズをオブリークグリッド全体の  $\frac{1}{4}$  となるように設定している。オブリークグリッドの境界に近い位置を窓領域の中心とした場合にもオブリークグリッドの内側にシフトして必ずサイズが全体の  $\frac{1}{4}$  となるようにしている。




図 7 突然変異 MM の例  
Fig. 7 An example of mutation MM.

PPEX で窓の縦横のサイズを 3 としたときの例を図 6 に示す。図 6 では、 $M(W_{p1}) = \{a, d\}$ ,  $\overline{M(W_{p1})} = \{b, c, e, f\}$ ,  $M(W_{p2}) = \{a, e, f\}$ ,  $\overline{M(W_{p2})} = \{b, c, d\}$  である。よって、親  $x_{p1}$  では  $\{b, c, e, f\}$  を  $x_{c1}$  にコピーし、 $x_{p2}$  では  $\{b, c, d\}$  を  $x_{c2}$  にコピーする。また、それぞれ  $\{a, d\}$  と  $\{a, e, f\}$  を  $x_{p2}, x_{p1}$  の  $SP$  における出現順序でそれぞれ  $x_{c1}, x_{c2}$  にコピーする。

**3.6 モジュールの移動による突然変異 MM**

提案手法では突然変異確率により選択されたモジュールを個体内でランダムに移動し、移動先のモジュールと位置を交換する。突然変異実行前の個体を  $x_{p1}$  とし、実行後の個体を  $x_{c1}$  とする。以下に MM を示す。  
**突然変異：MM**

- Step1:  $x_{p1} = (\Gamma_+^{p1}, \Gamma_-^{p1}, \Theta^{p1})$  において突然変異確率  $p_m$  により  $m_j (0 \leq j < n)$  を選択する。さらに  $m_j$  の個体上での移動先を決定するために、ランダムに  $rp_+ (0 \leq rp_+ < n), rp_- (n \leq rp_- < 2n)$  を生成する。
  - Step2:  $\Gamma_+^{p1}$  の  $rp_+$  の位置にあるモジュールを  $m_+$ ,  $\Gamma_-^{p1}$  の  $rp_-$  の位置にあるモジュールを  $m_-$  とする。
  - Step3:  $\Gamma_+^{p1}$  において、 $m_j$  と  $m_+$  を交換し、 $\Gamma_-^{p1}$  において、 $m_j$  と  $m_-$  を交換する。さらに、 $m_j$  の向き  $\theta_j$  を乱数  $ro (0 \leq ro \leq 7)$  により置き換える。
  - Step4:  $x_{p1}$  を  $x_{c1}$  の遺伝子座にコピーする。 □
- 図 7 に MM の例を示す。モジュール  $a$  を確率  $p_m$  で移動対象として選択する。 $rp_+$  と  $rp_-$  に  $a$  を移動するため、 $rp_+$  と  $rp_-$  のところにある  $d, c$  がそれぞれ選ばれる。そして、 $\Gamma_+^{p1}$  において  $a$  と  $d$  を交換し、 $\Gamma_-^{p1}$  において  $a$  と  $c$  を交換する。

提案手法では各世代の各個体のエリート度とあらかじめ与えているしきい値によりエリートと非エリートの個体に分け、それぞれの突然変異確率を  $p_{me}, p_{mn} (p_{me} < p_{mn})$  として MM を適用する。突然変

異確率を高くすれば個体のスキーマを破壊しやすく、突然変異確率を低くすればスキーマを保存しやすい。エリート個体の突然変異確率を低く設定することにより、エリート個体の良い性質が保存されやすくなる。

### 3.7 ヒューリスティックによる局所改良

GA では、問題特有の情報に基づくヒューリスティックを組み合わせるハイブリッド化により、解の質を向上させることができる<sup>3)</sup>。提案手法ではさらなる解の改善のために、エリート個体に対して以下に提案する局所改良 LI を適用する。LI では、水平、垂直制約グラフ  $G_H, G_V$  上の面積に直接影響のあるモジュールに対し、その位置と向きを変更することにより解の改良を行う。個体  $x_i^T$  に対する局所改良 LI を以下に示す。  
局所改良：LI

Step1: エリート個体  $x_i^T$  に対して  $G_H, G_V$  を生成し、各グラフで最長経路上にあるモジュールの集合をそれぞれ  $M_H, M_V$  とする。

Step2: モジュール  $m_1 \in (M_H \cup M_V) - (M_H \cap M_V)$  をランダムに選択する。 $m_1$  の向きを  $\theta_{m_1}$  とすると式 (3) のコスト  $g(x_i^T)$  が最小となるように  $\theta_{m_1}$  を決定する。

Step3: 次に、モジュール  $m_2 \in (M_H \cup M_V) - (M_H \cap M_V)$  をランダムに選択する。ここで、 $j (0 \leq j < n)$  を  $m_2$  の  $\Gamma_+^j$  における位置とし、乱数  $k (0 \leq k < n, k \neq j)$  を生成する。 $\Gamma_+^j$  において、 $m_2$  を  $k$  の位置に移動させ、位置  $j$  から  $k$  にあるモジュールを  $j$  の方向に 1 つずつシフトする。 $\Gamma_-^j$  についても同様にモジュールのシフトを行う。向きについてはすべて固定とする。

Step4: 新しく生成された個体  $x_i^{T'}$  に対して、もし  $g(x_i^{T'}) < g(x_i^T)$  ならば  $x_i^T \leftarrow x_i^{T'}$  と置き換える。そうでなければ  $x_i^T \leftarrow x_i^T$  とする。

Step5: 以上のステップ 1~4 の操作をあらかじめ与えた回数  $N$  回繰り返す。□

提案手法では世代数が進むに従い、反復回数  $N (\geq 1)$  を最大  $N_{LI}$  まで順次増加させることにより、前半では大域探索を優先し、後半では局所改良を強化することで効果的に解空間の探索を行うことを実現している。

### 3.8 スケーリングによる個体の選択

提案手法においても、GA で一般的に使用されている適応度のスケールリング手法<sup>3),4)</sup>を用いて、選択時に個体の適応度を一時的に変更することにより、解空間を効率良く探索できるようにする。スケールリングによ

表 1 適応度スケールリングのパラメータ

Table 1 Parameters for fitness scaling.

開始世代	終了世代	$a$	$b$
1	$0.25T_{max}$	0.5	$A_{lb}$
$0.25T_{max}$	$0.75T_{max}$	$0.25 + \frac{T}{T_{max}}$	$A_{lb}(1.5 - \frac{2T}{T_{max}})$
$0.75T_{max}$	$T_{max}$	1	0




図 8 適応度のスケールリング

Fig. 8 Fitness scaling.

り変更された個体の適応度  $f'(x_i^T)$  は、

$$f'(x_i^T) = a \times f(x_i^T) + b. \quad (5)$$

この式で、 $a, b$  は実数値のパラメータで世代が進むにつれて変化する。表 1 に終了世代数  $T_{max}$  としたときの今回採用したパラメータ  $a, b$  の値を示す。表 1 で、 $A_{lb}$  は面積下界値 (全モジュール  $M_{all}$  の面積の総和) であり、 $T$  は現在の世代数である。このスケールリングでは、初期世代で係数  $a = 0.5$  とし、個体間の適応度の差を実際より圧縮することにより選択において適応度の低い個体の淘汰を抑制し、個体集合に多様性を持たせている (図 8)。そして、探索が進むにつれて  $a$  を徐々に 1 に近付けることにより適応度の低い個体を淘汰し、より局所探索を強化することで短時間で効果的な解空間の探索を実現している。これらは予備実験よりその有効性を確認している。

### 3.9 提案手法

EAGA に基づく提案フロアプランニング手法のフローチャートを図 9 に示す。EAGA では、2.3 節で定義した個体のエリート度により GA の遺伝オペレータを動的に選択する。交差では、親の 2 個体のエリート度の和がしきい値  $D_c$  以上ならばエリート交差 CTPX を適用し、そうでなければ非エリート交差 PPEX を適用する。交差は、交差確率  $p_c$  により選ばれた個体にのみ適用する。また、突然変異 MM も同様に、個体のエリート度がしきい値  $D_m$  以上であればエリート突然変異確率  $p_{me}$  で適用し、そうでないなら非エリート突然変異確率  $p_{mn}$  で適用する。局所改良 LI はエリート個体にのみ適用し、指定回数  $N (\leq N_{LI})$  行う。選択では、スケールリングにより個体の適応度を

スキーマとは、個体の適応度に影響を与える個体表現の部分系列の集合を表すパターン表現<sup>3)</sup>。

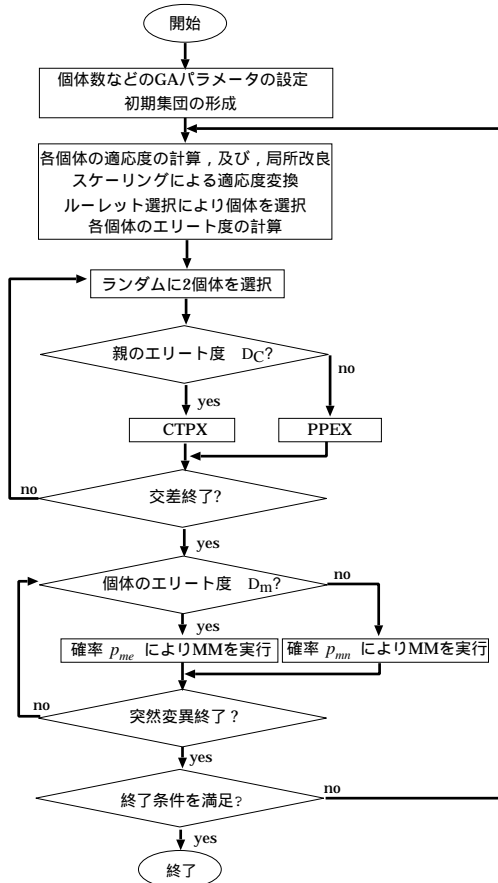


図9 提案手法 EAGA のフローチャート  
Fig. 9 Flowchart of EAGA.

変換し、適応度に比例した確率で次世代に残す個体を選択するルーレット選択を適用する。

#### 4. シミュレーション実験

汎用 GA ソフトウェア GENESIS5.0<sup>4)</sup> に今回新しく提案した交差手法 (CTPX, PPEX), 突然変異手法 MM, 局所改良 LI, および遺伝オペレータの適応的選択手法<sup>5)</sup> を加えて C 言語により提案手法を実現し, CPU が Ultra SPARC II (450 MHz) のワークステーション上でシミュレーション実験を行った。実験データとして 2 種類の MCNC ベンチマークデータ (ami33, ami49) とランダムに生成した 4 種類のデータを用いた。なお, チップの外周はフロアプランによって変化するため, 本実験においては MCNC ベンチマークデータに含まれる外枠 (チップの外周) のピンはネットリストから削除し, 提案手法および比較手法の両手法における配線長の計算ではこれらを考慮していない。

適応的遺伝的アルゴリズム EAGA がシーケンスペア表現によるフロアプランニング問題の解法の一手法として有効であることを検証するために, 本実験では, シーケンスペア表現を用いたフロアプランニング手法<sup>9)</sup> でよく用いられている SA に基づくフロアプランニング手法<sup>9)</sup>, 通常の GA (すなわち非適応的 GA, 以下では GA と表記), および, 提案 EAGA の 3 つを実現し比較した。EAGA と GA では, 世代数 ( $T_{max}$ )=12000, 個体数 ( $P$ )=20, 交差確率 ( $p_c$ )=0.6, 最大局所改良回数 ( $N_{LI}$ )= $(\frac{n}{10})^2$  とした ( $n$  はモジュール数)。さらに, EAGA で使用するパラメータに対しては, エリート突然変異確率 ( $p_{me}$ )=0.01, 非エリート突然変異確率 ( $p_{mn}$ )=0.05, エリート決定係数 ( $\alpha$ )=0.2, エリート影響度係数 ( $\beta$ )=0.5, エリート度計算における  $l_{max} = 3$ , 交差しきい値 ( $D_c$ )=1.5, 突然変異しきい値 ( $D_m$ )=0.7 に設定した。これらのパラメータ値は, 文献 5)~7) での実験的考察と本実験に対する予備実験の結果をもとに実験的に決定した。また, 初期解はランダムに生成し, 終了条件は GA の世代数が指定世代数  $T_{max}$  に達することとした。実験では, 各手法で 10 回の試行により得られたコスト, チップ面積, 総配線長に関する最良値, 最悪値, 平均値で評価を行った。

実験結果を表 2 に示す。表中の  $\#M$ ,  $\#N$ ,  $A$  は各データのモジュール数, ネット数, モジュールの面積の総和を表す。表 2 から, すべてのデータに対して, コストに関しては最良値, 最悪値, 平均値において, SA とほぼ同等の時間で同等の結果が得られている。特に, コストの平均値においては, rd200a を除くすべてのデータに対して SA より良い解が得られており, ami33 では 1.1%, ami49 では 0.8%, rd100a では 1.6%, rd100b では 0.1%, rd200b では 1.6%だけ SA より提案手法の方が優れていた。また, 最良値においても rd200b 以外のすべてのデータに対して SA より優れた解が得られた。この結果から EAGA は解空間の効果的な探索が可能であり, フロアプランニング問題の解探索手法の 1 つとして SA と同じように有効であるといえる。図 10 に EAGA による ami49 の最良レイアウト図を示す。

表 3 に ami33 に対するコスト上位の個体の状態を示す。これから分かるように, 提案 EAGA はコスト, 面積, 配線長, アスペクト比の異なる複数の解を保持しているため, 用途によっては複数の最良解の中からユーザが設計に適している解を選択することも可能である。

次に, 交差手法, 突然変異確率を 1 種類しか用いない非適応的 GA と EAGA の結果を比較する。表 2



表 2 実験結果

Table 2 Experimental results.

データ	手法	コスト ( $g(x_i^T)$ )			チップ面積 ( $A_i$ ) [ $mm^2$ ]			総配線長 ( $W_i$ ) [ $mm$ ]			時間 (sec)	
		最良値	最悪値	平均値	最良値	最悪値	平均値	最良値	最悪値	平均値		
<b>ami33</b>	EAGA	<b>1.428</b>	1.474	1.457	<b>1.213</b>	1.269	1.242	38.11	47.76	42.97	720	
	# $\mathcal{M}$ =33	SA	1.451	1.514	1.473	1.237	1.277	1.251	40.24	46.83	44.29	822
	# $\mathcal{N}$ =123	GA(CT)	1.433	1.532	1.479	1.236	1.294	1.250	<b>36.43</b>	53.75	45.91	730
	$\mathcal{A}$ =1.16	GA(PP)	1.441	1.548	1.491	1.226	1.292	1.259	37.16	53.77	46.28	730
<b>ami49</b>	EAGA	<b>41.78</b>	44.67	43.44	<b>37.01</b>	38.57	37.73	<b>928.8</b>	1246.6	1139.7	2117	
	# $\mathcal{M}$ =49	SA	42.36	44.03	43.78	37.14	38.63	38.15	953.8	1191.8	1069.8	2663
	# $\mathcal{N}$ =408	GA(CT)	43.07	44.91	44.05	37.71	38.78	38.10	1070.3	1369.4	1190.9	2047
	$\mathcal{A}$ =35.45	GA(PP)	43.25	45.53	44.21	37.14	38.95	38.13	1081.1	1368.4	1216.9	1978
<b>rd100a</b>	EAGA	<b>12.78</b>	13.21	13.03	<b>9.578</b>	9.805	9.687	<b>639.7</b>	688.2	669.1	7444	
	# $\mathcal{M}$ =100	SA	13.09	13.32	13.24	9.790	9.956	9.895	649.9	682.4	668.8	9060
	# $\mathcal{N}$ =551	GA(CT)	13.28	13.82	13.55	9.716	10.104	9.919	692.8	753.1	725.4	6324
	$\mathcal{A}$ =9.06	GA(PP)	13.38	13.65	13.48	9.696	9.975	9.892	692.2	745.6	717.9	6250
<b>rd100b</b>	EAGA	59.01	61.32	60.10	<b>53.33</b>	54.50	53.60	963.4	1397.6	1188.7	7074	
	# $\mathcal{M}$ =100	SA	<b>58.31</b>	63.52	60.17	53.62	59.50	55.49	<b>804.2</b>	1119.9	935.7	8737
	# $\mathcal{N}$ =422	GA(CT)	59.55	62.33	61.04	53.59	56.00	54.18	1124.0	1661.8	1373.4	5834
	$\mathcal{A}$ =51.98	GA(PP)	58.75	62.44	60.66	53.29	54.61	53.86	1091.4	1613.8	1359.5	5295
<b>rd200a</b>	EAGA	<b>46.50</b>	47.93	47.14	33.45	34.15	33.73	<b>2603.6</b>	2756.4	2683.4	24072	
	# $\mathcal{M}$ =200	SA	46.95	47.07	47.00	<b>33.37</b>	33.73	33.50	2689.9	2718.6	2700.1	32926
	# $\mathcal{N}$ =978	GA(CT)	47.81	49.54	48.65	33.93	34.76	34.30	2765.3	2956.9	2869.5	18159
	$\mathcal{A}$ =31.81	GA(PP)	48.18	49.26	48.75	34.13	34.78	34.36	2799.2	2949.9	2877.8	18636
<b>rd200b</b>	EAGA	<b>29.90</b>	30.90	30.25	<b>19.16</b>	19.28	19.21	2147.1	2245.3	2209.2	23325	
	# $\mathcal{M}$ =200	SA	30.10	31.01	30.72	19.45	19.83	19.60	<b>2130.9</b>	2276.3	2225.1	31842
	# $\mathcal{N}$ =891	GA(CT)	30.75	31.62	31.12	19.31	19.62	19.45	2267.9	2423.8	2335.0	17820
	$\mathcal{A}$ =17.78	GA(PP)	30.50	31.39	30.90	19.25	19.65	19.48	2197.9	2347.6	2284.2	18478




図 10 ami49 に対する EAGA の最良レイアウト  
Fig. 10 The best layout of EAGA for ami49.

の GA (CT), GA (PP) は, それぞれ交差手法に CTPX, PPEX のみを用いた結果である. 突然変異確率は,  $p_{me}=p_{mn}=0.01$  としている. 表 2 から, EAGA はコストの平均値に関してはほとんどのデータに対して良い結果を得ている. 計算時間に関してはエリート度の計算などが必要となるため, 平均的に非適応的 GA より長くなっている. EAGA はエリート度を導入することにより, エリートの個体に対しては, 親の性質を子に受け継ぐように交差手法や交差・突然変

表 3 ami33 におけるコスト上位の個体の状態

Table 3 The status of the elite individuals for ami33.

$g(x_i^T)$	$A_i$ [ $mm^2$ ]	$W_i$ [ $mm$ ]	アスペクト比
1434048	1246168	37576	1.18
1524292	1325352	39788	1.52
1602692	1369452	46648	1.15
1611246	1392776	43694	1.63
1703170	1455300	49574	1.25

コスト  $g(x_i^T)$ , 面積  $A_i$  [ $mm^2$ ], 配線長  $W_i$  [ $mm$ ]

異確率を設定し, 非エリートに対しては, 親とは異なる子ができるように交差手法や交差・突然変異確率を設定し, これを各個体に対して, アルゴリズムの実行中に適応的に選択している<sup>5)~7)</sup>. そのため, CTPX, PPEX を単独で用いる従来の GA より個体のエリート度による遺伝オペレータの適応的選択を行う EAGA の方が解の質が向上することが分かる. これにより, 適応的遺伝的アルゴリズムがフロアプランニング問題に対しても有効であることを検証することができた.

### 5. あとがき

本論文では VLSI 設計におけるフロアプランニング問題に対し, エリート度の概念に基づく遺伝パラメータの適応的調整機能を持つ適応的遺伝的アルゴリズムに基づくフロアプランニング手法を提案した. 提案アルゴリズムでは, 個体の優劣の指標としてエリート度

を導入することにより、エリート度の高い個体には局所探索能力の高い交差手法 CTPX を適用し、エリート度の低い個体には解空間を広く探索する交差手法 PPEX を適用することにより効果的な解空間の探索を実現した。さらに、個体の評価値に対するスケールリングを取り入れることにより、短時間での解空間の効果的探索を実現した。計算機上でのシミュレーション実験の結果、シーケンスペア表現によるフロアプランニング問題に対する解探索手法として従来からよく用いられている SA と同等の解を得ることができ、適応的遺伝的アルゴリズム EAGA がフロアプランニング手法の解探索手法の 1 つとして有効であることを示した。また、交差手法、突然変異確率を固定した非適応的 GA と比較し、交差手法と突然変異確率の適応的選択の有効性も確認した。

今後の課題としては、大規模データへの適用や EAGA の振舞いの詳細な解析などがある。また、アスペクト比可変のソフトモジュールを含む場合へのアルゴリズムの拡張やチップのアスペクト比制約やタイミング制約などの各種制約を考慮したフロアプランニング手法への拡張などがあげられる。

謝辞 本研究の一部は、文部科学省科学研究費補助金奨励研究 (A X 課題番号 12750293)、基盤研究 (B) (2 X 課題番号 12555097)、および、基盤研究 (C Q 2) (課題番号 12838008) による。

### 参 考 文 献

- 1) Cormen, T.H., Leiserson, C.E. and Rivest, R.L.: *Introduction to Algorithms*, The MIT Press (1990).
- 2) Davis, L.: Adapting operator probabilities in genetic algorithms, *Proc. 3rd International Conference on Genetic Algorithms*, pp.61-69 (1989).
- 3) Goldberg, D.E.: *Genetic Algorithms in Search, Optimization, and Machine Learning*, Addison-Wesley Publishing Company (1989).
- 4) Grefenstette, J.J.: Optimization of control parameters for genetic algorithms, *IEEE Trans. Systems, Man and Cybernetics*, Vol.SMC-16, No.1, pp.122-128 (1986).
- 5) 八田浩一, 松田憲治, 若林真一, 小出哲士: 遺伝的アルゴリズムにおける交差手法の適応的選択の一手法, *信学論 (D-I)*, Vol.J81-D-I, No.7, pp.900-909 (1998).
- 6) 八田浩一, 若林真一, 小出哲士: 遺伝的アルゴリズムにおける個体のエリート度に基づく遺伝的オペレータと GA パラメータの適応的調整, *信学論 (D-I)*, Vol.J82-D-I, No.9, pp.1135-1143 (1999).
- 7) Hatta, K., Wakabayashi, S. and Koide, T.: Solving the rectangular packing problem by an adaptive GA based on sequence-pair, *Proc. Asia and South Pacific Design Automation Conference*, pp.181-184 (1999).
- 8) 中矢真吾, 小出哲士, 若林真一, 八田浩一: 適応的遺伝的アルゴリズムに基づくフロアプランニング手法, *情報処理学会 DA シンポジウム'99 論文集*, pp.137-142 (1999).
- 9) Murata, H., Fujiyoshi, K., Nakatake, S. and Kajitani, Y.: VLSI module placement based on rectangle-packing by the sequence-pair, *IEEE Trans. Computer-Aided Design of Integrated Circuits and Systems*, Vol.15, No.12, pp.1518-1524 (1996).
- 10) Nakatake, S., Fujiyoshi, K., Murata, H. and Kajitani, Y.: Module packing based on the BSG-structure and IC layout applications, *IEEE Trans. Computer-Aided Design of Integrated Circuits and Systems*, Vol.17, No.6, pp.519-530 (1998).
- 11) Onodera, H., Taniguchi, Y. and Tamaru, K.: Branch-and-bound placement for building block layout, *Proc. 28th ACM/IEEE Design Automation Conference*, pp.433-439 (1991).
- 12) Sait, S.M. and Youssef, H.: *VLSI Physical Design Automation*, IEEE Press (1995).

(平成 13 年 4 月 16 日受付)

(平成 14 年 2 月 13 日採録)



中矢 真吾 (正会員)

平成 11 年広島大学工学部第二類 (電気系) 卒業。平成 13 年同大学大学院工学研究科博士課程前期修了。同年富士通 (株) 入社。在学中は VLSI CAD の研究に従事。



小出 哲士(正会員)

平成 2 年広島大学工学部第二類(電気系)卒業。平成 4 年同大学大学院博士課程前期修了。平成 4 年広島大学工学部助手,平成 11 年同助

教授。平成 11 年 4 月東京大学大規模集積システム設計教育研究センター助教授。同年 4 月広島大学助教授併任。平成 13 年 4 月広島大学ナノデバイス・システム研究センター助教授。博士(工学)。主として VLSI 設計自動化,組合せ最適化,VLSI 設計/教育に関する研究に従事。電子情報通信学会,IEEE,ACM 各会員。



若林 真一(正会員)

昭和 54 年広島大学工学部電気工学科卒業。昭和 59 年同大学大学院博士課程修了。同年日本アイ・ビー・エム(株)入社。東京基礎研究所勤務。昭和 63 年広島大学工学部助教

授。平成 13 年同大学大学院工学研究科助教授(生体システム論)。工学博士。主として,計算機援用設計,組合せ最適化,遺伝的アルゴリズム,並列アルゴリズムに関する研究に従事。電子情報通信学会,IEEE,ACM 各会員。