(12) 特許協力条約に基づいて公開された国際出願

(19) 世界知的所有権機関
国際事務局

(43) 国際公開日
2021年10月7日(07.10.2021)

WIPO | PCT

(10) 国際公開番号
WO 2021/199227 A1

(51) 国際特許分類:
G06N 20/00 (2019.01)

(21) 国際出願番号： PCT/JP2020/014727

(22) 国際出願日： 2020年3月31日(31.03.2020)

(25) 国際出願の言語： 日本語

(26) 国際公開の言語： 日本語

(71) 出願人: 株式会社日立ハイテク (**HITACHI HIGH-TECH CORPORATION**) [JP/JP]; 〒1056409 東京都港区虎ノ門一丁目１７番１号 Tokyo (JP).

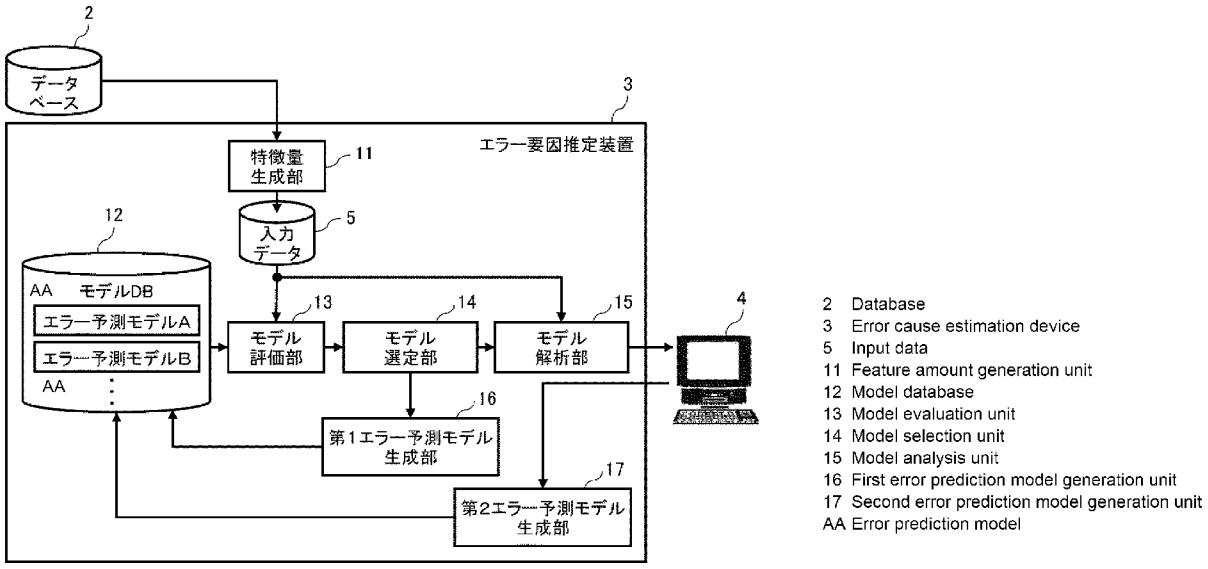
(72) 発明者: 吉田 泰浩 (**YOSHIDA Yasuhiro**); 〒1008280 東京都千代田区丸の内一丁目６番６号 株式会社日立製作所内 Tokyo (JP). 石川 昌義 (**ISHIKAWA Masayoshi**); 〒1008280 東京都千代田区丸の内一丁目６番６号 株式会社日立製作所内 Tokyo (JP). 早川 功一 (**HAYAKAWA Kouichi**); 〒1056409 東京都港区虎ノ門一丁目１７番１号 株式会社日立ハイテク内 Tokyo (JP). 高野 正幹 (**TAKANO Masami**); 〒1056409 東京都港区虎ノ門一丁目１７番１号 株式会社日立ハイテク内 Tokyo (JP). 笹嶋 二大 (**SASAJIMA Fumihiro**); 〒1056409 東京都港区虎ノ門一丁目１７番１号 株式会社日立ハイテク内 Tokyo (JP).

(74) 代理人: ポレール特許業務法人 (**POLAIRE I.P.C.**); 〒1030021 東京都中央区日本橋本石町三丁目３番５号 Tokyo (JP).

(54) **Title:** ERROR CAUSE ESTIMATION DEVICE AND ESTIMATION METHOD

(54) 発明の名称： エラー要因の推定装置及び推定方法

図 2



(57) **Abstract:** An error cause estimation device provided with: a feature amount generation unit for using data transmitted from the outside to generate feature amounts suitable for a machine learning model; a model database having at least one or more error prediction models, which are used in determining whether an error has occurred using the feature amounts as input data; a model evaluation unit for evaluating the performance of an error prediction model by comparing a prediction result of the error prediction model and an actually measured true error result; a model selection unit for selecting from the model database an error prediction model for which an evaluation value calculated by the model evaluation unit is greater than or equal to a preset defined value; and an error prediction model generation unit for generating a new error

WO 2021/199227 A1

[続葉有]

(81) 指定国(表示のない限り、全ての種類の国内保護が可能): AE, AG, AL, AM, AO, AT, AU, AZ, BA, BB, BG, BH, BN, BR, BW, BY, BZ, CA, CH, CL, CN, CO, CR, CU, CZ, DE, DJ, DK, DM, DO, DZ, EC, EE, EG, ES, FI, GB, GD, GE, GH, GM, GT, HN, HR, HU, ID, IL, IN, IR, IS, JO, JP, KE, KG, KH, KN, KP, KR, KW, KZ, LA, LC, LK, LR, LS, LU, LY, MA, MD, ME, MG, MK, MN, MW, MX, MY, MZ, NA, NG, NI, NO, NZ, OM, PA, PE, PG, PH, PL, PT, QA, RO, RS, RU, RW, SA, SC, SD, SE, SG, SK, SL, ST, SV, SY, TH, TJ, TM, TN, TR, TT, TZ, UA, UG, US, UZ, VC, VN, WS, ZA, ZM, ZW.

(84) 指定国(表示のない限り、全ての種類の広域保護が可能): ARIPO (BW, GH, GM, KE, LR, LS, MW, MZ, NA, RW, SD, SL, ST, SZ, TZ, UG, ZM, ZW), ユーラシア (AM, AZ, BY, KG, KZ, RU, TJ, TM), ヨーロッパ (AL, AT, BE, BG, CH, CY, CZ, DE, DK, EE, ES, FI, FR, GB, GR, HR, HU, IE, IS, IT, LT, LU, LV, MC, MK, MT, NL, NO, PL, PT, RO, RS, SE, SI, SK, SM, TR), OAPI (BF, BJ, CF, CG, CI, CM, GA, GN, GQ, GW, KM, ML, MR, NE, SN, TD, TG).

添付公開書類:

一 国際調査報告 (条約第21条(3))

prediction model with respect to the measured error when no corresponding error prediction model has been selected by the model selection unit. Thus, it is possible to estimate the cause of various types of errors that occur, even when there has been no prior annotation of error causes.

(57) 要約:エラー要因の推定装置は、外部から送られたデータを用いて機械学習モデルに適した特徴量を生成する特徴量生成部と、特徴量を入力データとしてエラー発生の有無の判定に用いられるエラー予測モデルを少なくとも1つ以上有するモデルデータベースと、エラー予測モデルの予測結果と実際に計測された真のエラー結果とを比較してエラー予測モデルの性能を評価するモデル評価部と、モデル評価部で計算された評価値が予め設定された規定値以上となるエラー予測モデルをモデルデータベースから選定するモデル選定部と、モデル選定部にて選択されるエラー予測モデルの該当がない場合には、計測されたエラーに対して新たなエラー予測モデルを生成するエラー予測モデル生成部と、を備えている。これにより、エラー要因の事前のアノテーションがなくても、発生する多種類のエラーに対してその要因を推定することができる。

明　細　書

発明の名称 ： エラー要因の推定装置及び推定方法

技術分野

[0001] 本発明は、エラー要因の推定装置及び推定方法に関する。

背景技術

[0002] 半導体計測装置や半導体検査装置は、レシピと呼ばれる設定パラメータに従って、半導体ウエハの表面において異常と判定された検査点ごとに検査動作や計測動作を実施する。レシピパラメータの調整は、計測・検査対象の属性や装置の特性等に応じて、エンジニアがマニュアル作業によって各項目を最適化するのが一般的である。したがって、例えば、調整が十分でないレシピの使用や、経時変化によって装置の特性が変わった場合等においては、検査動作や計測動作においてエラーが生じる可能性がある。このようなエラーは、レシピの内容に起因するエラーとしてレシピエラーと呼ばれる。

[0003] このようなレシピエラーが発生した際には、サービスエンジニアが半導体計測装置や半導体検査装置から装置内部データを解析して原因箇所を特定するのが一般的である。しかしながら、半導体の微細化・多様化に伴い、レシピ数及びレシピ設定項目の増加、レシピ作成の複雑化等が生じている。このため、レシピエラーの原因特定には時間を要し、装置の稼働率を低下させる一因となっている。

[0004] 特許文献１には、超小型電子機構の所望寸法を測定するのに用いられる計測ツールにおける障害を識別する方法により、ユーザが、最も問題のあるレシピに迅速に集中し、どの計測ツールにも典型的に存在するエラーログを用いて根本的な原因を決定することができること、この処理を自動化することができること等が開示されている。

[0005] 特許文献２には、ワークの加工面に不良が発生した場合にその要因を推定する技術として、機械学習装置を用いて、検査装置によるワークの加工面の検査結果を状態変数として観測し、加工面不良の発生要因を示すラベルデー

タを取得し、状態変数とラベルデータとを関連付けて学習する、加工不良要因推定装置が開示されている。

先行技術文献

特許文献

[0006] 特許文献1：特許第４３９８４４１号公報

特許文献2：特許第６５３０７７９号公報

発明の概要

発明が解決しようとする課題

[0007] 特許文献１に記載の方法においては、典型的なエラーログを用いて根本的な原因を自動的に決定することができるとされている。しかしながら、特許文献１においては、計測ツールによって用いられたレシピについての正規化された数のエラーが具体的にどのようなエラーであるか等が記載されていない。

[0008] 特許文献２に記載の加工不良要因推定装置の適用範囲は、状態変数とラベルデータとを関連付けて学習できる場合に限られる。言い換えると、アノテーションが必要となる。

[0009] 半導体検査装置等におけるレシピエラーの要因推定に際しては、エラーがどのようなメカニズムで発生するかは、製品・製造プロセス依存である。また、エラーのバリエーションは多岐にわたる。このため、エラー要因を事前に想定し網羅して学習に用いることは困難である。

[0010] 本発明は、エラー要因の事前のアノテーションがなくても、発生する多種類のエラーに対してその要因を推定することを目的とする。

課題を解決するための手段

[0011] 本発明のエラー要因の推定装置は、外部から送られたデータを用いて機械学習モデルに適した特徴量を生成する特徴量生成部と、特徴量を入力データとしてエラー発生の有無の判定に用いられるエラー予測モデルを少なくとも１つ以上有するモデルデータベースと、エラー予測モデルの予測結果と実際

に計測された真のエラー結果とを比較してエラー予測モデルの性能を評価するモデル評価部と、モデル評価部で計算された評価値が予め設定された規定値以上となるエラー予測モデルをモデルデータベースから選定するモデル選定部と、モデル選定部にて選択されるエラー予測モデルの該当がない場合には、計測されたエラーに対して新たなエラー予測モデルを生成するエラー予測モデル生成部と、を備えている。

[0012] 本発明のエラー要因の推定方法は、外部から送られたデータを用いて機械学習モデルに適した特徴量を生成する特徴量生成工程と、モデルデータベースに保存されているエラー予測モデルの予測結果と実際に計測された真のエラー結果とを比較して、特徴量を入力データとしてエラー発生の有無の判定に用いられるエラー予測モデルの性能を評価するモデル評価工程と、モデル評価工程で計算された評価値が予め設定された規定値以上となるエラー予測モデルをモデルデータベースから選定するモデル選定工程と、モデル選定工程にて選択されるエラー予測モデルの該当がない場合には、計測されたエラーに対して新たなエラー予測モデルを生成するエラー予測モデル生成工程と、を含む。

発明の効果

[0013] 本発明によれば、エラー要因の事前のアノテーションがなくても、発生する多種類のエラーに対してその要因を推定することができる。

図面の簡単な説明

[0014] [図1]実施例１に係るエラー要因推定装置を含む情報処理システムを示すブロック図である。

[図2]図１のエラー要因推定装置を示す構成図である。

[図3]実施例１に係る第１エラー予測モデル生成部における新たなエラー予測モデルの生成手順を示すフローチャートである。

[図4]実施例１に係る入力データのデータ構造の一例を示す表である。

[図5]図２のモデル解析部における処理及び表示例を示す模式図である。

[図6]実施例１に係るモデル評価部及びモデル解析部における処理及び表示例

を示す模式図である。

[図7]実施例１に係る特徴量の値とそのエラー発生への寄与度との関係の一例を示すグラフである。

[図8]実施例１に係る第２エラー予測モデル生成手順を示すフローチャートである。

[図9]実施例２に係るデータ分類部を備えたエラー要因推定装置を示す構成図である。

[図10]実施例２に係るデータ分類部を示す構成図である。

[図11]特徴量の値とそのエラー発生への寄与度との関係を用いてエラーデータを分類した状態を示すグラフである。

[図12]実施例３に係るエラー要因推定のみを実施するエラー要因推定装置を示す構成図である。

[図13]実施例３に係るエラー要因ラベル取得部及びエラー要因ラベルデータベースを備えたエラー要因推定装置を示す構成図である。

[図14]実施例３に係るユーザへのエラー要因候補を示す図である。

発明を実施するための形態

[0015] 以下に説明する実施形態において、「半導体検査装置」は、半導体ウエハの表面に形成されたパターンの寸法を計測する装置、半導体ウエハの表面に形成されたパターンの欠陥有無を検査する装置、或いはパターンが形成されていないベアウエハの欠陥の有無を検査する装置等を含み、これらの装置を複数組み合わせた複合装置をも含むものである。

[0016] また、以下に説明する実施形態において、「検査」とは、計測又は検査の意味で用いるものとし、「検査動作」とは、計測動作又は検査動作の意味で用いるものとし、「検査対象」とは、計測又は検査の対象となるウエハ、或いは、当該ウエハにおける計測又は検査の対象領域を指すものとする。

[0017] なお、本明細書において、エラー要因推定装置は、エラー要因の推定装置と同義であり、エラー要因推定方法は、エラー要因の推定方法と同義である。

[0018] 以下、エラー要因の推定装置及び推定方法の望ましい実施形態について説明する。

[0019] 前記推定装置は、特徴量生成部と、モデルデータベースと、モデル評価部と、モデル選定部と、エラー予測モデル生成部と、を備え、入力データ内のエラーデータをエラー要因ごとに分類するデータ分類部を更に備えていることが望ましい。

[0020] 前記推定装置において、エラー予測モデル生成部は、分類されたエラーデータごとに異なるラベル付けをして、このラベルとともにエラー予測モデルを生成し、このエラー予測モデルをモデルデータベースに送信することが望ましい。

[0021] 前記推定装置は、モデル選定部で選定されたエラー予測モデルにおけるエラー判定結果に対する特徴量の寄与度を数値化するモデル解析部を更に備えていることが望ましい。

[0022] 前記推定装置は、モデル解析部で計算された寄与度の値が高いものの特徴量について、エラー要因候補としてユーザに提示する構成を有することが望ましい。

[0023] 前記推定装置において、モデル選定部で複数のエラー予測モデルが選定された場合には、モデル評価部は、モデル評価値を算出し、モデル解析部で計算された特徴量ごとの寄与度は、モデル評価値を用いて補正され、複数のエラー予測モデルのそれぞれから計算された補正後の寄与度の値が高いものの特徴量について、エラー要因候補としてユーザに提示する構成を有することが望ましい。

[0024] 前記推定装置は、エラー要因候補に対してユーザから修正があった場合には、修正後のエラー要因がモデル解析部の解析結果に含まれるようにエラー予測モデルを生成するもう１つのエラー予測モデル生成部を更に備えていることが望ましい。

[0025] 前記推定装置は、特徴量生成部で生成された特徴量及びその組み合わせのうち少なくともいずれか一方に対応するエラー要因の関係を保存するエラー

要因ラベルデータベースと、モデル解析部で数値化された寄与度に対応する特徴量に対してエラー要因ラベルデータベース内のラベル関係を用いて対応するエラー要因を付与するエラー要因ラベル取得部と、を更に備えていることが望ましい。

[0026] 前記推定装置において、エラー予測モデル生成部は、対象とするエラーが発生した動作工程及びそれ以前の動作工程における入力データを用いて新たなエラー予測モデルを生成することが望ましい。

[0027] なお、推定装置の構成と推定方法の工程との関係に関して、特徴量生成部は特徴量生成工程に、モデル評価部はモデル評価工程に、モデル選定部はモデル選定工程に、エラー予測モデル生成部はエラー予測モデル生成工程に対応する。また、これらの工程は、１つの装置において実施されるものに限定されるものではなく、分散配置された複数の装置により実施されてもよい。

実施例 1

[0028] 図１は、実施例１に係るエラー要因推定装置を含む情報処理システムの一例を示したものである。

[0029] 本図において、半導体検査装置１は、ネットワーク１０１を介してデータベース２及びエラー要因推定装置３に接続されている。エラー要因推定装置３は、端末４（ＧＵＩ）に接続されている。エラー要因推定装置３は、半導体検査装置１が実施する検査動作におけるエラーの要因を推定する。

[0030] 半導体検査装置１から送られるデータには、例えば、装置データ、計測レシピ（以下単に「レシピ」と呼ぶ場合もある。）、計測結果及びエラー結果が含まれる。また、レシピには、計測点数、計測点（Ｅｖａｌｕａｔｉｏｎ Ｐｏｉｎｔ：ＥＰ）の座標情報、画像を撮像する際の撮像条件、撮像シーケンス等が含まれていてもよい。また、レシピには、計測点に併せて計測点を計測するための準備段階で取得される画像の座標や撮像条件等が含まれていてもよい。

[0031] 装置データは、装置固有パラメータ、装置機差補正データ及び観察条件パラメータを含む。装置固有パラメータは、半導体検査装置１を規定仕様どお

りに動作させるために用いる補正パラメータである。装置機差補正データは、半導体検査装置間の機差を補正するために用いるパラメータである。観察条件パラメータは、例えば、電子光学系の加速電圧等の走査型電子顕微鏡（ＳＥＭ）の観察条件を規定するパラメータである。

[0032] レシピは、レシピパラメータとして、ウエハマップ、アライメントパラメータ、アドレッシングパラメータ及び測長パラメータを含む。ウエハマップは、半導体ウエハの表面の座標マップ（例えばパターンの座標）である。アライメントパラメータは、例えば、半導体ウエハの表面の座標系と半導体検査装置１内部の座標系との間のずれを補正するために用いるパラメータである。アドレッシングパラメータは、例えば、半導体ウエハの表面に形成されているパターンのうち、検査対象領域内に存在する特徴的なパターンを特定する情報である。測長パラメータは、長さを測定する条件を記述したパラメータであり、例えばパターンのうちどの部位の長さを測定するかを指定するパラメータである。

[0033] 計測結果は、測長結果、画像データ及び動作ログを含む。測長結果は、半導体ウエハの表面のパターンの長さを測定した結果を記述したものである。画像データは、半導体ウエハの観察画像である。動作ログは、アライメント、アドレッシング及び測長の各動作工程における半導体検査装置１の内部状態を記述したデータである。例えば、各部品の動作電圧、観察視野の座標等が挙げられる。

[0034] エラー結果は、エラーが発生した場合に、アライメント、アドレッシング及び測長の各動作工程のいずれで発生したエラーであるかを示すパラメータである。

[0035] これらの装置データ、レシピ、計測結果、エラー結果等のデータは、ネットワーク１０１を介してデータベース２に蓄積される。蓄積されたデータは、エラー要因推定装置３にて解析される。解析結果は、端末４にてユーザが読み取ることができる形式で表示される。

[0036] 図２は、図１のエラー要因推定装置の詳細な構成を示したものである。

[0037] 図２において、エラー要因推定装置３は、外部のデータベース２に接続された特徴量生成部１１と、入力データ記録部５と、モデルデータベース１２（モデルＤＢ）と、モデル評価部１３と、モデル選定部１４と、モデル解析部１５と、第１エラー予測モデル生成部１６と、第２エラー予測モデル生成部１７と、を有している。なお、第１エラー予測モデル生成部１６は、単に「エラー予測モデル生成部」とも呼ぶ。また、第２エラー予測モデル生成部１７は、「もう１つのエラー予測モデル生成部」とも呼ぶ。

[0038] 特徴量生成部１１は、データベース２から送られた装置データ、レシピ、計測結果等の生データから、機械学習モデルに適した特徴量を抽出し、当該特徴量を入力データ記録部５に出力する。ここで、特徴量の抽出は、データのスケーリング、カテゴリカル変数のエンコーディング、交互作用特徴量等の複数のデータを組み合わせた複合的な特徴量作成等を含むものであってもよい。

[0039] モデルデータベース１２には、入力データ記録部５内のデータを入力として、各検査点におけるエラー発生の有無の判定に用いられるエラー予測モデルを予め少なくとも１つ以上記録しておく。この予め記録された初期のエラー予測モデルについては、別の半導体製造工場や製造ラインで生成されたモデルを転用してもよいし、データベース２内の任意のエラーに対して後述するモデル生成手順に基づき構築してもよい。

[0040] モデル評価部１３は、入力データ記録部５内の、例えばレシピ単位、ウエハ単位、検査点単位等のデータに対して、モデルデータベース１２内のエラー予測モデルの性能を評価する。性能評価は、エラー予測モデルを用いて判定されたエラー予測結果と、入力データ記録部５内の真のエラー結果とを比較することで得られる。性能の評価値としては、精度、再現率、適合率、Ｆ１値、ＡＵＣ等を用いることができる。ここで、Ｆ１値は、適合率と再現率との調和平均である。また、ＡＵＣは、Ａｒｅａ Ｕｎｄｅｒ ｔｈｅ Ｃｕｒｖｅの略称である。

[0041] モデル選定部１４は、モデル評価部１３において評価値が高いモデルを、

入力データ記録部５に含まれるエラーの判定に適したモデルとして１つ以上選定する。モデルの選定方法としては、モデル評価部１３で使用した評価値に対して予め規定値を設定し、この規定値以上となる評価値のモデルの中から選定する。

[0042] モデル選定部１４において、設定された規定値以上の評価値となったモデルが存在しない場合は、生成済みのエラー予測モデルに適合しない新規のエラーが入力されたとして、第１エラー予測モデル生成部１６にて新たなエラー予測モデルを生成する。

[0043] モデル解析部１５は、モデル選定部１４で選定されたエラー予測モデルについて、入力データ記録部５内の各特徴量がエラー判定に対してどの程度寄与したかを解析することにより、エラーと高い相関を示す特徴量を抽出する。

[0044] 図３は、図２の第１エラー予測モデル生成部１６における新たなエラー予測モデルの生成手順を示したものである。

[0045] ステップＳ１００において、上記のとおり、設定された規定値以上の評価値となったモデルが存在しないと判定された場合、ステップＳ１０１に移行する。

[0046] ステップＳ１０１においては、エラー予測モデルの生成に必要な学習データの選定（抽出）をする。選定する方法としては、エラー予測モデルで検出できなかったエラーと同じレシピ又は類似のレシピを含むデータをデータベース２又は入力データ記録部５から抽出する。

[0047] 次に、ステップＳ１０２では、学習データのうちどの特徴量を優先的に用いるかの重みづけを修正する。修正方法としては、例えばランダムサーチやベイズ最適化等の既存のパラメータ探索手法を活用することができる。

[0048] ステップＳ１０３では、学習データを入力としてステップＳ１０２で算出した重みに基づき、学習データ中に含まれるエラー発生の有無の判定に用いられる学習モデルであるエラー予測モデルを生成する。このエラー予測モデルは、決定木やＮｅｕｒａｌ　Ｎｅｔｗｏｒｋ等、どのような機械学習アル

ゴリズムを用いて生成するとしてもよい。

[0049] ステップＳ１０４では、ステップＳ１０３で生成されたエラー予測モデルの性能を評価する。評価方法としては、モデル評価部１３（図２）と同様に、精度、再現率、適合率、Ｆ１値、ＡＵＣ等の指標を用いることができる。また、望ましくは、交差検証等の手法を用いてこれらの評価値を計算できるとよい。

[0050] ステップＳ１０５では、ステップＳ１０４で計算された評価値が予め定められた規定値以上であるかどうかを判定する。規定値未満であれば、ステップＳ１０２に戻って、再度同様の処理を繰り返し、規定値以上であれば新規エラーモデルの生成完了としてモデルデータベース１２（図２）に保存する。

[0051] なお、上記の類似のレシピの選定方法としては、例えば、半導体ウエハの表面に形成されているパターンの登録情報を示すパラメータや測定倍率の値が近いものを選定するとすることができる。データベース２から抽出する場合には、特徴量生成部１１にて機器学習モデルに適した形式に特徴量を生成する。また、抽出するデータの期間を指定するとしてもよい。過去のデータであると、ウエハの製造条件や装置の状態が変化した可能性があるため、エラー発生時点から遡ってデータを抽出する期間が指定されることが望ましい。

[0052] さらに、学習データは、対象（予測対象）とするエラーが発生した動作工程と、それ以前の動作工程におけるレシピ又は計測結果とを含むとするとよい。半導体検査装置１（図１）における測定は、アライメント、アドレッシング、測長等の連続した動作工程を含む。

[0053] 図４は、半導体検査装置における測定から得られた特徴量の値を含む入力データのデータ構造の一例を示す表である。

[0054] 本図においては、それぞれの測定Ｉｎｄｅｘに対する特徴量（Z_1，Z_2，…，Z_m）の値、動作工程及びエラーの発生の有無（エラー結果）を示している。

[0055] 本図においては、測定Ｉｎｄｅｘが２の場合であって動作工程が２の場合においてエラーが発生している。この場合、その動作工程２より後の動作工程３以降の特徴量は、エラー発生とは無関係として除外してよいが、前の動作工程１に関しては、エラーに影響を与えている可能性があるため、学習データに含めることとする。

[0056] このように、学習済みのモデルで対応できないエラーが発生した場合には、新規エラーとして新たな予測モデルを生成することにより、事前のアノテーションを行うことなく、エラー要因ごとにエラー予測モデルの生成をすることができる。

[0057] つぎに、モデル解析部１５におけるエラー判定への寄与度の計算方法と、計算結果のユーザへの可視化方法とについて説明する。

[0058] 図５は、エラー予測モデルに対する入力された特徴量のエラー判定への寄与度の計算と、ユーザへの可視化方法とを示す模式図である。

[0059] 本図において、入力データ記録部５の入力データとモデルデータベース１２（図２）のエラー予測モデルＡ（２１０）とがモデル解析部１５に入力される。そして、寄与度の計算結果２２０が出力され、それぞれの特徴量のエラーへの寄与度のグラフ２３０が表示可能となる。言い換えると、特徴量の寄与度が数値化される。ここでは、入力データ記録部５の入力データは、特徴量（Z_1，Z_2，…，Z_m）の値及びエラー発生結果が、アライメント、アドレッシング、測長の各動作工程の度に割り振られる測定Ｉｎｄｅｘごとに格納されたデータ構造を有する例を示している。

[0060] これらの特徴量のエラー予測モデルにおけるエラー判定結果への寄与度は、例えば、エラー予測モデルが決定木をベースとしたアルゴリズムで構築される場合、各特徴量がモデル内の分岐に出現する個数や目的関数の改善値等に基づき計算される変数重要度（Ｆｅａｔｕｒｅ　Ｉｍｐｏｒｔａｎｃｅ）や、各特徴量の値のモデル出力への感度を計算するＳＨＡＰ値によって評価することができる。ここで、ＳＨＡＰは、モデルの予測結果に対する各変数（特徴量）の寄与を求めるための手法であり、ＳＨａｐｌｅｙ　Ａｄｄｉｔ

ｉｖｅ　ｅｘＰｌａｎａｔｉｏｎｓの略称である。

[0061] 図２のモデル選定部１４において選定されたモデルがエラー予測モデルＡであった場合、エラー予測モデルＡの入力に、例えば、測定Ｉｎｄｅｘが１の行のデータが入力され、特徴量Z_1を含めた場合と除外した場合とのエラー予測モデルＡの出力結果の差分に基づき、エラー判定へのφ寄与度$\phi_{1,1}$が計算される。この計算を全ての特徴量及び全ての測定Ｉｎｄｅｘに対して繰り返すことにより、予測モデルの判定結果に対して各特徴量がどの程度の影響を与えたかが数値化できる。各特徴量におけるＳＨＡＰ値の総和ϕ_{SUM}は、値の大きい特徴量から順に端末４に表示することができる。言い換えると、モデル解析部１５で計算された寄与度の値が高いものの特徴量をエラー要因候補とし、端末４等を介してユーザに提示することができる。

[0062] このように、入力データ記録部５における特徴量のエラー予測モデルに対する感度を解析することにより、エラーと高い相関を有する特徴量をユーザに提示することができる。

[0063] さらに、モデル選定部１４にて入力されたデータに対して性能のよいモデルを選択するとしたことにより、データ内に様々な特徴を持つエラーデータが混在する場合であっても、関連の低い特徴量がノイズとして抽出されることを回避して、抽出される特徴量の精度を高めることができる。

[0064] また、前述のモデル選定部１４にて２つ以上のモデルが選定された場合、それら複数のモデルの解析結果を複合して相関の高い特徴量を提示するとしてもよい。

[0065] つぎに、モデル選定部１４で２つのモデルとしてエラー予測モデルＡ及びエラー予測モデルＢが選択された場合のエラー要因候補の提示方法について説明する。

[0066] 図６は、本実施例に係るモデル評価部及びモデル解析部における処理及び表示例を示す模式図である。

[0067] 本図においては、入力データ記録部５の入力データとモデルデータベース１２（図２）のエラー予測モデルＡ（２１０）とがモデル評価部１３ａ及び

モデル解析部１５ａに入力される。また、入力データ記録部５の入力データとモデルデータベース１２（図２）のエラー予測モデルＢ（２１１）とがモデル評価部１３ｂ及びモデル解析部１５ｂに入力される。そして、特徴量のエラーへの寄与度のグラフ２３１が表示可能となる。

[0068] モデル評価部１３ａ、１３ｂ及びモデル解析部１５ａ、１５ｂの機能は、図２と同様である。また、図６においては、モデル評価部１３ａ、１３ｂ及びモデル解析部１５ａ、１５ｂを説明のために２つずつ示しているが、実際には、それぞれ１つのモデル評価部１３ａ、１３ｂ及びモデル解析部１５ａ、１５ｂで順番あるいは並列に処理を実行することにしてもよい。

[0069] 本図においては、モデル解析部１５ａ、１５ｂで計算された特徴量ごとのＳＨＡＰ値の総和ϕ_{SUM}に対して、モデル評価部１３ａ、１３ｂで得られたモデル評価値で補正することで最終的な寄与度ϕ'_{SUM}を計算する。最もシンプルには、例えばモデル評価部１３ａ、１３ｂでのモデル性評価指標が再現率であった場合、モデルの再現率をＳＨＡＰ値ϕ_{SUM}に乗算することにより、最終的な寄与度ϕ'_{SUM}を得るとすることができる。各エラー予測モデルで計算された最終的な寄与度ϕ'_{SUM}を値の大きい順に並べて表示することにより、複数のモデルから複合されたエラーと高い相関を有する特徴量をランキング形式で端末４を介してユーザに提示することができる。

[0070] さらに、これらのエラー発生に対して、寄与度の高いランキング上位の特徴量に対して、特徴量の値とエラーへの寄与度との関係を可視化した例について説明する。

[0071] 図７は、本実施例に係る特徴量の値とパラメータのエラー発生への寄与度との関係の一例を示すグラフである。横軸に特徴量、縦軸にパラメータのエラー発生への寄与度をとっている。

[0072] 本図に示すように、エラーへの寄与度の値に基づく正常領域及び危険領域の判定や、実際のエラー発生位置を端末４の画面に表示することにより、抽出された特徴量の妥当性をユーザが評価することができる。

[0073] 図２において選定されたエラー要因が実際と異なる場合、ユーザは、端末

４を介して正しいエラー要因の指定（修正）をすることができる。指定が実施された場合、第２エラー予測モデル生成部１７にて新たなエラー予測モデルを生成する。

[0074] つぎに、第２エラー予測モデル生成部１７におけるモデル生成手順について説明する。

[0075] 図８は、本実施例に係る第２エラー予測モデル生成手順を示すフローチャートである。

[0076] 本図においては、ユーザによる原因パラメータの修正がある場合（ステップＳ８００）に、ステップＳ２０１に移行する。

[0077] ステップＳ２０１においては、エラー予測モデルの生成に必要な学習データの選定（抽出）をする。選定方法は、図３のステップＳ１０１とは異なる。図８のステップＳ２０１においては、エラー予測モデルで検出されたエラーに対して同じレシピ又は類似レシピを含むデータを抽出する。

[0078] 本図における以降のＳ１０２からＳ１０５までの処理は、図３と同様である。

[0079] 次に、ステップＳ２０２において、エラー予測モデルを解析し、ステップＳ２０１で抽出された学習データ内の特徴量におけるエラー判定への寄与度を数値化する。これは、図２におけるモデル解析部１５と同様の処理である。

[0080] ステップＳ２０３において、予め定められた順位内の寄与度の高い特徴量中に、ユーザから指定されたエラー要因が含まれていなければＳ１０２から同様の処理を繰り返し、含まれていれば新規エラー予測モデルの生成完了としてモデルデータベース１２に保存する（ステップＳ３００）。

[0081] このように、機械学習で正解にたどり着けない場合、人手で正解を教えることで学習モデルを高度化することができる。

実施例 2

[0082] 図９は、実施例２に係るデータ分類部を備えたエラー要因推定装置を示す構成図である。

[0083] 本実施例（本図）と実施例１との違いは、入力データ記録部５から送られたデータを分類するデータ分類部１８をエラー要因推定装置３に設けたことである。他の構成は、図２と同様である。

[0084] 実施例１においては、同じレシピで発生するエラーは同じ要因であるとの想定の下、同じレシピ又は類似のレシピのデータを用いて、モデル評価・モデル生成を実行している。

[0085] これに対して、本実施例（図９）においては、データ分類部１８にてエラー要因ごとにエラーデータを分類し、分類されたエラーデータごとにモデル評価・モデル生成を実行する。

[0086] つぎに、データ分類部１８の構成について説明する。

[0087] 図１０は、図９のデータ分類部の詳細を示す構成図である。

[0088] 図１０においては、データ分類部１８は、エラー予測モデル生成部１９と、モデル解析部１１５と、エラー要因クラスタリング部２０と、データ分割部２１と、分割データ記録部１２２と、を備えている。

[0089] エラー予測モデル生成部１９は、入力データ記録部５から送られた入力データに含まれるエラー発生の有無の判定に用いられる学習モデルであるエラー予測モデルを生成する。エラー予測モデル生成部１９における工程においては、図８のステップＳ１０３と同様のものを用いることができる。

[0090] モデル解析部１１５は、エラー予測モデル生成部１９にて生成されたモデルの判定結果に各特徴量がどの程度寄与したかを、例えばＳＨＡＰ値を用いて計算する。

[0091] エラー要因クラスタリング部２０は、モデル解析部１１５にて計算されたＳＨＡＰ値に代表される各特徴量のエラーへの寄与度について、教師なし学習を適用して分類する。

[0092] データ分割部２１は、分類されたエラーと正常データとに分割する。分割されたデータは、分割データ記録部１２２に保存される。

[0093] つぎに、この分類の考え方について説明する。

[0094] 図１１は、特徴量の値とパラメータのエラー発生への寄与度との関係を用

いてエラーデータを分類した状態を示すグラフである。横軸に特徴量、縦軸にパラメータのエラー発生への寄与度をとっている。

[0095] 本図においては、異なるエラー要因に対応する分類１、２をそれぞれの領域に分割し、それぞれにおいてエラー発生とされたデータ（エラーデータ）を分離する。これは、要因の異なるエラーでは、それを判別するためのモデル内部の分岐式も異なるためであり、エラー判定への寄与度を示すＳＨＡＰ値は、エラー要因に関連する特徴量ごとにその存在範囲が異なることが期待されるからである。エラーデータは、このＳＨＡＰ値に応じて分離する。

[0096] このようにしてエラー要因ごとに分離されたエラーデータに対して、図９の第１エラー予測モデル生成部１６や第２エラー予測モデル生成部１７にてエラー予測モデルを生成し、モデル解析部１５にてモデルを解析することにより、入力データ記録部５の入力データ内にモデルデータベース１２内のエラー予測モデルで対応できないエラー要因が複数存在する場合であっても、関連の低い特徴量がノイズとして抽出されることを回避して、抽出される特徴量の精度を高めることができる。ここで、データ分類部１８で分割されたエラーデータを用いてエラー予測モデルを生成する際には、対象のエラーデータと同一のレシピ又は類似のレシピである正常データを合わせて学習データとして用いることができる。

[0097] また、分類されたエラーデータごとに異なるラベル付けをして、このラベルとともにエラー予測モデルを生成してモデルデータベース１２に保存するとしてもよい。このラベル付けは、異なるインデックスを順に自動で割り振るとしてもよいし、ユーザがエラー要因をラベル付けするとしてもよい。このエラー要因のラベル付けは、分割されたデータ単位で実施すればよいため、従来手法である発生エラー１件単位へのラベル付けと比較して、処理数を大幅に削減することができる。この場合、図９においてモデル評価部１３が不要となり、モデル選定部１４の機能がエラーデータのラベルとエラー予測モデルのラベルとが一致するものを選択する動作に置き換わる。

実施例 3

[0098] 実施例１のエラー要因推定装置において、図２のモデルデータベース１２内に十分なエラー予測モデルのバリエーションが保存された際には、新たなエラー予測モデルは生成せず、入力されたエラーデータに対してエラー要因の推定のみを実施する運用としてもよい。

[0099] この場合におけるエラー要因推定装置の構成について、実施例３として説明する。

[0100] 図１２は、本実施例のエラー要因推定装置を示す構成図である。

[0101] 本図においては、データベース２２から、エラーデータとして、エラーが発生した測定点におけるレシピ・計測結果や、それと同じウエハであって同じレシピであるものにおけるレシピ・計測結果のデータセットが入力される。

[0102] 特徴量生成部１１にて、これらのデータに対して機械学習モデルに適した特徴量を抽出し、モデル入力エラーデータ記録部２３にエラーデータを出力する。

[0103] 以降の処理は、図２と同様であり、モデル入力エラーデータ記録部２３のエラー予測に対して評価値の高いエラー予測モデルを１つ以上モデルデータベース１２内から選択し、そのモデルの解析結果としてエラー予測に寄与度の大きい特徴量を、端末４を介してユーザに提示する。この場合、モデル選定部１４は、不要となる。

[0104] このようにエラー要因推定装置３の機能を発生したエラーの要因推定に限定することにより、必要となる入力データも最小限とすることができる。

[0105] 図１３は、エラー要因推定装置の変形例を示す構成図である。

[0106] 本図においては、エラー要因推定装置３は、エラー要因ラベル取得部２４と、エラー要因ラベルデータベース２５（エラー要因ラベルＤＢ）と、を備えている。これにより、モデル解析部１５で抽出された特徴量に基づきエラー要因候補を取得することができる。

[0107] エラー要因ラベルデータベース２５には、各特徴量やその組み合わせに対応するエラー要因の関係を保存しておく。この場合、特徴量へのエラー要因

のラベル付けが予め必要となるが、従来手法である発生エラー１件単位へのラベル付けと比較して、必要な処理数を大幅に削減することができる。

[0108] エラー要因ラベル取得部２４においては、モデル解析部１５で得られたランキング上位の特徴量に対して、エラー要因ラベルデータベース２５内のラベル関係を用いて対応するエラー要因を付与する。

[0109] このラベル付けされたエラー要因を、端末４を介してユーザに提示する。このとき、モデル解析部１５で計算された各特徴量の寄与度の大きさを、対応するエラー要因の確からしさとして換算して表示するとしてもよい。

[0110] つぎに、この表示の例について説明する。

[0111] 図１４は、本実施例に係るユーザへのエラー要因候補の表示例を示したものである。

[0112] 図中右側のグラフは、モデル解析部１５で計算された各特徴量の寄与度の大きさを示している。図中左側には、右側にグラフに示すデータを基に換算したエラー要因の確からしさを示している。

[0113] このように、エラー予測モデルを解析してエラー判定に寄与した特徴量を計算し、各特徴量やその組み合わせに対応したエラー要因がラベル付けされることにより、発生したエラーと相関の高い特徴量や対応するエラー要因候補をユーザに提示することができる。

[0114] （その他）

本発明は、前述した実施例に限定されるものではなく、様々な変形例が含まれる。上記の実施例は、本発明を分かりやすく説明するために詳細に説明したものであり、必ずしも説明した全ての構成を備えるものに限定されるものではない。例えば、実施例３の図１３に示すエラー要因ラベル取得部２４及びエラー要因ラベルデータベース２５は、実施例１の図２及び実施例２の図９にも組み合わせることができ、それぞれ特徴量や、特徴量の組み合わせに紐づけられたエラー要因をユーザに示すことができる。

[0115] 前述した実施例においては、半導体検査装置のエラー要因を推定する例を説明したが、装置の動作を規定するパラメータ及びそのパラメータを採用し

たときにエラーが生じるか否かについての予測モデルを生成させることにより、半導体検査装置以外の装置についても本発明を適用することができる。

[0116] また、前述した実施例においては、エラー予測モデルに対する特徴量の寄与度についてＳＨＡＰ値を用いて数値化する例を示しているが、Ｆｅａｔｕｒｅ　Ｉｍｐｏｒｔａｎｃｅ等、他の評価値を適用することができる。

符号の説明

[0117] １：半導体検査装置、２、２２：データベース、３：エラー要因推定装置、４：端末、５：入力データ記録部、１１：特徴量生成部、１２：モデルデータベース、１３、１３ａ、１３ｂ：モデル評価部、１４：モデル選定部、１５、１５ａ、１５ｂ、１１５：モデル解析部、１６：第１エラー予測モデル生成部、１７：第２エラー予測モデル生成部、１８：データ分類部、１９：エラー予測モデル生成部、２０：エラー要因クラスタリング部、２１：データ分割部、２３：モデル入力エラーデータ記録部、２４：エラー要因ラベル取得部、２５：エラー要因ラベルデータベース、１０１：ネットワーク。

請求の範囲

[請求項1] 外部から送られたデータを用いて機械学習モデルに適した特徴量を生成する特徴量生成部と、

前記特徴量を入力データとしてエラー発生の有無の判定に用いられるエラー予測モデルを少なくとも１つ以上有するモデルデータベースと、

前記エラー予測モデルの予測結果と実際に計測された真のエラー結果とを比較して前記エラー予測モデルの性能を評価するモデル評価部と、

前記モデル評価部で計算された評価値が予め設定された規定値以上となる前記エラー予測モデルを前記モデルデータベースから選定するモデル選定部と、

前記モデル選定部にて選択される前記エラー予測モデルの該当がない場合には、計測されたエラーに対して新たなエラー予測モデルを生成するエラー予測モデル生成部と、を備えた、エラー要因の推定装置。

[請求項2] 前記入力データ内のエラーデータをエラー要因ごとに分類するデータ分類部を更に備えた、請求項１記載のエラー要因の推定装置。

[請求項3] 前記エラー予測モデル生成部は、分類された前記エラーデータごとに異なるラベル付けをして、このラベルとともに前記エラー予測モデルを生成し、このエラー予測モデルを前記モデルデータベースに送信する、請求項２記載のエラー要因の推定装置。

[請求項4] 前記モデル選定部で選定された前記エラー予測モデルにおけるエラー判定結果に対する前記特徴量の寄与度を数値化するモデル解析部を更に備えた、請求項１～３のいずれか一項に記載のエラー要因の推定装置。

[請求項5] 前記モデル解析部で計算された前記寄与度の値が高いものの前記特徴量について、エラー要因候補としてユーザに提示する構成を有する

、請求項４記載のエラー要因の推定装置。

[請求項6] 前記モデル選定部で複数のエラー予測モデルが選定された場合には、

前記モデル評価部は、モデル評価値を算出し、

前記モデル解析部で計算された前記特徴量ごとの前記寄与度は、前記モデル評価値を用いて補正され、前記複数のエラー予測モデルのそれぞれから計算された補正後の寄与度の値が高いものの前記特徴量について、エラー要因候補としてユーザに提示する構成を有する、請求項４記載のエラー要因の推定装置。

[請求項7] 前記エラー要因候補に対して前記ユーザから修正があった場合には、修正後のエラー要因が前記モデル解析部の解析結果に含まれるようにエラー予測モデルを生成するもう１つのエラー予測モデル生成部を更に備えた、請求項５又は請求項６に記載のエラー要因の推定装置。

[請求項8] 前記特徴量生成部で生成された前記特徴量及びその組み合わせのうち少なくともいずれか一方に対応するエラー要因の関係を保存するエラー要因ラベルデータベースと、

前記モデル解析部で数値化された前記寄与度に対応する前記特徴量に対して前記エラー要因ラベルデータベース内のラベル関係を用いて対応するエラー要因を付与するエラー要因ラベル取得部と、を更に備えた、請求項４記載のエラー要因の推定装置。

[請求項9] 前記エラー予測モデル生成部は、対象とするエラーが発生した動作工程及びそれ以前の動作工程における前記入力データを用いて新たなエラー予測モデルを生成する、請求項１～３のいずれか一項に記載のエラー要因の推定装置。

[請求項10] 外部から送られたデータを用いて機械学習モデルに適した特徴量を生成する特徴量生成工程と、

モデルデータベースに保存されているエラー予測モデルの予測結果と実際に計測された真のエラー結果とを比較して、前記特徴量を入力

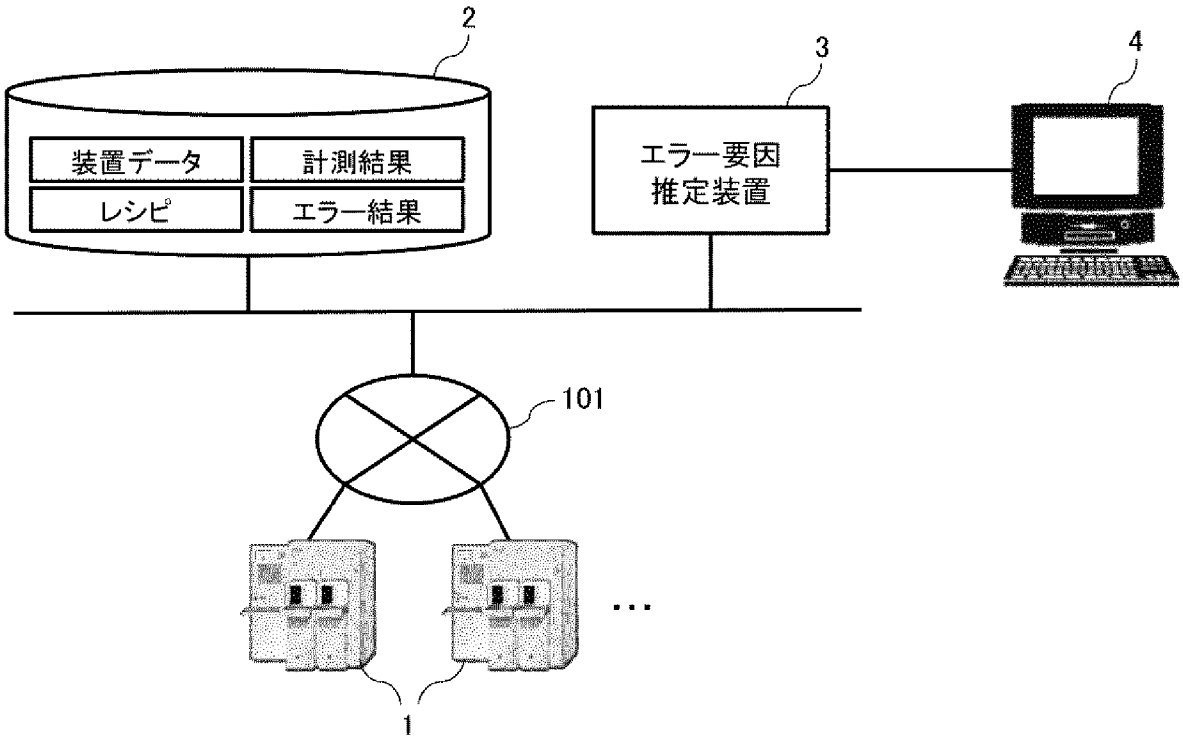
データとしてエラー発生の有無の判定に用いられるエラー予測モデルの性能を評価するモデル評価工程と、

前記モデル評価工程で計算された評価値が予め設定された規定値以上となる前記エラー予測モデルを前記モデルデータベースから選定するモデル選定工程と、

前記モデル選定工程にて選択される前記エラー予測モデルの該当がない場合には、計測されたエラーに対して新たなエラー予測モデルを生成するエラー予測モデル生成工程と、を含む、エラー要因の推定方法。

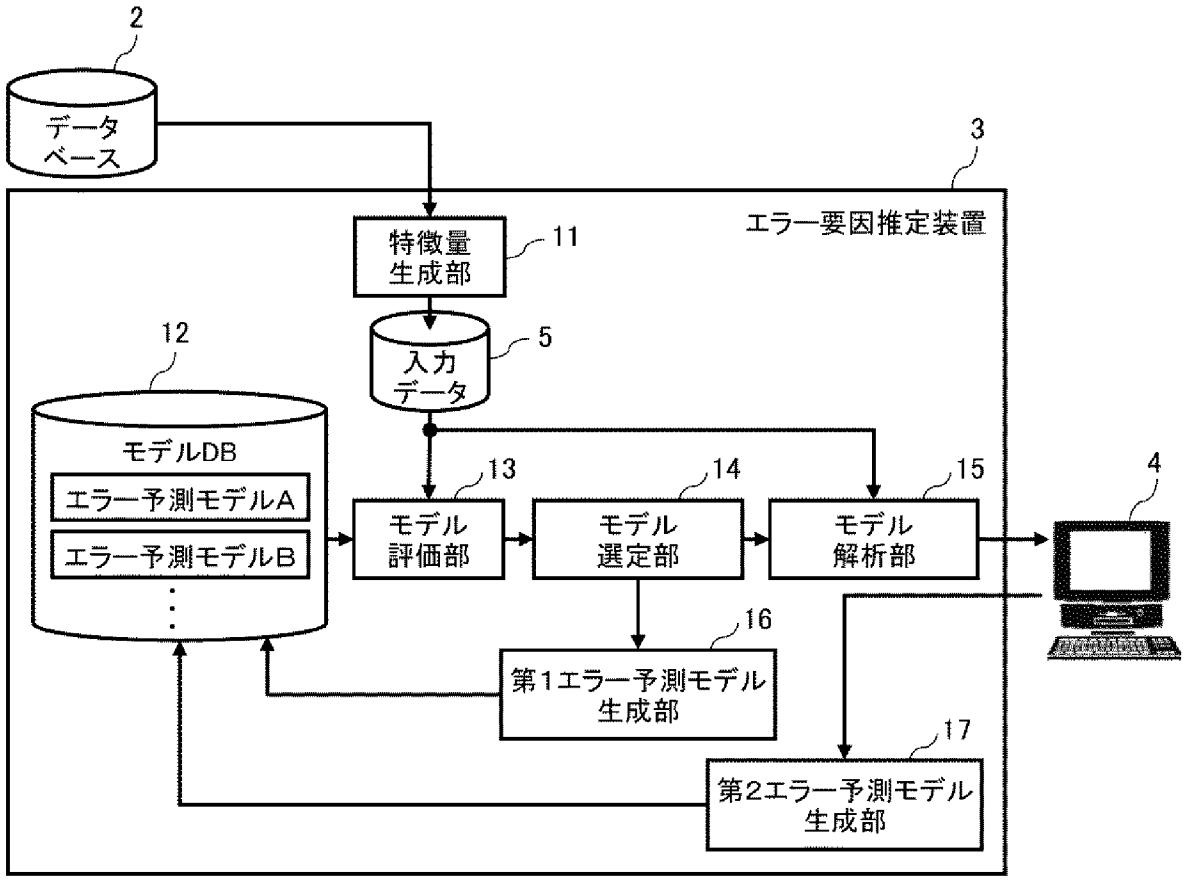
[図1]

図 1



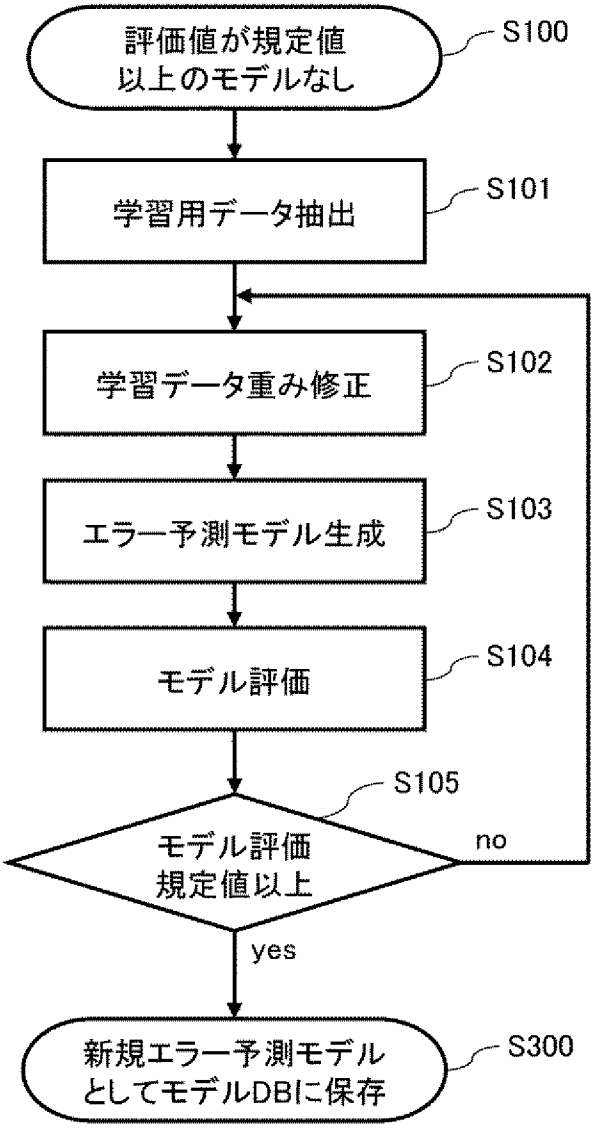
[図2]

図 2


2
データベース
3
エラー要因推定装置
特徴量生成部
11
入力データ
5
12
モデルDB
エラー予測モデルA
エラー予測モデルB
13
モデル評価部
14
モデル選定部
15
モデル解析部
4
16
第1エラー予測モデル生成部
17
第2エラー予測モデル生成部

[図3]

図 3



[図4]

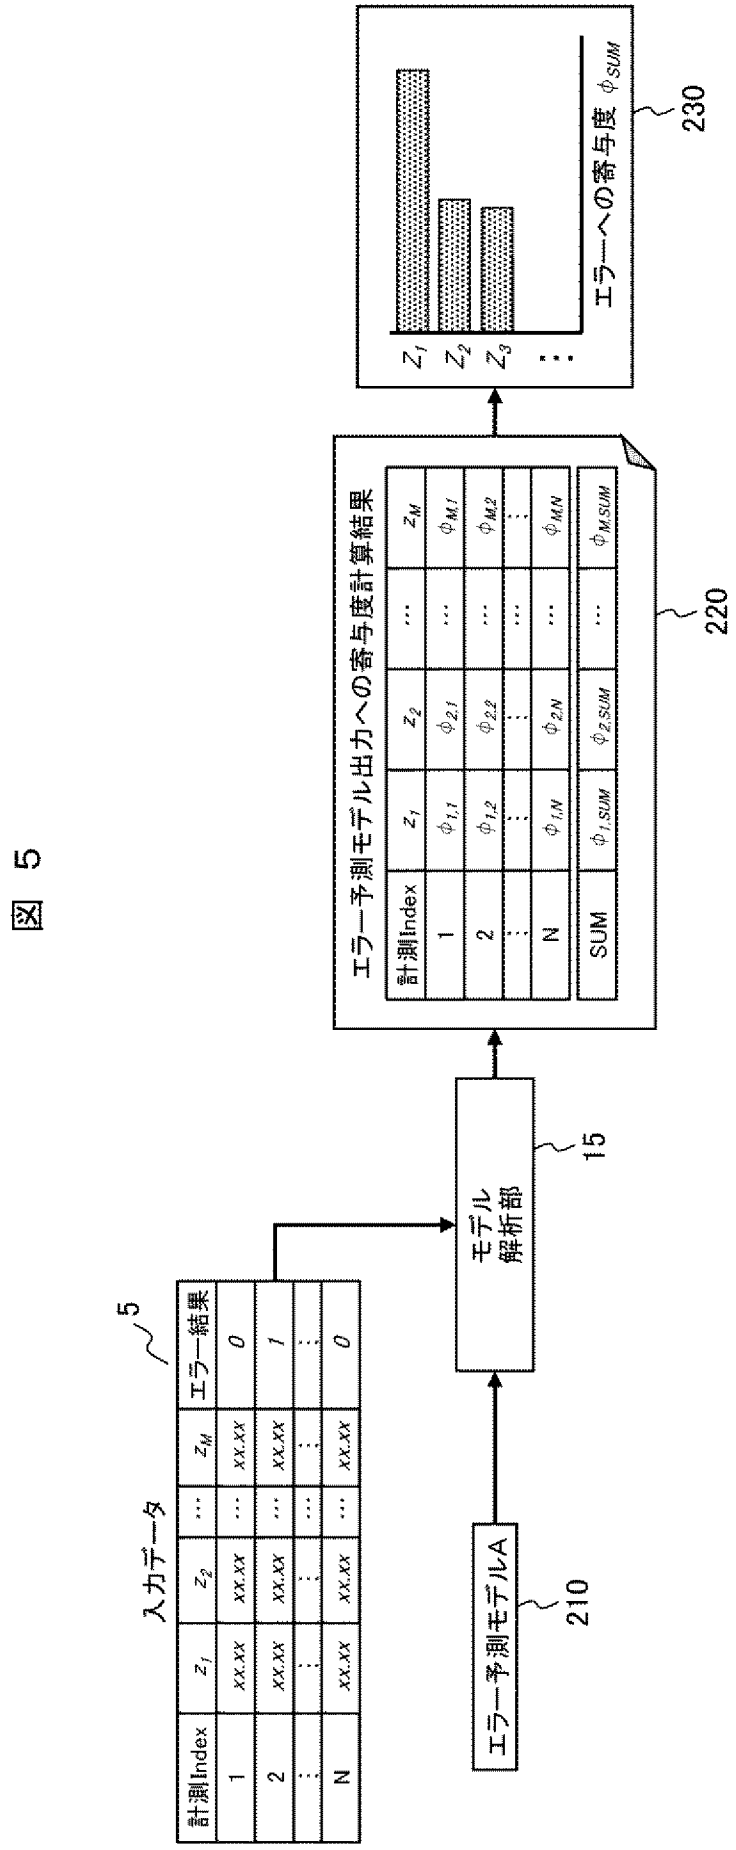
図 4

測定Index	z_1	z_2	…	z_M	動作工程	エラー結果
1	xx.xx	xx.xx	…	xx.xx	1	0
2	xx.xx	xx.xx	…	xx.xx	2	1
3	xx.xx	xx.xx	…	xx.xx	2	0
4	xx.xx	xx.xx	…	xx.xx	3	0
…						

学習データ

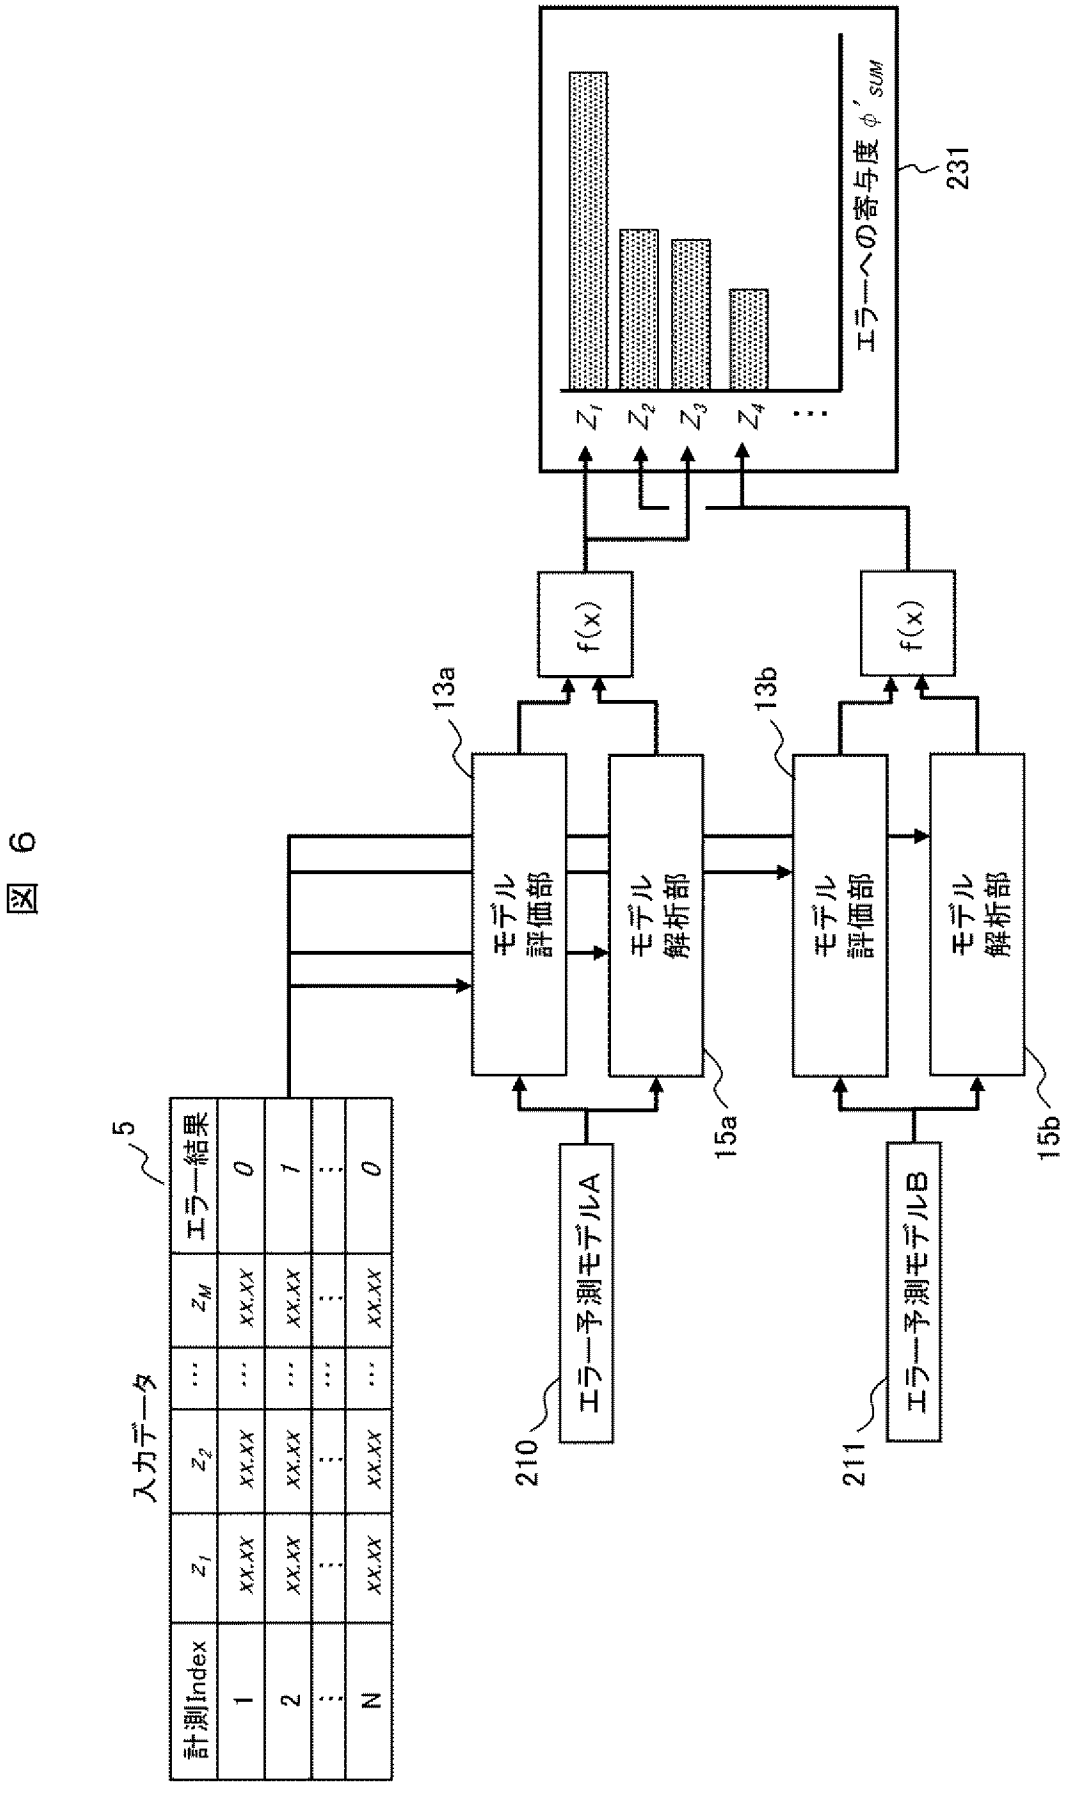
[図5]

図 5


入力データ
5
計測Index
z_1
z_2
z_M
エラー結果
1
2
N
xx.xx
0
1
エラー予測モデルA
210
モデル解析部
15
エラー予測モデル出力への寄与度計算結果
SUM
220
エラーへの寄与度 ϕ_{SUM}
230

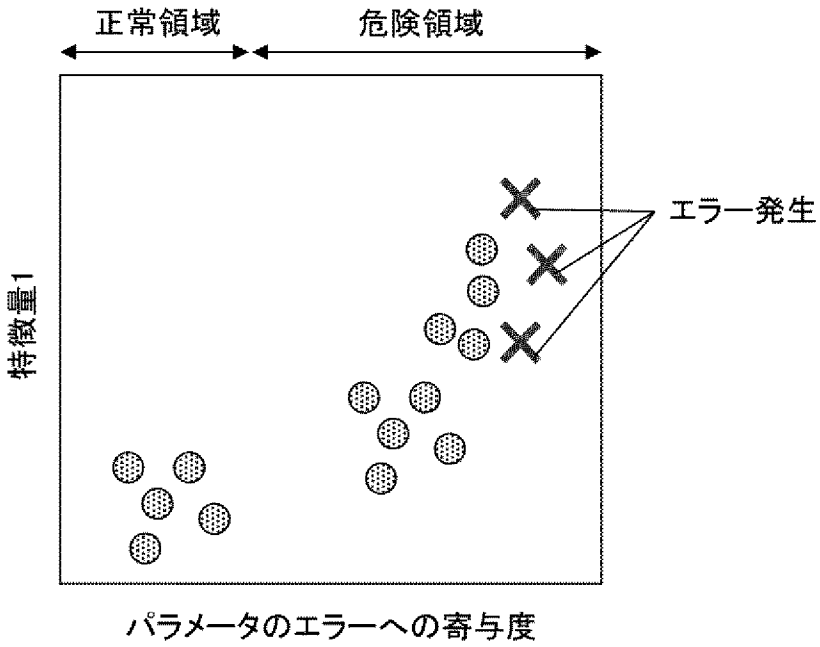
[図6]

図 6


入力データ
5
計測Index
z_1
z_2
…
z_M
エラー結果
1
xx.xx
xx.xx
…
xx.xx
0
2
xx.xx
xx.xx
…
xx.xx
1
N
xx.xx
xx.xx
…
xx.xx
0
13a
13b
モデル評価部
モデル解析部
モデル評価部
モデル解析部
f(x)
f(x)
15a
15b
210
211
エラー予測モデルA
エラー予測モデルB
231
エラーへの寄与度 ϕ'_{SUM}
z_1 z_2 z_3 z_4 …

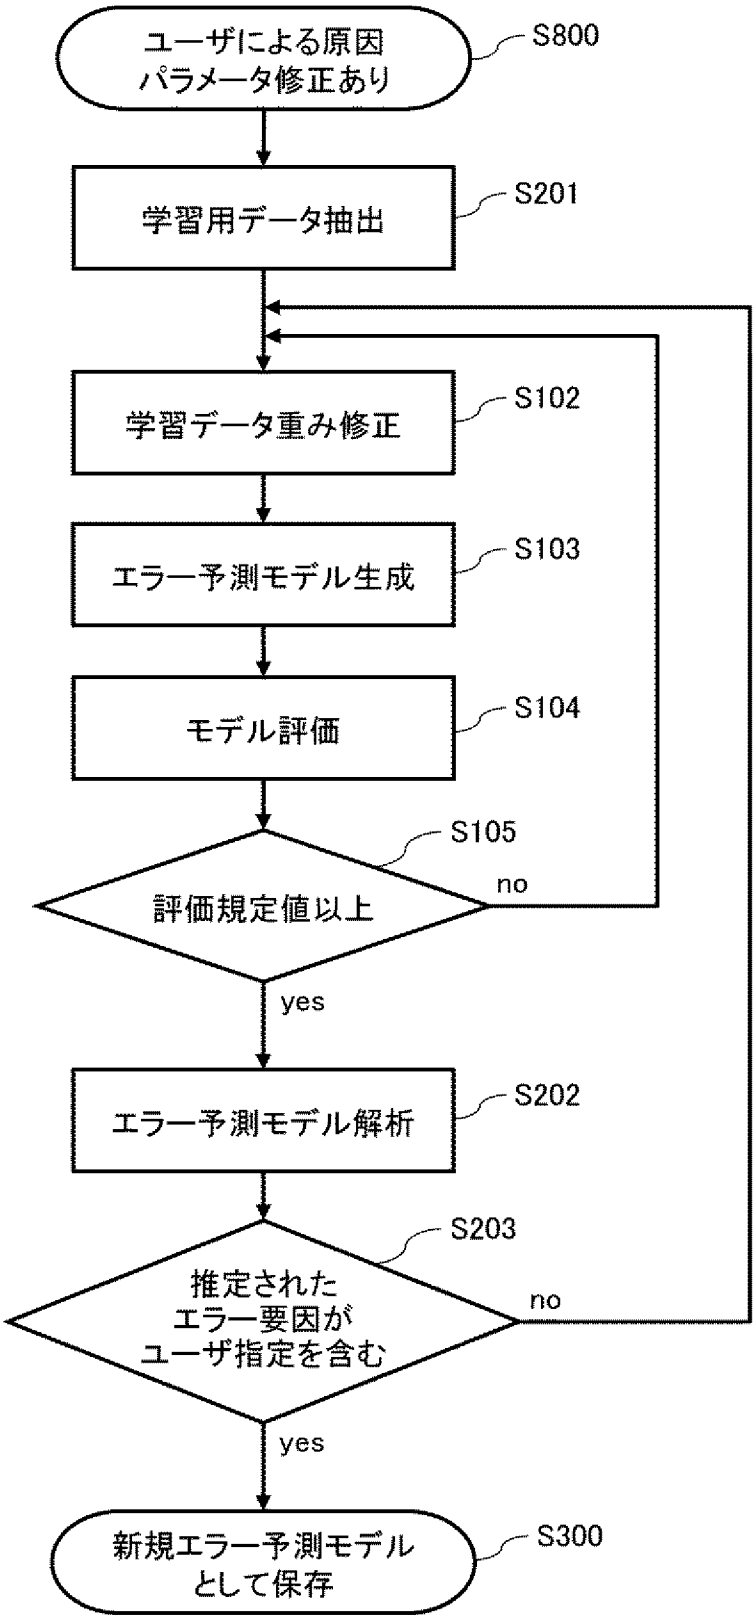
[図7]

図 7



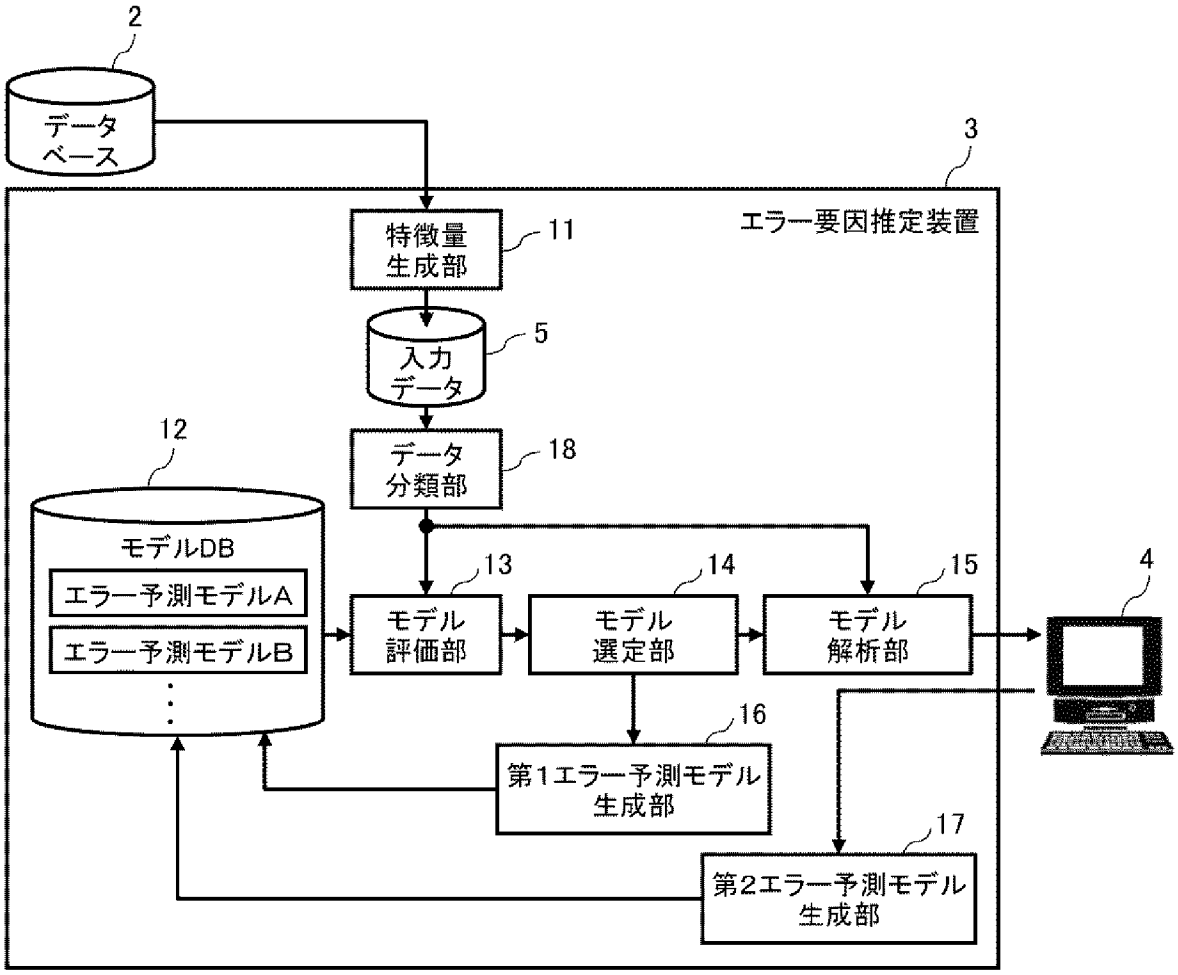
[図8]

図 8


ユーザによる原因
パラメータ修正あり
S800
学習用データ抽出
S201
学習データ重み修正
S102
エラー予測モデル生成
S103
モデル評価
S104
S105
評価規定値以上
no
yes
エラー予測モデル解析
S202
S203
推定された
エラー要因が
ユーザ指定を含む
no
yes
新規エラー予測モデル
として保存
S300

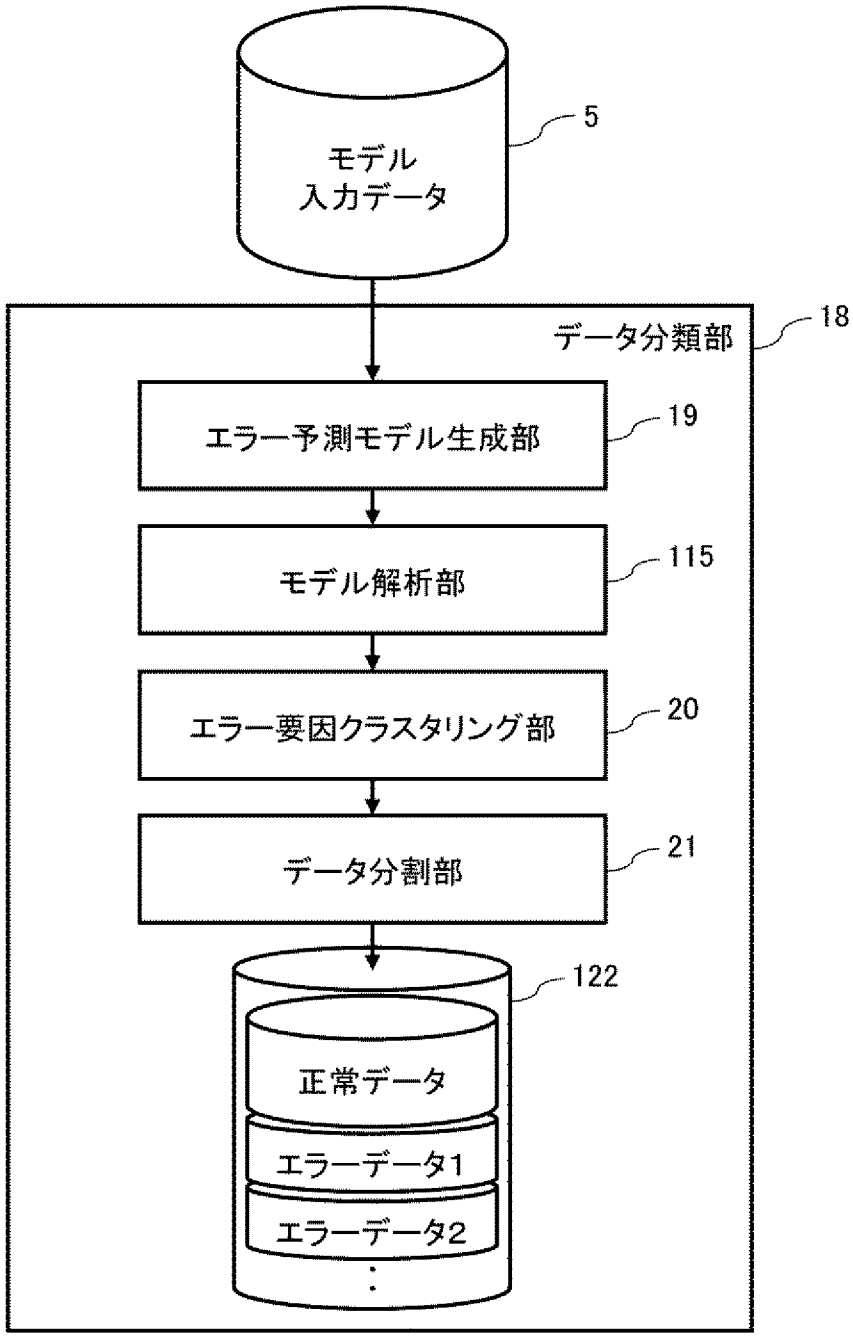
[図9]

図 9


2
データベース
3
エラー要因推定装置
特徴量生成部
11
入力データ
5
データ分類部
18
12
モデルDB
エラー予測モデルA
エラー予測モデルB
13
モデル評価部
14
モデル選定部
15
モデル解析部
4
16
第1エラー予測モデル生成部
17
第2エラー予測モデル生成部

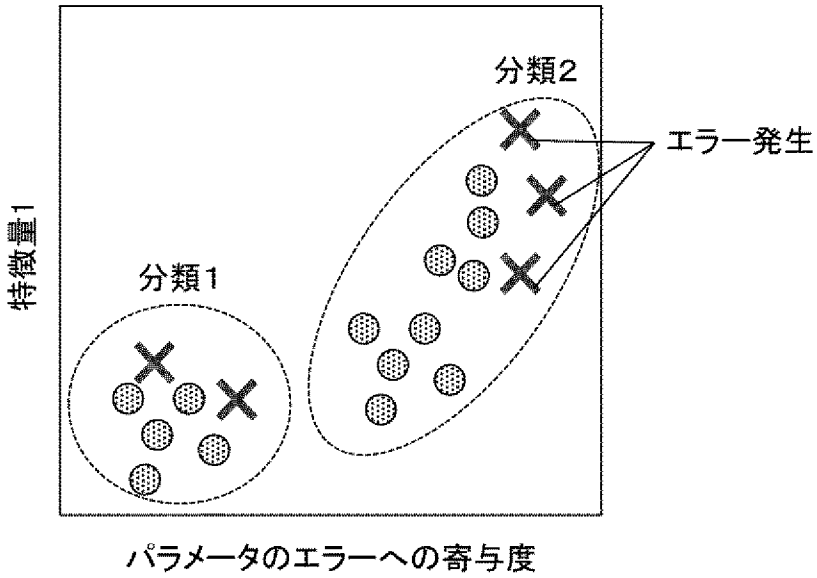
[図10]

図 10


モデル
入力データ
5
データ分類部
18
エラー予測モデル生成部
19
モデル解析部
115
エラー要因クラスタリング部
20
データ分割部
21
122
正常データ
エラーデータ1
エラーデータ2

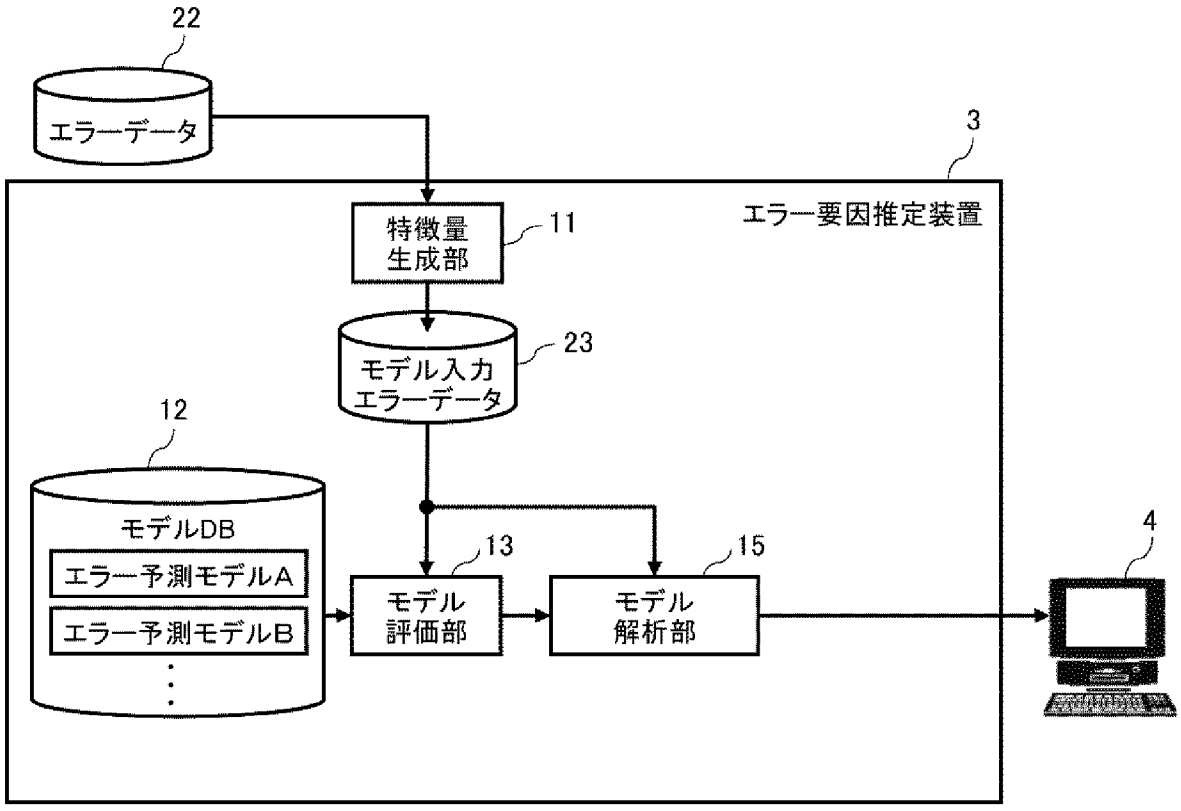
[図11]

図 11



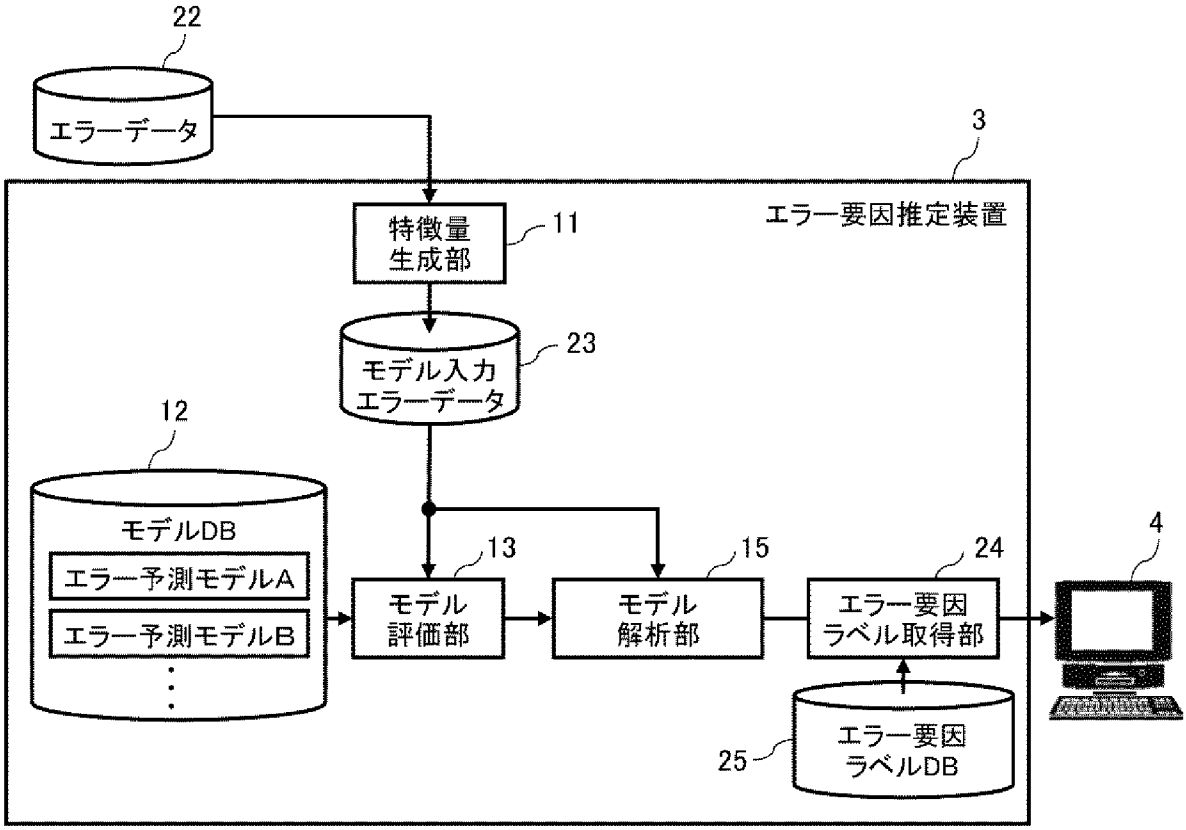
[図12]

図 12



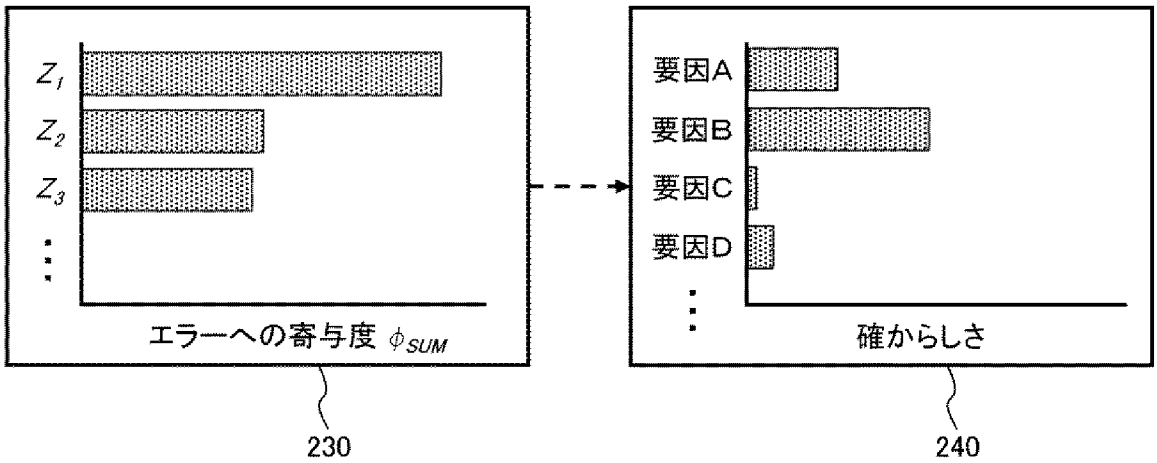
[図13]

図 13



[図14]

図 14



INTERNATIONAL SEARCH REPORT

International application No.
PCT/JP2020/014727

A. CLASSIFICATION OF SUBJECT MATTER
Int.Cl. G06N20/00(2019.01)i
FI: G06N20/00

According to International Patent Classification (IPC) or to both national classification and IPC

B. FIELDS SEARCHED

Minimum documentation searched (classification system followed by classification symbols)
Int.Cl. G06N20/00

Documentation searched other than minimum documentation to the extent that such documents are included in the fields searched
Published examined utility model applications of Japan 1922-1996
Published unexamined utility model applications of Japan 1971-2020
Registered utility model specifications of Japan 1996-2020
Published registered utility model applications of Japan 1994-2020

Electronic data base consulted during the international search (name of data base and, where practicable, search terms used)

C. DOCUMENTS CONSIDERED TO BE RELEVANT

Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
Y A	JP 6530779 B1 (FANUC LTD.) 24 May 2019 (2019-05-24), paragraphs [0023]-[0040], [0047]-[0050]	1-5, 7-10 6
Y A	WO 2018/173121 A1 (PREFERRED NETWORKS, INC.) 27 September 2018 (2018-09-27), paragraphs [0022]-[0035]	1-5, 7-10 6
Y A	JP 2019-537839 A (KLA CORPORATION) 26 December 2019 (2019-12-26), paragraphs [0078], [0079], [0092], [0098], [0101]	4-5, 7-8 6

☐ Further documents are listed in the continuation of Box C.

☒ See patent family annex.

* Special categories of cited documents:
"A" document defining the general state of the art which is not considered to be of particular relevance
"E" earlier application or patent but published on or after the international filing date
"L" document which may throw doubts on priority claim(s) or which is cited to establish the publication date of another citation or other special reason (as specified)
"O" document referring to an oral disclosure, use, exhibition or other means
"P" document published prior to the international filing date but later than the priority date claimed
"T" later document published after the international filing date or priority date and not in conflict with the application but cited to understand the principle or theory underlying the invention
"X" document of particular relevance; the claimed invention cannot be considered novel or cannot be considered to involve an inventive step when the document is taken alone
"Y" document of particular relevance; the claimed invention cannot be considered to involve an inventive step when the document is combined with one or more other such documents, such combination being obvious to a person skilled in the art
"&" document member of the same patent family

Date of the actual completion of the international search	Date of mailing of the international search report
01 June 2020	09 June 2020
Name and mailing address of the ISA/ Japan Patent Office 3-4-3, Kasumigaseki, Chiyoda-ku, Tokyo 100-8915, Japan	Authorized officer Telephone No.

INTERNATIONAL SEARCH REPORT
Information on patent family members

International application No.
PCT/JP2020/014727

JP 6530779 B1	24 May 2019	US 2018-0307203 A1 paragraphs [0031]-[0049], [0055]-[0061]
WO 2018/173121 A1	27 September 2018	US 2020-0014761 A1 paragraphs [0026]-[0041]
JP 2019-537839 A	26 December 2019	US 2018-0107928 A1 paragraphs [0080], [0081], [0094], [0100], [0103]

国際調査報告

国際出願番号
PCT/JP2020/014727

A. 発明の属する分野の分類（国際特許分類（ＩＰＣ））

G06N 20/00(2019.01)i
FI: G06N20/00

B. 調査を行った分野

調査を行った最小限資料（国際特許分類（ＩＰＣ））

G06N20/00

最小限資料以外の資料で調査を行った分野に含まれるもの

日本国実用新案公報	１９２２－１９９６年
日本国公開実用新案公報	１９７１－２０２０年
日本国実用新案登録公報	１９９６－２０２０年
日本国登録実用新案公報	１９９４－２０２０年

国際調査で使用した電子データベース（データベースの名称、調査に使用した用語）

C. 関連すると認められる文献

引用文献のカテゴリー*	引用文献名　及び一部の箇所が関連するときは、その関連する箇所の表示	関連する請求項の番号
Y	JP 6530779 B1 (ファナック株式会社) 24.05.2019 (2019-05-24) [0023]-[0040],[0047]-[0050]	1-5,7-10
A		6
Y	WO 2018/173121 A1 (株式会社Ｐｒｅｆｅｒｒｅｄ　Ｎｅｔｗｏｒｋｓ) 27.09.2018 (2018-09-27) [0022]-[0035]	1-5,7-10
A		6
Y	JP 2019-537839 A (ケーエルエー コーポレイション) 26.12.2019 (2019-12-26) [0078]-[0079],[0092],[0098],[0101]	4-5,7-8
A		6

☐ Ｃ欄の続きにも文献が列挙されている。

☑ パテントファミリーに関する別紙を参照。

* 引用文献のカテゴリー
"A" 特に関連のある文献ではなく、一般的技術水準を示すもの
"E" 国際出願日前の出願または特許であるが、国際出願日以後に公表されたもの
"L" 優先権主張に疑義を提起する文献又は他の文献の発行日若しくは他の特別な理由を確立するために引用する文献（理由を付す）
"O" 口頭による開示、使用、展示等に言及する文献
"P" 国際出願日前で、かつ優先権の主張の基礎となる出願の日の後に公表された文献
"T" 国際出願日又は優先日後に公表された文献であって出願と抵触するものではなく、発明の原理又は理論の理解のために引用するもの
"X" 特に関連のある文献であって、当該文献のみで発明の新規性又は進歩性がないと考えられるもの
"Y" 特に関連のある文献であって、当該文献と他の１以上の文献との、当業者にとって自明である組合せによって進歩性がないと考えられるもの
"&" 同一パテントファミリー文献

国際調査を完了した日	国際調査報告の発送日
01.06.2020	09.06.2020

名称及びあて先
日本国特許庁(ISA/JP)
〒100-8915
日本国
東京都千代田区霞が関三丁目４番３号

権限のある職員（特許庁審査官）
渡部　博樹 5B 3868
電話番号 03-3581-1101 内線 3545

国際調査報告
パテントファミリーに関する情報

国際出願番号
PCT/JP2020/014727

引用文献	公表日	パテントファミリー文献	公表日
JP 6530779 B1	24.05.2019	US 2018-0307203 A1 [0031]-[0049],[0055]-[0061]	
WO 2018/173121 A1	27.09.2018	US 2020-0014761 A1 [0026]-[0041]	
JP 2019-537839 A	26.12.2019	US 2018-0107928 A1 [0080]-[0081],[0094],[0100],[0103]	