

## 4.3 多変量データ解析手法に基づく統計的プロセス管理

### 4.3.1 緒言

仕様を満たす製品を製造し、プロセスを安全かつ効率的に運転するためには、何らかの異常が発生した際に、異常を素早く検出し、その原因を究明した上で、適切な対応処置を取れるようなシステムを構築する必要がある。品質管理および異常検出を行うための手法として、統計的プロセス管理 (Statistical Process Control; SPC) がある。特に、Shewhart 管理チャートは様々な分野で広く普及しており、化学プロセスも例外ではない。しかし、Shewhart 管理チャートを用いて各測定変数を独立に監視する方法は、多変数プロセスには有効ではない。その理由として、1) 監視すべき変数の数の増加に伴いフォルス・アラームも増加すること、2) 変数間の相関関係を考慮できないこと、が挙げられる。そこで、多変数プロセスを対象とした統計的プロセス管理に関する研究が行われてきた。多変量統計的プロセス管理 (Multivariate Statistical Process Control; MSPC) を実現するためには、変数間の相関関係を捉え、少数の統計量で運転状態を代表させる必要がある。最も基本的な統計量は Hotelling  $T^2$  統計量である。Jackson ら<sup>1,2)</sup>は主成分分析 (Principal Component Analysis; PCA) を利用した残差分析を提案し、主成分の  $T^2$  統計量と残差の二乗和である  $Q$  統計量とを同時に監視する方法を提案した。ここで、残差とは元の測定値と少数の主成分によって再構築された値との差である。

主成分分析に代表される多変量解析手法はケモメトリクス手法とも呼ばれ、分析化学分野での適用例が多い。化学プロセスには非常に多くの測定変数が存在し、かつそれらの変数が強い相関を持つことが多いため、モデリングや運転監視にケモメトリクス手法が有効である。Wise と Gallagher<sup>3)</sup>はケモメトリクスを "the science of relating measurements made on a chemical system to the state of the system via application of mathematical or statistical methods" と定義した上で、複数のケモメトリクス手法とその化学プロセス監視および動的プロセスモデリングへの適用についてまとめている。主成分分析や Partial Least Squares (PLS) を用いた MSPC 手法の開発とその適用事例としては、流動床反応器および抽出蒸留塔への適用<sup>4)</sup>、multiway 主成分分析を用いたセミバッチ反応器への適用<sup>5)</sup>とバッチ重合反応器への適用<sup>6)</sup>、動的主成分分析の利用<sup>7)</sup>、multiblock 手法を用いた大規模プロセスへの適用<sup>8)</sup>などがある。

多くの適用事例が示しているとおり、主成分分析を利用した MSPC 手法は化学プロセスの運転管理に非常に適している。しかし、監視指標である  $T^2$  と  $Q$  が管理限界内に存在する限り、たとえ運転状態が変化したとしても、その変化を検出することはできない。

本研究では、運転状態が変化すれば多次元空間内での運転データの分布状態も変化することに着目し、新しい MSPC 手法を提案する。さらに、制御系設計や異常診断などの検討に用いるテスト問題として開発された Tennessee Eastman プロセスに従来法および新手法を適用し、異常検出性能を評価すると共に、各手法の特徴および設計パラメータの与える影響について検討する。さ

らに、異常が検出された時点で異常原因の特定に有用な情報を得る方法についても検討する。物理モデルや過去の異常発生時の運転データの存在を前提としない場合、利用可能な運転データから有用な情報を抽出する必要がある。主成分分析を用いた従来型 MSPC 手法によって異常検出を行う場合、寄与プロットを利用して異常に強く関与した変数を特定する作業が行われる<sup>9-11)</sup>。そこで本報では、新手法の1つであるデータの非類似度に基づく異常検出手法について、その運転指標である非類似度への各変数の寄与を新たに定義し、得られた寄与に基づいて異常原因に関する情報を得ることを試みる。

#### 4.3.2 新しい運転監視手法

本節では、提案する2種類の運転監視手法について簡単に説明する。1つは移動主成分分析と呼ばれる手法であり、以後 MPCA と略記する。もう1つは運転データの非類似度に基づく方法であり、以後 DISSIM と略記する。各手法の詳細は文献 12)、13)を参照されたい。

##### (1) 移動主成分分析による運転監視

運転状態の変化は変数間の相関関係の変化を引き起こすため、時間と共に変化する各主成分の向きを監視することによって運転状態の変化を検出することができると考えられる。この運転監視手法を MPCA (Moving Principal Component Analysis) と呼ぶ。主成分の変化に基づいて異常検出を行うためには、正常運転状態を代表する基準主成分を選択し、その基準主成分と各時刻の運転状態を代表する主成分との差を監視する必要がある。主成分の変化を評価するための指標として、

$$A_i(k) = 1 - |w_i(k)^T w_{i0}| \quad (4.3.1)$$

を用いる。ここで、 $w_i(k)$ は  $k$  ステップでの第  $i$  主成分を、 $w_{i0}$  は正常データから決定される第  $i$  基準主成分を表す。 $w_i$  と  $w_{i0}$  は共に単位ベクトルであり、 $A_i$  は内積に基づく監視指標である。ある時刻の主成分と基準主成分とが直交する場合、すなわち2つの主成分が全く異なる場合には、 $A_i$  は1となる。一方、ある時刻の主成分と基準主成分とが一致する場合には、 $A_i$  は0となる。

MPCA による運転監視システムは、以下の手順で構築される。

- 1) 正常運転データを標準化する。
- 2) 主成分分析を適用し、正常運転状態を表す基準主成分  $w_{i0}$  を決定する。
- 3) 幅  $w$  ステップの窓を移動させ、正常運転データから  $w$  個のサンプルを含む複数のデータを作成する。作成したデータに主成分分析を適用し、各時刻の運転状態を表す主成分  $w_i$  を求める。
- 4) 指標  $A_i$  を計算し、その管理限界を設定する。

なお、基準主成分と管理限界の決定に際しては異なるデータを用いるべきである。オンラインで監視を行う際には、まず、幅  $w$  ステップの窓を逐次移動させ、各時刻での運転状態を表すデータ

行列を更新する。なお、データの標準化にはステップ1で求めた平均と標準偏差を用いる。更新したデータ行列に主成分分析を適用し、指標  $A_i$  を求める。この指標が管理限界を超えれば、何らかの異常が発生したとみなす。主成分を逐次計算する方法としては、ここで述べたような窓を用いる方法以外に、逐次主成分分析を用いる方法がある<sup>14)</sup>。

MPCA の適用により、 $T^2$  と  $Q$  を監視指標とする従来法では検出できない運転状態の変化を検出することができる。しかし、複数の主成分が同程度の分散を持つ場合には、変数間の本質的な相関関係は変化しないにもかかわらず、データから計算される主成分は大きく変化することがある。このような状況下では、指標  $A_i$  は有効に機能しない。そこで、各主成分を個別に監視する代わりに、複数の主成分が張る部分空間の時間的変化を監視する。

## (2) データの非類似度に基づく運転監視

運転データの非類似度 (Dissimilarity Index) に基づく新しい運転監視手法を DISSIM と名付ける。この手法は、多次元空間内での運転データの分布状態が運転状態を反映していることに着目し、正常運転データの分布と直近のデータの分布との非類似度を監視するものである。以下で、分布の違いを定量的に評価するために導入された非類似度とその監視方法について簡単に説明する。

監視すべき  $P$  個の変数に対して  $N_i$  個のサンプルからなる2つのデータ行列  $X_i$  ( $i=1,2$ ) を考える。各データ行列の共分散行列は直交行列を用いて対角化できる。このとき得られる直交行列と対角行列とを用いて、データ行列  $X_i$  を  $Y_i$  へと線形変換する。この変換をうまく行えば、変換後のデータ行列  $Y_1$  と  $Y_2$  は同一の主成分を持ち、かつ、それらの主成分が逆順序となる。換言すれば、 $Y_1$  の第1主成分方向は  $Y_2$  の最後の主成分方向と等しい。図 4.3.1 に2種類の例を示す。右下図において、 $Y_1$  と  $Y_2$  の第1主成分が直交していることが重要である。線形変換後のデータ行列が有する、この特徴を利用して、データの非類似度  $D$  を次式で定義する。

$$D = \frac{4}{P} \sum_{j=1}^P (\lambda_j - 0.5)^2 \quad (4.3.2)$$

ここで、 $\lambda_j$  は変換後データ行列の共分散行列の固有値である。データの分布がきわめて似ている場合には、 $\lambda_j$  は 0.5 に近い値となり、 $D$  は 0 に近い値となる。一方、データの分布が大きく異なる場合には、最大固有値と対応する最小固有値はそれぞれ 1 と 0 に近い値となるため、 $D$  は 1 に近い値を取るようになる。

DISSIM による運転監視システムは、以下の手順で構築される。

- 1) 正常運転データを標準化する。
- 2) 幅  $w$  ステップの窓を移動させ、正常運転データから  $w$  個のサンプルを含む複数のデータを作成する。作成したデータから正常運転状態を代表する基準データを選択する。

3) 非類似度  $D$  を計算し、その管理限界を設定する。

本手法においても MPCA と同様に、基準データと管理限界の決定に際しては異なるデータを用いるべきである。オンラインで監視を行う際には、まず、幅  $w$  ステップの窓を逐次移動させ、各時刻での運転状態を表すデータ行列を更新する。なお、データの標準化にはステップ 1 で求めた平均と標準偏差を用いる。更新したデータ行列と基準データ行列との非類似度  $D$  を求める。この指標が管理限界を超えれば、何らかの異常が発生したとみなす。

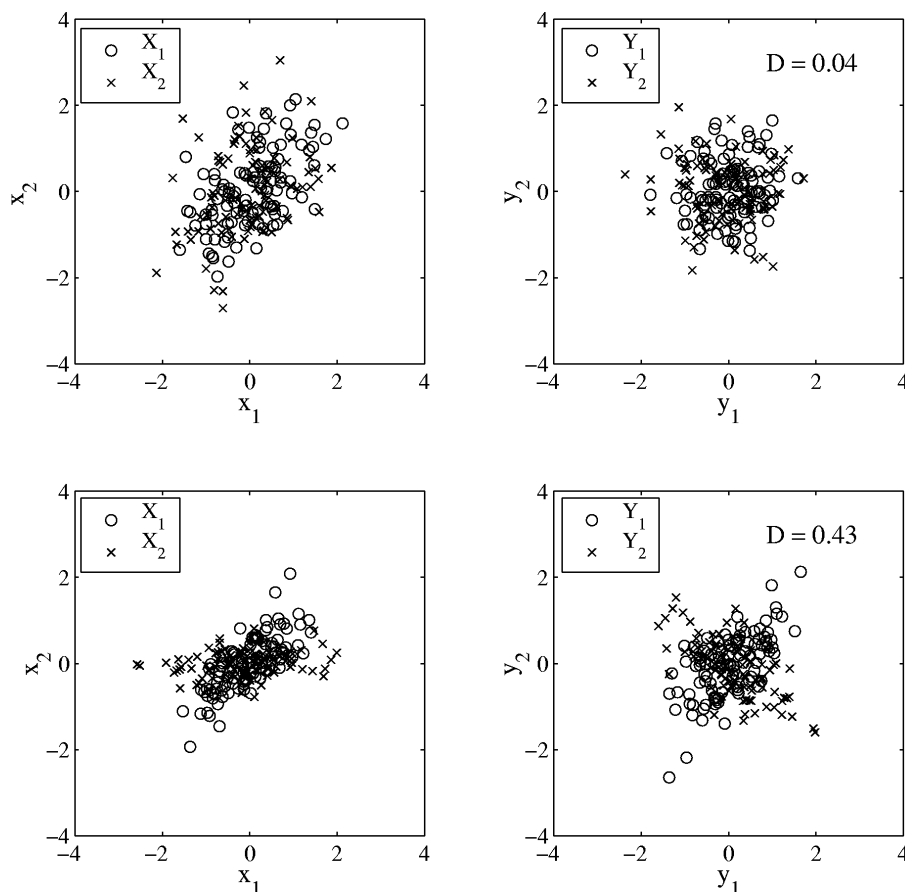


図 4.3.1 データ行列の非類似度を評価するための線形変換  
(上図：データが類似している場合、下図：データが異なる場合)

4.3.3 化学プロセスへの適用

本節では、主成分分析を用いた従来の多変量監視手法 (conventional MSPC; cMSPC)、新しく提案した運転監視手法である MPCA と DISSIM の計 3 手法を、現実の化学プロセスを模した Tennessee Eastman プロセス<sup>15)</sup>に適用し、各手法の比較を行うと共に、その特徴について検討する。

( 1 ) Tennessee Eastman プロセス

Tennessee Eastman プロセスは、反応装置、凝縮装置、気液分離装置、圧縮装置、精留装置の 5 つの主要装置から構成されている。このプロセスには 12 の操作変数とオンライン測定可能な 22 のプロセス変数があり、その他に 19 の組成測定値も利用可能である。また、シミュレータにはあらかじめ 20 種の外乱(または異常)が用意されている。ダイナミックシミュレーションを行うために、図 4.3.2 に示す PID 制御系<sup>16)</sup>を適用した。プロセス変数のサンプリング間隔は 3 分とした。

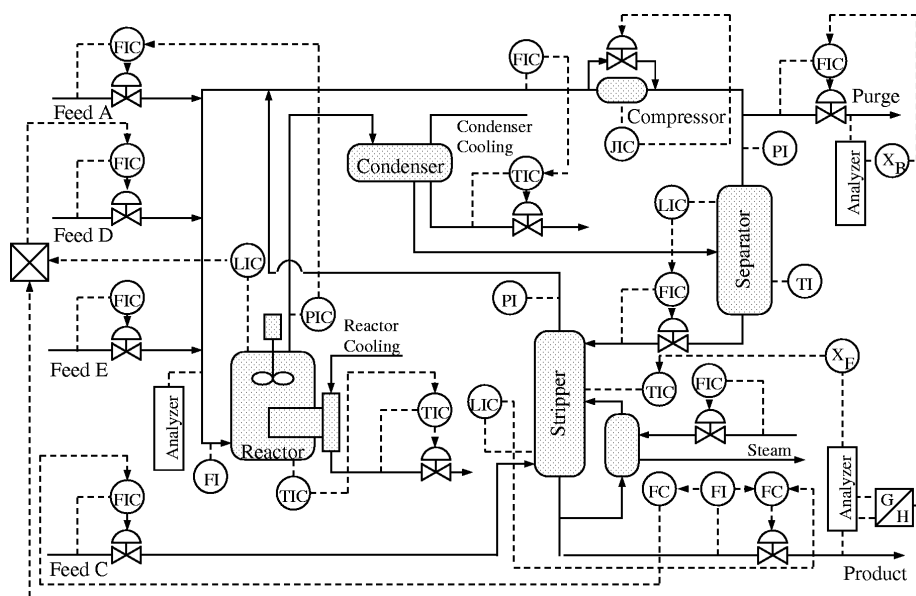


図 4.3.2 Tennessee Eastman プロセスと制御系

( 2 ) 評価方法

本報では、各監視指標の管理限界は正常運転時に管理限界を超えるサンプル数がサンプル全体の 1%となるように決定し、信頼度 (reliability) と呼ぶ指標を用いて各監視手法の評価を行う。ここで、信頼度は異常発生後のサンプルのうち管理限界を超えるサンプルの割合として定義される。今回は、異常発生後 100 ステップのデータを用いて信頼度を計算する。なお、運転監視にはオンライン測定可能な 16 変数<sup>17)</sup>を用いる。

( 3 ) 運転監視結果

従来法 (cMSPC) の適用に際しては、採用する主成分数を選択する必要がある。主成分数の選択に関しては様々な手法がある。例えば、データが標準化されている場合、1 以上の分散を持つ主成分を採用する方法がある。この適用例では、合計 6 個の主成分が 1 以上の分散を持ち、それ

らの累積寄与率は 68%である。しかし、あらゆる主成分数について信頼度を計算した結果、運転監視を目的とする場合には 11 個の主成分を用いた方が良いという結果が得られた。

MPCA の適用に際しては、主成分と共に窓幅  $w$  を選択する必要がある。各時刻での運転状態を正しく反映する主成分を得るためには十分な数のサンプルが必要であるが、過度に大きな窓幅を用いると異常検出速度が低下してしまう。数種類の窓幅を用いて検討した結果に基づいて、各主成分の変化を監視する場合には  $w=300$ 、複数の主成分が張る部分空間の変化を監視する場合には  $w=100$  とした。MPCA では監視する主成分の選択が異常検出性能に大きく影響する。A1 や A2 は多くのケースにおいて非常に良い指標であるが、いくつかのケースにおいて極端に信頼度が低くなってしまふ。一方、A1-11 はすべてのケースについて他と同等かそれ以上の信頼度を実現できている。この結果は、プロセスの運転状態を把握するために第 1 から第 11 主成分が重要であることを意味しており、先の従来法の監視結果とも一致する。さらに、A1-11 を監視指標とする MPCA の信頼度は従来法の信頼度よりも高く、MPCA が優れた手法であることを示している。一般的には、監視する変数の数が増加すると、各主成分の変化を監視するよりも複数の主成分が張る部分空間の変化を監視した方が良い結果が得られる。

DISSIM の適用に際しては、窓幅が監視性能に大きな影響を与える。この適用例では、 $w=100$  や  $w=200$  という比較的小さな窓幅を用いた場合の信頼度が低く、窓幅を 200 より大きく設定する必要がある。窓幅を 300 とした場合の信頼度は非常に高く、DISSIM が従来法よりも優れていると判断される。DISSIM の主要な設計変数は窓幅であり、従来法や MPCA のように主成分数を選択する必要はない。このため、高い運転監視性能を比較的容易に実現することができる。

ケース 3 の運転監視結果を図 4.3.3 に示す。このケースでは、原料温度がステップ 0 においてステップ状に変化している。この外乱の影響は PID 制御を用いて容易に抑え込むことができるため、監視している変数の変化は顕著でない。実際、 $Q$  を指標とした場合の信頼度は 18.9%しかなく、図 4.3.3 から従来法による早期検出は困難であることがわかる。さらに、70 ステップ以降に  $Q$  が管理限界を超えているものの、90 ステップ以降は再び管理限界内に収まっており、ステップ状変化を継続的に検出することができていない。一方、MPCA と DISSIM では異常発生後監視指標が継続的に増加傾向にあり、管理限界も超えていることから、何らかの変化が発生したことは明らかである。なお、ステップ状変化に対して監視指標が緩やかに増加するのは、監視指標の算出に窓を利用しているためである。以上の結果から、MPCA あるいは DISSIM を利用することによって、従来法よりも優れた運転監視性能を実現できることがわかる。MPCA および DISSIM が従来法では検出が困難な異常を検出することができるのは、それらの手法がデータの分布あるいは相関関係に着目しているためである。




図 4.3.3 ケース 3 の監視結果（実線：監視指標、点線：管理限界）

本報では、プロセスの動特性を考慮しない運転監視手法についてのみ検討した。しかし、データに自己相関が存在する場合、自己相関を考慮しない通常の監視方法ではフォルス・アラームが頻発するなどの弊害が生じるため、管理チャートの適用には十分な注意が必要である。自己相関を持つデータを扱う方法として、自己回帰移動平均（ARMA）モデルなどの時系列モデルを同定し、そのモデルを用いて計算される残差に管理チャートを適用する方法が一般的である。別の方法として、現時刻の測定値に加えて過去の測定値を監視変数（入力変数）とする動的モデルを利用する方法があり、その有効性も報告されている。

#### 4.3.4 異常原因の特定に向けて

異常が検出された場合、その原因を特定する必要がある。物理モデルや過去の異常発生時の運転データが利用可能な場合には、それらを利用した異常診断方法を採用することができる。しかし、そのようなモデルやデータが存在しない場合には、異常検出時の運転データから異常原因の特定に役立つ情報を抽出しなければならない。主成分分析を用いた従来型 MSPC 手法によって異常検出を行う場合、寄与プロットを利用して、管理限界を超えた監視指標への寄与が大きい変数を特定する作業が行われる<sup>9-11)</sup>。本節では、非類似度への各プロセス変数の寄与を新たに導入し、異常検出時の寄与に基づいて異常に関与しているプロセス変数を特定する方法について述べる。

従来型 MSPC 手法による異常検出を行う場合、監視指標  $Q$  への各変数の寄与は、残差の平方

として簡単に与えられる。一方、監視指標  $T^2$  への寄与は簡単には定義することができない。実際、これまでに提案されている  $T^2$  への寄与では、計算が複雑で解釈も難しくなる<sup>18)</sup>、寄与が負の値となる場合が生じる<sup>10,11)</sup>、などの問題点がある。

本報では、非類似度への各プロセス変数の寄与を以下の手順で導出する。まず、式(4.3.2)に基づいて、非類似度へ最も寄与する固有値 1 を求める。次に、変換後データ行列の第 1 主成分得点が元の変数の線形結合で表現できることに注意して、各変数の第 1 主成分得点への寄与を求める。新たに定義した、非類似度への各変数の寄与の有用性を検証するとともに、従来法で用いられる寄与との比較を行うために、図 4.3.3 と同じケース 3 の運転データから寄与を計算した結果を図 4.3.4, 4.3.5 に示す。これらの図において、異常が検出されていない時刻における寄与はゼロとしている。なお、ケース 3 の外乱は  $T^2$  統計量よりもむしろ  $Q$  統計量によって検出される。したがって、従来法については  $Q$  統計量への寄与のみを示している。 $Q$  統計量への寄与が大きな変数は  $x_7, x_{13}, x_{15}$  である。これらの 3 変数はいずれも温度であり、系内の温度に関連する異常が発生していることを示している。一方、非類似度  $D$  への寄与が大きな変数は  $x_9, x_{12}, x_{13}, x_{15}$  である。このうち  $x_9, x_{13}, x_{15}$  は温度であり、やはり系内の温度に関連する異常が発生していると考えられる。実際に付加された外乱は原料温度のステップ状変化であるため、寄与プロットから得られた情報は異常原因について検討する上で有用であると言える。なお、 $x_{12}$  は精留装置の圧力であるが、これも温度変化が圧力に影響を与えたと解釈できる。

ただし、寄与プロットから原料温度の変化が異常原因であると断定することはできない。異常原因を特定するためには、寄与プロットから得られる情報だけでなく、プロセスに関する知識を利用する必要がある。特に、ここで対象とした Tennessee Eastman プロセスはリサイクル流れを有するとともに、数多くの制御ループが存在するため、測定変数は複雑に影響し合っている。このため、寄与プロットだけを用いて異常原因を特定することは困難であり、またそれを望むべきでもないと思われる。さらに、今回は操作変数を監視変数として利用していないことも指摘しておく必要がある。フィードバック制御の効果により、外乱の影響は制御量ではなく操作量に顕著に現れる。したがって、操作変数を監視変数として用いることにより、有益な情報を得ることができると思われる。

本報では示していないが、単純な 4 変数系のシミュレーションデータを用いて、提案した寄与プロットによる異常に関与した変数の特定を行った結果、異常が発生した変数を正確に特定することができた。この結果は、非類似度への各変数の寄与が異常変数の特定に有効な情報を与えることを示している。Tennessee Eastman プロセスのような大規模プロセスを監視対象とする場合には、各装置ごとに異常検出を行い、異常が検出された装置に関連する変数のみを対象として寄与プロットを描くことにより、異常変数の特定を容易に行える場合もあると考えられる。



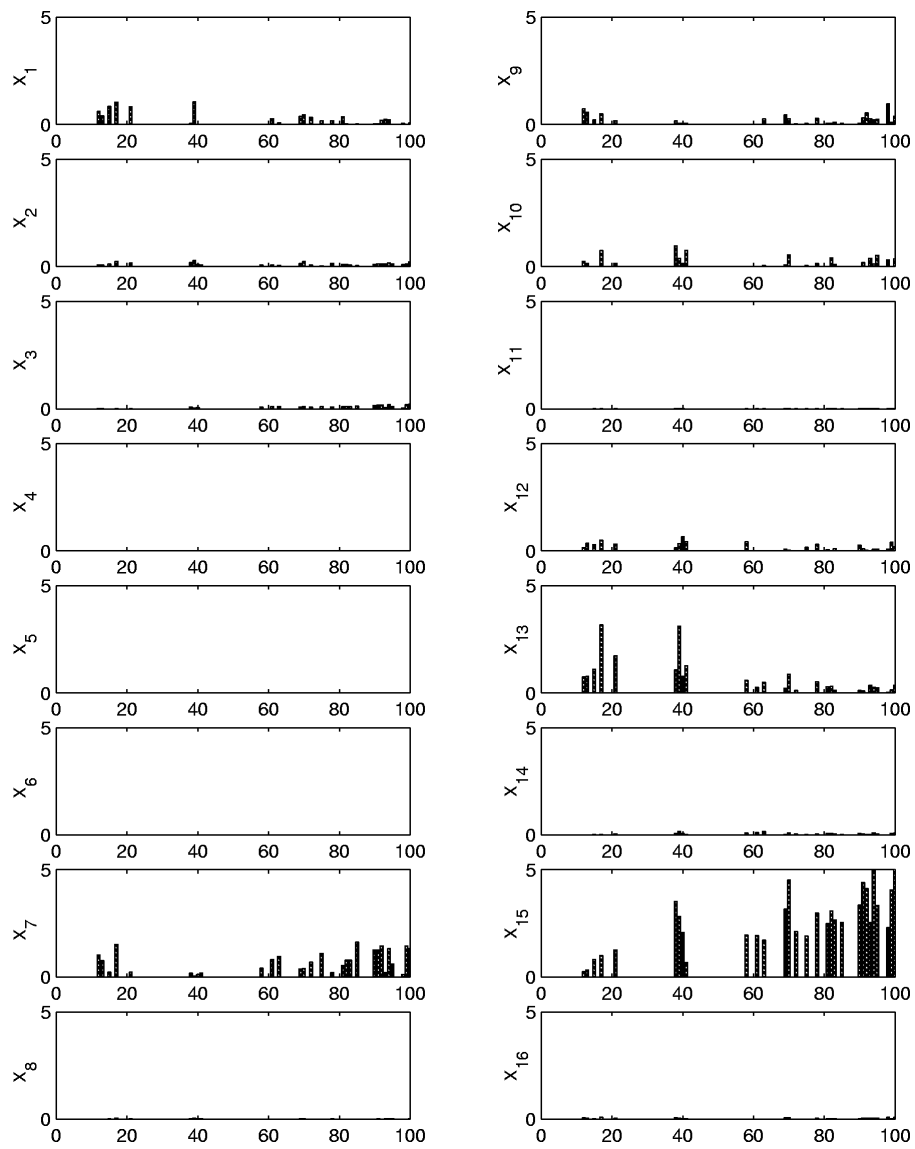


図 4.3.4 Q の寄与プロット ( ケース 3 )




図 4.3.5 D の寄与プロット ( ケース 3 )

#### 4.3.5 結言

主成分分析を用いた従来の運転監視手法と新たに提案した 2 種類の運転監視手法を Tennessee Eastman プロセスに適用し、運転監視性能を比較すると共に各手法の特徴について検討した。

新手法である MPCCA と DISSIM は従来法よりも優れた運転監視性能を示した。MPCCA と DISSIM は変数の相関関係あるいはデータの分布に着目した手法であるため、従来の監視指標である  $T^2$  や  $Q$  が管理限界を超えないような小さな変化をも検出することができる。MPCCA では主成分を逐次求めるために、DISSIM では各時刻の運転状態を代表する運転データを得るために、ある幅を持つ窓が利用される。この窓の利用による平滑化効果のため、監視指標は比較的緩やかに変化する。この結果、異常検出が容易になる反面、検出が遅れるという欠点もある。しかし、

窓幅を適切に調節することにより、優れた運転監視性能を実現することは可能である。また、MPCA を適用する際には監視する主成分の選択が必要であり、かつその選択が監視結果に多大な影響を与えるが、DISSIM では主成分を選択する必要がない。この観点から、DISSIM は設計が容易で実用的な手法であると考えられる。

さらに本報では、監視指標である非類似度への各変数の寄与を新たに定義し、異常検出時に計算される各変数の寄与に基づいて、発生した異常に関連する変数を特定する方法を示した。ただし、複雑かつ大規模なプロセスを監視対象とする場合には、寄与プロットから得られる情報のみに基づいて異常原因を特定することはできず、プロセスに関する知識を併用する必要がある。

#### 引用文献

- 1) J. E. Jackson and G. S. Mudholkar: "Control procedures for residuals associated with principal component analysis", *Technometrics*, Vol.21, pp.341-349 (1979)
- 2) J. E. Jackson: "Principal components and factor analysis: Part I -- principal components", *J. of Quality Technology*, Vol.12, pp.201-213 (1980)
- 3) M. Wise and N. B. Gallagher: "The process chemometrics approach to process monitoring and fault detection", *J. Proc. Cont.*, Vol.6, pp.329-348 (1996)
- 4) J. V. Kresta, J. F. MacGregor, and T. E. Marlin: "Multivariate statistical monitoring of process operating performance", *Can. J. Chem. Eng.*, Vol.69, pp.35-47 (1991)
- 5) P. Nomikos and J. F. MacGregor: "Monitoring batch processes using multiway principal component analysis", *AIChE J.*, Vol.40, pp.1361-1375 (1994)
- 6) P. Nomikos and J. F. MacGregor: "Multivariate SPC charts for monitoring batch processes", *Technometrics*, Vol.37, pp.41-59 (1995)
- 7) W. Ku, R. H. Storer, and C. Georgakakis: "Disturbance detection and isolation by dynamic principal component analysis", *Chemometrics and intelligent laboratory systems*, Vol.30, pp.179-196 (1995)
- 8) J. F. MacGregor, C. Jaeckle, C. Kiparissides, and M. Koutoudi: "Process monitoring and diagnosis by multiblock methods", *AIChE J.*, Vol.40, pp.826-838 (1994)
- 9) P. Miller, R. E. Swanson, and C. E. Heckler: "Contribution plots: a missing link in multivariate quality control", *Appl. Math. and Comp. Sci.*, Vol.8, pp.775-792 (1998)
- 10) P. Nomikos: "Detection and diagnosis of abnormal batch operations based on multi-way principal component analysis", *ISA Transactions*, Vol.35, pp.259-266 (1996)
- 11) J. A. Westerhuis, S. P. Gurden, and A. K. Smilde: "Generalized contribution plots in

- multivariate statistical process monitoring”, *Chemometrics and Intelligent Laboratory Systems*, Vol.51, pp.95-114 (2000)
- 12) Manabu Kano, Hiromu Ohno, Shinji Hasebe, and Iori Hashimoto: “A New Multivariate Statistical Process Monitoring Method Using Principal Component Analysis”, *Computers & Chemical Engineering* (印刷中)
- 13) Manabu Kano, Hiromu Ohno, Shinji Hasebe, and Iori Hashimoto: “Statistical Process Monitoring Based on Dissimilarity of Process Data”, *AIChE J.* (投稿中)
- 14) S. J. Qin, W. Li, and H. H. Yue: “Recursive PCA for adaptive process monitoring”, *Proc. of IFAC World Congress*, Vol.N, pp.85-90, Beijing, P. R. China. (1999)
- 15) J. J. Downs and E. F. Vogel: “A plant-wide industrial process control problem”, *Computers chem. Engng*, Vol.17, pp.245-255 (1993)
- 16) T. J. McAvoy and N. Ye: “Base control for the Tennessee Eastman problem”, *Computers chem. Engng*, Vol.18, pp.383-413 (1994)
- 17) G. Chen and T. J. McAvoy: “Predictive on-line monitoring of continuous processes”, *J. Proc. Cont.*, Vol.8, pp.409-420 (1998)
- 18) R. L. Mason, N. D. Tracy, and J. C. Young: “Decomposition of T2 for multivariate control chart interpretation”, *J. of Quality Technology*, Vol.27, pp.99-108 (1995)

< 本研究に関する研究発表 >

(1)学会誌等

- 1) 加納学、長尾浩二、大野弘、長谷部伸治、橋本伊織: “移動主成分分析を用いた運転監視”, *化学工学論文集*, 第25巻、第6号、pp.998-1003 (1999)
- 2) 加納学、大野弘、長谷部伸治、橋本伊織: “時系列データの非類似度に基づく運転監視”, *化学工学論文集*, 第25巻、第6号、pp.1004-1009 (1999)
- 3) 加納学、大野弘、長谷部伸治、橋本伊織: “新しい統計的プロセス管理手法の化学プロセスへの適用”, *計測自動制御学会論文集*, 第37巻、第2号、pp.160-167 (2001)
- 4) Manabu Kano, Koji Nagao, Hiromu Ohno, Shinji Hasebe, Iori Hashimoto, Ramon Strauss, and Bhavik R. Bakshi: “Comparison of Statistical Process Monitoring Methods: Application to the Eastman Challenge Problem”, *Computers & Chemical Engineering*, Vol.24, Nos.2-7, pp.175-181 (2000)
- 5) Manabu Kano, Hiromu Ohno, Shinji Hasebe, and Iori Hashimoto: “A New Multivariate Statistical Process Monitoring Method Using Principal Component Analysis”, *Computers*

& Chemical Engineering (印刷中)

- 6) Manabu Kano, Hiromu Ohno, Shinji Hasebe, and Iori Hashimoto: “Statistical Process Monitoring Based on Dissimilarity of Process Data”, AICHE J. (投稿中)

(2)口頭発表

- 1) Manabu Kano, Koji Nagao, Hiromu Ohno, Shinji Hasebe, and Iori Hashimoto: “New Methods for Process Monitoring Using Principal Component Analysis”, AICHE Annual Meeting, Dallas, TX, Oct. 31-Nov. 5 (1999)
- 2) Manabu Kano, Koji Nagao, Hiromu Ohno, Shinji Hasebe, and Iori Hashimoto: “Dissimilarity of process data for statistical process monitoring”, IFAC Symposium on Advanced Control of Chemical Processes (ADCHEM), Pisa, Italy, June 14-16 (2000)
- 3) Manabu Kano, Hiromu Ohno, Shinji Hasebe, Iori Hashimoto, Ramon Strauss, and Bhavik R. Bakshi: “Contribution Plots for Fault Identification Based on the Dissimilarity of Process Data”, AICHE Annual Meeting, Los Angeles, CA, Nov. 12-17 (2000)
- 4) Natthaphon Showchaiya, Manabu Kano, Shinji Hasebe, and Iori Hashimoto, “Predictive Inferential Control of Distillation Compositions”: International Symposium on Design, Operation and Control of Next Generation Chemical Plants (PSE Asia 2000), Kyoto, Japan, Dec. 6-8 (2000)