



## アルミニウムの圧延プロセスにおける 慢性不良発生要因の解析

### ～ ベイジアンネットワークによる不良発生要因のモデル化 ～\*

森口 隆弘\*\*, 浅田 勝義\*\*\*, 大町 奈央子\*\*\*\*, 本村 陽一\*\*\*\*\*

## Cause Analysis of Chronic Defects in Aluminum Rolling Process ～ Modelling by Bayesian Networks ～\*

Takahiro Moriguchi\*\*, Katsuyoshi Asada\*\*\*, Naoko Omachi\*\*\*\* and Yoichi Motomura\*\*\*\*\*

### 1. はじめに

アルミニウム合金板材の特性は塑性加工と熱処理の結果として得られる内部組織に影響され<sup>1),2)</sup>, 目的の特性を得るため, 複数のプロセスを経て製造される。しかし, 何らかの原因により目的の特性を満たさない製品は検査工程において不良と判定され出荷できないため, 歩留まり向上のために圧延プロセスにおける不良の要因を洗い出し, 日々対策を検討・実施している。

不良は突発不良と慢性不良の2種類に大別することができる。突発不良とは製造プロセス中の変化点が原因となって発生する不良であり, 不良発生時の変化点調査によって比較的容易に対策検討が可能である。一方, 慢性不良とは複合要因に起因し, 断続的に発生する不良であり, 一般的に要因解明が困難であるとされている。

本研究は, 圧延プロセスにおける慢性不良低減条件の解明を目的として, 慢性不良発生現象のモデル化を試みたものである。その際, 不良原因となる内部組織を測定することは困難であるため, 熟練者の経験や過去蓄積された定性的な知見を定量化した上でモデルに取り込む必要がある。これを可能にするアプローチの一つ, ベイジアンネットワーク技術を活用して慢性不

良発生現象のモデル化を検討した。

### 2. ベイジアンネットワーク

ベイジアンネットワーク(以下, BN)とは, 多変数間の定性的な依存関係をグラフ構造によって表し, 定量的な関係を条件付き確率で表したモデルである<sup>3)</sup>。BNで親ノードを原因, 子ノードを結果としてモデル化すれば蓋然性(原因が結果に及ぼす影響の度合い)を確率で表現して, 定量評価できるようになる。また, Fig. 1で表すよう, 重回帰分析の多くは説明変数Xから並列的に目的変数Yを説明する構造になるが, ベイジアンネットワークは説明変数間の交互作用も記述することができる。

### 3. データと特徴量作成

対象データは, 工場における圧延プロセスで取得された実績データ385件であり, 用いた変数は工場に設置されたセンサーで測定された計測因子56変数と不良程度を表す1因子である。この元データに定性的な知見を追加するため, 熟練者に対してヒアリングを実施し, 定量化してモデルに組み込むことができる因子を

\* 本稿の主要部分は, 第35回人工知能学会全国論文集(2021)に掲載。

The main part of this paper has been published in bulletin of the 35th Japanese Society for Artificial Intelligence (2021).

\*\* (株)システムサポート, 元(株)UACJ R&Dセンター 第二研究部

System Support Inc., Former Research Development II, Research & Development Division, UACJ Corporation

\*\*\* (株)UACJ R&Dセンター 第二研究部

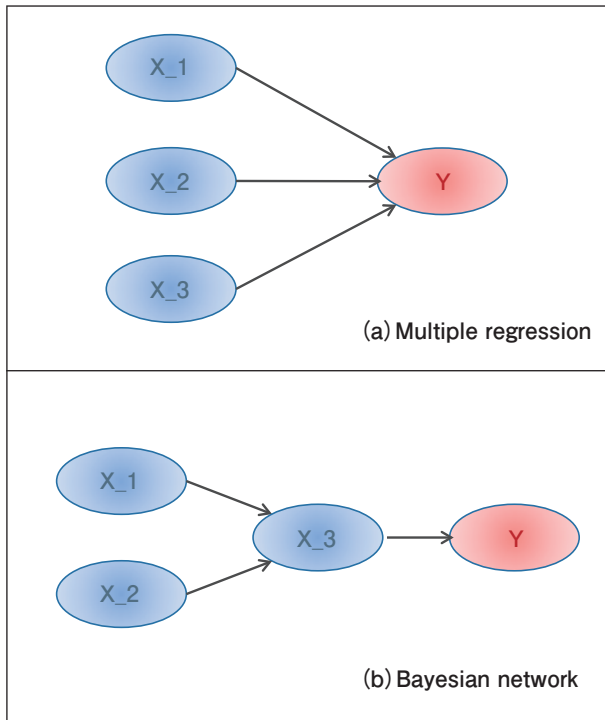
Research Development II, Research & Development Division, UACJ Corporation

\*\*\*\* (株)UACJ R&Dセンター 第二研究部, 博士(理学)

Research Development II, Research & Development Division, UACJ Corporation, Ph. D. (Sci.)

\*\*\*\*\* 独立行政法人 産業技術総合研究所, 博士(工学)

National Institute of Advanced Industrial Science and Technology, Ph. D. (Eng.)



**Fig. 1** Graph structures of a general multiple regression model (a) and a Bayesian network model (b).

抽出した。このように元データに含まれない新たな変数を作ることは特徴量作成（特徴量エンジニアリング）と呼ばれる。特徴量作成によりモデルの可読性や汎化性、精度の向上が期待できる。

### 3.1 熟練者へのヒアリング

アルミニウム板材に関する熟練者の知識を抽出するため、ヒアリングを行った。ヒアリングは不良の1次因子から始める。得られた1次因子を計測可能な因子と不可能な因子に分類し、計測不可因子についてはさらに2次、3次…と計測可能な因子が見つかるまで上流にさかのぼりながらヒアリングを実施する。最後にヒアリングから抽出された因子を計測可能な因子（計測因子）、計測不可であるが他因子から特徴量化が可能な因子（知識因子）、計測不可で他因子からの特徴量化も不可能な因子（除外因子）の3つに分類し、計測因子と知識因子のみを用いて不良現象をモデル化した。

### 3.2 知識因子の定量化

ヒアリングで抽出された定性的な知識は工場実績データに含まれないため、何らかの方法で定量化する必要がある。そこで、 $i+1$ 次の知識因子の要因となる $i$ 次の計測因子と知識因子を式(1)に代入することで、定量化した。

$$x_{i+1} = \sum_i^N c_i \cdot \frac{x_i - \mu_i}{\sigma_i} \quad (1)$$

$N$ : 因子 $i+1$ に影響する因子の数

$x_i$ : 因子 $i$ の特徴量または測定値

$\mu_i$ :  $x_i$ の平均値

$\sigma_i$ :  $x_i$ の標準偏差

$c_i$ : 因子 $i$ が因子 $i+1$ に正の影響があるとき: 1

負の影響があるとき: -1

## 4. 解析

計測因子56変数と定量化された知識因子7変数をベイジアンネットワークに組み込んでグラフ構造を構築する。モデル化の条件を以下に示す。

### 4.1 連続値の離散化

ベイジアンネットワーク学習には、定量因子の離散化が必要となる。因子の値が二値の場合、値が小さいものを「low」、値が大きいものを「high」とした。因子の値が連続値、または三値以上の離散的な値を取る場合は、平均以上を「high」、平均未満を「low」と二値化した。

### 4.2 親子関係の設定

次に、ヒアリングの結果を基に、親子関係を設定した。子ノードが計測因子または知識因子の場合、 $i$ 次因子に対して $i+1$ 次因子を全て強制的に親ノードとした。子ノードが不良の場合、不良を除く全因子を親ノード候補とし、親ノードの数は最大3とした。

### 4.3 学習条件の設定

グラフ構造は、上記で設定した親子条件を考慮しつつ、データによって自動的に構築することができる。学習条件は、親ノードの探索アルゴリズムをGreedy Search、パラメータ評価基準をAIC (Akaike's Information Criterion)、条件付き付確率値の推定方法をMAP (Maximum A Posteriori)とした。

## 5. 解析結果

汎用性能を正確に検証するため、モデルの性能評価にはk-Fold法(分割数5)を適用し、5つの学習用データとテストデータの組み合わせに対して解析を行った。

5.1 モデルの予測精度

Table 1にモデルの性能として、構築された5つのモデルのうち正解率中央値をもつモデルの混同行列を代表値として示す。混同行列とは二値分類タスクにおける実測と予測のクロス表であり、TP (真陽性：不良が正しく不良と予測された数)、TN (真陰性：良品が正しく良品と予測された数)、FP (偽陽性：良品が間違っ不良と予測された数)、FN (偽陰性：不良品が間違っ良品と予測された数) で表される。5つのモデルの正解率は64%～80%、中央値は73%であった。この結果より、本モデルを用いることでおおよその不良傾向が把握できるといえる。

5.2 ネットワーク図の解釈

構築されたネットワーク図を用いて不良発生現象の解釈を行った。4.1と同様に、正解率中央値をもつモデルを代表ネットワーク図とし、不良 (Defect) 周辺の依存関係を Fig. 2 に示す。各ノード M\_x と P\_x は計測因子と知識因子を表し、ノード間の矢印は因子間の依存関係を表す。計測因子と知識因子に関する親子 (因果) 関係は全て3.1のヒアリング結果を反映したものであるが、それ以外はデータで決められた関係となる。不良 (Defect) の親ノードは M\_0, M\_28, M\_42 の3つであり、これらの因子はアルミニウム板材の塑性加工に関わる因子であった。

Table 1 The confusion matrix of the representative model.

n=385		Prediction	
		Defect	Good
Data	Defect	TP (Truth Positive) 112	FN (False Negative) 58
	Good	FP (False Positive) 46	TN (Truth Negative) 169




Fig. 2 The part of the graph structure around the defect node.

5.3 影響度の評価

次に、塑性加工に関わる3つの因子、M\_0, M\_28およびM\_42の不良率への影響について調査した。単因子の影響度は、ある因子の状態「high」「low」における不良率の変化で、その影響度と方向を見積もることができる (その際、他の因子の状態は指定しない)。元データにて49%であった不良はいずれの因子を「low」状態にすることで不良を抑制できM\_0の影響度が最も高いという結果であった (Table 2)。

次に、M\_0, M\_28ならびにM\_42の不良に対する3因子の複合的な影響を検討した。最も影響の高いM\_0因子の状態を「low」とし、M\_28とM\_42の状態を変化させたときの不良率の変化を Fig. 3 に示す。Fig. 3のx軸に各因子の状態を示しているが、「-」は状態を固定しないことを意味する。これにより、M\_0が低い時に不良率は低下できるものの、M\_28とM\_42の状態に大きく依存し、M\_0を低くするだけでは不良率低減は保証できず、M\_28やM\_42も「low」状態に保つことで不良率を20%以下に抑制できることが示唆された。

5.4 不良低減のメカニズム

得られたネットワーク図と確率推論を用いて不良率低減のメカニズムについて検討した。M\_0の状態と知識因子の関係を調査したところ、M\_0 = lowの時、アルミニウム板材の内部状態P\_57, P\_61ならびにP\_62の状態が抑制されることが分かった (Fig. 3)。

次に、M\_0, M\_28及びM\_42が不良率に影響するメカニズムについて検討した。M\_0 = low状態の時、M\_28やM\_42の状態変化において不良率は変化するものの、P\_57, P\_61ならびにP\_62の知識因子への影響はほとんど見られなかった (Fig. 3)。この結果より、

Table 2 Impact to the defect rate of each factor.

Factor	Status	
	high	low
M_0	71	26
M_28	51	48
M_42	49	48




Fig. 3 Impact to the defect rate of the combination of three factors.

M\_0, M\_28ならびにM\_42が「low」状態の場合の不良抑制メカニズムは、本モデルにおける知識因子では説明不可であると考えられる。

## 6. おわりに

本研究では、圧延プロセスにおける慢性不良発生要因の解明を目的としてデータと人の知識からベイジアンネットワークを学習することで慢性不良発生要因のモデル化を試みた。その結果、以下の結果が得られた。

- ベイジアンネットワークを活用することで慢性不良発生メカニズムに関するモデルを構築することができた。また、塑性加工に関わるM\_0, M\_28, M\_42の3つの因子が主に慢性不良に影響する可能性が示唆された。
- 塑性加工に関わる上記3因子の慢性不良への影響について評価した結果、慢性不良が低減する可能性のある条件が示された。
- 影響度評価とネットワーク図より、塑性加工に関わる3つの因子の内、主因子M\_0による慢性不良低減メカニズムは、本手法でモデル化されていると考えられる。
- 影響度評価とネットワーク図より、塑性加工に関わる上記3因子の複合要因での慢性不良低減メカニズムは、本モデルでは説明できないと考えられる。

本モデルを生産活動において運用し、計測因子や知識因子の追加よりモデル精度を継続して改善することで不良発生現象の説明性を向上させ、より納得性の高い効果的な不良低減条件が提案できることが期待される。

## 参考文献

- 1) 菱川 滋, 小林 博幸: アルミニウムの板圧延技術, Furukawa-Sky Review, 4 (2008), 1-9.
- 2) 里 達雄: アルミニウム合金のマルチ組織制御と高強度・高延性化への挑戦, 軽金属 66 (2016) 433-443.
- 3) 本村 陽一, 佐藤 泰介: ベイジアンネットワーク-不確定性のモデリング技術, 人工知能学会誌, 15 (2000), 575-582.



森口 隆弘 (Takahiro Moriguchi)

(株)システムサポート

元 (株)UACJ R&D センター 第二研究部



浅田 勝義 (Katsuyoshi Asada)

(株)UACJ R&D センター 第二研究部



大町 奈央子 (Naoko Omachi)

(株)UACJ R&D センター 第二研究部

博士 (理学)



本村 陽一 (Yoichi Motomura)

独立行政法人 産業技術総合研究所

博士 (工学)