

Parameter Estimation of Air-Cooled Furnace for Metal Components using Random Forest

Ikuto Nakatsukasa*, Yasuaki Ito†, Koji Nakano†, and Victor Parque†

*School of Informatics and Data Science, Hiroshima University

Kagamiyama 1-4-1, Higashi-Hiroshima, 739-8527, JAPAN

†Graduate School of Advanced Science and Engineering, Hiroshima University

Kagamiyama 1-4-1, Higashi-Hiroshima, 739-8527, JAPAN

Abstract—The cooling conditions during heat treatment, particularly in the normalizing process, have a critical impact on the final material properties and overall treatment outcomes. These conditions, if not precisely controlled, can lead to significant variations in product quality. Traditionally, industry experts have relied on historical data, trends, and their own experience to estimate the optimal cooling parameters. However, this approach can be subjective and prone to inaccuracies, especially for new or complex components. In this study, we aimed to address this challenge by developing a predictive model using random forest algorithms to estimate the ideal cooling conditions. The model takes into account various factors such as the chemical composition, weight, material type, and geometric shape of the metal components being treated. The results demonstrated that our model achieved a high level of predictive accuracy, with a coefficient of determination (R^2) of approximately 0.94, indicating that the model is highly reliable for practical applications in this field.

Index Terms—parameter estimation, air-cooled furnace, machine learning, random forest

I. はじめに

熱処理は、金属材料に加熱および冷却を加えることで、形を変えることなく性質を向上させる加工技術である。ここでいう性質とは、硬さ、粘り、耐衝撃性、耐腐食性等である。処理結果に大きな影響を与える加熱温度と冷却速度によって、いくつかの処理に分けられる。得たい特徴や目的に合わせ、これらの処理を組み合わせることで処理を行う。

特に冷却速度は処理によって得られる性質に大きな影響を与えるので、緻密な調整を行うために、油で放冷する水冷、炉中で放冷する炉冷、空気中で放冷する空冷が使い分けられる。このうち、主に焼ならし処理で使用される空冷は、処理効率やタイムサイクル等の制約がある実際の現場において、冷却速度を早めることを目的にファンを利用することが多い。ただし、ファンによって与えられる風の強さによって冷却が急速すぎたり、逆に十分な冷却がなされなかったりした結果、目的の性質を持った金属が得られない場合があるため、その強さは金属部品ごとに慎重な設定が必要となる。熱処理における冷却速度は、部品の粒子および析出物のサイズに影響を与えたり [1]、層状構造における層の幅に影響を与えたりするとされている [2]。熱処理を行うある工場において、この冷却条件の設定が過去の類似部品の処理結果や、ベテラン職員の感覚に委ねられていることによる、属人化や、精度が問題となっていた。

本研究では、金属部品ごとに得られる情報のみから、焼ならし処理における適切な冷却速度を予測する機械学習モデ

ルの作成を行なった。熱処理における機械学習の活用として、鋼のマルテンサイト開始温度を予測した例 [3] や、真空浸炭における最適な処理条件を多層パーセプトロンを用いた機械学習モデルで予測した例 [4] がある。

II. ランダムフォレスト

ランダムフォレスト (Random Forest) [5] は、多数の決定木を用いたアンサンブル学習法の一つである。各決定木はデータのランダムなサブセットで学習し、予測時にはそれぞれの木の予測結果を集約して最終結果を決定する。これにより、個々の決定木のバラつきや過学習を抑え、より高い精度と安定性を実現する。決定木の各ノードでは、特徴量の値に基づいてデータを2つのサブセットへの分割を行う。分割は、予測値と目的変数の平均二乗誤差 (MSE) を最小化するものが選択される。各ノードにおける平均二乗誤差は以下の式で求められる。

$$MSE = \frac{1}{k} \sum_{i=1}^k (y_i - \hat{y}_i)^2$$

ここで、 k はサンプル数、 y_i は実際の観測値、 \hat{y}_i は予測値を表す。

ランダムフォレストは分類や回帰など、さまざまなタスクに対して効果的に利用可能である。今回は連続値を予測するため、回帰分析となる。多くの場合、回帰モデルの性能の評価には決定係数 R^2 が使用される。決定係数は0から1までの値を取り、1に近いほどモデルが実際のデータに当てはまり、性能が良いことを示している。具体的には、以下の式で求められる。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

このとき、 y_i は実際の観測値、 \hat{y}_i は予測値、 \bar{y} は全体の平均を表す。

後述の性能評価では、各説明変数がモデルに与える影響を図るために、寄与率を比較した。これは、ある特徴量が予測値と目的変数の平均二乗誤差を減少させた量に基づいて計算される。

III. モデルの作成

本節では、実際にランダムフォレストを用いた、焼ならし処理における冷却条件を予測するモデルを紹介する。はじめに、モデルに利用した各変数について説明する。なお金属部品のデータについて、金属部品メーカーから入手できるデー

タを除き、特別な作業をすることなく迅速に取得、使用できるデータのみを使用している。金属部品メーカーから入手できるデータとは、金属部品ごとに別途送付される検査証明書 (Certified Material Report) によるもので、化学成分量が記載されている。

- 化学成分量
 金属に含まれる元素の割合で、項目は炭素 (C)、ケイ素 (Si)、マンガン (Mn)、リン (P)、硫黄 (S)、ニッケル (Ni)、クロム (Cr)、モリブデン (Mo)、銅 (Cu) の9つがある。熱処理においてこれらの元素は、処理結果にそれぞれ異なる変化を与え、特に炭素、クロムはその影響が大きいことで知られている。
- 材質
 金属部品の原料となる金属で、用途ごとに使い分けられる。材質ごとに、上記化学成分の含有量基準値が定められている。今回のデータセットにおいては、7つの材質のデータが含まれている。ワンホットエンコーディングを行い、カテゴリカルデータとして使用した。
- 重量
 金属部品一個あたりの重量である。
- 形状
 部品の形状で、今回は見た目では判別できる4つの形状に分けた。
 - ギヤシャフト形 ギヤの付いた棒状の部品
 - ワッシャー形 円筒形部品のうち、厚さが高さより大きい部品
 - リング形 円筒形部品のうち、高さが厚さより大きい部品
 - ブロック形 穴がなく、立体に近い部品

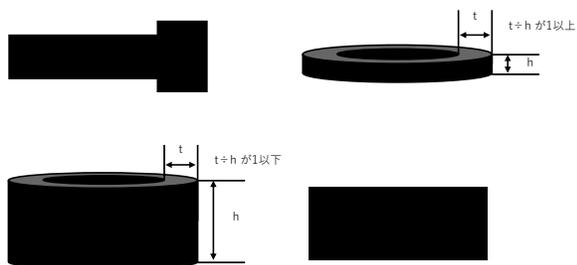


Fig. 1. 形状パターン (左上: ギヤシャフト形 右上: ワッシャー形 形左下: リング形 右下: ブロック形)

- 冷却条件
 冷却条件として、ファンに設定するパラメータを用いた。このパラメータはファンの回転数を調整するために用いられ、この値が大きくなるほど回転数も大きくなるものである。取りうる値は0から60までの整数の値である。

学習は、金属部品のデータ (化学成分割合、材質、重量、形状パターン) を説明変数に、実際に処理を行い、適切な値であると判断された冷却条件を目的変数とした、22項目からなるデータ992件のデータセットを用いた。このうち、75%を学習データに、残りをテストデータとした。

なお、ランダムフォレストの決定木は合計100本とし、最大深さは制限なしとした。また、それぞれのノードにおいて全ての特徴量を使用した。

IV. 性能評価

本節では、前節の学習モデルの性能評価を行うために、各説明変数を追加したモデルの性能を比較する。今回、性能評価には決定係数 R^2 を用いた。表 I に、モデルの決定係数 R^2 を示す。

TABLE I
 各説明変数の追加によるモデルの決定係数 R^2 の変化

説明変数	学習データ	テストデータ
成分量	0.90	0.77
成分量と材質	0.90	0.80
成分量と重量	0.98	0.92
成分量と形状	0.92	0.80
全て	0.98	0.94

次に、各説明変数がモデルに与えた影響について考察する。表3に各説明変数のモデルへの寄与率 (重要度) を示す。また、決定木の追加による平均二乗誤差の変化を図3に示す。

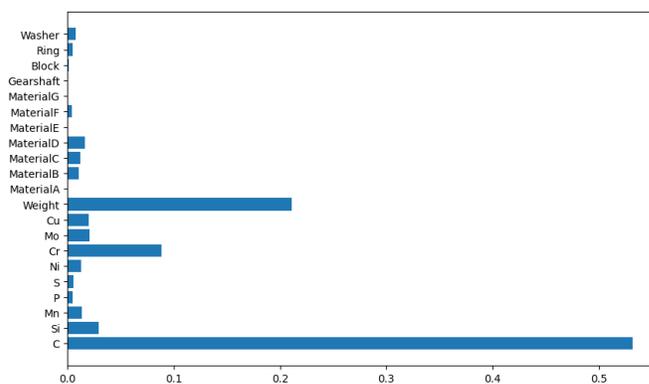


Fig. 2. 重要度

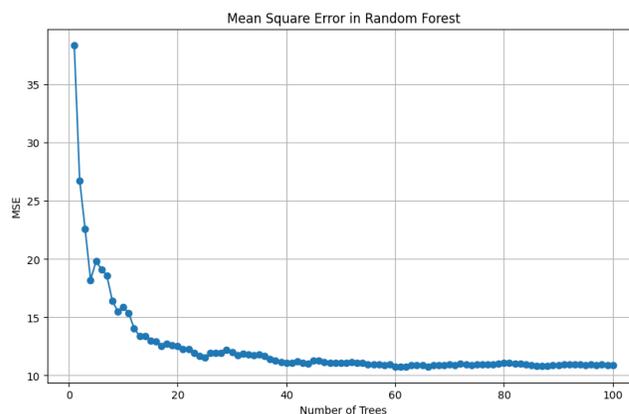


Fig. 3. 平均二乗誤差の変化

- 1) 化学成分量
 化学成分量のみを用いたモデルでもテストデータに対する決定係数 R^2 が0.77となった。特に炭素の寄与率0.5は超えており、重要な要素であると言える。熱処理

において炭素は、硬さ、強さといった、焼入れ性に強く影響を与える最も重要な元素とされている。また、炭素同様に熱処理において重要とされるクロムの値も比較的大きくなっている。一般的に熱処理において重要とされる元素が冷却条件の決定にも重要な要素となったと考えられる。

2) 材質

7つの材質について、モデルの作成において特に重要となる傾向は見られなかった。一部材質において、寄与率が他と比べて高くなっているが、これらの材質に性質的な共通点は特に見出せなかった。全体から見て冷却条件の決定に材質はあまり重要な要素ではないと考えられる。

3) 重量

部品一つあたりの重量は、炭素の次に重要な要素となった。熱処理と重量に関して、「質量効果 (Mass Effect)」が知られている。これは、質量が大きい金属部品ほど、中心への焼きが入りにくく、逆に小さいものほど焼きが入りやすいことを示したものである。冷却条件においても同様に、質量差が冷却のされやすさ (されにくさ) に影響を与えるため、重要な要素となったと考えられる。

4) 形状

形状による熱の通りやすさが影響を与えると考えられたが、いずれの形状も全体から見ると重要な要素とはいえなかった。一方で、ワッシャー形とリング形は比較的重要度が高くなっている。これは双方とも中心が空いた形状であり、他の形状より冷却されやすかったためであると考えられる。

以上より、冷却条件の決定を行うモデルの作成において、化学成分量 (特に炭素、クロム) と重量が重要な要素であると言える。これらの説明変数のみでも、決定係数 R^2 は 0.92 と、全ての説明変数を追加したモデルとほぼ同等の性能を示している。(表 I) 逆に、その他の要素がモデルの性能向上に与える影響は軽微であるため、実用性という点では化学成分量と質量のみを使用したモデルで十分であると考えられる。

また現場において、本モデルを利用した値を利用して、約 40 点ほど処理を行った結果、全ての場合で正しい処理条件となった。ここでの正しい処理条件とは、その値を使用して処理した結果、基準値内の焼入れ性を得られる場合の値をいう。今後もデータの蓄積を重ねることで、さらなる精度向上が見込まれる。

V. まとめ

本研究では、焼ならし処理における空冷冷却条件を化学成分量、重量といった金属部品ごとに得られる情報から予測する学習モデルを作成した。結果として、決定係数 R^2 が 0.94 の精度のモデルを実現することができた。現場での的中率も高く、十分実用性の高いモデルであることが示された。

REFERENCES

[1] H. H. Wai Cho, A. Takaichi, Y. Kajima, H. L. Htat, N. Kittikundecha, T. Hanawa, and N. Wakabayashi, "Effect of post-heat treatment cooling conditions on microstructures and fatigue properties of cobalt chromium molybdenum alloy fabricated through selective laser melting," *Metals*, vol. 11, no. 7, p. 1005, 2021.

[2] M. Yan, H. Zhang, F. Yang, Y. Gui, Z. Han, and H. Fu, "The effect of heat treatment on the microstructure and mechanical properties of powder metallurgy ti-48al alloy," *Metals*, vol. 14, no. 6, p. 661, 2024.
[3] M. Rahaman, W. Mu, J. Odqvist, and P. Hedström, "Machine learning to predict the martensite start temperature in steels," *Metallurgical and Materials Transactions A*, vol. 50, pp. 2081–2091, 2019.
[4] H. Jia, D. Ju, and J. Cao, "Machine learning based optimization method for vacuum carburizing process and its application," *Journal of Materials Informatics*, vol. 3, no. 2, p. 9, 2023.
[5] L. Breiman, "Random forests," *Machine learning*, vol. 45, pp. 5–32, 2001.