

データ駆動型手法によるステンレス鋼の動的応力-ひずみ関係の予測モデリング

研究代表者 熊本大学大学院先端科学研究部 准教授 黒田 雅利

共同研究者 熊本大学先進マグネシウム国際研究センター 教授 眞山 剛

1. 緒言

自動車の衝突解析ならびに原子炉機器の地震や事故発生時の構造解析などを行う上で、動的有限要素解析は必要不可欠である。一般に鉄鋼材料のひずみ速度依存性は、 $10^0/\text{s}$ 以上のひずみ速度域で大きくなることが報告されている。従って、動的有限要素解析では材料の構成則（応力-ひずみの関係）にひずみ速度依存性を考慮する必要があるが、 $10^0/\text{s} \sim 10^3/\text{s}$ 程度の中ひずみ速度域では以下の式で表される Johnson-Cook モデル¹⁾が広く一般に利用されている。

$$\sigma = [A + B\varepsilon_p^n] \left[1 + C \ln \left(\frac{\dot{\varepsilon}_p}{\dot{\varepsilon}_{p0}} \right) \right] [1 - (T^*)^m] \quad (1)$$

ここで、 σ は応力、 ε_p は塑性ひずみ、 $\dot{\varepsilon}_p$ は塑性ひずみ速度、 $\dot{\varepsilon}_{p0}$ は参照塑性ひずみ速度、 T^* は相同温度、 A , B , C , m , n は定数である。この定数は、実験で得られた各ひずみ速度や各温度における応力-ひずみ関係のデータをモデルに当てはめ回帰分析を行うことで求められる。しかしながら、実験で得られる応力-ひずみに関するデータが Johnson-Cook モデルに適合しない場合、動的有限要素解析で得られる結果と実際の現象との誤差は大きくなる。

近年、Kirchdoerfer と Ortiz により発表された“Data-driven computational mechanics”と題した論文²⁾を契機として、データ駆動型手法を利用して材料特性を予測する試みが各分野で活発化しつつある。この手法は元々、固体中の応力やひずみの分布を求めるのに必要となる力のつり合い条件、ひずみの適合条件、材料構成則のうち、材料構成則のみが材料の実験解析データを基にモデル化を要することを指摘した上で、この材料構成則のモデルの代わりに、材料の実験解析データを直接的に用いることを提案したものである。従って動的有限要素解析の精度を向上させるためには、できるだけ多くの各ひずみ速度や各温度における応力-ひずみ曲線の実験データを、直接利用することが最善であると考えられる。しかしながら、ひずみ速度や温度を変化させた応力-ひずみ曲線の実験データを蓄積するには、多大な時間と労力を要する。この問題を解決するには、限られた実験データからひずみ速度や温度が変化した場合の応力-ひずみ曲線を精度良く評価可能な、Johnson-Cook モデルに代わる新たな材料構成モデルが求められる。

実験計画法は、効率的な実験を計画して得られた実験データを適切に分析することを目的として、少ない実験回数で多くの情報が得ることが可能となる統計学的手法である。また機械学習を活用することで、蓄積されたデータを機械（コンピュータ）で分析してモデルを構築し、予測結果を出力することが可能となる。そこで本研究では、落錘式試験を利

用して、実験計画法と機械学習とを組み合わせたステンレス鋼の動的応力-ひずみ関係の予測モデルを構築し、そのモデルの妥当性を検証した。

2. 供試材および実験方法

材料は、表 1 に示す化学成分を有する市販の 316 系ステンレス鋼の丸棒材を用いた。その機械的性質を表 2 に示す。まずその丸棒材から、直径 15mm、高さ 15mm の円柱試験片を必要数切り出した。次に、試験片端面の平行度を 0.03mm 程度にするため、320 番、

表 1 Chemical compositions

Material	C	Si	Mn	P	S	Ni	Cr	Mo
SUS316	0.05	0.27	1.31	0.036	0.027	10.03	16.83	2.00

表 2 Mechanical properties

Material	0.2% proof stress (MPa)	Tensile strength (MPa)	Elongation (%)	Brinell hardness (HBW)
SUS316	636	743	35	197

800 番、1200 番の SiC 耐水研磨紙を用いて自動研磨装置（Ollie 製，OP-801-M）により研磨を行った。端面の平行度は、ダイヤルゲージ（Ollie 製，PTC-001）を用いて計測した。作製された円柱試験片に対して、落錘式衝撃試験機（アントワークス/米倉製作所製，IITM-22）を用いて、落錘が試験片に衝突した際の変位と荷重のデータをデジタル形式で出力することで、衝撃時の応力-ひずみ線図を算出した。図 1 に落錘式衝撃試験機の外観図と模式図を示す。荷重はロードセルにより測定し、変位は衝突後の加速度を積分して速度の変化を算出し、更に速度を積分することで算出した。加速度は、以下の式で表されるニュートンの運動方程式を用いて求めた。

$$F = ma \quad (2)$$

ここで、 m は重錘の重量、 F はロードセルにより測定された荷重である、また吸収エネルギーは、変位-荷重曲線の面積を求めることで算出した。ひずみ速度は、錘の落下高さと重量を変化させることで制御した。また温度は、恒温槽を通じて制御した。




図 1 Drop weight impact testing machine

3. 実験計画

様々なひずみ速度の応力-ひずみ曲線の実験データを蓄積するためには、適切な実験計画を立案することが不可欠である。本研究では、ひずみ速度に影響する落錘式衝撃試験の試験条件として、落下高さ、錘の重量、試験片温度の3因子を取り上げ、応答曲面モデル作成で一般的な実験計画である中心複合計画³⁾に基づいて試験条件を決定した。3因子に対する中心複合計画は、図2の模式図に示すように、8個の要因点(●印)、6個の軸点(★印)、6個の重複した中心点(○印)の合計20個から構成される^{4)~6)}。ここで中心点を重複させるのは、再現性を調べることでモデルの信頼性を評価するためである。3因子に対する中心複合計画では、中心点から要因点までの距離を1と仮定すると、中心点から軸点までの距離は1.68となる。従って中心点を原点に置いた場合の各因子のとり値は、-1.68, -1, 0, 1, 1.68の5段階となり、本研究に適用すると落下高さは200, 464, 850, 1236, 1500(mm)、錘の重量は4, 7, 12, 17, 20(kg)、試験片温度は-130, -69, 20, 109, 170(°C)となる。表3に実験の順番をランダムにしてまとめた実際の20個の実験計画を示す。




図 2 Central composite design for three factors^{4)~6)}

表 3 Testing conditions

Run Number	Falling Height (mm)	Falling Weight (kg)	Specimen Temperature (°C)
1	200	12	20
2	850	12	20
3	850	12	20
4	850	12	20
5	1500	12	20
6	850	12	20
7	850	4	20
8	850	12	20
9	850	20	20
10	850	12	20
11	464	17	109
12	1236	7	109
13	464	7	109
14	850	12	170
15	1236	17	109
16	850	12	-130
17	1236	7	-69
18	464	7	-69
19	464	17	-69
20	1236	17	-69

4. モデル作成

落錘式衝撃試験により得られるデジタル形式の生の実験データには、試験機の振動や電気信号などの外乱、衝撃時に生じる応力波といったノイズが含まれている。本研究では、ローパスフィルター（LPF）を用いてフィルタリングを行うことで、これらのノイズを除去した。フィルタリング条件は、図 3 に示すように低周波数領域におけるピークスペクトルの谷間（図中左側点線部分）とした。




図 3 Explanatory diagram of filtering condition

表 3 の試験条件で落錘式衝撃試験を実施することで蓄積された様々なひずみ速度の応力－ひずみ曲線に対して、機械学習による予測モデルを作成した．機械学習には MATLAB の Statistics and Machine Learning Toolbox⁷⁾を利用し、サポートベクターマシン（SVM）法により機械学習モデルを作成した．

5. モデル検証

本研究で作成した予測モデルの妥当性を検証するために、表 4 の 20℃（室温）のみの試験条件で追加実験を実施し、予測値と実測値との比較を行った．図 4～図 7 にそれぞれ、表 4 の①～④の試験条件での予測値と実測値を比較した結果を示す．同図より、②と③の試験条件では予測値と実測値が良く一致している一方、①と④の試験条件では予測値と実測値が一致していないことが分かる．

表 4 Additional testing conditions

Specimen Number	Falling Height (mm)	Falling Weight (kg)	Specimen Temperature (°C)
①	525	8	20
②	525	16	20
③	1175	8	20
④	1175	16	20




図 4 Comparison between prediction and observation for specimen
① (525mm, 8kg, 20℃)




図 5 Comparison between prediction and observation for specimen
② (525mm, 16kg, 20°C)




図 6 Comparison between prediction and observation for specimen
③ (1175mm, 8kg, 20°C)




図 7 Comparison between prediction and observation for specimen
④ (1175mm, 16kg, 20℃)

また、機械学習モデルの妥当性を定量的な観点から検証するために、RMSE, MAE の 2 種類の機械学習における評価指標を用いて、モデルの精度を評価した。表 4 の①～④の試験条件の機械学習モデルに対して、RMSE, MAE を評価した結果を表 5 に示す。ここで、RMSE は平均平方二乗誤差とも称される指標で、予測値と実測値の差を二乗した平均の平方根を表す。また、MAE は平均絶対誤差とも称される指標で、予測値と実測値の差の絶対値の平均を表す。両者の指標とも値が小さいほど精度が高いモデルと評価される。同表からも、②と③の試験条件では機械学習モデルの精度が高いことが確認できた。①と④の試験条件で予測値と実測値が一致しなかった原因については、今後の検討課題である。

表 5 Model evaluation metrics in machine learning

Specimen Number	RMSE	MAE
①	192.00	148.12
②	41.233	26.186
③	54.203	42.441
④	257.50	166.28

6. 結言および将来への展望

本研究では、実験計画法と機械学習とを組み合わせることで、ひずみ速度や温度を変化させた場合のステンレス鋼の動的応力-ひずみ関係の予測が可能となるようなデータ駆動型モデルを作成し、そのモデルの妥当性を検証した。その結果、試験条件によっては予測

モデルが実測値と良く一致することが分かった. 今後, 更なる実験データの蓄積等により, 機械学習モデルの適用可能な範囲についてさらに検討が必要と考えられる.

将来的に機械学習モデルによる動的応力-ひずみ関係の予測が可能になると, 材料構成モデルとして有限要素解析プログラムに組み込むことで, 次世代型の動的有限要素解析システムの開発が期待される. また機械学習モデルは機構論的なものではないため, 材料の微視的な変形機構との関係を明らかにするためには, 結晶塑性モデルとの連成も必要になってくるものと考えられる.

謝辞

本研究は, 公益財団法人 JFE21 世紀財団 2021 年度技術研究助成の支援を受けて実施されました. ここに記して謝意を表します.

参考文献

- (1) Johnson, G. R. and Cook, W. H., “A constitutive model and data for materials subjected to large strains, high strain rates and high temperatures”, Proceedings of the 7th International Symposium on Ballistics, (1983) 541-547.
- (2) Kirchdoerfer, T. and Ortiz, M., “Data-driven computational mechanics”, Computer Methods in Applied Mechanics and Engineering, 304 (2016) 81-101.
- (3) Montgomery, D. C., “Design and Analysis of Experiments -6th Edition-”, John Wiley & Sons, Inc., (2005).
- (4) Kuroda, M. and Marrow, T. J., “Preparation of fatigue specimens with controlled surface characteristics”, Journal of Materials Processing Technology, 203 (2008) 396-403.
- (5) 黒田雅利, 秋田貢一, 小林祐次, 辻俊哉, ”ショットピーニング加工を施したステンレス鋼の統計的実験計画法による表面特性予測”, 日本機械学会論文集, 84 (2018) DOI:10.1299/transjsme.18-00150.
- (6) 黒田雅利, 島崎智憲, 岩本達也, 秋田貢一, 小林祐次, 水野悠太, ”仕上げ加工制御によるオーステナイト系ステンレス鋼疲労試験片の表面特性予測技術”, 材料, 72 (2023) 154-160.
- (7) MathWorks, “MATLAB Statistics and Machine Learning Toolbox User's Guide (R2024b)” (2024).

成果報告 (学会発表)

- ・ 黒田雅利, 眞山剛, 松尾慎太郎, 呉雨澤, 中谷寛太, “データ駆動型手法によるオーステナイト系ステンレス鋼の動的応力-ひずみ関係の予測”, 日本機械学会 M&M2023 材料力学カンファレンス (2023 年 9 月 27 日発表)