進化計算による設計探査

小 石 正 隆

Design Exploration based on Evolutionary Computation

Masataka Koishi (The Yokohama Rubber Co., Ltd. 2-1 Oiwake, Hiratsuka, Kanagawa 259-1217, Japan)

Since tires carry out many functions and many of them have tradeoffs, it is important to find the combination of design variables that satisfy well-balanced performance in conceptual design stage. To find a good design of tires is to solve the multi-objective design problems, i.e. inverse problems. Recently, multi-objective evolutionary algorithms are getting popular in many fields to find the Pareto solutions. In this paper, we introduce design exploration of tires using evolutionary computation and self-organizing map. A self-organizing map (SOM) proposed by Kohonen is used to map Pareto solutions from high-dimensional objective space onto 2-dimensional space. The SOM can be considered as an inverse function that defines the relation between Pareto solutions and design variables. We can get useful design knowledge from the map. It helps design engineers to make their decision in conceptual design stage.

Key Words : Design Exploration, Evolutionary Computation, Genetic Algorithm, Self-Organizing Map, Optimization, FEM, Response Surface Method

1. は じ め に

タイヤの設計開発では、目標とするタイヤの諸特性を満足し得るスペック（形状、構造、材料などの設計変数）を決定するために、これまでの知見、試作評価や、計算力学シミュレーションなどの情報に基づいた意思決定がなされている。その中で、有限要素法（Finite Element Method, 以下FEMと記す）に代表される計算力学シミュレーションと共に最適設計の役割が増大している。最適設計とは特性値（目的関数）が所定の条件（最大化、最小化など）を満足する最適なスペック（設計変数）を見出すことである。例えば、FEMと、数理計画法（例えば逐次2次近似法）や進化計算（例えば遺伝的アルゴリズム）などの最適化手法を組み合わせ、図1に示すように繰り返し計算を経ることで最適案を得ることができる^{1,2)}。

しかしながら、最適設計により最適案が見出せたとしてもそのスペック以外の情報が乏しいため、設計情報（設計知識）としての上位概念を捉え難く、設計知識の共有化や他設計への展開が容易ではないという課題がある。そこで、設計開発の初期段階（基本設計）で使える設計知識の取得を目的とした設計探査^{3,4)}が注目されている。本稿では進化計算を用いた設計探査について解説する。先ず設計探査の準備として進化計算等の手法を解説し、次に具体例としてタイヤ形状設計への適用例を示し、最後に今後の展開に

ついて紹介したい。

あらかじめお断りしておくが、設計探査も決して万能で

図1 最適設計の流れ

小石 正隆；横浜ゴム（株）研究本部 小石研究室（〒254-8601 神奈川県平塚市追分2-1）研究室長、工博、平成10年、横浜国立大学大学院工学研究科博士課程修了。昭和60年、横浜ゴム（株）入社、現在に至る。専門は、計算力学シミュレーション。日本ゴム協会ゴムの力学研究分科会主査、日本機械学会フェロー、計算力学部門総務委員。

はない。方法論ですべて解決するわけではなく、それを使うエンジニアのセンスや力量に負うところも少なくない。しかしながら設計探索は、経験の浅いエンジニアでも、長年積み上げられてきた設計知識を比較的短期間で見出せる魅力を有している。

2. 設計探索の準備

2.1 遺伝的アルゴリズム (GA)

遺伝的アルゴリズム (Genetic Algorithm, 以下GAと記す) とは生物の進化過程をコンピュータで模擬する計算手法⁵⁾であり、進化計算 (Evolutionary Computation) を代表するアルゴリズムの1つである。図2にGAの流れを示す。設計変数を遺伝子情報に見立て、突然変異や交叉、さらに自然淘汰に相当する処理を繰り返すことで、目的関数が所定の条件を満たす設計変数を見出すこと、すなわち最適設計を実現できる。

複数の目的関数を同時に扱う最適化は多目的最適化、或いは多数目的最適化と呼ばれる。実際の設計問題では目標特性が単一である場合が少ないため複数の目的関数を扱う必要がある。多目的最適化では目的関数間にトレードオフ関係が存在する場合が多く、最適解はパレート解と呼ばれる最適解集合を形成する。例として、2目的最大化問題のパレート解 (解A, B, C, D) とパレートランキング (括弧内の数字) を図3に示す。図中、解A, B, C, Dは、どちらの目的関数もそれらより勝る解が存在しない。この場合、パレートランキングは1となりこれらの解はパレート解と見なされる。一方、解Eに注目すると、解Eよりも両目的関数で優れる解Bが存在するため、解Eのパレートランキングは2となりパレート解と見なされない。このようにパレートランキングはパレート解の判断基

準として利用できる。GAにパレートランキングを導入することで多様なパレート解を同時に探索できることが示され⁶⁾、多目的最適化問題の直接解法としてGAが注目されてきた。多目的最適化向けに提案されたGAには数多くの種類⁷⁻⁹⁾が存在しそれぞれ名称が異なるが、ここでは総称して多目的GAと呼ぶ。設計探索ではパレート解を取得するために多目的GAを用いる。

2.2 応答曲面

FEMによる特性値計算を前提とする多目的最適化では、繰返し計算の中で目的関数の値をFEMで求める。この場合、FEM計算に時間を要する場合は計算コストが非常に高くなる。例えば、多目的GAにおける個体数を40とし世代数を100とすると合計4000回のFEM計算を必要とする。仮に1ケースのタイヤFEM計算に10分費やすと仮定すると多目的最適化に約30日を要することになる。ましてやタイヤのFEM計算は1時間以上の計算時間を要する場合が少なくない。そこで、目的関数の計算にFEMを直接使う代わりに、応答局面、或いはメタモデルと呼ばれる近似モデルを用い計算コストを軽減する^{1,10)}。応答曲面としては2次多項式などの非線形関数が用いられる。応答曲面を作成するには、先ず、対象とする設計パラメータの定義域にサンプル点を配置しそのサンプル点でのFEM計算を実施し目的関数の値を得る。次にサンプル点でのFEMの計算値と応答曲面の計算値との残差が最小となるように、すなわち最小自乗法により応答曲面の未知パラメータを定める。応答曲面を用いる場合の最適設計の流れを図4に示す。応答曲面の作成手順が最適化の前段階に含まれるため一見複雑に見えるが、図1の手順に比べ非常に短時間で最適化を終了できる。ただし、応答曲面を用いる場合、最適解の精度は応答局面の近似精度に大きく依存するため、応答局面の利用に当たっては近似精度の確認が必要であることは言うまでもない。

図2 遺伝的アルゴリズムの流れ

図3 2目的最大化問題のパレート解とパレートランキング (括弧内の数字)

図4 応答曲面を用いる最適設計の流れ

2.3 自己組織化マップ (SOM)

設計探索では、多目的最適化で得られるパレート解から、設計に役立つ情報（知識）をどのように見出すかが課題となる。目的関数が2つの場合はパレート解を2次元散布図として可視化できるものの、目的関数が3つの場合はパレート解空間が3次元空間となるため図やグラフでその全容を可視化するのは難しく、まして4つ以上の場合には全く困難となる。そこで活躍するのが自己組織化マップ (Self Organizing Map, 以下SOMと記す)^{11,12)} などのデータマイニングや機械学習の手法¹³⁾ である。SOMは教師無しニューラルネットワークの一種であり、学習過程で多次元空間のデータを2次元平面上に写像できる。SOMでは目的関数など多次元空間のデータ間の距離でデータ同士の類似度を定義し、距離の近いデータ（類似するデータ）が2次元平面上でも近くなるように写像される。2次元平面のSOMはノードと呼ばれる点の集まりであるが、各ノードには元の多次元データ（及びそれらに関連したデータ）が保存されている。例えば、4つの目的関数で作成したSOMの各ノードには、目的関数の4つのデータだけではなく関連する設計変数も保存できる。したがって、SOM上に目的関数や設計変数を表示（可視化）することができ、それらを並べて表示することで視覚的に目的関数間の相関関係を把握できるだけでなく、目的関数と設計変数との因果関係も理解できる。

3. タイヤ形状設計への適用

それでは、次にタイヤの形状設計へ設計探索を適用した事例を紹介する。タイヤには燃費（転がり抵抗）、制動、摩耗、操安（コーナーリング特性）、振動騒音など多くの特性が求められているが、その幾つかはトレードオフの関係にある。そのため、タイヤの設計開発では、タイヤ特性間の相関関係（トレードオフ関係）を把握することや、一歩踏み込んでそのトレードオフを解消するための打ち手を見出すことが重要となる。特に近年では、転がり抵抗などのCO₂排出削減に繋がる低燃費性能の更なる改善が求められているため、転がり抵抗とトレードオフ関係にある他特性との両立が課題となっている。

タイヤ設計への適用事例として、ここではタイヤの摩耗性能改善を目的とするタイヤ形状の設計探索を取り上げる。一般にFR車の前輪はショルダー部が摩耗し易い傾向（ショルダー摩耗）を示し、後輪はセンター部が摩耗し易い傾向（センター摩耗）を示す。前・後輪が同じタイヤサイズの場合、装着位置が不確かなため装着位置の影響も合わせて考える。ここで考える最適化問題は、「前輪、後輪どちらに装着されても、偏摩耗が少なく、かつ摩耗量が少ないタイヤ形状を見出す」である。したがって、目的関数として、

f1：前輪の偏摩耗指数

f2：後輪の偏摩耗指数

f3：前輪の摩耗量指数

f4：後輪の摩耗量指数

の4つを定め（4目的最小化問題）、各目的関数の算出にはFEMソフトのLS-DYNA¹⁴⁾ を利用する。また、設計変数としてタイヤトレッド部の形状を定める3つの設計変数を考える。なお、設計変数の定義域以外の制約条件は特に設定していない。

まず、摩耗性能を表す目的関数の応答局面（近似式）を2次多項式で作成した。次にNCGA⁹⁾ と呼ばれる多目的GAを用い約2500のパレート解を探索した。4目的（4次元データ）のパレート解を、2つの目的関数の組合せとして散布図に表示したものを図5に示す。

2つの目的関数間のトレードオフはこの図からも確認できるものの、4つの目的関数間の関係をこの図から理解するのは難しい。また、パレート解と設計変数との関係に至っては知るすべがない。そこで、パレート解のデータを用いてSOMを作成した（図6）。

図6はパレート解全体をデータの類似度（データ間の距離）に応じ10個の領域（クラスター）に分割し、各クラスターをグレースケールで表示している。このSOMは約3000のノードで構成され、各ノードは学習結果として得られた4つの目的関数の値と3つの設計変数の値（計7つ

図5 摩耗性能改善のための4目的最適化問題のパレート解

図6 パレート解情報で作成した自己組織化マップ(クラスター表示)

のデータ)を持っている。SOMではパレート解の数とノード数を一致させる必要はないものの、ノードの値は学習過程で決定されるため元の値から多少外れる場合がある。参考のため、図7に元の値とSOMに写像された値とを比較した一例を示す。横軸が元の関数(応答曲面)で得られた値を示し、縦軸がSOMに写像された値を示す。若干外れるデータも見られるが高い決定係数が得られている。なお、SOMの2次元平面には座標という概念がないため、一般的に縦軸と横軸には物理的な意味ない。また、地図のように見えるが方向や距離といった概念も無い。あるのはノード間の相対的な位置関係(類似関係)である。ラフな

図7 応答曲面 (RSM) の値と自己組織化マップ (SOM) で写像した値との比較

いい方をすれば, 多次元空間のデータを地球儀に例えると, 世界地図がSOMに相当する。地図上の方向や距離は地球儀上のものと異なるが, 隣国間の繋がりは保たれる。例えばメルカトル図法では地図上の東西方向の距離が緯度によって大きく異なるが, 同様にSOMにも絶対的な距離(類似度)は存在しない。

SOMに各目的関数の数値をコンター表示したものを図8に示す。それぞれの目的関数は指数化してあり, 各指数は小さい方が望ましい。すなわち, f1は左上の領域が良く, f2にとっては左下の領域が良いことになる, また, f3とf4はどちらも右上が良い領域を示し領域全体にわたって相関が強いことが視覚的に分かる。一方, f1, f2, f3はそれぞれ望ましい領域が異なるため, トレードオフの関係があることが分かる。さらにSOMには設計変数も表示することができる(図9)。その結果, 所望の目的関数の組み合わせ(性能バランス)とそれに対応した設計変数の組み合わせを確認できる。つまり, SOMを見ながら所定の目的関数の組み合わせを選択すれば, それを実現する各設計変数の組み合わせが分かる。これはSOMを利用する利点の一つであるが, SOMを「可視化された逆関数」と見なすことができる。解析を順問題とすれば目的性能を達成するための設計変数を模索する設計は逆問題となるが, その設計の流れに適合するデータベースをSOMで得ることができる。

次に, クラスタごとの平均値を用いてパレート解全体の特徴をみる。図10はクラスタごとの各目的関数の平均値を表している。グラフの縦軸は各目的関数の平均値を重ねて示している。このグラフを見ると, 偏摩耗 (f1, f2) だけを改善するのであれば, #2のクラスタが優れるこ

図8 目的関数ごとにコンター表示したパレート解の自己組織化マップ

図9 設計変数ごとに表示したパレート解の自己組織化マップ

とが分かる。すなわち, 摩耗寿命に優れるキャップコンパウンド (ここでは考慮していない設計変数) を利用できる状況であれば, #2のクラスタを設計案として採用できることが分かる。もし, 他性能との兼ね合いで摩耗寿命に優れるキャップコンパウンドが採用できないのであれば, #7, あるいは#8のクラスタが良いことが分かる。これらのクラスタは平均値の和が小さいと共に偏摩耗指数と摩耗量指数の比率がほぼ均等である。一方, 図11はクラスタごとの設計変数の平均値を示している。図10と合わせて見ることで, クラスタごとの性能バランスとその設計変数との因果関係を理解できる。図11のグラフより#7と#8のクラスタでは設計変数の組み合わせが異なることが分かる。これらのクラスタは目的関数のバランスがほぼ等しいにも関わらず, 設計変数の組み合わせ(タイヤ形状)が異なっている。実開発では, 摩耗以外の特性も加味しなければならないし, その他の制約も考えられる, そのような状況で, ほぼ同じ性能バランスを具現化できる設計案が複数見出せることは非常に有益である。

これらの探索例はほんの一例であり, 適用分野や目的に

図10 クラスタごとの目的関数の平均値

図11 クラスタごとの設計パラメータの平均値

応じて様々な設計探索が可能である¹⁵⁾。

4. 今後の展開

4.1 マルチスケール設計探索

上記解析事例ではパレート解全体を探索対象とし、クラスター平均値に基づいた設計探索について示した。しかしながら、特定のクラスターに着目した局所的な設計探索も可能である。例えば、図12は上記とは異なるタイヤの設計問題への適用例（3目的の設計探索）である。図中、f1（最小化）、f2（最大化）、f3（最小化）は目的関数を表し、x1～x4はタイヤの設計変数を表す。また、マップ上のC1～C12はクラスター番号を表す。図12よりこの事例ではクラスターC1が目指すべき設計案であることが確認できた。また、表1に示すパレート解全体での相関分析を見ると、f2と相関する設計変数はx3であるが、x3はf3とも相関していることがわかる。x3とf2及びf3との相関係数が同一の符号であるのに対し目的関数の方向性が逆であることからf2を単独にコントロールできる設計変数が見当たらない。しかしながら、表2に示すクラスターC1の相関分析を見ると設計変数x2でf2を単独にコントロールでき

(a)

(b)

図12 全パレート解領域の目的関数 (a) 及び設計パラメータ (b) の自己組織化マップ

ることが分かる。すなわち、基本設計としてクラスターC1を選択すれば、詳細設計段階でx2を使ってf2をチューニングできることになる。以上をまとめると、パレート解全体の設計探索から基本設計に関わる知識を得ることができ、さらに、特定のクラスターの設計探索から詳細設計のチューニングパラメータが得られることになる。このような大域的な設計探索と局所的な設計探索の組み合わせはマルチスケール設計探索と呼ぶことができ、今後の展開が期待される。

4.2 トレードオフ関係の打開

最後にトレードオフ関係の打開について簡単に触れる。得られたパレート解を対象とした設計探索からも設計に役

表1 全パレート解領域における相関分析

	f1	f2	f3	x1	x2	x3	x4
f1	1.00						
f2	0.01	1.00					
f3	-0.09	0.79	1.00				
x1	0.24	-0.09	-0.60	1.00			
x2	-0.20	-0.03	0.06	-0.21	1.00		
x3	0.07	-0.97	-0.80	0.16	-0.11	1.00	
x4	0.90	0.07	0.00	0.10	-0.11	0.03	1.00

表2 クラスタC1における相関分析

	f1	f2	f3	x1	x2	x3	x4
f1	1.00						
f2	0.29	1.00					
f3	-0.30	0.07	1.00				
x1	0.60	0.50	-0.66	1.00			
x2	-0.33	-0.74	-0.11	-0.27	1.00		
x3	-0.02	-0.31	-0.22	0.00	-0.06	1.00	
x4	0.34	-0.01	0.07	-0.05	-0.02	0.00	1.00

立つ情報（知識）を取得できることはすでに述べた。さらに、トレードオフ関係を打開できれば、新たな知識を獲得できるばかりではなく付加価値の高い製品開発への展開が期待できる。3節において「摩耗寿命に優れるキャップコンパウンド（ここでは考慮していない設計変数）を利用できる状況であれば、#2のクラスターを設計案として採用できる」と述べたように、一般には新たな設計変数を導入することで、あるいは設計変数を見直すことでトレードオフ関係を打開できる可能性がある。ただし、ここではパレート解を望ましい方向へ拡張する取り組みの一端を紹介する。パレート解を望ましい方向（どちらの特性値も改善される方向）へ拡張できる設計変数を見出し、パレート解を拡大した事例を示す（図13）。この事例は転がり抵抗とコーナリング特性を目的関数としたタイヤ形状の設計探索である。ここでは、パレート解だけではなく、最適化過程で得られた設計案のデータも含めたデータマイニングにより、トレードオフ関係にあるコーナリング特性と転がり抵抗を同時に改善できる設計変数を見出すことができた。さらに、それらの設計変数の定義域を調整することでパレート解を望ましい方向へ拡張することができた。最近の取り組みの中で、真のパレート解探索を目的として発展してきた多目的GAのアルゴリズムを改良することでこのような問題に対応できることが見えてきており、今後の展開に期待したい。

5. お わ り に

多目的GAやSOMなどの進化計算に援用された設計知

図13 パレート解を望ましい方向へ改善した例

識獲得のための「設計探索」について紹介した。設計探索は優良な設計案（例えばパレート解）を選別するためのふるいとして最適化を用い、そこで選別されたデータから設計に有用な情報（知識）を見出すことを目的とする点で、単に最適解を見出すことを目的とする従来の最適設計とは異なっている。本稿ではタイヤの形状設計への適用について述べたが、この方法論は他の設計問題へも適用可能であり、さらには、入出力関係が定義された諸問題へ展開可能である。

References

- 1) Kashiwamura, T.; Shiratori, M.; Yu, Q.; Khoda, I.: *Nippon Kikagakkai Ronbunshu Ser.A*, **62**, 2180 (1996)
- 2) Nakajima, Y.; Kamegawa, T.; Abe, A.: *Tire Sci. Technol.*, **24**, 184 (1996)
- 3) Obayashi, S.; Sasaki, D.: *AIAA Paper 2002-0991* (2002)
- 4) Koishi, M.; Shida, Z.: *Tire Sci. Technol.*, **34**, 170 (2006)
- 5) Goldberg, D.E., "Genetic Algorithms in Search, Optimization and Machine Learning", Addison-Wesley Publishing Company, Inc. (1989)
- 6) Fonseca, C.; Fleming, P.J.: *Proc. of the 5th ICGA*, p.416 (1993)
- 7) Deb, K.; Agrawal, S.; Pratap, A.; Meyarivan, T.: *KanGAL report 200001*, Indian Institute of Technology, India (2000)
- 8) Obayashi, S.; Takahashi, S.; Takeguchi, Y.: "Lecture Notes in Computer Science", Springer, **1498**, p.260 (1998)
- 9) Watanabe, S.; Hiroyasu, T.; Miki, M.: *Proceedings of the 4th Asia-Pacific Conference on Simulated Evolution and Learning (SEAL-2002)*, p.198 (2002)
- 10) Timothy, W. S.; Timothy, M. M.; John, J. K.; Farrokh, M.: *AIAA paper 98-4755* (1998)
- 11) Kohonen, T.: "Self-Organizing Maps", Springer (1995)
- 12) Viscovery SOMine Version 4.0 Users Manual, Eudaptics software gmbh (2001)
- 13) Witten, I.; Frank, E.: "Data Mining: Practical Machine Learning Tools and Techniques", Morgan Kaufmann Publishers, Elsevier Inc. (2005)
- 14) LS-DYNA Version 971 Users Manual, LSTC (2007)
- 15) Oyama, A.; Nonomura, T.; Fujii, K.: *Journal of Aircraft*, **47**, 1756 (2010)

日本語表記参考文献

- 1) 柏村孝義; 白鳥正樹; 于強; 国府田勲: 日本機械学会論文集 (A編), **62**, 2180 (1996)