

# 機械学習を用いたデータ駆動型カスケードニング法の提案

中津川英治<sup>†</sup> 新谷浩平<sup>†</sup> 土山稔<sup>†</sup>

トヨタ自動車株式会社 車両デジタル開発部<sup>†</sup>

## 1. はじめに

システム開発の初期段階では、V字開発に基づいて複数のシステム性能要求を満足する特性や諸元を求めること（カスケードニング）が重要である一方で、企画段階にそれぞれの要求を満たすように機械要素へ目標割付するのは困難である。具体的には、システムモデルの中で機械要素を表現できない場合や表現できても計算負荷が膨大になってしまう課題がある。更に、多性能成立の最適化問題を解く上で、計算回数が膨大となり、限られたリソースの中でカスケードニングを行うのは容易ではない。そこで、本研究では、図1のようなモデルベース開発（MBD）で用いられるシミュレーション技術の中で、まだモデル化できていない機械要素を機械学習モデルにより表現するのに加えて、デジタルアセットを用いたデータ駆動型のカスケードニング技術を提案し、車両の性能開発の中で、重要な機械要素であるエンジンマウントを題材に、数値事例を用いて提案手法の妥当性を示す。

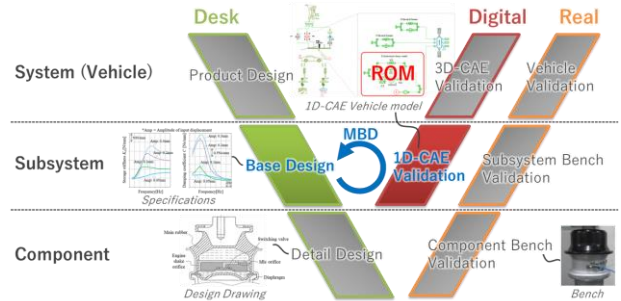


図1 V字開発内のモデルベース開発の構成図




図2 ROMの概略図（例. エンジンマウント）

## 2. Reduced Order Modeling

Reduced Order Model (ROM)とは、機械要素の特性を表現する入出力を、実験データや数値計算結果を学習することで、従来モデルより大幅に次元を削減させたまま特性を模倣するデータ駆動型の機械学習モデルを示す。線形特性を有する機械要素は、回帰モデル  $y = f(x)$  を用いて表現できるが、過渡現象かつ非線形特性を有する入出力は回帰モデルでは表現しきれない。そこで、時系列データ分析に特化したアルゴリズムである Recurrent Neural Network (RNN) [2] を用いて、システム内の一部の機械要素を置換する。ここで、例として車両の重要な部品の1つであるエンジンマウントのROMを図2に示す。

## 3. Bayesian Active Learning

Bayesian Active Learning (BAL) を用いれば、多性能成立のための最適解を効率的に探索することが可能である。まずは、DOEに基づいて設計空間に対し、初期サンプルを作成し、シミュレーションを用いて応答を算出した学習データを  $\mathcal{D} = \{(\mathbf{x}_i, \mathbf{y}_i)\}_{i=1 \sim n}$  と表す。ここで、 $\mathbf{x} \in \mathcal{X} \subset \mathbb{R}^d$  は設計

変数を表し、 $\mathbf{y} \in \mathbb{R}$  は応答を表す。Gaussian Process (GP) を用いれば回帰モデル  $f: \mathbb{R}^d \rightarrow \mathbb{R}$  は次のように表すことができる。

$$f \sim \mathcal{GP}(y | m(\mathbf{x}), k(\mathbf{x}, \hat{\mathbf{x}})) \quad (1)$$

GP は事後分布としての予測平均  $\mu(\mathbf{x})$  と偏差  $\sigma(\mathbf{x})$  を得ることができ、BAL ではこれらを用いて次点を選択するための指標である獲得関数を算出する。最適値探索のための獲得関数は Expected Hypervolume Improvement (EHVI) [2] は次のように定義される。

$$EHVI[f_1(\mathbf{x}), \dots, f_m(\mathbf{x})] = \int_{\mathbf{y} \in \mathbb{R}^m} HVI(\mathbf{y}, P) \cdot \phi(\mathbf{y}) d\mathbf{y} \quad (2)$$

多目的関数を最適化するサンプル点は、EHVIが最大となる点を探索し、最適解を更新する。


## 4. 数値検証例

### 4.1 車両の動的性能を対象とした目標割付


自動車部品の中でも、エンジンマウントは、NVH (Noise Vibration Harshness) 性能に対しては低ばね・低減衰化による伝達力の低減、乗心地性能に対しては高剛性・高減衰化によるパワープラント揺動の抑制が必要な部品である。図3に示すように、この性能を両立させる為、変位入力の振幅により特性が切り替わる自立切替式液封マウントが開

Data-Driven Set Based Design Method Using Machine Learning

<sup>†</sup> EIJI NAKATSUGAWA, KOHEI SHINTANI, MINORU TSUTSHIYAMA, TOYOTA MOTOR CORPORATION



(a) マウントの役割と構造



(b) マウント特性 (例. Initial values)

図3 自立切替式液封マウントの構造(a)と特性(b)

発された. しかし, 振幅依存の非線形特性を物理モデルで表現できず, モデルベース開発を進めるのに課題があった. そこで, NVH性能と乗心地性能を両立させた自立切替式液封マウントの目標割付を題材に, データ駆動型カスケード法を適用した.

#### 4.2 データ駆動型カスケード法の結果

図3(b)のばね剛性と減衰係数の周波数特性を時間軸に変換した時系列データを学習したROM(赤破線)と実機ベンチの実験結果(黒線)の荷重応答を図4に示す. RMSEも小さく, 広い周波数帯域まで非線形特性を再現し, ROMの精度を保証されていることが確認できた.

本検証で用いる設計変数と目的関数を表1, 2に示す. 車両性能として, NVH性能(エンジン起振時の座面振動)と乗心地性能(路面入力時の座面振動)を目的関数とする. また, 実現可能なマウント特性から制約条件を設定したばね減衰特性を切替えるパラメータを設計変数とし, 目的関数を最小化する. なお, LBは設計変数の下限, UBは設計変数の上限, FAは目的関数の成立範囲を示している. ROMを含む車両システムモデルを用いて, BALを200回反復試行し, 2つの目的関数の最適化結果を図5に示す. 成立解を複数得ることができ, 多性能両立するマウント特性をロバストに設計できることが確認できた.




図4 実験結果とROMによる予測結果の比較

表1 マウント特性の設計変数

	Design variables	LB	UB
$x_1$	Switching amplitude (Initial: 0.2)	0.12	0.5
$x_2$	Shifting frequency (Initial: 0.0)	-0.9	2.0
$x_3$	Scaling amplitude (Initial: 1.0)	0.8	1.2

表2 車両システム性能の目的関数

	Objective function	FA
$f_1$	Idle vibration performance (Minimize)	$\leq 0.3$
$f_2$	Ride comfort performance (Minimize)	$\leq 0.3$

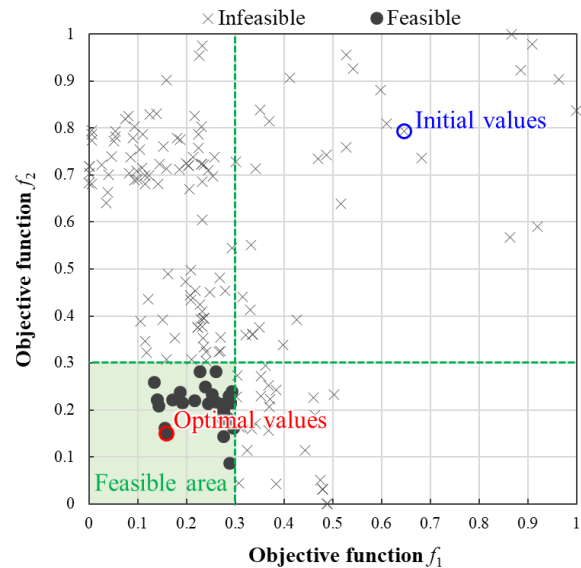


図5 Bayesian active learningの成立解と非成立解

#### 5. おわりに

本研究ではROMとBALを用いたデータ駆動型カスケード法を提案した. 開発初期段階において, モデル化が困難な機械要素を既存のデータセットよりROMにより表現することで, 精度を担保した状態でのシステムの性能予測を実現した. 更に, BALを用いた多目的最適化を実施することで, より多くの成立解を効率的に探索できた. 以上を組み合わせたデータ駆動型カスケード法を用いれば, V字開発の初期段階において, 多性能成立を目的とした機械要素へのロバストな目標割付に利用でき, 開発の手戻りの削減が期待できる.

#### 参考文献

[1] Funahashi, K., Nakamura, Y., Approximation of dynamical systems by continuous time recurrent neural networks, Neural networks 6.6, No.801-806, 1993  
 [2] Łaniewski-Wołk, L., Obayashi, S., and Jeong, S., "Development of expected improvement for multi-objective problem.", In Proceedings of 42nd Fluid Dynamics Conference/Aerospace Numerical Simulation Symposium, 2010