

オイラー型解法による多ケース弾塑性構造解析に基づく深層学習モデルの構築

名古屋大学 学生会員 ○戸井田 一聖
名古屋大学 正会員 西口 浩司
名古屋大学 正会員 干場 大也
名古屋大学 正会員 加藤 準治

1. はじめに

自動車産業界において、自動車の衝突性能評価は車体の安全性を評価するために必要な評価指標の一つであり、評価方法として数値シミュレーションによる衝突解析が求められている。特に上流設計工程では、デザイナーとメーカー、Computer-Aided Engineering(以下、CAE と呼ぶ) 技術者の三者が協調した設計を実現するため、意思決定可能な計算精度で衝突性能をリアルタイムに予測する手法が求められている。そこで本研究では、高速かつ自動に計算メッシュ作成が可能であるオイラー型構造解析手法を用いて多数の構造形状の弾塑性解析結果のデータセットを生成し、ディープニューラルネットワークを活用したサロゲートモデルを構築する。基礎検証として、構築したモデルを用いて、楕円の穴が空いた長方形の弾塑性固体の衝突解析の問題を対象に衝突時に発生するひずみエネルギーを予測する。さらに、精度検証も行うことで、本研究で構築したモデルの妥当性と有効性を検証する。

2. サロゲートモデルの構築手法

2.1 基礎方程式

本研究では解析に使用する固体を圧縮性弾塑性固体と仮定し、以下に示す質量保存則 (1) と運動方程式 (2) を利用する。この時 ρ_0 は初期自国の質量密度、 ρ は現時刻の質量密度、 J は体積変化率、 v はオイラー表記の速度ベクトル、 ω はコーシー応力テンソル、 b は既知の情報として与えられる物体力ベクトルを示す。

$$\rho J = \rho_0 \tag{1}$$

$$\rho \left\{ \frac{\partial v}{\partial t} + (v \cdot \nabla) v \right\} = \nabla \cdot \sigma + \rho b \tag{2}$$

固体の変形勾配テンソル F の評価方法としていかに示す変形勾配テンソルの時間発展式 $\dot{F}$ を用いる。この時、 L は速度勾配テンソルである。

$$\frac{DF}{Dt} = L \cdot F \tag{3}$$

2.2 教師データの作成方法

本研究では教師データの作成方法として、著者らの既往論文 [2],[3] に記載されているオイラー型構造解析手法を利用する。この手法では固定メッシュの生成方法として解析領域をキューブと呼ばれる領域に分割し、分割後の各キューブを同数のセルで等間隔に分割するビルディング・キューブ法を利用し、固体領域の表現方法としてマーカー粒子を利用する。空間固定のメッシュ上では、マーカー粒子から固定メッシュに補間した体積変化率 J の値を用いて質量保存則の計算を行い、さらにコロケート有限体積法を用いて運動方程式の計算を行う。

2.3 問題設計

本研究では基礎検証として、図 1 に示す楕円の穴が空いた長方形の弾塑性固体を初速度 $v_0 = 300\text{m/s}$ で $2\text{m} \times 2\text{m}$ の解析領域の下面に衝突させる 2 次元の衝突問題を取り扱う。そして図 1 に示す 6 角パラメータをサロゲートモデルの入力値として与え、 $t=0.8\text{ms}$ の時のひずみエネルギーを出力値として予測するサロゲートモデルを構築する。




図-1 問題設計の固体形状と解析領域，物性値

2.4 ニューラルネットワークの構築

本研究では基礎検証として 2 次元の画像データを入力変数として与えるため、画像認識の深層学習に適した畳み込みニューラルネットワーク (Convolutional Neural Network, CNN) を用いる。入力画像は図 2 に示す (128×128) のピクセルデータとなっており、畳み込み層の数や活性化関数

などのパラメータについては引用元の文献を参考にされたい。[1]



図-2 入力画像例

3. 結果と考察

図3には精度比較検証結果として、訓練データ数ごとの平均絶対誤差率 (Mean Absolute Percentage Error) の結果を示す。なお、図3に示す精度検証にはテストデータを利用している。この図からは訓練データ数が3800ケースの時にMAPEが約4%、RMSPEが約7%で予測できていることが分かる。一方で、どの訓練データ数においてもRMSPEの値がMAPEの値に比べて全体的に高くなっていることや訓練データの数に応じて顕著に予測精度が変化していること、また訓練データの数による誤差の変化がRMSPEのほうが大きいことが確認できる。

この原因として、RMSPEはMAPEに比べテストデータの結果とサロゲートモデルの予測結果に置ける誤差が大きい外れ値のデータの影響を受けやすいため、どの訓練データ数においても外れ値であるテストデータが一定数存在したと考えられる。




図-3 異なる訓練データ数での MAPE

そこで、本研究では外れ値が実際に存在していたかどうかを確認するため、訓練データ数ごとに横軸をオイラー型構造解析手法の出力値、縦軸をサロゲートモデルの予測値としたテストデータの散布図を作成する。図4にはこの散布図を3つの異なる訓練データ数に分けて示している。

図4よりどの訓練データ数においても外れ値が一定数存在していることが確認できる。さらに、横軸であるオイラー型構造解析手法の出力値が 1×10^7 [J] ~ 2×10^7 [J] の時のテストデータと比較して、 2×10^7 [J] 以上のテストデータは全体的に予測精度が低く、外れ値もその中心から発生していることも読み取れる。

このような結果が起こる原因として、訓練データのオイ

ラー型構造解析手法の出力値が 1×10^7 [J] と 2×10^7 [J] の間に偏っていることにより、それ以外の範囲のデータの学習が不十分であることが考えられる。




図-4 異なる訓練データ数とテストデータの散布図の比較

4. 結論

本研究ではオイラー型構造解析手法を活用して教師データを作成し、CNNを用いたサロゲートモデルを構築し、基礎検証として楕円の穴が空いた長方形の固体の衝突問題を対象にひずみエネルギーを予測した。またテストデータを用いて精度検証を行い、構築したモデルの妥当性と有効性について調査した。今後の課題として楕円の穴の位置が低い形状など外れ値の影響を受けやすい訓練データを増やすことや今回のピクセルデータを必要なメモリ量が少ない点群データとして3次元の教師データを作成しひずみエネルギーの予測を行うことが挙げられる。

参考文献

- [1] WYDER, Philippe M.; LIPSON, Hod. Visual design intuition: predicting dynamic properties of beams from raw cross-section images. *Journal of the Royal Society Interface*, 2021, 18.184: 20210571
- [2] J. Bonet and RD. Wood: *Nonlinear continuum mechanics for finite element analysis*, Cambridge university press, 1997.
- [3] 西口浩司, 嶋田宗将, 大高雅史, 岡澤重信, 坪倉誠: ラグランジュマーカー粒子を用いたオイラー型有限体積法による圧縮性固体解析, *土木学会論文集 A2(応用力学)*, 75(2), pp.I237-I248, 2019.
- [4] Y. LeCun, L. Bottou, Y. Bengio, P. Haffner: Gradient-based learning applied to document recognition, *Proceedings of the IEEE*, Vol. 86, No. 11, pp. 2278-2324, 1998