

ベイズモデルに基づく設備総合効率の低下要因の定量評価 Bayesian Model-Based Quantitative Evaluation of Factors Leading to Reduced Overall Equipment Efficiency

正力 一樹[†] 沖本 純幸[†] 島崎 悠太[†] 嶺岸 瞳[†]
Shoriki Kazuki Okimoto Yoshiyuki Shimazaki Yuta Minegishi Akira

1. はじめに

近年、IoT(Internet of Things)やAI(Artificial Intelligence)の進化により、実世界の事象をデータ化して収集し、これを分析することで課題発見や解決を行う CPS(Cyber Physical System)の開発、応用が多くの分野で進められている。中でも製造業における CPS では、生産に関する様々なデータの活用によるスマートファクトリーの実現を目指す動きが活発であり、生産性の最大化が期待されている[1-3]。

工場の生産性を最大化する一般的な取り組みとして、TPM(Total Production Management)活動がある[4, 5]。図 1 に、TPM における重要な生産性指標の 1 つ、設備総合効率(OEE: Overall Equipment Effectiveness)の構成を示す。OEE は、品種切り替えや設備トラブルで設備が停止する「①停止ロス」、設備不調で生産速度が低下する「②性能ロス」、設備不調や材料の変動で不良が増加する「③不良ロス」で構成され、それらの積算値である。OEE は生産活動における正味価値を生み出す時間であり、その向上は生産性の最大化につながる。図 2 に、異常が発生してから改善までの時間である、平均復旧時間(MTTR: Mean Time To Repair)を短縮したときの OEE 改善効果の模式図を示す。図 2 上は改善前、下は改善後を示している。MTTR を短縮することにより設備停止時間が短くなり OEE を向上することができる。このように OEE 向上には、MTTR を短縮することが改善策の一つであるが、そのためには、OEE 低下の検知、およびその要因となるロスを即時に特定する必要がある。ただし、多品種混合生産下では品種と設備の大量の組み合わせが存在し、それぞれで定常時の OEE が変動する点を考慮しなくてはならない。

一般的な異常検知手法として、ベイズ統計を用いる方法がある。これは、目的変数を確率変数とみなして、その分布を表現するパラメータを、観測した実データからベイズ推定によって推論する手法である[6]。この場合、OEE を確率的に変動する目的変数、設備や品種を説明変数とみなして実測値からその事後分布を推定することで、生起確率が小さい OEE を異常値として検知することができる。これにより、設備や品種の組み合わせによる OEE の変動を考慮した異常検知が可能となる。しかし、OEE の値は、複数存在するロス要因の積算値であり、それらは相互に関係し合っている。そして、これらロス要因は、稼働時間(s)、MTBF(Mean Time Between Failures: 平均故障間隔)、単位時間あたりの生産数(pcs/s)、不良率(%)など異なる指標で評価されており、そのままでは相互比較が困難である。した




図 1 OEE の構成




図 2 MTTR 短縮による OEE 改善効果

がって、従来のベイズ推定を適用するだけでは、突発的な OEE の低下を検知できても、その原因が生産速度の変化によるものか、設備不調による低下か、不良品によるものか判断がつかない。

以上の理由から、多品種混合生産の中で複数のロス要因の混在した影響を判断するためには、異なる要因を同じ指標で評価し、それぞれの要因の異常度を定量的に推定する必要がある。そこで本稿では、タクトタイムという統一的な指標で OEE を表現し、階層ベイズモデルによってモデル化する手法を提案する。タクトタイムは、良品 1 つあたりに要する製造時間であり、ロス要因ごとに分解して評価することができる。この時、あるロス要因の観測値を得る前と後のタクトタイムのカルバック・ライブラー情報量(Kullback-Leibler Divergence, 以降、情報量と呼ぶ)の差は、その要因の観測値そのものが持つ情報量を意味する。この情報量を各ロス要因に対して計算し、タクトタイムへの影響度として定量的に評価することで、異常検知及び、タクトタイム悪化のロス要因特定が可能となる。

2. 本論

2.1 提案手法

2.1.1 解析モデル

OEE は理想的な生産数と実際の生産数の比であり、時間を製造数で除したタクトタイムによっても同等の評価が可能である。したがって、本稿では管理時間 t_{mng} を良品数 n_{good} で除したタクトタイム τ_1 を実効タクトと定義し、こ

[†]パナソニックインダストリー(株) 技術本部 プロセスデバイス革新センター スマートファクトリー技術部
Panasonic Industry Co., Ltd. Engineering Division Process Device Innovation Center Smart Factory Technology Department

これを確率変数としてモデル化する。τ₁ は OEE を構成する 3つのロス要因ごとに分解でき、それぞれ良品 1 つあたりの時間として表現できる。

- ① 「停止ロス」は、製造装置が停止した時間であるため、停止時間 $t_{stop,i}$ を良品数で割ることにより求まる。これを停止時間 f_i とする。ただし、添え字 i は k 個存在する停止要因を識別する番号であり、各停止要因 f_i の合計停止時間を f とする(式(1))。
- ② 「性能ロス」は設備不調等により本来よりも生産速度が低下するロスであり、停止時間や不良品数に影響を受けない。したがって、この生産速度は、設備が一切の停止なく、製造した製品が全て良品である場合のタクトタイムとして表現できる。この値は純粋な設備のタクトタイムであり、本来の生産速度に性能ロスが加わった値と考えることができる。本稿ではこれを理想タクトと定義し、τ₀とおく(式(2))
- ③ 「不良ロス」は不良品を製造した時間であるため、製造時間に不良率を掛け、良品数で除した値で表せる(式(3))。これを不良製造時間 y とする。また、実効タクトτ₁は、τ₀, f , y の和によって近似することができる(式(4))。

$$f = \sum_{i=1}^k f_i = \sum_{i=1}^k \frac{t_{stop,i}}{n_{good}} \quad \dots(1)$$

$$\tau_0 = \frac{t_{opr}}{n_{good}} \quad \dots(2)$$

$$y = t_{opr} \frac{n_{prod} - n_{good}}{n_{prod}} \frac{1}{n_{good}} \quad \dots(3)$$

$$\tau_1 = \frac{t_{mng}}{n_{good}} \approx \tau_0 + \sum f_i + y \quad \dots(4)$$

このように分解したτ₀, f_i , y も確率変数として、階層ベイジモデルで表現すると、次のように定式化できる。

$$p(\tau_1, \tau_0, f, y | s_1, s_2, e) = p(\tau_1 | \tau_0, f, y) \prod p(f_i | e) p(\tau_0 | s_1, s_2, e) p(y | s_1, e) \quad \dots(5)$$

ただし、 e は設備番号、 s_1, s_2 は製造部品の構造を表すパラメータである。右辺第 2 項で停止時間 f が設備番号 e に、理想タクトτ₀が、設備番号 e および製品パラメータ s_1, s_2 に、不良製造時間 y が製品パラメータ s_1, s_2 に依存することは、それぞれの分散分析結果から決定した。

一般的な統計モデルでは対象製品は品種と設備の大量の組み合わせが存在し、それぞれにモデルが必要となるが、本手法は情報を段階的に与えることで、組み合わせに応じた事後確率分布を推定可能であるため、このような製品群に有効である。

さらにτ₀は、事前検討の結果、設備番号 e 、製品パラメータ s_1, s_2 の線形回帰を平均値とする対数正規分布に従うと仮定した。すなわち、τ₀の推定分布は式(6)で表すことができる。ただし、 w^e, w^{s_1}, w^{s_2} は平均値の回帰係数であり、σ₀は対数正規分布のパラメータである。

$$p(\tau_0 | e, s_1, s_2) = \int \text{LogN}(\tau_0; \log(w^e e + w^{s_1} s_1 + w^{s_2} s_2), \sigma_0) \times p(w^e, w^{s_1}, w^{s_2}, \sigma_0) dw^e dw^{s_1} dw^{s_2} d\sigma_0 \quad \dots(6)$$

停止時間 f は設備番号 e を条件とするパラメータで決定する 0 過剰のガンマ分布Gamma₀に従うと仮定すると、その推定分布は式(7)で表せる。ただし、Gamma はガンマ分布、θは0の発生確率、α,βはガンマ分布のパラメータである。

$$p(f_i | e) = \int \text{Gamma}_0(f; \theta_i^e, \alpha_i^e, \beta_i^e) p(\theta_i^e, \alpha_i^e, \beta_i^e) d\theta_i^e, \alpha_i^e, \beta_i^e \quad \dots(7)$$

$$\text{Gamma}_0 = \begin{cases} \theta & (f = 0) \\ (1 - \theta) \text{Gamma}(f; \alpha, \beta) & (f > 0) \end{cases}$$

不良製造時間 y は、設備番号 e および製造パラメータ s_1 を条件とするパラメータで決定するガンマ分布に従うと仮定すると、その推定分布は式(8)で表される。ここで、κおよびθはガンマ分布のパラメータである。

$$p(y | e, s_1) = \int \text{Gamma}(y; \kappa^{e, s_1}, \theta^{e, s_1}) p(\kappa^{e, s_1}, \theta^{e, s_1}) d\kappa^{e, s_1} d\theta^{e, s_1} \quad \dots(8)$$

実効タクトτ₁はτ₀, f , y の総和の対数値を平均パラメータとする対数正規分布に従うと仮定すると、推定分布は式(9)で表される。ここで、σ₁は対数正規分布のパラメータである。

$$p(\tau_1 | \tau_0, f, y, \sigma_1) = \int \text{LogN}(\tau_1; \log(\tau_0 + f + y), \sigma_1) p(\sigma_1) d\sigma_1 \quad \dots(9)$$

図 4 に構築したタクトタイムのグラフィカルモデルを示す。矢印は各変数の依存関係を表している。各ロス要因の変数である f, τ_0, y はそれぞれ独立であり、製造条件の影響を受けるため、設備番号 e および製品仕様 s_1, s_2 を説明変数にして推定する。これにより、製造条件の変動を考慮したタクト推定が可能となる。

2.1.2 モデル推定

構築した解析モデルにτ₁, f ,τ₀, y の観測値データ \mathcal{D} を使って、製造条件である説明変数 e, s_1, s_2 からτ₀と f と y のそれぞれの予測確率分布を推定する。また、これらの分布の積算値から、実効タクトτ₁の予測確率分布を得ることができこれを $p(\tau_1 | \mathcal{D})$ と表すものとする(図 4(a))。また、ある要因の実効タクトへの影響を定量化するには、このモデルのある変数に対して、実測値を入力し、実効タクトの予測確率分布を再度計算する(図 4(b))。これを全要因に対して行うことで、各要因の実効タクトへの影響を切り分けて評価することが可能となる。




図 3 実効タクトのグラフィカルモデル

2.1.3 インパクトファクターの導入

次に前項のモデルで推定した各要因別の予測確率分布の変化から、それらの実効タクトへの影響度を定量化するために新たに考案した指標であるインパクトファクターについて説明する。異常度は発生確率の高低で評価するが、実効タクト低下に対する影響度を定量化するため情報量と呼ばれる評価指標に変換する手法を用いた。確率分布 p に対して、ある値 x を観測する情報量 I は下記で定義される。

$$I = -\text{Log}_2(p(x)) \quad \dots(10)$$

式(5)より、情報量 I は確率 p の逆数であり、発生確率の低い事象ほど大きな値をとる、分布中央からの乖離度を表す指標である。情報量を用いることで、複数の要因の影響を加算または減算し、それぞれの乖離度を統合した値として評価することができる。

新たに実効タクトが観測された時、過去データからの標準的な予測分布 $p(\tau_1|D)$ と、観測された要因ごとの観測値を考慮した分布での情報量を比較することで、影響度の定量化を行う。図 5 にその概念図を示す。まず、過去データからの標準的な分布 A を解析モデルから推定し、実効タクト τ_1 を実測する情報量 I_A を式(11)から求める。

$$I_A = -\text{Log}_2(p(\tau_1|D)) \quad \dots(11)$$

次に、評価対象の停止要因 f_i の実測値を与えて新たな確率分布 B を推定し、 τ_1 を観測する情報量 I_B を式(12)で求める。

$$I_B = -\text{Log}_2(p(\tau_1|D, f_i)) \quad \dots(12)$$

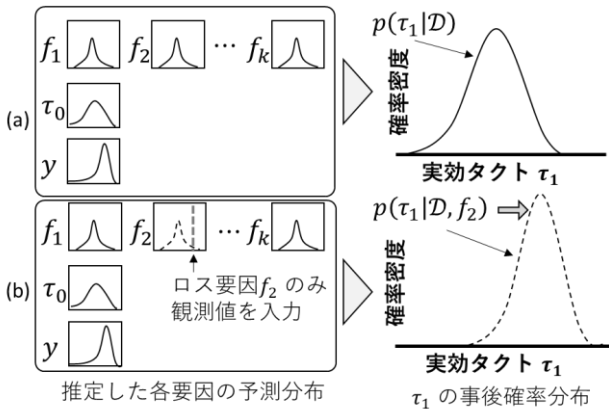



図 4 定常状態および要因 f_2 の観測値を与えたときの確率密度分布の推定



■ I_A : 定常状態の実効タクトが τ_1 となる情報量
 ▨ I_B : 停止要因 f_i の情報量

図 5 インパクトファクターの概念図

ここで、標準分布での情報量 I_A と評価対象を加えた後の情報量 I_B の差 (図 5 のハッチング部) を式(13)で求め、これをインパクトファクター $I(f_i)$ と定義する。

$$I(f_i) = -\text{Log}_2(p(\tau_1|D)) - (-\text{Log}_2(p(\tau_1|D, f_i))) \quad \dots(13)$$

実測された実効タクトの変化に対して、 $I(f_i)$ の値が大きい停止要因は、実効タクトの変化に影響を与えている要因である。すなわち OEE が低下したあるロットにおいて、 $I(f_i)$ が大きい要因はそのロットにおける OEE 低下原因であることを意味しており、これを各ロス要因に対して求めることで、ロス要因ごとの相互評価が可能となる。

2.2 評価

2.2.1 対象データ

モデル推定および推論に用いる設備稼働ログデータは、工場から取得したロット単位のデータ 13395 件となっており、各レコードは表に示す情報を含む。ここで、停止要因毎停止時間は要素数 k の配列であり、 k 個の停止要因それぞれについて、停止した時間を記録したものである。ここで、管理時間 t_{opr} 、稼働時間 t_{mng} 、停止時間 $t_{stop,i}$ の間には、式(14)が成立する。

$$t_{mng} = t_{opr} + \sum_i^k t_{stop,i} \quad \dots(14)$$

また、学習および推論に使用するデータ概要を表 2 に示す。このうち、12638 件のデータをモデル推定、残り 757 件のデータを異常度の推論に使用する。

2.2.2 モデル推定

モデルの推定は、過去の稼働ログデータを用いてベイズ推定を行う。推定時のアルゴリズムには MCMC(Markov Chain Monte Carlo)法を用いた。図 6 に、実データ分布および推定した事後分布の一部を箱ひげ図で示す。縦軸は推定時の製造条件を、横軸は実効タクトを示している。ただし、ひげの終端はそれぞれ 5%、95% 点を示す。設備、製造パラメータの条件によっては分布の端や中央値にずれが見られるが、概ね推定できていることが分かる。

表 1 データ形式

名称	変数	データ型
ロット番号	l	文字列
ロット終了日時	d	日時
管理時間	t_{mng}	非負実数
稼働時間	t_{opr}	非負実数
製造数	n_{prod}	非負整数
良品数	n_{good}	非負整数
停止要因毎停止時間	$t_{stop,i}$	非負実数配列
設備番号	e	文字列
製造パラメータ 1	s_1	文字列
製造パラメータ 2	s_2	文字列

表 2 データ概要

名称	変数	ユニーク数
ロット番号	l	13395
設備番号	e	50
製造パラメータ 1	s_1	3
製造パラメータ 2	s_2	2
停止要因	i	66

2.2.3 推論およびインパクトファクターによる原因推定

図 7 上部に、前項で推定したモデルを用いて、推論対象データを推論した結果を、下部にそのときの製造条件を示す。実線はある設備の実効タクト τ_1 の実測値である。破線は解析モデルより推定した確率分布の 50% 値、ハッチングで示した範囲は確率分布の 95% 区間を示している。ここで、上図の A ロットは実効タクト τ_1 の実測値が定常状態の確率分布の 95% 区間外にあるため、OEE が異常に低下していると予想される。実際、モデル推定に使用した同条件のデータの OEE 分布と比較すると、定常状態より低下していることが分かる (図 8)。表 3 に同ロットの全要因のインパクトファクター $I(f_i)$ を算出して降順に並べた結果を示す。停止要因 f_1 の $I(f_i)$ が 5.335 で最大値となっていることから、




図 6 実効タクトの実データ分布および推定した事後分布




図 7 実効タクトの推定分布および観測値

f_1 が生産性能を低下させた主要因と考えられる。また、性能ロス、停止ロスによる OEE 低下を $I(f_i)$ という同一の指標で定量的に評価できており、OEE 向上のために優先して対応が必要となる項目をリストとして可視化している。

3. おわりに

本稿では、製造現場における OEE 低下の検知およびその原因の評価手法として、OEE をタクトタイムで表現し、階層ベイズモデルによってモデル化する方法を提案した。本手法は、OEE のロス要因をタクトタイムという共通の単位で表現することにより、従来単位が統一されていなかった各ロス要因に対し、相互比較を可能とした。また、情報量から計算したインパクトファクターを導入することにより、これらの実効タクトへの影響度を定量的に評価し、製造現場での OEE 改善に大きく貢献した。今後は、同技術の精度向上、妥当性評価を進めつつ、工程が複数連続した製造ラインに対しても応用を進める。

参考文献

- [1] 古川 慈之, “スマート工場の構成要素とその実現に向けた取り組み”, 成形加工, Vol.35, No.1 (2023).
- [2] Lee, J., Bagheri B., & Kao H.-A., “A Cyber-Physical Systems architecture for Industry 4.0-based manufacturing systems”, Manufacturing Letters, Vol. 3, pp. 18-23 (2015).
- [3] Zhong, R. Y., Xu X., Klotz E., & Newman, S. T., “Intelligent Manufacturing in the Context of Industry 4.0”, A Review. Engineering, Vol. 3, No. 5, pp.616-630 (2017).
- [4] 伊藤賢次, “TQC と TPM”, 日本生産管理学会論文誌, Vol.8, No.1 (2001).
- [5] Abdul T. B., Lim P. P., “Implementation of Total Productive Maintenance (TPM) in Automotive Industry, IEEE Symposium on Business”, Engineering and Industrial Applications, pp. 55-58 (2011).
- [6] 久保 拓弥, “データ解析のための統計モデリング入門(第 15 版)”, 岩波書店(2018).

表 3 各ロス要因のインパクトファクター

ロス要因	停止時間 [s]	インパクトファクター
f_1	9669	5.335
τ_0	-	0.6215
f_3	1549	0.3049
f_7	671	0.3049
f_6	18	0.2345
f_2	2849	0.1605
f_4	9	0.0825
y	-	0.0825

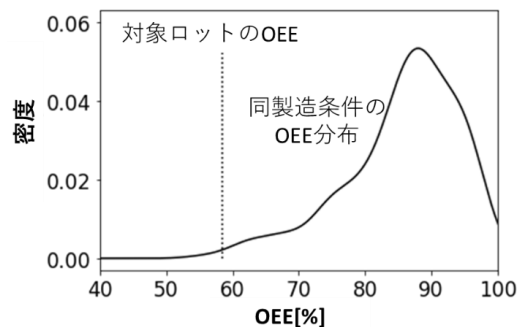


図 8 定常状態の OEE 分布および対象ロットの OEE