

(19) 日本国特許庁(JP)

(12) 公開特許公報(A)

(11) 特許出願公開番号

特開2021-149727

(P2021-149727A)

(43) 公開日 令和3年9月27日(2021.9.27)

(51) Int.Cl.	F I	テーマコード (参考)
<b>G05B 23/02 (2006.01)</b>	G05B 23/02 302Y	3C223

審査請求 未請求 請求項の数 3 O L (全 11 頁)

(21) 出願番号 特願2020-50564 (P2020-50564)  
 (22) 出願日 令和2年3月23日 (2020.3.23)

(71) 出願人 00005326  
 本田技研工業株式会社  
 東京都港区南青山二丁目1番1号  
 (74) 代理人 100154380  
 弁理士 西村 隆一  
 (74) 代理人 100081972  
 弁理士 吉田 豊  
 (72) 発明者 井手 隼人  
 栃木県芳賀郡芳賀町芳賀台6番地1 ホン  
 ダエンジニアリング株式会社内  
 Fターム(参考) 3C223 AA12 BA01 CC01 FF04 FF22  
 FF26 FF45 GG01 HH02

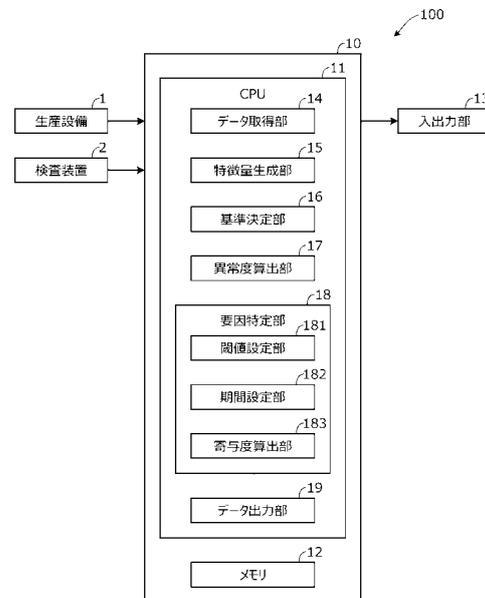
(54) 【発明の名称】 要因分析装置および要因分析方法

(57) 【要約】

【課題】設備で加工不良が発生する要因を精度よく特定する。

【解決手段】生産設備1で加工不良が発生する要因を特定する要因分析装置10は、生産設備1で加工不良が発生した加工不良発生時を含む監視期間に検出された生産設備1の稼働状態を示す複数のパラメータの時系列データを取得するデータ取得部14と、取得された時系列データに基づいて複数のパラメータの代表値としての複数の特徴量を生成する特徴量生成部15と、生成された複数の特徴量に基づいて生産設備1の稼働状態が異常であるか否かを判定する判定基準を決定する基準決定部16と、決定された判定基準に基づいて生産設備1の稼働状態の異常の頻度を示す異常度を算出する異常度算出部17と、算出された異常度に基づいて複数の特徴量の中から生産設備1で加工不良が発生する要因となる特徴量を特定する要因特定部18とを備える。

【選択図】 図3



**【特許請求の範囲】****【請求項 1】**

設備で加工不良が発生する要因を特定する要因分析装置であって、

前記設備で加工不良が発生した加工不良発生時を含む監視期間に検出された前記設備の稼働状態を示す複数のパラメータの時系列データを取得するデータ取得部と、

前記データ取得部により取得された時系列データに基づいて、前記複数のパラメータの代表値としての複数の特徴量を生成する特徴量生成部と、

前記特徴量生成部により生成された複数の特徴量に基づいて、前記設備の稼働状態が異常であるか否かを判定する判定基準を決定する基準決定部と、

前記基準決定部により決定された判定基準に基づいて、前記設備の稼働状態の異常の頻度を示す異常度を算出する異常度算出部と、

前記異常度算出部により算出された異常度に基づいて、前記特徴量生成部により生成された複数の特徴量の中から前記設備で加工不良が発生する要因となる特徴量を特定する要因特定部と、を備えることを特徴とする要因分析装置。

10

**【請求項 2】**

請求項 1 に記載の要因分析装置において、

前記要因特定部は、

前記データ取得部により取得された時系列データと、前記異常度算出部により算出された異常度と、に基づいて、前記設備の稼働状態が正常から異常に移行するときの異常度の閾値を設定する閾値設定部と、

20

前記閾値設定部により設定された閾値に基づいて、前記設備の稼働状態が正常から異常に移行する直前の期間を設定する期間設定部と、

前記特徴量生成部により生成された複数の特徴量のそれぞれについて、前記期間設定部により設定された期間における異常度に対する寄与度を算出する寄与度算出部と、を有することを特徴とする要因分析装置。

**【請求項 3】**

設備で加工不良が発生する要因を特定する要因分析方法であって、

前記設備で加工不良が発生した加工不良発生時を含む監視期間に検出された前記設備の稼働状態を示す複数のパラメータの時系列データを取得するデータ取得ステップと、

前記データ取得ステップで取得された時系列データに基づいて、前記複数のパラメータの代表値としての複数の特徴量を生成する特徴量生成ステップと、

30

前記特徴量生成ステップで生成された複数の特徴量に基づいて、前記設備の稼働状態が異常であるか否かを判定する判定基準を決定する基準決定ステップと、

前記基準決定ステップで決定された判定基準に基づいて、前記設備の稼働状態の異常の頻度を示す異常度を算出する異常度算出ステップと、

前記異常度算出ステップで算出された異常度に基づいて、前記特徴量生成ステップで生成された複数の特徴量の中から前記設備で加工不良が発生する要因となる特徴量を特定する要因特定ステップと、を含むことを特徴とする要因分析方法。

**【発明の詳細な説明】****【技術分野】**

40

**【0001】**

本発明は、設備で加工不良が発生する要因を分析する要因分析装置および要因分析方法に関する。

**【背景技術】****【0002】**

従来より、各種機械や装置を含む設備に発生する異常を検知するようにした装置が知られている（例えば、特許文献 1 参照）。特許文献 1 記載の装置では、設備を監視して得られた状態値から特徴量を生成するとともに、統計的な処理により仮想の特徴量を生成し、これらの特徴量に基づいて、設備に発生する異常を検知するための異常検知モデルを生成する。

50

【先行技術文献】

【特許文献】

【0003】

【特許文献1】特開2019-159902号公報

【発明の概要】

【発明が解決しようとする課題】

【0004】

しかしながら上記特許文献1記載の装置では、実際に設備で加工不良が発生する前の仮想の特微量に基づいて異常検知モデルを生成するため、設備で加工不良が発生する要因を精度よく特定することが難しい。

10

【課題を解決するための手段】

【0005】

本発明の一態様は、設備で加工不良が発生する要因を特定する要因分析装置であって、設備で加工不良が発生した加工不良発生時を含む監視期間に検出された設備の稼働状態を示す複数のパラメータの時系列データを取得するデータ取得部と、データ取得部により取得された時系列データに基づいて、複数のパラメータの代表値としての複数の特微量を生成する特微量生成部と、特微量生成部により生成された複数の特微量に基づいて、設備の稼働状態が異常であるか否かを判定する判定基準を決定する基準決定部と、基準決定部により決定された判定基準に基づいて、設備の稼働状態の異常の頻度を示す異常度を算出する異常度算出部と、異常度算出部により算出された異常度に基づいて、特微量生成部により生成された複数の特微量の中から設備で加工不良が発生する要因となる特微量を特定する要因特定部と、を備える。

20

【0006】

本発明の他の態様は、設備で加工不良が発生する要因を特定する要因分析方法であって、設備で加工不良が発生した加工不良発生時を含む監視期間に検出された設備の稼働状態を示す複数のパラメータの時系列データを取得するデータ取得ステップと、データ取得ステップで取得された時系列データに基づいて、複数のパラメータの代表値としての複数の特微量を生成する特微量生成ステップと、特微量生成ステップで生成された複数の特微量に基づいて、設備の稼働状態が異常であるか否かを判定する判定基準を決定する基準決定ステップと、基準決定ステップで決定された判定基準に基づいて、設備の稼働状態の異常の頻度を示す異常度を算出する異常度算出ステップと、異常度算出ステップで算出された異常度に基づいて、特微量生成ステップで生成された複数の特微量の中から設備で加工不良が発生する要因となる特微量を特定する要因特定ステップと、を含む。

30

【発明の効果】

【0007】

本発明によれば、設備で加工不良が発生する要因を精度よく特定することができる。

【図面の簡単な説明】

【0008】

【図1】本発明の実施形態に係る要因分析装置が適用される生産工程の一例を模式的に示す概略図。

40

【図2A】図1の生産設備の稼働状態を示す時系列データの一例を示す図。

【図2B】加工期間ごとに管理される図2Aの時系列データの一例を示す図。

【図3】本発明の実施形態に係る要因分析装置を含む要因分析システムの全体構成を示すブロック図。

【図4A】図3の基準決定部により決定される判定基準に基づく判定結果の一例を示す図。

【図4B】図4Aの部分拡大図。

【図5A】図3の異常度算出部により算出される異常度の一例を示す図。

【図5B】図5Aの部分拡大図。

【図6】値およびカーネル関数の値の設定を変更したときの、図3の異常度算出部に

50

より算出された異常度の一例を示す図。

【図7】図3の閾値設定部による閾値の設定について説明するための図。

【図8】図3の寄与度算出部による回帰分析の結果の一例を示す図。

【図9】図3の寄与度算出部により算出される寄与度の一例を示す図。

【図10】本発明の実施形態に係る要因分析装置により実行される処理の一例を示すフローチャート。

【発明を実施するための形態】

【0009】

以下、図1～図10を参照して本発明の実施形態について説明する。図1は、本発明の実施形態に係る要因分析装置が適用される生産工程の一例を模式的に示す概略図であり、

10

【0010】

生産設備1と検査装置2とは、制御盤などの設備コントローラ3に接続され、検査装置2によりワークW<sub>n</sub>の切断不良などの加工不良の発生が検知されると、設備コントローラ3を介して加工不良の発生が報知され、必要に応じて生産設備1が停止される。生産設備1には、レーザの焦点距離やコンペアCの搬送速度など生産設備1の稼働状態を示す複数のパラメータを連続的に検出する複数のセンサが設けられる。

20

【0011】

図2Aおよび図2Bは、生産設備1の稼働状態を示す時系列データについて説明するための図である。図2Aは、生産設備1の稼働状態を示す複数のパラメータの時系列データの一例を示す図である。図2Aに示すように、生産設備1の稼働状態を示す複数(例えば、7個)のパラメータX<sub>1</sub>～X<sub>7</sub>の検出結果は、n個(例えば、5000個)のワークW<sub>n</sub>のそれぞれを加工するときの加工期間T<sub>n</sub>ごとの時系列データとして管理される。

【0012】

図2Aに示すように、各ワークW<sub>n</sub>の加工期間T<sub>n</sub>には、検査装置2による加工不良の検知結果が関連付けられる。例えば、検査装置2により5000番目のワークW<sub>5000</sub>の加工不良が検知されると、加工期間T<sub>5000</sub>における生産設備1の稼働状態で加工不良が発生したものと、加工期間T<sub>5000</sub>が加工不良発生時として管理される。

30

【0013】

図2Aに示す時系列データは、n個の加工期間T<sub>n</sub>ごとに管理することもできる。例えば、図2Bに示すように、検査装置2による加工不良の検知結果を、n個(例えば、5千個)の加工期間T<sub>n</sub>ごとの時系列データとして管理することができる。同様に、加工期間T<sub>n</sub>ごとのパラメータX<sub>1</sub>～X<sub>7</sub>の平均値や標準偏差などを、各加工期間T<sub>n</sub>を代表する特徴量として算出し、加工期間T<sub>n</sub>ごとの時系列データとして管理することができる。

【0014】

このように、生産設備1の稼働状態を示す特徴量を加工期間T<sub>n</sub>ごとの時系列データとして管理することで、図2Bに破線で示すような加工不良発生時の生産設備1の稼働状態を把握することができる。しかしながら、図2Bに示すように、ワークW<sub>n</sub>の加工不良が発生する頻度は極めて低いため(例えば、5千個のうち5個)、生産設備1で加工不良が発生する要因を特定することは難しい。そこで、本実施形態では、生産設備1で加工不良が発生する要因を精度よく特定できるよう、以下のように要因分析装置を構成する。

40

【0015】

図3は、本発明の実施形態に係る要因分析装置(以下、装置)10を含む要因分析システム100の全体構成を示すブロック図である。図3に示すように、要因分析システム100は、生産設備1と、検査装置2と、装置10とを有する。

【0016】

50

装置10は、CPU11、ROM、RAMなどのメモリ12、およびI/Oその他の周辺回路などを有するコンピュータを含んで構成されるとともに、キーボードやマウス、タッチパネル、液晶ディスプレイなどの入出力部13を有する。CPU11は、データ取得部14と、特徴量生成部15と、基準決定部16と、異常度算出部17と、要因特定部18と、データ出力部19として機能する。

#### 【0017】

データ取得部14は、生産設備1で加工不良が発生した加工不良発生時を含む監視期間における、検査装置2による加工不良の検知結果およびパラメータ $X_1 \sim X_7$ の時系列データを取得する。例えば、図2Bに示すように、5千個のワーク $W_n$ のうち5個に加工不良が発生した場合の監視期間として、加工期間 $T_1 \sim T_{5000}$ におけるパラメータ $X_1 \sim X_7$ の時系列データを取得する。データ取得部14により取得されたパラメータ $X_1 \sim X_7$ の時系列データは、メモリ12に記憶される。

10

#### 【0018】

特徴量生成部15は、データ取得部14により取得されたパラメータ $X_1 \sim X_7$ の時系列データに基づいて、加工期間 $T_n$ ごとの特徴量 $X(n)$ を生成する。具体的には、先ず、各パラメータ $X_1 \sim X_7$ の時系列データを加工期間 $T_n$ ごとに分割し、加工期間 $T_n$ ごとに複数(例えば、7個)のデータセットを生成する。

#### 【0019】

次いで、図2Aに示すように、各加工期間 $T_n$ を分割(例えば、8分割)した分割期間 $S_1 \sim S_8$ ごとに各データセットを分割し、加工期間 $T_n$ ごとに複数(例えば、 $7 \times 8$ 個)のデータセットを生成する。さらに、各データセットについて平均値や標準偏差などの複数通り(例えば、7通り)の代表値を算出し、加工期間 $T_n$ ごとに複数(例えば、 $7 \times 8 \times 7$ 個)の特徴量を生成する。

20

#### 【0020】

換言すると、特徴量生成部15は、加工期間 $T_n$ ごとに多次元(例えば、 $7 \times 8 \times 7$ 次元)の特徴量 $X(n)$ を生成する。すなわち、パラメータ $X_1$ の分割期間 $S_1$ の平均値である特徴量 $X_{1\_S1\_AVE}$ などの複数(例えば、 $7 \times 8 \times 7$ 個)の特徴量を成分とする多次元(例えば、 $7 \times 8 \times 7$ 次元)の特徴量 $X(n)$ を生成する。特徴量生成部15により生成された特徴量 $X(n)$ は、メモリ12に記憶される。

#### 【0021】

基準決定部16は、特徴量生成部15により生成された多次元の特徴量 $X(n)$ に基づいて、生産設備1の稼働状態が異常であるか否かを判定する判定基準を決定する。例えば、多次元のデータセットでの異常検知に適したOC SVM (One-Class Support Vector Machine)などの学習モジュールを用いて、生産設備1の稼働状態が異常であるか否かを判定するための判定モデルを生成する。すなわち、図2Bに示すような5個が異常、4995個が正常である5千個の特徴量 $X(1) \sim X(5000)$ からなるデータセットを学習し、生産設備1の稼働状態が異常であるか否かを判定するための判定モデルを生成する。

30

#### 【0022】

より具体的には、基準決定部16は、特徴量 $X(n)$ の次元(例えば、 $7 \times 8 \times 7$ 次元)に対応する多次元空間において、各特徴量 $X(n)$ が異常であるか正常であるかを識別するための識別境界 $T_h$ を設定する。OC SVM学習モジュールによる学習を行う場合、基準決定部16は、 $\gamma$ 値およびカーネル関数 $k(\gamma)$ などのパラメータを含む $\gamma$ を設定する。 $\gamma$ 値は、多次元空間の原点 $O$ に対する識別境界 $T_h$ の位置を規定し、 $\gamma$ 値が大きいほど異常と判定される特徴量 $X(n)$ が多くなる。また、カーネル関数 $k$ を例えばRBFカーネル(The Gaussian RBF kernel。動径基底関数)とする場合、カーネル関数 $k$ の $\gamma$ 値は、識別境界 $T_h$ の形状を規定する。なお、カーネル関数 $k$ は、RBFカーネル関数に限らない。

40

#### 【0023】

換言すると、識別境界 $T_h$ を用いて、特定の加工期間 $T_n$ に対応する多次元の特徴量 $X(n)$ を構成する複数の特徴量の組み合わせが、他の加工期間と比較して統計的に逸脱し

50

、生産設備 1 の稼働状態が異常であるか否かが判定される。すなわち、実際には加工不良が発生しなかった場合も含め、生産設備 1 の稼働状態が異常であるか否かが判定される。また、 $\theta$  値を用いて、特徴量  $X(1) \sim X(5000)$  に対応する加工期間  $T_1 \sim T_{5000}$  のうち、異常と判定される加工期間  $T_n$  の割合が調整される。

#### 【0024】

図 4 A , 4 B は、基準決定部 16 により決定される判定基準に基づく判定結果の一例を示す図であり、特徴量  $X(n)$  の 1 成分である特徴量  $X_{1\_S1\_AVE}(n)$  の値を、判定結果が異常の場合は白プロットで示し、判定結果が異常の場合は黒プロットで示す。図 4 A , 4 B に示すように、特徴量  $X(n)$  は、実際に生産設備 1 で加工不良が発生した 5 回の加工不良発生時（図 4 A , 4 B に破線で示す）以外にも、異常であると判定される。基準決定部 16 により決定された判定基準（ $\theta$  値およびカーネル関数  $k$  の  $\theta$  値）は、メモリ 12 に記憶される。

10

#### 【0025】

異常度算出部 17 は、基準決定部 16 により決定された判定基準に基づく判定結果について、異常の場合は“1”、正常の場合は“0”として、指数移動平均などにより積算し、時系列性を考慮した異常度  $p(n)$  を算出する。すなわち、基準決定部 16 により決定された判定基準に基づいて加工期間  $T_n$  ごとの特徴量  $X(n)$  が異常であると判定される頻度を示す異常度  $p(n)$  を算出する。異常度算出部 17 により算出された異常度  $p(n)$  は、メモリ 12 に記憶される。なお、指数移動平均に代えて加重移動平均などにより異常度  $p(n)$  を算出してもよい。

20

#### 【0026】

図 5 A , 5 B は、異常度算出部 17 により算出される異常度  $p(n)$  の一例を示す図である。図 5 A , 5 B に破線で示すように、実際に生産設備 1 で加工不良が発生した 5 回の加工不良発生時に対応して、加工期間  $T_n$  ごとの特徴量  $X(n)$  が異常であると判定される頻度を示す異常度  $p(n)$  が高まっている。このように実際の加工不良発生時に対応して異常度  $p(n)$  が高まる期間に着目すれば、ノイズの影響を受けずに、生産設備 1 で加工不良が発生する要因を特定することができる。

#### 【0027】

データ出力部 19 は、図 5 A , 5 B に示すような加工期間  $T_n$  ごとの異常度  $p(n)$  のチャートを液晶ディスプレイなどの入出力部 13 に表示するための表示制御信号を生成して出力する。図 6 は、基準決定部 16 により設定される  $\theta$  値およびカーネル関数  $k$  の  $\theta$  値を変更したときの、異常度算出部 17 により算出される異常度  $p(n)$  の一例を示す図であり、入出力部 13 に表示された異常度  $p(n)$  のチャートを示す。

30

#### 【0028】

図 6 に示すように、 $\theta$  値およびカーネル関数  $k$  の  $\theta$  値が変化すると、識別境界  $T_h$  および加工期間  $T_n$  ごとの特徴量  $X(n)$  の判定結果が変化することで、判定結果を積算した異常度  $p(n)$  のチャートの形状が変化する。図 6 の例では、 $\theta$  値を 0.10、カーネル関数  $k$  の  $\theta$  値を 0.1 に設定した場合の異常度  $p(n)$  のチャートにおいて、破線で示す実際の加工不良発生時に対応するピークの形状がノイズ成分から分離されてシャープになっている。基準決定部 16 は、 $\theta$  値およびカーネル関数  $k$  の  $\theta$  値を変更したときの異常度  $p(n)$  のチャートを実際の加工不良発生時と比較し、例えば予め定められたピーク形状とのパターンマッチングにより  $\theta$  値およびカーネル関数  $k$  の  $\theta$  値を決定する。

40

#### 【0029】

要因特定部 18 は、基準決定部 16 により決定された判定基準（ $\theta$  値およびカーネル関数  $k$  の  $\theta$  値）に基づいて異常度算出部 17 により算出された異常度  $p(n)$  に基づいて、生産設備 1 で加工不良が発生する要因となる特徴量を特定する。すなわち、特徴量  $X(n)$  を構成する複数の特徴量の中から、異常度  $p(n)$  が高まる要因となる特徴量を特定する。要因特定部 18 は、機能的構成として、閾値設定部 181 と、期間設定部 182 と、寄与度算出部 183 とを有する。

#### 【0030】

50

図7は、閾値設定部181による閾値 $p_0$ の設定について説明するための図である。閾値設定部181は、生産設備1の稼働状態が正常から異常に移行するときの異常度 $p(n)$ の閾値 $p_0$ を設定する。具体的には、閾値設定部181は、異常度 $p(n)$ のチャートを実際の加工不良発生時と比較し、破線で示す実際の加工不良発生時に対応する異常度 $p(n)$ のピークの極大値がノイズ成分から分離されるように閾値 $p_0$ を設定する。例えば、異常度 $p(n)$ の複数のピークの極大値のうちの最小値を閾値 $p_0$ として設定する。

#### 【0031】

期間設定部182は、閾値設定部181により設定された閾値 $p_0$ に基づいて、生産設備1の稼働状態が正常から異常に移行する直前の期間 $t_1 \sim t_7$ を設定する。換言すると、異常度 $p(n)$ が閾値 $p_0$ を超えて高まる期間 $t_1 \sim t_7$ が設定される。より具体的には、期間設定部182は、極大値が閾値 $p_0$ を超えるすべてのピークについて、例えばピークの直前の閾値 $p_0$ からピークの極大値までの期間 $t_1 \sim t_7$ を設定する。あるいは、各ピークの極大値に至る直前数回（例えば、5回）の加工期間 $T_n$ を期間 $t_1 \sim t_7$ として設定してもよい。

10

#### 【0032】

寄与度算出部183は、特徴量 $X(n)$ の各成分について、期間設定部182により設定された期間 $t_1 \sim t_7$ における異常度 $p(n)$ に対する寄与度 $R_c$ を算出する。具体的には、寄与度算出部183は、監視期間におけるすべての特徴量 $X(1) \sim X(5000)$ から期間 $t_1 \sim t_7$ の特徴量 $X(n)$ を抽出し、特徴量 $X(n)$ の各成分についてLasso回帰などの回帰分析（重回帰分析）を行う。

20

#### 【0033】

図8は、寄与度算出部183による回帰分析の結果の一例を示す図であり、回帰分析により得られた予測異常度 $p(n) < \hat{\ } >$ と実際の異常度 $p(n)$ との相関関係を示す。図8に示すような予測異常度 $p(n) < \hat{\ } >$ に対応して、特徴量 $X(n)$ の各成分の回帰係数（標準偏回帰係数）が算出される。寄与度算出部183は、回帰分析により得られた回帰係数の絶対値を、特徴量 $X(n)$ の各成分の寄与度 $R_c$ として算出する。なお、Lasso回帰に代えて、ランダムフォレストやXGBoostなどにより寄与度 $R_c$ を算出してもよい。

#### 【0034】

図9は、寄与度算出部183により算出される、特徴量 $X(n)$ の各成分の寄与度 $R_c$ の一例を示す図であり、寄与度 $R_c$ の高い上位10成分を示す。異常度 $p(n)$ が閾値 $p_0$ を超えて高まる期間 $t_1 \sim t_7$ （図7）の特徴量 $X(n)$ を抽出して回帰分析を行い、各成分の寄与度 $R_c$ を算出するため、異常度 $p(n)$ の高まりに対する寄与度 $R_c$ の高い成分を特定することができる。すなわち、特徴量 $X(n)$ を構成する複数の成分の中から、生産設備1で加工不良が発生する要因となる成分を特定することができる。また、図9に示すような寄与度 $R_c$ の高い上位の成分のみに絞り込んだ特徴量 $X(n)$ を用いて判定モデルを再生成（再学習）することで、過学習を防ぎ、判定モデルの汎化性能を高めることができる。

30

#### 【0035】

図10は、装置10により実行される処理の一例を示すフローチャートであり、予めメモリ12に記憶されたプログラムに従い、CPU11で実行される処理の一例を示す。図10のフローチャートに示す処理は、例えば、生産設備1および検査装置2から装置10に生産設備1の稼働状態を示す時系列データが入力されると開始される。

40

#### 【0036】

図10に示すように、まずステップS1で、生産設備1および検査装置2から入力された監視期間の時系列データを取得する。次いでステップS2で、ステップS1で取得された時系列データに基づいて加工期間 $T_n$ ごとの多次元の特徴量 $X(n)$ を生成する。次いでステップS3で、ステップS2で生成された加工期間 $T_n$ ごとの特徴量 $X(n)$ を学習データとして、生産設備1の稼働状態が異常であるか否かを判定するための判定モデルを生成する。

50

## 【0037】

次いでステップS4で、ステップS3で決定された判定モデルを用いて、ステップS2で生成された加工期間 $T_n$ ごとの特徴量 $X(n)$ についての異常判定を行う。次いでステップS5で、ステップS4の異常判定の結果を積算して異常度 $p(n)$ を算出する。次いでステップS6で、ステップS5で算出された異常度 $p(n)$ のチャートの形状が適切であるか否かを判定する。

## 【0038】

ステップS6で否定されると、ステップS3に戻って判定モデルの設定を変更する。一方、ステップS6で肯定されるとステップS7に進み、ステップS5で算出された異常度 $p(n)$ のチャートを実際の加工不良発生時と比較して異常度 $p(n)$ の閾値 $p_0$ を設定する。次いでステップS8で、ステップS7で設定された閾値 $p_0$ に基づいて、回帰分析の対象期間を設定する。

## 【0039】

次いでステップS9で、ステップS8で設定された対象期間における特徴量 $X(n)$ の各成分について回帰分析を行い、閾値 $p_0$ から極大値までの範囲の異常度 $p(n)$ に対する寄与度 $R_c$ を算出する。次いでステップS10で、ステップS9で算出された寄与度 $R_c$ の高い上位の成分のみに絞り込んだ特徴量 $X(n)$ を用いて判定モデルを再生成する。

## 【0040】

このように、実際の加工不良発生時を含む監視期間の時系列データに基づいて、特徴量 $X(n)$ を生成して学習するため、実際のデータを反映した判定モデルを生成することができる(ステップS1~S3)。判定モデルによる異常判定の結果(離散値)を積算し、異常と判定される頻度を示す異常度 $p(n)$ (連続値)として定量化するため、実際の加工不良の発生頻度が極低い場合でも、異常度 $p(n)$ が高まる期間を特定することができる(ステップS4~S8)。異常度 $p(n)$ が閾値 $p_0$ 以上で、かつ高まる期間のデータを抽出して回帰分析を行うため、ノイズの影響を受けることなく、生産設備1で加工不良が発生する要因を精度よく特定することができる(ステップS9)。また、異常の要因となる成分のみに絞り込んだ特徴量 $X(n)$ を再学習することで、過学習を防ぎ、汎化性能を高めた判定モデルを再生成することができる(ステップS10)。

## 【0041】

本発明の実施形態によれば以下のような作用効果を奏することができる。

(1) 装置10は、生産設備1で加工不良が発生する要因を特定する。装置10は、生産設備1で加工不良が発生した加工不良発生時を含む監視期間 $T_1 \sim T_{5000}$ に検出された生産設備1の稼働状態を示す複数のパラメータ $X_1 \sim X_7$ の時系列データを取得するデータ取得部14と、データ取得部14により取得された時系列データに基づいて、複数のパラメータ $X_1 \sim X_7$ の代表値としての複数の特徴量を成分とする特徴量 $X(n)$ を生成する特徴量生成部15と、特徴量生成部15により生成された特徴量 $X(n)$ に基づいて、生産設備1の稼働状態が異常であるか否かを判定する判定基準を決定する基準決定部16と、基準決定部16により決定された判定基準に基づいて、生産設備1の稼働状態の異常の頻度を示す異常度 $p(n)$ を算出する異常度算出部17と、異常度算出部17により算出された異常度 $p(n)$ に基づいて、特徴量生成部15により生成された特徴量 $X(n)$ の複数の成分の中から生産設備1で加工不良が発生する要因となる成分を特定する要因特定部18とを備える(図3)。

## 【0042】

実際のデータを反映した判定モデルによる異常判定の結果を頻度として定量化することで、実際の加工不良の発生頻度が極低い場合でも、ノイズの影響を受けることなく、生産設備1で加工不良が発生する要因を精度よく特定することができる。また、特定された要因に絞り込んで再学習することで、過学習を防ぎ、汎化性能を高めた判定モデルを再生成することができる。

## 【0043】

(2) 要因特定部18は、データ取得部14により取得された時系列データと、異常度

算出部 17 により算出された異常度  $p(n)$  とに基づいて、生産設備 1 の稼働状態が正常から異常に移行するときの異常度  $p(n)$  の閾値  $p_0$  を設定する閾値設定部 181 と、閾値設定部 181 により設定された閾値  $p_0$  に基づいて、生産設備 1 の稼働状態が正常から異常に移行する直前の期間  $t_1 \sim t_7$  を設定する期間設定部 182 と、特徴量生成部 15 により生成された特徴量  $X(n)$  の複数の成分のそれぞれについて、期間設定部 182 により設定された期間  $t_1 \sim t_7$  における異常度  $p(n)$  に対する寄与度  $R_c$  を算出する寄与度算出部 183 とを有する (図 3)。

【0044】

すなわち、判定モデルにより異常と判定される頻度が高まる期間を特定し、そのような期間について回帰分析を行うことで、ノイズの影響を受けることなく異常の要因を特定することができる。

10

【0045】

以上では、本発明を要因分析装置として説明したが、本発明は、要因分析方法として用いることもできる。すなわち、要因分析方法は、生産設備 1 で加工不良が発生する要因を特定する要因分析方法であって、生産設備 1 で加工不良が発生した加工不良発生時を含む監視期間に検出された生産設備 1 の稼働状態を示す複数のパラメータの時系列データを取得するデータ取得ステップ S1 と、データ取得ステップ S1 で取得された時系列データに基づいて、複数のパラメータの代表値としての複数の特徴量を生成する特徴量生成ステップ S2 と、特徴量生成ステップ S2 で生成された複数の特徴量に基づいて、生産設備 1 の稼働状態が異常であるか否かを判定する判定基準を決定する基準決定ステップ S3、基準決定ステップ S3 で決定された判定基準に基づいて、生産設備 1 の稼働状態の異常の頻度を示す異常度  $p(n)$  を算出する異常度算出ステップ S5 と、異常度算出ステップ S5 で算出された異常度  $p(n)$  に基づいて、特徴量生成ステップ S2 で生成された複数の特徴量の中から生産設備 1 で加工不良が発生する要因となる特徴量を特定する要因特定ステップ S6 ~ S9 とを含む (図 10)。

20

【0046】

以上の説明はあくまで一例であり、本発明の特徴を損なわない限り、上述した実施形態および変形例により本発明が限定されるものではない。上記実施形態と変形例の 1 つまたは複数任意に組み合わせることも可能であり、変形例同士を組み合わせることも可能である。

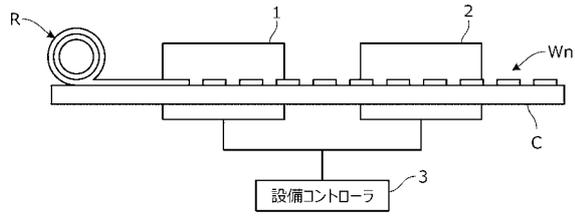
30

【符号の説明】

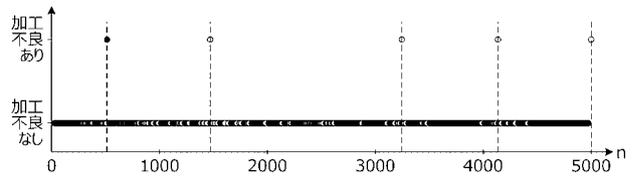
【0047】

1 生産設備、2 検査装置、3 設備コントローラ、10 要因分析装置(装置)、11 CPU、12 メモリ、13 入出力部、14 データ取得部、15 特徴量生成部、16 基準決定部、17 異常度算出部、18 要因特定部、19 データ出力部、100 要因分析システム、181 閾値設定部、182 期間設定部、183 寄与度算出部、Wn ワーク

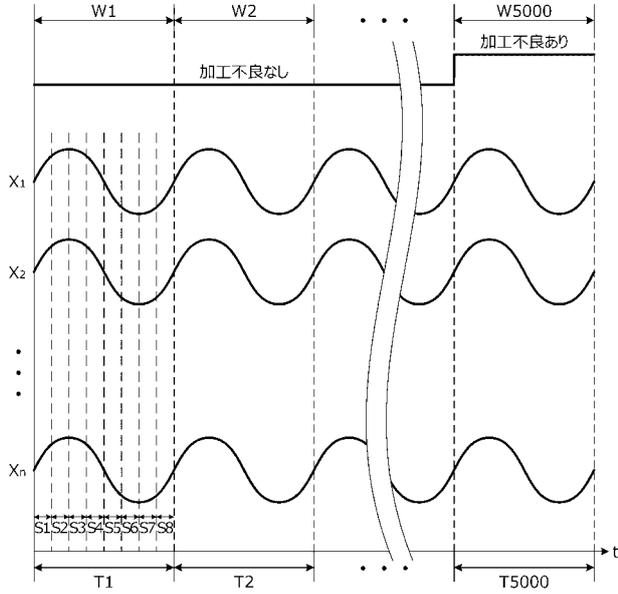
【図 1】



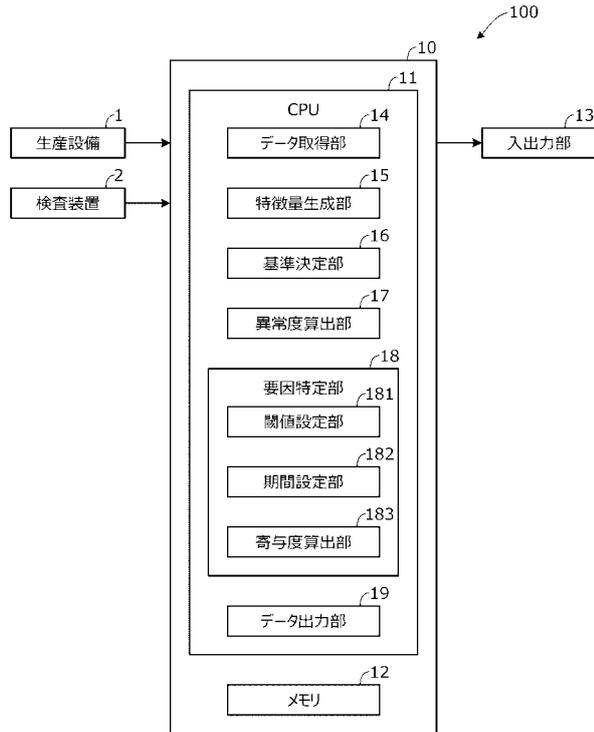
【図 2 B】



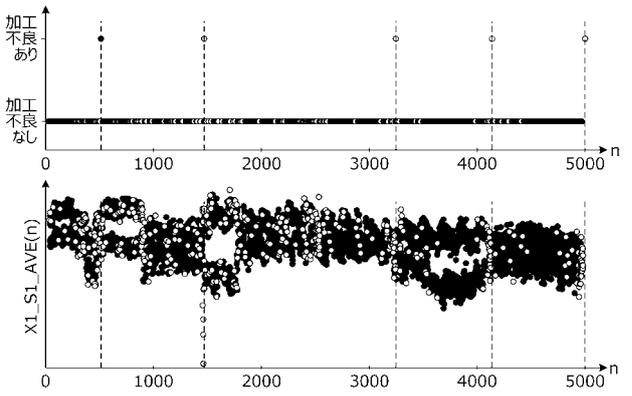
【図 2 A】



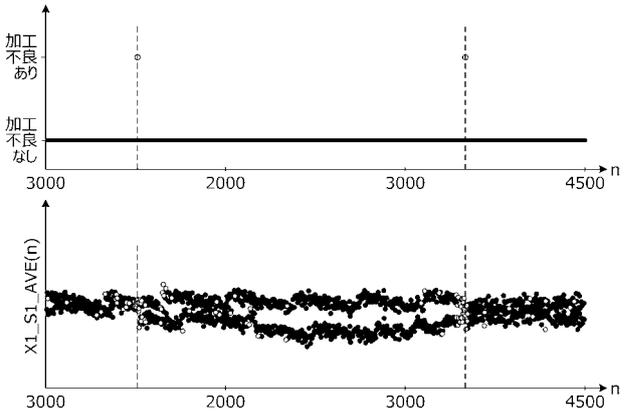
【図 3】



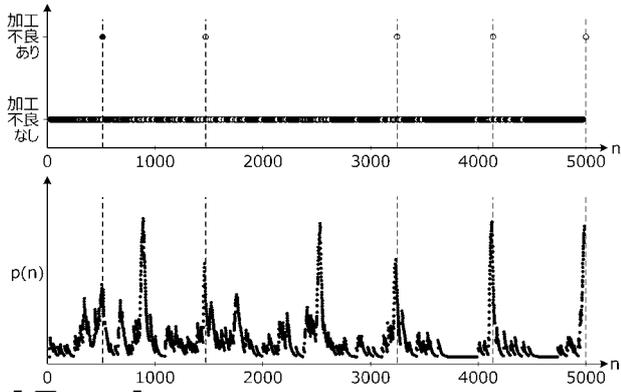
【図 4 A】



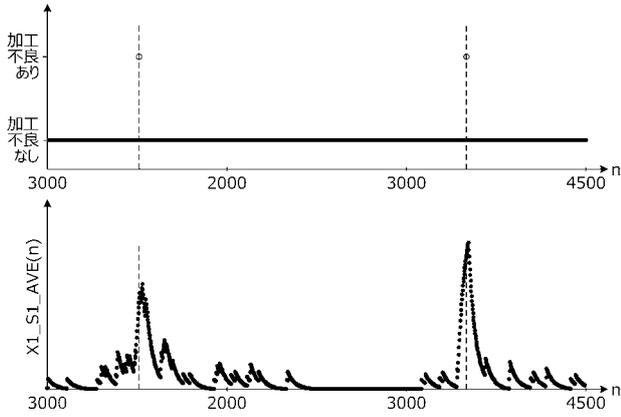
【図 4 B】



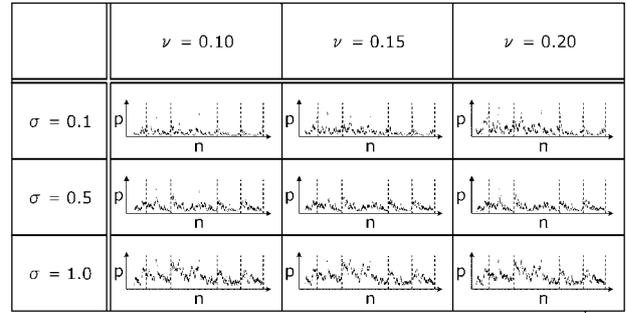
【図 5 A】



【図 5 B】

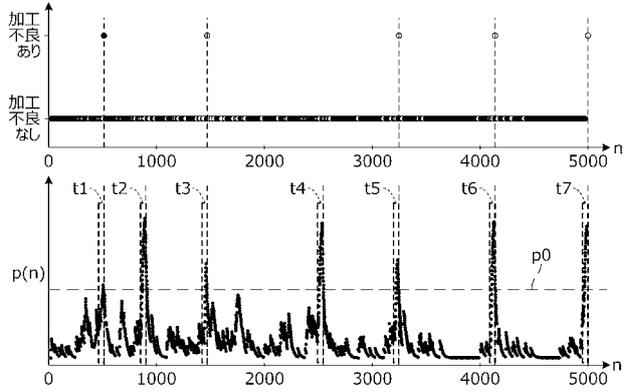


【図 6】

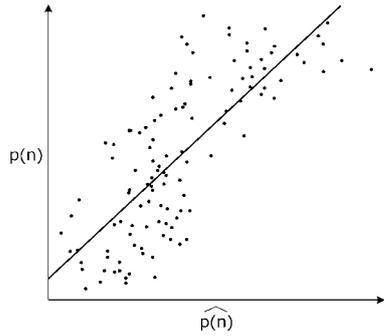


13

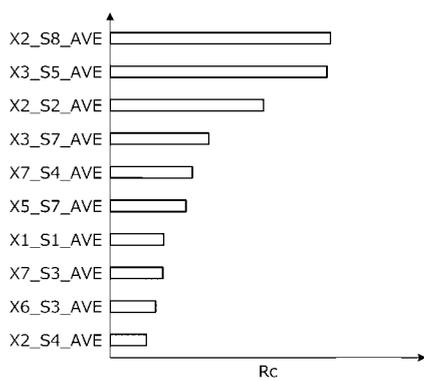
【図 7】



【図 8】



【図 9】



【図 10】

