

(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
2016年10月20日(20.10.2016)



(10) 国際公開番号

WO 2016/166878 A1

- (51) 国際特許分類:
G06Q 50/10 (2012.01) *G06F 19/00* (2011.01)
G06F 17/30 (2006.01)
- (21) 国際出願番号: PCT/JP2015/061778
- (22) 国際出願日: 2015年4月17日(17.04.2015)
- (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: 株式会社日立製作所(HITACHI, LTD.)
[JP/JP]; 〒1008280 東京都千代田区丸の内一丁目
6番6号 Tokyo (JP).
- (72) 発明者: 平山 淳一(HIRAYAMA Junichi); 〒
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). 嶺 竜治
(MINE Ryuji); 〒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).
- (74) 代理人: 井上 学, 外(INOUE Manabu et al.); 〒
1008220 東京都千代田区丸の内一丁目6番1号
株式会社日立製作所内 Tokyo (JP).

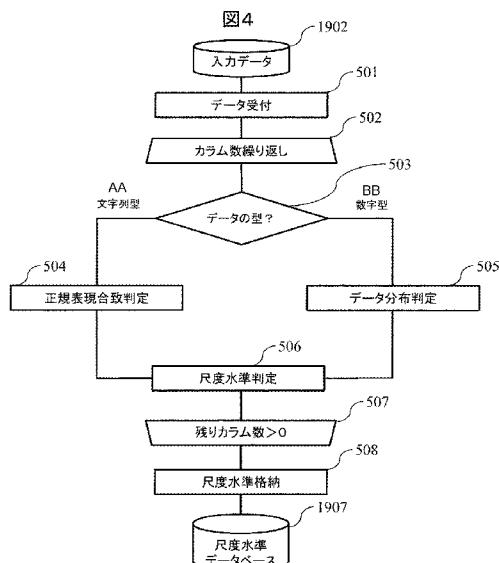
(81) 指定国(表示のない限り、全ての種類の国内保護が可能): AE, AG, AL, AM, AO, AT, AU, AZ, BA, BB, BG, BH, BN, BR, BW, BY, BZ, CA, CH, CL, CN, CO, CR, CU, CZ, DE, DK, DM, DO, DZ, EC, EE, EG, ES, FI, GB, GD, GE, GH, GM, GT, HN, HR, HU, ID, IL, IN, IR, IS, JP, KE, KG, KN, KP, KR, KZ, LA, LC, LK, LR, LS, LU, LY, MA, MD, ME, MG, 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, SM, ST, SV, SY, TH, TJ, TM, TN, TR, TT, TZ, UA, UG, US, UZ, VC, VN, 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), エリトリア (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).

[続葉有]

(54) Title: AUTOMATIC DATA PROCESSING SYSTEM, AUTOMATIC DATA PROCESSING METHOD, AND AUTOMATIC DATA ANALYSIS SYSTEM

(54) 発明の名称: データ自動加工システム、データ自動加工方法、およびデータ自動解析システム



- 501 Data reception
502 Repeat column number
503 Data type?
504 Regular expression conformance determination
505 Data distribution determination
506 Scaling level determination
507 Remaining number of columns > 0
508 Scaling level storage
1902 Input data
1907 Scaling level database
AA Character string
BB Numerical

(57) Abstract: An automatic data processing system is configured to comprise: a reception unit for receiving data pertaining to numbers, characters, and symbols; a data type determination unit for determining the type of the data; a scaling level determination unit for determining the scaling level of the data on the basis of the distribution of the data when the data is numerical; and a data processing unit for processing data on the basis of the scaling level. Such a configuration makes it possible to provide a system for automatically determining the scaling level, which is an index for setting the properties of the data, and performing automatic processing of the data.

(57) 要約: データ自動加工システムを、数字、文字、および符号に関するデータを受け付ける受付部と、データの型を判定するデータ型判定部と、データが数字型である場合に、データの分布に基づいてデータの尺度水準を判定する尺度水準判定部と、尺度水準に基づいてデータを加工するデータ加工部からなる構成とする。係る構成により、データの性質を定める指標である尺度水準を自動で判定し、データの自動加工を行うシステムを提供することができる。



添付公開書類:

— 国際調査報告（条約第 21 条(3)）

明 細 書

発明の名称 :

データ自動加工システム、データ自動加工方法、およびデータ自動解析システム

技術分野

[0001] 本発明は、データ自動加工システム、データ自動加工方法、およびデータ自動解析システムに関する。

背景技術

[0002] 近年、ビッグデータと呼ばれる大量のデータを分析し、今まで人が勘と経験で行ってきた意思決定を支援するシステムの開発が急速に発展してきている。例えば、ある目的変数を変動させる他の説明変数が何であるかと見つけ出すための相関分析や、説明変数群の値から目的変数の値を予測する回帰分析や、似た傾向を持つ変数同士をグルーピングするクラスタリングといった機械学習・統計分析を主なデータ分析の手法としているシステムが開発されている。

[0003] データ分析を行う際、蓄積した生のデータそのままでは、分析に適さないことが多く、何らかの加工演算を施したデータを新たに分析用のデータとすることが多い。データ加工演算の例として、量子化や代表値などがある。量子化とは、例えば $0.0 \sim 30.0$ で分布しているデータを、 $0.0 \sim 10.0 \Rightarrow \text{Low}$ 、 $10.0 \sim 20.0 \Rightarrow \text{Middle}$ 、 $20.0 \sim 30.0 \Rightarrow \text{High}$ のようにある区間に分け、その区間に属する値に対して、新たにラベル化する作業である。代表値とは、あるカラム内のデータに対する平均や各値の頻度などにより、データをそのカラムを代表する1つの値にまとめた数値のことである。データ加工の例を、図1を用いて説明する。図1はRDB（リレーションナルデータベース）形式の入力テーブル100に蓄積されたデータを、出力テーブル110に圧縮している例である。入力テーブル100が”作業ID”（104）をキーとしているのに対し、圧縮後の出力テーブル110では、”作業者ID”（111）がキー

となっている。このとき、”作業者ID”（101）が同じレコードをグループとし、そのグループごとに代表値を求めている。この加工により、各カラムの値を、それぞれの作業者「700A」「700B」「700C」を代表する値に直すことができる。前述のデータ加工に関する文献として、特許文献1がある。この公報では、テーブルに蓄積された変数を元に、事前に定めたルール・集計方法に従い、新たな変数を作成し、それを新たに説明変数として追加している。ルール・集計方法の例として、時系列を表す変数があれば1時間ごとに纏めて平均をとる集約演算などがある。このように説明変数を追加した後に、目的変数と説明変数の寄与度を計算することで、目的変数に寄与する説明変数を特定している。

[0004] また、データの性質を定める指標である尺度水準というものが知られている。例えば特許文献2には、データの尺度水準によって散布度の計算式を変えて、計算した散布度によって自社の製品・サービスの独自性を判定し、ポジショニング・マップを作成している。更に、非特許文献1には、尺度水準についての記載が存在する。

先行技術文献

特許文献

[0005] 特許文献1：特開2012-27880号公報

特許文献2：特開2011-243050号公報

非特許文献

[0006] 非特許文献1：S. S. Stevens, “On the Theory of Scales of Measurement,” Science, vol. 103, no. 2684, pp. 677-680, Jun. 1946

発明の概要

発明が解決しようとする課題

[0007] しかしながら、データの加工演算に関して見かけ上は同様に数値に見えるデータであっても、そのデータの持つ性質は異なり、適用出来る加工演算も異なる。例えば、作業ごとの所要時間：[180[s], 240[s], …]のような数量

を示すデータに対して平均を求める代表値化には意味があるが、作業者ID：[23513, 24512, …]のような符号や名前を示すデータに対して平均を求めてもその数値は意味を成さない。このように、意味を成さない演算を施してしまった場合には、適切な分析結果にはならず、誤った分析結果を招いてしまう恐れや、真に抽出したい分析結果が意味のない分析結果に埋もれてしまう恐れがある。

[0008] 前述の例のような、適用可能なデータ加工演算は、前処理としてデータ分析の知識を持つ専門家が、手作業で全てのカラムに対し適切に設定する必要があり、分析作業のコスト増大の原因となっていた。また、データ分析の知識を持たない非専門家が、これらの設定を行うことは困難であった。

[0009] さらに、特許文献2では、データの尺度水準によって散布度の計算方法を変えているが、データの尺度水準をユーザが事前に指定する必要があり、尺度水準の判定を自動で行うことはできなかった。

[0010] そこで、本発明はデータの性質を定める指標である尺度水準を自動で判定し、各データに適した方法によりデータ加工を行うシステムおよび方法、並びにデータの尺度水準を自動で判定する機能を有するデータ解析システムを提供することを目的とする。

課題を解決するための手段

[0011] 前記課題を解決するための手段のうち代表的なものを例示すれば、数字、文字、および符号に関するデータを受け付ける受付部と、データについてデータの型を判定するデータ型判定部と、データが数字型である場合にデータの分布に基づいてデータの尺度水準を判定する尺度水準判定部と、尺度水準に基づいてデータを加工するデータ加工部と、を有するデータ自動加工システムが挙げられる。

[0012] また、数字、文字、および符号に関するデータを入力とするデータ自動加工方法であって、データを受け付ける受付ステップと、データについてデータの型を判定するデータ型判定ステップと、データが数字型である場合にデータの分布に基づいてデータの尺度水準を判定する尺度水準判定ステップと

、尺度水準に基づいてデータを加工するデータ加工ステップと、を有することを特徴とするデータ自動加工方法が挙げられる。

[0013] さらに、数字、文字、および符号に関するデータを受け付ける受付部と、データについてデータの型を判定するデータ型判定部と、データが数字型である場合にデータの分布に基づいてデータの尺度水準を判定する尺度水準判定部と、尺度水準に基づいてデータを加工するデータ加工部と、加工部によって加工されたデータを解析するデータ解析部と、解析部によって解析されたデータを出力する出力部と、を有するデータ解析システムが挙げられる。

発明の効果

[0014] 本発明によれば、データの性質を定める指標である尺度水準を自動で判定し、データの自動加工を行うシステムおよび方法、並びにデータの尺度水準を自動で判定する機能を有するデータ解析システムを提供することができる。

図面の簡単な説明

[0015] [図1]データ加工の一例を示す図。

[図2]各尺度水準の説明図。

[図3]入出力テーブルの一例を示す図。

[図4]データ自動加工システムの処理フローを示す図。

[図5]データ分布判定ステップの処理フローを示す図。

[図6]正規表現判定ステップの処理フローを示す図。

[図7]加工演算判定部の処理フローを示す図。

[図8]尺度水準ごとの適用可能加工演算を示すテーブルの一例を示す図。

[図9]加工演算選択部の処理フローを示す図。

[図10]演算口バスト性判定ステップの処理フローを示す図。

[図11]データ自動加工システムのハードウェア構成図。

[図12]各尺度水準を持つデータの分布を示す図。

[図13]等分散性と非等分散性を持つデータの分布を示す図。

[図14]単調変化の特性を持つデータの分布を示す図。

[図15]データの等分散性の判定の流れの一例を示す図。

[図16]データ加工操作を行うためのG U Iの一例を示す図。

[図17]データ自動解析システムの構成図。

[図18]データ自動加工システムの構成図。

[図19]加工演算データベースおよび加工演算判定部を有するデータ自動加工システムの構成図。

[図20]加工演算選択部を有するデータ自動加工システムの構成図。

発明を実施するための形態

[0016] 以下の実施の形態においては、便宜上その必要があるときは、複数のセクションまたは実施の形態に分割して説明するが、特に明示した場合を除き、それらは互いに無関係なものではなく、一方は他方の一部または全部の変形例、詳細、補足説明等の関係にある。また、以下の実施の形態において、要素の数等（個数、数値、量、範囲等を含む）に言及する場合、特に明示した場合および原理的に明らかに特定の数に限定される場合等を除き、その特定の数に限定されるものではなく、特定の数以上でも以下でもよい。

[0017] さらに、以下の実施の形態において、その構成要素（要素ステップ等も含む）は、特に明示した場合および原理的に明らかに必須であると考えられる場合等を除き、必ずしも必須のものではないことは言うまでもない。同様に、以下の実施の形態において、構成要素等の形状、位置関係等に言及するときは、特に明示した場合および原理的に明らかにそうでないと考えられる場合等を除き、実質的にその形状等に近似または類似するもの等を含むものとする。このことは、上記数値および範囲についても同様である。

実施例 1

[0018] 本実施例では、データの尺度水準を自動で決定するデータ自動加工システムの例を説明する。

[0019] 図18は、本実施例のデータ自動加工システムの構成図の例である。データ自動加工システム1901は、入力データ1902を受け付けて、データの尺度水準を判定しデータを加工して、出力データベース1903に加工デ

ータを出力する。データ自動加工システム 1901 は、データ受付部 1904、データ型判定部 1905、尺度水準判定部 1906、尺度水準データベース 1907、及びデータ加工部 1908 を備えている。

- [0020] データ受付部 1904 は、入力データ 1902 を受け付ける。その際、受け付けたデータをデータ自動加工システム 1901 中で取り扱うデータ形式に変換してもよい。入力データ 1902 は、数字、文字、または符号に関するデータである。入力データ 1902 の例として、例えば表形式のデータがある。表形式のデータを示した図 3 の入力テーブル 400 は、RDB (リレーションナルデータベース) の形式をしており、キー部 404 およびバリュ部 405 からなる。この他に、キー部 404 が省略されておりバリュ部 405 のみの形式であってもよい。ここでは、便宜上、表の形で表現しているが、CSV (Comma Separated Value ; カンマ区切りデータ) でも、スペース区切りデータでも、タブ区切りデータでも本質的には同じである。データ受付部 1904 は、受け付けたデータをデータ型判定部 1905 に送信する。
- [0021] データ型判定部 1905 は、受付部 1904 から受信したデータについて各カラムに格納されたデータの型が、浮動小数点型、整数型、文字列型のいずれであるかを判定する。判定方法としては、例えば、代表的なデータベース言語であるSQLにて判定された結果を用いて smallint、integer、bigint 等ならば整数型、decimal、numeric、real 等ならば浮動小数点型、それ以外ならば文字列型とする方法がある。
- [0022] データ型判定部 1905 は、データ自動加工システム 1901 に入力されたデータ及びデータの各カラムについて判定したデータの型についての情報を尺度水準判定部 1906 に送信する。
- [0023] 図 4 は、入力データ 1902 を受け付けて尺度水準データベース 1907 に各カラムの尺度水準を格納する処理の一例を示した図である。
- [0024] ステップ 501 にて、データ受付部 1904 により入力データ 1902 を受け付ける。次に、ステップ 503、504、505、及び 506 を入力データ 1902 のカラムの数だけ繰り返す(ステップ 502 および 507)。

- [0025] ステップ503では、データ型判定部1905により、各カラム内のデータの型を判定する。例えば、上述した代表的なデータベース言語であるSQLにて判定された結果を用いて各カラム内のデータの型を判定する。ステップ503の判定結果において、当該カラムのデータが浮動小数点型もしくは整数型(これらを以下では数字型とする)ならばステップ505へ遷移し、文字列型ならばステップ504へ遷移する。
- [0026] ステップ504では、所定の正規表現との合致有無の判定を行う。所定の正規表現とは、例えば、日付表現、時刻表現、時間表現、またはリスト表現などが挙げられる。
- [0027] ステップ505では、カラム内のデータの分布の判定を行う。データの分布とは、データの統計値を基に計算されるデータの統計的な性質である。例えば、連續性、中心性、単調減少性、平滑性、または等分散性等が挙げられる。
- [0028] ステップ506にて、ステップ504により判定された所定の正規表現との合致有無またはステップ505により判定されたデータの分布を基に各カラム内の尺度水準を判定する。
- [0029] ステップ504～506は、尺度水準判定部1906により処理が行われる。これらの処理により、各カラムについて名義尺度、順序尺度、間隔尺度、比例尺度のうち、どれにあてはまるかを判定する。
- [0030] ステップ507にて、尺度水準判定部1906により判定した尺度水準を各カラムと紐づけて尺度水準データベース1907に格納する。

<尺度水準の説明>

次に、尺度水準の例を、図2を用いて説明する

尺度水準とは、カラムに保存されているデータを、それらが表現する情報の性質に基づき数学・統計学的に分類する基準である。Stanley Stevensが提案した分類（非特許文献1）がよく用いられている。尺度には低い方から順に、図2に示す4つの水準があり、高い水準はより低い水準の性質を含む形になっている。

[0031] 名義尺度 (Nominal scale)

数字・文字を単なる名前として個々のデータに割り振る。2つのデータに同じ名前がついていればそれらは同じカテゴリに属する。データ間の比較は等しいか異なるかでのみ可能である。順序はなく、加減などの算術演算もできない。代表値は最頻値で表される。データの例としては、ID、氏名、フラグなどがある。例えば作業ID= (00001, 00002, 00004, 00007, ...) は、作業ID=0001と作業ID=00002のデータは作業が違うことのみを表し、どちらが大きいかといった比較はできない。

[0032] 順序尺度 (Ordinal scale)

データに割り振られた数字・文字は順序を表す。データ間の比較は等しいか異なるかに加え、その前後・大小関係にも意味がある。一方、順序の間隔は等しくないため、加減などの算術演算には意味がない。データの例としては、作業効率Gr. やオーダー順などがある。例えば、作業効率Gr. = (5, 4, 3, ...) に対して、5よりも4の方が良いといった比較はできる。一方、5→4の間隔と、4→3の間隔は均一ではなく、単純に差をとった1という値は意味を成さない。

[0033] 間隔尺度 (Interval scale)

データに割り振られた数字は順序尺度の性質を全て満たし、さらに差が等しいということは間隔が等しいということを意味する。2つデータ間の差を比較しても意味がある。加減算にも意味があるが、尺度上のゼロ点は任意で負の値も使える。代表値は最頻値、中央値、算術平均などで表される。データの例としては、時刻や日付などがある。例えば、日付 =(11/4, 11/6, 11/8...) に対して、11/4→11/6の差をとった2[日間]には定量的な意味があり、同様に11/6→11/8の2[日間]との大小の比較が可能である。

[0034] 比例尺度 (Ratio scale)

データに割り振られた数字は間隔尺度の性質を全て満たし、さらに2つのデータの比にも、乗除算にも意味がある。尺度上のゼロ点は絶対的である。代表値は最頻値、中央値、算術平均、幾何平均などで表される。データの例と

しては、時間や数量などがある。例えば、作業数量 = (2, 5, 10, ...)に対して、2[個]と5[個]の比をとって、2.5倍多いといった意味づけが可能である。

- [0035] 尺度水準判定部1906は、データが格納されている各カラムが上記4つの尺度水準のどれにあてはまるかを判定する。尺度水準判定部1906は、データ型判定部1905が、当該カラム内のデータを数字型と判定した場合にはデータ分布の判定を行い、文字列型ならば正規表現合致有無の判定を行う。
- [0036] データ分布の判定では、尺度水準判定部1906は各カラムに格納されているデータの分布の判定を行い、そのデータの分布に基づいてカラムの尺度水準を判定する。データの分布は、データの値と当該データの値の出現頻度から計算してもよい。さらに、横軸にデータの値を、縦軸にデータの値の出現頻度を設定することでヒストグラムを作成し、その形状からデータの分布を求めてよい。データの値とデータの値の出現頻度の組合せ以外にもデータの分布を判断できるものであれば組合せの種類は問わない。
- [0037] 図5は、数字型のデータについて、図4のデータ分布判定505および尺度水準判定506の処理フローの一例を示した図である。

- [0038] ステップ601では、カラム内のデータが十分に連続性を持つか判定する。連続性とは、カラム内のデータが飛び飛びになっておらず十分に密になっているかを表す指標である。カラム内のデータの数字が等間隔で、数量的な意味があれば、すなわち、間隔尺度や比例尺度のデータであれば、データが不規則に飛び飛びにはなりにくいといった特性を判断するための指標である。図12は、様々なデータの分布を示す図であり、横軸がデータの値、縦軸がそのデータの出現頻度である。図12の例の場合、ヒストグラム1301、1302が連続性を持たない例、それ以外が連続性を持つ例である。連続性を持つかどうかの判定方法の例として、例えば、以下のような方法がある。

(1) カラム内のデータを昇順もしくは降順にソートし、データの値が重複するものを排除し、1つにする。

(2) (1) のデータ列の全ての値に対し、隣り合う 2 つの値の差分値を求める。

(3) 求めた全ての差分値の標準偏差を求める。

(4) 求めた標準偏差がある閾値以下になれば、連続性を持つと判定する。より好ましくは、(2) にて差分値を求めた後に、最小の差分値で割ることで正規化することが望ましい。別の例として、データの標準偏差とレンジ（最大値－最小値）の比率がある閾値以下になるかどうかを判定する方法が考えられる。レンジに代わって、75%点－25%点や90%点－10%点を用いることもできる。このほか、データの値が連続的であるかどうかを計算する方法であれば、これらには依らない。ステップ 601 にて連続性を持つと判定された場合、ステップ 602 に遷移し、連続性を持つと判定されなかった場合、名義尺度であると判定される(ステップ 605)。

[0039] このステップ 601 によって、データの値の間にギャップが存在するカラムを判定することができ、その結果、当該カラムが名義尺度であると判定することができる。これにより、数字型のデータが名義尺度であるかその他の尺度水準であるかを判定することができる。

[0040] ステップ 602 では、カラム内のデータが中心性もしくは単調減少性を持つか判定する。中心性とは、データの中央や平均付近のデータが多く存在し、ヒストグラムが山なりに分布するかを表す指標である。図 12 の例の場合、ヒストグラム 1301、1304 が中心性を持つ例、それ以外が中心性を持たない例である。単調減少性とは、ヒストグラムを描いた際に、横軸の値の増加に対し、縦軸の値が徐々に減少していくかを表す指標である。これらの指標は、数量データ、特に比例尺度のデータのヒストグラムによく見られる、正規分布形状、対数正規分布形状、及び指数分布形状を判断するためのものである。図 12 の例の場合、ヒストグラム 1305、1306 が単調減少性を持つ例、それ以外が単調減少性を持たない例である。中心性および単調減少性を持つかどうかの判定方法の例として、尖度および歪度がある閾値以上になるかどうかを判定する方法がある。尖度は式(1) で計算される値

であり、歪度は式（2）で計算される値である。

[0041] [数1]

【数1】

$$\sum_{i=1}^N (x_i - \mu)^4 / N\sigma^4 \quad \cdots \text{式(1)}$$

[0042] [数2]

【数2】

$$\sum_{i=1}^N (x_i - \mu)^3 / N\sigma^3 \quad \cdots \text{式(2)}$$

[0043] 式（1）（2）において、 x_i ($i=1$ to N) は各データの値、 μ は平均、 σ は標準偏差を示す。ここで、尖度とはデータの中心性を示すものであり、上記式（1）の値が大きいときに尖度が大きく、すなわち中心性があることを意味する。例えば、式（1）の値が3以上であるときに中心性を持つデータであると判断してもよい。また、歪度とはデータの単調減少性を示すものであり、上記式（2）の値が大きいときに歪度が大きく、すなわち、単調減少性があることを意味する。例えば、式（2）の値が0.5以上であるときに歪度を持つデータであると判断してもよい。このほか、ヒストグラムが大局的な山状もしくは単調減少するかを判定する方法であれば、これには依らない。ステップ602で中心性もしくは単調減少性を持つと判定された場合、ステップ604に遷移し、中心性および単調減少性を持たないと判定された場合、ス

ステップ603に遷移する。

[0044] このステップ602により、カラム内のデータが不規則に存在しているかどうか判定することができる。

[0045] ステップ603では、カラム内のデータが平滑性を持つかどうか判定する。平滑性とは、ヒストグラムを描いた際に、横軸の値の増加に対し、縦軸の値の変化が緩やかであるかどうかを表す値である。カラム内のデータの数字に数量的な意味があれば、すなわち名義尺度でなければ、数字が隣り合うデータの頻度が近くなりやすいといった特性を判断するための指標である。図12の例の場合、ヒストグラム1304、1307、1308が平滑性を持つ例、それ以外が平滑性を持たない例である。平滑性を持つかどうかの判定方法の例として、例えば以下のような方法がある。

(1) カラム内のデータの最大値から最小値までを、いくつかの均等幅の区間に分ける。

(2) 分けた区間ごとに、当該区間に属するデータ数を計算する。

(3) 当該区間に属するデータ数と、隣り合う区間に属するデータ数の差分を、全ての区間にに対して計算する。

(4) 計算した全ての区間の差分値の平均を計算する。

(5) 計算した平均がある閾値以下になれば、平滑性を持つと判定する。

[0046] このほか、ヒストグラムの形状が平滑的になるかどうかを判定する方法であれば、これには依らない。ステップ603にて平滑性を持つと判定された場合、間隔尺度と判定され、平滑性を持たないと判定された場合、名義尺度と判定される(ステップ605及び606)。

[0047] ステップ602および603により、カラム内のデータの値の間にギャップは存在しないが、不規則にデータが存在していて、値の隣り合うデータ同士に頻度の差が大きく表れるようなカラムを判定することができ、その結果、カラムが名義尺度であると判定することができる。さらに、カラム内のデータの値の間にギャップは存在しないが、不規則にデータが存在していて、値の隣り合うデータ同士に似たような頻度をもつ傾向があるカラムを判定す

ることができ、その結果、カラムが間隔尺度であると判定することができる。これにより、連続性があり、かつ、中心性がないもしくは単調減少性がない数字型のデータについて、名義尺度か間隔尺度か判定をすることが出来る。

[0048] ステップ604では、カラム内のデータが等分散性を持つかどうか判定する。等分散性とは、データの平均値の変化に対して、分散値が変化しないかどうかを表す指標である。図13は、等分散性を持つデータ分布の例と等分散性を持たないデータ分布の例を示した図である。図13の例の場合、上段のヒストグラム1410が等分散性を持つ例、下段のヒストグラム1420が等分散性を持たない例である。ヒストグラム1410では、分布1411、1412、1413、1414と分布の平均値が大きくなても、分布の分散が不变である。一方、ヒストグラム1420では、分布1421、1422、1423、1424と分布の平均値が大きくなるにつれて、分布の分散が大きくなる。

[0049] 等分散性を持つかどうかの判定方法の例を、図15を用いて説明する。

(1) 入力テーブル(1610)の着目しているカラム(例、”処理数”と”開始時刻[s]”)の値に対し、加工キー(例、”作業者ID”)が同じ行(点線内)ごとに平均と分散を求める。この加工キーは、ユーザが入力してもよいし、データ自動加工システムがランダムに選択してもよい。

(2) 求めた平均と分散に着目し、平均が増加しても分散が大きく変化しないかどうかを判定する。図15の場合、”処理数”は平均が増加すると分散が増加しており、”開始時刻[s]”は平均が増加しても分散が大きく変化していない。例えば、各加工キーの分散／平均を計算して、その差を閾値と比較して上記判断を行ってもよい。等分散性を持つデータの場合、分散／平均の値は、各加工キー間で変動する。

(3) 分散が大きく変化しないと判定されれば、等分散性を持つ、それ以外ならば、等分散性を持たないと判定する。

[0050] ステップ604にて、等分散性を持つと判定された場合、間隔尺度と判定

され、等分散性を持たないと判定された場合、比例尺度と判定される(ステップ606および607)。このように比例尺度と間隔尺度の判定をすることが出来ることを、発明者は新たに発見した。ステップ604によって、連続性があり、かつ、中心性を持つもしくは単調減少性を持つ数字型のデータについて、間隔尺度か比例尺度かを判定することが出来る。

- [0051] 尺度水準判定部1906は、上述のように各カラムの尺度水準を判定した後、カラムに格納されているデータと尺度水準とを紐づけた情報を尺度水準データベース1907に格納する。例えば、図3の入力テーブル400が入力データ1902であるとすると、尺度水準データベース内の尺度水準テーブル410のバリューポート415に各カラムの尺度水準を格納する。また、尺度水準判定部1906は、データ加工部1908にデータの加工を行うトリガを送信する。
- [0052] データ加工部1908は、尺度水準判定部1906からトリガを受け付けた後に、各カラムの尺度水準を基にデータに適用可能な演算処理を施して各カラム内のデータを加工する。図8は、データ加工部1908が各データの加工をする際に用いる、尺度水準902及び演算タイプ903毎に適用可能加工演算904を格納したテーブル901の図である。データ加工部1908内にテーブル901が構築されていてもよいし、データ加工部1908の外からデータ加工の際に適用可能演算904を読みだしても構わない。データ加工部1908は、尺度水準データベース1907の尺度水準を読みだして、それぞれの尺度水準に適用可能演算904の処理を各カラムに行い、データを加工した結果を出力データベース1903に格納する。例えば、図3の加工データテーブル430のバリューポート435に演算を施したデータをカラムごとに格納する。加工データテーブル430は、出力データベース1903内に構築されている。
- [0053] ここまで、各カラムについてそれぞれ処理を行い、出力もテーブルにすると記述したが、必ずしもカラム形式やテーブル形式である必要はなく、一定のデータの集合を定義できるものであれば形式は問わない。例えば、カラム

形式ではなく、リスト形式のデータ、またはデータの配列に対して処理を行っても構わない。

- [0054] 図11は、実施例1におけるデータ自動加工システムを実現するハードウェア構成の一例を示す図である。
- [0055] 実施例1におけるハードウェア構成は、コンピュータシステム(計算機)を用いて実現され、少なくとも1組の、CPU1201、ROM1202、RAM1203、キーボード1204、表示装置1205、HDD1206、プリンタ1207、マウス1208、バス1209、DB1210、およびネットワーク1211から構成される。
- [0056] ROM1202は、データ自動加工システムのOS(オペレーティングシステム)などを記憶する。RAM1203は、データ自動加工に関するコンピュータソフトウェアを格納する。キーボード1204は、CPU1201を操作する。HDD1206は、入力データや加工データを格納する。表示装置1205は、入力データ、加工データ、またはデータ加工の過程などをユーザに示す。マウス1208は、CPU1201を操作する。バス1209は、各々のデータを通信するためのものである。DB1210は、各データを格納しておく。ネットワーク1211は、バス1209とDB1210を繋ぐ。
- [0057] データ自動加工システム1901において、CPU1201で、RAMに格納されたデータ自動加工に関するコンピュータソフトウェアを実行することで、図18に示した各機能を実現することができる。
- [0058] このように、実施例1に表すデータ自動加工システム1901は、数字、文字、および符号に関するデータを受け付ける受付部1904と、データについて、データの型を判定するデータ型判定部1905と、データが数字型である場合に、データの分布に基づいてデータの尺度水準を判定する尺度水準判定部1906と、尺度水準に基づいてデータを加工するデータ加工部1908と、を備えている。
- [0059] 係る構成により、本実施例に係るデータ自動加工システム1901は、デ

ータの性質を定める指標である尺度水準を自動で判定し、各データに適した方法によりデータ加工を行うことが可能となる。

[0060] <データが文字列型の場合の例>

尺度水準判定部1906は、データ型判定部1905が、当該カラムのデータを文字列型と判定した場合、正規表現合致有無の判定を行う。

[0061] 正規表現合致有無の判定では、尺度水準判定部1906は各カラムに格納されているデータと予め設定されている正規表現との合致の判定を行い、その合致の有無に基づいて尺度水準を判定する。

[0062] 図6は、図4の正規表現合致判定504および尺度水準判定506の処理のフローの一例を示した図である。

[0063] ステップ701では、カラム内のデータが日付表現もしくは時刻表現であるかどうかを判定する。日付表現の例として、「2014/12/20」「2014-12-20」「14/12/20」「14-12-12」「Dec. 20 2014」(2014年12月20日)などが挙げられる。時刻表現の例として、「15:47」「03:47 AM」(15時47分)、「16:01:42」「04:01:42」(16時01分42秒)などが挙げられる。日付表現もしくは時刻表現を持つかどうかの判定方法として、前述の表現例を正規表現で記述し、カラムに格納されているデータ内のすべての文字列が当該正規表現に合致するかを判定する方法がある。なお、時刻表現に関しては、後述の時間表現との差異を明確にするため、取りうる時刻の範囲に注意して、正規表現を記述する必要がある。また、時刻表現および時間表現のどちらにも該当するデータの場合、前述の等分散性の判定を用いて、等分散性を持つ場合に時刻表現であると判定し、等分散性を持たない場合に時間表現であると判定する方法もある。文字列型のデータの場合には、時刻表現もしくは時間表現のデータを数字型のデータに変換して等分散性の判定を行う。例えば、「12:30:00」の場合には「750」分のように変換する。ここでは、分単位の変換としているが、秒単位でも時間単位でも構わない。その後、そのデータの値と、その出現頻度から前述のデータの等分散性に関する分布を計算することにより、時刻表現と時間表現の判定を行う。ステップ701にて、日付表現もしく

は時刻表現と判定された場合には、当該カラムは間隔尺度であると判定され(ステップ707)、日付表現および時刻表現と判定されなかった場合には、ステップ702に遷移する。ステップ701によって、文字列型のデータを格納するカラムが間隔尺度であるかその他の尺度水準であるかを判定することが出来る。

[0064] ステップ702では、カラム内のデータが時間表現であるかどうかを判定する。時間表現を持つ文字列の例として、「9' ' 58」(9秒58)、「3' 26' ' 00」「03:26」(3分26秒00)、「2:02' 57」「02:02:57」(2時間02分57秒)などが挙げられる。時間表現であるかどうかの判定方法の例として、前述の表現例を正規表現で記述し、カラムに格納されているデータ内のすべての文字列が当該正規表現に合致するかを判定する方法がある。ステップ702にて、時間表現と判定された場合には、当該カラムは比例尺度であると判定され(ステップ706)、時間表現と判定されなかった場合には、ステップ703に遷移する。ステップ702によって、文字列型のデータを格納するカラムが比例尺度であるかその他の尺度水準を持つかの判定をすることができる。

[0065] ステップ703では、カラム内のデータがリスト表現であり、かつ単調変化するかを判定する。リスト表現を持つ文字列の例として、「1.***, 2.***, ...」「1:***, 2:***, ...」「A.***, B.***, ...」「I.***, II.***, ...」などが挙げられる。リスト表現であるかどうかの判定方法の例として、前述の表現例を正規表現で記述し、カラムに格納されているデータ内のすべての文字列が当該正規表現に合致するかを判定する方法がある。

[0066] 図14は、単調変化をしているデータの分布を示す図である。

[0067] ここでは、横軸を各リストの数値(文字の場合は数値に変換)、縦軸をその値の出現頻度としてヒストグラムを作成している。

[0068] 単調変化であるとは、ヒストグラム1510のように横軸の値の増加に対して、縦軸の値が規則的に徐々に減少する単調減少であるか、もしくはヒストグラム1520のように横軸の値の増加に対して、縦軸の値が規則的に徐

々に増加する単調増加であるか、もしくはヒストグラム 1530 のように横軸の値の増加に対して、ただ一つのピークを持ち、ピークの前では単調増加、ピークの後では単調減少するか、の 3 つのいずれかに該当するかを言う。ステップ 703 にて、データがリスト表現を持ち、かつ単調変化であると判定された場合には、当該カラムは順序尺度であると判定され、判定されなかった場合には、当該カラムは名義尺度であると判定される(ステップ 704 及び 705)。ステップ 703 によって、文字列型のデータが順序尺度であるか名義尺度であるかの判定を行うことができる。

[0069] 上記では、ステップ 701 ~ 703 を順番に適用して尺度水準を判定したが、このステップの順番は変わってもよい。またその際は、ステップ 701 ~ 703 すべてで当てはまらないと判定されたカラムが名義尺度であると判定する。

[0070] このように、データ自動加工システム 1901 は、データが文字列型である場合に、データの所定の正規表現との合致有無に基づいてデータの尺度水準を判定する尺度水準判定部を備えている。係る構成により、データが文字列型の場合にもデータの性質を定める指標である尺度水準を自動で判定し、各データに適した方法によりデータ加工を行うことが可能となる。

[0071] <加工演算の提示に関する変形例>

ここでは、判定された尺度水準に合わせたデータの加工演算の提示に関する内容を説明する。基本的なシステム構成は図 18 と同じであるが、以下の点が相違する。

[0072] 図 19 は、加工演算の提示を行うデータ自動加工システムを表した図である。

[0073] データ自動加工システム 1901 は、入力データ 1902 を受け付け、データの尺度水準及びデータに適用可能な加工演算を判定し、表示装置 1205 に適用可能な加工演算を表示し、加工したデータを出力データベース 1903 に出力する。また、加工したデータを表示装置に表示してもよい。

[0074] データ自動加工システム 1901 は、図 18 の構成に加えて、加工演算判

定部 2001、加工演算データベース 2002、及び表示部 2003 を備えている。

[0075] 尺度水準判定部 1906 は、各カラムの尺度水準を判定して尺度水準データベースに格納した後に、加工演算判定部 2001 に加工演算を行うトリガを送信する。

[0076] 加工演算判定部 2001 は、尺度水準判定部 1906 からトリガを受け付けた後に尺度水準データベース 1907 から各カラムの尺度水準、および、加工演算データベース 2002 からそれぞれの尺度水準に適用可能な演算を受け付け、各カラムの尺度水準から該カラム内のデータに適用可能な加工演算を選択し、表示部 2003 に送信する。また、各カラムに適用可能な加工演算をデータ加工部 1908 に送信する。

[0077] 図 7 は、加工演算判定部 2001 による処理のフローを示した図である。

[0078] 尺度水準受付ステップ 801 にて、尺度水準データベース 1907 から各カラムに入力されたデータとカラムに紐づけられた尺度水準を受け付ける。受付の形式は、例えば、図 3 の尺度水準テーブルのようにバリューパート 415 に各カラムの尺度水準が格納されている情報を受け付ける。

[0079] 次の加工演算抽出ステップ 803 は、ステップ 801 にて受け付けたテーブルのカラムの数だけ繰り返し処理される(ステップ 802 及びステップ 804)。加工演算抽出ステップ 803 では、演算タイプ指定ステップ 810 にてユーザが指定した演算タイプと、尺度水準受付ステップ 801 にて受け付けた尺度水準を基に、加工演算データベース 2002 から適用可能な演算を抽出する。

[0080] 演算タイプ指定ステップ 810 では、ユーザが任意の加工演算のタイプを指定する。指定は、キーボード 1204 やマウス 1208 から行うことが出来る。指定された加工演算のタイプはデータ自動加工システム 1901 内のタイプ受付部が受け付ける(図示せず)。加工演算のタイプは、例えば、正規化、量子化、代表値、または散布度などが挙げられる。図 16 の演算タイプ(選択) 1702 の表示がタイプの指定の際のユーザインターフェースの例

である。

- [0081] 加工演算データベース 2002 は、尺度水準と演算タイプごとにカラムに適用可能な加工演算が格納されている。図8は、各尺度水準と演算タイプについて、尺度水準 902 及び演算タイプ 903 毎に適用可能加工演算 904 を格納したテーブル 901 の図である。加工演算データベース 2002 は例えば、図8のようなテーブル 901 を有してもよい。
- [0082] ステップ 803 は、ステップ 801 で受け付けた各カラムに入力されているデータ並びに各カラムの尺度水準、ステップ 810 にて指定された演算タイプ、および加工演算データベース 2002 に格納されている適用可能加工演算を基に、各カラムのデータに適用可能な加工演算を抽出する。例えば、カラムの尺度水準が名義尺度であり、ユーザが指定した演算タイプが代表値であった場合には、最頻値の加工演算を抽出する。
- [0083] 加工演算データベース 2002 に格納されている演算タイプ、適用可能加工演算は、図8に示したものに依らず、適宜、演算タイプおよび適用可能加工演算を追加・削除してもよい。また、尺度水準と各演算タイプに適用可能な加工演算が紐づけられていれば、901のようなテーブル形式に限らない。
- [0084] 加工演算送信ステップ 805 では、加工演算判定部 2001 が抽出した適用可能な演算を表示部 2003 及びデータ加工部 1908 に送信する。送信の形式として、例えば図3の適用可能加工演算テーブル 420 が挙げられる。
- [0085] 表示部 2003 は、加工演算判定部 2001 から受信した各カラムに適用可能な加工演算を表示装置 1205 に送信する。表示装置 1205 は、表示部 2003 から受信した適用可能な加工演算をユーザに表示する。例えば、図16の適用可能加工演算 1708 のように表示する。このように各カラムに適用が可能な加工演算をバリューパーク 1709 に表示する。
- [0086] データ加工部 1908 は、加工演算判定部 2001 から各カラムに適用可能な加工演算を受け付けて、各カラムに適用可能な加工演算を適用する。そ

の際、ユーザが指定した演算タイプに該当する適用可能加工演算 904 を適用してもよい。また、データ加工部 1908 が、表示装置 1205 に加工演算適用後のデータを送信し、表示装置 1205 がそのデータをユーザに表示してもよい。その際の表示例として、図 16 のデータ加工結果 1710 が挙げられる。

[0087] このように、データ自動加工システム 1901 は、数字、文字、及び符号に関する各データに対して、各データの尺度水準と紐づけて各データに適用可能な加工演算を判定する加工演算判定部 2001 と、適用可能な加工演算を画面に表示する表示部 2003 とを備えている。

[0088] 係る構成により、データを機械学習や統計分析可能な形式へ適切に変換することができる加工演算を提示することができる。これにより、データマイニングや統計学の知識のない非専門家でもデータの加工演算を行うことができ、また、専門家の場合でも、入力データテーブルのカラム数が数百～となる場合には、1つ1つのカラムに対し適用可能な演算を考慮し、手動で設定するのは大きなコストとなっていたが、このコストを削減することが可能となる。さらに、意味のないデータ加工による分析の無駄、および分析結果の誤解を無くすことが可能となる。

[0089] <最適な加工演算の選択に関する変形例>

あるカラム内のデータに対してあるデータ加工演算が適用できる場合でも、そのデータ加工演算の結果が不安定な場合があり、加工後の値が適切なものであるかどうかを分析者が手作業と直感により毎回判断する必要があった。

[0090] ここでは、適用可能な加工演算の中からの最適な加工演算の選択に関する内容を説明する。基本的なシステム構成は図 19 と同様であるが、以下の点が相違する。

[0091] 図 20 は、最適な加工演算を選択するデータ自動加工システム 1901 を表した図である。

[0092] データ自動加工システム 1901 は、入力データ 1902 を受け付け、カラムの尺度水準を判定し、各カラムに最適な加工演算を選択し、最適な加工

演算により加工したデータを出力データベース1903に出力する。

- [0093] データ自動加工システム1901は、図19の構成に加えて加工演算選択部2101を備えている。
- [0094] 加工演算選択部2101は、加工演算判定部2001が抽出した適用可能な加工演算の中から、各カラムに最も適用するのが適している加工演算を選択し、選択した加工演算をデータ加工部1908に送信する。
- [0095] 図9は、加工演算選択部2101の処理のフローを示した図である。
- [0096] 加工演算受付ステップ1001にて、加工演算選択部2101は、加工演算判定部2001から適用可能加工演算テーブル420を受け付ける。
- [0097] 次の演算口バスト性判定ステップ1003と最適加工演算選択ステップ1004は、適用可能加工演算テーブル420のカラムの数だけ繰り返し処理される(ステップ1002及び1005)。
- [0098] 演算口バスト性判定ステップ1003は、適用可能加工演算テーブル420のバリューパート425に格納された適用可能加工演算について、演算の口バスト性を判定する。
- [0099] 最適加工演算選択ステップ1004は、演算口バスト性判定ステップ1003にて判定された口バスト性に関する値を基に各カラムに最適な加工演算を選択する。
- [0100] 最後に、最適加工演算送信ステップ1006は、加工演算選択部2101により最適加工演算選択ステップ1004が選択した各カラムに最適な加工演算をデータ加工部1908に送信する。
- [0101] データ加工部1908は、受信した各カラムに最適な加工演算をカラム内の各データに施してデータを加工する。
- [0102] 次に、図10を用いて、演算口バスト性判定ステップ1003および最適加工演算選択ステップ1004の処理のフローを説明する。
- [0103] N分割ステップ1102、演算適用ステップ1104、及び分散計算ステップ1106は、は適用可能加工演算テーブルの各バリューパートに格納された適用可能加工演算の数だけ繰り返し処理される。

- [0104] まず、N分割ステップ1102にてデータをランダムにN個の集合に分割する。Nは、ユーザが指定してもよいし、任意の数でもよい。例えば、5～10個に分割することが考えられる。
- [0105] 次の演算適用ステップ1104は、データの分割数Nだけ繰り返し処理される。
- [0106] 演算適用ステップ1104は、分割後のデータに対して加工演算受付ステップ1001で受け付けた適用可能な加工演算を施し、加工後のデータの値を計算する。
- [0107] 分散計算ステップ1106では、N個の加工後のデータの値について分散を計算する。分散の計算方法は、既存の方法で構わない。
- [0108] 最後に、分割値最小演算選択ステップ1108にて、分散計算ステップ1106で計算した分散値が最小となる加工演算を、最もロバスト性の高い演算と判定し、最適な加工演算として選択する。ここで、演算ロバスト性とは、演算適用後の各データの値のばらつきの小ささを示す性質のことという。
- [0109] 上記では、分散を基に演算ロバスト性の判定に利用しているが、これは標準偏差でも同様に判定をすることが出来る。
- [0110] ここまで、各カラムについてそれぞれ処理を行い、出力もテーブルにすると記述したが、必ずしもカラム形式やテーブル形式である必要はなく、一定のデータの集合を定義できるものであれば形式は問わない。例えば、カラム形式ではなく、リスト形式のデータ、またはデータの配列に対して処理を行っても構わない。
- [0111] このように、データ自動加工システム1901は、数字、文字、及び符号に関する各データに対して、各データの尺度水準と紐づけて各データに適用可能な加工演算を判定する加工演算判定部2001と、適用可能な加工演算のうち、演算適用後の各データの値のばらつきが最も小さい加工演算を選択する加工演算選択部2101と、各データの値のばらつきが最も小さい加工演算を適用することによりデータを加工するデータ加工部1908とを備えている。

[0112] 係る構成により、適用可能なデータ加工演算が複数ある場合に、最も演算適用後の値が安定している演算によりデータの加工をすることができる。これにより、データ分析の精度を高めることができる。さらに、データ加工の試行錯誤を行うことなく、精度の高いデータ分析を行うことができる。

実施例 2

[0113] 本発明のデータ自動加工システムの別の例を示す。

[0114] 実施例2は、データ自動加工システムについてのG U I (グラフィカルユーザインタフェース)に関する内容である。基本的な構成は図19及び図20と同様である。

[0115] 図16に示すように、表示装置1204上に、データ加工操作をユーザが行うためのG U Iを表示し、ユーザからの入力を元に、ユーザからの入力があるごとに、データ加工結果を変えて表示装置1204に表示する。ユーザからの入力は、図11のキーボード1203やマウス1206を介して行われる。

[0116] まず、ユーザが図3の入力テーブル400をデータ自動加工システムに入力すると、入力テーブル表示部1701に表示される。

[0117] 演算タイプ選択部1702では、図8の適用可能加工演算格納テーブル901に事前定義された演算タイプのうち、いずれか1つをユーザが選択することができる。ユーザが選択した演算タイプは図7の演算タイプ指定ステップ810に入力される。

[0118] 尺度水準判定部1906が、入力テーブル400の各カラムの尺度水準を判定すると、図3の尺度水準テーブル410を、尺度水準判定結果表示部1706に表示する。尺度水準選択部1707では、尺度水準判定部1906により自動判定された尺度水準が初期状態として設定されるが、ユーザが必要に応じて書き換えて尺度水準を再設定することもできる。

[0119] 演算タイプ選択部1702と、尺度水準選択部1707により、演算タイプと尺度水準が選択されると、加工演算判定部2001により、図3の適用可能加工演算テーブル420が作成され、適用可能演算表示部1708に表

示される。各カラムの適用可能演算は、加工演算選択部 2101 にて、選択されたロバスト性の最も高い加工演算のみを表示しても良いし、ロバスト性の高い順に加工演算を表示してもよい。

[0120] 適用演算選択部 1709 では、適用可能な演算が複数ある場合に、いずれか 1 つの演算をユーザが選択することができる。

[0121] 適用演算選択部 1709 にて、演算が選択されると、データ加工結果表示部 1710 に、図 3 の加工テーブル 430 が表示される。

[0122] 係る構成により、各カラムの尺度水準を自動判定し、各カラムの尺度水準と、適用可能な演算をユーザに提示しながら、データ加工を進めることが可能となる。これにより、データ分析の知識のない非専門家でも、データの性質を把握しながら、容易にデータ分析を行うことができる。

実施例 3

[0123] 本発明のデータ自動加工システムを利用したデータ自動解析システムの例について説明する。

[0124] 図 17 は、本実施例のデータ自動解析システムの構成図を表した図である。データ自動解析システム 1801 は、センサなどで取得したビックデータである入力データ 1802 を受け付け、データについて解析を行い、出力データ 1803 を出力する。データ自動解析システム 1801 は、データ前処理部 1804、加工データベース 1805、およびデータ解析部 1806 を備えている。

[0125] データ前処理部 1804 は、入力データ 1802 を受け付け、データ解析に適したデータに加工し、加工データベース 1805 に格納する。データ前処理部 1804 は、実施例 1 で説明したデータ自動加工システムを内部に有しており、入力データのカラムごとに尺度水準を判定し、適用可能演算を各カラムに施してデータを加工する。

[0126] データ解析部 1806 は、加工データベース 1805 に格納されているデータを基に、相関分析、回帰分析、またはクラスタリングなど既知の機械学習や統計分析の処理を行い、データを解析する。そして解析して得た結果を

出力データ 1803 として出力部(図示せず)により出力する。

[0127] データ自動解析システム 1801 を実現するハードウェア構成については、実施例 1 と同様に、図 11 で示したものである。

[0128] このように、実施例 3 に表すデータ自動解析システム 1801 は、数字、文字、および符号に関するデータを受け付ける受付部 1904 と、データについて、データの型を判定するデータ型判定部 1905 と、データが数字型である場合に、前データの分布に基づいてデータの尺度水準を判定する尺度水準判定部 1906 と、尺度水準に基づいてデータを加工するデータ加工部 1908 と、加工部によって加工されたデータを解析するデータ解析部 1806 と、解析部によって解析されたデータを出力する出力部と、を有するデータ自動解析システム。係る構成により、データの前処理に関するユーザの負担を軽減させることができ、データ自動解析システムの前処理を容易にすることができる。

符号の説明

[0129] 100 入力テーブル、101 作業者 ID、102 処理数、
103 商品 ID、104 作業 ID、111 作業者 ID
112 処理数、113 商品 ID、400 入力テーブル
401 処理数、402 商品 ID、403 優先度
404 キ一部、405 バリューパー、410 尺度水準テーブル
411 処理数、412 商品 ID、413 優先度
414 キ一部、415 バリューパー
420 適用可能加工演算テーブル、421 処理数
422 商品 ID、423 優先度、424 キ一部
425 バリューパー、430 加工データテーブル、431 処理数
432 商品 ID、433 優先度、434 キ一部
435 バリューパー、501 データ受付ステップ
502、507 カラム数繰り返し、503 データの型判定ステップ
504 正規表現合致判定ステップ、505 データ分布判定ステップ

506 尺度水準判定ステップ、 508 尺度水準格納ステップ
601 連續性判定ステップ
602 中心性及び単調減少性判定ステップ
603 平滑性判定ステップ、 604 等分散性判定ステップ
605 名義尺度判定、 606 間隔尺度判定
607 比例尺度判定、 701 日付表現及び時刻表現判定ステップ
702 時間表現判定ステップ
703 リスト表現及び単調変化判定ステップ、 704 名義尺度判定
705 順序尺度判定、 706 比例尺度判定
707 間隔尺度判定、 801 尺度水準受付ステップ
802、804 カラム数繰り返し、 803 加工演算抽出ステップ
805 加工演算送信ステップ、 810 演算タイプ指定ステップ
901 適用可能加工演算格納テーブル、 902 尺度水準
903 演算タイプ、 904 適用可能加工演算
1001 加工演算受付ステップ
1002、1005 カラム数繰り返し
1003 演算口バスト性判定ステップ
1004 最適加工演算選択ステップ
1006 最適加工演算送信ステップ
1101、1107 適用可能演算数繰り返し
1102 N分割ステップ、 1103、1105 分割データ数繰り返し
1104 演算適用ステップ、 1106 分散計算ステップ
1108 分散値最小演算選択ステップ、 1201 C P U
1202 R O M、 1203 R A M、 1204 キーボード
1205 表示装置、 1206 H D D、 1207 プリンタ
1208 マウス、 1209 バス、 1210 D B、
1211 ネットワーク
1301～1303 名義尺度を持つデータ分布のヒストグラム例図

- 1304～1306 比例尺度を持つデータ分布のヒストグラム例図
1307、1308 間隔尺度を持つデータ分布のヒストグラム例図
1410 等分散性を持つデータ分布のヒストグラム例図
1420 等分散性を持たないデータ分布のヒストグラム例図
1510、1520、1530 単調変化するデータ分布のヒストグラム
例図
1610 入力テーブル、1620 平均と分散を求めた後のテーブル
1701 入力テーブル表示部、1702 演算タイプ選択部
1706 尺度水準結果表示部、1707 尺度水準選択部
1708 適用可能演算表示部、1709 適用演算選択部
1710 データ加工結果表示部、1801 データ自動解析システム
1802 入力データ、1803 出力データ
1804 データ前処理部、1805 加工データ
1806 データ解析部、1901 データ自動加工システム
1902 入力データ、1903 出力データベース
1904 データ受付部、1905 データ型判定部
1906 尺度水準判定部、1907 尺度水準データベース
1908 データ加工部、2001 加工演算判定部
2002 加工演算データベース、2003 表示部
2101 加工演算選択部。

請求の範囲

- [請求項1] 数字、文字、および符号に関するデータを受け付ける受付部と、
前記データについて、前記データの型を判定するデータ型判定部と
、
前記データが数字型である場合に、前記データの分布に基づいて前
記データの尺度水準を判定する尺度水準判定部と、
前記尺度水準に基づいて前記データを加工するデータ加工部と、を
有するデータ自動加工システム。
- [請求項2] 請求項1に記載のデータ自動加工システムであって、
前記データの分布は、前記データの値と前記データの値の出現頻度
に基づいたデータの頻度分布であることを特徴とするデータ自動加工
システム。
- [請求項3] 請求項2に記載のデータ自動加工システムであって、
前記尺度水準判定部は、前記データの値と前記データの値の出現頻
度からなるヒストグラムの形状を基に前記データの尺度水準を判定す
ることを特徴とするデータ自動加工システム。
- [請求項4] 請求項2に記載のデータ自動加工システムであって、
前記尺度水準判定部は、前記データの頻度分布について連續性を有
しているか判定し、前記データの頻度分布が連續性を有していないと
判定した場合に前記データを名義尺度と判定することを特徴とするデ
ータ自動加工システム。
- [請求項5] 請求項2に記載のデータ自動加工システムであって、
前記尺度水準判定部は、前記データの頻度分布について連續性、中
心性、単調減少性、および等分散性を有しているか判定し、前記デ
ータの頻度分布が連續性を有しており、中心性を有する若しくは単調減
少性を有しており、かつ等分散性を有していない場合に前記データを
比例尺度と判定することを特徴とするデータ自動加工システム。
- [請求項6] 請求項1に記載のデータ自動加工システムであって、

前記尺度水準判定部は、前記データが文字列型である場合に、前記データと所定の正規表現との合致有無に基づいて前記データの尺度水準を判定することを特徴とするデータ自動加工システム。

[請求項7]

請求項6に記載のデータ自動加工システムであって、
前記尺度水準判定部は、前記データがリスト表現の正規表現と合致し、かつ、前記データの値と前記データの値の出現頻度に基づいたデータの頻度分布が単調変化を示している場合に前記データを順序尺度と判定することを特徴とするデータ自動加工システム。

[請求項8]

請求項6に記載のデータ自動加工システムであって、
前記尺度水準判定部は、前記データが時刻表現の正規表現および時間表現の正規表現と合致した場合に、前記データの値と前記データの値の出現頻度に基づいたデータの頻度分布について等分散性を有していると判定された場合に前記データが時刻表現であると判定し、前記データの値と前記データの値の出現頻度に基づいたデータの頻度分布について等分散性を有していないと判定された場合に前記データが時間表現であると判定し、前記データの尺度水準を判定することを特徴とするデータ自動加工システム。

[請求項9]

請求項1に記載のデータ自動加工システムであって、
数字、文字、及び符号に関する各データに対して、前記各データの尺度水準と紐づけて前記各データに適用可能な加工演算を判定する加工演算判定部と、

前記適用可能な加工演算を画面に表示する表示部と、を有することを特徴とするデータ自動加工システム。

[請求項10]

請求項1に記載のデータ自動加工システムであって、
数字、文字、及び符号に関する各データに対して、前記各データの尺度水準と紐づけて前記各データに適用可能な加工演算を判定する加工演算判定部と、

前記適用可能な加工演算のうち、演算適用後の前記各データの値の

ばらつきが最も小さい加工演算を選択する最適加工演算選択部を有し

、

前記データ加工部は、前記各データの値のばらつきが最も小さい加工演算を適用することにより前記データを加工することを特徴とするデータ自動加工システム。

[請求項11] 数字、文字、および符号に関するデータを入力とするデータ自動加工方法であって、

前記データを受け付ける受付ステップと、

前記データについて、前記データの型を判定するデータ型判定ステップと、

前記データが数字型である場合に、前記データの分布に基づいて前記データの尺度水準を判定する尺度水準判定ステップと、

前記尺度水準に基づいて前記データを加工するデータ加工ステップと、を有することを特徴とするデータ自動加工方法。

[請求項12] 請求項11に記載のデータ自動加工方法であって、

前記データの分布は、前記データの値と前記データの値の出現頻度に基づいたデータの頻度分布であることを特徴とするデータ自動加工方法。

[請求項13] 数字、文字、および符号に関するデータを受け付ける受付部と、

前記データについて、データの型を判定するデータ型判定部と、

前記データが数字型である場合に、前記データの分布に基づいて前記データの尺度水準を判定する尺度水準判定部と、

前記尺度水準に基づいて前記データを加工するデータ加工部と、

前記加工部によって加工されたデータを解析するデータ解析部と、

前記解析部によって解析されたデータを出力する出力部と、を有するデータ自動解析システム。

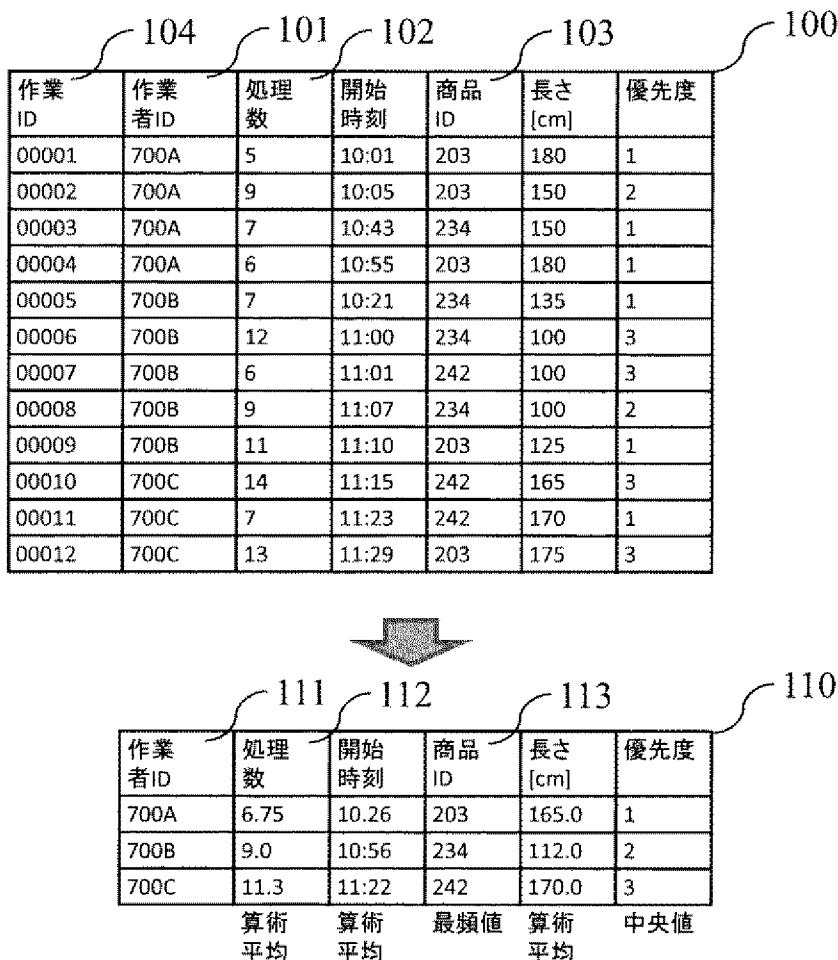
[請求項14] 請求項13に記載のデータ自動解析システムであって、

前記データの分布は、前記データの値と前記データの値の出現頻度

に基づいたデータの頻度分布であることを特徴とするデータ自動解析システム。

[図1]

図1



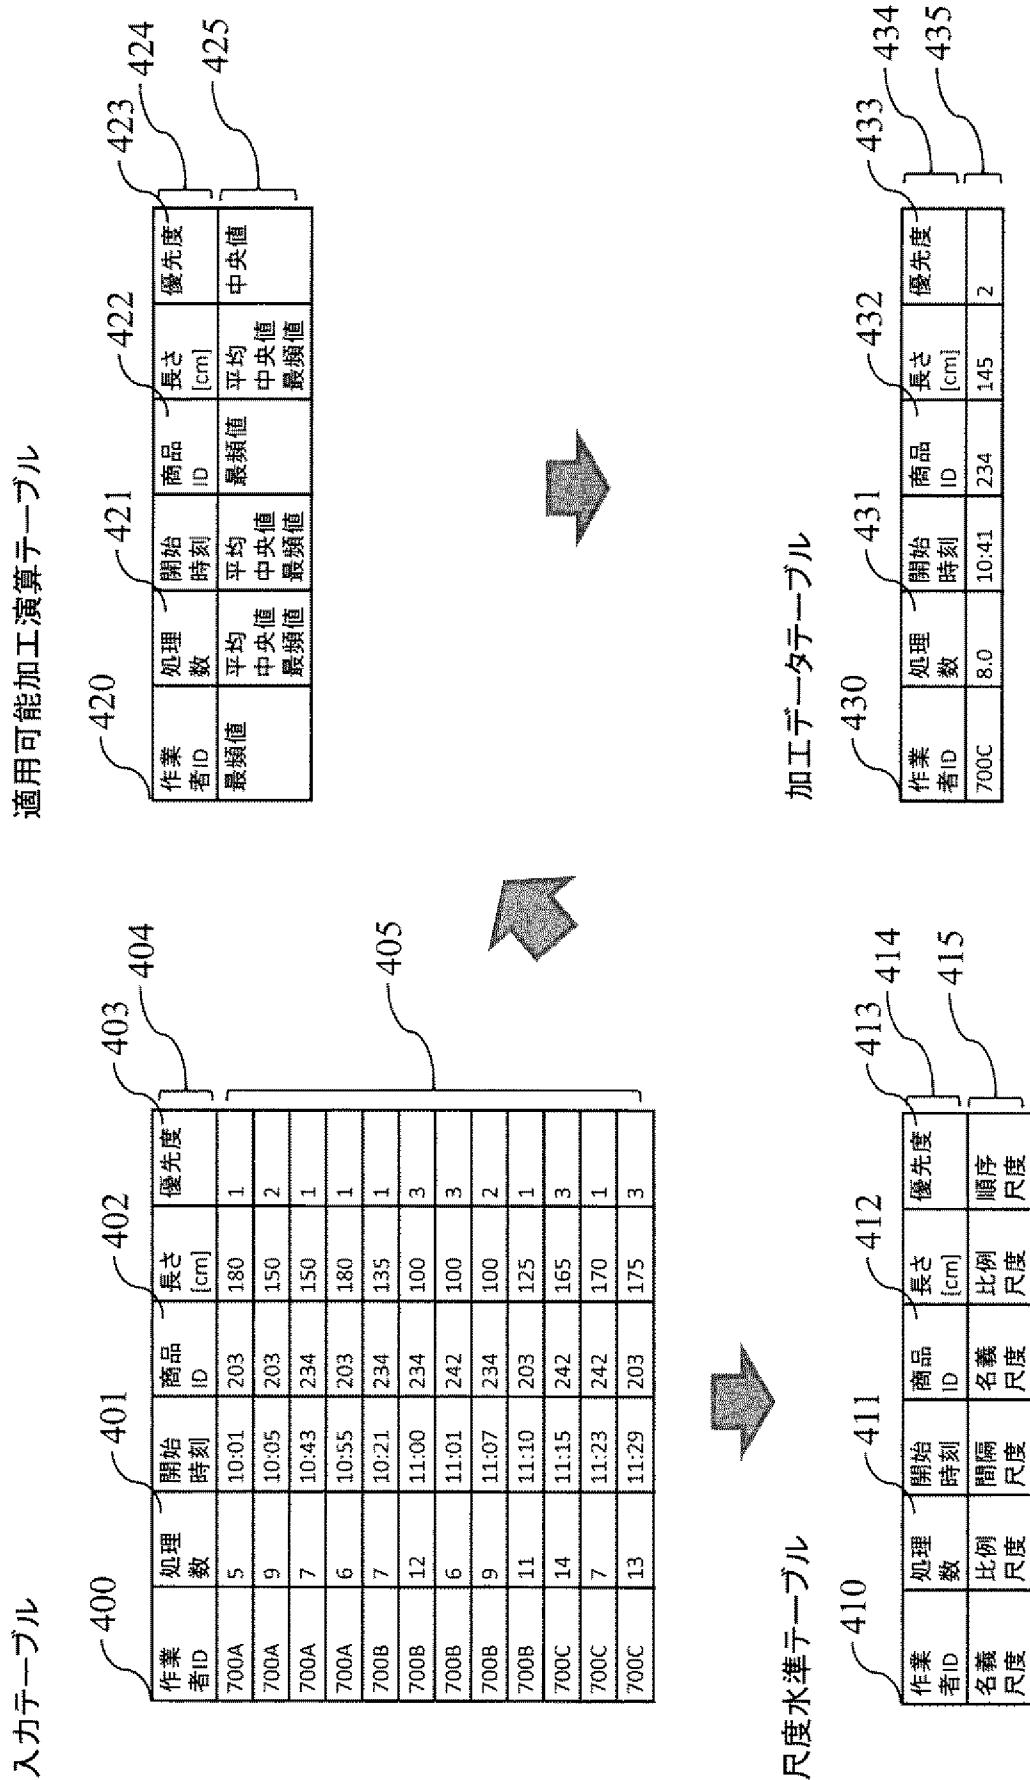
[図2]

概要		データの例	意味のあるデータ加工演算 (情報が多い、ロバスト性の高い順)
比例尺度	比率が等しい 0に意味あり	作業効率[個/秒]:(0.353, 1.246...) 作業時間:(14:00, 30:00...) (840, 1800...) 作業数:(1, 5, 10...) 数量:(2, 40, 210...)	[正規化] 基準値正規化、レンジ正規化 [量子化] 個数等分割、値域等分割 [代表値] 算術平均、幾何平均、中央値、最頻値 [散布度] 散布度、変動率、分散、レンジ、ユニーク数
順序尺度	大小・前後関係に意味あり 差に意味はない	従業員レベル:(5, 4, 3, 2, 1) (A, B, C, D, E) オーダー順:(1, 2, 3, 4, 5)	[正規化] -- [量子化] 個数等分割 [代表値] 中央値、最頻値 [散布度] ユニーク数
間隔尺度	間隔が等しい 差に意味あり 0に意味はない	開始時刻:(13:15:00...) (131500...) (AM 1:15...) X座標:(0, 1, 2 ...) 日付:(2013/11/23,...) (20131123,...)	[正規化] レンジ正規化 [量子化] 個数等分割、値域等分割 [代表値] 算術平均、中央値、最頻値 [散布度] 分散、レンジ、ユニーク数
名義尺度	他のデータとの 区別のみに 意味あり	従業員ID:(86100, 787813...) (62100, 11922...) 商品コード:(4329471, 4432719...) (12342, 15421...) 従業員名:(平山淳一、日立太郎....) 在庫フラグ:(0, 1)(T, F)	[正規化] -- [量子化] 個数等分割 [代表値] 最頻値 [散布度] ユニーク数

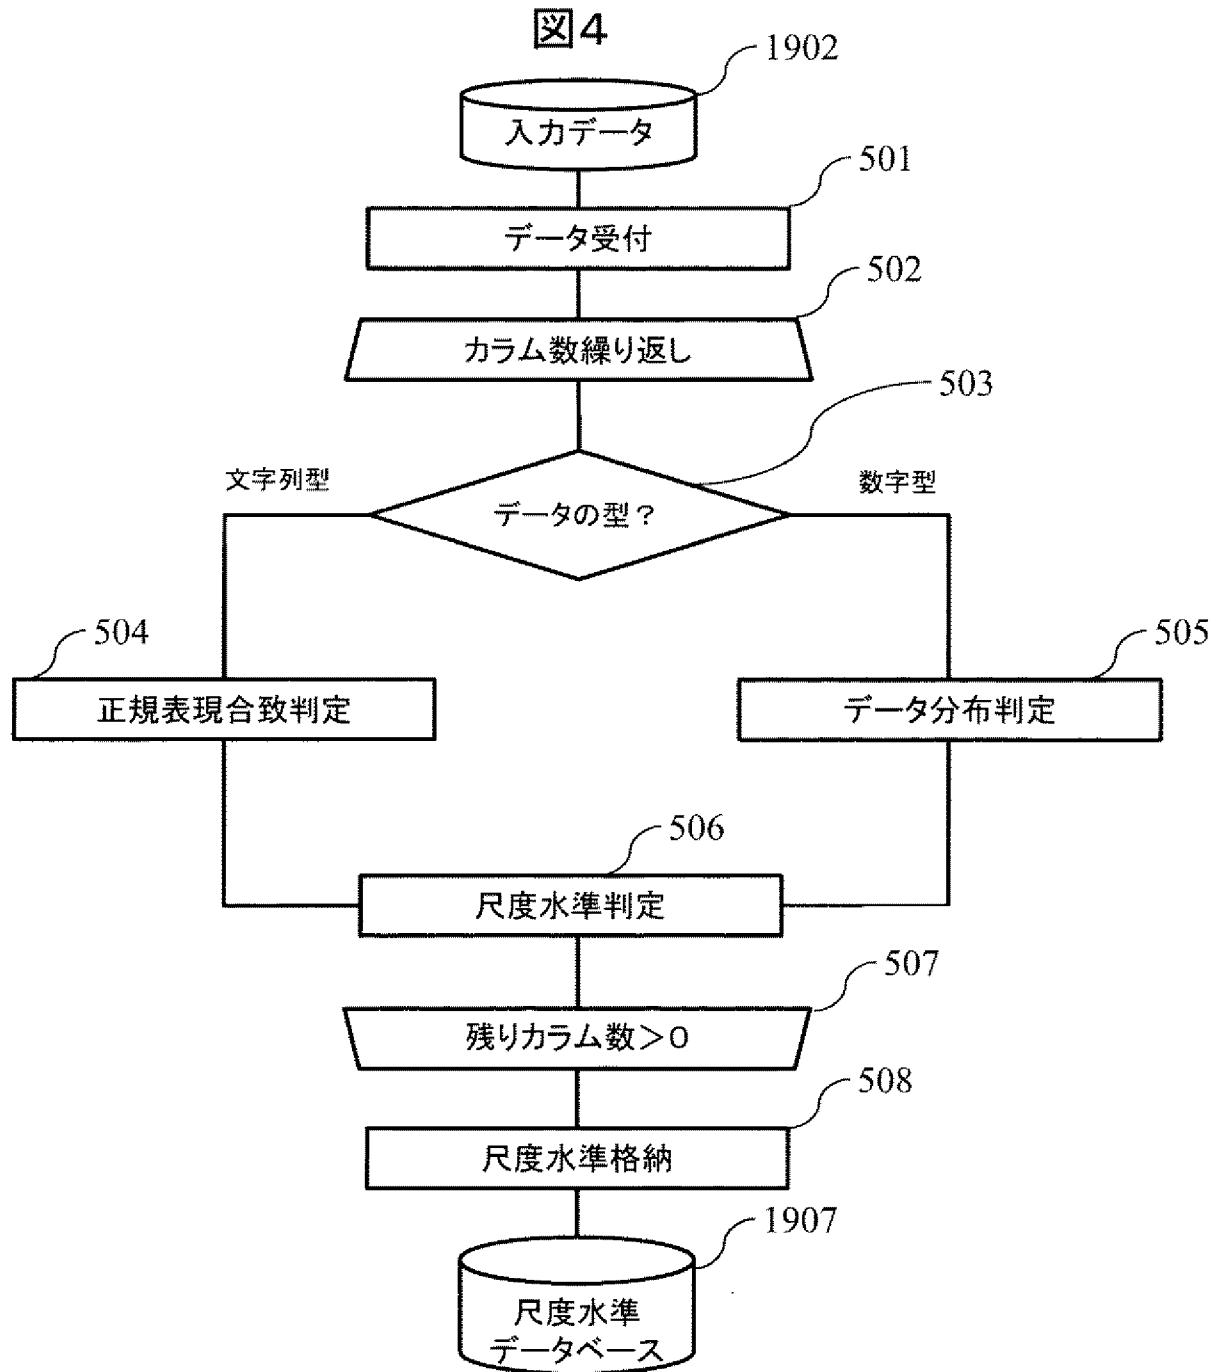
図2

[図3]

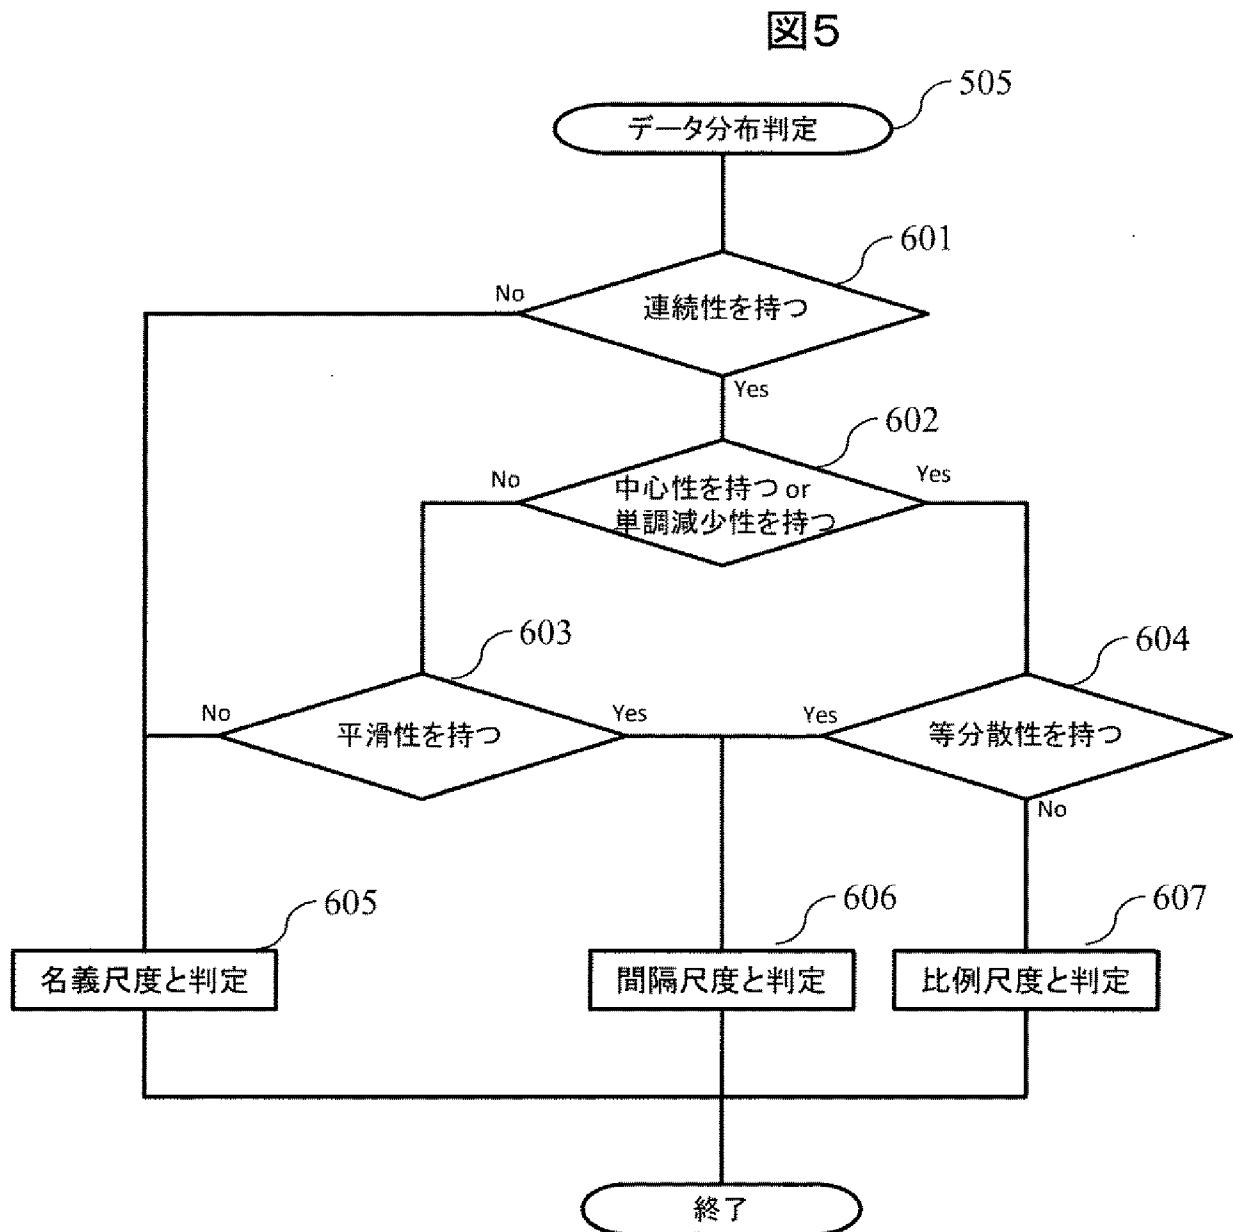
図3



[図4]

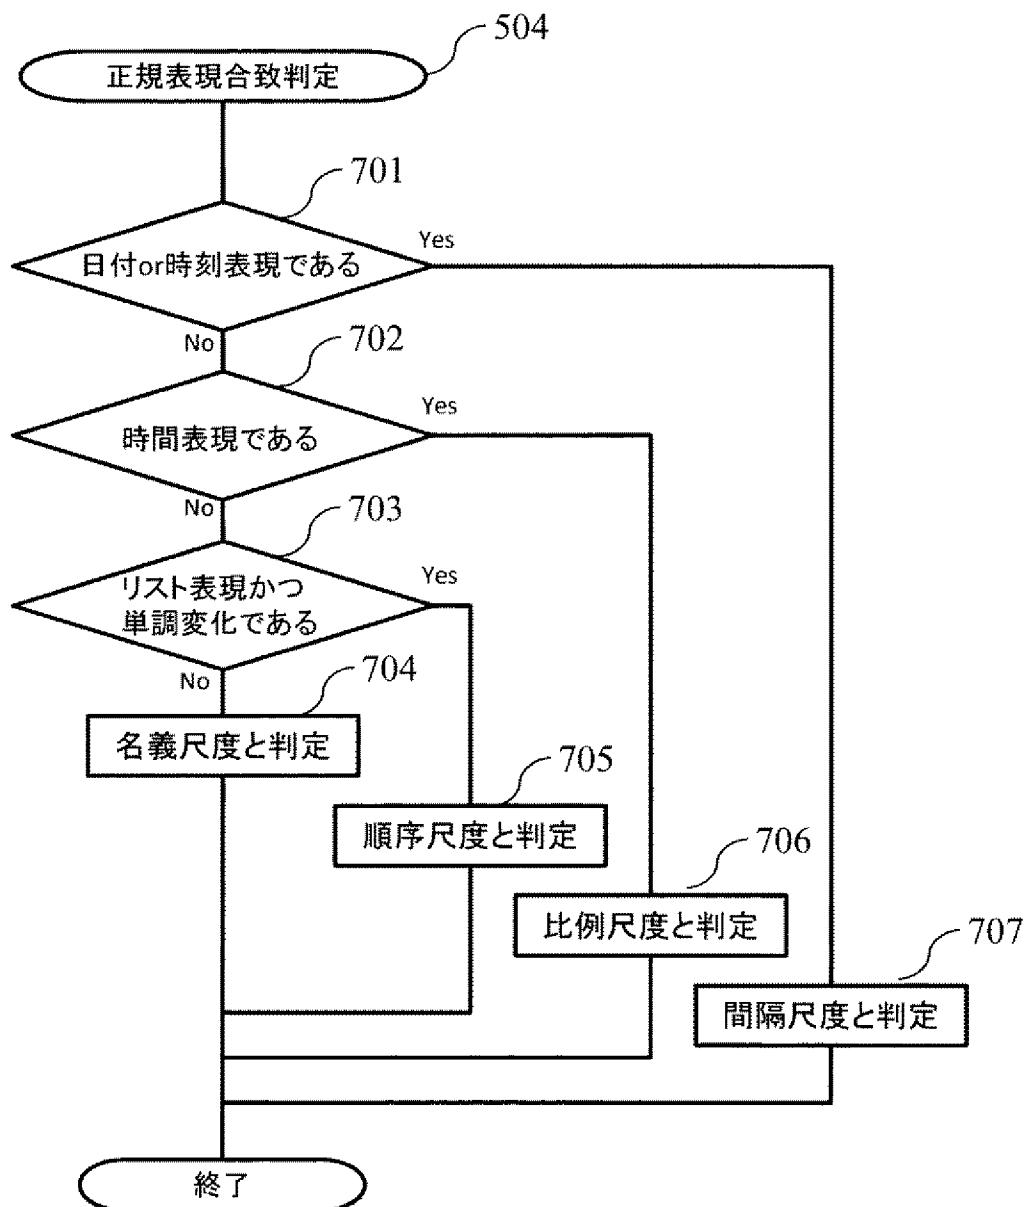


[図5]



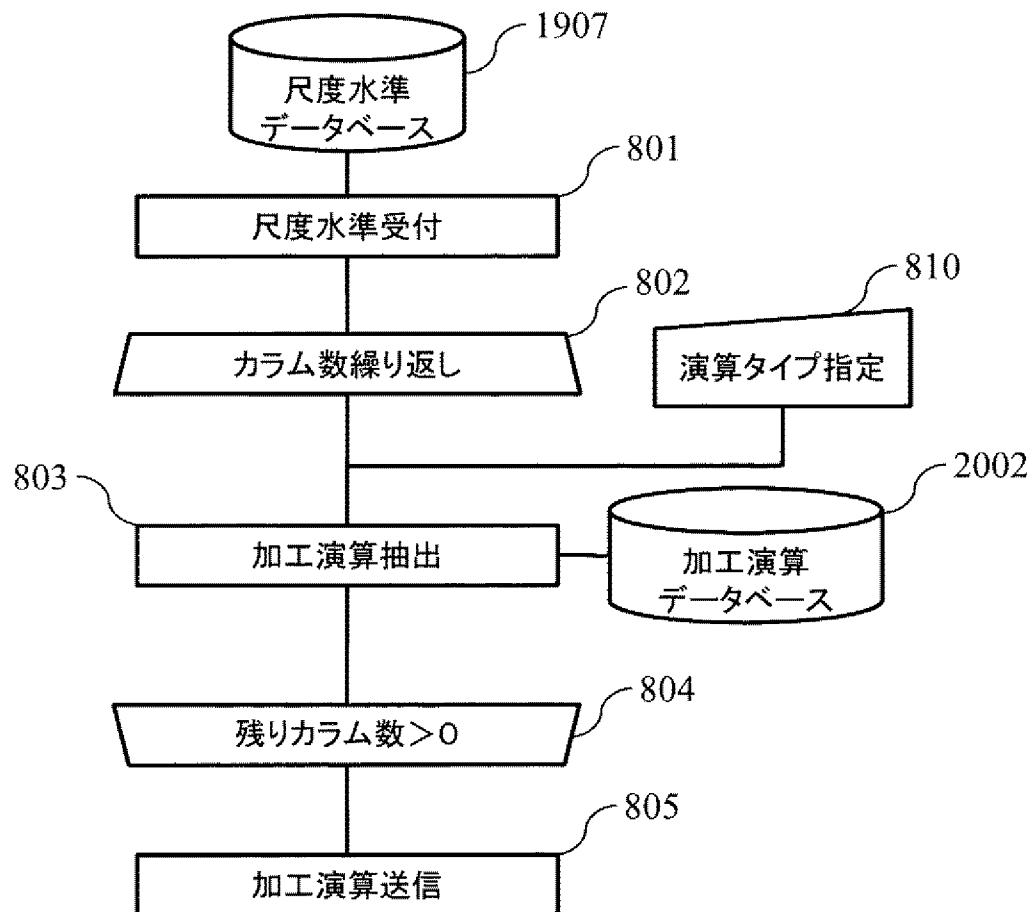
[図6]

図6



[図7]

図7



[図8]

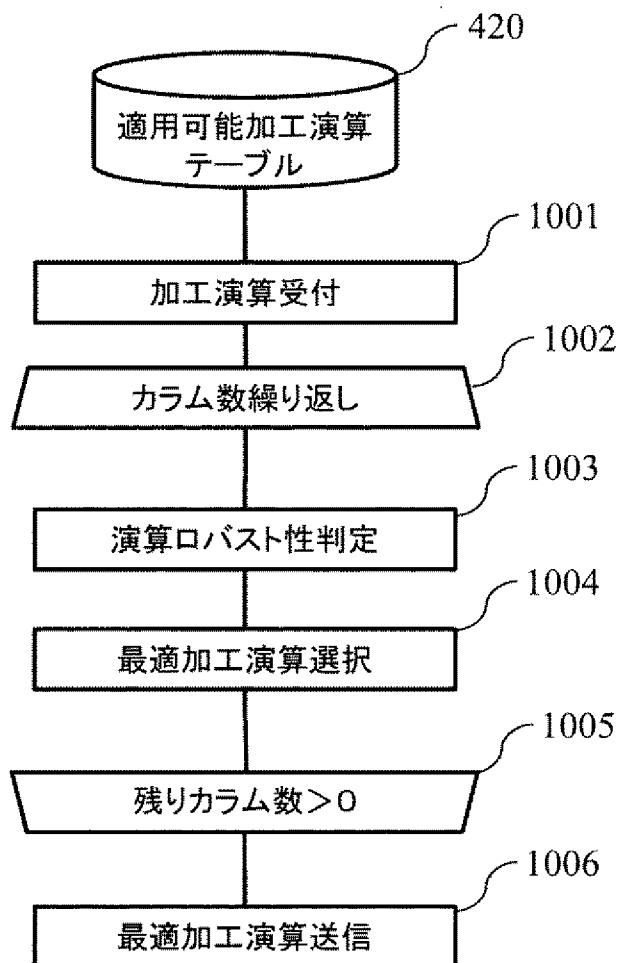
図8



尺度水準	演算タイプ	適用可能加工演算
比例尺度	正規化	基準値正規化、レンジ正規化
	量子化	個数等分割、値域等分割
	代表値	算術平均、幾何平均、中央値、最頻値
	散布度	変動率、分散、レンジ、ユニーク数
間隔尺度	正規化	レンジ正規化
	量子化	個数等分割、値域等分割
	代表値	算術平均、中央値、最頻値
	散布度	分散、レンジ、ユニーク数
順序尺度	正規化	---
	量子化	個数等分割
	代表値	中央値、最頻値
	散布度	ユニーク数
名義尺度	正規化	---
	量子化	個数等分割
	代表値	最頻値
	散布度	ユニーク数

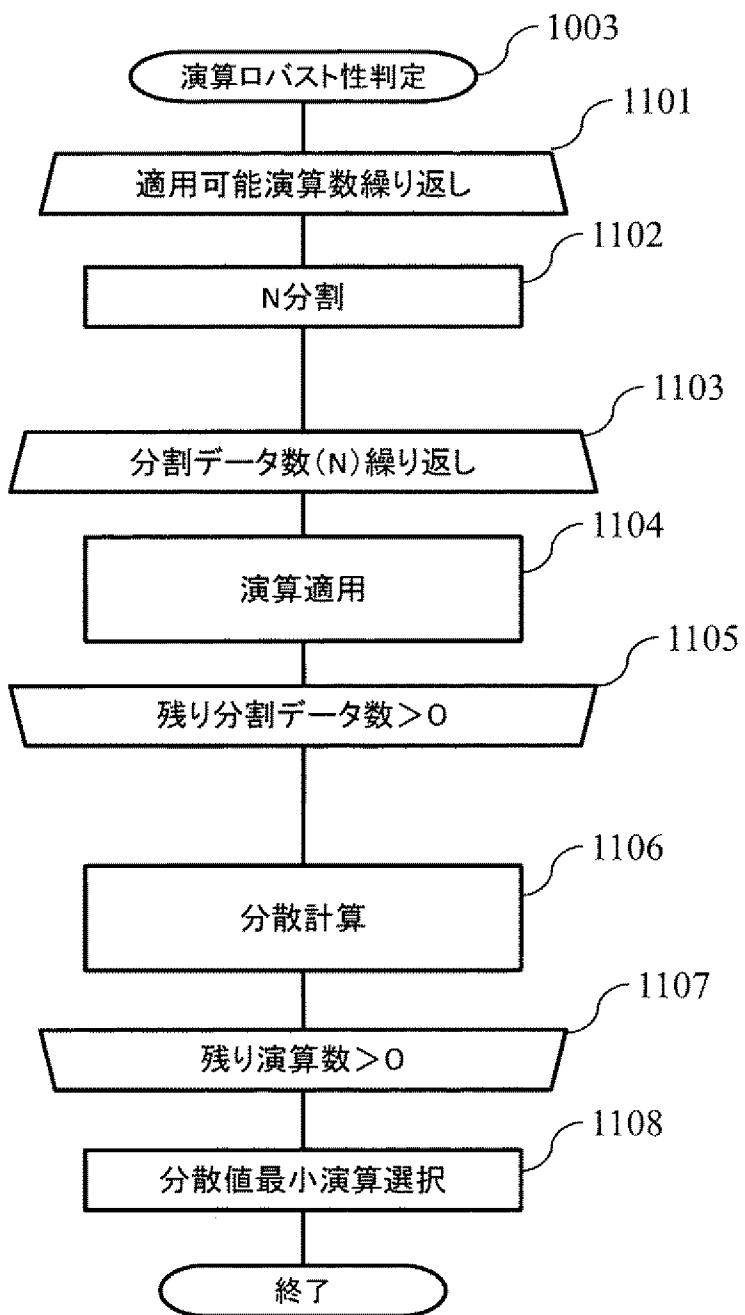
[図9]

図9



[図10]

図10



[図11]

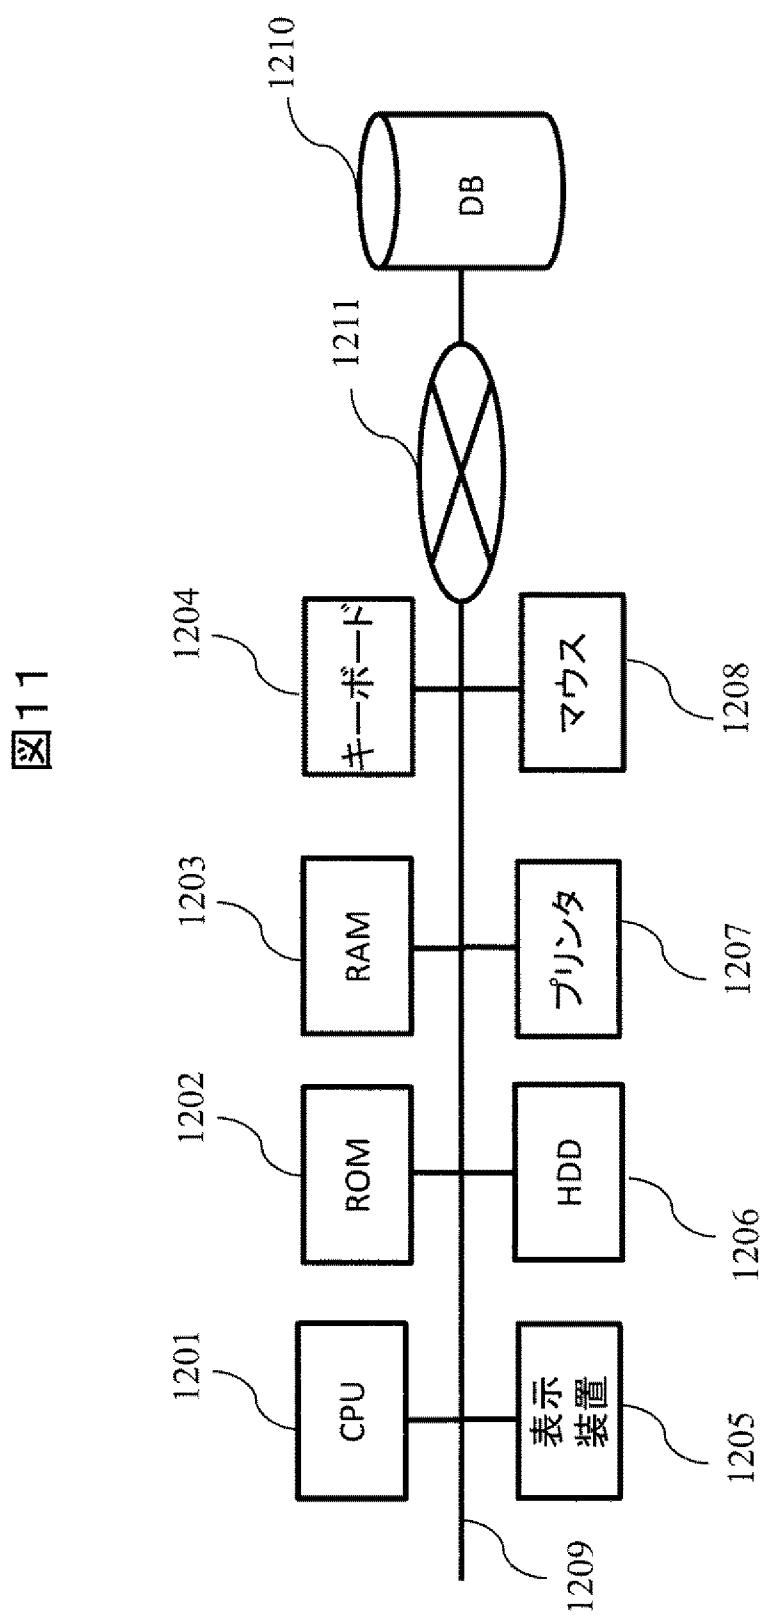
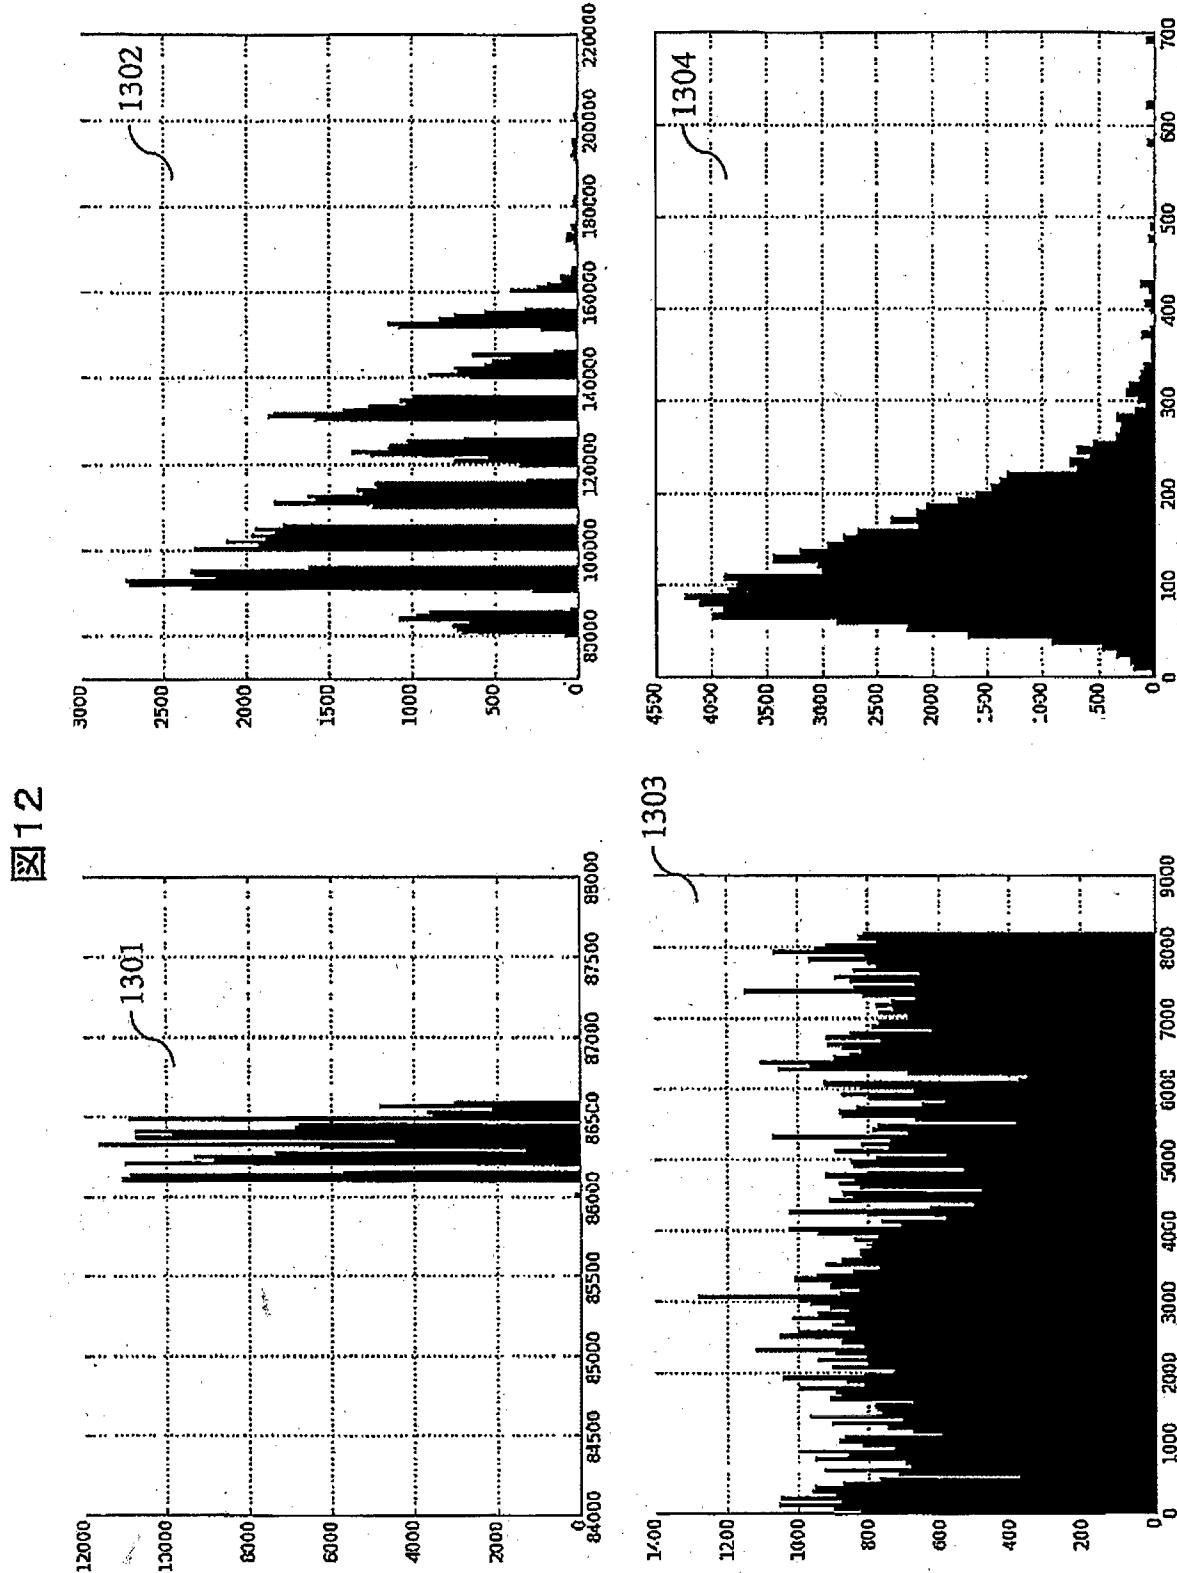
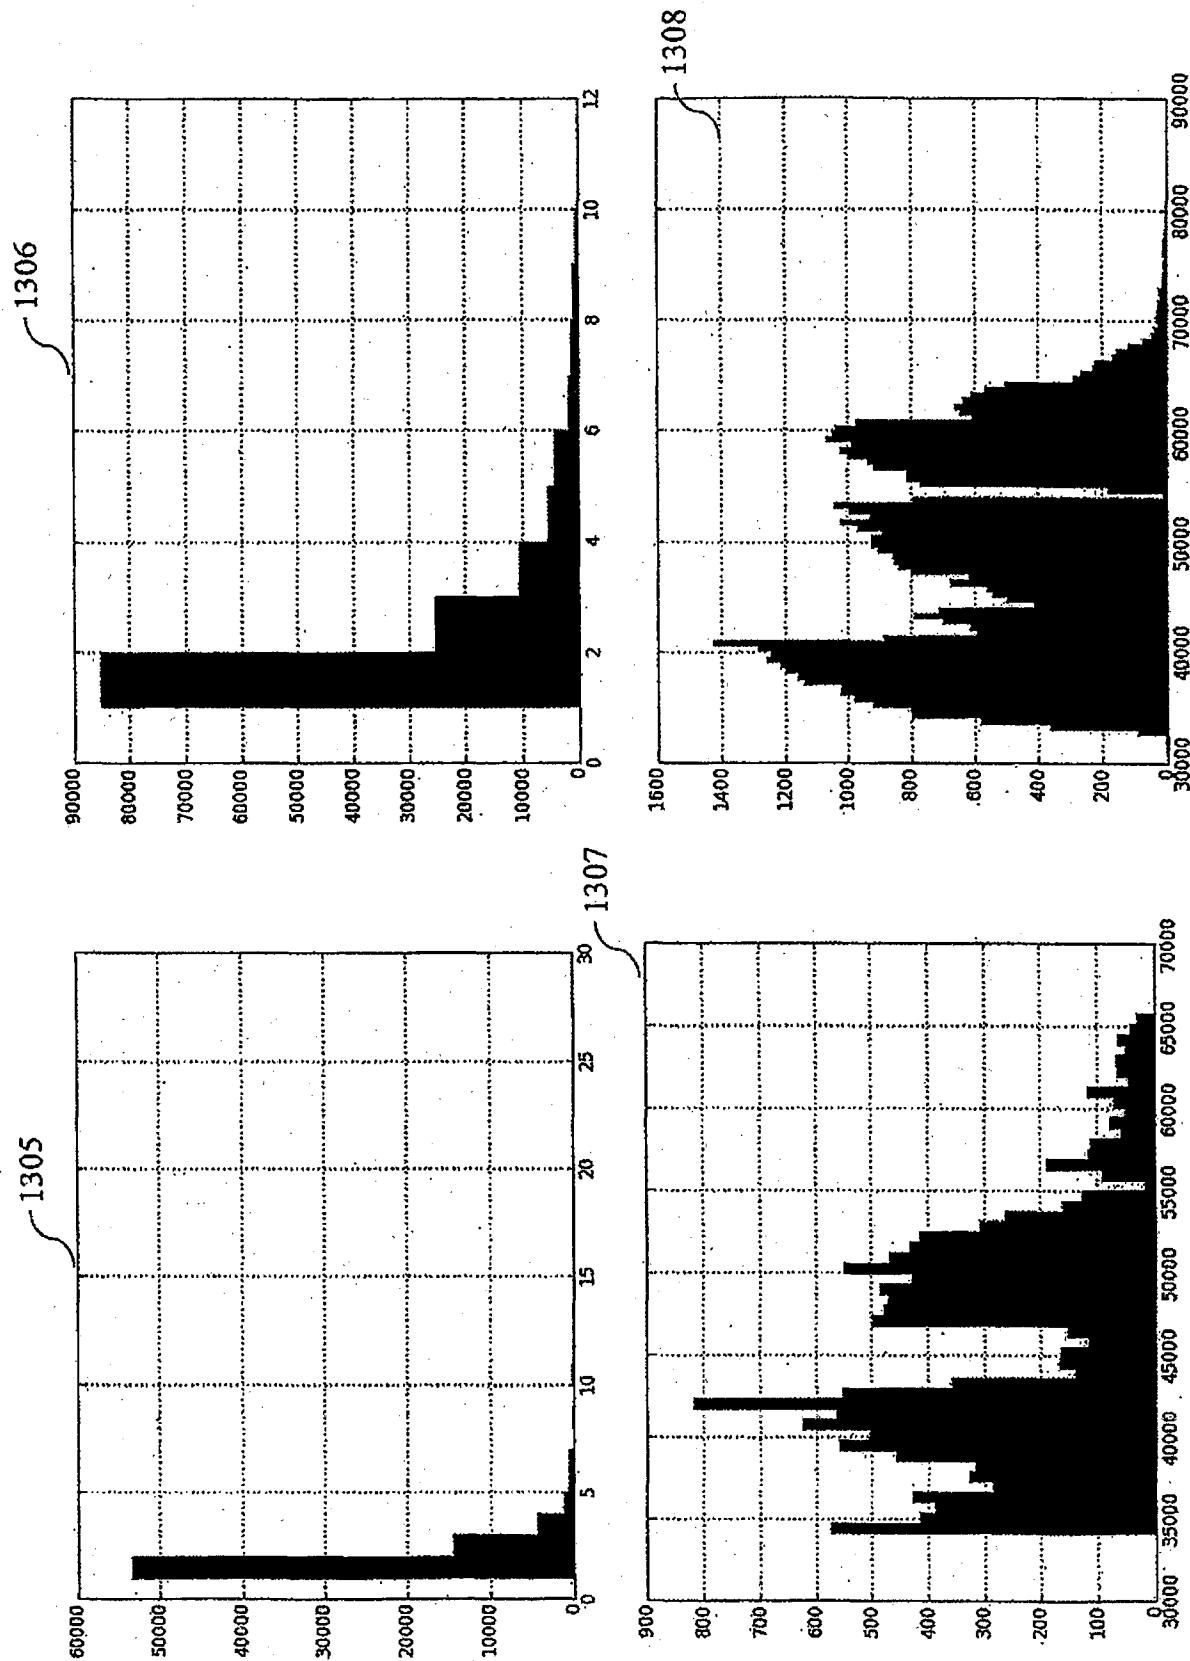


図12]

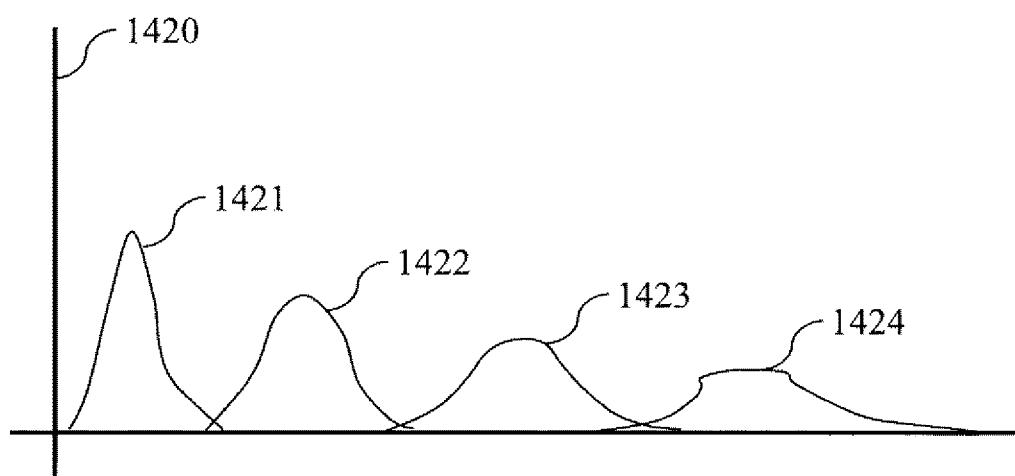
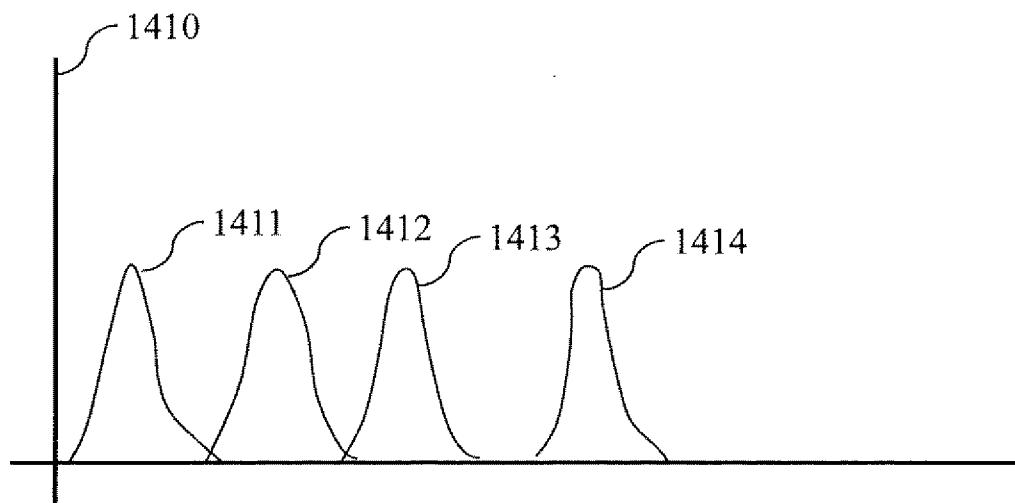


[図12] つづき



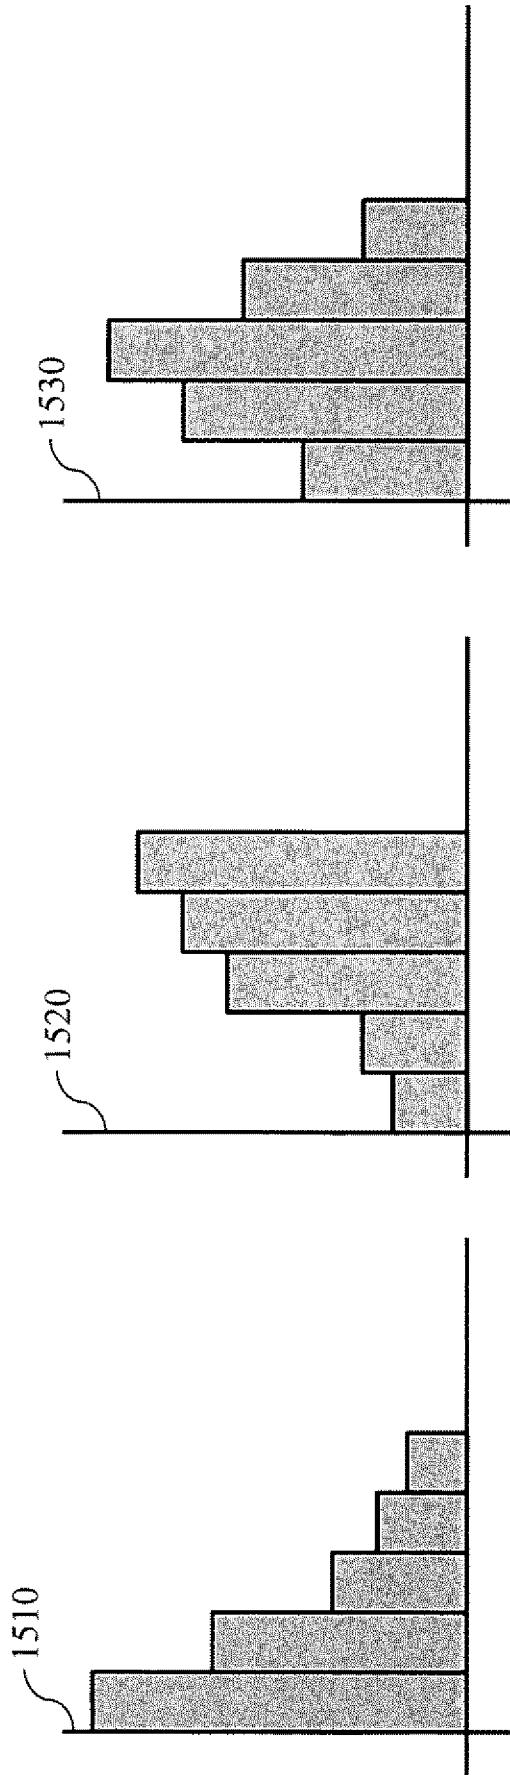
[図13]

図13



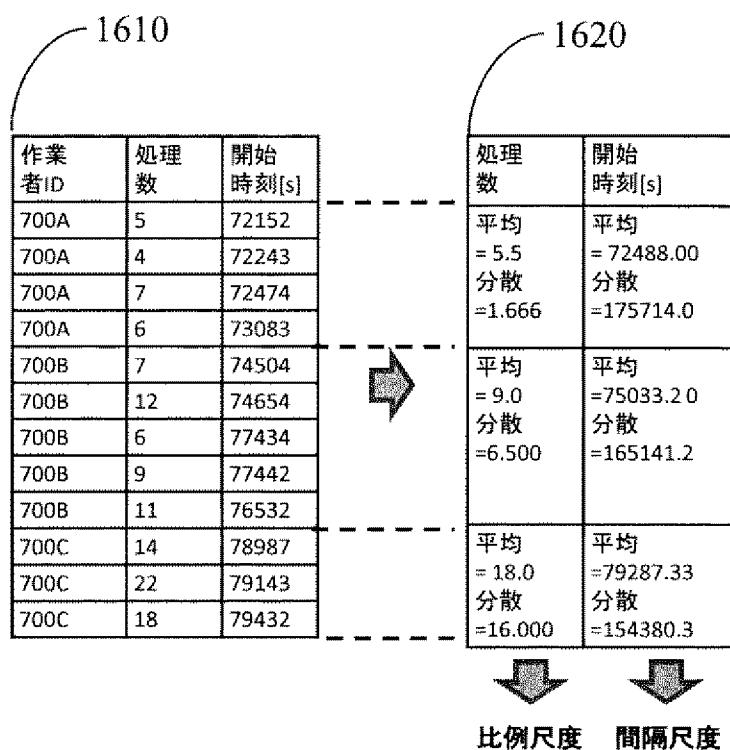
[図14]

図14



[図15]

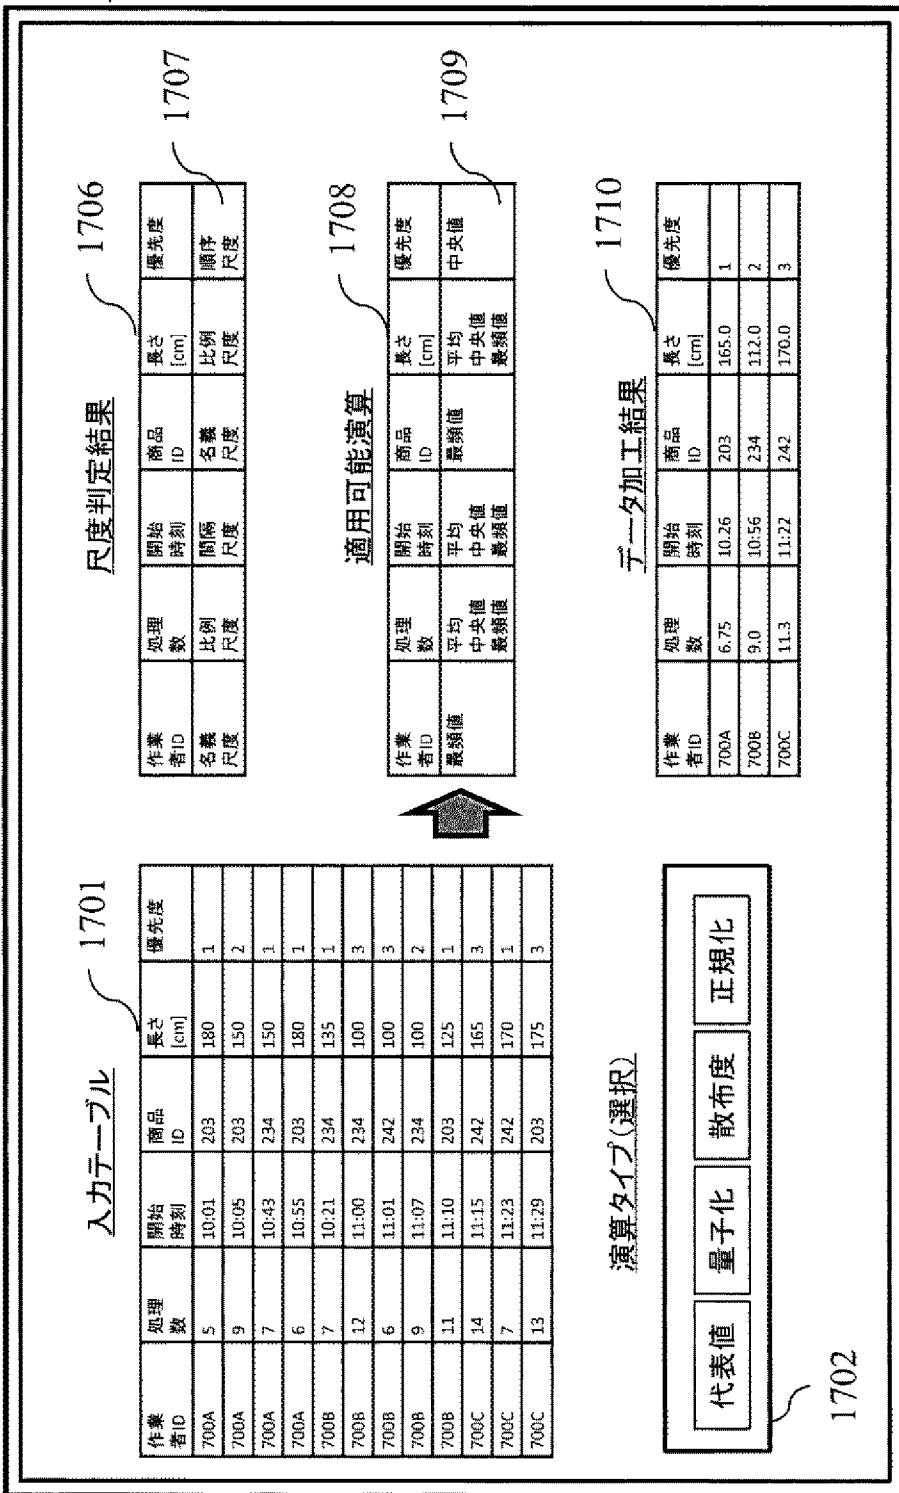
図15



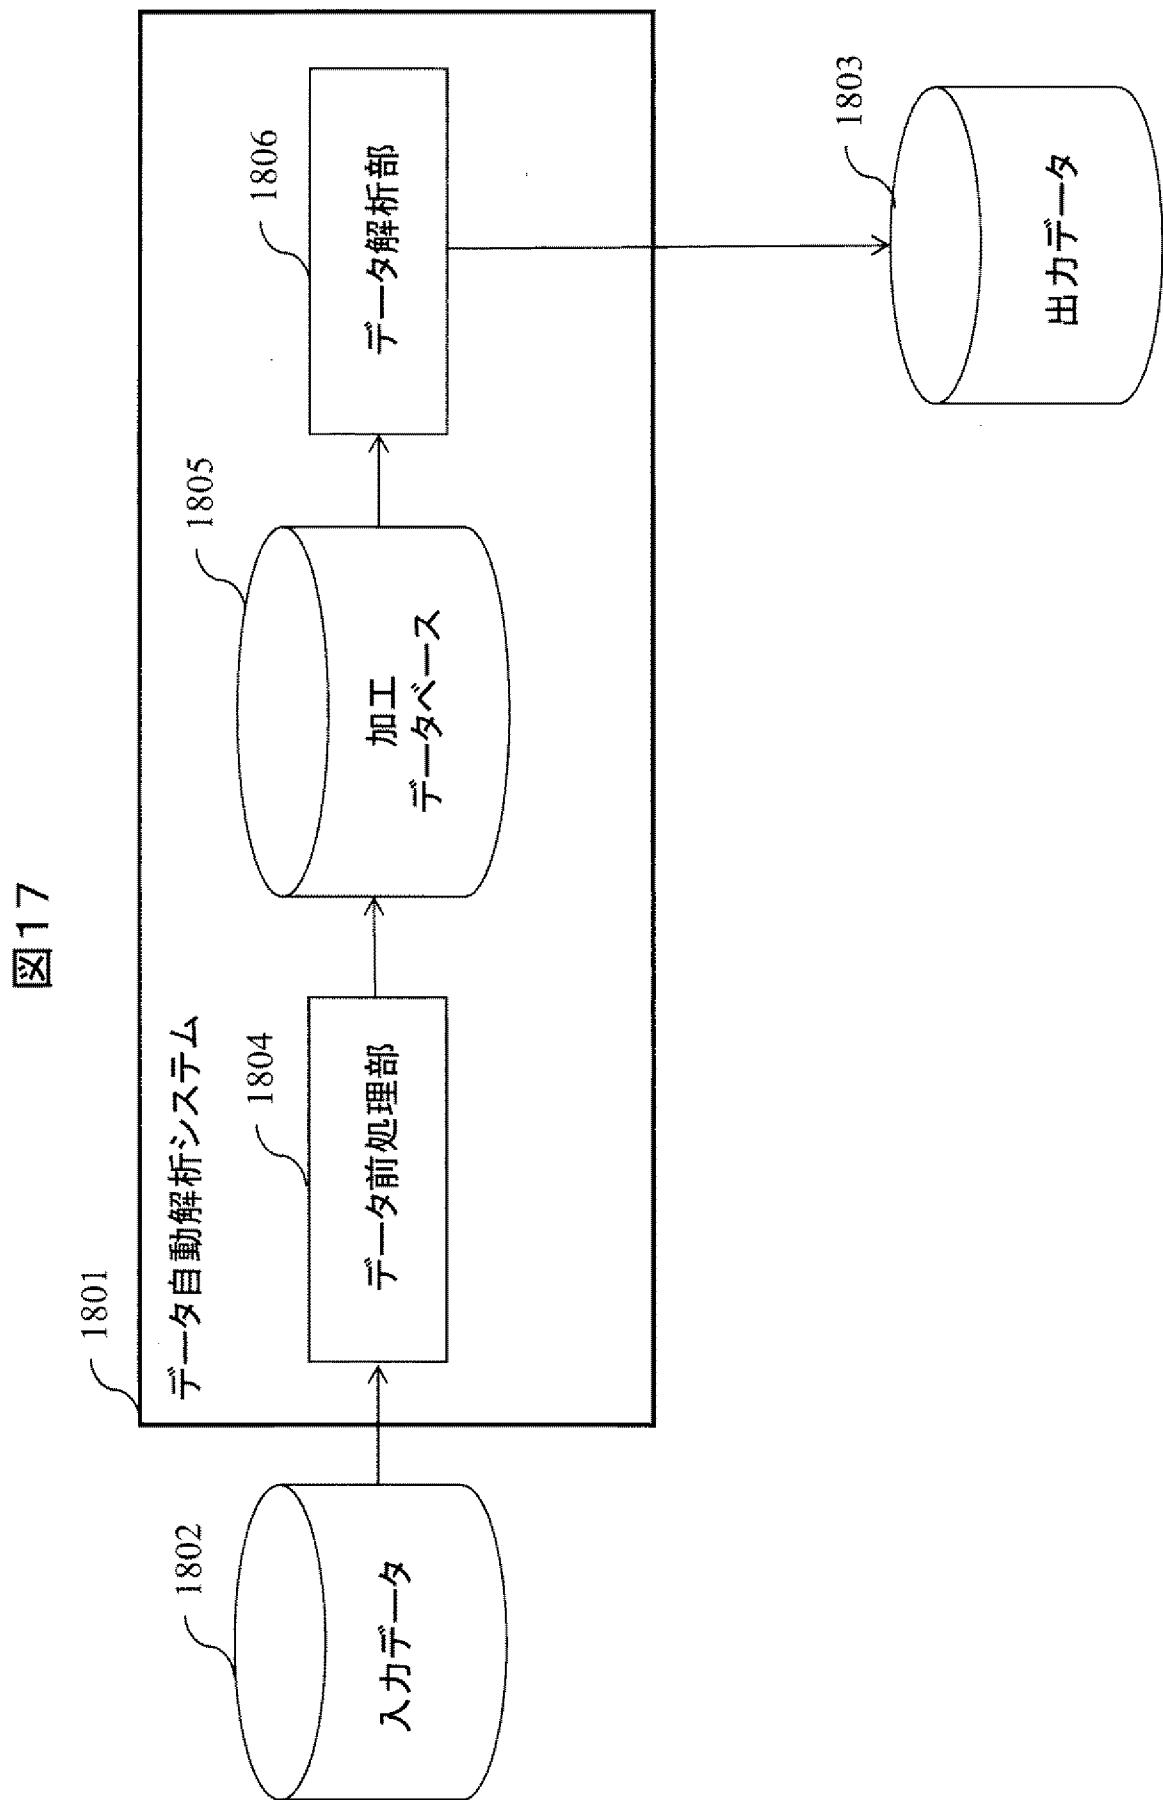
比例尺度 間隔尺度

[図16]

図16

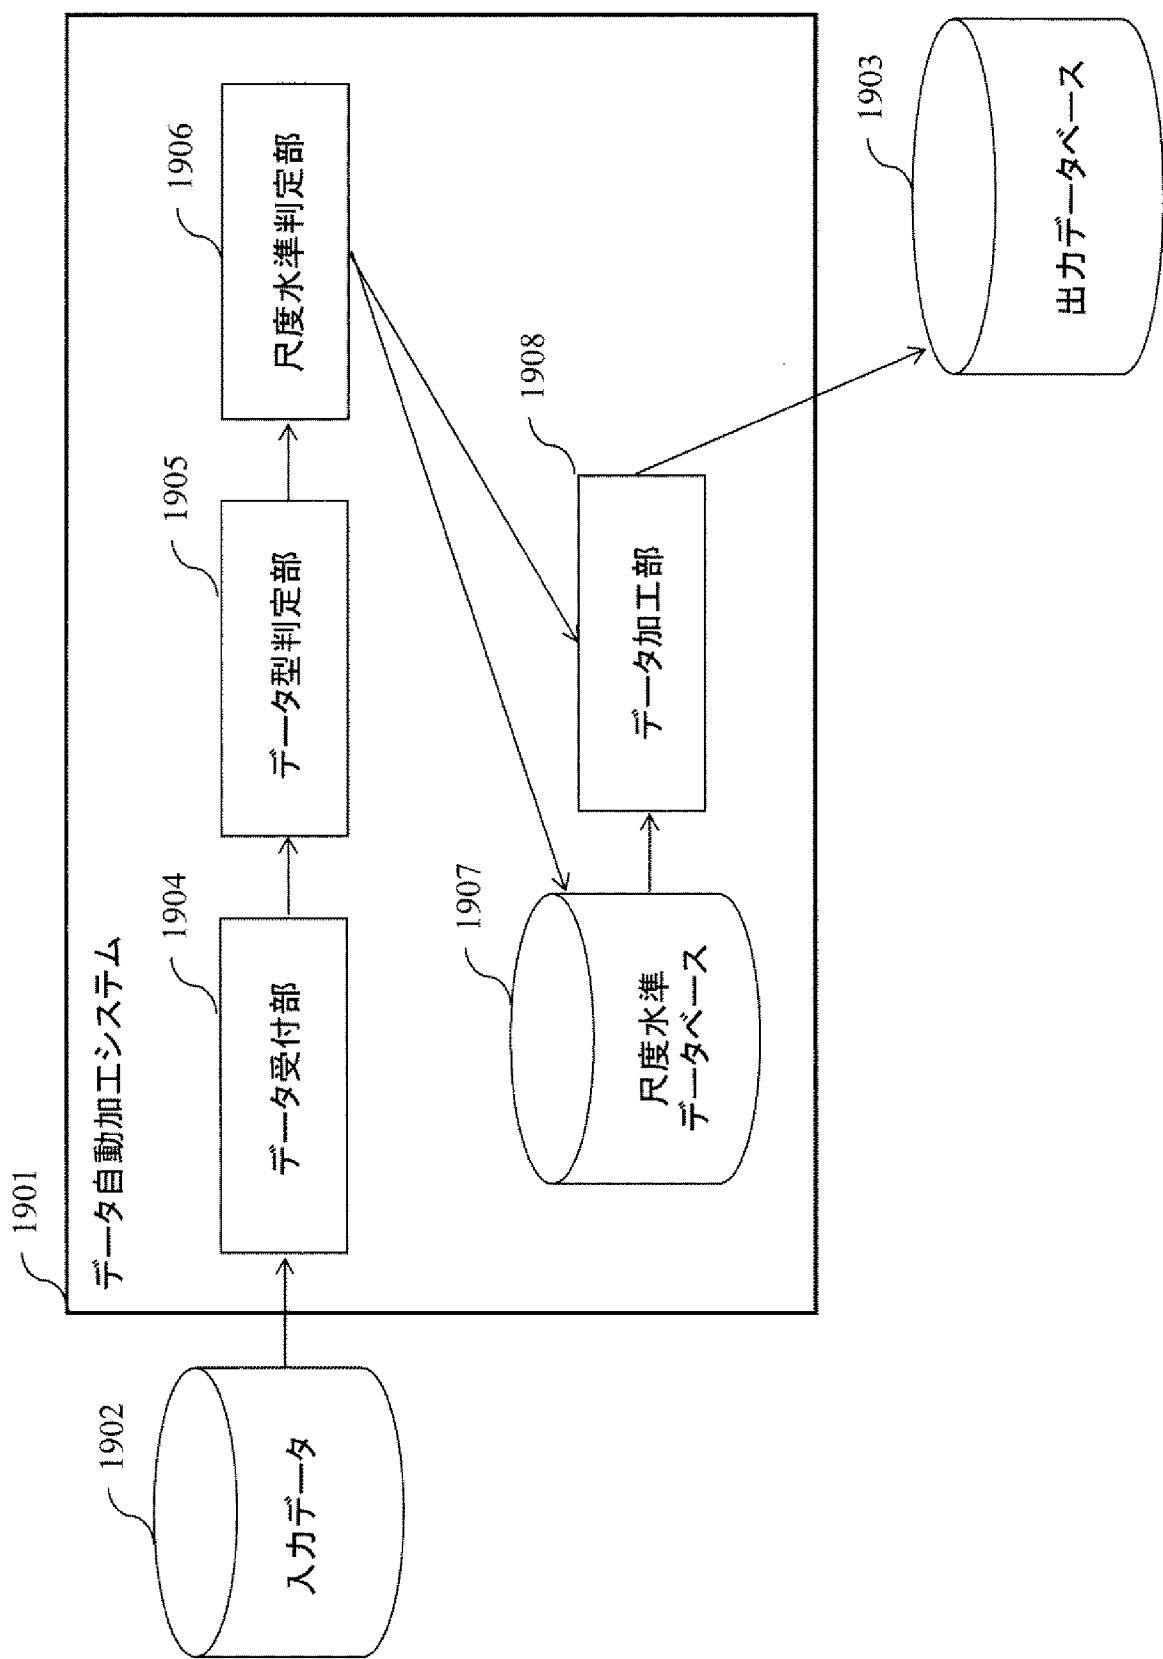


[図17]

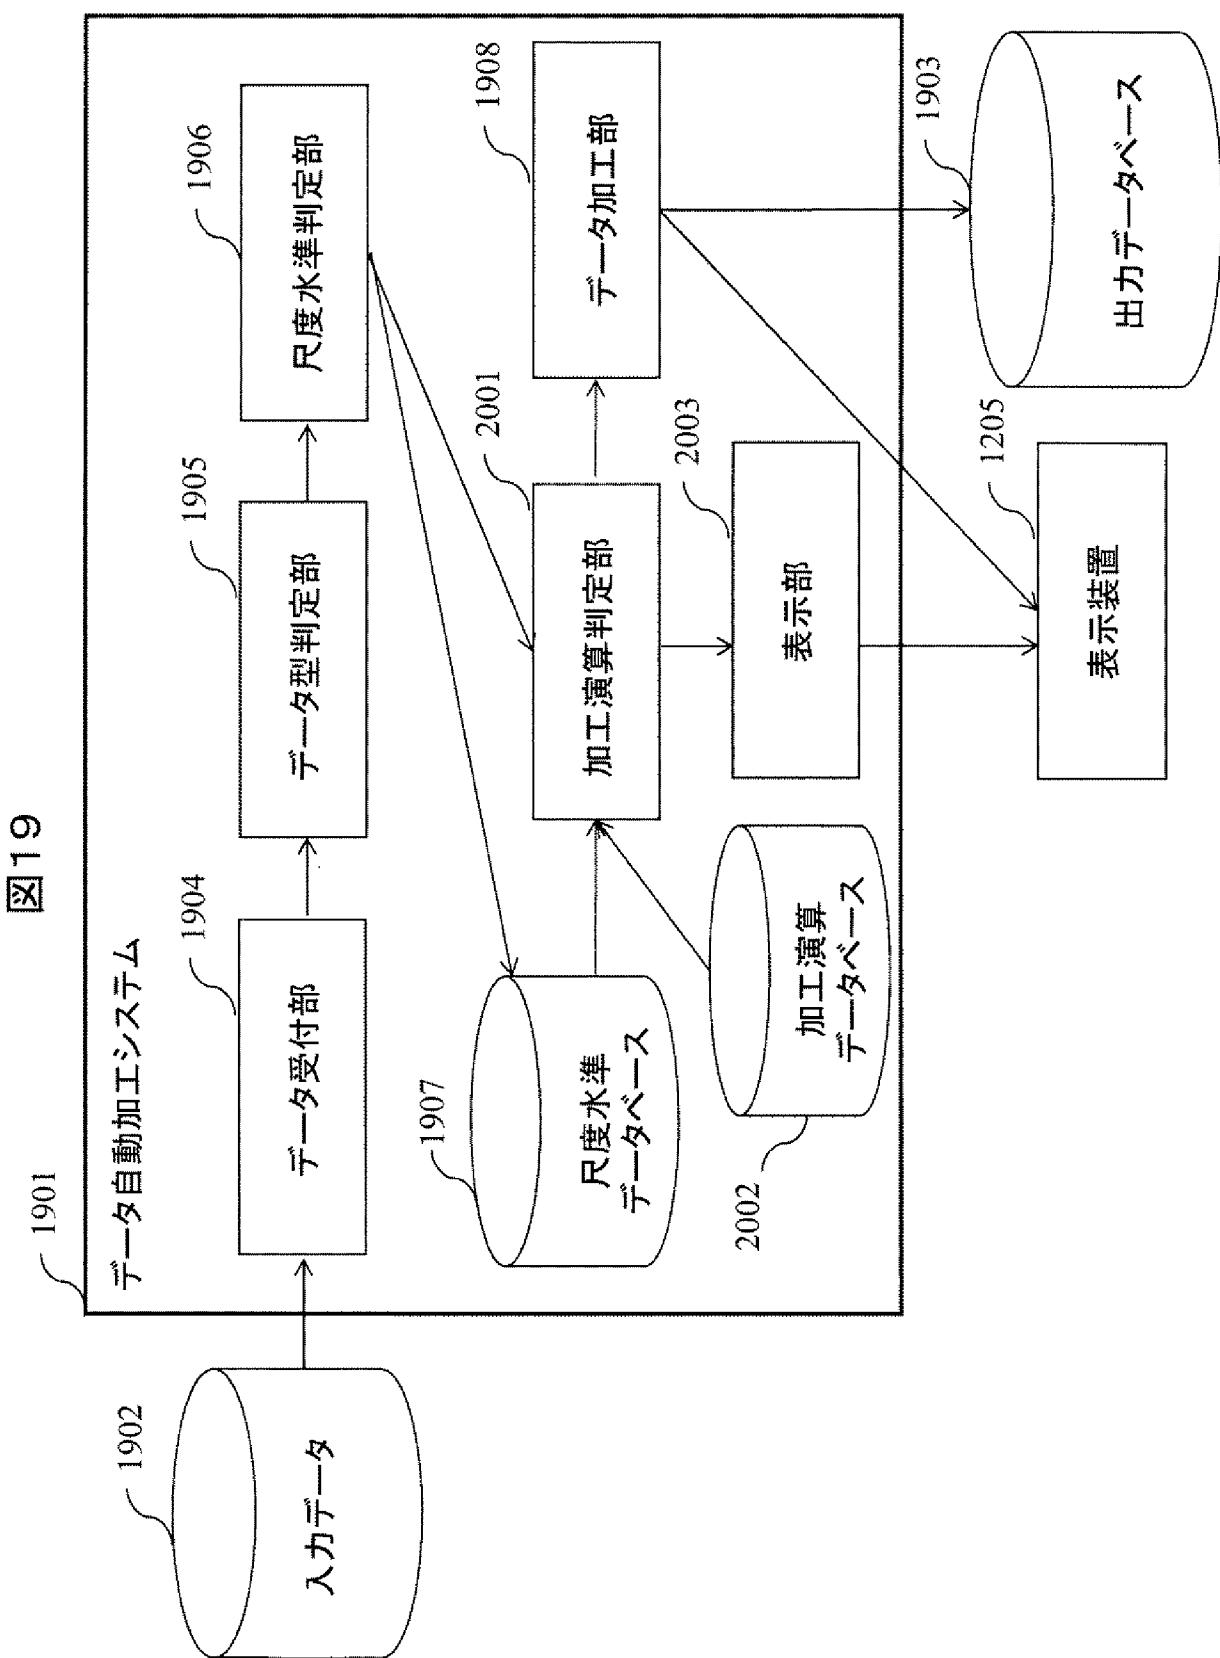


[図18]

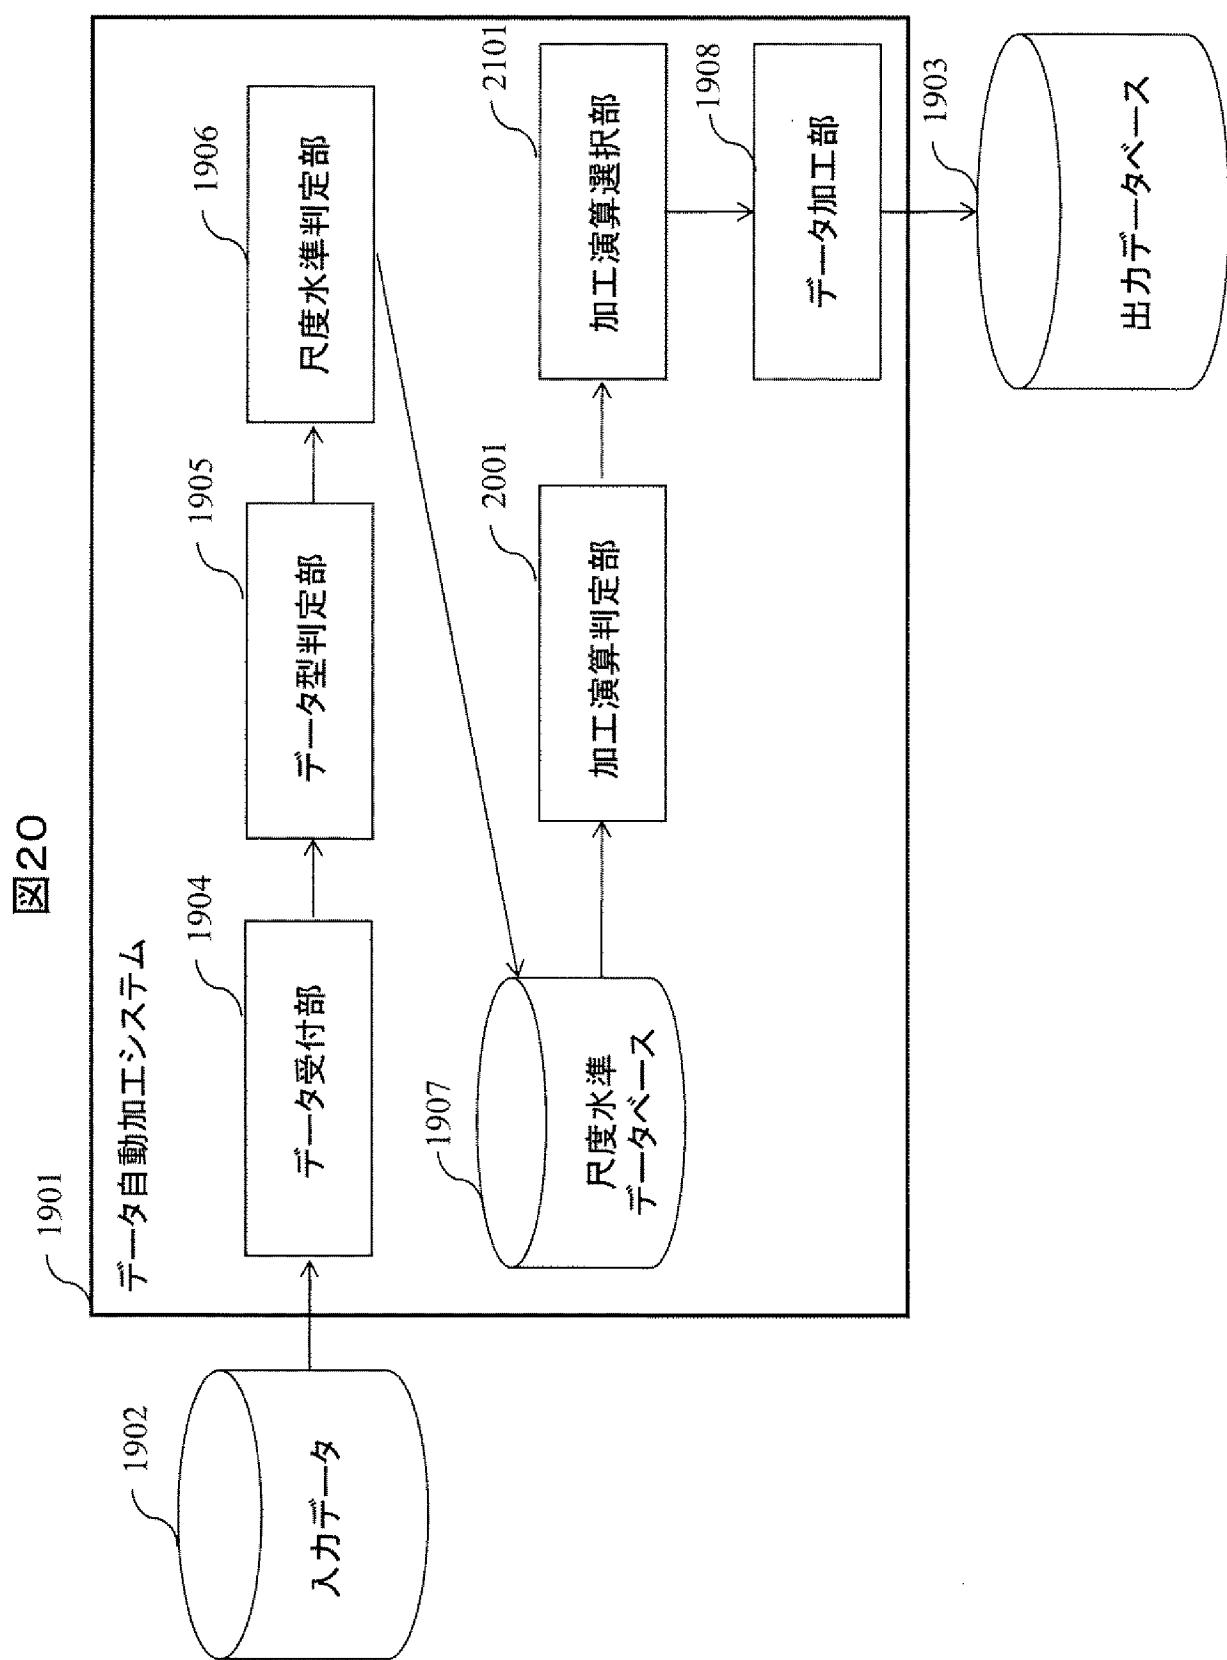
図18



[図19]



[図20]



INTERNATIONAL SEARCH REPORT

International application No.

PCT/JP2015/061778

A. CLASSIFICATION OF SUBJECT MATTER

G06Q50/10(2012.01)i, G06F17/30(2006.01)i, G06F19/00(2011.01)i

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)
G06Q50/10, G06F17/30, G06F19/00

Documentation searched other than minimum documentation to the extent that such documents are included in the fields searched

Jitsuyo Shinan Koho	1922-1996	Jitsuyo Shinan Toroku Koho	1996-2015
Kokai Jitsuyo Shinan Koho	1971-2015	Toroku Jitsuyo Shinan Koho	1994-2015

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 2015-32013 A (KDDI Corp.), 16 February 2015 (16.02.2015), particularly, paragraphs [0023] to [0025] (Family: none)	1-7, 9-14 8
Y A	JP 2000-353163 A (Justsystem Corp.), 19 December 2000 (19.12.2000), particularly, paragraphs [0032], [0039] (Family: none)	1-7, 9-14 8
Y A	written by KELLY Diane, translated by Hideo JOHO, Methods for Evaluating Interactive Information Retrieval Systems with Users, Maruzen Publishing Co., Ltd., 20 April 2013 (20.04.2013), pages 45 to 47	4-5 1-3, 6-14

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	"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
"E" earlier application or patent but published on or after the international filing date	"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
"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)	"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
"O" document referring to an oral disclosure, use, exhibition or other means	"&" document member of the same patent family
"P" document published prior to the international filing date but later than the priority date claimed	

Date of the actual completion of the international search
06 July 2015 (06.07.15)

Date of mailing of the international search report
14 July 2015 (14.07.15)

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

International application No.

PCT/JP2015/061778

C (Continuation). DOCUMENTS CONSIDERED TO BE RELEVANT

Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
Y A	written by Berry, Michael J.A., translated by Atsushi EHARA, Mastering Data Mining <Riron-hen>, 1st edition, Kaibundo Shuppan Kabushiki Kaisha, 30 October 2002 (30.10.2002), pages 204 to 209	6-7 1-5, 8-14

A. 発明の属する分野の分類(国際特許分類(I.P.C.))

Int.Cl. G06Q50/10(2012.01)i, G06F17/30(2006.01)i, G06F19/00(2011.01)i

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(I.P.C.))

Int.Cl. G06Q50/10, G06F17/30, G06F19/00

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	1971-2015年
日本国実用新案登録公報	1996-2015年
日本国登録実用新案公報	1994-2015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 2015-32013 A (KDDI 株式会社)	1-7, 9-14
A	2015.02.16, 特に段落 23-25 (ファミリーなし)	8
Y	JP 2000-353163 A (株式会社ジャストシステム)	1-7, 9-14
A	2000.12.19, 特に段落 32, 39 (ファミリーなし)	8
Y	KELLY Diane 著, 上保秀夫訳, インタラクティブ情報検索システム の評価, 丸善出版株式会社, 2013.04.20, pp. 45-47	4-5 1-3, 6-14
A		

 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」国際出願目前で、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矛盾するものではなく、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

06.07.2015

国際調査報告の発送日

14.07.2015

国際調査機関の名称及びあて先

日本国特許庁 (ISA/JP)

郵便番号 100-8915

東京都千代田区霞が関三丁目4番3号

特許庁審査官(権限のある職員)

5L 4534

大野 朋也

電話番号 03-3581-1101 内線 3562

C (続き) . 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 A	ベリー マイケル J. A. 著, 江原淳訳, マスタリング・データマ イニング <理論編>, 第1版, 海文堂出版株式会社, 2002.10.30, pp.204-209	6-7 1-5, 8-14