

CAE における機械学習の利用動向

— 宇宙機開発への活用可能性

Machine Learning Trends in CAE: Their Applicability to Spacecraft Development

原田 竜善*

Tatsuyoshi Harada

我々は、CAE（Computer Aided Engineering）技術を用いて宇宙機の熱・構造に関する設計・開発事業を行っている。その CAE 技術における機械学習の活用について、近年産業界・学会で事例が多く紹介されている。本稿では、CAE の機械学習活用に関する調査報告と、「宇宙機開発分野の CAE」の機械学習活用の可能性について整理する。

We have been performing thermal and structural analyses for spacecraft design and development using computer aided engineering (CAE). Many applied cases of machine learning approach to CAE are recently reported in industry and academic conferences. This report summarizes utilization trends of the machine learning and possibility to spacecraft development.

1. まえがき

宇宙機は、総開発費用が数百億円規模と高額で、一度運用を開始すれば保守が困難であり、宇宙空間で数年から十数年間運用される事から、高い品質・信頼性が求められている。それに対して CAE 解析・試験などによる網羅的な設計検証や、設計マージンなどにより、品質・信頼性を確保している。一方、近年の宇宙の商用利用・財政負担軽減などを背景に、更なる生産性の向上・コスト削減が求められている。これらの課題に対し、新たな試みとして、現在様々な産業で研究・開発が盛んな機械学習の活用の可能性を検討する。

本稿では、宇宙機の熱・構造設計で広く用いられている CAE に着目し、CAE の機械学習の活用について事例を調査し報告する。また、宇宙機の熱設計を例に、CAE における機械学習活用方法案を示し、最適化や自動化など、生産性向上について整理する。

2. CAE の機械学習活用に関する調査

2.1 産業界の状況

図 1 に示すとおり、第二次 AI ブームのピークであった 1991 年以降、AI 関連の発明件数は減少傾向であった。しかし、近年の産業界の AI 技術の取り組みは活発で、AI 関連の発明・特許出願件数が 2014 年以降に急増しており、2017 年には約 3000 件に上っている⁽¹⁾。特徴として




図 1 AI 関連発明の国内出願件数の推移

は、メカトロ、情報通信機器、交通などに関連する分野に AI を導入しようとする傾向が強いと分析されている。

2.2 技術の位置づけ

CAE は、実験、理論科学に続く第三の科学と言われる計算科学を設計分野に活用した技術であり、宇宙機の設計で広く活用されている。それに対して、第四の科学とされるのが機械学習などのデータ科学であり、実験・観測・シミュレーションなどで収集したデータを分析し結論を導き出す手法である。これらの手法も設計・性能評価・予測技術などに用いられている。

2.3 CAE の機械学習活用事例

宇宙開発に関連した分野で、CAE と機械学習を用いた

* 鎌倉事業部 宇宙第三技術部

表1 産業界におけるCAEの機械学習活用事例

事例	分野	手法	報告年
① 数値流体解析による流体制御予測	機械設計	深層強化学習	2018
② 基盤設計における必要総数予測	プリント基板設計	サポートベクター回帰	2016
③ 機械設計における3次元モデル部品の自動検出	機械設計	機械学習 (詳細不明)	2016
④ タービン翼の圧力損失最小/形状最適化	機械設計	deep Q-network	2019
⑤ 人工衛星の断熱材 (MLI) 面積最小化	人工衛星設計	遺伝的アルゴリズム	2007
⑥ はんだ付け時の熱風の温度・速度の自動化	機械設計	機械学習 (詳細不明)	
⑦ 圧縮機のサージ流量予測	機械設計	深層学習	2019
⑧ 人工衛星運用時の故障予兆検知	人工衛星設計	再帰型ニューラルネットワーク、サポートベクターマシン	2018
⑨ 自動車衝突時のシミュレーション	自動車開発	機械学習 (詳細不明)	2018
⑩ 解析形状モデルの機械学習の手法に関する調査	CAE 解析	geometric deep learning	
⑪ 衛星画像の変化検知	防災	深層学習	2018

事例報告を調査し表1に整理する^{(2)~(9)}。①~⑥が機械学習の強みである最適化や逆解析に関する事例であり、⑦~⑨がCAE解析では難易度が高い問題に機械学習を利用した例である。⑩⑪では機械学習に不可欠な学習データ(入力データ)をシミュレーションなどで自動生成する内容が報告されている。

3. 宇宙機開発分野 CAE への機械学習活用の可能性

前章の調査から、CAEにおける機械学習の活用方法は以下のように分類できる。

- (1) 機械学習の学習データをCAE解析モデルから生成
- (2) CAEモデルの入力パラメータを機械学習で生成
- (3) 従来のCAE解析の機械学習への置き換え

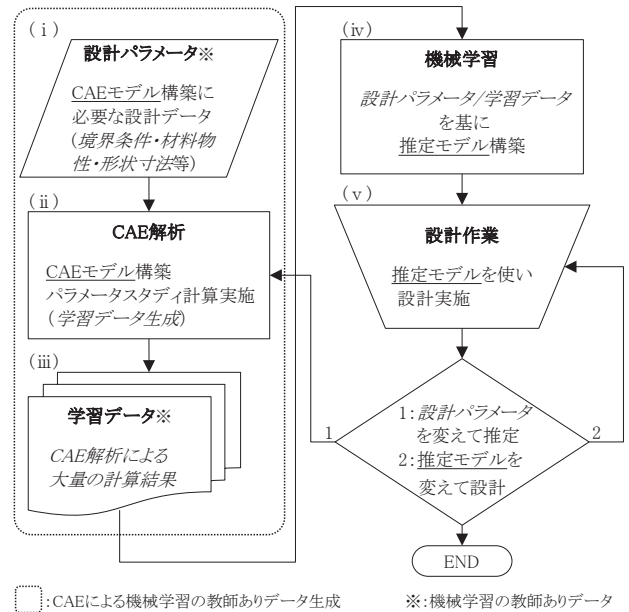
上記(2)の方法は、学習に関するパラメータの決定方法が工学的解釈を積み上げるような方法でないため、設計へのフィードバックがブラックボックス化する懸念があり実用化が進んでいない。(3)の方法は、方程式をニューラルネットワークで近似し、メッシュフリーな数値計算を行う方法などが提案されているが、現状では精度の面でCAEに置きかえるには至っていない。

それに対して(1)の方法は、設計と解析との関係が明示的である。また、機械学習による最適化や自動化などのメリットも利用できるなど、宇宙機設計に活用できる可能性があると考えられるため、本稿では(1)の方法について更に検討する。

3.1 機械学習活用法の検討

(1)の活用方法について、表1の事例からは手法の詳細などの情報が少なく十分な分析ができなかったため、本稿では図2に示す方法を提案し検討を行う。なお、機械学習の入力データは、表1の事例の中で多く用いられていた「学習データ(教師あり)」とする。

図2で提案する機械学習の活用方法では、(i)の設計データを基に、(ii)で有限要素法や有限差分法などの解析的手法により近似解を求める。(iii)でCAE解析結果から学習データ(教師あり)を生成し、(iv)で機械学習により不確定なモデルパラメータを決定する。(v)では機械学習



□: CAEによる機械学習の教師ありデータ生成 ※: 機械学習の教師ありデータ

図2 CAEによる学習データ(教師あり)の生成

の推定モデルを使って設計を行い、必要に応じパラメータやモデルを見直しを繰り返す。

以下に、主要な処理である(ii) CAE解析と、(iv) 機械学習の内容について記す。

3.1.1 (ii) CAE解析

設計条件を変えながらパラメータスタディ計算を実行し、設計値とその解析結果から教師付きの学習データを生成する。パラメータスタディの対象となる設計項目は図3の入力と出力の部分に示す多数の設計項目である。この中から機械学習の推定モデル作成に必要な項目を選び、パラメータスタディ用のCAEモデルを構築する。図3に宇宙機の熱解析に必要な入出力データとCAE解析との関係を示す。

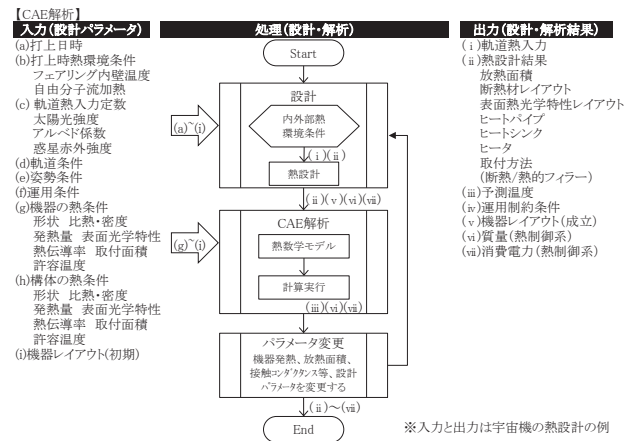


図3 CAEの主な流れと入出力データ




図4 機械学習の処理の流れと入出力データ

3.1.2 (iv) 機械学習

宇宙機の放熱面設計を例とした場合、学習データ(教師あり)は、図3の(g)~(i)に示す発熱量/形状/機器レイアウトと、(ii)(iii)(v)に示す放熱面積/予測温度/機器レイアウトになる。図4に機械学習と入出力データの関係を示す。なお、機械学習の手法としては回帰分析を用いた。

3.2 簡易モデルによる検証

図2の実現性を確認するために、宇宙機の放熱面積を算出する模擬設計を実施する。検討では、機器発熱量3パターン、放熱面積は4パターン、計12ケースのパラメータスタディを行い、発熱機器搭載パネルを40℃に制御する放熱面積推定モデルを、機械学習により算出する。検討の前提条件を表2に、CAEモデルで定義した形状モデル図(メッシュ図)を図5に、CAE解析の結果(学習データ(教師あり))を図6に、機械学習により推定したモデルを図7に各々示す。本稿の熱解析には、汎用熱解析ソフトウェアのSINDA/FLUINTを使用する。

本モデルは、図5に示すとおり、放熱面を8×8に分割する。発熱機器は放熱面パネル中央とし、放熱面形状は中央から同心円状に1メッシュずつ変化させる形状とする。

パラメータスタディの結果を、横軸「放熱面積(入力)」、縦軸「予測温度(出力)」とし、機器発熱量ごとに整理して図6のグラフにまとめ、学習データ(教師あり)を作成する。

図6の学習データ(教師あり)から、設計目標温度に対する「機器発熱量と放熱面積」の値を抽出して機械学習(回帰分析)を行い、推定モデルを算出する(図7)。

図7では推定モデルと理論値をプロットし、推定モデルと理論値との比較を行った。理論値は以下の式(1)により算出する。その考え方を以下に示す。

宇宙機における熱平衡を考える。宇宙空間からの熱入力と宇宙機内部での発熱量の合計は、宇宙機表面から

表2 検討モデルの前提条件

熱的に定常状態	
軌道熱入力は太陽光のみ	
外部搭載機器からの赤外放射なし	
太陽光強度(一定値)	1,350[W/m ²]
機器発熱量	10[W], 12[W], 15[W]
放熱面積	0.16[m ²], 0.09[m ²], 0.04[m ²], 0.01[m ²]

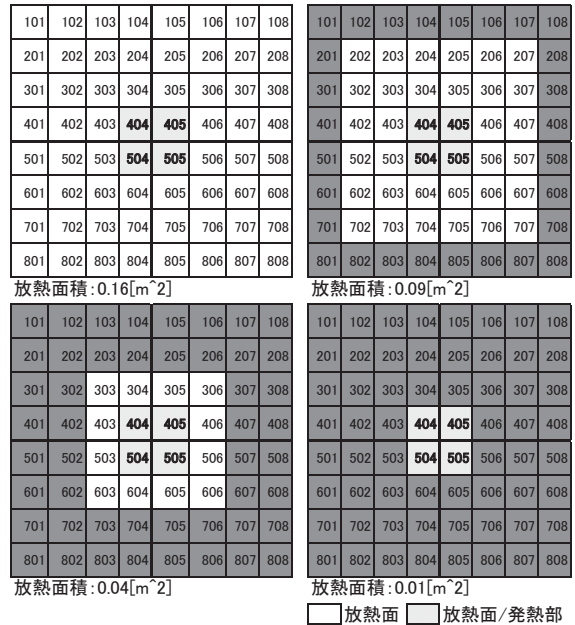


図5 CAEモデル図

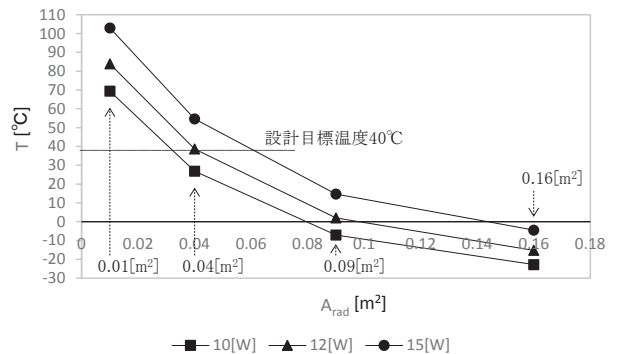


図6 学習データ(教師あり)

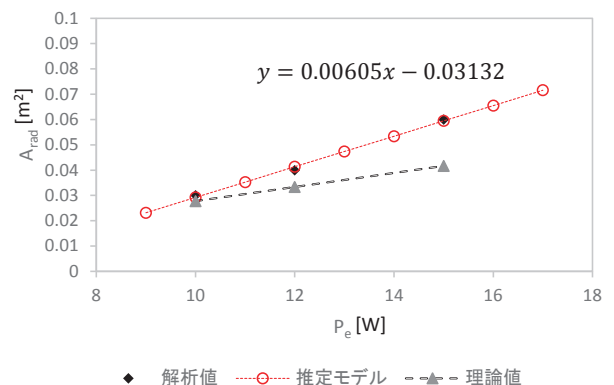


図7 推定モデル

宇宙空間に放射する熱量に等しいので

$$\alpha P_s \sin \beta A_{\text{rad}} + P_e = \eta \varepsilon \sigma T^4 A_{\text{rad}}$$

が成り立つ¹⁰⁾。これより

$$A_{\text{rad}} = \frac{P_e}{(\eta \varepsilon \sigma T^4 - \alpha P_s \sin \beta)} \quad (1)$$

ただし

A_{rad} : 放熱面積 [m²] P_e : 機器発熱 [W]
 η : フィン効率 [-] ε : 赤外放射吸収率 [-]
 σ : Stefan-Boltzmann 定数 [Wm⁻²K⁻⁴]
 T : 放射面温度 [K] α : 太陽光吸収率 [-]
 P_s : 太陽光強度 [Wm⁻²] β : 太陽光入射角 [rad]

推定モデルと理論値を比較すると、放熱面積 0.03 m² 付近では良く合うが、放熱面積が広がるにつれて差が広がる傾向にある。これは、理論値ではフィン効率一定としているのに対し、推定モデルは CAE モデル側でメッシュを詳細化しフィン効率の変動を模擬しているためであり、CAE 解析と機械学習を組み合わせた推定モデルの利点と考える。

また、図 7 の推定モデルの算出は機器発熱量を説明変数とする単回帰分析により行っているが、実設計においては、他の設計パラメータも説明変数に加えた重回帰分析などにより、複数の設計パラメータの評価が求められるので、実用の際は注意が必要である。

3.3 留意点

検討した手法は、数値解析により人工的にデータを作り出す方法であり、それが故に以下のような利点や難点が指摘されている。

機械学習に CAE 解析を使用する利点として、機械学習の入力データとなる「教師データ」の生成のしやすさがある。例えば、CAE 解析を複数の条件を変更しながら自動的に実行し、大量のデータを生成する事が可能であり、解析ケースを追加しデータを増やす事も容易である。また、自然由来のデータを使用した場合にしばしば発生するデータのノイズも CAE 解析では基本的に発生しないため、均質なデータを生成できる。

一方、CAE モデルの特徴であるメッシュデータに由来する難点がある。それは、立体や平面などの形状を模擬した幾何学データに対して、複数の学習アルゴリズムが提案され、問題に適した使い分けが必要とされていることであり、実用には注意が必要である。

4. むすび

本稿の目的は、宇宙機設計業務で使用している CAE 解析への機械学習の活用の可能性について、産業界の事例(2章)や技術的検討(3章)により調べる事であった。

結論を以下に記す。

2章では、産業界・学会から報告されている複数の論文・技術資料により、CAE 解析での機械学習利用の実例を確認した。ただし、製品設計への汎用的な適用例や、一般化している手法やツールの事例など、産業界での普及は確認できず、業務への適用を検討する際は留意すべきである。また、手法の詳細については情報が少なく十分な分析ができなかったため、3章では産業界の事例の中から、実用的と考えられる方法の一つとして「機械学習の学習データを CAE 解析モデルから生成する」方法を選び試行した。その結果、宇宙機の熱設計において、機器発熱量を変数とした最適な放熱面積を機械学習(回帰分析)で求める事ができ、機械学習活用の可能性の一例を確認した。

また、3章の(2)の行で述べた「設計に機械学習を用いた場合のブラックボックス化は実用化に向けての障壁となる」と複数指摘^{11) 12)}されており、留意が必要である。なお、本稿では対策としては3章の(1)で述べたとおり「CAEの計算結果を機械学習の入出力データとする方法」を提案した。

参考文献

- (1) 特許庁 審査第四部 審査調査室：AI 関連発明の出願状況調査 (2019)
- (2) 小泉 拓：宇宙開発におけるデータサイエンス・AI の利用に向けた試み、みずほ情報総研レポート、15, 16～25 (2018)
- (3) 野崎 直行, 今野 栄一, 佐藤 満, 坂入 慎, 澁谷 利行, 金澤 裕治, Georgescu, S.: 製品設計における人工知能技術の応用, 雑誌 FUJITSU, 67, No.3, 58～65 (2016)
- (4) 齊藤 弘樹, 服部 均, 米倉 一男：機械学習と CAE を利用したターボ機械の設計支援技術, IHI 技報, 59, No.1, 30～43 (2019)
- (5) 津田 健太, 岡本 篤, 千葉 正克, 大久保 博志, 東 久雄, 杉山 吉彦, 秋田 剛, 中村 揚介, 今村 博昭：遺伝的アルゴリズムによる 50 kg 級小型衛星の熱制御システム設計, 日本航空宇宙学会論文集, 55, No.639, 195～201 (2007)
- (6) MONOist: AI と CAE、ビッグデータの融合で匠の技は残せるのか—オムロンのチャレンジ (2018)
<https://monoist.atmarkit.co.jp/mn/articles/1809/21/news025.html>
- (7) 杉江 卓哉, 梅津 里香, 竹島 敏明, 海老沢 研, 長瀬 雅之, 湖海 亮：機械学習を用いた宇宙機の故障検知, 宇宙科学情報解析シンポジウム (2018)

- <https://repository.exst.jaxa.jp/dspace/bitstream/axis/879968/1/SA6000122017.pdf>
- (8) MONOist: CAEの代わりにAIでボンネットの構造を分析、頭部障害値が誤差5%で一致した (2018)
<https://monoist.atmarkit.co.jp/mn/articles/1809/18/news027.html>
- (9) 株式会社科学計算総合研究所: FEMと幾何学の機械学習 (2019)
https://www.ricos.co.jp/tech-0101_ml_fem_geometry/
- (10) 大西 晃, ほか 編: 宇宙機の熱設計, 名古屋大学出版会 (2014)
- (11) 宮川 尚紀: シミュレーション解析における機械学習の展開可能性, みずほ情報総研技報, 9, No.1 (2018)
- (12) 和田 義孝: 深層学習, 日本機械学会計算力学部門ニューズレター, No.58, 11 ~ 14 (2017)

SINDA/FLUINTは、C&R Technologies, Inc.の商標または登録商標です。

執筆者紹介

原田 竜善

1996年入社。入社以来、宇宙機の熱設計・解析業務等に従事。