

FEMを用いた鍛造品の材質分布予測

Estimation of Material Distribution of Forged Part by FEM

藤 田 崇 史^{*(1)} 越 智 達 朗^{*(2)} 樽 井 敏 三^{*(3)}
 Takashi FUJITA Tatsuro OCHI Toshimi TARUI

抄 録

階層型ニューラルネットワークを用いて材質予測モデルを作成した。更にこのモデルを鍛造解析FEMソフトウェアに組み込み、鍛造材質分布予測システムを構築した。開発したシステムの詳細と、このシステムをナックルの鍛造に適用した例について紹介した。

Abstract

Estimation model of material was made by using the hierarchical type neural network. This model was included into analyze metal forming processes on the computer by FEM, and estimation system of material distribution of forged part was built. This report presents the details of developed system and the example of the application of this system to forge of knuckle arm.

1. 緒 言

自動車用部品は燃費向上のために軽量化が求められおり鋼材も例外ではない。軽量化のためには、高強度化による部品の薄肉化が有効であり、自動車のフレーム、外板等ではすでに高強度化が行われている。現在、足周り、エンジン部品等に適用する高強度鍛造用鋼の研究が行われているが、高強度化に伴う設計変更では試作-材質試験-鋼材成分への反映を繰り返すため多大な労力と時間が必要となっている。ここで、鍛造品の材質分布が予測可能であれば、その部品の最弱部が判明し、設計への反映および鋼材開発速度の向上が望める。

材質予測^{1)~10)}に関しては、薄板、厚板の分野が先行しているが、その多くは物理モデルと言われる計算方法を採用している。即ち加熱温度、加熱時間、析出物の析出状態から加熱 γ 粒径を予測し、その予測した γ 粒径と圧延時のパススケジュールから再結晶ないしは未再結晶 γ 粒径、残留転位密度を予測し、更にこれらの予測値と冷却条件を用いて変態時の組織分率、粒径、形状等の組織因子を予測し、組織因子から材質を予測するという逐次予測型の計算を行っている。この計算方法は、冶金現象を逐次シミュレートする方法であるため、材質に影響を及ぼす因子を特定しやすいといった利点を持つ反面、逐次予測を行うがゆえに誤差がたまりやすく、更に組織因子から材質を予測する段階で、僅かの組織因子の違いが材質に大きな影響を及ぼすため、材質の予測精度には限界があるといった欠点が存在する。

一方、物理モデル以外の材質予測技術としてニューラルネットワークを用いた例が報告されている^{11)~14)}。ニューラルネットワークにはいくつか種類があるが、その中で最も一般的である階層型

ニューラルネットワークは、入力層、中間層、出力層の各々にユニットと呼ばれる非線形演算子を配置し、ユニット間の伝達を記述するリンク荷重を調整することによって、入力と出力を関連付けている。ニューラルネットワークの特徴は、非線形の現象や多数のパラメータが複雑に相関しあう現象に適用可能であることである。しかしながら、ニューラルネットワーク自体は、一種のブラックボックスであり、特に多層構造のニューラルネットワークではリンク荷重の物理的意味を考察することは極めて困難である。表1に材質予測を行う場合の物理モデルとニューラルネットワークモデルの比較を示す。

上記の特徴を持つニューラルネットを用いて硬度を予測し、さらに市販の鍛造解析FEMソフトウェア“DEFORM-3D”にユーザーサブルーチンとして組み込んで、鍛造品の硬度分布を推定した例について報告する。

2. 材質予測モデルに用いたニューラルネットワークの構造

図1にニューラルネットワークの構造を示す。中間層を2層配置し、入力層には加熱温度、加工温度、歪み、冷却速度等のプロセス条件と化学組成を、出力層には硬度を配置して、入力層にデータを入力すると、出力層に硬度が算出されるシステムになっている。入力値および出力値はそれぞれの最大値、最小値を元に規格化している。各ユニットの伝達関数にはシグモイド関数を用い、各ユニットの入力値は単純加算とした。

$$x = \sum w_i h_i \quad (1)$$

$$y = 1 / (1 + \exp(-x)) \quad (2)$$

* (1) 室蘭技術研究部 主任研究員
 北海道室蘭市仲町12 〒050-8550 TEL:(0143)47-2662

* (2) 室蘭技術研究部 部長

* (3) 鉄鋼研究所 鋼材第二研究部 主幹研究員

表1 物理モデルとニューラルネットワークモデルの比較
Comparison of physics model and neural networks model

	Neural networks model	Physics model
Outline	Quality of the material is estimated by using the complicated regression equation that can describe every function. Accuracy of estimation improves by accumulating the result of the simplified experiment.	It is based on the metallurgy phenomenon. Phase fraction and grain diameter are estimated from dislocation density, nucleation rate and growth rate. Quality of the material is estimated by these value.
Advantage	Even quality of the material of the complicated system that is not formulated in a physics model is predictable. It can be estimated even if bainite or martensite is mixed in ferrite and pearlite.	The factor which influences quality of the material is specified easy.
Disadvantage	Much experimental data is necessary. The meaning of the coefficient is weak in comparison with physics model.	An error is easy to bring about because it is the accumulation of the estimation. The transformation model of bainite and martensite isn't established.

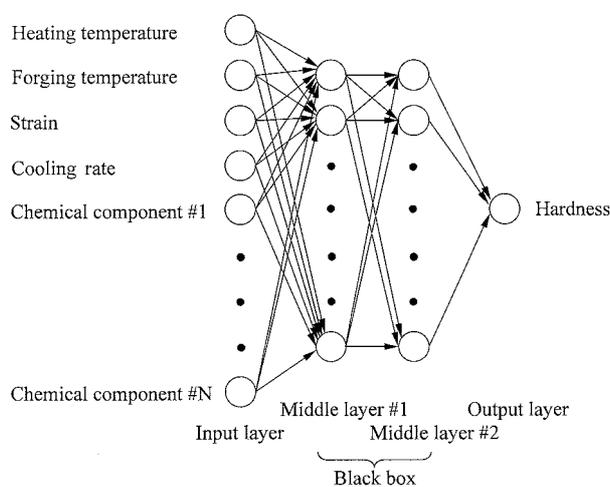


図1 ニューラルネットワークの構造
The structure of neural networks

ここで w_i はリンク荷重, h_i は前層ユニットの出力値, y はユニットの出力値を示す。

3. 学習方法および教師データ

ある入力が与えられたとき, 特定の出力が得られるように入出力データを関係付けること, 即ちニューラルネットワーク内のユニット間の結合係数(リンク荷重)を決定することを学習と呼び, 学習を行うために予め与えておく入出力の参照データを教師データと呼ぶ。学習は教師出力データとニューラルネットワークの計算出力データとの差の2乗和を最小にすることを目的としており, リンク荷重を変化させて最適値を探すものである。その手法としては, ニュートンの急降下法を学習規則に適用したバックプロパゲーション法(誤差逆伝播法), カルマンフィルタを学習規則に適用した拡張カルマンフィルタ法等があるが, 本報では拡張カルマンフィルタ法¹⁵⁾を用いて学習を行った。

教師データの採取は8mm径×12mm長の小型試験片を用いて行った。熱間鍛造を模擬した熱間加工試験を行い, 冷却後試験片の硬度を測定した。試験条件を変え1055セットのデータを用意した。採取したデータの範囲を表2に示す。

表2 硬度の予測用教師データ
Teaching data for estimation of hardness

	Min.	Max.	Ave.
C (mass%)	0.0017	0.6	0.313
Si (mass%)	0.009	1.63	0.940
Mn (mass%)	0.15	2	1.387
P (mass%)	0.0017	0.021	0.0152
S (mass%)	0.0029	0.1	0.0159
Ni (mass%)	0	0.503	0.034
Cr (mass%)	0	1	0.314
Cu (mass%)	0	0.29	0.035
Mo (mass%)	0	1.01	0.091
V (mass%)	0	0.51	0.0915
t-Nb (mass%)	0	0.031	0.0023
t-Al (mass%)	0	0.039	0.0270
t-Ti (mass%)	0	0.5	0.0237
Zr (mass%)	0	0.002	0.0000
Pb (mass%)	0	0.17	0.0027
Ca (mass%)	0	0.0024	0.0001
t-B (mass%)	0	0.0011	0.0001
t-N (mass%)	0.0014	0.016	0.0097
Heating temperature (°C)	680	1300	1111
Forging temperature (°C)	640	1300	897
Strain	0	2.42	1.52
Strain rate (1/s)	0	12.25	8.00
Cooling rate (°C/s)	0.5	10	0.64
Hardness (Hv)	59	603	288

前述のように, ニューラルネットワークは非常に柔軟性の高い構造をしており, 中間層のユニットを増やすことにより, いかなる関数にも適応可能である。実験値を教師データとする場合, その精度を見積もる必要があるが, 本研究では実験誤差5%と仮定して学習を行っている。学習の繰り返し計算時に実験値との最大誤差が5%以下になったときを学習終了とした。即ち学習の繰り返し計算中に教師データと学習データを比較するプログラムステップで, 最大の誤差を示す硬度データがHV400である場合は, 学習データがHV380~420の範囲に入ったときを学習終了, また最大の誤差を示す硬度データがHV100の場合は, 学習データがHV95~105の範囲に入ったときを学習終了とした。

4. 学習結果

図2に学習に用いた全教師データ(実測値)と全学習データ(計算値)の比較を示す。広い硬度範囲において、実測値と計算値は学習終了誤差5%の範囲内で一致している。

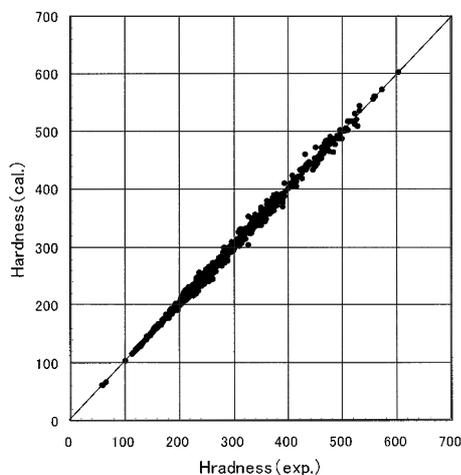


図2 実験値と計算値の比較

Comparison of the experimentation and the calculation

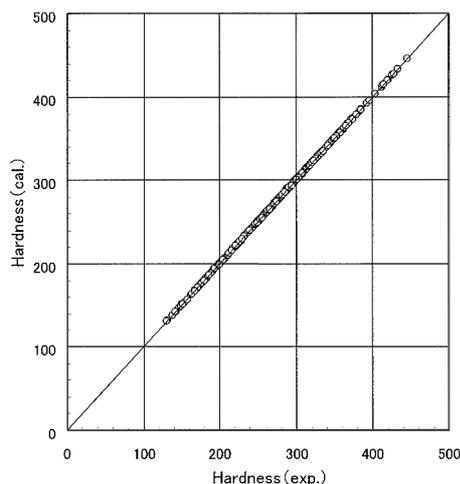


図3 実験値と計算値の比較

Comparison of the experimentation and the calculation

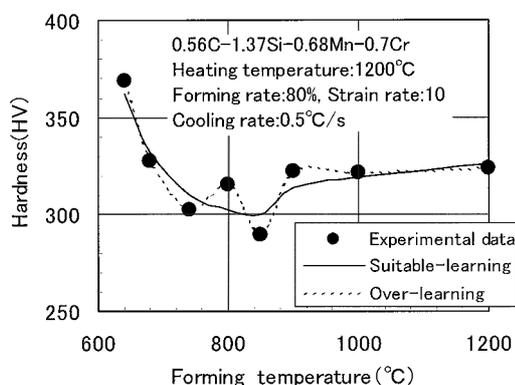


図4 適学習時、過学習時の予測値の比較

Comparison of the estimated value of suitable-leaning and over-leaning

教師データの硬度範囲をHV117~422、データ数959個に絞り、学習終了誤差を0.1%として過学習させた場合の学習結果を図3に示す。教師データと学習データは完全に一致しているが、図4に示すように測定ばらつきまでも再現してしまっており、実用には適さない。

本研究では、図2の学習により生成したリンク加重セットをFEM鍛造解析システムに組み込んだ。

5. 鍛造材質予測システムの構成

先に述べたように、鍛造解析自体は市販のFEMソフトウェア“DEFORM-3D”を用いて行った。このソフトウェアは、試験片の形状および型形状等の形状データ、炉温および加熱時間等の加熱条件、鍛造速度および型温度、接触熱伝達係数等の鍛造条件、各種冷媒との接触面定義や熱伝達係数等の冷却条件の設定により、鍛造一冷却をシミュレートすることができる。

FEMの計算は時間刻みで実行されるが、この時間刻み毎に鍛造素材に切られたFEMのメッシュの全要素について、温度、歪み等のデータが計算される。これら時間、温度、歪みのデータを元に材質予測に必要なデータを抽出した。材質予測では、成分、加熱温度、加工温度、歪み、歪み速度、冷却速度が必要であるが、加熱温度は加工前の歪みが0の時の最高温度、加工温度は歪みが増えられている間の時間-歪み平均温度(式(3))、歪みは累積歪み、歪み速度は平均歪み速度(式(4))、冷却速度は800°Cから500°C間の平均冷却速度とした。

鍛造ソフトウェアに成分の入力項は存在しないので、供試鋼の成分を記述した外部ファイル1を用意した。鍛造冷却プロセスを通して計算された各要素毎の加熱温度、加工温度、歪み、歪み速度、冷却速度と外部ファイル1の成分データを基に、FEMの計算が終了する冷却完了のタイミングで各要素毎の硬度を計算した。硬度の計算は、学習済みのリンク加重セットを記述した外部ファイル2を用いて行った。将来ニューラルネットワークの構造に変更があった場合にも対応可能なように、外部ファイル2にはニューラルネットワークの構造を示す、入力数、出力数、中間層数、各中間層のユニット数も記述してある。

図5に鍛造材質予測システムの構成を示す。

$$T = \left(\sum_{i=m}^n (t_i - t_{i-1}) (\epsilon_i - \epsilon_{i-1}) T_i \right) / (t_n - t_m) \epsilon_n \quad (3)$$

$$\dot{\epsilon} = \left(\sum_{i=m}^n (t_i - t_{i-1}) (\dot{\epsilon}_i - \dot{\epsilon}_{i-1}) \right) / (t_n - t_m) = \frac{\epsilon_n}{t_n - t_m} \quad (4)$$

ここでTは平均加工温度、 t_m は加工開始時間、 t_n は加工終了時間、 ϵ_m は初期歪み(=0)、 ϵ_n は累積歪みを示す。

6. 鍛造計算例

ここでは実際の計算例としてナックルの鍛造について紹介する。計算は下記の条件で行った。

素材の成分: 0.33C - 1.2Si - 1.6Mn - 0.1V

素材の形状: 68mm ϕ \times 210mm

加熱条件: 1200°C加熱、素材温度均一

鍛造条件: 鍛造速度300mm/s

冷却条件: 鍛造後空冷

図6に鍛造工程-冷却工程のワークの温度分布を示す。実際の鍛

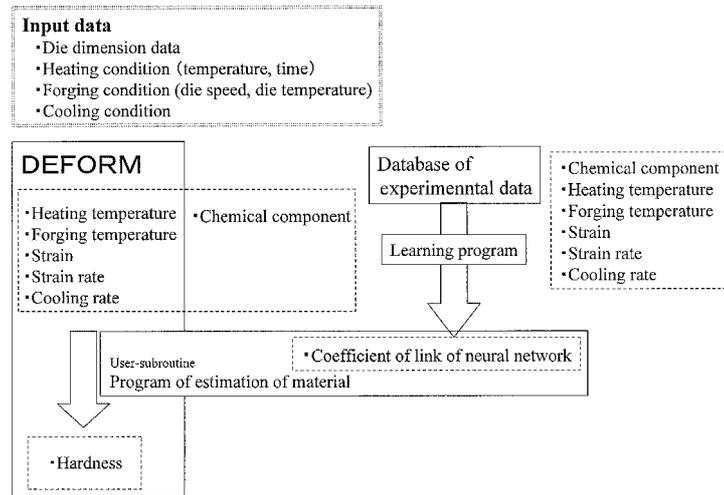


図5 鍛造材質予測システム
Estimation system of material distribution of forged part

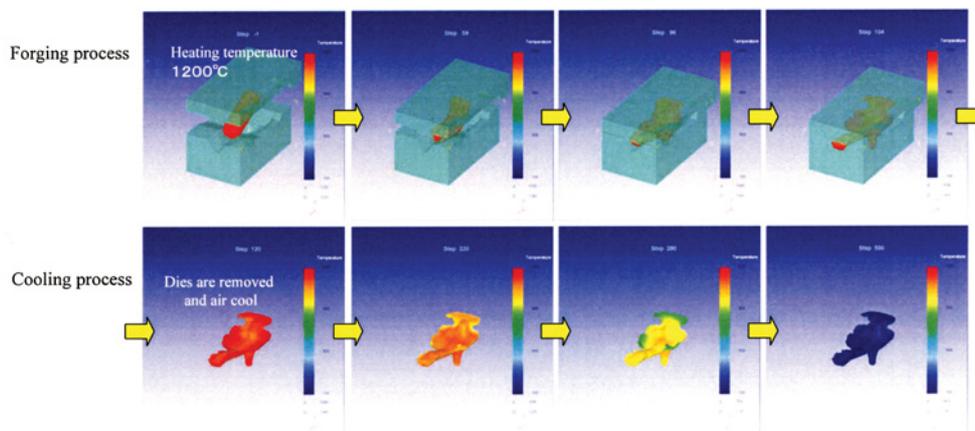


図6 鍛造—冷却工程の温度分布
Temperature distribution of forging and cooling process

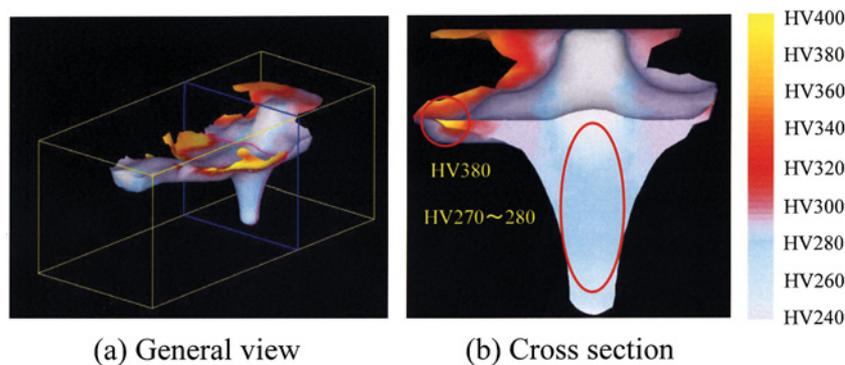


図7 鍛造品の硬度分布
Hardness distribution of forged part

造は多段で行われているが、バス間時間が比較的短時間であることから、1回鍛造でもシミュレート可能と判断して、1回鍛造で計算を行った。冷却完了後の硬度分布を図7に示す。ばりの部分の硬度が高く、軸の部分の硬度が低いことが計算されているが、実際の鍛造品の硬度と比較的良好一致を見ている。ばりの部分は、加工度が高く、また冷却速度も早いことからこの値となったと推測される。実際の鍛造品ではばり部分はベイナイト組織となっており、本予測

モデルがフェライト-パーライト組織だけでなく、ベイナイトも予測可能であることを示している。

7. 今後の課題

紹介した材質予測モデルは、通常成分の鋼を用い加熱—鍛造—空冷といった単純なプロセスの場合に比較的良好予測値を示す。しかしながら、成分が大ききはずれるような場合や、加熱—冷却を繰り返

返すような複雑なプロセスでは、予測値がはずれてしまう。紹介した材質予測モデルについて現在以下に示す問題点が明らかとなっている。

一つ目は、内挿の予測は比較的良好な精度で推測可能であるが、外挿の予測は精度が低下し、場合によっては想像し難い値を提示することである。この現象が、ニューラルネットワークを用いた材質予測の宿命であるのか否か、現在検討中である。対応として、教師データを規格化の際、通常0～1の範囲で規格化するところを、0.25～0.75の範囲で規格化することにより、外挿の予測精度を向上させようと試みているが、未だ十分な結果は得られていない。確実な解決策として、幅広い範囲の教師データを揃えることにより、全て内挿の予測になるよう調整することが考えられ、現在教師データを増やす試験を継続中である。これと並行して、例えばCを増量すれば硬度は上昇する、冷却速度を増せば硬度は上昇する等の基本的な材質法則を学習の段階で導入することも検討中である。

二つ目は、材質を決定づけるプロセス因子として、加熱温度、歪み、歪み速度、冷却速度を取り上げているが、これ以外の因子が考慮されていないことである。例えば、歪みは物理因子である転位密度の代替として導入しているが、多段鍛造では鍛造毎に転位の回復や再結晶が生じるため転位密度が減少し、累積歪みと転位密度の関係に大きな乖離が生じている可能性がある。また、冷却中に温度保持や昇温をするような場合にも、教師データでは考慮されていない析出等の新たな現象が発生するため、本予測モデルでは推測不可能である。これらは、プロセス因子中に温度の時間積分を標記する因子が無いことが原因であると考えられ、現在テンパー・パラメータ等の時間を含んだ温度因子の追加を検討中である。

三つ目は、教師データの精度の問題である。この学習は5%の精度で行っているが、教師データが全てこの精度内に入っている確証が無く、過学習になっている可能性が否定できない。過学習であるが故の一つ目の問題点として挙げた外挿の大幅精度低下を招いている可能性がある。これは、過去の試験データを掘り起こして学習

データとして転用したことが原因と考えられ、データの素性について今後精査が必要である。

8. 結 言

ニューラルネットワークは、冶金現象のようにいくつかの現象が複雑に絡み合う現象に適応可能であるとの仮定の元、ニューラルネットワークを用いた材質予測モデルを作成した。更にこのモデルを鍛造解析FEMソフトウェアに組み込み、鍛造材質予測システムを構築した。このシステムを用いたナックルの鍛造をシミュレートした結果、実測値と比較的良好一致を見た。一方、研究を進める過程でいくつかの問題点も明らかとなり、今後、これらの課題を解決していくことが重要である。

参考文献

- 1) 鉄鋼材料の材質予測・制御技術の現状と将来. 第131, 132回西山記念技術講座, 1989, 日本鉄鋼協会
- 2) 鉄鋼材料の組織と材質予測技術. 第180, 181回西山記念技術講座, 2004, 日本鉄鋼協会
- 3) Senuma, T. et al.: Proc. Int. Conf. on Physical Metallurgy of Thermomechanical Processing of Steels and Other Metals. Tokyo, ISIJ, 1988, p.423
- 4) 矢田浩, 瀬沼武秀: 日本金属学会会報. 29(6), 430 (1990)
- 5) 難波茂信: R&D神戸製鋼技報. 51(3), 36(2001)
- 6) 柳本潤: 鉄と鋼. 89(2), 221(2003)
- 7) Umamoto, M. et al.: ISIJ Int. 32(4), 306(1992)
- 8) 大内千秋: 塑性加工シンポジウム. 174, 1997, p.1
- 9) 吉田広明: 材料とプロセス. 15(2), 370(2002)
- 10) 竹林 ほか: 川崎製鉄技報. 33(3), 122(2001)
- 11) 市川和利: 溶接技術. 44(11), 136(1996)
- 12) 藤井英俊 ほか: 日本金属学会誌. 63(7), 905(1999)
- 13) Tenner, J. et al.: Ironmaking and Steelmaking. 28, 15(2001)
- 14) Myllykokki, P.: J. Mater. Process. Tech. 79, 9(1998)
- 15) 村瀬治比古, 小山修平, 石田良平: カルマン・ニューロコンピューティング. 初版. 東京, 森北出版(株), 1994, p.175