

# AI・ビッグデータ解析を活用した軽量ロボット部材の開発支援

## Development of AI / big data analysis method to support manufacturing of lightweight parts

いわき技術支援センター 機械・材料科 穴澤大樹  
技術開発部 工業材料科 工藤弘行 矢内誠人

本研究では、ロボット部材として利用が期待されるアルミ鋳造品の製造条件最適化や機械的特性評価の効率向上のために、製造条件や金属組織から機械的特性を予測するシステムの開発に取り組んだ。品質管理に用いている製造データ等を集積してデータベースを作成し、AI・ビッグデータ解析による強度予測を行ったところ、学習データを十分に集積できた範囲では良い精度で予測ができる一方で、学習データが不足した範囲では、予測精度が著しく低下することが分かった。

Key words: AI、ビッグデータ、ロボット、DAS 値、ニューラルネットワーク

### 1. 緒言

福島県では、ロボットテストフィールドの運用が始まったことから、ロボット部材を提供する企業群も増えることが望まれる。しかし、多くの中小企業では製造条件の最適化や新製品開発の検討に要する時間やコストの面から、新規参入のハードルは高い。そこで、AIやビッグデータ解析を活用することで、製造条件の最適化や製品の機械的特性評価の効率を向上し、時間やコストを低減できないか検討を行うこととした。

図1に本研究で目指すシステムの概要を示した。目指すのは、品質管理に用いる製造データや顕微鏡写真等の材料データから、製品の機械的特性を精度良く予測するシステムである。成分や温度等の製造データから製品の機械的特性を予測することができれば、最適な製造条件の検討の際に、試行錯誤に要する時間とコストを低減することができると考えられる。

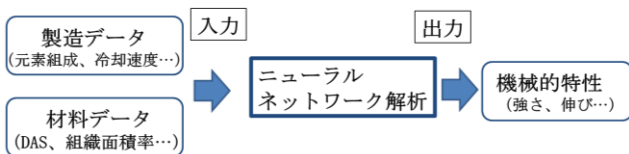


図1 システム概要

### 2. 実験

#### 2.1. 予測モデル構築プロセス

本研究では、AI・ビッグデータ解析としてニューラルネットワークによる予測を行う。ニューラルネットワークによって予測モデルを構築するプロセスを図2に示した。本研究では、このプロセスに沿って検討、試験、解析を進めた。

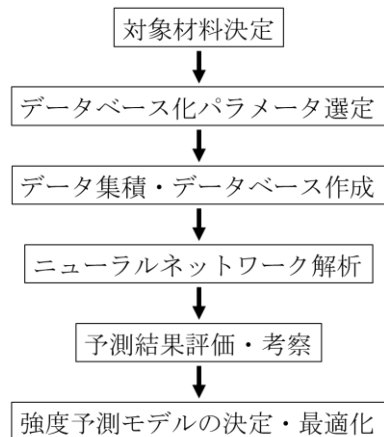


図2 予測モデル構築プロセス

#### 2.2. 対象材料・データベース化パラメータ選定

本研究でターゲットとする材料は、軽量部材として利用が期待されるアルミ鋳造品とした。その中でも一般的に使用されているAC4C材を主に検討を行った。図3に鋳造品の特性決定要因を図示した。AC4C材を始めとするアルミ鋳造品は、製造データにより材料組織が決定し、材料組織により機械的特性が決定すると考えられ、データベース化するパラメータはこの関係性を念頭に検討した。

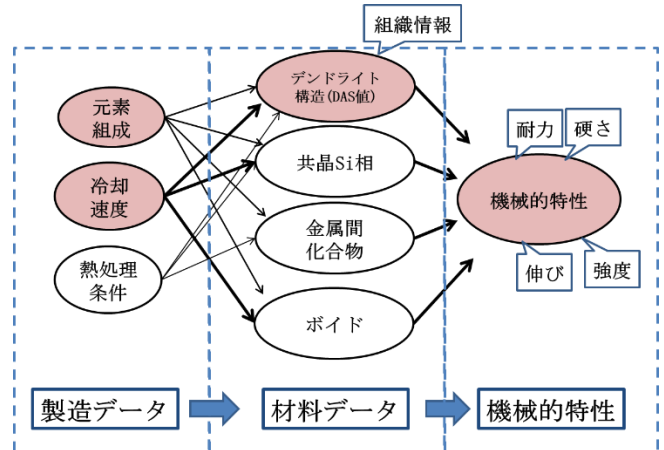


図3 鋳造品の特性決定要因の関係性

また、今回解析で取り扱うデータは全て数値データとする必要があるため、定量化が可能なものを優先して選択することにした。加えて、データを収集するコストと時間も加味して選択を行った。その結果、主に①合金成分、②冷却速度、③金属組織情報、④硬さ、⑤強度の5つをデータベース化することとした。データベース化する項目については、図3で赤塗りした。それぞれの詳細は次の通りである。

#### ① 合金成分（製造データ）

データベース作成に協力いただいた県内のアルミ鋳造メーカーとの協議の上、JISに規定がある中のSi、Mg、Cu、Zn、Ti、Cr、Niの含有量をデータベース化することとした。そのほか、改良材として添加するSrやNaについてもデータを収集した。

#### ② 冷却速度（製造データ）

材料組織を決定する重要な因子であり、機械的特性にも大きく影響を与えることが知られている。品質管理や方案設計の際に取得した温度データから算出してデータベース化することとした。この時、初晶点から共晶点までの冷却速度を算出した。

#### ③ 観察による金属組織情報（材料データ）

アルミ鋳造合金の組織情報の代表値として、DAS値（デンドライトアームスペーシング値）を使用することとした。DAS値は一般的にアルミ鋳造品の尺度として用いられているパラメータ<sup>1)</sup>であり、機械的特性と相関があることが知られている。図3に示したように製造データと機械的特性を結びつけるデータとして利用できる可能性が高いためデータベース化することとした。

#### ④ 硬さ（機械的特性データ）

一般的に品質管理でも用いられているが、今回は機械的特性として取り扱う。強度と相関があることが知られている。今回はロックウェル硬さとブリネル硬さをデータベース化することとした。

#### ⑤ 強度（機械的特性データ）

本研究の出力データ、つまり答えとなるデータである。通常は引張試験によって測定を行うが、今回は、当所の開発支援事業で開発した強度評価手法である切り欠き曲げ試験<sup>2)</sup>により強度を測定した。切り欠きを入れたサンプルの曲げ試験結果から引張強度の算出を行う方法で、図4に示したように試験片寸法が引張試験片に比べて小さいため、ビッグデータ化に適した試験法であると考えられる。また、試験領域が微小であるため、欠陥の存在確率から考えると、ボイドの影響を受けにくいと考えられる試験法である。




図4 切り欠き曲げ試験片寸法

### 2. 3. データベース構築

前項で挙げた各パラメータについて、企業の協力のもと、約600サンプルのデータを集積した。材料科学においては1つの学習データ取得にかかるコストが大きく、AI・ビッグデータ解析を行う上で最大の障壁が学習データの不足である。本研究では、多くのデータを収集するために、生産現場において日常的に取得している品質管理データを活用した。

### 2. 4. ニューラルネットワーク解析

#### 2. 4. 1 ニューラルネットワークについて

本研究では、ニューラルネットワーク解析ソフト「ニューラルワークス Predict」により予測を行った。ニューラルネットワーク構造の概略を図5に示した。最大の特徴は、入力と出力の間に隠れ層を導入し、出力が実験結果に近づくように隠れ層のパラメータを調整していくという構造である<sup>3)</sup>。ニューラルネットワークの一部のパラメータは人の手で調整が必要となるが、本ソフトでは、主に①データのノイズの程度、②データ変換の程度、③変数選択の程度、④ネットワーク探索の程度を選択すると、自動でパラメータの調整が行われる。

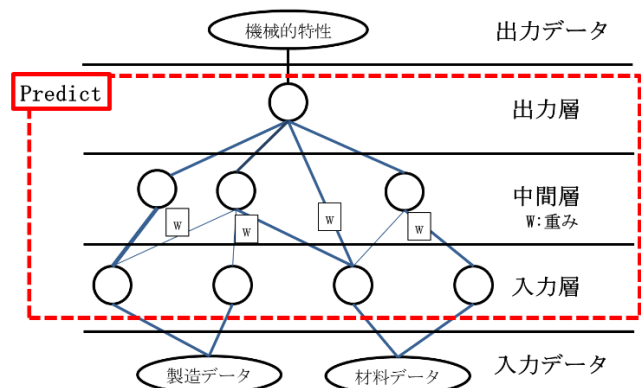


図5 ニューラルネットワーク構造概略

また、ノイズを含むデータを取り扱う際に、学習データ量が不足した場合等には、予測精度が低下する過学習という現象が生じるが、学習データが少ない場合でも、過学習を抑制する手法がいくつかある。本研究では、ソフトに搭載されているカスケードコリレーション法を過学習抑制手法として用いた。カ

スケードコリレーション法とは、入力と出力の相関が高まるように隠れ層を追加していく手法で、最小限の隠れ層数でネットワークを構築することができる。ネットワークが複雑化、巨大化しにくいいため、過学習を抑制することができる。

### 2. 4. 2 評価指標について

ニューラルネット解析結果の主な評価指標を表1に示した。いずれも実測値と予測値から算出される値で、本研究では、この数値から予測精度の良し悪しを判断する。Accuracyは10%と20%の2通りで算出し、Confidence Intervalは95%とした。

表1 評価指標

R	実測値と予測値の線形相関
Avg. Abs.	実測値と予測値の絶対誤差平均
RMS	実測値と予測値の2乗平均誤差平方根
Accuracy	実測値との誤差が20%以内の予測割合
Confidence Interval	予測の95%が収まるよう算出した実測値と予測値の差

### 2. 4. 3 入出力データ検討

入出力データは図6に示した3つのパターンで解析を行った。パターン1は製造条件から強度を予測するものである。データベース作成の手間とコストが小さいため、十分な予測精度が確保できることが確認できれば、製造現場での活用法の第一候補となる。パターン2は製造条件とDAS値から強度を予測するものである。強度と強い相関を持つDAS値を入力に加えることで、予測精度を高めることを狙っている。パターン3は、製造条件から一度DAS値を予測し、予測DAS値から強度を予測する方法である。製造条件によって金属組織が決定し、金属組織から機械的特性が決定されるという材料科学的な考え方に即している。

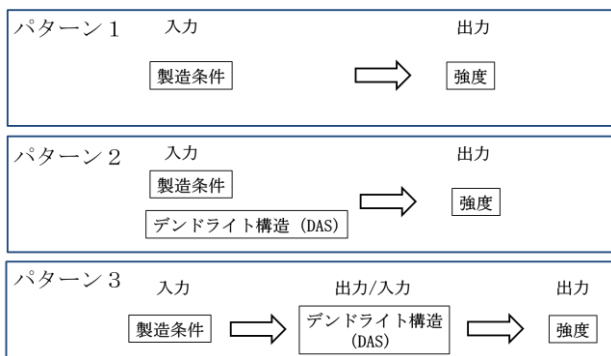


図6 入出力データ選択パターン

## 3. 結果及び考察

解析結果を表2に示す。いずれの評価指標においても、パターン2が良い結果を示した一方で、パターン1、パターン3は同程度の低い予測精度となった。パターン2が良い予測精度を示している理由は、強度と相関があることが知られているDAS値が予測結果に大きく寄与しているためと考えられる。パターン3がパターン1と同程度になっている理由としては、製造条件からDAS値を予測する段階で予測精度が低くなっているためと考えられる。

表2 解析結果

	パターン1	パターン2	パターン3
R	0.54	0.83	0.57
Avg. Abs. [MPa]	41	22	42
RMS [MPa]	58	35	58
Accuracy (20%)	0.67	0.90	0.68
Accuracy (10%)	0.42	0.63	0.38
Conf. Interval [MPa]	113	69	113

ここで、パターン1とパターン3でAccuracyが低くなっている原因の一つと考えられるのが、学習データベースの幅の狭さである。

図7に横軸を冷却速度、縦軸を強度として、実測値と予測値をプロットしたグラフを示した。プロットしたデータは、冷却速度が欠損となっているデータセットを除いたパターン1のデータである。グラフを見ると、冷却速度が0.05~1.0[K/s]付近は実測値と予測値が重なっている。一方、その範囲外では、予測値がばらつき、実測値と大きくずれていることが分かる。これは、冷却速度が0.05~1.0[K/s]の範囲の学習データは豊富にあるが、その範囲外の学習データが少ないためである。




図7 冷却速度-強度データ分布

表3に冷却速度が0.05~1.0[K/s]の範囲で解析を行った結果を示した。表2と比較するとパターン1、パターン3において大きく予測精度が向上している。この結果から、学習データ量を十分に確保できれば、製造条件からでも強度予測ができる可能性があると考えられる。ただし、予測が適用できる範囲については十分に注意する必要がある。図7には、冷却速度を横軸にとっているが、実際には、成分値等の他のデータにおいても同様のことが言える。図7の冷却速度0.1[K/s]付近では、実測値に差がある一方で、予測はそのデータに追従できていない。これは、Sr等の改良材添加の有無によって実測値に差が生じているが、改良材を添加したサンプルの学習データが少ないために予測ができていないと考えられる。

製品はある程度決められた条件内で製造するため、製造データを活用していく上では、データ範囲が狭くなってしまいうのは避けて通れない課題となる。そのため、学習用のデータベースを実験的、もしくはCAEを活用して整備する必要があると考えられる。

表3 解析結果(冷却速度0.05-1.0[K/s])

	パターン1	パターン2	パターン3
R	0.91	0.88	0.85
Avg. Abs. [MPa]	16	16	18
RMS [MPa]	21	24	26
Accuracy (20%)	0.97	0.94	0.90
Accuracy (10%)	0.71	0.78	0.68
Conf. Interval [MPa]	42	47	51

また、パターン3の精度を低下させている要因の一つと考えられるのは、材料データとして活用しているのがDAS値のみであるという点である。データベース化しなかった材料データには、DAS値の他に共晶Si相や金属間化合物、ボイドがある。これらは機械的特性に影響を与えることが知られている一方で定まった定量化手法がないか、定量化にかかるコストと時間が大きいために今回はデータベース化できなかった。これらのパラメータを定量化することができれば、強度予測精度を大きく向上させることができると考えられるため、今後、画像処理等による定量化手法の検討を行う必要がある。特にパターン3では、一度材料データに落とし込んでから強度を予測しているため、材料データのパラメータを増やすことで、大きな精度向上が期待できる。

また、上述した要因以外に、データの欠損やノイズも予測精度低下の大きな要因となるため、今後解析を行い、検討する必要がある。

## 4. 結言

本研究では、製造条件の最適化や特性評価の効率向上を目的として、AI・ビッグデータ解析により、製造データや材料データから強度予測を行ったところ、下記の成果と知見を得た。

- ① 品質管理のみに使用されていた製造データを活用することにより、約600サンプルのデータを集積することができた。
- ② 製造データのみでも十分なデータ量があれば実験値との誤差20%以内では97%、誤差10%以内では71%の精度で予測ができることが分かった。ただし、学習データが少ない範囲での予測精度は著しく低下するため、予測が適用できる範囲を常に注意する必要がある。
- ③ 品質管理に用いている製造データだけでは、学習範囲が狭くなってしまいうため、適宜、学習用データを実験的もしくはCAEを活用して補強する必要がある。
- ④ 製造データベースに観察による材料データを加えることで、予測精度が向上することを確認した。今回は材料データとしてDAS値のみを使用した。今回は材料データとしてDAS値のみを使用した。ボイドや共晶Siの情報を定量化して入力することでさらなる予測精度向上が期待できる。

以上の結果から、次年度は学習データの補強や材料データの定量化手法の検討を行い、更に精度よく強度予測できるよう取り組む。また、欠損データの影響やデータノイズについても解析を行い、解析条件についても検討する。

## 謝辞

本研究を遂行するにあたり、サンプルやデータの提供を始め、ご協力を賜りました株式会社ミウラ様に深謝申し上げます。

## 参考文献

- 1) 軽金属学会 鑄造・凝固部会. デンドライトアームスペーシング測定手順, 軽金属, Vol. 38(1), 1998, pp. 54-60.
- 2) 工藤弘行. 画像解析を活用したアルミ鑄造製品の实体強度評価, 平成28年度福島県ハイテクプラザ試験研究報告(2017) pp. 1-5.
- 3) 吉田隆. しなやかで強い鉄鋼材料. 初版, 株式会社エヌ・ティー・エス, 2016年, pp. 173-183. ISBN 978-4-86043-453-3