

多岐にわたる現象をモデル化するための方法論の研究

～階層型判別分析による欠陥現象のモデル化～

パナソニック株式会社 オートモーティブ&インダストリアルシステムズ社
山田大介*, 清水貴宏

1. はじめに

昨今、IoT、ビッグデータ、機械学習などが様々な分野で活用されている。製造業においても搬送や製品の仕分けなどに活用されていることが知られている。

しかしながら、製造業の製造過程等で発生する問題・課題を解決する分野での活用事例は、あまり報告されていないように思われる。それについてはいくつかの原因が考えられる。例えば、製造過程で発生する問題・課題については良否の判定だけでは不十分であって、『解決』『改良』が求められる。そのためには、物理・化学・力学などの固有技術に基づいた現象の推定やモデル化と、改善に結びつけるための発想力が不可欠である。これは、技術者が行わなければならない。この領域には現在のIoTや機械学習では対応できない部分があると考える。

一方で、最近の製造業においては多岐にわたる現象と様々な原因が複雑に関係し、

技術者が高度な統計的方法論を活用しなければ、問題・課題解決のためのモデリングが困難になってきているのも事実である。

多岐にわたる現象と様々な要因をモデリングする方法として、一般的に表.1 に示すような統計的方法論などがある。現象を識別するための方法論として知られ、活用されている。

表.1 現象の識別に用いられる統計的方法論

統計的方法論	メリット	デメリット
ディープラーニング	多岐にわたる現象を高精度に識別できる	モデル化できるが、対象の現象とモデルを構成する原因因子に技術的意味があるか不明
MT法	多岐にわたる現象を識別できる	
判別分析	単純な良否判定を識別できる モデル化できる	多岐にわたる現象の識別が難しい

ディープラーニングやMT法は、製造過程で発生する複数の不良現象を高精度に識別できる。しかしながら、モデリングに用いられる原因因子の技術的妥当性は不明確であるという危険性がある。判別分析は、1種類の不良と良品の識別、および、技術者が妥当性を確認できるようなモデリングは行えるが、複数の不良現象を同時に識別することはできない。

今回の事例では、同時に判別できない複数の不良が含まれた状態において、従来の判別分析を応用的に活用することで判別と妥当なモデリングが行え、製造工程における問題を解決した内容を報告する。

Study of the methodology to model various phenomenon

～ Modeling of a defect phenomenon by hierarchical discriminant analysis ～

Panasonic Corporation

Automotive & Industrial Systems Company

*DAISUKE YAMADA

TAKAHIRO SHIMIZU

2. 背景

判別分析は、単純な良否判定をモデル化でき、現象の簡単な理解や、良否判定結果を予測するのに有効な方法である。

【事例1】外観不良が1種類の場合

電子部品の外観検査の良否判定に活用する場合において、図.1 に示すような、1種類の外観不良があった場合の原因分析を説明する。

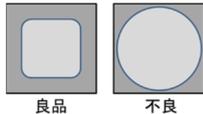


図.1 1種類の外観不良のイメージ図

不良現象を推定し、表.2 に示すように、因子A、因子B、因子Cのデータを収集した。

表.2 収集データ (良品 n=24、欠陥 n=12)

結果	Ln(因子A)	因子B	因子C
不良	0.470	136	56
不良	0.956	109	206
不良	-0.511	134	49

良品	-1.609	172	35
良品	-1.609	126	96

判別分析結果を以下の表.3 と図.2 に示す。

表.3 StatWorks5 による判別分析結果 (事例1)

目的変数		判別効率D ²	D* ²	D** ²	群	重心スコア	
結果	マハラノビス距離	11.932	11.007	10.225	1: 不良	5.966	
	誤判別率(%)	4.207	4.857	5.493	2: 良品	-5.966	
		判別効率D ²	変化量	誤判別率	F値	P値 (上側)	判別係数
vNo.	定数項						
IN 3	A	0.036	-11.896	46.226	91.595	0.000	8.036
IN 5	C	7.958	-3.974	7.920	10.743	0.002	-0.051

$F \geq 0 \dots$ 欠陥, $F < 0 \dots$ 良品

$$F = 9.436 + 8.036 * \text{因子A} - 0.051 * \text{因子C} \quad \dots \text{式(1)}$$

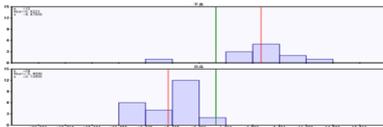


図.2 事例1におけるスコアのヒストグラム

不良に影響する要因として因子A,Cが検出された。判別関数Fは、式(1)のように得ることができた。誤判別率は4.207%であり、高い精度で分析できた。モデル式を構成する原因因子は、不良に至る現象と一致する内容であった。ところが、実際の業務においては、必ずしも、図.1に示すように外観不良が1種類のみであるとは限らない。

【事例2】外観不良が複数種類ある場合

図.3 に示すように、複数の不良が混在する場合がある。



図.3 複数の不良が混在する場合のイメージ図
表.4 に収集したデータを示す。

表.4 収集データ (良品 n=591、欠陥 n=228)

結果	Ln(因子A)	因子B	因子C
不良	-0.916	119	117
不良	-0.223	132	16
不良	-0.223	117	62

良品	-1.609	58	92
良品	-0.916	66	100

表.4 のデータに対し、判別分析を実施した結果を表.5、図.4 に示す。

表.5 StatWorks5 による判別分析結果 (事例2)

目的変数		判別効率D ²	D* ²	D** ²	群	重心スコア	
結果	マハラノビス距離	4.016	3.994	3.972	1: 不良	2.008	
	誤判別率(%)	15.817	15.884	15.950	2: 良品	-2.008	
		判別効率D ²	変化量	誤判別率	F値	P値 (上側)	判別係数
vNo.	定数項						
IN 8	A	1.553	-2.463	26.658	308.238	0.000	2.428
IN 9	B	2.896	-1.120	19.741	116.238	0.000	0.031

$F \geq 0 \dots$ 欠陥, $F < 0 \dots$ 良品

$$F = -2.668 + 2.428 * \text{因子A} + 0.031 * \text{因子B} \quad \dots \text{式(2)}$$

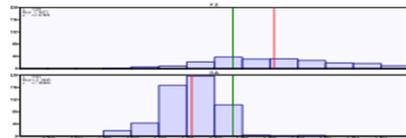


図.4 事例2におけるスコアのヒストグラム

要因として因子A,Bが検出され、判別関数Fは、式(2)のように得ることができた。

しかし、誤判別率が15.817%であり、分析精度は高くない。モデル式を構成する原因因子も、不良現象と一致しない。図.3で示した欠陥1、欠陥2、欠陥3は各々異なる不良現象であると考えられ、式(2)の1つのモデル式のみでは、全ての不良に至る現象を説明できない。このように、判別分析は、多岐にわたる現象の識別が同時にできないという課題がある。

今回、我々は、現象と様々な原因が複雑に関係している最近の製造業において、技術者が問題解決のためのモデリングに活用できる統計的方法論を検討した。

3. 事例内容

3.1 事例背景

事例 2 において、技術者が 5 ゲンを元に不良現象を層別し、原因因子を推定した例を図. 5 の系統図に示す。

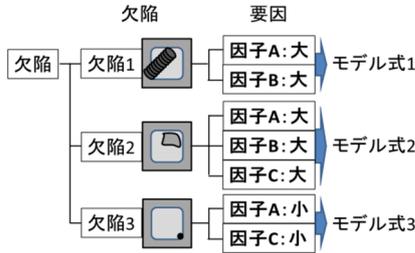


図. 5 事例 2 の不良現象についての系統図

図. 5 で示す系統図が適切であれば、不良を層別した結果を元に、判別分析などにより適切なモデル式を得ることができる。しかし、適切であるかどうかは、技術者のレベルによるところが大きい。

我々は、現象の識別からモデル化までを、技術者が適切に行える方法論として、階層型判別分析を検討した。図. 6 に階層型判別分析の考え方を示す。

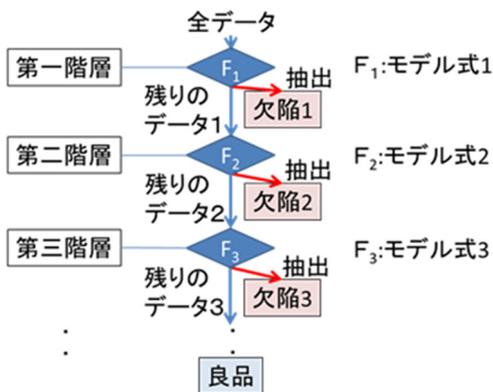


図. 6 階層型判別分析の考え方

階層を設けて段階的に判別分析を行い、不良現象を層別し、複数の結果と原因の因果関係をモデル化する方法である。階層型判別分析は、因子が検出されなくなるまで行う。

3.2 階層型判別分析の活用事例

事例 2 に対し階層型判別分析を実施した結果、図. 7 のように第三階層まで分析できた。

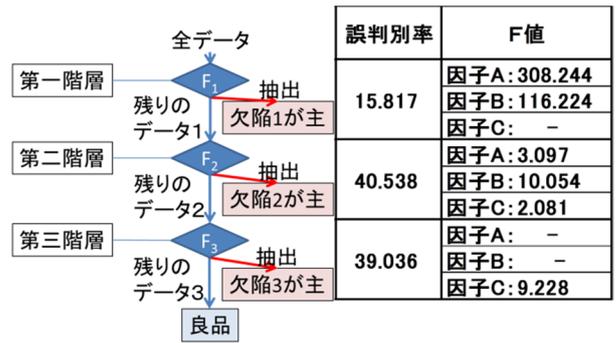


図. 7 階層型判別分析結果

階層型判別分析により、以下の式(3)～式(5)の3つのモデル式を得ることができた。各階層で得られたモデル式を順に説明する。

$$F_1 = -2.668 + 2.428 * \text{因子A} + 0.031 * \text{因子B} \quad \dots \text{式(3)}$$

$$F_1 > 0 \dots \text{欠陥}, F_1 < 0 \dots \text{良品}$$

式(3)は、因子 A, B で構成され、技術的に欠陥 1 が検出されることが説明できた。

$$F_2 = -1.652 + 0.736 * \text{因子A} + 0.015 * \text{因子B} + 0.009 * \text{因子C} \quad \dots \text{式(4)}$$

式(4)は式(3)に因子 C を加えることで、技術的に欠陥 2 が検出できることがわかった。

$$F_3 = 1.994 - 0.023 * \text{因子C} \quad \dots \text{式(5)}$$

式(5)は因子 C 単独で、式(4)の因子 C の係数とベクトルが異なる。これにより、技術的に欠陥 3 が検出できることがわかった。各階層で抽出された不良を実際に確認すると、第一階層は図. 3 で示す欠陥 1、第二階層は欠陥 2、第三階層は欠陥 3 が主であった。

以上から、階層型判別分析により、複数の不良現象の層別とモデリングが可能になると考えられる。ただし、識別精度の向上が課題であると考えられる。表. 6 に、階層型判別分析を用いて事例 2 のデータを識別した結果を示す。

表. 6 階層型判別分析によるデータの識別結果

方法論	(n = 228)	(n = 591)
	不良を正しく識別した割合	良品を正しく識別した割合
階層型判別分析 第一階層 (通常の判別分析)	73.5%	94.1%
階層型判別分析 第二階層	88.9%	56.3%
階層型判別分析 第三階層	94.3%	42.1%

3. 3 新たな分析方法の提案と活用事例

階層型判別分析の分析精度を向上するため、マハラノビス D 活用・階層型判別分析を新たに考案した。図. 8 に分析の考え方を示す。

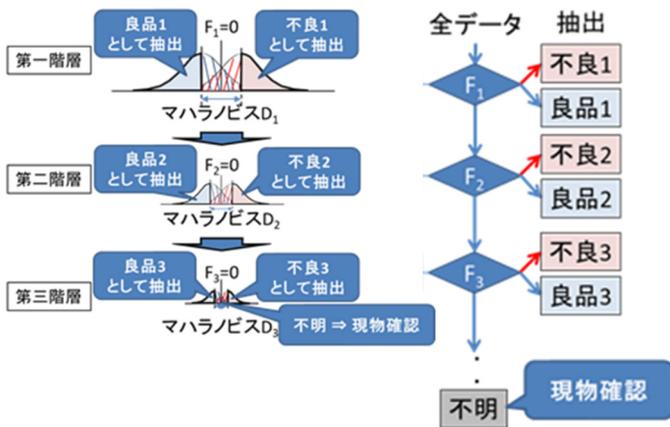


図. 8 マハラノビス D 活用・階層型判別分析

各階層の判別分析から得られるモデル式を元に、各データの判別スコアを参照し、誤判別する危険性が低いと推測されるデータを段階的に抽出する方法である。

図. 9 に、事例 2 に対し、マハラノビス D 活用・階層型判別分析を実施した結果を示す。

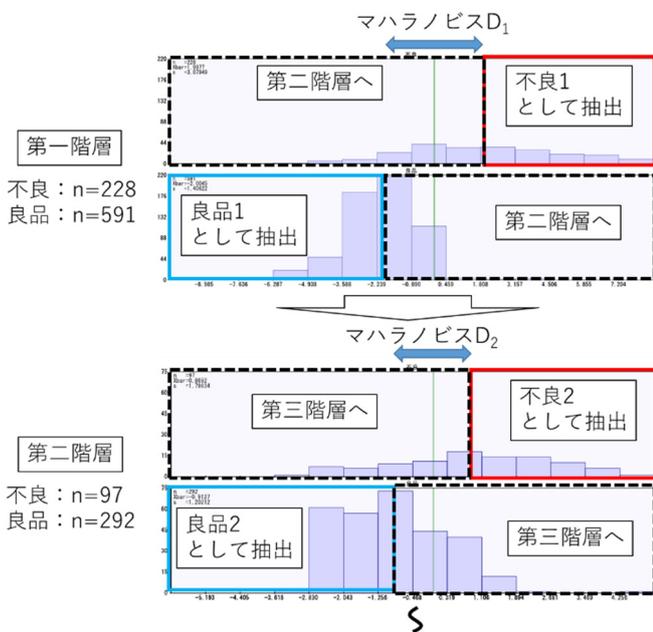


図. 9 マハラノビス D 活用・階層型判別分析結果

先の 3.2 節で述べた結果と同様に、第三階層まで不良現象を層別できた。欠陥 1~欠陥 3 に各々対応する 3 つのモデル式を得ることができた。また、誤判別する危険性が低いデータ

を段階的に抽出することで、階層型判別分析より分析精度を向上できた。表. 7 に、各方法論におけるデータの識別結果を示す。

表. 7 各方法論におけるデータの識別結果

方法論	(n = 228)	(n = 591)
	不良を正しく識別した割合	良品を正しく識別した割合
判別分析	73.5%	94.1%
階層型判別分析 第三階層	94.3%	42.1%
マハラノビス D 活用 階層型判別分析 第三階層	80.1%	89.7%

不良の識別精度が低下した理由は、不明に分類された不良が存在したためである。

マハラノビス D 活用・階層型判別分析の結果を元に、不良現象を考察した。図. 10 に系統図を示す。因子 A, B, C の大小関係により、3 つの不良現象が発生すると考えられる。

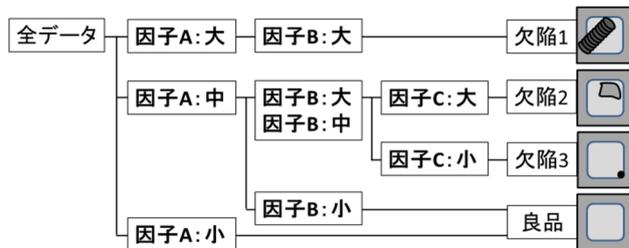


図. 10 分析結果から考察した不良現象の系統図

4. 効果

階層型判別分析により、異なる不良現象と因果関係を層別し、モデリングを行うことができた。また、限られた変数を段階的に有効活用することができると考えられる。

また、マハラノビス D 活用・階層型判別分析により、分析精度の向上に期待ができる。

5. 最後に

複数の不良現象を識別し、かつモデル化する方法として、階層型判別分析を考案した。更なる分析精度の向上は、今後の課題である。

ディープラーニングなどと合わせて活用することで、多岐にわたる複雑な現象の因果関係を理解することに役立てると期待する。

本著作物は原著作者の許可を得て、株式会社日本科学技術研修所（以下弊社）が掲載しています。本著作物の著作権については、制作した原著作者に帰属します。

原著作者および弊社の許可なく営利・非営利・イントラネットを問わず、本著作物の複製・転用・販売等を禁止します。

所属および役職等は、公開当時のものです。

■公開資料ページ

弊社ウェブページで各種資料をご覧ください <http://www.i-juse.co.jp/statistics/jirei/>

■お問い合わせ先

(株)日科技研 数理事業部 パッケージサポート係 <http://www.i-juse.co.jp/statistics/support/contact.html>