

深層学習をもちいた自動車構造部品の エネルギー吸収特性予測

Deep Learning Approach for Predicting Energy Absorption Characteristics of Automotive Structural Components

西原剛史¹⁾, 海氣絵里¹⁾, 鈴木香織¹⁾, 大嶺慶太¹⁾, 横井俊昭²⁾, 中村秋吾²⁾, 中本昌洋²⁾

Tsuyoshi Nishihara, Eri Kaiki, Kaori Suzuki, Keita Ohmine,
Toshiaki Yokoi, Shugo Nakamura and Masahiro Nakamoto

- 1) マツダ株式会社 (〒730-8670 広島県安芸郡府中町新地3-1, E-mail: Nishihara.tsu@mazda.co.jp)
2) 株式会社電通総研 (〒108-0075 東京都港区港南2-17-1, E-mail: yokoi.toshiaki@dentsusoken.com)

In automotive structural component development, there is a demand to design structures that ensure high energy absorption performance while remaining lightweight and being designed within a short timeframe. Finite Element Analysis (FEA) is commonly used as an effective means for structural analysis; however, it requires time for model construction and analysis. This study aims to address these challenges by constructing a surrogate model capable of instantaneously predicting the energy absorption characteristics of automotive structural components and enhancing its applicability even under varying load conditions. This approach holds promise for streamlining automotive component design.

Key Words : Deep Learning, Crash Safety, Surrogate Model

1. はじめに

自動車業界はCASE (Connected, Autonomous, Shared & Services, Electric) に代表される新たなニーズへの対応が迫られている。新技術へのリソース集中が進む中、自動車開発における効率向上が喫緊の課題となっている。

自動車開発の現場ではFEM (Finite Element Method) 解析が活用され、部品構造の最適化はコンピュータ上で実施されている。FEM解析による評価では実際に物を製作する必要がないため、試作品を実際につけて評価する開発と比較して大幅に開発効率が向上した。しかし、自動車構造部品には剛性、強度、エネルギー吸収量、生産性、重量、コストなど多岐にわたる目標が存在し、これらをすべて満たす構造を見つけ出すことは容易ではない。その結果、FEM解析による構造検討に多大な工数を費やしている。更なる効率化の手段として、近年急速に進展しているAIの活用が期待されている[1]。FEM解析を代替するAI技術、具体的にはサロゲートモデルを使用することで、数分から数時間かかるFEM解析による機械的特性の予測が瞬時に可能となる。これにより、部品構造の設計が大幅に効率化できる[2][3]。

著者らは、アルミニウム合金の押出成形材(以下、アルミ押出材)を題材として、エネルギー吸収特性を予測するサロゲートモデルを構築した[4]。Fig.1のように、アルミ押出材の断面画像データをAIに入力することで、円柱状の負荷子で断面幅方向に圧縮した際のエネルギー吸収特性を予測できる。FEMではモデルの構築時間も含めて、一つの断面構造のエネルギー吸収特性を予測するのに約30分を要

するが、サロゲートモデルを使用すれば約5ミリ秒で予測が可能となる。それにより、FEM解析では実現不可能であった大量の最適化探索が可能となる。実際に著者らは、遺伝的アルゴリズムを用いて断面の頂点座標や部位の板厚を最適化することで、目標となるエネルギー吸収特性を最軽量で実現する断面形状を提案することに成功した。

しかしながら、実際の自動車構造部品の開発では、様々な条件で衝撃した場合のエネルギー吸収特性を予測する必要があることに加え、最も効率的にエネルギー吸収ができる固定方法などを検討する必要がある。そこで本報では、断面画像からだけではなく、負荷条件も入力情報に加え、エネルギー吸収特性を高精度で予測できるように改良を行った。

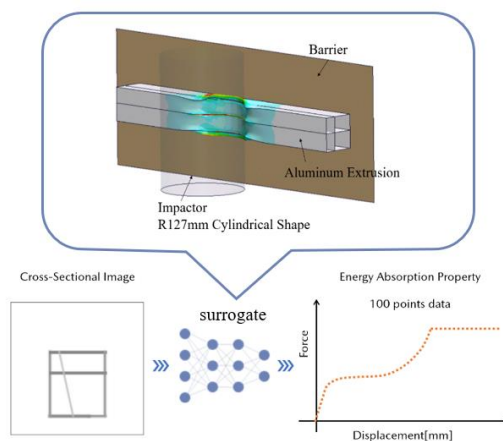


Fig. 1 Prediction of energy absorption property from cross-sectional images using the surrogate model

2. 学習データの準備

(1) Meshデータの準備

まず、断面の構造は、その断面を構成する辺の数、各辺の始点と終点の座標、および板厚を指定することで定義した。例えばFig. 2の(a)に示す図形であれば、辺の本数は6本であり、各辺の始点と終点の座標を定義することで各辺の位置を決定した。ここで、外形形状は長方形をベースにして、各辺に凹凸を加えることで、多様でかつ生産実現性の高い構造になるようにした。内側のリブの座標は、すでに設定した辺からランダムに2点を選んで設定した。その後、各辺の板厚は1.5mmから5.0mmの範囲からランダムに板厚を設定した。このように決めた断面構造から、解析に用いるMeshデータと断面画像をそれぞれ作成した。

Meshデータの作成は、まず各辺の両端に節点を配置する(Fig. 2-a)。次に、同一座標上の節点を結合し、辺が交差する点に新たな節点を追加する(Fig. 2-b)。最後に、各節点間に等間隔で新たな節点を追加し、節点の位置を決定した(Fig. 2-c)。これらの節点を長手方向に等間隔で配置し、それらをつなぎ合わせてMeshデータを作成した。




Fig. 2 Definition of cross section and mesh generation methods

(2) 断面画像の準備

断面画像は、Pythonライブラリmatplotlibを用いて作成した。具体的には、ホワイトキャンバス上に各辺を示す線を順番に描画し、断面の画像を生成した。ここで、断面の画像サイズは128×128ピクセルとし、学習時には空白部分の値が0、部材が存在するピクセルはその辺の板厚の1/10の値となるようにした。生成した断面画像の一例をFig. 3に示す。2値画像としなかった理由としては、設計上アルミ押出材の板厚は0.1mm単位で調整する必要があることに対し、128ピクセルでは2.0mm程度の解像度しか持たないためである。




Fig. 3 Cross-sectional gray scale image

このようにして作成した断面画像の一部をFig. 4に示す。生産の実現性を確保しつつ、多様な断面画像を作成した。




Fig. 4 Samples of cross-sectional images in the training data

(3) FEM解析の実施

生成したMeshデータに境界条件を設定して衝撃解析を実施した。衝撃解析は市販ソフトウェアLS-Dynaを用いた。境界条件はFig. 5に示す3モードとし、軸圧縮モードに関しては押出材長さを300mm, 400mm, 500mm, 600mmの4種類についてFEM解析を実施した。また、3点曲げモードに関しては、支持間距離を0mm, 300mm, 400mm, 500mm, 600mmの5種類とし、支持面と押出材表面は固着条件とした。ここで支持間距離0mmの場合は、円柱状負荷子で断面を圧縮するモードとなる。各圧縮モードにおいては、負荷子を時速50kmで150mmだけ強制変位させ、支持治具の反力を計測した。これにより、アルミ押出材のエネルギー吸収特性を取得した。

	Mode	Image
0	Double-Supported Beam (Tide Connection)	
1	Axial Crush	
2	Lateral crush	

Fig. 5 Boundary conditions for FEM analysis

(4) 結果データの処理

FEM解析からFig. 6の(a)で示したエネルギー吸収特性を得ることができる。横軸は負荷子の変位量、縦軸は固定治具の反力であり、グラフを積分した値がエネルギー吸収量となる。本報では、Fig. 5で示した複数の圧縮モードにおけるエネルギー吸収特性を1つのサロゲートモデルによって予測することを目指した。

FEM解析によって得られたエネルギー吸収特性であるFig. 6の緑線を確認すると、約100mmの変位で荷重値が急

激に増加している。これは、負荷子変位量を一律で150mmとして解析を実施したため、断面幅が小さい場合にアルミ押出材が完全につぶれ、非常に高い荷重が発生したためである。エネルギー吸収部材の設計においては部材が完全につぶれた後に発生する大荷重の値は重要でない。そこで、荷重が1000kN以上に達した時点で部材が完全につぶれたとみなし、それ以降の荷重値が1000kNとなるようにデータを加工した(Fig. 6 b)。その後、1000Hzのローパスフィルタを用いて高周波成分を除去した(Fig. 6 c)。そして、横軸0.5mmの間隔で取り出して得られた300点の荷重値データをサロゲートモデルの学習に使用する教師データとした。

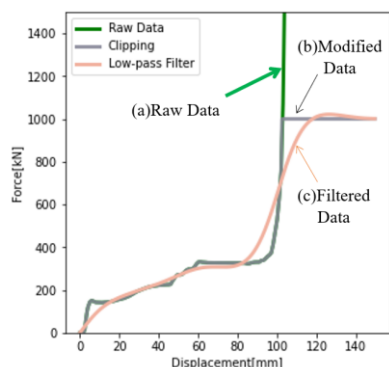


Fig. 6 Energy absorption data

3. 評価関数

(1) エネルギー吸収部材の設計における要素

ここでエネルギー吸収部材の設計における、エネルギー吸収特性の要件について述べる。Fig. 7は自動車のエネルギー吸収部材を模式的に表した図である。一般的に自動車のエネルギー吸収部材は、生産性などの観点から複数部品を組み合わせる制作される場合が多い。このように複数の部品からなる構造体によってエネルギー吸収をする場合、衝突先端側 (Fig. 7の場合は部品A) から圧縮されてエネルギー吸収する必要がある。これは、エネルギー吸収部材の変形モードをロバストにすることと、衝突時の部品交換コストを抑えるためである。

衝突先端側から順番にエネルギー吸収部材を圧縮させるためには、部品A, B, Cの塑性変形荷重は、

$$f_a < f_b < f_c \quad (1)$$

である必要がある。そのように設計することで、最初に部品Aが塑性変形荷重 f_a でエネルギー吸収し、つぶれ切った後に荷重値が急激に増加する。そして変形荷重値が f_b に達したところで、部品Bが塑性変形をはじめる。同様に変形荷重が f_c を超えると、部品Cが塑性変形してエネルギー吸収する。保護したいエリアを塑性変形させないためには、 f_c が保護エリアの強度値 f_p よりも小さい必要がある一方で、部品A, B, Cそれぞれで吸収するエネルギーの合計は、衝突

前に自動車が保有する運動エネルギーよりも大きい必要がある。このように前後部品の荷重バランスを確保しつつ、エネルギー吸収できるように具体構造を設計するため、様々な荷重レンジで、高精度で塑性変形荷重を予測できる必要がある。




Fig. 7 Schematic illustration of energy-absorbing parts for automobiles

(2) 評価関数の設定

(1)で述べた条件を満足するように部品構造を設計するためには、荷重値の小さい部品の特性についても高精度で予測できることが求められる。また、次の部品が塑性変形を始めるまでのエネルギー吸収量を正確に予測するためには、部品がつぶれ切って荷重が急激に増加する変位量と傾きを予測できる必要がある。一方で、その後一定荷重を超えた以降については予測できる必要がない。以上の条件を満足させるため、評価関数には平均絶対パーセント誤差(MAPE)を用いた。

$$MAPE = \frac{1}{n} \sum_{i=1}^n abs\left(\frac{\hat{y}_i - y_i}{\max(y_i, \epsilon)}\right) \quad (2)$$

ここで y_i は教師データの値、 \hat{y}_i はサロゲートモデルの予測値である。また、 ϵ は分母が0になることを防ぐための係数であり非常に小さい値を設定することが一般的であるが、本ツールを活用して設計するエネルギー吸収部材の荷重域を考慮して、正規化前の荷重値が100kNに相当する値とした。

評価関数の確認のために、荷重値を変えて作成した教師データ例と予測結果例をFig. 8に示す。左に示すグラフの縦軸の最大値は250kNであるのに対し、右のグラフは1000kNで、右側に示すデータの荷重値が高い。それぞれについてMSEとMAPEを算出すると、Fig. 8下部に示す通り、MSEは荷重値の高い右側が大きいが、MAPEでは左側に示すグラフの方が大きな値を示す。このように荷重値の絶対値によらず一致度合いを評価できるMAPEが、構造設計ツールの性能評価として適切であると考えられる。

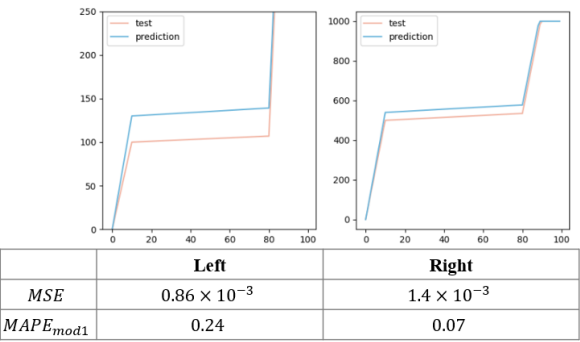


Fig. 8 Comparison of loss functions using generated data
Left) Low force data, Right) High force data

4. サロゲートモデルの学習

(1) ネットワーク構成

学習に用いたサロゲートモデルのネットワーク構成を Fig. 9に示す. (a)画像はWideResnet[5][6]を使用して1024次元のベクトルにエンコードされ, (b)解析条件である圧縮モードと治具間距離, 押出材長さはMLP(多層パーセプトロン)で1024次元のベクトルにエンコードされる. 次に(c)これらのベクトルはアダマール積にて結合される. ここで結合方法としては, 連結, 和算, アダマール積を比較し, 最も精度が高かったアダマール積を選択した. その後, MLPを用いてデコードされ, 300点のエネルギー吸収特性が予測される. MLPの層数とパーセプトロンの数は, ハイパーパラメータとして設定し, 最適な値をチューニングに

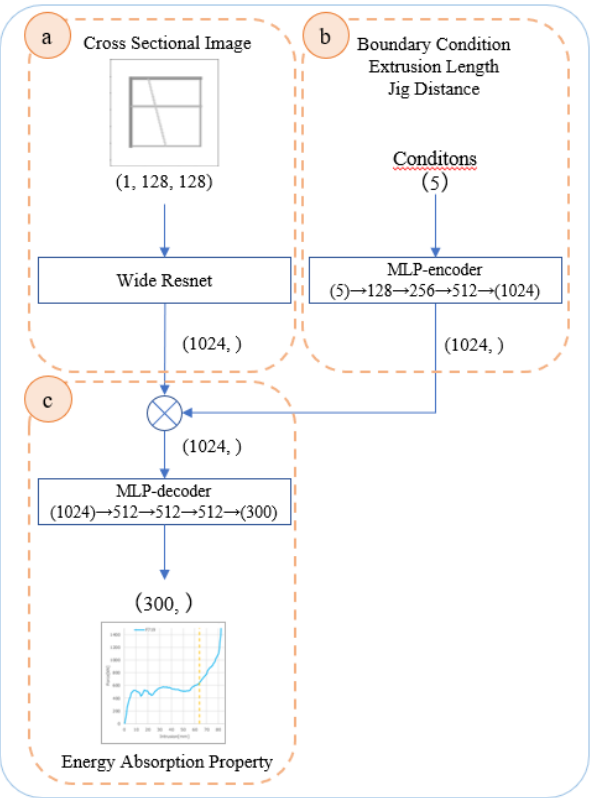


Fig. 9 Surrogate model network architecture

より決定した.

(2) ハイパーパラメータ

学習に用いたOptimizerや主要なハイパーパラメータを Table 1に示す.

Table 1 Hyperparameters

Parameter	Value
Optimizer	SGD
Learning Rate	0.1
Momentum	0.9
Weight Decay	1e-6
Dropout Rate	0.0
Batch Size	128
Scheduler	Cosine Annealing

(3) 学習結果

2章で述べた通り, 断面形状や境界条件を変更して 27,000件のFEM解析を実施した. それらの中から計算エラーで終了したものを除いた24,000件を学習データセットとして用いた. 学習データセットは21,000件と3,000件にランダムに分割し, それぞれを学習データと検証データとした. 学習には, PyTorchフレームワークを使用し, NVIDIA A100 GPUを1台利用した.

学習したサロゲートモデルを用いて検証用データを評

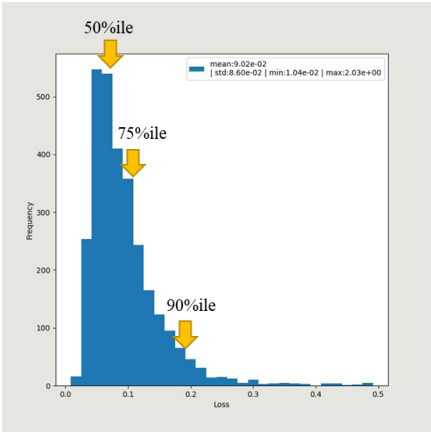


Fig. 10 Loss frequency distribution

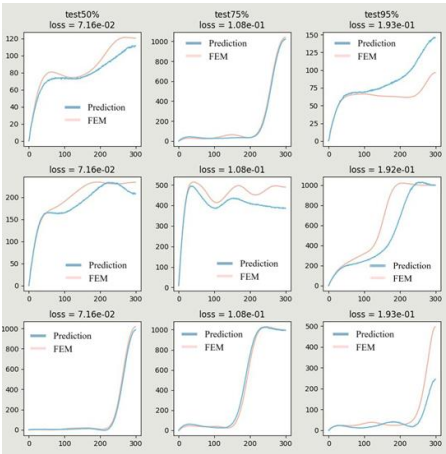


Fig. 11 Examples of FEM and prediction data

価した結果を以下に示す。Fig. 10は検証データ3,000件についてのMAPEの頻度分布である。分布を確認すると、ほとんどのデータは誤差20%以内で予測できていることが分かる。頻度分布図の中に示した各パーセンタイル順位に最も近い結果3件ずつをFig. 11に示す。左の列が50%ileのLoss値に最も近い結果3件であり、中央列が75%ile、右列が95%ileの結果である。いずれもFEMとサロゲートモデルで予測したエネルギー吸収特性である。左と中央列ではサロゲートモデルはFEMの結果を良く再現できており、95%ileの結果においても、波形パターンをおおよそ予測できていることが確認できた。これらの結果から、最終的な確認にはFEM解析や実機評価が必要となるものの、自動車部品構造の検討初期段階でのコンセプト検討に活用できるサロゲートモデルが構築できたと考えられる。

(4) 予測結果グラフの振動低減

FEM結果を高精度で予測可能なサロゲートモデルを構築できたものの、サロゲートモデルの予測結果の中にはFig. 12のようにグラフが振動している結果が見られた。FEM結果はローパスフィルタによる処理を実施しているため、学習データには存在しない振動である。




Fig. 12 Oscillations in predicted graph

そこで、エネルギー吸収特性の荷重値だけでなく、荷重の微分値についてもMAPEを算出し、重みづけして足し合わせた(3)式を損失関数に用いた。

$$loss = MAPE(y_i, \hat{y}_i) + w MAPE\left(\frac{dy_i}{dx}, \frac{d\hat{y}_i}{dx}\right) \quad (3)$$

ここで w は重み係数で、パラメータスタディによって $w = 1.0$ と決定した。その結果、サロゲートモデルの予測結果




Fig. 13 Without oscillations in predicted graph

はFEM結果と同様に、高周波振動の無い滑らかな結果となった(Fig. 13)。また、微分成分を加えない(2)式で求めたMAPE誤差も9.0%から8.7%と若干の改善が見られた。

5. サロゲートモデルの活用例

作成したサロゲートモデルを活用することによって、複数のモードで要求性能を満足する構造の検討に役立てることができる。例えば、2種類のアルミ押出部品を接合して作られるFig. 14に示す構造体を考える。ここで、青色で示した部品Aを梁、橙色で示した部品Bを柱と呼ぶこととする。簡略化した構造ではあるが、このような構造は自動車構造部品に多く存在し、自動車の衝突時に適切にエネルギー吸収し、内部にある部品等を保護することが求められ、高いエネルギー吸収量と軽量を両立する必要がある。




Fig. 14 Examples of component structural analysis utilizing surrogate model

実際の衝突事故の際には、自動車のどこが衝突するかが不明であるため、Fig. 15に示すように、例えば柱と柱の間に衝突した場合も、柱の真上に衝突した場合も、どちらの場合でも適切にエネルギー吸収できる必要がある。ここで適切にエネルギーを吸収するとは、所定のエネルギー吸収を実施した後、梁と保護エリアの間隙 D_1 、 D_2 のどちらもが正であることである。本例は2種類のアルミ押出材だけを接合した部品ではあるが、目標エネルギー吸収量を満足するようにそれぞれのアルミ押出材の断面形状を決定することは容易ではなく、FEM解析で最軽量構造を導出するには、多大な検討工数を要する。




Fig. 15 Examples of component structural analysis utilizing surrogate model

そこで、Fig. 15の検討事例を簡易化しFig. 16に示すバネモデルに置き換える．断面形状情報から、サロゲートモデルを用いて梁と柱のつぶれ特性を予測し、それぞれのつぶれ特性を1自由度のバネとみなして足し合わせることで、系全体としてのエネルギー吸収特性を求めることができる．接合部の強度を評価できていないなどの課題はあるが、この簡易モデルを用いることで、1時間で10,000ケース以上の断面パターンでのエネルギー吸収特性を求めることができる．




Fig. 16 Simplified model of two aluminum extrusion component

簡易化したモデルを用いて断面形状の最適化を実施した．必要吸収エネルギー量は10000[J]と定め、その他の寸法条件はFig. 14に示した通りとした．断面形状は、奥行き方向幅を100mmと固定し、梁の幅は4ケース(25, 50, 75, 100mm)について最適化した(梁の幅が大きくなると、梁と保護エリアの隙Dは小さくなる)．設計変数をTable2、およびFig. 17に示す．リブの板厚は1.5mmより小さい場合にリブを作成しないこととし、リブの本数を可変とした．

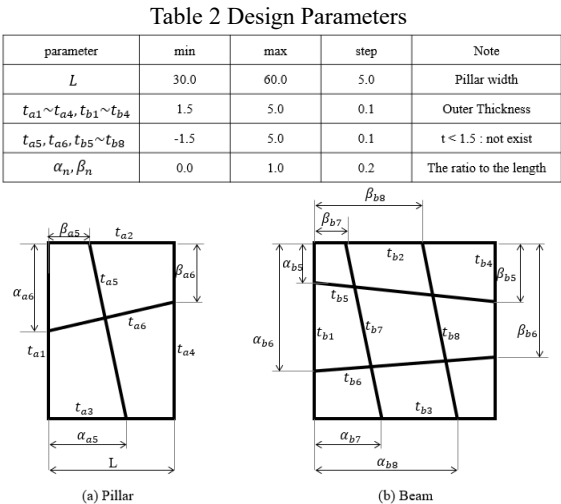


Fig. 17 Design Parameters

最適化はPythonライブラリのOptuna[7]のNSGA2を用い、1世代あたり100ケースで100世代までの合計10,000ケースを計算した．結果を確認すると、梁の断面幅に応じて異なる断面形状が最適解として得られている．梁の断面幅を75mm, 100mmとした場合には保護エリアとの残存隙が負の値、つまり保護エリアに梁が侵入し、成立解がないことを示している．また、梁の断面幅が25mmと50mmの場合

Part A Width	25	50	75	100
Total Weight	4.53	6.80	8.97	8.50
Remaining Distance	0mm	0mm	-2.5mm	-8mm
Cross-Section of Part A (Beam)				
Cross-Section of Part B (Pillar)				

Fig. 18 Optimization results

での総重量を比較すると、断面幅を25mmにした方が小さい．このことから、梁の断面幅を小さくし、保護エリアとの初期隙Dを広くすることで、梁をたわませてエネルギー吸収することが軽量化につながるという示唆が得られた．このように、サロゲートモデルを用いることで、様々な条件下での最軽量構造を簡易に求めることができ、構造コンセプトの検討を短期間で実施することが可能となる．

6. まとめ

「アルミ押出材のエネルギー吸収特性予測」を題材としてサロゲートモデルを構築した．

- (1) 断面画像および境界条件を入力とし、エネルギー吸収特性を高精度で予測することができた．
- (2) 損失関数にMAPEを用い、学習時に微分成分を追加することで、荷重レベルによらず高精度かつ振動を抑えて予測することができた．
- (3) 衝突現象を簡易化したバネモデルとサロゲートモデルを組み合わせることにより、コンポーネント部品の最軽量構造提案が可能であることを示した．

参考文献

[1] 飯干茂義ほか、エンジニアリングへの AI 適用状況について、人工知能学会全国大会論文集 第 37 回 (2023). 一般社団法人 人工知能学会, 2023

[2] 横井俊昭, SDF に基づいた深層学習による 3D 形状生成 AI とサロゲートモデルを用いたトポロジー最適化の試み, 日本機械学会 第 36 回計算力学講演会(2023)

[3] 鈴木香織ほか、深層学習を用いた B ピラー3 点曲げのエネルギー吸収特性予測, 学術講演会予稿集 (秋) No. 130-23, 自動車技術会, 2023

[4] 西原剛史ほか、深層学習を用いたアルミ押出部品のエネルギー吸収特性予測, 学術講演会予稿集 (春) No. 26-22, 自動車技術会, 2022

[5] He, Kaiming, et al. "Deep residual learning for image recognition." Proceedings of the IEEE conference on computer vision and pattern recognition. 2016.

[6] Zagoruyko, Sergey, et al. "Wide residual networks." arXiv preprint arXiv:1605.07146 (2016).

[7] Akiba, Takuya, et al. "Optuna: A next-generation hyperparameter optimization framework." Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining. 2019.