

(15) 遺伝的アルゴリズムを用いた感性設計の試み Trial of Kansei Design Using Genetic Algorithms

荒川 雅生, 大橋 隆裕, 町村 昌紀, 萩原 一郎

Masao Arakawa, Takahiro Oohashi, Masanori Machimura, Ichiro Hagiwara

東京工業大学

〒152 目黒区大岡山 2-12-1 工学部機械科学科

Tel. 03-5734-3556, Fax.03-5734-2893, email: maar@mech.titech.ac.jp

Genetic Algorithms are assumed precise mathematical or numerical models of their analyses. However, these models are needed only in calculation of fitness function. And fitness function only determine the possibility of leaving offsprings to the next generation, or the possibility of survival in the next generation. Thus, what we needed in fitness functions are to give approximate difference among each individual in the population. In this study, we stress on these characteristic of fitness function and carry out optimization of Kansei which seemed to have difficulties in making up mathematical or numerical models. To demonstrate the effectiveness, we first start from showing how much robustness do genetic algorithms have in searching true optimum solution by treating simple multi-peaked problem with adding white noise to its fitness function. As a demonstrative example, we treat a problem which will make up neutral expression of human faces with given grammar for portraiting their faces. Through this example, we show possibility to use genetic algorithms in Kansei design.

Key Words: Genetic Algorithms, Kansei Design, Adaptive Range method, Robustness

1. 緒言

人間の感性を設計に取り入れ感性工学として初めて整理した長町の研究⁽¹⁾では、SD(Semantic Differential)尺度を用いた感性評価実験に基づき、その結果を数量化理論を用いて定量化し、因果関係などを考慮して感性を向上させ、様々な製品の開発を行ってきた。また、定量化した感性評価の結果をデータベースに整理し、感性の向上を遺伝的アルゴリズムを用いて、“設計の遺伝と進化”としてとらえ自動車のフロントビューに適用した研究⁽²⁾など多数存在する。しかしながら、これらの研究で行う感性の定量化の基になるSD尺度ではかなり多くの形容詞対からなるアンケートを断続的に行う必要がある。そのため被験者の疲労は大きなものであり、それに基づき完全な形で数値化してしまうことは、感性が本来持っているゆらぎや余裕を失ってしまうのではないと思われる。そのうえ、人間の感性とは微妙な違いや組み合わせによって感じ方が変わってくる。すなわち、多峰性が激しい問題といえる。既存のデータを基にアンケートを行い、数量化理論を通じて定量化する事は、近似式の中に多峰性を丸め込ませてしまう可能性がある。松田等⁽³⁾は感性評価をニューラルネットワークに記憶させて、定量化し、その情報を用いて満足化設計を行っている。具体的には自動車の走行時のプロのテストドライバーのフィーリングテストの結果という極めて再現性の高い感性評価の結果を教師信号としてニューラルネットワークへの学習を行っている。しかしながら、ニューラルネットワー

クへの学習を考えた場合に、教師信号にゆらぎやばらつきがあるとニューラルネットワークの学習はなかなかうまくいくものではないため、テストドライバーのようなプロの評価者がいないかぎり適用ができないものと思われる。感性の数量化に関しては、この他にAHPを用いた手法⁽⁴⁾なども存在する。しかしながら、感性のように本質的にあいまいなあるいは定性的な量を数値化する場合には、質の高い感性情報が必要となり、そのためには、テストドライバーのようなエキスパートの感性情報を用いるか、あるいは、アンケートの母集団を広げて信頼性を高めるかしなければならないものと考えられる。

これに対して、荒川ら^(5,6)は数量化によらない方法として、人間の感性というあいまいな量を、定性的な把握を通じて最適化を行う手法を提示した。定性的な最適設計手法を用いたこの手法では、定性的感度の導出が大きなカギになる。そこに、2値比較によるアンケートと中心差分の考え方を利用して比較的有効に定性的感度を導出し、最適化をはかっている。その結果を人間工学上の経験値として得られたものと比較し、有効性を示したり、多目的最適設計に適用し、パレート解集合を求め、解集合の比較より、各目的関数の順序関係よりこの関係が希求通りであることを示したりしている。しかしながら、この手法はおおまかな傾向の把握が可能であることを前提としているので、強い多峰性のある問題には不適切であり、また、アンケートの種類が多くなってしまう欠点を有していた。

感性の最適化を計る場合、その最適化手法にはどのよう

な事が要求されるのであろうか。ここでは、その要求として下記の項目があげられると考える。

- (1)感性という多峰性のある問題に対して有効であること。
- (2)誤差を含んだ解析結果でも解を求められること。
- (3)感性の近似をなるべく用いない数量化手法を解析部で持てること。
- (4)設計の状況を被験者に提示できること。

上記のような要求を全て満足できる最適化手法が存在するとは考えられない。しかしながら、その中でも遺伝的アルゴリズムは、(1)、(2)については満足出来るものと考えられる。何故ならば、遺伝的アルゴリズムにおいて解析結果が関係してくるのは、適応度関数値の決定である。この適応度関数とは、次世代にどれだけの確率で子孫を残せるか、あるいは、自分自身が次世代に生き残れるかの確からしさを決める役割を演じるだけであり、厳密な評価をしなくても、その世代内で多少の誤差があってもおおよその順序関係が把握できれば十分であると考えられるからである。本研究では、遺伝的アルゴリズムの適応度関数のこの性質を調べ、感性最適化手法として好適であることを示す。また、具体的な例として人間の表情の感性実験結果を示し、感性最適化手法としての可能性を示すことを目的とする。

2. 領域適応型遺伝的アルゴリズム

本研究では、遺伝的アルゴリズムとして領域適応型遺伝的アルゴリズムを採用した。このアルゴリズムは、実数領域、離散値領域ともに世代の状況に応じて探索領域を自動的に変化させ、最も適した探索領域で単純GAを行なうものである。詳細は、文献(7,8)を参照されたい。

2.1 従来までの変数の表現法 一般にバイナリ表現に基づくGAsでは、0, 1からなる染色体の線列の中から各変数ごとに割り当てられた線列(p_i)をとりだし、これをまず整数化する。整数化にはバイナリコードとグレーコードと呼ばれるデコード化方法が存在する。このように整数化された整数をここでは $C(p_i)$ と呼ぶ。 $C(p_i)$ を用いて、設計変数としての整数化、離散変数化、連続変数化を行う。従来までの手法では、

a) 整数化の場合

$$DI(p_i) = x_{i,\min} + C(p_i) \quad (1)$$

ここで、 $DI(p_i)$ は p_i を整数化したものであり、 $x_{i,\min}$ はあらかじめ与えられた整数の最小値である。

b) 離散変数化の場合

$$DC(p_i) = \text{Database}[[C(p_i)]] \quad (2)$$

ここで、 $DC(p_i)$ は p_i を離散変数化したものであり、 $\text{Database}[[k]]$ とは各変数ごとに与えられた所与の離散値のデータベース中の第 k 番目の離散値であることを示す。

b) 連続変数化の場合

各変数ごとに上下限値($x_{i,\max}, x_{i,\min}$)を予め設定し、各設計変

数ごとに割り振られたビット数 m_i から

$$R(p_i) = x_{i,\min} + \frac{C(p_i) \times (x_{i,\max} - x_{i,\min})}{2^{m_i} - 1} \quad (3)$$

ここで、 $R(p_i)$ は p_i を連続変数化したものである。

2.2 実数領域適応型遺伝的アルゴリズム 本手法では初期世代では従来までの手法と同じである。第2世代目からは、前世代における各設計変数の平均値 μ_i と標準偏差 σ_i を用いて

$$R(p_i) = \begin{cases} \mu_i - \sqrt{-2\sigma_i^2 \ln \left(LB + \frac{(UB-LB)C(p_i)}{2^{m_i}-1} \right)} & \text{for } C(p_i) < 2^{m_i-1} \\ \mu_i + \sqrt{-2\sigma_i^2 \ln \left(UB - \frac{(UB-LB)(C(p_i)-2^{m_i-1})}{2^{m_i}-1} \right)} & \text{for } C(p_i) \geq 2^{m_i-1} \end{cases} \quad (4)$$

と表される。この概略は図1に示すとおりであり、システムパラメータLB,UBの間を等間隔に分割し、それぞれのy座標に対応するx座標の値をもって対応する p_i の連続変数とするものである。なお、システムパラメータにはLB,UBの他に、 σ_i の上下限値 $\sigma_{\max}, \sigma_{\min}$ を設けている。 $\sigma_{\max}$ は、初期集団において探索領域がいたずらに大きくなるのを防ぐ目的で、 $\sigma_{\min}$ は収束していったときに探索領域が狭まりすぎるのを防ぐ目的で設定したものである。

この他にも、収束性の向上と安定へ向けた工夫として、最良解の保証と外来種突然変異を導入している。

最良解の保証とは、過去の世代において最も適応度の高かった解の組合せを必ず探索領域内に残しておくための操作で、

$$\begin{aligned} & \text{for } \text{Max value}_i > \mu_i, \text{ if } \text{Max value}_i > \mu_i + \sqrt{-2\sigma_i \ln(LB)} \\ & \text{then } \sigma_{i,\text{new}}^R = \frac{\text{Max value}_i - \mu_i}{\sqrt{-2 \ln(LB)}} \\ & \text{for } \text{Max value}_i < \mu_i, \text{ if } \text{Max value}_i < \mu_i - \sqrt{-2\sigma_i \ln(LB)} \\ & \text{then } \sigma_{i,\text{new}}^L = \frac{-\text{Max value}_i + \mu_i}{\sqrt{-2 \ln(LB)}} \end{aligned} \quad (5)$$

ここに、 Max value_i とは、初期世代から前世代までの間で最も適応度関数の値が大きかった個体のその変数における実数値であり、 $\sigma_{i,\text{new}}^R, \sigma_{i,\text{new}}^L$ はそれぞれ平均値の右側、左側に新しく与えられたパラメータである。また、外来種突然




Fig.1 Illustrative sketch of adaptive range expression of continuous variables

変異とは、従来までのように特定のビットの反転を行うのではなく、全く新しい個体をランダムに発生させて集団の中に残す方法である。こうすることにより、多様性を保証し、世代ごとに変化する探索領域に適応させることを目的としている。

側面制約への対応として、各変数ごとに状況に応じてシステムパラメータを操作することにより、探索領域が必ず側面制約($upper_i, lower_i$)を守るような工夫を加えるために、以下のような操作を行った。

for lower bound

$$LB_{i,new}^L = \exp\left(-\frac{(lower_i - \mu_i)^2}{2\sigma_i^2}\right)$$

if $LB_{i,new}^L > UB - margin$ then $LB_{i,new}^L = UB - margin$ and

$$\sigma_{i,new}^L = \frac{lower_i - \mu_i}{\sqrt{-2\ln(LB_{i,new}^L)}} \quad (6)$$

for upper bound

$$LB_{i,new}^R = \exp\left(-\frac{(upper_i - \mu_i)^2}{2\sigma_i^2}\right)$$

if $LB_{i,new}^R > UB - margin$ then $LB_{i,new}^R = UB - margin$ and

$$\sigma_{i,new}^R = \frac{upper_i - \mu_i}{\sqrt{-2\ln(LB_{i,new}^R)}} \quad (7)$$

ここで、 $LB_{i,new}^R$ 、 $LB_{i,new}^L$ とはそれぞれ平均値の右側、左側の限界値を決定するために新しく設定されたパラメータであり、 $\sigma_{i,new}^R$ 、 $\sigma_{i,new}^L$ はそれぞれ平均値の右側、左側に新しく与えられたパラメータである。marginとは $[LB, UB]$ 間の任意の値であり、LBだけの操作では、 $LB_{i,new}^R$ 、 $LB_{i,new}^L$ がUBを上回る可能性があるため、それを回避する目的で設定したものである。LB_{i,new}がmarginの値を越えたときは、 σ_i の値も同時に操作することで前世代の平均値 μ_i と上限の側面制約 $upper_i$ あるいは下限の側面制約 $lower_i$ との間で分割ができるように設定の変更を行っている。

2.3 離散変数の取り扱い 本研究では、式(1)の $x_{i,min}$ の値を前世代の整数値の平均値 μ_i を基に操作する手法を提示する。すなわち、整数においては、

$$DI(p_i) = x_{i,min} + C(p_i) \quad (8)$$

である。ここで、

$$x_{i,min} = \text{Int}(\mu_i + 0.5) - 2^{m-1} \quad (9)$$

もし、この値が、設定した上下限値を越えてしまう場合、致死遺伝子を生じさせないために、

$$\text{if } x_{i,min} < lower_i \text{ then} \\ x_{i,min} = lower_i \quad (10)$$

$$\text{else if } x_{i,min} + 2^{m-1} > upper_i \text{ then} \\ x_{i,min} = upper_i - 2^{m-1} + 1$$

とすればよいことがわかる。連続変数の場合と同様に最良解を保証する場合、

$$\text{if } x_{i,min} > \text{Max value}_i \text{ then} \\ x_{i,min} = \text{Max value}_i \quad (11)$$

$$\text{else if } x_{i,min} + 2^{m-1} < \text{Max value}_i \\ x_{i,min} = \text{Max value}_i - 2^{m-1} + 1.$$

とすればよいことがわかる。

さらに、所与の離散値を扱う場合、式(8)で与えられた整数値をさす離散値を与えればよい。すなわち、

$$DC(p_i) = \text{Database}[DI(p_i)] \quad (11)$$

となる。

この手法を用いる場合、従来まで問題になっていた離散点の数とビット数の不適合によって生じる致死遺伝子の問題点が生じないなどの利点があり、これは、収束性の向上へ向けて大きな寄与をするものと考えられる。

2.4 誤差に対するロバスト性 遺伝的アルゴリズムがどの程度誤差に対して強いかを調べるため、簡単な多峰性のある問題に対して領域適応型遺伝的アルゴリズムを試行した。ここでは、多峰性のある問題として、

$$f = 10 \exp(-0.01(x_1 - 10)^2 - 0.01(x_2 - 15)^2) \sin(x_1) \quad (12)$$

という単純な問題を設定した。これに対して、各設計変数ごとに3ビットの染色体を割り当てた。また、初期的な領域として $[0, 10]$ を与えた。これは、 x_2 に関しては解は明らかに初期設定の領域外にあるものである。式(12)に対して、各世代、各個体毎に関数呼びだすことにし、そこにホワイトノイズをのせることにした。すなわち、

$$f = f + a \cdot \text{random}[-1, 1] \quad (13)$$

ここで、aとはノイズの最大振幅であり、 $\text{random}[-1, 1]$ とは $[-1, 1]$ 間のホワイトノイズを与えるものである。a=0,1,2,3,4,5,6,7,8,9,10の11通りについて、各5回試行し、各設計変数の平均値の挙動でその性質を示すことにした。図2～12に結果を示す。




Fig. 2 Cases of no white noise




Fig. 3 Cases of white noise with $[-1, 1]$ added






Fig. 4 Cases of white noise with $[-2, 2]$ added




(a) mean value of x1 (b) mean value of x2

Fig. 5 Cases of white noise with $[-3,3]$ added




(a) mean value of x1 (b) mean value of x2

Fig. 6 Cases of white noise with $[-4,4]$ added



(a) mean value of x1 (b) mean value of x2


Fig. 7 Cases of white noise with $[-5,5]$ added



(a) mean value of x1 (b) mean value of x2


Fig. 8 Cases of white noise with $[-6,6]$ added

この結果は、単純な問題に対するケーススタディであり、決して大げさな結論をいえるものではない。しかしながら、この関数の最大のピーク値が9.6弱であり、2番目のピーク値が5.7弱である。ホワイトノイズの振幅を考えると、 $a=2$ までは安定して答えの周辺に行くことは容易に考えられることであり、また、図2～4を見ても結果的に解の周辺に落ち着いていっていることが分かる。 $a=3\sim5$ までは1番目のピーク値は何とか信用できるもの残りうるが、2番目のピーク値は既に誤差の範囲内に入るものと考えられるものである。しかも、初期設定の問題から真の解の領域を探索することさへ難しい状況である。図5～7を見ると真の解を求められない場合が出てきていることがわかる。しかしながら、比較的真的解を見つげられることが分かる。 $a=6\sim10$ は関数評価が全く当てにならない場合である。そのような場合でも提示した手法では正解の周辺に行く場合




(a) mean value of x1 (b) mean value of x2

Fig. 9 Cases of white noise with $[-7,7]$ added




(a) mean value of x1 (b) mean value of x2

Fig. 10 Cases of white noise with $[-8,8]$ added



(a) mean value of x1 (b) mean value of x2

Fig. 11 Cases of white noise with $[-9,9]$ added



(a) mean value of x1 (b) mean value of x2

Fig. 12 Cases of white noise with $[-10,10]$ added

があることが確認できる。以上を考察すると、提示した手法が非常に誤差に対して強いことがいえるものと考えられる。実際に感性実験を行う場合でも、その評価値の誤差は評価値そのものの信頼性を失う範囲ではないと思われる。その範囲内においては多峰性のある問題に対して提示した手法が有効である可能性はこのケーススタディから見いだせたものと考えられる。

3. 提示する感性評価手法

感性とはそもそも数学的モデルに載るものではなく、その対象が置かれた場合、被験者の条件によって微妙に異なってくるものと考えられる。そこで、例えば、形状の問題にする場合には、背景等の環境を出きただけ同じにする必要があるものと考えられる。そこで、CG等の利用が考えられる。また、感性の評価としてより直接的な評価法が望ま

れるものとする。以下、その例を試行した感性実験を基に説明する。

3. 1 対象の形状の決め方 設計変数と形状との関連を明確にし、その文法に添って形状を決定することが望ましいと考える。本研究では、以下の例において人間の表情を取り扱っているが、その表現方法として図13のようなパラメータを用いて楕円と直線で表情を表現するものとした。

3. 2 感性計測法 本研究では遺伝的アルゴリズムを用いるので、必要なデータはその世代内における個体間の差である。そこで、個体全ての形状を被験者に提示し、被験者が目的とする感性に合うものはどれか、合わないものはどれかを選んでもらい、それぞれ+1点、-1点とし、単純に加算した結果を感性評価とした。これは、予め多くのデータを提供し、感性実験を行い感性の補間をせず、直接感性を反映させるための工夫である。

ここでは、なるべく多くの方から情報を寄せていただくために、インターネット上で画像を表示し、これにこたえてもらうことで、感性情報を収集した。

4. 感性実験例

本研究では人間の表情を対象とする。ここでは、人間の表情としてもっとも基本的な中立表情に関する感性実験を行う。図13の表現方法における感性実験の様子を以下示すことにする。

遺伝的アルゴリズムとしては各パラメータについて3ビット合計87ビットからの構成となる。いたずらに被験者に見せる表情を増やせないため、ここでは各世代ごとに20個体を考える。そして、20個体の中から被験者が中立表情と思うものを3つ、これは中立表情と思われないものを3つ選んでもらい、その集計結果から適応度を構成するものとした。このアンケートは特定の数人に対して行うのではなく、不特定で、なるべく多くの人間に対して行うことで、より広い範囲のに人間の感性を反映させたい。これらの要求を満たすため、本研究ではインターネットを活用し、ホームページ上 (<http://hagiwarai.mech.titech.ac.jp/>)




Fig.13 Facial expression data (N-Data)

ohashi/question.html) でこのアンケートを行った。それによって、不特定多数の人々の回答を収集する事ができた。また、アンケートの回答は1回につき15～20人から得た。

図14に初期世代における個体の表情を示す。また、その時の評価結果を図15に示す。次にこの結果を基に遺伝子操作を行い、新しい20個体の似顔絵を作り、同様の評価をしてもらった。これを繰り返して行った結果の一例を図16に示し、この評価の結果を図17に示す。図14と図17を比べるとわかるように、目に多少問題があるように思われるものの、N-Dataの集団が世代を重ねることで、全体的には中立表情へと近づいていっているのが見て取れる。このことは、図15と図16において、第1回のアンケートでは、各N-Dataについて「中立表情に見えるかどうか」というアンケート被験者の評価がどちらか片方に集中しがちであるのに対し、第9回のアンケートでは、それぞれ評価にばらつきが生じてきていることから確認することができる。




Fig.14 N-Data (the initial generation)

(a) No. of N-Data (b) judgement										
(b) \ (a)	0	1	2	3	4	5	6	7	8	9
○	0	3	0	3	2	8	3	0	4	0
×	8	4	2	3	3	0	1	6	1	3
Fit ne ss	- 8	- 1	- 2	0	- 1	8	2	- 6	3	- 3

(a) No. of N-Data (b) judgement										
(b) \ (a)	10	11	12	13	14	15	16	17	18	19
○	3	0	0	2	6	0	6	0	0	3
×	0	9	1	0	- 0	2	0	3	0	1
Fit ne ss	3	- 9	- 1	2	6	- 2	6	- 3	0	2

Fig.15 Result of questionnaire in initial generation

(a) No. of N-Data (b) judgement										
(b) \ (a)	0	1	2	3	4	5	6	7	8	9
○	3	3	6	2	1	7	3	7	0	0
×	3	4	0	0	2	3	1	2	6	4
Fit ne ss	0	- 1	6	2	- 1	4	2	5	- 6	- 4

(a) No. of N-Data (b) judgement										
(b) \ (a)	10	11	12	13	14	15	16	17	18	19
○	3	0	1	4	0	3	1	1	4	0
×	2	3	2	0	5	2	2	3	0	3
Fit ne ss	1	- 3	- 1	4	- 5	1	- 1	- 2	4	- 3

Fig.16 Result of questionnaire in 9th generation




Fig.17 N-Data (the 10th generation)

また本研究では、領域適応型遺伝的アルゴリズムの適応度をアンケートによって決定し、アンケートの回答者数は特に制限せず、15～20人程度ということで行ってきた。一般的に、遺伝的アルゴリズムにおける適応度は、全世代共通の定式化された適応度関数によって決定される。しかし本手法では、適応度は人間の感性という定式化の仕様がないものによって決定されており、しかもアンケートの回答者は各回ごとに異なるので、評価基準も全世代共通のものではない。しかし、そもそも遺伝的アルゴリズムにおける適応度というのは、「その世代において、次の世代に自らの遺伝子を残すための確かさ」であり、あくまでも「その世代における、確かさ」である。自然界の進化過程においても、世代が変わればその環境も異なり、各個体の環境への適応度を決定する因子は変化してくる。すなわち、全世代共通の適応度関数の定式化が問題なのではなく、重要なのは決定された適応度の「確かさ」なのである。そのため、定式化が不可能とも言える人間の感性を扱うのに、遺伝的アルゴリズムは非常に適した最適化手法であると考えられる。本例題を通じて、その一端が示されたものと考えられる。

5. 結 言

本研究では、感性設計における最適化の手法として要求されることに、

- (1) 感性という多峰性のある問題に対して有効であること。
- (2) 誤差を含んだ解析結果でも解を求められること。
- (3) 感性の近似をなるべく用いない数量化手法を解析部で持てること。
- (4) 設計の状況を被験者に提示できること。

という4点を指摘した。また、その手法として遺伝的アルゴリズムが適しているものと考えた。多峰性がありしかも誤差を含んだ評価値に対して遺伝的アルゴリズムがどの程度ロバスト性を有するかを簡単な数値計算結果より示し、この要求の(1),(2)に関してはかなり満足のいくものであることを示した。また、感性の評価として近似によらない直接な方法を、設計の状況を被験者に示すための試行として、CGを用いた画像を被験者に示し、その結果を直接適応度関数に割り当てた。このような値は数少ない被験者では本来不十分と考えられるが、遺伝的アルゴリズムの性質を考

慮して、少ない被験者からでも必要な条件は得られるものと考え設計を進めた。その結果、十分な収束には至っていないものの、比較的希求する方向に向かっていっていることが示され、提示する手法の有効性の一端が示された。

提示した手法は、特に感性情報の収集部分にかなり大きな改良点があるものと思う。例えば、現在行なわれているインターネットを通じたアンケートは、インタラクティブなものとはなっていない。CGI等の機能を利用し、よりインタラクティブなものにする必要がある。そのほか、複数の感性を同時に扱えるものでもない。この様な点を含めて今後更なる検討が必要である。しかしながら、遺伝的アルゴリズムの適用という点においてはその可能性を示せたものと考えられる。

謝 辞

本研究は、東京工業大学J R東日本寄附講座内での研究成果の一部である。ここに関係各位に謝意を表する。また、有益な御助言を頂いた早稲田大学山川宏教授に謝意を表する。

参考文献

- [1]長町:感性工学,1989,海文堂。
- [2]勝山,山川:遺伝的アルゴリズムによる感性を考慮した設計の遺伝と進化に関する研究,第3回システム最適化に関するシンポジウム講演論文集,土木学会,1993,p.71-76。
- [3]松田他4名:ニューラルネットワークによる感性情報定量化と満足化設計法(自動車操安性設計への適用),第6回設計工学・システム部門講演論文集[No.96-45],日本機械学会,1996,p.253-256。
- [4]木下:わかりやすい意思決定論,1996,近代科学社。
- [5]荒川,カム,山川:定性的な感度評価を用いた定性的な最適設計に関する研究,第5回設計工学・システム部門講演論文集[No.95-24],1995,p.303-306。
- [6]Arakawa, M., Yoshida, K., Hagiwara, I., Yamakawa, H.: Multiobjective Qualitative Optimization Using Qualitative Kansei Estimation (Preliminary Design of VDT Chair), Proc. on Int. Symp. of Optimization and Innovative Design 97, (in CD-ROM), 1997。
- [7]荒川,萩原:実数領域適応型(ARRange)遺伝的アルゴリズムの開発,第6回設計工学・システム部門講演論文集[No.96-45],日本機械学会,p.246-249。
- [8]Arakawa, M. & Hagiwara, I.: Nonlinear Integer, Discrete and Continuous Optimization Using Adaptive Range Genetic Algorithms, Proc. of Design Technical Conference (in CD-ROM), ASME, 1997。