

黒鉛球状化処理工程自動化AIの開発

Developing an AI System for the Automation of Spheroidal Graphitization Treatment Processes

小川耕平*

Kohei Ogawa

澤田健二*

Kenji Sawada

上杉徳照**

Tokuteru Uesugi

ダクタイル鉄管の製造工場である加賀屋工場では、従業員の高齢化、原材料費の高騰、歩留まり向上の要請に対応するために工程の自動化が課題である。工場内の各工程の内、溶解鑄造工程では、性状の安定しない溶かした鉄である溶湯を扱うため、製造条件の設定には熟練作業者の長年の経験による部分が大きく、産業用ロボット導入などの単純な設備投資での自動化は困難であった。一方、昨今各分野でAI（人工知能）の活用拡大が進んでいるが製造工程への適用には課題があった。本稿では、黒鉛球状化処理工程の自動化 AI の開発により得られた知見を報告する。

At the Kagaya Plant, a production facility for ductile iron pipes, automation of manufacturing processes has become critical issue in response to workforce aging, rising raw material cost, and demands for improved yield. Among the various processes within the plant, the melting and casting stage presents particular challenges for automation as it involves handling of molten iron with unstable properties. The setting of manufacturing conditions in this stage has traditionally relied heavily on the long-standing experience of skilled operators, making simple automation through capital investment in industrial robots difficult. While the application of Artificial Intelligence (AI) has been expanding across various fields in recent years, its implementation in manufacturing processes still faces hurdles. This paper reports the insights gained from the development of an AI system for automating the graphite spheroidization treatment process.

1 はじめに

当社のダクタイル鉄管（図1）の製造拠点の1つである加賀屋工場では、労働人口減少による従業員の高齢化や労働力の減少への対応、原材料費の高騰、製造コストの削減、歩留まり向上の要請に対応するため各工程の自動化による合理化が喫緊の課題であり順次設備投資を進めてきた。

ダクタイル鉄管の製造工程の内、上工程と呼ばれる製品の概略形状を得るまでの工程は、図2に示す通り以下に大別される。キュボラと呼ばれる溶解炉を用いて、コークスを燃料とし、主原料である鉄源を溶融したものである溶湯を得る「溶解工程」、溶湯の成分を目標値に調整する「成分調整工程」、および、溶湯を鑄型に流し込んで冷却して製品の概略形状を形成する「鑄造工程」である。



図1 ダクタイル鉄管




図2 ダクタイル鉄管製造の上工程

* パイプシステム事業部 研究部

** 大阪公立大学大学院情報学研究科

これらの工程は、特に高温かつ流動性を有する溶湯を扱う点において、作業環境が過酷であり、安全確保の面からも自動化の必要性が高い。しかしながら、溶湯の性状は品質管理上重要である一方で、その安定化およびリアルタイムでの把握が技術的に困難であるため、これまで自動化の取り組みは限定的であった。

一方、近年 AI (Artificial Intelligence: 人工知能) 技術の活用がさまざまな分野で急速に進展している。加賀屋工場においても、工程の自動化に AI を適用することによる、従来からの課題解決を検討するため、AI モデルに求められる要件の整理を行った結果を図 3 に示す。

対象となる各工程は、継続的な改善活動により高効率かつ合理的な操業が実現されており、後工程はその精度を前提として設計されている。このため、AI モデルには熟練作業員による操業精度を上回る高精度が求められる。また、AI モデルに予期せぬ動作が生じた場合、工場全体の操業停止や安全性に関わる重大なリスクを伴う可能性がある。したがって、AI モデルはその動作が予見可能であり、ブラックボックス化されていないことが必須条件となる。このような背景から、導入する AI は高精度かつ不測の動作を排除できる、独自開発によるモデルが望ましいと考えられる。

一方で、製造工程の自動化・合理化によって得られるメリットは、ある程度事前に定量的に算出可能であり、これらのメリットが十分に創出される範囲内で AI モデルの開発コストを抑える必要がある。なお、これらの課題は国内の製造工場全般にも共通すると考えられ、参考

となる先行事例が少ない点も、本取り組みにおける課題の一つであった。

本報告では、成分調整工程の一部である、黒鉛球状化処理工程を対象として、工程の自動化を目的に独自の AI モデルを開発し、現場における長期実証試験を実施した結果について報告する。

2 AI適用対象工程

2.1 自動化 AI 導入対象工程の選定

加賀屋工場における初の自動化 AI 導入工程を選定するにあたり、設定した条件は以下の通りである。

- a) AI モデルの開発に十分な学習データが存在すること
すでにデータを収集している工程から選定するために設定した。
- b) 現状、人が数値の入力をしている工程であること
自動化に際して、産業用ロボットや専用自動機の開発が必要となることを避けるために設定した。
- c) 精度向上により、コストメリットが得られること
精度向上によって、原材料の使用料減少や製品歩留まり向上などの自動化によるもの以外のメリットが得られることが好ましいために設定した。

これらの条件に照らして検討した結果、黒鉛球状化処理工程（以下「球状化処理工程」）が最も適していると判断し、AI 適用対象工程として選定した。図 4 a. に成分調整工程全体写真、b. に球状化処理装置を示す。

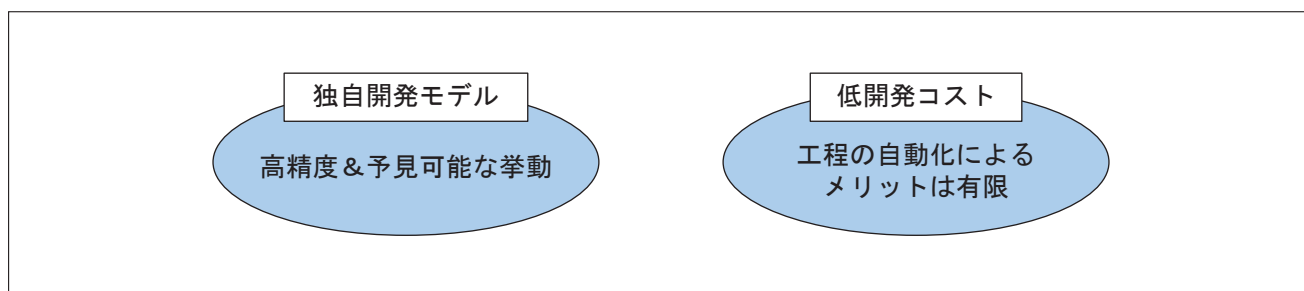


図3 AIモデルに求められる要件




図4 球状化処理工程写真

2.2 球状化処理の概要

球状化処理工程では、キュボラから排出された溶湯を数トン単位で取鍋（トリベ）と呼ばれる容器に取り分け、そこに Mg（マグネシウム）を添加する。図5 a. に示す Mg を添加しない場合の鑄造後の金属組織は、Fe（鉄）主体の地金を分断する形で脆弱な黒鉛が存在するが、図5 b. に示す Mg を添加した場合は鑄造後の金属組織中に現れる黒鉛を球状化させることで、Fe 主体の強固な層の連続性が確保される。これにより、機械的性質（強度、延性、靱性）が著しく向上する。

ただし、Mg は鑄鉄溶湯に安定的に溶解させることが難しい元素で、式 1 に示す Mg 歩留まりは加賀屋工場では 50 % 前後となり、安定した値を得ることが困難である。加賀屋工場では、チューブ状の鉄皮の内側に Fe、Si とともに Mg を充填したワイヤを溶湯に連続投入する「Mg コアードワイヤ法」を採用しており、設定した Mg 投入量に基づき、正確な量を溶湯に添加することが可能となっている¹⁾。


$$\text{Mg 歩留まり (\%)} = \frac{\text{処理溶湯量 (kg)} \times \text{処理後 Mg 値 (\%)}}{\text{投入 Mg 量 (kg)}} \quad \dots \text{式 1}$$

2.3 球状化処理の方法

球状化処理工程の流れを図 6 に示す。従来は、熟練作業者が Mg 添加前の溶湯成分やその他の諸条件を総合的に判断し、Mg 歩留まりを設定（以下「設定歩留まり」）していた。設定歩留まりと処理対象の溶湯量、目標 Mg 濃度に基づき、投入すべき Mg 量およびワイヤの投入長さが自動的に計算され、実際の Mg 添加が行われる。

その後溶湯の一部を採取し、成分分析を実施することで、実際に得られた Mg 歩留まり（以下「正解歩留まり」）を算出する。目標 Mg 濃度を下限値とする場合、設定歩留まりが正解歩留まりを上回ると、Mg の添加量が不足し、製品の機械的性質が不十分となる品質上の不良リスクが生じる。一方、設定歩留まりが正解歩留まりを大きく下回ると、Mg の過剰添加によるコスト増加が懸念される。

そのため、作業者は 1 日あたり 50 回以上行われる処理に対して、必要十分な Mg 投入量とするべく、設定歩留まりを慎重に決定していた。



a. Mg 添加無し（普通鑄鉄）

b. Mg 添加有り（ダクタイル鑄鉄）

図5 Mg添加有無による黒鉛組織




図6 球状化処理工程の流れ

3 実験方法

本実験では、開発した AI モデルにより予測された Mg 歩留まりに基づいて球状化処理を実施し、その結果得られたデータを用いてモデルの性能を評価した。以下に、使用した AI モデルの構成および評価手法について述べる。

3.1 AI モデル

筆者らは、球状化処理の自動化を実現するため、加賀屋工場における過去の実操業データ数万件を活用し、最適と考えられる AI モデルを構築した。モデル構築の詳細については既報²⁾にて報告済みであり、以下では現場に実装したモデルの特徴に焦点を当てて説明する。

3.1.1 学習データ

AI モデルの学習には、約 45,000 件の特定成分種に関する過去データを使用した。予測対象となる目的変数は Mg 歩留まり（式 1）であり、予測の入力データである説明変数には球状化処理前の溶湯成分を含む諸条件計 64 項目を用いた。

本モデルの特徴の一つは、説明変数に現在処理対象の杯（1 回分の球状化処理に相当する溶湯）だけでなく、直前の前回杯および前々回杯の諸条件と正解歩留まりを加えた点にある。これは、熟練技術者へのヒアリングにより、Mg 歩留まりの予測において過去の処理条件と正解歩留まりが重要な因子であることが判明したためであり、結果として予測精度の大幅な向上に寄与した²⁾。

3.1.2 学習アルゴリズム

学習アルゴリズムには、決定木のアンサンブル手法として広く用いられている「勾配ブースティング決定木 (Gradient Boosting Decision Tree)」を採用した。本手法は、予測精度と計算速度の両面において優れており、産業応用に適している³⁾。

3.1.3 損失関数

歩留まりのような数値を予測するモデルの損失関数には「二乗誤差 (Squared Error)」が用いられるのが一般的であるが、二乗誤差の場合は予測値と正解値との差

の分布は正規分布となる。Mg 歩留まり予測に適用する場合、Mg の下限値という品質上の重要な値を満足するためには、図 7 に示すとおり全体の設定歩留まりを低下させることになり、大幅なコスト上昇を招くことが予想された。

そのため、損失関数に「分位損失 (Quantile Loss)」を採用した。分位損失を用いた回帰手法は「分位点回帰」と呼ばれ⁴⁾、歩留まり管理への応用は筆者らの知る限り前例がない。ある杯における学習時の分位損失 QL は式 2 で表される。

$$QL = \tau \max(Y - \hat{Y}, 0) + (1 - \tau) \max(\hat{Y} - Y, 0) \quad \cdots \text{式 2}$$

ここで Y はある杯の正解歩留まり、 \hat{Y} はモデルにより算出される予測歩留まりである。

分位損失では、係数 τ (タウ) により、予測値が正解値より小さい場合と大きい場合の損失比率を調整することで、予測値と正解値との差の分布を左右非対称とすることができる。そのため、Mg 歩留まり予測に適用するにあたり、球状化処理後の Mg 値が不良リスクの境界値である下限値を下回る場合を重視し、 τ の値を変化させて品質とコストのバランスをとることを目的としてモデルの挙動を確認した。

3.2 評価方法

AI モデルの性能評価は、球状化処理後の溶湯における Mg 濃度が、設定された下限値を下回る割合である「下限外率」を指標として実施した。これは、製品の機械的性質に影響を及ぼす可能性がある不良リスクの発生頻度を示すものであり、モデルの予測精度を評価する上で重要な指標である。

加えて、テスト期間中に使用された Mg の総量を換算し、熟練作業による操業期間における Mg 使用量と比較することで、AI モデル導入によるコスト面での効果も評価した。これにより、実用性と経済性の両面から、モデルの妥当性を検証した。




図7 損失関数に二乗誤差を使った場合のイメージ

4 実験結果

実装実験は、開発した AI モデルによる Mg 歩留まりの予測値に基づいて球状化処理を実施し、その結果を評価する方法で行った。実験に使用した各モデルとその結果を表 1 に示す。なお、各テスト条件のデータ収集期間は 3 ヶ月～1 年であり、対象杯数は 900 杯から 4,000 杯程度を対象とした。

条件 I では、損失関数の係数 $\tau = 0.05$ に設定した結果、下限外れ率は熟練作業者の実績値を大きく下回り、品質面では良好な結果が得られた。一方で、Mg 使用量は人の実績値を上回り、コスト面では不利な結果となった。

条件 II および条件 III では、 $\tau = 0.08, 0.10$ と段階的に増加させた。これに伴い、下限外れ率は悪化したが、Mg 使用量は減少した。これらの結果は、損失関数における τ の設定が、品質とコストのトレードオフに大きく影響することを示している。

以上の結果を踏まえ許容できる加減外れ率でありながら最もコストメリットが得られた条件 III を採用して工程の自動操業を継続している。

5 考察

各実験条件による操業時の、設定歩留まりと正解歩留まりの差の発生分布を図 8 に示す。いずれの条件においてもその分布は正規分布ではなく、左右非対称かつ Mg の下限値を意識しそれを下回る杯を極力発生させないモデルの挙動が良く現れている。また、条件 I、条件 II、条件 III へと τ の値を増加させることで、その分布は Mg の下限値を表す 0 に近づく傾向が確認された。なお、こ

の現象は、損失関数の構造に起因するものであり、図 9 に示すように、設定歩留まりが正解歩留まりよりも小さい側（図 9 中横軸正の範囲）に外れた場合に与える損失（式 2）が、 τ の値が大きいほど増加するためである。すなわち、 τ の増加によりモデルは過剰な Mg 投入を抑制する方向に学習される。

条件 III（ $\tau = 0.10$ ）では、下限外れ率を人の実績と同等以下に維持しつつ、Mg 使用量を低減することができた。これは、品質とコストという本来相反する要素の両方において改善が見られたことを意味し、開発した AI モデルが人による操業に比べて高い予測精度を有していると評価できる。本研究で開発した AI モデルが熟練作業業者による操業を上回る精度を示した要因について、以下の点が挙げられる。

本モデルでは、従来現場で暗黙知として扱われていた「直前の杯や前々回の杯の処理結果を参考にする」という判断プロセスを、説明変数として明示的にモデルに組み込んだ点が大きいの。これは、熟練作業業者が経験的に行っていた判断をデータとして定式化したものであり、過去の処理結果を踏まえた予測が可能となったことで、モデルの精度向上に大きく寄与した。

損失関数として分位損失を採用したことにより、Mg の下限値という品質上の重要な閾値を意識したモデル設計が可能となった。一般的な損失関数である二乗誤差では捉えきれない、下限値を下回るリスクを重点的に抑制するような学習が行われたことで、品質確保において優れた性能を発揮したと考えられる。

さらに、従来の人による操業時は複数の作業業者が交代で操業を行っており、個々の判断やその時々状況によ

表 1 各学習モデルでの実験結果

条件名	学習モデル τ	下限外れ率	Mg 使用量比
条件 I	0.05	0.47 %	102.4 %
条件 II	0.08	2.34 %	99.6 %
条件 III	0.10	2.21 %	98.6 %
比較用過去操業実績	—	3.37 %	100 %




図 8 各条件の設定歩留まりと正解歩留まりの差の分布




図 9 学習時の損失の関係

り、品質とコストのバランスの取り方にばらつきが生じる。一方、AI モデルでは、損失関数の係数 τ を調整することで、品質とコストのバランスをあらかじめ定義された基準に基づいて一貫して制御することが可能である。このように、人的要因によるばらつきを排除し、安定した操業を実現できる点も、AI モデルの優位性の一つである。

6 まとめ

球状化処理工程における Mg 歩留まり予測を対象として AI モデルを開発し、現場実装による長期テストを通じて、熟練作業を上回る精度での自動化が可能であることを確認した。

また、損失関数として分位損失を採用し、係数 τ を調整することで、品質（下限外れ率）とコスト（Mg 使用量）のバランスの制御が可能となり、人による操業と比べて、高品質（低下限外れ率）かつ、低コストの操業を実現できた。

7 おわりに

本報告で述べた AI モデルの開発は、当社加賀屋工場における工程の合理化およびスマート工場化を目的とした AI 活用の第一歩として行ったものである。開発された Mg 歩留まり予測モデルおよび制御システムは、現時点でも継続的、安定的に稼働している。

今後は、さらなる生産活動の効率化および事業の発展を目指し、AI 技術の活用を一層推進していく方針である。

参考文献：

- 1) 鹿毛秀彦・山本展也・峯野慎也：
凝固・組織制御溶湯処理技術（接種・球状化处理）
鑄造工学第 89 巻（2017）、P589 ～ 600
- 2) 福島瑞貴・上杉徳照・辻川正人・堤 親平・小川耕平・
澤田健二・中本光二：
分位損失を用いた機械学習による黒鉛球状化处理
における Mg 歩留まりの予測、鑄造工学、第 94 巻
（2022）、P69 ～ 75
- 3) 有賀康顕・中山心太・西林 孝：
仕事ではじめる機械学習、オライリー・ジャパン（2018）
- 4) R. Koenker and G. Bassett:
REGRESSION QUANTILES, Econometrica 46
（1978）、P33

執筆者：

小川耕平

2008 年入社

ダクタイル鉄管の研究・開発に従事



澤田健二

1999 年入社

ダクタイル鉄管の研究・開発に従事



上杉徳照

大阪公立大学大学院 教授
博士（工学）

