

# 適応度予測に基づく対話型進化計算とその似顔絵生成への応用

佐藤 嘉洋<sup>†</sup> 栢菅 彩<sup>‡</sup> 有田 隆也<sup>†</sup>

<sup>†</sup> 名古屋大学大学院情報科学研究科 <sup>‡</sup> 名古屋大学情報文化学部

## Interactive Evolutionary Computation based on Fitness Prediction and its Application to Generation of Facial Caricature

Yoshihiro Sato<sup>†</sup> Aya Kayasuga<sup>‡</sup> Takaya Arita<sup>†</sup>

<sup>†</sup> Graduate School of Information Science, Nagoya University

<sup>‡</sup> School of Informatics and Sciences, Nagoya University

**Abstract:** Interactive evolutionary computation is one of the optimization methods, which efficiently extracts person's sensitivity and makes it reflect in evolution. We propose a technique in which fitness is predicted by using the evaluation values estimated based on the user's selection history even when the users don't evaluate by giving numerical values. This technique was evaluated by simulation using a human user model based on the NK fitness landscape. It has been shown that mean fitness was 2 % greater than the one without any prediction methods when fluctuation was large in a smooth landscape. Then we applied this technique to generation of facial caricature.

### 1 はじめに

対話型進化計算法は、通常の進化計算法における個体に対する適応度評価を人間が逐次的に行うことによって、人間の主観的評価に基づいた最適化に適した手法である。人間による直接的な評価が可能なため、例えば芸術作品の生成など、人間の感性や感覚といった明示的に表現できない評価基準を必要とするタスクに対して、人間の主観性を反映させることに適している。その反面、人間が評価系であるが故に以下の問題が存在する。

- 1) 評価基準が変動する。
- 2) 個体数や探索世代数が少なくならざるを得ない。
- 3) 評価による人間の疲労が蓄積される。

人間の疲労が起因して評価がさらに変動したり、個体数や探索世代数がさらに少なくなる可能性もある。また、音楽や動画像の最適化というタスクでは、時系列的に解候補を提示せざるを得ず、これらの問題はさらに深刻である。

上記の問題点に対する解決策としては、1) 進化計算法の探索性能の向上や、2) インタフェースの改善が主に組み込まれている。例えば、1) に対しては、ユーザーの好みにより近いと思われる個体 (= 適応度が高い個体) を予測し、提示することによって探索性能を向上させようとする試みがある [3][4]。これらは、ユーザーが過去に解候補に与えた評価値を基にしてニューラルネットワーク (NN) やユークリッド距離などによって予測するものであった。しかし、「好みの個体を選択する」といった評価方法を採用した場合や、インタフェースの改善の一環として、ユーザーに対して数値的な評価を求めない場合には、予測に必要な評価値がユーザーから得られない。

そこで、本研究では、特にユーザーから数値的な評価が得られない場合における適応度予測を利用した探索性能の向上に焦点を当て、解候補の生成法を検討した。具体的には、適応度予測に必要な評価値をユーザーの探索履歴を基にシステム側で見積もり、それを NN による予測に利用す

る方法を考えた。そして、予測適応度に基づいて解候補を生成することで、探索性能の向上を目指す。この提案手法の有意性が示されれば、ユーザーの負担が少ない評価法を採用しつつ、解探索の効率性を向上させることが出来る可能性がある。

ところで、対話型進化計算法に対する改善策の評価・検討においても、人間を評価系にした場合、以下のような問題点が挙げられる。

- 1) 評価は人間やタスクに依存するため、提案手法に対する客観的、定量的な評価が困難である。
- 2) 数多くのデータを収集するには、それ相応の被験者を必要とし、その都度、被験者の負担となる。

上記の問題に対処するために、本研究では、ユーザーの選択モデルなるものを構築し、それを使用して提案手法の評価を行った。ユーザーの選択モデルとは、タスクを人工的な適応度地形の山登りと想定し、ユーザーがシステムから提示された個体 (解候補) の中から希望の個体を選択する、という操作をモデル化したものである。この人工的な適応度地形は、与えられたタスク、及び、ユーザーの主観によってその形状が決まると考えられる。ユーザーの選択モデルを使用することで解候補に対する選択操作を計算機上で行うことが出来、提案手法に対する定量的な評価データを数多く収集することが可能となる。



Fig. 1: 提案手法とユーザーの選択モデルの位置づけ

提案手法とユーザーの選択モデルの位置づけを図1に示す。2では、探索性能の向上を目指して、評価値見積もりとニューラルネットワークによる学習・予測に基づいた解候補生成手法を提案する。また、提案手法の評価にあたり、人間の代わりに評価系としての役割を担うユーザーの選択モデルについて3で述べる。4では、ユーザーの選択モデルに基づいたシミュレーション実験によって提案手法の評価・検討を行う。5では、提案手法を似顔絵生成モデルに応用した結果について紹介する。

## 2 適応度予測に基づく解候補の生成

### 2.1 概要

解候補の生成とは、ユーザーによって評価された個体を基に、次世代にユーザーに提示する個体を遺伝的操作等で生成することである。本研究では、予測適応度を使用して解候補を生成する手法を提案する。また、提案手法は、ユーザーが提示個体の中から好みの個体を1個体選択することによって評価を行うことを前提としている。解候補生成の流れは次の通りである。ユーザーに選択された個体及び選択されなかった個体に対して、システム側で評価値を見積もる。見積もり評価値とその遺伝子型をトレーニングデータセットとしてNNを利用してユーザーの評価特性を学習する。その後、学習済みNNによって算出された予測適応度に基づいて解候補を生成する。

### 2.2 評価値の見積もり

NNによってユーザーの評価特性を学習させ、適応度を予測することを考えた際、ユーザーが評点づけによって評価する場合には、それを学習データに用いればよい。しかし、個体の選択による評価の場合は、その評価を数値的な評価値に変換する必要がある。本研究では、「非選択個体に対する評価は、選択個体に比べて低い」ということに着目した評価値見積もり法を提案する。

#### 2.2.1 評価値見積もり手法1

1) 選択個体 選択個体の評価値  $f_{select}(g)$  は、前世代の選択個体の評価値  $f_{select}(g-1)$  を基準として求める。「探索が進んだ分、選択個体の評価値も増加する」という仮定から基準評価値より  $\Delta f$  大きく見積もる。その見積もり幅  $\Delta f$  に関しては、個体間の距離と適応度にはある程度の相関があることから、個体間の距離に比例した値を取り得るよう設定する。また、探索の収束を表現するために世代が進むごとに指数関数的に変化幅が減少するようにした。

$$f_{select}(g) = f_{select}(g-1) + \Delta f \quad (1)$$

$$\Delta f = \alpha \times \gamma^g$$

$f_A$ : 個体  $A$  の評価値

$g$ : 世代数

$select(g)$ :  $g$  世代目で選択された個体

$\alpha$ : 一様乱数  $[0 \sim \beta \times dist(select(g), select(g-1))]$

$dist(A, B)$ : 個体  $A - B$  間のハミング距離

$\beta, \gamma$ : 定数 ( $0 < \gamma < 1$ )

2) 非選択個体 非選択個体の評価値  $f_{nonselect}(g)$  は、現世代の選択個体の評価値  $f_{select}(g)$  を基準とし、基準評価値より小さく見積もる。その見積もり幅  $\Delta f$  に関しては、選択個体と同様、個体間の距離に応じて決定する。

$$f_{nonselect}(g) = f_{select}(g) - \Delta f \quad (2)$$

$$\Delta f = \alpha \times \gamma^g$$

$f_A$ : 個体  $A$  の評価値

$g$ : 世代数

$nonselect(g)$ :  $g$  世代目で選択されなかった個体

$\alpha$ : 一様乱数  $[0 \sim \beta \times dist(select(g), select(g-1))]$

$dist(A, B)$ : 個体  $A - B$  間のハミング距離

$\beta, \gamma$ : 定数 ( $0 < \gamma < 1$ )

#### 2.2.2 評価値見積もり手法2

1) 選択個体 選択個体の評価値  $f_{select}(g)$  は、世代数に関わらず、常に 1.0 とする。

$$f_{select}(g) = 1.0 \quad (3)$$

2) 非選択個体 非選択個体の評価値  $f_{nonselect}(g)$  は、世代数に関わらず、一律 0.0 とする。

$$f_{nonselect}(g) = 0.0 \quad (4)$$

### 2.3 NNによる学習と適応度予測

ユーザーに提示された個体の遺伝子型と2.2で見積もられた評価値を学習データセットとして、世代毎に誤差逆伝播法によって学習を行う。NNの構造は、3層フィードフォワード型ニューラルネットワーク(入力層のニューロン数=個体の遺伝子長, 中間層のニューロン数=入力層のニューロン数, 出力層のニューロン数=1)。適応度予測値は、学習済みNNの入力層に個体の遺伝子型を入力して得られた出力値とする。遺伝的操作を経て生成された子個体に対して適応度を予測し、予測値が大きい個体を解候補とする。

## 3 ユーザーの選択モデル

### 3.1 モデルの概要

ユーザーの選択モデルとは、タスク自体を人工的な適応度地形と想定し、ユーザーがシステムから提示された個体(解候補)の中から希望の個体を選択するという操作をモデル化したものである。モデル化の狙いは、

- 1) 提案手法に対する客観的な評価・検討をするため
- 2) 多様なタスク、多様なユーザーの主観に対する提案手法の評価をするため

である。そもそも対話型進化計算におけるユーザーの選択とは適応度地形のピーク(最適解)を目指してパラメータ空間を探索することである。対話型進化計算における適応度地形は、システムの特徴パラメータに対して人間の心理空間上のターゲット(好み)とシステムの出力との距離を対応

付けたものである。よって、その形状はユーザーに課せられたタスクに応じて、及び、ユーザーによっても異なる。また、人間が評価する以上、常に一定の評価がなされるとは限らない。つまり、常に、厳密に、適応度の高い個体を選択するとは限らない。人間による評価には変動(=選択の揺らぎ)が伴うのである。以上をまとめると、ユーザーの選択をモデル化するとは、

- 1) 適応度地形を用意する
- 2) 適応度地形上を揺らぎを伴いながら探索することになる。

### 3.2 適応度地形

NK 適応度地形モデルにより適応度地形を生成する。対話型進化計算の対象となるタスクごとに形状が異なる ( $K$  の値が異なる) 地形が考えられる。例えば、「与えられた顔画像と全く同じ画像を検索する問題」は、最もターゲットに一致する 1 点を探すことになるので最適解は一つの単峰性の適応度地形、つまり  $K$  は限りなく小さな値と推測される。一方、「洋服をデザインする」といった人間の好みに依存する問題の場合、好みのデザインの領域付近にある個体を探すのが目的であるため、最適解は一つではない多峰性の適応度地形と考えられ、 $K$  はある程度大きな値と思われる。

### 3.3 選択における揺らぎ

選択の揺らぎは提示個体間の類似度にも依存すると思われる。そこで、揺らぎを考慮したユーザーの選択操作をべき乗スケールとルーレット選択によって計算機で実現する。べき乗スケールの乗数が大きいほど、個体間の相対適応度差が顕著になり、揺らぎの少ない選択操作が表現出来る。このようにスケールの乗数は揺らぎの度合いに対応しており、ここでは揺らぎパラメータと呼ぶことにする。以下の式によって算出される確率  $P$  で選択個体を決定する。

$$P(i) = F'_i = \frac{F_i^w}{\sum_{j=1}^S F_j^w} \quad (5)$$

[ $P(i)$ : 個体  $i$  が選択される確率,  $F'_i$ : 個体  $i$  の相対適応度,  $F_i$ : 個体  $i$  の適応度 (NK 適応度地形の値),  $w$ : 揺らぎパラメータ,  $S$ : 提示個体数 (評価対象個体数)]

### 3.4 ユーザーの選択モデルを用いた対話型進化計算の流れ

- 1) NK 適応度地形を用意する。
- 2) 提示個体それぞれの適応度を NK 適応度地形を参照して求める。
- 3) (5) 式の確率に従って個体を選択する。
- 4) 選択された個体を基に、次世代に提示する個体を解候補生成手法によって求める。
- 5) 2) に戻る。2)~5) を決められた回数だけ繰り返す。

## 4 評価実験

### 4.1 設定

ユーザーの選択モデルを評価系としたシミュレーション実験によって、本研究で提案した解候補生成手法の評価を行う。2.2 の手法 1、手法 2 との比較検討のために、適応度予測をしない手法 (= 予測は行わず、子個体の中からランダムに選択した個体を解候補とする) についても実験した。実験の設定値は、NK 適応度地形 ( $N = 35$ ,  $K = 0, 2, 4$ )、提示個体数=解候補数 ( $S = 9$ )、評価値の見積もり ( $\mu = 1/N$ ,  $\sigma = 0.85$ )、選択の揺らぎ ( $w = 100$ (揺らぎ大),  $300$ (揺らぎ小))、探索世代数 =  $100$ [世代]、試行回数 =  $30$ [試行] とした。

### 4.2 結果

図 2~図 4 は、各地形 ( $K = 0, 2, 4$ )、及び、選択の揺らぎにおいて、選択個体の平均適応度 (1~100 世代) を各手法ごとに初期 (1-20 世代)、中期 (21-80 世代)、後期 (81-100 世代) に分けて示したものである。選択の揺らぎが大きい場合 ( $w = 100$ )、 $K = 0, 2$  の適応度地形では、手法 2 の平均適応度が、他手法に比べて約 1~2% 大きい。手法 4 の適応度地形では、予測なし、手法 2、手法 1 の順で大きく、予測なしと他手法との差は約 1~2% である。一方、選択の揺らぎが小さい場合 ( $w = 300$ )、 $K = 0$  では、3 手法ともほぼ同じ平均適応度となった。 $K = 2$  では、予測なしの手法が最も大きく、他手法との差は約 1% 程である。 $K = 4$  では、手法 1 が他手法に比べて約 1% 大きくなった。また、初期に比べて中期、後期になるにつれて提案手法の優位性が大きくなるのが、特に  $K=4$  の場合に顕著に現れている。探索が進むにつれて学習の効果が現れたためと考えられる。以上をまとめると、手法 2 の効果が表れているのは、 $K$  が比較的小さく、選択の揺らぎが大きい場合である。手法 1 については、その逆で、 $K$  が比較的大きく、選択の揺らぎが小さい場合に効果が見られる。




Fig. 2: 選択個体の平均適応度 ( $K = 0$ )

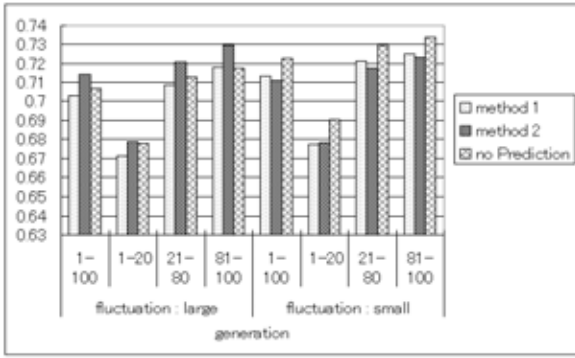


Fig. 3: 選択個体の平均適応度 ( $K = 2$ )




Fig. 4: 選択個体の平均適応度 ( $K = 4$ )

手法 1 と手法 2 の違いは選択-非選択個体間の評価値見積もり幅である。その幅が大きい手法 2 では、選択個体と非選択個体の区別を明確にした状態、いわば選択個体におけるピークがより強調された予測適応度地形を学習することになる。従って、学習後の NN による予測適応度に基づいた解候補生成時には、選択個体に類似した個体に対する選択圧が比較的強くかかると考えられる。地形の形状が単調で局所解の少ない場合には、この選択圧によって進化速度が早められ、平均適応度が高くなったと推測される。

揺らぎが大きい場合は、解候補の中から適応度が大きくない個体も選択される可能性があるため、解候補全ての個体の適応度が探索効率に影響する。図 5 は  $K = 0$  で、揺らぎが大きい場合における解候補の平均適応度と標準偏差を世代ごとにプロットしたものである。この図によると、手法 2 の平均適応度は予測なしの手法に比べて世代を通して大きい。また、標準偏差は若干、手法 2 の方が小さい。学習・予測の効果によって非選択個体周辺の個体、つまり適応度が小さな個体は解候補として選択されず、解候補全体の平均適応度を高く保つことが出来ていることが揺らぎに対して手法 2 がロバストである原因と考えられる。

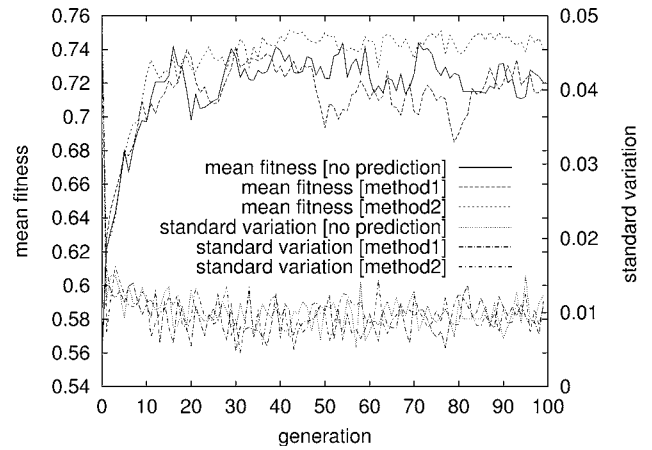


Fig. 5: 解候補の平均適応度と標準偏差の推移 ( $K = 0$ , 揺らぎ大)

一方、手法 1 では、非選択個体に対してもある程度大きな評価値を見積もることで、結果的に非選択個体に対する選択圧も生じるため、手法 2 に比べると多様性が維持される。比較的複雑な地形 ( $K = 4$ ) では、局所解に陥らない為にもこの多様性維持機能は有効であると思われる。予測なしの手法も同様に多様性は保たれるが、手法 1 では、世代後期の選択個体ほど評価値を高く見積もることによって探索の収束性を高めることが出来ると考えられ、これが予測なしの手法よりも良い結果となっている要因と考えられる。

このように、比較的単調な地形では、進化圧によって探索の高速化を期待できる手法 2 が適しており、局所解に陥る可能性がある場合には、多様性の維持と探索の収束性をバランスよく考慮した手法 1 が適していると評価実験の結果から考察される。

## 5 似顔絵システムへの応用

### 5.1 似顔絵生成システム

#### 5.1.1 システムの概要

提案手法を採用した似顔絵生成システムを作成した (図 6)。ユーザはインスピレーションを受けながら心に描くイメージを具現化することにより、特定の人の似顔絵を書いたり、抽象的なイメージから顔を作ることが出来る。



Fig. 6: システム操作画面

### 5.1.2 顔の遺伝子表現

顔画像は、髪（前髪・後髪）、輪郭、眉、目（上瞼・瞳・下瞼）、鼻、口（上唇・下唇）の6個の顔部分と10個の画像パーツの組み合わせによって表現される。各顔パーツの種類は、前髪：7種類、後髪：8種類、輪郭：4種類、眉：4種類、上瞼・下瞼：各4種類、瞳：1種類、鼻：4種類、上唇：1種類、下唇：1種類である。各顔パーツに対して位置、拡大・縮小、回転等の画像変換を必要に応じて付加してある。上記のパーツの種類・変形の組み合わせによって、約17億通りの顔が生成可能である。

顔の遺伝子表現を図7に示す。各顔は46ビットの遺伝子配列から形成されており、そのうち35ビット（2ビット：眼鏡の表示）が顔の進化に関わる部分で、残り11ビットは表情の進化に関わる遺伝子である。

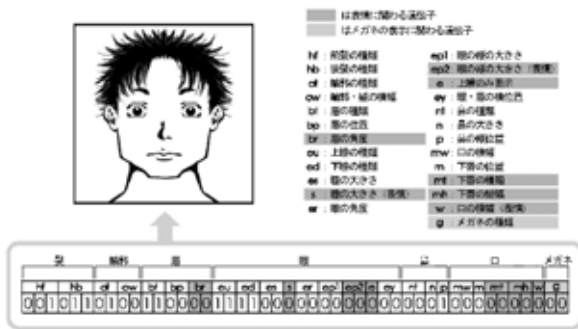


Fig. 7: 顔の遺伝子表現

### 5.1.3 進化

画面上で顔の進化と表情の進化を切り替えることができるようにしてある。これによって顔の探索と表情の探索を分けて行うことができる。

#### 顔の進化

- 1) ユーザーが、画面上に並べられた顔画像の中から、理想とする顔に最も近い顔画像を選ぶ。
- 2) ユーザーが選んだ顔を親として、その遺伝子を受け取る。
- 3) 提案手法によって8個の解候補を生成する。
- 4) 3)で生成された遺伝子列を読み取り、各遺伝子に対応する顔画像を画面上に提示する。中心は親の顔画像が表示される。
- 5) 1)に戻る。

この1)~4)の操作を繰り返すことにより、膨大な数の顔画像の中からユーザーの希望を反映した顔画像を探し出すことができる。

#### 表情の進化

人物の印象は、パーツの特徴だけでなく、表情も大きく影響することから、顔の進化だけでなく、表情の進化もできるようにした。表情の生成は、表情形成に大きく関わるパーツ（眉、眼、口）に対する拡大・縮小・回転等の変形によって行われる。アルゴリズムについては顔の進化と同

様である。無表情な顔は表情進化に関わる遺伝子が全て0の場合である。

### 5.1.4 探索性能の向上

1で述べたように、システムの評価系を人間が担っている以上、問題となるのが個体数、探索世代数の制約や人間の疲労である。本システムでは探索性能の向上策として、提案手法以外に以下の3つを採用している。

- 1) 顔の特定の部分に対しては突然変異を起こさせないように固定することが出来る機能を付加した。固定したい部分は画面上で指定することが出来る。これによって期待する顔への収束速度を早める効果が期待できる。
- 2) 突然変異させる遺伝子数を画面上で3段階調整することが出来るようになっている。突然変異数を小さくすることで、探索後期における顔の微調整が可能となる。
- 3) 任意の時点における顔画像の履歴を保存することが出来るようにした（画面上で「履歴に保存」を選択し、保存させたい顔を選択する）。これによって希望するイメージに近かった状態へいつでも戻ることが出来る。そこから別の進化の道を模索することも可能である。

## 5.2 似顔絵生成

### 5.2.1 実験方法

2つの提案手法を組み込んだ似顔絵生成システムを作成し、被験者4名による実験を行った。被験者は20代学生4名。課題として「人物(図8)の似顔絵作成」と「不幸そうな女の顔の作成」を課した。それぞれの課題に対して、手法1、手法2の2通りの実験を被験者の満足がいく結果が得られるまで行った。初期画像は2手法とも同じ画像とした。また、システムのパラメータは、 $\alpha = 1/N$ ,  $\beta = 0.85$ に設定した。

### 5.2.2 結果

課題、それぞれの操作結果を図9、図10に示す。課題では、似顔絵生成のターゲットが目前に存在しているので、どのユーザーの似顔絵も類似したものになっている。ターゲットがひとつに絞られているので、課題を解くということは、最適解がほぼ一つの単峰性の適応度地形を探索することと推測される。従って、評価実験結果を踏まえると、 $K$ が小さい場合に効果が見られた手法2が適していると考えられる。ターゲットが絞られているので、特に探索初期では、手法2のように進化速度を高めて探索をすることが好ましいと思われる。



Fig. 8: 課題の似顔絵生成対象人物

課題1: 人物の似顔絵作成		
類似者A	手動選択(手法1)	手動選択(手法2)
試行回数 所要時間(分)	32 4:22	32 4:18
類似者B	手動選択(手法1)	手動選択(手法2)
試行回数 所要時間(分)	27 3:17	42 4:05
類似者C	手動選択(手法1)	手動選択(手法2)
試行回数 所要時間(分)	42 4:52	24 3:19
類似者D	手動選択(手法1)	手動選択(手法2)
試行回数 所要時間(分)	32 4:44	32 4:00

Fig. 9: 課題 : 人物 (図 8) の似顔絵作成結果

一方、課題 では、“不幸そうな女”という各ユーザーが頭に思い描く曖昧なイメージに基づいて似顔絵生成が行われるのでユーザーごとに異なる似顔絵となっている。“不幸そうな”印象を拓く顔は一つとは限らないため、多峰性の適応度地形を探索することに相当すると推測される。この場合は、手法1のように選択されなかった個体に対してもある程度の評価値を見積もることによって多様性のある解候補を生成し、そこからユーザーの求める顔へと絞っていく方法が有効であると考えられる。

課題2: 不幸そうな女の顔の作成		
類似者A	手動選択(手法1)	手動選択(手法2)
試行回数 所要時間(分)	17 2:08	13 2:14
類似者B	手動選択(手法1)	手動選択(手法2)
試行回数 所要時間(分)	32 3:21	34 3:50
類似者C	手動選択(手法1)	手動選択(手法2)
試行回数 所要時間(分)	28 4:20	27 4:41
類似者D	手動選択(手法1)	手動選択(手法2)
試行回数 所要時間(分)	45 5:06	40 4:24

Fig. 10: 課題 : 不幸そうな女の顔の作成結果

## 6 まとめ

本研究では、対話型進化計算の探索性能向上を目指して、特に、ユーザーから数値的な評価が得られない場合における適応度予測と、それによる解候補生成手法を提案した。また、あらゆるタスクに対する客観的なデータに基づいて提案手法を解析するために、ユーザーの選択モデルを構築し、それをを用いて評価実験を行った。その結果、比較的単調な適応度地形 ( $K=0, 2$ ) を持つタスクにおいて、選択の揺らぎが大きい場合には、提案手法2が最も良い結果となり、適応度予測の効果が見られた。一方、 $K$ が比較的大きい場合 ( $K=4$ ) には、提案手法1の平均適応度が最も高くなった。評価値の見積もり方によって解候補の多様性や過去の個体に対する選択圧が異なると考えられる為、予測の効果が最も表れる適応度地形は、手法ごとに異なることが分かった。さらに、提案手法を組み込んだ似顔絵生成システムを作成し、実際に被験者をを用いて似顔絵生成を行った。

## 参考文献

- [1] 有田隆也, “人工生命 (改訂 2 版)”, 医学出版, 2002.
- [2] 高木英行, 畝見達夫, 寺野隆雄, “対話型進化計算法の研究動向”, 人工知能学会誌, Vol. 13, No. 5, pp. 24-35, 1998.
- [3] 大崎美穂, 高木英行, “対話型 EC 操作者の負担低減-評価値予測による提示インタフェースの改善-”, 人工知能学会誌, Vol. 13, No. 5, pp. 44-51, 1998.
- [4] 長尾光悦, 山本雅人, 鈴木恵二, 大内東, “インタラクティブ GA に基づく画像検索システムの評価”, 人工知能学会誌, Vol. 13, No. 5, pp. 720-727, 1998.
- [5] Stuart A. Kauffman, “At Home in the Universe”, Oxford University Press, 1995.
- [6] J. -H. Lee and S. -B. Cho, “Analysis of Direct Manipulation in Interactive Evolutionary Computation on Fitness Landscape”, Proceedings of the 2002 Congress on Evolutionary Computation, Vol. 1, pp. 460-465, Hawaii, U.S.A., May 2002.
- [7] H. Takagi, “Interactive Evolutionary Computation : Fusion of the Capabilities of EC Optimization and Human Evaluation”, Proceedings of the IEEE, Vol. 89, No. 9, pp. 1275-1296, 2001.