

ベイジアンネットワークによる浸炭部品の異常粒発生予測

伊藤 靖朗* 加藤 豪* 前田 誠** 吉田 拓未***
 山下 翼*** 小島 秀平*** 井上 純哉****

抄 録

駆動系浸炭部品の強度低下を引き起こす異常粒成長は、複雑な現象が生じるため発生予測が困難である。本研究では、ベイジアンネットワークを構築し、冷間鍛造を模擬した試験片データを用いて学習させ、素材の材料特性および製造条件から異常粒成長の発生有無を予測できる手法を開発した。⁽¹⁾

1. 背景

近年、自動車業界においてはCASE (Connected, Autonomous, Shared & Services, Electric) への対応に伴い、開発期間を短縮しつつ高品質部品を安定的に供給することが強く求められている。同時に、熟練技術者の減少や製造現場におけるデジタルトランスフォーメーション (DX) の推進により、製造条件の最適化を効率的に行う手法の確立が喫緊の課題となっている。

このような産業的背景の中、人工知能 (AI) を活用した製造工程および条件の最適化技術は、開発期間の短縮と品質の安定化を同時に実現する有効なアプローチとして注目を集めている⁽²⁾。これらの技術的潮流を踏まえ、当社においてもAIを活用した製造プロセスの最適化技術の開発に着手した。

2. 選定テーマと課題

駆動系部品は主に動力伝達に関わるため、肌焼鋼に高温で浸炭焼入れ、焼戻し処理を行い、高い強度を確保する。その際の懸念事項の一つに、部品の強度低下を引き起こす鋼材の結晶の異常粒成長 (grain growth以下、G.G.) がある (Fig. 1, 2)。この現象は金属組織、浸炭温度、塑性歪みなどの要因が重なると生じる⁽³⁾。

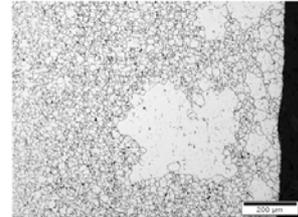


Fig. 1 Example of G.G.

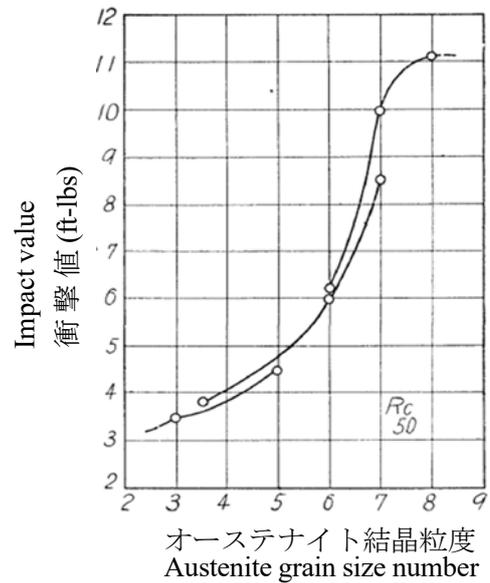


Fig. 2 Strength reduction due to G.G.⁽⁴⁾

そのため、単純なパラメータの回帰では予測が困難であるので、パラメータの組合せにより感度が変わることを考慮した予測を行う必要がある (Fig. 3).

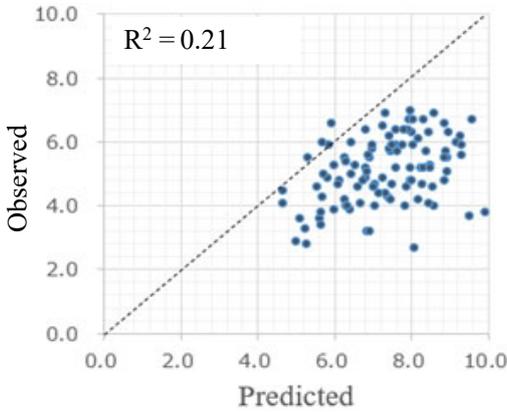


Fig. 3 Multiple regression analysis of post-carburization grain size number based on in-house evaluation test results

先行研究では一部のパラメータのみを変化させ、G.G.の発生に対する定量的な影響を報告している⁽⁶⁾。しかし、実際の部品製造ではそれ以外のパラメータも変化しているため、先行研究を参考にした部品製造条件の設定を行うことが難しい。

そこで、複数のパラメータを同時に変化させた多様な組合せでの発生予測を行うことを課題とした。

3. 課題解決方法

今回、複数のパラメータを同時に変化させた多様な組合せでの発生を予測させるためにAIを用いた。

AIを用いた材料特性の予測は、主に単一工程で特性が決定する高分子材料で多く用いられている⁽⁶⁾。一方、複数工程を経て複雑な組織変化が生じる鉄鋼材料を用いた部品の特性予測における適用事例は少ない⁽⁷⁾。

従来の単純なAIでの予測は、説明変数間の関係性を考慮せずに説明変数と目的変数との関係性を学習させる傾向がある。そのため、説明変数の組合せによる影響を十分に考慮できない。

そこで、因果関係の構造を直接表現し、既存の知見を反映することが可能な確率モデル (以下ベイジアンネットワーク) を用いることにした (Fig. 4)。

これにより、複雑かつ多様な組合せ検討が実施でき、G.G.の発生予測が可能になると考えた。

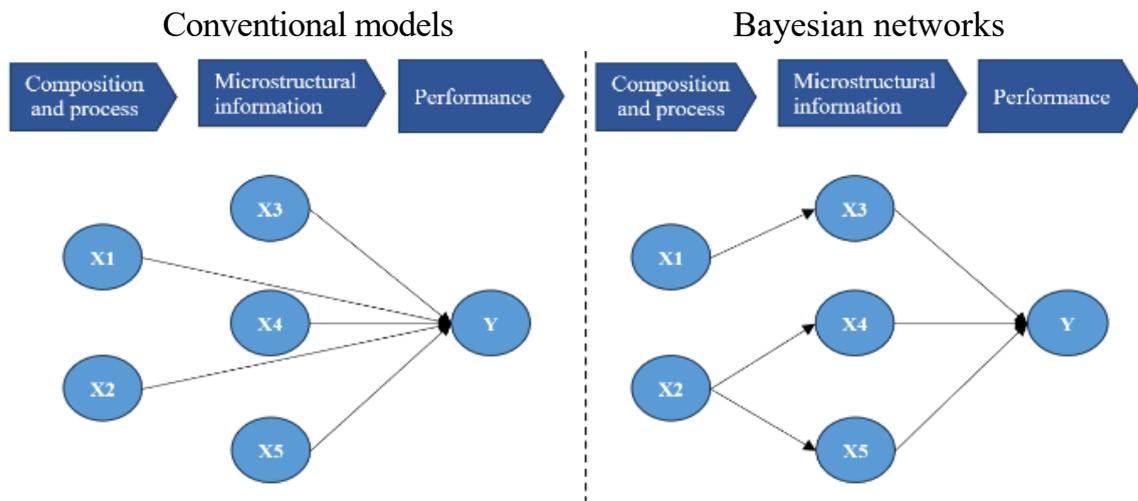


Fig. 4 Comparison between conventional prediction models and Bayesian networks

一般に、ベイジアンネットワークは連続値を扱う場合、正規分布など特定の分布を仮定する必要がある。そのため、実際のデータがその仮定から外れると予測精度が低下するリスクがある。一方、本研究では「G.G.の発生有無」という二値（離散的）分類問題として課題を定義したため、粒径サイズなどの連続値データを直接扱う必要はない。ここで浸炭後の最大粒の粒度番号をJIS G 0551に従い測定し、浸炭後の最大粒の粒度番号が5以下のものが存在した場合、G.G.発生と定義した。

このような離散値データでは条件付き確率を直接モデル化でき、分布仮定に伴う誤差のリスクがなく、計算も効率的である。

そのため、今回は分類によるベイジアンネットワークを用いることとした。

4. 解析手順

AIによる組合せ検討および予測可否評価は、事前にパラメータを変化させ、G.G.の発生を確認したテストピース（TP）の評価結果を用いた。このTP評価は、実部品の製造を模擬し、各パラメータは実部品の製造範囲を考慮し、設定した。

今回、実データを使用することで、AIが学習する際の補完がなく、G.G.の発生予測の精度が向上できると考えた。

また、本研究の結果を実際の部品製造に反映させるため、製造時に制御可能な素材および工程パラメータでG.G.の発生有無が予測できるモデルを作成した。

4.1 影響パラメータの選定

事前のTP評価で取得した、G.G.に影響するパラメータの中で、浸炭後の最大粒の粒度番号と相関が高いものを選定した。

また、選定したパラメータの中で、浸炭後の最大粒の粒度番号と共線性があるものは除いた（Table 1）。

Table 1 Parameters affecting G.G.

Orange hatching: selected parameters	
Material and forging parameters	Grain size number ave.
	Grain size number σ
	Width of pearlite bands σ
	Width of pearlite bands ave.- σ
	Spacing of pearlite bands σ
	Spacing of pearlite bands ave.- σ
	Shear strain
	Effective strain
Post-cold forming and carburization parameters	Grain size number in carbon segregation ave.
	Grain size number ave.
	Grain size number σ
	Aspect ratio
	Angle between pearlite and ferrite
	$L \times \theta$
	$\tau \times$ migration distance
	Hardness \times migration distance of carbon segregation
	Spacing of carbon segregation ave.
	Spacing of carbon segregation σ
	Spacing of carbon segregation ave.- σ
	Width of carbon segregation σ
Width of carbon segregation ave.- σ	
Carburizing temperature	
Post-carburization parameters	Grain size number ave.
	Grain size number σ
	Area fraction of grains with grain size number 5 or less
	Grain size number around the largest grain ave.
	Grain size number around the largest grain σ
	Distance from the largest grain to pearlite bands
	Spacing of pearlite bands ave.
Width of pearlite bands ave.	

4.2 有向非巡回グラフの作成

要ベイジアンネットワークを構築するためには、変数間の関係性を表すネットワークを作成する必要がある。

原理およびモデルから求めたパラメータ同士の関係に基づき、ベイジアンネットワークの基礎となるDAG (Directed Acyclic Graph; 有向非巡回グラフ) を作成することにした。また、G.G.は部品製造時の金属組織の変化により発生するので、組織の変化に応じ、段階的にモデルを作成した (Fig. 5)。

4.3 変数の離散化

分類によるベイジアンネットワークを扱う際、連続値を離散値に変換する必要がある。

そこで、設定したパラメータのデータを離散化し、分類した。具体的には冷間成形後および浸炭条件のパラメータの値により、浸炭後の最大粒の粒度番号が5以下か否かに大別できる値 (閾値) を求めた。

同様に、冷間成形後および浸炭条件のパラメータの値が大別できる素材および冷間成形条件のパラメータの閾値を求めた (Fig. 6)。

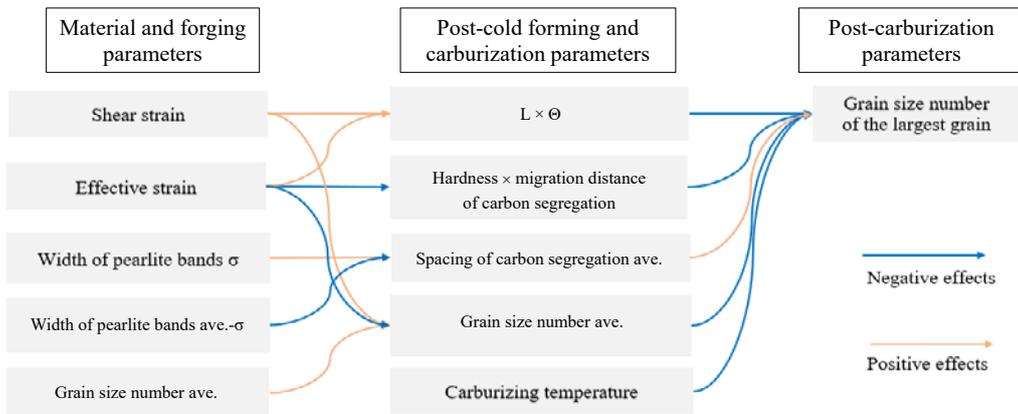


Fig. 5 The DAG in this study

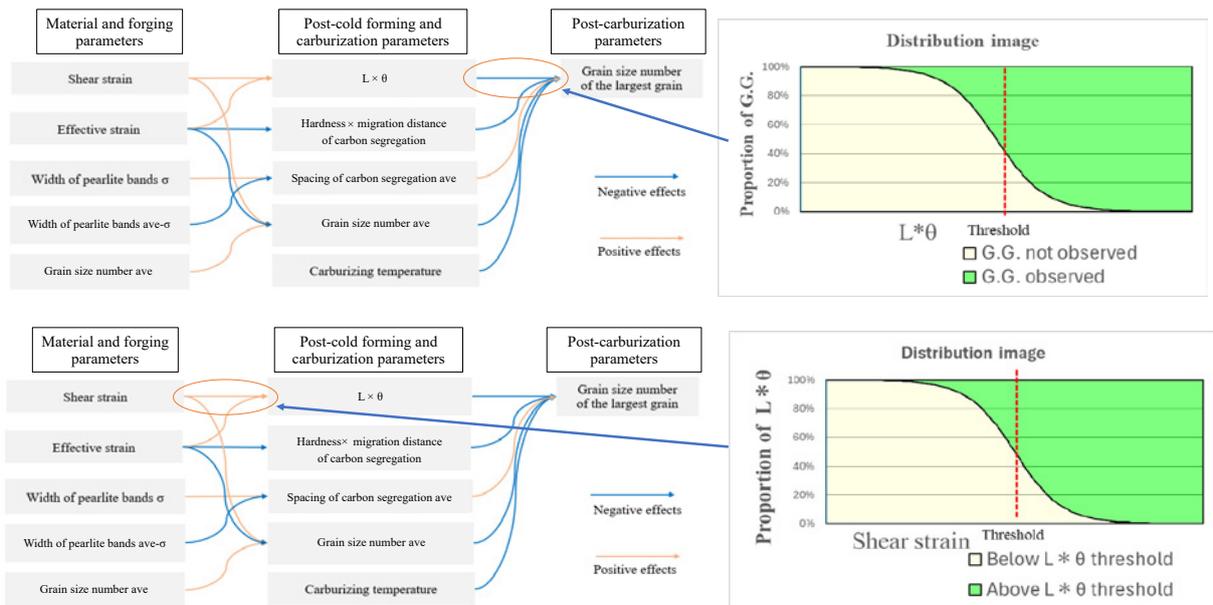


Fig. 6 Setting of threshold values

4.4 ベイジアンネットワークの構築

4.1-4.3の結果を統合し、ベイジアンネットワークを構築した。このベイジアンネットワークでは、ある説明変数(例えば、素材パラメータの一つ)を変更すると、その影響がネットワークを通じて伝播し、関連する他の説明変数(冷間成形後パラメータ)の確率分布を更新する。最終的に、この更新が目的変数(G.G.発生の有無)の予測確率に反映される。

この特性を利用することで、素材および工程パラメータを変化させ、G.G.が発生または発生しない条件の範囲を示すことが可能である。

5. 予測の検証方法と結果

分作成したモデルの精度を検証するため、全組合せ(108通り)を用いて一つ抜き交差検証を実施した(Table 2)。まず、一つの組合せを除いた残りの組合せのデータをAIに学習させた。その後、除いた組合せの素材および工程パラメータの実データを、学習させた予測モデルに入力し、G.G.の発生を予測させた。その結果が実データに沿っているかを確認した。

検証の結果、素材および工程パラメータを入力したG.G.の発生予測の結果は、79通りの組合せで実データと合致した(Table 3)。

Table 2 Leave-one-out cross-validation method

	Validation pattern							
	1	2	3	4	...	107	108	
Data No. 1	×	○	○	○	...	○	○	
No. 2	○	○	○	○	...	○	○	
No. 3	○	○	○	○	...	○	○	
No. 4	○	○	○	○	...	○	○	
~~~~~								
No. 107	○	○	○	○	...	○	○	
No. 108	○	○	○	○	...	○	○	

○ : Training data  
 × : Validation data

Table 3 Prediction results of G.G.

	Result
Occurrence	96% (22/23)
Non-occurrence	67% (57/85)
Total	73% (79/108)

6. 予測モデルの精度向上

本結果は、複雑な現象を予測するという点で、高精度の予測結果が得られたが、実際の部品製造でG.G.を発生させない条件の予測値としては、67%と期待に対して低い予測結果と考えた(Table 3)。そこで、部品製造で要求されるG.G.を発生させない条件の精度を高めるため、製造可能な条件の範囲内で判定基準を見直した。その結果、Fig. 7に示す通り、88%まで予測精度が向上した。これにより、G.G.を発生させない製造条件を高精度に予測することが可能となった。

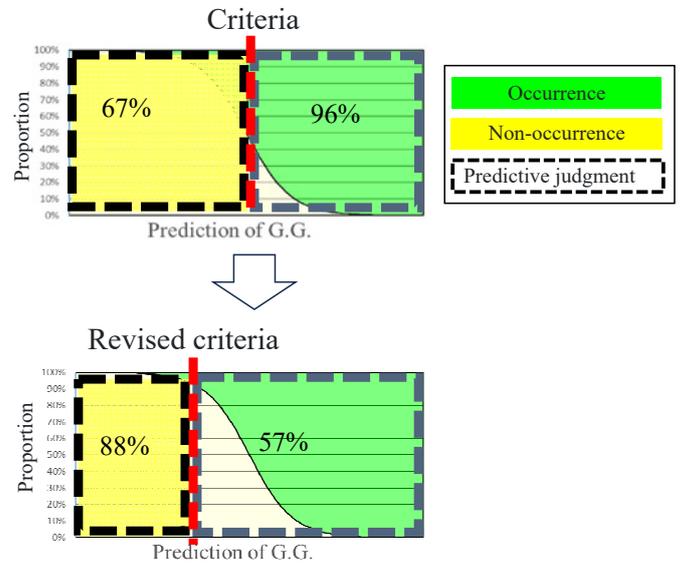


Fig. 7 Modified decision criteria improved non-G.G. precision to 88%

## 7. 結言

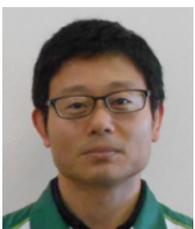
AIを活用した製造プロセスの最適化技術開発として、これまでの研究で予測が困難とされていた鋼材の結晶の異常粒成長(G.G.の発生予測)に取り組み、以下の知見を得た。

- ① パラメータ間の因果関係を考慮可能なベイジアンネットワークを構築することで、G.G.の発生を予測することができた。
- ② ①の結果、G.G.を発生させない製造条件を88%の高精度に予測することができた。

## 8. 参考文献

- (1) 水野 朗, 加藤 豪, 前田 誠, 吉田 拓未, 山下 翼, 小島 秀平, 井上 純哉: ベイジアンネットワークによる浸炭部品の異常粒発生予測, 2025年春季大会 学術講演会予稿集(春), (公社)自動車技術会, 2025年, pp. 1-4, 許諾を得て転載
- (2) 筒井 和政, 他: 鉄鋼分野における深層学習技術の活用現状, 鉄と鋼, Vol. 109, No. 6, pp. 464-489 (2023)
- (3) 吉村 英徳, 他: 肌焼鋼浸炭時の旧オーステナイト粒異常成長機構の解明, JFE技報, No. 23, pp. 30-35 (2009)
- (4) 益子 美明: 鋼のオーステナイト結晶粒度と機械的性質について, 材料試験, 6巻46号, pp. 446-452 (1957)
- (5) 藤田 昇輝: 計算材料科学に基づく鉄鋼材料の塑性変形と集合組織の予測, CAMP-ISIJ, Vol. 37, pp. 387-389 (2024)
- (6) 池端 久貴: PoLyInfoを活用した高分子インフォマティクス, 日本化学会情報化学部会誌, 37巻4号, pp. 94-98 (2019)
- (7) Hui Wang, et al.: An integrated approach for numerically predicting the failure of resistance spot welds, Science and Technology of Welding and Joining, 27, pp. 229-237 (2022)

### ■ 著者 ■



伊藤 靖朗



加藤 豪



前田 誠



吉田 拓未



山下 翼



小島 秀平



井上 純哉