



マハラノビス・タグチ・システムにおける 高次元データ解析法の展開

大久保 豪人*¹

Development of High-dimensional Data Analysis Procedures in Mahalanobis-Taguchi System

Masato OHKUBO*¹

Abstract– The Mahalanobis-Taguchi (MT) system, which is representative of the Taguchi method, plays an important role in various fields centered on the manufacturing industry. Within these fields, the MT method proposed at the earliest stage has been applied to various data as a practical anomaly detection procedure, and there are abundant application cases. However, it is clear that the conventional MT method cannot always perform appropriate analyses. Therefore, due to the practical demand for the MT system, we have proposed novel anomaly detection procedures to appropriately analyze real problems. In this paper, we comprehensively report our research results on the MT system, especially for high-dimensional data.

Keywords– Anomaly detection, Mahalanobis-Taguchi method, Principal component analysis, Quality engineering, Recognition Taguchi method

1. はじめに

マハラノビス・タグチ (MT) システム [1] は、タグチメソッドで知られる田口玄一博士が提唱した一連の多変量解析法の総称である。その中でも最初期に提案された MT 法は、製造業を中心とした様々な業種・業態の企業やその他の組織において重要な役割を担っている。例えば、製造業における設備機器の状態監視、医療における各種疾病の診断等が適用事例として挙げられる。また、近年ではセンサーデータを利用した異常検知システム [2] に MT 法が使用され、Internet of Things (IoT) の先駆的な事例として実務家の注目を集めている。

このように MT 法は実務的な需要から様々なデータに適用されているものの、従来プロセスでは、必ずしも適切な分析ができるとは限らない。そこで、著者らは MT システムへの実務的な需要を踏まえたうえで、実問題を適切に分析するための新たな異常検知方式を提案した [3]-[7]。本稿では、これまでの研究成果の中でも、特に MT システムにおける高次元データを対象とした異常検知方式の改良 [3], [4], [6] に関する総合的な報告を行う。

前述のように MT 法は実用的な異常検知方式として広く普及しているものの、変数の次元 P に比べて十分なサンプルサイズ N を確保する必要があることが知られている。実際、宮川ら [8] あるいは永田 [9] は P に比べて N が十分に大きくなければ MT 法の異常検知尺度であるマハラノビス距離が大きな予測バイアスをもつことを指摘した。そして、このことが異常検知性能の低下につながることを著者らは示している [4]-[6]。

一方、実問題では時に、経済的あるいは物理的な制約により十分な N が確保できない場合がある [6]。また、センサー等から経時的にデータを取得できる状況においても、第 5 章で述べるようにリアルタイム性を確保するためには N を小さくすることが望ましい場合もある。さらに、 N に比べ P が大きくなる ($N < P$) データや、マイクロアレイ・データに代表されるような N に比べ P が遥かに大きくなる ($N \ll P$) データが解析対象となる場合もあり得る。

このような場合、従来の MT 法では精度よく異常を検知することが困難になるだけでなく、 $N < P$ あるいは $N \ll P$ となる場合には解析自体が実行できなくなってしまふという問題が発生する。ここで、本稿では以降、 $N < P$ となるデータを高次元データ、 $N \ll P$ となるデータを超高次元データと区別して呼ぶことにする。

*¹ 東洋大学経営学部経営学科 東京都文京区白山 5-28-20

*¹ Toyo University, 5-28-20 Hakusan, Bunkyo-ku, Tokyo

Received: 24 July 2019, Accepted: 13 September 2019.

したがって、本稿では、高次元データあるいは超高次元データを適切に解析するための方法論について議論するものとする。具体的には、高次元データを対象とした異常検知方式として後述の MT-PPCA 法 [4] と RT-PC 法 [3] を取り上げ、その使い分けにおける留意点を述べる。また、超高次元データを対象とする場合、各異常検知方式をいかに改良すべきか方向性を示す [6]。

本稿の構成は次の通りである。第 2 章では、MT 法の概要を述べたうえで、高次元データに適用する場合の問題点を指摘する。第 3 章では、高次元データを適切に解析するための二つの方法論を取り上げ、その使い分けにおける留意点を述べる。第 4 章では、第 3 章で示した二つの方法論を超高次元データ解析に応用するための方向性を示す。最後に、第 5 章ではまとめを述べる。

2. MT システムにおける異常検知

本章では、MT 法の概要を示したうえで、高次元データに適用する場合の問題点を指摘する。

2.1 MT システムの概要

田口博士は当初、2.3 節に示すマハラノビス距離に基づく異常検知方式を MT システム (後の MT 法) として提案した。ところが、その後、その改良方式である MTA 法 [10] や、高次元バイナリ・データを対象とした異常検知方式である RT 法 [11]、回帰問題を扱う T 法 [12] 等が同博士によって提案された。そのため、現在では、最初期に提案された MT システムを MT 法、一連の分析方式を総じて MT システムと呼ぶようになっており (例えば、参考文献 [13])、本稿もそれに従っている。なお、MT 法とその改良方式の提案背景等については参考文献 [13] を参照されたい。また、それらの理論については参考文献 [9], [14] に詳しい。

2.2 MT 法の概念

MT 法はホテリングの T^2 管理図 [15] に、SN 比に基づく項目選択や項目診断等のアイデアを加えて発展させた実用的な異常検知のための方法論である。

ここで、異常検知とは、ある個体が正常な個体か異常な個体かを判定するための多変量解析法である。ただし、一般の多変量解析法における通常の判別分析が正常な個体と異常な個体の両方が均質な母集団を形成すると仮定するのに対して、異常検知では正常な個体のみが均質な母集団を形成すると仮定する。そして、新たに観測された個体が、正常な個体が形成する母集団から逸脱していなければ正常、そうでなければ異常と判定する。ゆえに、異常検知は異常な個体が均質な母集団を形成することを仮定する必要がないため、多種多様な異常が発生

する場合や未知の異常が発生する可能性がある場合の判別に有用であるといえる。

2.3 MT 法の解析手順

MT 法では、前節で述べた「正常な個体が形成する均質な母集団」のことを「単位空間」と呼ぶ。そして、その単位空間からの逸脱度をマハラノビス距離に基づいて定量化し、対象となる個体が正常か否かを判定する。以下、MT 法における単位空間上のマハラノビス距離の算出手順を中心に説明する。その他の解析手順については参考文献 [13] 等を参照されたい。

いま母集団上で観測された P 次元変数 \mathbf{x} の母平均ベクトルを $\boldsymbol{\mu}$ 、母共分散行列を Σ とする。このとき、母集団上のマハラノビス距離を次のように定義する：

$$\Delta(\mathbf{x}) = (\mathbf{x} - \boldsymbol{\mu})^\top \Sigma^{-1} (\mathbf{x} - \boldsymbol{\mu}) \quad (1)$$

ただし、ベクトルあるいは行列の転置を \top とした。なお、本稿のベクトルは縦ベクトルとして扱う。

ここで、MT 法では、単位空間に属する N 個の個体から求めた標本平均ベクトルおよび標本共分散行列を $\boldsymbol{\mu}$ および Σ の推定量として母集団上のマハラノビス距離を推定する。また、判定対象となる新たな個体に対してマハラノビス距離を計算する際も、単位空間から既に計算した母数の推定量を用いる。そして、そのマハラノビス距離が、事前に定めた閾値を超えていれば異常、超えていなければ正常と判定する。

なお、上述のように母集団上のマハラノビス距離を推定するとき、MT 法における推定されたマハラノビス距離とホテリングの T^2 管理図 [15] における T^2 統計量は等しくなる。したがって、MT 法と T^2 管理図はいずれもマハラノビス距離に基づく異常検知方式として解釈できる。そのため、両者の概念的あるいは理論的な差異についての議論がなされている [16]。また、参考文献 [13] には実用上の観点から両者の相違点が整理されている。

2.4 MT 法の問題

前節で述べたように MT 法とはマハラノビス距離に基づく異常検知方式のことである。この異常検知方式の問題の一つは共分散行列の逆行列計算を必要とするため、 $N < P$ である場合、マハラノビス距離が計算できなくなることである。また、第 1 章で述べたように $N > P$ の場合でも精度よく異常を検知するためには、高次元になるほど数多くのサンプルを準備する必要がある。このことは学習データへのラベリング (技術者が正常な個体か否かを判断し、その情報を付与したデータセットを作成すること) に対するコストを増加させるため、実用上の問題が発生する。

3. 高次元データ解析法

本章では、 $N < P$ の場合にもマハラノビス距離を計算するための方法論として、MT-PPCA法 [4] と RT-PC法 [3] を取り上げ、その使い分けにおける留意点を述べる。

3.1 MT法の距離

本節では、以降の議論のため、MT法が用いる距離と固有値および固有ベクトルの関係について説明する。前章で述べたように、MT法が異常度の尺度として用いる距離はマハラノビス距離である。ここで、マハラノビス距離は母共分散行列 Σ の固有値 $\lambda_1, \lambda_2, \dots, \lambda_P$ および対応する長さ1の固有ベクトル $\xi_1, \xi_2, \dots, \xi_P$ を用いて、

$$\Delta(\mathbf{x}) = \sum_{p=1}^P \frac{\{\xi_p^\top(\mathbf{x} - \boldsymbol{\mu})\}^2}{\lambda_p} \quad (2)$$

と変形できることに注意する [17]。 (2) 式より、母集団上のマハラノビス距離を推定するには、 Σ のすべての固有値および固有ベクトルの推定が必要であることがわかる。一方、 $P > N$ の場合、標本共分散行列からは高々 $N - 1$ 個の固有値および固有ベクトルしか求めることができない。したがって、母集団上のマハラノビス距離は推定できず、異常検知も実行不能となってしまふ。

3.2 MT-PPCA法の距離

本節では、MT-PPCA法 [4] が用いる距離と固有値および固有ベクトルの関係性の考察を通して、本異常検知方式が高次元データを適切に分析するための方法論の一つとなっていることを示す。

MT-PPCA法 [4] とは、probabilistic principal component analysis (PPCA) モデル [18] の仮定のもとで推定した母集団上のマハラノビス距離に基づく異常検知方式であり、高次元データを対象としたMT法として提案された。ここで、PPCAモデルの仮定のもとでは、母集団上のマハラノビス距離が、

$$\Delta_{PPCA}(\mathbf{x}) = \sum_{m=1}^M \frac{\{\xi_m^\top(\mathbf{x} - \boldsymbol{\mu})\}^2}{\lambda_m} + \sum_{p=M+1}^P \frac{\{\xi_p^\top(\mathbf{x} - \boldsymbol{\mu})\}^2}{\sigma^2} \quad (3)$$

と変形できることに注意する [6]。ただし、 $M < P$ であり、 σ^2 は $\sigma^2 < \lambda_M$ を満たすものとする。 (3) 式より、PPCAモデルの仮定のもとでの母集団上のマハラノビス距離は第 $M + 1$ 以降の固有値がすべて同じ値をとることを仮定した場合のマハラノビス距離であることがわかる。また、 (3) 式は次のように変形できる。

$$\Delta_{PPCA}(\mathbf{x}) = \sum_{m=1}^M \frac{\{\xi_m^\top(\mathbf{x} - \boldsymbol{\mu})\}^2}{\lambda_m} + \frac{\Xi(\mathbf{x})}{\sigma^2} \quad (4)$$

ただし、

$$\Xi(\mathbf{x}) = (\mathbf{x} - \boldsymbol{\mu})^\top (\mathbf{x} - \boldsymbol{\mu}) - \sum_{m=1}^M \{\xi_m^\top(\mathbf{x} - \boldsymbol{\mu})\}^2 \quad (5)$$

であり、 $\Xi(\mathbf{x})$ を以降、残差と呼ぶことにする。 (4) 式より、 (3) 式のマハラノビス距離を計算するためには、第1から第 M 固有値および固有ベクトルを推定すればよいことがわかる。したがって、 $N < P$ の場合においても、 $N > M$ ならば、母集団上のマハラノビス距離を推定でき、異常検知も実行可能となる。なお、 (4) 式における各パラメータの推定量については参考文献 [4] を参照されたい。

3.3 RT-PC法の距離

本節では、RT-PC法 [3] が用いる距離と固有値および固有ベクトルの関係性の考察を通して、本異常検知方式が高次元データを適切に分析するための方法論の一つとなっていることを示す。

RT-PC法 [3] とは、高次元バイナリ・データを対象とした異常検知方式であるRT法 [11] の改良方式であり、高次元連続量データを対象とした異常検知方式である。以下、RT-PC法の距離 (以降、RD) について説明する。ただし、RT-PC法の解析手順は、用いる距離の違いを除いてMT法と同様であることを注意しておく。

まずRDを定義するためには、 P 次元変数 \mathbf{x} を $M + 1$ 次元変数 \mathbf{z} に集約する必要がある。ここで、 $Q = M + 1$ として、 \mathbf{z} の第 q ($q = 1, 2, \dots, Q$) 番目の変数を Z_q と表記するとき、各 Z_q は次のように定義される：

$$Z_q = \xi_q^\top(\mathbf{x} - \boldsymbol{\mu}) \quad (q = 1, 2, \dots, M) \quad (6)$$

$$Z_Q = \sqrt{\Xi(\mathbf{x}) / (P - M)} \quad (7)$$

なお、 (6) 式は第1から第 M 主成分であり、 (7) 式は残差をその自由度で除した後に平方根をとったものである。

次に、 Q 次元変数 \mathbf{z} に対する (1) 式と同様のマハラノビス距離を母集団上のRDとして定義する：

$$\Delta(\mathbf{z}) = (\mathbf{z} - \boldsymbol{\mu}_z)^\top \Sigma_z^{-1} (\mathbf{z} - \boldsymbol{\mu}_z) \quad (8)$$

ただし、 Q 次元変数 \mathbf{z} の母平均ベクトルを $\boldsymbol{\mu}_z$ 、母共分散行列を Σ_z としている。 (8) 式より、母集団上のRDを計算するためには、第1から第 M 固有値および固有ベクトルを推定すればよいことがわかる。したがって、 $N < P$ の場合においても、 $N > M$ であるならば、母集団上のRDを推定でき、異常検知も実行可能となる。なお、 (6) 式から (8) 式における各パラメータの推定量については参考文献 [3] を参照されたい。

3.4 適用上の注意

本節では、MT-PPCA法とRT-PC法は本質的に異なる異常検知方式として捉えたうえで、解析の目的に応じて使い分ける必要があることを注意しておく。

まず、本節での議論に先立ち、ホテリングの T^2 管理図 [15] を始めとする多変量管理図の分野におけるデータ空間の解釈について説明しておく。多変量管理図の分野では、母共分散行列のスペクトル分解を、

$$\Sigma = \sum_{m=1}^M \lambda_m \xi_m \xi_m^T + \sum_{p=M+1}^P \lambda_p \xi_p \xi_p^T \quad (9)$$

とするとき、データ空間全体を第1項と第2項に対応した固有ベクトルが張る空間に分けて異常原因を考察する。いま第1項に対応した固有ベクトルが張る空間を主部分空間、第2項に対応した固有ベクトルが張る空間をノイズ空間と呼ぶことにする。このとき、主部分空間に発生した異常は高々 M 個の主成分が大きく変動したことが原因であり、ノイズ空間に発生した異常は本質的な相関構造の崩れが原因だと考える [19]。言い換えれば、主部分空間に発生した異常は主成分の変動として技術的な解釈が可能である一方、ノイズ空間に発生した異常は技術的な解釈が困難であるか意味をもたないと捉えることができる。このような考え方に基づけば、MT-PPCA法とRT-PC法は以下に注意して使い分けるべきといえる。

MT-PPCA法の距離（以降、単にMD）とRDは、第1から第 M 固有値および固有ベクトルを応用した距離であるものの、RDとMDに基づく異常検知方式は検知する異常の定義が異なっている。MDに基づく方式では、単位空間の中心に発生したデータほど、単位空間に属する（正常である）確率が高いと判断される。一方、RDに基づく方式では、単位空間の中心付近に発生したデータも異常と判定される可能性がある [20]。これは、RDがその定義式から、残差が小さな値をとるほど、RDの値が大きくなることに起因する。(5)式の残差は観測変数 \mathbf{x} が単位空間の中心である $\boldsymbol{\mu}$ に近い値をとるほどゼロの値に近づく。そのため、 \mathbf{x} が単位空間の中心付近に発生するほど、RDの値は大きくなり、異常と判定される確率が高くなるという性質をもつようになる。

このことは特に異常原因について考察する必要がある場合、大きな影響があるといえる。RDに基づく異常検知方式は、第 $M+1$ 固有ベクトル以降が張るノイズ空間の中心付近に発生したデータも異常と捉えるため、第 $M+1$ 主成分以降が技術的な意味をもつ場合、定性的な意味合いが不明になる。一方、第 $M+1$ 主成分以降がノイズによる変動を意味すれば、データの本質的な構造に変化があるものと判断できる。よって、第 $M+1$ 主成分以降が技術的な意味をもつか否かを事前に確認したうえで、両者を使い分ける必要がある。

4. 超高次元データ解析法

前章では高次元データに適用可能なMTシステムの異常検知方式として、MT-PPCA法 [4] とRT-PC法 [3] を取り上げた。また、各異常検知方式で用いる距離を推定するには母共分散行列の固有値および固有ベクトルを推定すればよいことも述べた。ここで、従来のMT-PPCA法 [4] およびRT-PC法 [3] では、これらの推定量として、通常の主成分分析（以降、従来型PCA）と同様の手順により計算するものを使用することに注意されたい。

本章では、まず従来型PCAに基づく固有値および固有ベクトルの推定法は、超高次元データを適用対象とする場合、推定精度および解釈容易性の両面から問題があることを指摘する。そして、推定精度および解釈容易性を同時に向上させるため、スパースPCAを応用した固有値および固有ベクトルの推定法をMT-PPCA法 [4] およびRT-PC法 [3] に導入する方法について説明する。

4.1 従来型PCAに基づく推定法の問題

MTシステムでは、異常を検知するだけでなく、異常原因の特定等に有用な知見を獲得することも解析の目的となる場合がある。したがって、固有値および固有ベクトルの推定精度を向上させることは、主成分の解釈を行ううえで重要であり、異常の発生原因を追究するうえでも有益であるといえる。加えて、それらの推定精度は異常検知性能にも大きな影響を与えてしまう [6]。

しかしながら、従来型PCAは大標本漸近理論のもとで、その精度保証が与えられていることに注意されたい。このことは $N \ll P$ となる超高次元データを扱う問題設定においては、必ずしもよい方法論とは限らないことを意味する。実際、変数の次元 P が $P \rightarrow \infty$ となる前提のもとで、従来型PCAに基づく固有値および固有ベクトルの推定量が一致性を満たす状況は極めて限定的であることが報告されている [21]-[23]。すなわち、超高次元データを適用対象とする場合、従来型PCAでは推定量の精度保証を与えることが困難となる。

また知見獲得の観点からは、固有ベクトルの解釈容易性も重要である。高次元になるほど固有ベクトルの要素数が増加することに注意すると、超高次元データを対象とする場合、固有ベクトルの解釈は困難になるといえる。すなわち、もとの変数が主成分に与える影響を、固有ベクトルの要素をもとに判断する場合、技術的な考察は高次元になるほど難しくなる。これはもとの変数が主成分に与える影響が全くない（固有ベクトルの対応する要素がゼロである）場合でも、従来型PCAで推定すると非ゼロの値をとることに起因する。したがって、固有ベクトルの要素をゼロとみなすための閾値設定を効率よく実行する方法論が必要となるといえる。

4.2 スパース PCA に基づく推定法

本節では、超高次元小標本データを解析対象とした場合にも、固有値および固有ベクトルの推定精度と解釈容易性を同時に向上させるための方策の一つとして、スパース PCA を応用した固有値および固有ベクトルの推定法を MT-PPCA 法 [4] および RT-PC 法 [3] に導入する方法が有用との見解を示す。

スパース PCA とは、固有ベクトルの大部分がゼロの値をとることを仮定したうえで、固有値および固有ベクトルを推定し、主成分分析を実行するための方法論である。スパース PCA では、固有ベクトルの要素に対する L_1 ノルム等を罰則として、罰則項付きで従来型の PCA に対応した最適化問題を解くことを通して、固有値および固有ベクトルを推定する。スパース PCA に基づく固有ベクトルの推定量は、その要素の大部分が厳密にゼロの値をとるため解釈容易となる。また同時に非ゼロ要素に対する縮小推定も行うため、サンプルサイズが十分でない場合においても推定精度の向上が期待できる。

したがって、スパース PCA のアルゴリズムの中から、超高次元データを適用対象とする場合でも、固有値および固有ベクトルの推定に対する精度保証を与えることができるものを選択すれば、所望の異常検知方式を実現できるといえる。そして、参考文献 [6] では、その一例として、第 1 固有値と対応する固有ベクトルを推定することに焦点を絞ったうえで、Regularized Sparse PCA (RSPCA) [24] を応用する方法を提案している。ここで、RSPCA の最適化問題は次の通りである。

$$\min_{\mathbf{f}, \mathbf{v}} \|\mathbf{X} - \mathbf{f}\mathbf{v}^\top\|_F^2 + \rho P(\mathbf{v}) \quad (10)$$

ただし、 \mathbf{X} は $N \times P$ のデータ行列、 N 次元ベクトル \mathbf{f} は分散 1 に基準化した第 1 主成分得点、 P 次元ベクトル \mathbf{v} は第 1 固有ベクトルである。また、 $\|\cdot\|_F$ はフロベニウス・ノルム、 $P(\mathbf{v})$ は正則化項、非負定数 ρ は正則化項の重みである。 $P(\mathbf{v})$ としては L_1 ノルム等の使用が提案されており、適当な条件の下での一致性が証明されている (Shen et al. (2013))。なお、第 1 固有値は (10) 式の最適解 \mathbf{f}^* および \mathbf{v}^* を用いて次のように推定できる。

$$\hat{\lambda}_1 = \left(\mathbf{f}^{*\top} \mathbf{X} \mathbf{v}^* / \sqrt{N-1} \right)^2 \quad (11)$$

5. おわりに

本稿では、著者らのこれまでの研究成果の中でも、特に高次元データを対象とした MT システムに関する総合的な報告を行った。まず、MT システムにおける最初期の異常検知方式である MT 法を高次元データに適用する場合の問題を述べた。そして、変数の次元がサンプルサイズよりも大きい場合でも異常検知を適切に実行す

るための方法論として、MT-PPCA 法と RT-PC 法を取り上げ、その使い分けにおける留意点を述べた。さらに、変数の次元がサンプルサイズよりも遥に大きな超高次元データを対象とする場合には、スパース PCA に基づく MT-PPCA 法と RT-PC 法が精度および解釈容易性の向上の観点から有用であるとの見解を示した。

近年、IoT 関連技術の進展に伴って、様々な産業分野においてセンサーやスマートデバイスから膨大なデータが取得・蓄積されている。特に製造業では、このように蓄積された履歴データを活用し、設備機器の異常検知システムを実現しようという動きがある。履歴データはリアルタイムに蓄積され、サンプルサイズも膨大になるものの、正常なデータが永続的に定常性を満たすとは考えにくい。すなわち、正常なデータは限定的に定常性を満たすと仮定して、単位空間を更新していく必要がある。この際、高次元小標本における検知性能が十分に確保されれば、更新間隔を短く設定でき、定常性の仮定が緩和されることで適用範囲が広がることが期待される。

今後の課題として、MT システムにおけるガウシアン・グラフィカル・モデリングを応用した新たな異常検知方式の確立を挙げる。本稿では、主成分分析を応用した高次元データ解析法を取り上げたが、これまでに著者らは新たな高次元データ解析法として、ガウシアン・グラフィカル・モデリングを応用した MT 法を提案している [5]。その一方で、RT-PC 法に対応するような異常検知方式の提案には至っていない。また、超高次元データを対象とする場合の分析方式をいかに実現するかについての議論を行っていく必要もある。

謝辞：本研究の一部は日本学術振興会 (JSPS) 科研費 JP18K13953 の助成を受けて実施しました。

参考文献

- [1] G. Taguchi and R. Jugulum, "The Mahalanobis-Taguchi Strategy: A Pattern Technology System", John Wiley and Sons, 2002.
- [2] 高濱正幸, 三上尚高, ガスタービンプラントの異常予兆検知, 品質工学, Vol.20, No.4, pp.437-443, 2012.
- [3] 大久保豪人, 永田 靖, タグチの RT 法における同一次元でない連続量データへの適用方法, 品質, Vol.42, No.2, pp.248-264, 2012.
- [4] 大久保豪人, 永田 靖, MT システムにおける小標本データの解析方法, 日本経営工学会論文誌, Vol.66, No.1, pp.30-38, 2015.
- [5] 大久保豪人, 永田 靖, グラフィカル・モデリングに基づくマハラノビス・タグチ法, 応用統計学, Vol.46, No.1, pp.13-26, 2017.
- [6] M. Ohkubo and Y. Nagata, "Anomaly detection in high-dimensional data with the Mahalanobis-Taguchi system", Total Quality Management & Business Excellence, Vol.29(9-10), pp.1213-1227, 2018.

- [7] M. Ohkubo and Y. Nagata, "Anomaly detection for unlabelled unit space using the Mahalanobis-Taguchi system", *Total Quality Management & Business Excellence*; [Online 13 May 2019].
- [8] 宮川雅巳, 田中研太郎, 岩澤智之, 中西寛子, マハラノビス・タグチ・システムにおける実際の誤判別率, *品質*, Vol.37, No.1, pp.101-106, 2007.
- [9] 永田 靖, MT システムの諸性質と改良手法, *応用統計学*, Vol.42, No.3, pp.93-119, 2013.
- [10] 田口玄一, 機能と機能性 (8) 20 世紀の MTS 法と 21 世紀の MT 法, *標準化と品質管理*, Vol.55, No.2, pp.61-70, 2002.
- [11] 田口玄一, 目的機能と基本機能 (11) 認識のための T 法, *品質工学*, Vol.14, No.2, pp.171-175, 2006.
- [12] 田口玄一, 目的機能と基本機能 (6) T 法による総合予測, *品質工学*, Vol.13, No.3, pp.309-314, 2005.
- [13] 立林和夫, 手島昌一, 長谷川良子, 入門 MT システム, 日科技連出版社, 2008.
- [14] 永田 靖, MT システムの研究, *国際学研究*, Vol.6, No.2, pp.29-36, 2017.
- [15] H. Hotelling, (1947), "Multivariate quality control - illustrated by the air testing of sample bombsights. C. Techniques of Statistical Analysis", C. Eisenhart, M.W. Hastay, and W.A. Wallis (eds), McGraw-Hill, pp.113-184, 1947.
- [16] W.H. Woodall, R. Koudelik, K.L. Tsui, S.B. Kim, Z.G. Stoumbos, and C.P. Carvounis, "A review and analysis of the Mahalanobis-Taguchi system", *Technometrics*, Vol.45, No.1, pp.1-15, 2003.
- [17] 宮川雅巳, 永田 靖, マハラノビス・タグチ・システムにおける多重共線性対策について, *品質*, Vol.33, No.4, pp.77-85, 2003.
- [18] M.E. Tipping and C.M. Bishop, "Mixtures of probabilistic principal component analyzers", *Neural Computation*, Vol.11, 443-482, 1999.
- [19] J.E. Jackson and G.S. Mudholkar, "Control procedures for residuals associated with principal component analysis", *Technometrics*, Vol.21, No.3, pp.341-349, 1979.
- [20] 永田 靖, 土居大地, タグチの RT 法で用いる距離の性質とその改良, *品質*, Vol.39, No.3, pp.364-375, 2009.
- [21] S. Jung and J.S. Marron, "PCA consistency in high dimension, low sample size context", *The Annals of Statistics*, Vol.37, No.6B, pp.4104-4130, 2009.
- [22] K. Yata and M. Aoshima, "PCA consistency for non-Gaussian data in high dimension, low sample size context", *Communications in Statistics - Theory and Methods*, Vol.38(16-17), pp.2634-2652, 2009.
- [23] S. Jung, A. Sen, and J.S. Marron, "Boundary behavior in high dimension, low sample size asymptotics of PCA", *Journal of Multivariate Analysis*, Vol.109, pp.190-203, 2012.
- [24] H. Shen and J.Z. Huang, "Sparse principal component analysis via regularized low rank matrix approximation", *Journal of Multivariate Analysis*, Vol.99, No.6, pp.1015-1034, 2008.

大久保 豪人



2011 年早稲田大学創造理工学部経営システム工学科卒業。18 年同大学院創造理工学研究科経営システム工学専攻博士後期課程を修了。博士 (工学)。13 年より、大手総合化学メーカー勤務。早稲田大学創造理工学部経営システム工学科助手、助教を経て現在に至る。実用的な統計的異常検知法等の研究・開発に従事。
