

(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
2018年9月7日(07.09.2018)



(10) 国際公開番号

WO 2018/159558 A1

- (51) 国際特許分類:
G06N 99/00 (2010.01) G06T 7/00 (2017.01)
- (21) 国際出願番号: PCT/JP2018/007041
- (22) 国際出願日: 2018年2月26日(26.02.2018)
- (25) 国際出願の言語: 日本語
- (26) 国際公開の言語: 日本語
- (30) 優先権データ:
特願 2017-040325 2017年3月3日(03.03.2017) JP
- (71) 出願人: 富士通株式会社 (FUJITSU LIMITED)
[JP/JP]; 〒2118588 神奈川県川崎市中原区上小田中4丁目1番1号 Kanagawa (JP).
- (72) 発明者: 梅田 裕平 (UMEDA, Yuhei); 〒2118588 神奈川県川崎市中原区上小田中4丁目1番1号 富士通株式会社内 Kanagawa (JP).
- (74) 代理人: 特許業務法人酒井国際特許事務所 (SAKAI INTERNATIONAL PATENT OFFICE); 〒1000013 東京都千代田区霞が関3丁目8番1号 虎の門三井ビルディング 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, 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, KE, KG, KH,

(54) Title: DATA GENERATION METHOD, DATA GENERATION DEVICE, DATA GENERATION PROGRAM

(54) 発明の名称: データ生成方法、データ生成装置及びデータ生成プログラム




FIG. 1:

- 1 Information processing device
101 Chronological data storage unit
103 First generation unit
105 Image data storage unit
107 Machine learning unit
109 Learning data storage unit
111 Second generation unit
113 Relatedness storage unit
115 Determination unit
117 Determination result storage unit

(57) Abstract: This data generation method includes processing by which, by performing a persistent homology process on a collection of points represented by coordinates generated using a plurality of pieces of chronological data and a contribution ratio of each of the plurality of pieces of chronological data, the following are generated: a Betti number sequence corresponding to the contribution ratio; a feature image from the plurality of Betti number series generated for each of the plurality of contribution ratios; and machine learning data in which the feature image and a classification



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,
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), 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)）

corresponding to the plurality of pieces of chronological data are associated.

(57) 要約：本データ生成方法は、複数の時系列データと、複数の時系列データそれぞれの寄与率とにより生成される座標で表された点の集合に対するパーシステントホモロジ処理により、寄与率に対応したベッチ数系列を生成し、複数の寄与率に対してそれぞれ生成された複数のベッチ数系列から特徴画像を生成し、特徴画像と、複数の時系列データに対応した分類とを対応付けた機械学習データを生成する処理を含む。

明 細 書

発明の名称：

データ生成方法、データ生成装置及びデータ生成プログラム

技術分野

[0001] 本発明は、時系列データの処理技術に関する。

背景技術

[0002] 時系列データに対する機械学習が行われている。例えば、人に装着されたウェアラブルセンサにより取得された時系列データを学習データとし、かつ、時系列データが取得された時点における人の状態を教師データとして、学習モデルに対する機械学習をコンピュータに実行させる。そして、機械学習された学習モデルを利用し、新たな時系列データが取得された時点における人の状態をコンピュータに推定させる。

[0003] 時系列データに対する機械学習に関して、或る文献は以下のような技術を開示する。具体的には、図形化手法に基づき時系列データが図形化され、図形化の結果に対して、位相幾何学に基づくデータ分析手法の一つである位相的データ解析 (Topological Data Analysis) が実行される。そして、位相的データ解析の結果に対して、DNN (Deep Neural Network) を用いた機械学習が実行される。

[0004] 但し、上記文献に記載の技術は、単一の時系列データに対する機械学習の技術であるので、複数の時系列データに対する機械学習に適した技術ではない。

先行技術文献

非特許文献

[0005] 非特許文献1：富士通株式会社、“人々の安心安全な暮らしを支える新しいAI「時系列ディープラーニング」”、[online]、平成28年3月10日、[平成28年12月1日検索]、インターネット<URL：<http://journal.jp.fujitsu.com/2016/03/10/01/>>

発明の概要

発明が解決しようとする課題

[0006] 本発明の目的は、１つの側面では、複数の時系列データに対する機械学習に適した特徴情報を生成することである。

課題を解決するための手段

[0007] 一態様に係るデータ生成方法は、複数の時系列データと、複数の時系列データそれぞれの寄与率とにより生成される座標で表された点の集合に対するパーシステントホモロジ処理により、寄与率に対応したベッチ数系列を生成し、複数の寄与率に対してそれぞれ生成された複数のベッチ数系列から特徴画像を生成し、特徴画像と、複数の時系列データに対応した分類とを対応付けた機械学習データを生成する処理を含む。

発明の効果

[0008] １つの側面では、複数の時系列データに対する機械学習に適した特徴情報を生成できる。

図面の簡単な説明

[0009] [図1]図１は、第１の実施の形態の情報処理装置の機能ブロック図である。
[図2]図２は、第１の実施の形態のメイン処理フローを示す図である。
[図3]図３は、時系列データの正規化について説明するための図である。
[図4]図４は、拡張アトラクタの生成について説明するための図である。
[図5]図５は、 α の値の一例を示す図である。
[図6]図６は、拡張ベクトル生成処理の処理フローを示す図である。
[図7]図７は、バーコード図の一例を示す図である。
[図8]図８は、バーコードデータの一例を示す図である。
[図9]図９は、バーコードデータとベッチシリーズとの関係について説明するための図である。
[図10]図１０は、パーシステント区間の一例を示す図である。
[図11]図１１は、特徴画像について説明するための図である。

[図12]図12は、第1の実施の形態のメイン処理フローを示す図である。

[図13]図13は、第1の実施の形態におけるCNNの一例を示す模式図である。

[図14]図14は、ラベルと重み行列との関係を説明するための図である。

[図15]図15は、統計量の算出について説明するための図である。

[図16]図16は、関連度のベクトルの生成について説明するための図である。

[図17]図17は、第1の実施の形態のメイン処理フローを示す図である。

[図18]図18は、第1の関係データについてのパターンを示す図である。

[図19]図19は、第2の関係データについてのパターンを示す図である。

[図20]図20は、第3の関係データについてのパターン及び第4の関係データについてのパターンを示す図である。

[図21]図21は、時系列データの具体例を示す図である。

[図22]図22は、時系列データの具体例を示す図である。

[図23]図23は、時系列データの具体例を示す図である。

[図24]図24は、時系列データの具体例を示す図である。

[図25]図25は、時系列データの具体例を示す図である。

[図26]図26は、時系列データの具体例を示す図である。

[図27]図27は、時系列データの具体例を示す図である。

[図28]図28は、時系列データの具体例を示す図である。

[図29]図29は、関連度と寄与パラメータとの関係を示す図である。

[図30]図30は、第2の実施の形態におけるメイン処理フローを示す図である。

[図31]図31は、第2の実施の形態における学習モデルの一例を示す図である。

[図32]図32は、第3の実施の形態の情報処理装置の機能ブロック図である。

[図33]図33は、第3の実施の形態におけるメイン処理フローを示す図であ

る。

[図34]図34は、入力ベクトルの一例を示す図である。

[図35]図35は、第3の実施の形態におけるメイン処理フローを示す図である。

[図36]図36は、第3の実施の形態におけるメイン処理フローを示す図である。

[図37]図37は、第4の実施の形態の情報処理装置の機能ブロック図である。

[図38]図38は、第4の実施の形態におけるメイン処理フローを示す図である。

[図39]図39は、第4の実施の形態における関連度の算出について説明するための図である。

[図40]図40は、コンピュータの機能ブロック図である。

発明を実施するための形態

[0010] [実施の形態1]

図1は、第1の実施の形態の情報処理装置1の機能ブロック図である。情報処理装置1は、時系列データ格納部101と、第1生成部103と、画像データ格納部105と、機械学習部107と、学習データ格納部109と、第2生成部111と、関連度格納部113と、判定部115と、判定結果格納部117とを含む。

[0011] 第1生成部103、機械学習部107、第2生成部111および判定部115は、例えば、図40に示したメモリ2501にロードされたプログラムが図40に示したCPU (Central Processing Unit) 2503により実行されることで実現される。時系列データ格納部101、画像データ格納部105、学習データ格納部109、関連度格納部113および判定結果格納部117は、例えば、図40に示したHDD (Hard Disk Drive) 2505又はメモリ2501に設けられる。

[0012] 第1生成部103は、時系列データ格納部101に格納されているデータ

に基づき処理を実行し、処理結果を画像データ格納部 105 に格納する。機械学習部 107 は、画像データ格納部 105 に格納されているデータに基づき処理を実行し、処理結果を学習データ格納部 109 に格納する。第 2 生成部 111 は、学習データ格納部 109 に格納されているデータに基づき処理を実行し、処理結果を関連度格納部 113 に格納する。判定部 115 は、関連度格納部 113 に格納されているデータに基づき処理を実行し、処理結果を判定結果格納部 117 に格納する。

[0013] 時系列データ格納部 101 に格納されているデータは、例えば、生体データ（心拍数、脳波、脈拍或いは体温などの時系列データ）、ウェアラブルセンサのデータ（ジャイロセンサ、加速度センサ或いは地磁気センサなどの時系列データ）、金融データ（金利、物価、国際収支或いは株価などの時系列データ）、自然環境のデータ（気温、湿度或いは二酸化炭素濃度などの時系列データ）、又は社会データ（労働統計或いは人口統計などのデータ）等である。但し、時系列データは、少なくとも以下のルールに従って変化するデータであるとする。

[0014] [数1]

$$x(i) = f(x(i-1), \dots, x(i-2), x(i-N)) \quad \dots (1)$$

[0015] 例えば、不規則な時系列データ又は手書き文字の軌跡などの人為的な動きに関するデータは、本実施の形態の対象外であるとする。また、時系列データ格納部 101 には、複数の時系列データを含むデータセットが複数格納されているとする。

[0016] 図 2 は、第 1 の実施の形態の情報処理装置 1 が実行する処理の処理フローを示す図である。

[0017] 第 1 生成部 103 は、時系列データ格納部 101 に格納されている複数のデータセットのうち 1 つのデータセットを特定する。そして、第 1 生成部 103 は、特定したデータセットに含まれる複数の時系列データの各々を、値の平均が 0 になるように平行移動する（図 2：ステップ S1）。

[0018] 第 1 生成部 103 は、ステップ S1 の処理が実行された全時系列データの

振幅の幅が同じになるように正規化を実行する（ステップS3）。

[0019] 複数の時系列データが異なる種類の時系列データである場合には軸のスケールが異なるので、時系列データの生の値をそのまま利用することは問題である。例えば図3に示すように、時系列データ t_1 の値の変動が時系列データ t_2 の値の変動より大きい場合であっても、分類に与える影響に関しても時系列データ t_1 の方が大きいとは限らないので、軸のスケールが異なっていると誤った学習が行われる可能性がある。そこで、ステップS3の処理により軸のスケールを一致させることで、この問題を解消することができる。

[0020] 第1生成部103は、 α の各値について、正規化された複数の時系列データから拡張アトラクタを生成する（ステップS7）。第1生成部103は、生成した拡張アトラクタをメモリ2501に格納する。

[0021] 例えば、時系列データの数が2つである場合には以下のような拡張アトラクタが生成される。

[0022] [数2]

$$\begin{pmatrix} (1-\alpha)*x_1 \\ (1-\alpha)*x_2 \\ (1-\alpha)*x_3 \\ \alpha*y_1 \\ \alpha*y_2 \\ \alpha*y_3 \end{pmatrix}, \begin{pmatrix} (1-\alpha)*x_2 \\ (1-\alpha)*x_3 \\ (1-\alpha)*x_4 \\ \alpha*y_2 \\ \alpha*y_3 \\ \alpha*y_4 \end{pmatrix}, \dots, \begin{pmatrix} (1-\alpha)*x_k \\ (1-\alpha)*x_{k+1} \\ (1-\alpha)*x_{k+2} \\ \alpha*y_k \\ \alpha*y_{k+1} \\ \alpha*y_{k+2} \end{pmatrix} \quad \dots (2)$$

[0023] α は寄与パラメータである。 x_i ($1 \leq i \leq (k+2)$) は第1の時系列データの値であり、 y_j ($1 \leq j \leq (k+2)$) は第2の時系列データの値である。

[0024] 図4は、拡張アトラクタの生成について説明するための図である。拡張アトラクタの生成はターケンスの埋め込み定理に基づく。第1の時系列データから取り出されたN個（Nは埋め込み次元である。式（2）の例では $N=3$ ）の値に $(1-\alpha)$ が乗じられ、第2の時系列データから取り出されたN個の値に α が乗じられ、それらの値は1つの点の座標の成分になる。式（2）の例では $\tau=1$ であるため1つおきに要素が取り出されている。但し、Nの

値および τ の値は式（２）の例には限られない。

[0025] 寄与パラメータ α は、例えば、 $0 \leq \alpha \leq 1$ を満たす実数であり、時系列データの値の大きさを調整するパラメータである。但し、 α の範囲はこのような範囲でなくてもよい。本実施の形態においては、例えば図５に示すように、一定の間隔で設定された複数の値が使用される。

[0026] そして、第１生成部１０３は、ステップＳ７において生成された拡張アトラクタを用いて、拡張ベクトル生成処理を実行する（ステップＳ９）。拡張ベクトル生成処理については、図６乃至図１０を用いて説明する。

[0027] 第１生成部１０３は、寄与パラメータ α の値のうち未処理の値を１つ特定する（図６：ステップＳ４１）。

[0028] 第１生成部１０３は、ステップＳ４１において特定した値についての拡張アトラクタを、メモリ２５０１から読み出す（ステップＳ４３）。

[0029] 第１生成部１０３は、パーシステントホモロジ処理によって、拡張アトラクタからバーコードデータを穴の次元（以下、穴次元と呼ぶ）毎に生成する（ステップＳ４５）。

[0030] 「ホモロジ」とは、対象の特徴を m （ $m \geq 0$ ）次元の穴の数によって表現する手法である。ここで言う「穴」とはホモロジ群の元のことであり、０次元の穴は連結成分であり、１次元の穴は穴（トンネル）であり、２次元の穴は空洞である。各次元の穴の数はベッチ数と呼ばれる。

[0031] 「パーシステントホモロジ」とは、対象（ここでは、拡張アトラクタ）における m 次元の穴の遷移を特徴付けるための手法であり、パーシステントホモロジによって点の配置に関する特徴を調べることができる。この手法においては、対象における各点が球状に徐々に膨らまされ、その過程において各穴が発生した時刻（発生時の球の半径で表される）と消滅した時刻（消滅時の球の半径で表される）とが特定される。

[0032] 穴の発生半径と消滅半径とを使用することで、例えば図７に示すようなバーコード図を生成することができる。図７において、横軸は半径を表し、各線分は１つの穴に対応する。線分の左端に対応する半径は穴の発生半径であ

り、線分の右端に対応する半径は穴の消滅半径である。線分はパーシステント区間と呼ばれる。このようなバーコード図から、例えば半径が0.18である時には2つの穴が存在するということがわかる。

[0033] 図8に、バーコード図を生成するためのデータ（以下、バーコードデータと呼ぶ）の一例を示す。図8の例では、穴次元を表す数値と、穴の発生半径と、穴の消滅半径とがバーコードデータに含まれる。ステップS45において、バーコードデータは穴次元毎に生成される。

[0034] 以上のような処理を実行すれば、或る拡張アトラクタから生成されるバーコードデータと他の拡張アトラクタから生成されるバーコードデータとの類似関係は、拡張アトラクタ間の類似関係と等価である。よって、拡張アトラクタとバーコードデータとの関係は1対1の関係である。

[0035] すなわち、拡張アトラクタが同じであれば、生成されるバーコードデータは同じである。逆に、バーコードデータが同じであれば、拡張アトラクタも同じである。また、拡張アトラクタが類似している場合にはバーコードデータも類似するため、機械学習に必要な条件が満たされる。拡張アトラクタが異なる場合には、バーコードデータも異なる。

[0036] なお、パーシステントホモロジーの詳細については、例えば「平岡裕章、『タンパク質構造とトポロジー パーシステントホモロジー群入門』、共立出版」を参照されたい。

[0037] 図6の説明に戻り、第1生成部103は、長さが所定長未満であるパーシステント区間のデータを、ステップS45において生成されたバーコードデータから削除する（ステップS47）。なお、パーシステント区間の長さは、（消滅半径－発生半径）によって算出される。所定長は、例えば、0次元の穴が発生してから消滅するまでの時間をK等分した時間（以下、ブロックと呼ぶ）の長さである。但し、1ブロックの長さに限られるわけではなく、複数ブロックの長さを所定長としてもよい。

[0038] 発生から消滅までの時間が短い元は、ノイズによって発生するものがほとんどである。長さが所定長未満であるパーシステント区間のデータを削除す

れば、ノイズの影響を緩和することができるので、分類性能を向上させることができるようになる。但し、削除の対象は次元が1以上であるパーシステント区間のデータであるとする。

[0039] ノイズが発生した場合においては、僅かな時間だけ1次元以上の穴が発生することがある。ステップS47の処理を実行すれば、両ケースにおいて生成されるデータはほぼ同じになるので、ノイズの影響を取り除くことができるようになる。

[0040] なお、長さが所定長未満であるパーシステント区間のデータが削除されるので、削除後のバーコードデータ間の類似関係は、元のバーコードデータ間の類似関係と厳密には等価ではない。削除が行われない場合には、類似関係は等価である。

[0041] 図6の説明に戻り、第1生成部103は、バーコードデータを統合し、統合されたバーコードデータから拡張ベクトルを生成する（ステップS48）。拡張ベクトルはベッチ数の系列である。

[0042] 上で述べたように、バーコードデータは穴次元毎に生成されるので、第1生成部103は、複数の穴次元のバーコードデータを統合することで1塊のバーコードデータを生成する。ベッチ数の系列は、パーシステントホモロジにおける球の半径（すなわち時間）とベッチ数との関係を示すデータである。図9を用いて、バーコードデータと生成されるベッチ数の系列との関係について説明する。上段のグラフはバーコードデータから生成されるグラフであり、横軸が半径を表す。下段のグラフはベッチ数の系列から生成されるグラフであり、縦軸はベッチ数を表し、横軸は時間を表す。上で述べたように、ベッチ数は穴の数を表しており、例えば上段のグラフにおいて破線に対応する半径の時には存在している穴の数が10であるので、下段のグラフにおいては破線に対応するベッチ数も10である。ベッチ数は、ブロック毎に計数される。なお、下段のグラフは疑似的な時系列データのグラフであるので、横軸の値自体が意味を持つわけではない。

[0043] 基本的には、同じバーコードデータからは同じ系列が得られる。すなわち

、元の点の集合が同じであれば同じ系列が得られる。但し、異なるバーコードから同じ系列が得られるケースが極めて稀に発生する。

[0044] 例えば図10に示すようなバーコードデータを考える。このバーコードデータは1以上の次元の穴に関するデータであるとする。図10(a)のケースにおいては、パーシステント区間p1が時刻t1で開始し、かつ、時刻t2で終了し、パーシステント区間p2が時刻t2で開始し、かつ、時刻t3で終了する。一方、図10(b)のケースにおいては、パーシステント区間p4が時刻t1で開始し、かつ、時刻t3で終了する。両ケースにおけるパーシステント区間p3は全く同じであるとする。

[0045] このような場合、両ケースにおけるバーコードデータからは全く同じ系列が得られるので、両ケースを区別することができない。しかし、このような現象が発生する可能性は極めて低い。また、両ケースの点の集合は元々似ており、機械学習による分類に与える影響が極めて小さいので、上記のような現象が発生しても問題は無い。

[0046] 従って、或るバーコードデータから生成されるベッチ数の系列と、別のバーコードデータから生成されるベッチ数の系列との類似関係は、上で述べた稀なケースが発生しなければ、バーコードデータ間の類似関係と等価である。以上から、データ間の距離の定義は変わるものの、バーコードデータから生成されるベッチ数の系列間の類似関係は、元の拡張アトラクタ間の類似関係とほぼ等価である。

[0047] 図6の説明に戻り、第1生成部103は、 α の値のうち未処理の値が有るか判定する(ステップS49)。未処理の値が有る場合(ステップS49: Yesルート)、ステップS41の処理に戻る。未処理の値が無い場合(ステップS49: Noルート)、処理は呼び出し元に戻る。

[0048] 以上のように、パーシステントホモロジ処理を実行すれば、拡張アトラクタにおける点の位置関係を、バーコードデータに反映することができる。パーシステントホモロジ処理によって生成されたバーコードデータは、バーコードの本数が一定ではないため、そのままでは機械学習の入力とすることが

難しい。そこで本実施の形態においては、バーコードデータをベッチ数の系列に変換することで、機械学習の入力とすることを可能にしている。

[0049] また、上で述べたように、本実施の形態によればノイズの影響を取り除くことができる。

[0050] 図2の説明に戻り、第1生成部103は、ステップS9において生成された複数の拡張ベクトルを、 α の値の大きさの順に列方向に結合することで特徴画像を生成し（ステップS11）、生成した特徴画像を画像データ格納部105に格納する。そして処理は端子Aを介して図12のステップS13に移行する。

[0051] 図11は、特徴画像の一例を示す図である。正方形の図形はセルを表し、各セルには拡張ベクトルの要素であるベッチ数が格納される。1つの行が1つの拡張ベクトルに対応する。従って、図11の例においては、11個の拡張ベクトルが結合されており、特徴画像は11の行を有する行列に相当する。図11においては拡張ベクトルの要素の数が15であるが、数に限定は無い。

[0052] 図12の説明に移行し、機械学習部107は、ステップS11において生成された特徴画像に対して、CNN (Convolutional Neural Network) を用いた機械学習を実行する（ステップS13）。ここでは、機械学習部107は、特徴画像とそのラベルとに基づく機械学習を実行する。機械学習部107は、機械学習の結果（例えば更新後の重み行列等）を学習データ格納部109に格納する。

[0053] なお、説明を簡単にするため複数のデータセットのうち1つのデータセットについてステップS1乃至S13の処理が実行される例を示したが、実際には、複数のデータセットの各々について処理が実行される。そして、機械学習が十分に進んだことが確認されたうえで、ステップS17以降の処理が実行される。

[0054] 第2生成部111は、分類に関する複数のラベルのうち未処理のラベルを1つ特定する（ステップS17）。

[0055] 図13は、第1の実施の形態におけるCNNの一例を示す模式図である。

第1の実施の形態の機械学習においては、ステップS11において生成された特徴画像を入力として、畳み込み等の演算が実行される。最終特徴層と識別層との間は全結合である。図13の例においてはラベルの数は2であるが、ラベルの数が3以上であってもよい。

[0056] 第2生成部111は、ステップS17において特定したラベルについて、最終特徴層と識別層との間の重み行列の要素を、学習データ格納部109から読み出す。そして、第2生成部111は、読み出した要素の絶対値を算出する（ステップS19）。

[0057] 図14は、ラベルと重み行列との関係を説明するための図である。CNNにおいては、最終特徴層における各ユニットの各セルの値に重み行列 W_n における重みが乗じられるので、ステップS19においては各セルについての重みが読み出される。なお、重みの絶対値は活性度とも呼ばれる。

[0058] 第2生成部111は、最終特徴層と識別層との間の各重み行列の各行について、ステップS19において算出した絶対値の統計量（例えば、平均値又は最大値）を算出する（ステップS21）。

[0059] 図15は、活性度の統計量の算出について説明するための図である。最終特徴層の各ユニットの画像データは、ステップS11において生成された特徴画像を圧縮した画像データに相当するので、縦軸は寄与パラメータ α に対応している。後述のように、本実施の形態においては寄与パラメータ α と関連度との関係に基づき複数の時系列データの相関関係が特定されるので、図15に示すように、 α の各値について統計量が算出される。従って、例えば最終特徴層のユニット数が2であれば、2つの重み行列それぞれの各行について、ステップS19において算出された絶対値の統計量が算出される。すなわち、最終特徴層の各ユニットについてベクトルが生成される。

[0060] 第2生成部111は、最終特徴層のベクトルについて、ユニット間で要素の値の統計量（例えば、平均、総和又は最大値）を行毎に算出する。そして、第2生成部111は、算出した統計量を要素とするベクトルを生成する（

ステップS 2 3)。第 1 の実施の形態においては、ステップS 2 3において生成されたベクトルの各要素の値を関連度として取り扱う。関連度とは、対象の分類に対してセルが及ぼす影響の度合いを表す値である。

[0061] 図 1 6 は、関連度のベクトルの生成について説明するための図である。ステップS 2 1 の処理の結果として生成されたベクトルの要素数（すなわち行数）はユニット間で同一である。従って、ステップS 2 3においては、値の統計量が行毎に関連度として算出され、関連度のベクトルが 1 つ生成される。

[0062] 第 2 生成部 1 1 1 は、ステップS 2 3において生成した関連度のベクトルの要素の最大値、最小値、並びに最大値および最小値の位置（例えば要素番号）を特定する（ステップS 2 5）。第 2 生成部 1 1 1 は、関連度のベクトルと、特定した最大値、最小値、並びに最大値および最小値の位置とを関連度格納部 1 1 3 に格納する。処理は端子 B を介して図 1 7 のステップS 2 7 に移行する。

[0063] 図 1 7 の説明に移行し、判定部 1 1 5 は、関連度格納部 1 1 3 に格納されている情報を読み出す。そして、判定部 1 1 5 は、最小値に対する最大値の割合が所定値以下であるか判定する（図 1 7 : ステップS 2 7）。所定値とは、例えば 1 . 2 である。最小値に対する最大値の割合が所定値以下であることは、最大値と最小値との差が比較的小さいことを意味する。

[0064] 最小値に対する最大値の割合が所定値以下である場合（ステップS 2 7 : Y e s ルート）、判定部 1 1 5 は、以下の処理を実行する。具体的には、判定部 1 1 5 は、ステップS 1 7 において特定されたラベルについての分類に両方の時系列データが独立して影響することを示す第 1 の関係データを生成し（ステップS 2 8）、第 1 の関係データを判定結果格納部 1 1 7 に格納する。そして処理はステップS 3 7 に移行する。

[0065] 図 1 8 は、第 1 の関係データについてのパターンを示す図である。図 1 8 において、縦軸は関連度を表し、横軸は寄与パラメータ α を表す。最小値に対する最大値の割合が所定値以下である場合には、 α の値が比較的小さいと

き（すなわち、一方の時系列データの値に乘じられる寄与パラメータの値が比較的大きい場合）と、 α の値が比較的大きいとき（すなわち、他方の時系列データの値に乘じられる寄与パラメータの値が比較的大きい場合）とで、関連度が同程度になる。このような場合には、対象のラベルについての分類に両方の時系列データが影響を及ぼしていると考えられる。そして、 α の値の大きさが中程度であるとき（仮に α の範囲が $0 \leq \alpha \leq 1$ であれば、 α が約0.5であるとき）の関連度も両端の関連度と同程度であるので、時系列データの間に時間相関が無いと考えられる。

[0066] 一方、最小値に対する最大値の割合が所定値以下ではない場合（ステップS27：Noルート）、判定部115は、以下の処理を実行する。具体的には、判定部115は、最大値および最小値が関連度のベクトルの端に位置するか判定する（ステップS29）。

[0067] 最大値および最小値が関連度のベクトルの端に位置する場合（ステップS29：Yesルート）、判定部115は、以下の処理を実行する。具体的には、判定部115は、ステップS17において特定されたラベルについての分類に最大値側の時系列データが影響することを示す第2の関係データを生成し（ステップS30）、第2の関係データを判定結果格納部117に格納する。そして処理はステップS37に移行する。

[0068] 図19（a）及び図19（b）は、第2の関係データについてのパターンを示す図である。図19（a）及び図19（b）において、縦軸は関連度を表し、横軸は寄与パラメータ α を表す。最大値および最小値が関連度のベクトルの端に位置する場合、関連度と寄与パラメータ α との関係はおおよそ図19（a）又は図19（b）に示すような関係である。このような場合には、対象のラベルについての分類には、関連度の最大値側の時系列データが影響すると考えられる。そして、時系列データ間の時間相関は無いと考えられる。

[0069] 一方、最大値および最小値の少なくともいずれかが関連度のベクトルの端に位置しない場合（ステップS29：Noルート）、判定部115は、以下

の処理を実行する。具体的には、判定部 115 は、最大値が関連度のベクトルの中央に位置するか判定する（ステップ S 31）。

[0070] 最大値が関連度のベクトルの中央に位置する場合（ステップ S 31 : Yes ルート）、判定部 115 は、以下の処理を実行する。具体的には、判定部 115 は、ステップ S 17 において特定されたラベルについての分類に両方の時系列データが影響し、かつ、時系列データ間に相関関係があることを示す第 3 の関係データを生成し（ステップ S 32）、第 3 の関係データを判定結果格納部 117 に格納する。そして処理はステップ S 37 に移行する。

[0071] 図 20 (a) は、第 3 の関係データについてのパターンを示す図である。図 20 (a) において、縦軸は関連度を表し、横軸は寄与パラメータ α を表す。最大値が関連度のベクトルの中央に位置する場合、両端の関連度の値が比較的小さくなると考えられ、その場合には対象のラベルについての分類に対して単独の時系列データが影響することはない。そして、最大値が関連度のベクトルの中央に位置することから、時系列データ間に時間相関があると考えられる。

[0072] 一方、最大値が関連度のベクトルの中央に位置しない場合（ステップ S 31 : No ルート）、判定部 115 は、以下の処理を実行する。具体的には、判定部 115 は、最小値が関連度のベクトルの中央に位置するか判定する（ステップ S 33）。

[0073] 最小値が関連度のベクトルの中央に位置する場合（ステップ S 33 : Yes ルート）、判定部 115 は、以下の処理を実行する。具体的には、判定部 115 は、ステップ S 17 において特定されたラベルについての分類に両方の時系列データが影響し、かつ、時系列データ間に相関関係が無いことを示す第 4 の関係データを生成し（ステップ S 35）、第 4 の関係データを判定結果格納部 117 に格納する。一方、最小値が関連度のベクトルの中央に位置しない場合（ステップ S 33 : No ルート）、処理はステップ S 37 に移行する。

[0074] 図 20 (b) は、第 4 の関係データについてのパターンを示す図である。

図 20 (b) において、縦軸は関連度を表し、横軸は寄与パラメータ α を表す。最小値が関連度のベクトルの中央に位置する場合、両端の関連度の値が比較的大きくなると考えられ、その場合には対象のラベルについての分類に対して時系列データ単独で影響する。そして、最小値が関連度のベクトルの中央に位置することから、時系列データ間に時間相関が無いと考えられる。

[0075] 第 2 生成部 111 は、未処理のラベルが有るか判定する（ステップ S 37）。未処理のラベルが有る場合（ステップ S 37：Yes ルート）、処理は端子 C を介して図 12 のステップ S 17 に戻る。一方、未処理のラベルが無い場合（ステップ S 37：No ルート）、処理は終了する。なお、判定結果格納部 117 に格納された関係データは表示装置に表示され又は他の端末等に送信され、ユーザにより確認される。

[0076] 以上のように、本実施の形態によれば、複数の時系列データそれぞれの特徴が反映された特徴画像が生成されるようになる。複数の時系列データそのものを機械学習の入力とすることは難しいが、本実施の形態の方法により生成された特徴画像は機械学習に適している。また、特徴画像の生成過程においてノイズが取り除かれるため、機械学習の精度を高めることが可能である。

[0077] 以下では、時系列データ間の相関関係の特定について、図 21 乃至図 29 に示した具体例を用いて説明を追加する。

[0078] 図 21 乃至図 28 の上段には 1 つ目の時系列データ（図 21 乃至図 28 における「第 1 軸」の時系列データ）が示されており、図 21 乃至図 28 の下段には 2 つ目の時系列データ（図 21 乃至図 28 における「第 2 軸」の時系列データ）が示されている。線種が同じである時系列データは同じデータセットに含まれる。例えば、図 21 の第 1 軸の太線の時系列データは、図 21 の第 2 軸の太線の時系列データと同じデータセットに含まれる。

[0079] まず、図 21、図 22 及び図 29 (a) を用いて、第 1 の例について説明する。第 1 の例においては、第 1 軸の時系列データと第 2 軸の時系列データとの組合せが図 21 に示した組み合わせである場合にラベル 1 が付与され、

第1軸の時系列データと第2軸の時系列データとの組合せが図22に示した組み合わせである場合にラベル2が付与される。

[0080] より具体的には、図21に示すように、第1軸の全時系列データの振幅は約1であり、第2軸の時系列データの振幅はランダムに与えられている。第1軸の時系列データの位相及び第2軸の時系列データの位相はランダムに与えられている。

[0081] また、図22に示すように、第1軸の全時系列データの振幅は約0.5であり、第2軸の時系列データの振幅はランダムに与えられている。第1軸の時系列データの位相及び第2軸の時系列データの位相はランダムに与えられている。

[0082] 図21及び図22に示した複数のデータセットについて本実施の形態の処理を実行することで算出された関連度のベクトルを図29(a)に示す。図29(a)に示した例においては、最小値(0.075)に対する最大値(0.138)の割合が所定値(ここでは1.2)より大きく、 α の値が最も小さい場合に関連度の最大値が出現し、かつ、 α の値が最も大きい場合に関連度の最小値が出現している。このパターンは図19(a)に示したパターンに相当するので、最大値側の時系列データである第1軸の時系列データのみが分類に影響を及ぼす(すなわち、第2軸の時系列データは分類に無関係)ことがわかる。

[0083] 図23、図24及び図29(b)を用いて、第2の例について説明する。第2の例においては、第1軸の時系列データと第2軸の時系列データとの組合せが図23に示した組み合わせである場合にラベル1が付与され、第1軸の時系列データと第2軸の時系列データとの組合せが図24に示した組み合わせである場合にラベル2が付与される。

[0084] より具体的には、図23に示すように、各データセットについて、第1軸の時系列データの振幅は約1であり、かつ、第2軸の時系列データの振幅は約0.5である。第1軸の時系列データの位相及び第2軸の時系列データの位相はランダムに与えられている。

- [0085] また、図 2 4 に示すように、各データセットにおいて、第 1 軸の時系列データの振幅は約 0.5 であり、かつ、第 2 軸の時系列データの振幅は約 1 である。第 1 軸の時系列データの位相及び第 2 軸の時系列データの位相はランダムに与えられている。
- [0086] 図 2 3 及び図 2 4 に示した複数のデータセットについて本実施の形態の処理を実行することで算出された関連度のベクトルを図 2 9 (b) に示す。図 2 9 (b) に示した例においては、関連度の最大値は 0.105 であり、関連度の最小値は 0.091 である。最小値に対する最大値の割合が所定値（ここでは 1.2）以下であるので、このパターンは図 1 8 に示したパターンに相当する。つまり、第 1 軸の時系列データおよび第 2 軸の時系列データの両方が分類に影響を及ぼすことがわかる。この場合、少なくともいずれかの時系列データによって分類をすることが可能である。
- [0087] 図 2 5、図 2 6 及び図 2 9 (c) を用いて、第 3 の例について説明する。第 3 の例においては、第 1 軸の時系列データと第 2 軸の時系列データとの組合せが図 2 5 に示した組み合わせである場合にラベル 1 が付与され、第 1 軸の時系列データと第 2 軸の時系列データとの組合せが図 2 6 に示した組み合わせである場合にラベル 2 が付与される。
- [0088] より具体的には、図 2 5 に示すように、各データセットについて、第 1 軸の時系列データの振幅と第 2 軸の時系列データの振幅との両方が約 1 であるか、又は、第 1 軸の時系列データの振幅と第 2 軸の時系列データの振幅との両方が約 0.5 である。第 1 軸の時系列データの位相及び第 2 軸の時系列データの位相はランダムに与えられている。
- [0089] また、図 2 6 に示すように、各データセットについて、第 1 軸の時系列データの振幅が約 1 であり、かつ、第 2 軸の時系列データの振幅が約 0.5 であるか、又は、第 1 軸の時系列データの振幅が約 0.5 であり、かつ、第 2 軸の時系列データの振幅が約 1 である。第 1 軸の時系列データの位相及び第 2 軸の時系列データの位相はランダムに与えられている。
- [0090] 図 2 5 及び図 2 6 に示した複数のデータセットについて本実施の形態の処

理を実行することで算出された関連度のベクトルを図 29 (c) に示す。図 29 (c) に示した例においては、関連度の最大値は 0.074 であり、関連度の最小値は 0.055 である。最小値に対する最大値の割合が所定値（ここでは 1.2）より大きく、かつ、最小値が中央のセルに近いセルに位置するので、このパターンは図 20 (b) に示したパターンに相当する可能性がある。つまり、第 1 軸の時系列データおよび第 2 軸の時系列データの両方が分類に影響を及ぼす（すなわち、両方の時系列データが必要である）が両者は時間相関を有しないと考えられる。

[0091] 図 27、図 28 及び図 29 (d) を用いて、第 4 の例について説明する。第 4 の例においては、第 1 軸の時系列データと第 2 軸の時系列データとの組合せが図 27 に示した組み合わせである場合にラベル 1 が付与され、第 1 軸の時系列データと第 2 軸の時系列データとの組合せが図 28 に示した組み合わせである場合にラベル 2 が付与される。

[0092] より具体的には、図 27 に示すように、各データセットについて、第 1 軸の時系列データの振幅と第 2 軸の時系列データの振幅との両方が約 1 であり、第 1 軸の時系列データの位相と第 2 軸の時系列データの位相とが同じである。

[0093] また、図 28 に示すように、各データセットについて、第 1 軸の時系列データの振幅と第 2 軸の時系列データの振幅との両方が約 1 であり、第 2 軸の時系列データの位相は第 1 軸の時系列データの位相と半位相分ずれている。

[0094] 図 27 及び図 28 に示した複数のデータセットについて本実施の形態の処理を実行することで算出した関連度のベクトルを図 29 (d) に示す。図 29 (d) に示した例においては、関連度の最大値は 0.320 であり、関連度の最小値は 0.118 である。最小値に対する最大値の割合が所定値（ここでは 1.2）より大きく、かつ、最大値が中央のセルに位置するので、このパターンは図 20 (a) に示したパターンに相当する。つまり、第 1 軸の時系列データおよび第 2 軸の時系列データの両方が分類に影響を及ぼし（すなわち、両方の時系列データが必要であり）、かつ、両者は時間相関を有

することがわかる。

[0095] 以上のように、本実施の形態によれば、対象のラベルについて複数の時系列データの相関関係を特定することができるようになる。例えば、2つの時系列データのうち一方のみが分類に影響することが判明した場合、他方の時系列データを値の取得および解析の対象から外すことができるので、分類への悪影響を回避できるとともに、データの取得および解析に要する時間およびコストを短縮することができる。また、例えば、2つの時系列データのうちいずれか一方の時系列データのみで分類が可能である場合、データの取得の容易さ等の観点から時系列データを選択することができるので、データの取得にかかる時間及びコストを減らすことができるようになる。また、解析に要する時間およびコストも削減することができるようになる。また、例えば、2つの時系列データの両方が必要であることが判明した場合、時間軸を揃えて2つの時系列データを取得すべきであるか否かを事前に把握できるので、センサ等の設定を誤ってしまうことを防ぐことができる。

[0096] また、第1の実施の形態においてはCNNを用いた機械学習が利用され、特徴画像におけるセル間の関係が考慮されるため、以下で説明する他の実施形態と比較して学習の精度を高めることができるようになる。

[0097] [実施の形態2]

第1の実施の形態においては特徴画像に対してCNNを用いた機械学習が実行されるが、機械学習の方法はCNNには限られない。以下では、図30及び図31を用いて、特徴画像を直接学習させる方法について説明する。なお、第2の実施の形態の処理において第1の実施の形態の処理と異なる部分は端子A以降の処理であるので、端子A以降の処理のみ以下で説明する。第2の実施の形態における機械学習を、単層の学習モデルを用いた機械学習と呼ぶ。

[0098] まず、機械学習部107は、ステップS11において生成された特徴画像に対して、単層の学習モデルを用いた機械学習を実行する（図30：ステップS51）。機械学習部107は、機械学習の結果（例えば更新後の重み行

列等)を学習データ格納部109に格納する。

[0099] 図31は、第2の実施の形態における学習モデルの一例を示す図である。第2の実施の形態においては、特徴画像における各セルの値そのものに対する機械学習が実行される。各セルの値には識別層への重みが乗じられる。

[0100] ステップS53以降の処理は、複数のデータセットの各々についてステップS51の処理が実行され、かつ、機械学習が十分に進んだことが確認された後に実行される。

[0101] 第2生成部111は、分類に関する複数のラベルのうち未処理のラベルを1つ特定する(ステップS53)。

[0102] 第2生成部111は、ステップS53において特定したラベルについて、特徴画像における各セルについての重みを学習データ格納部109から抽出する(ステップS55)。

[0103] 第2生成部111は、特徴画像における各セルについて、分散を算出する(ステップS57)。複数のデータセットについてステップS11までの処理が実行されれば複数の特徴画像が生成されるので、各セルについて、複数の値から分散が算出される。

[0104] 第2生成部111は、特徴画像における各セルについて、算出した分散と抽出した重みの絶対値とに基づき関連度を算出する(ステップS59)。例えば、セル(x, y)の分散を $v_{x,y}$ とし、かつ、重みの絶対値を $w_{x,y}$ とすると、第2生成部111は、セル(x, y)の関連度を $v_{x,y} * w_{x,y}$ として算出する。

[0105] 第2生成部111は、各行について関連度の統計量(例えば、平均又は最大値)を算出することで関連度のベクトルを生成し(ステップS61)、生成したベクトルを関連度格納部113に格納する。そして処理は端子Bを介して図17のステップS27に移行する。

[0106] 以上のような処理を実行すれば、例えばCNNを実行することが適切ではない場合においても、複数の時系列データの相関を特定することができるようになる。

[0107] [実施の形態3]

第3の実施の形態においては拡張ベクトルから生成されたデータに対して SVM (Support Vector Machine) を用いた機械学習が実行される。

[0108] 図32は、第3の実施の形態の情報処理装置1の機能ブロック図である。情報処理装置1は、時系列データ格納部101と、第1生成部103と、ベクトルデータ格納部119と、機械学習部107と、学習データ格納部109と、第2生成部111と、関連度格納部113と、判定部115と、判定結果格納部117とを含む。

[0109] 第1生成部103、機械学習部107、第2生成部111および判定部115は、例えば、図40に示したメモリ2501にロードされたプログラムが図40に示したCPU2503により実行されることで実現される。時系列データ格納部101、ベクトルデータ格納部119、学習データ格納部109、関連度格納部113および判定結果格納部117は、例えば、図40に示したHDD2505又はメモリ2501に設けられる。

[0110] 第1生成部103は、時系列データ格納部101に格納されているデータに基づき処理を実行し、処理結果をベクトルデータ格納部119に格納する。機械学習部107は、ベクトルデータ格納部119に格納されているデータに基づき処理を実行し、処理結果を学習データ格納部109に格納する。第2生成部111は、学習データ格納部109に格納されているデータに基づき処理を実行し、処理結果を関連度格納部113に格納する。判定部115は、関連度格納部113に格納されているデータに基づき処理を実行し、処理結果を判定結果格納部117に格納する。

[0111] 図33は、第3の実施の形態の情報処理装置1が実行する処理の処理フローを示す図である。

[0112] 第1生成部103は、時系列データ格納部101に格納されている複数のデータセットのうち1つのデータセットを特定する。そして、第1生成部103は、特定したデータセットに含まれる複数の時系列データの各々を、値の平均が0になるように平行移動する(図33:ステップS71)。

- [0113] 第1生成部103は、ステップS71の処理が実行された全時系列データの振幅の幅が同じになるように正規化を実行する（ステップS73）。
- [0114] 第1生成部103は、 α の各値について、正規化された複数の時系列データから拡張アトラクタを生成する（ステップS77）。第1生成部103は、生成した拡張アトラクタをメモリ2501に格納する。拡張アトラクタの生成は、第1の実施の形態と同様である。
- [0115] 第1生成部103は、ステップS77において生成された拡張アトラクタを用いて、拡張ベクトル生成処理を実行する（ステップS79）。拡張ベクトル生成処理については、図6乃至図10を用いて説明したとおりであるので、ここでは説明を省略する。
- [0116] 第1生成部103は、ステップS79において生成された複数の拡張ベクトルを、 α の値の大きさの順に行方向に結合することで入力ベクトルを生成し（ステップS81）、生成した入力ベクトルをベクトルデータ格納部119に格納する。そして処理は端子Dを介して図35のステップS83に移行する。
- [0117] 図34は、入力ベクトルの一例を示す図である。正方形の図形はベクトルの要素を表し、各要素にはベッチ数が格納される。図34の例では7つの要素を有するベクトルが1つの拡張ベクトルに対応する。このような拡張ベクトルが連結されることで、1つの入力ベクトルが生成される。
- [0118] 図35の説明に移行し、機械学習部107は、ステップS81において生成された入力ベクトルに対して、SVMを用いた機械学習を実行する（ステップS83）。機械学習部107は、機械学習の結果を学習データ格納部109に格納する。
- [0119] なお、説明を簡単にするため複数のデータセットのうち1つのデータセットについてステップS71乃至S83の処理が実行される例を示したが、実際には、複数のデータセットの各々について処理が実行される。そして、機械学習が十分に進んだことが確認されたうえで、ステップS85以降の処理が実行される。

- [0120] 第2生成部111は、入力ベクトルの各要素について、値の平均値および分散を算出する（ステップS85）。複数のデータセットについてステップS83までの処理が実行されれば複数の入力ベクトルが生成されるので、各要素について、値の平均および分散が算出される。
- [0121] 第2生成部111は、ステップS85において算出した平均値を各要素の値とするベクトルを生成する。そして、第2生成部111は、SVMを用いた機械学習の結果を用いて、生成したベクトルの分類スコアを基準分類スコアとして算出する（ステップS87）。
- [0122] 第2生成部111は、ステップS87において生成したベクトルの各要素について、当該要素のみ値を（平均＋分散）又は（平均－分散）に変更した場合の分類スコアを、SVMを用いた機械学習の結果を用いて算出する（ステップS89）。
- [0123] 第2生成部111は、各要素の関連度を、ステップS89において算出した分類スコアと基準分類スコアとの差として算出し（ステップS91）、関連度格納部113に格納する。そして処理は端子Eを介して図36のステップS93に移行する。
- [0124] 図36の説明に移行し、判定部115は、関連度格納部113に格納されている情報を読み出す。そして、判定部115は、最小値に対する最大値の割合が所定値以下であるか判定する（図36：ステップS93）。所定値とは、例えば1.2である。最小値に対する最大値の割合が所定値以下であることは、最大値と最小値との差が比較的小さいことを意味する。
- [0125] 最小値に対する最大値の割合が所定値以下である場合（ステップS93：Yesルート）、判定部115は、以下の処理を実行する。具体的には、判定部115は、両方の時系列データが分類に独立して影響することを示す第1の関係データを生成し（ステップS95）、第1の関係データを判定結果格納部117に格納する。そして処理は終了する。
- [0126] 一方、最小値に対する最大値の割合が所定値以下ではない場合（ステップS93：Noルート）、判定部115は、以下の処理を実行する。具体的に

は、判定部 115 は、最大値および最小値が関連度のベクトルの端に位置するか判定する（ステップ S 97）。

[0127] 最大値および最小値が関連度のベクトルの端に位置する場合（ステップ S 97 : Yes ルート）、判定部 115 は、以下の処理を実行する。具体的には、判定部 115 は、最大値側の時系列データが分類に影響することを示す第 2 の関係データを生成し（ステップ S 99）、第 2 の関係データを判定結果格納部 117 に格納する。そして処理は終了する。

[0128] 一方、最大値および最小値の少なくともいずれかが関連度のベクトルの端に位置しない場合（ステップ S 97 : No ルート）、判定部 115 は、以下の処理を実行する。具体的には、判定部 115 は、最大値が関連度のベクトルの中央に位置するか判定する（ステップ S 101）。

[0129] 最大値が関連度のベクトルの中央に位置する場合（ステップ S 101 : Yes ルート）、判定部 115 は、以下の処理を実行する。具体的には、判定部 115 は、分類に両方の時系列データが影響し、かつ、時系列データ間に相関関係があることを示す第 3 の関係データを生成し（ステップ S 103）、第 3 の関係データを判定結果格納部 117 に格納する。そして処理は終了する。

[0130] 一方、最大値が関連度のベクトルの中央に位置しない場合（ステップ S 101 : No ルート）、判定部 115 は、以下の処理を実行する。具体的には、判定部 115 は、最小値が関連度のベクトルの中央に位置するか判定する（ステップ S 105）。

[0131] 最小値が関連度のベクトルの中央に位置する場合（ステップ S 105 : Yes ルート）、判定部 115 は、以下の処理を実行する。具体的には、判定部 115 は、分類に両方の時系列データが影響し、かつ、時系列データ間に相関関係が無いことを示す第 4 の関係データを生成し（ステップ S 107）、第 4 の関係データを判定結果格納部 117 に格納する。そして処理は終了する。また、最小値が関連度のベクトルの中央に位置しない場合（ステップ S 105 : No ルート）、処理は終了する。なお、判定結果格納部 117 に

格納された関係データは表示装置に表示され又は他の端末等に送信され、ユーザにより確認される。

[0132] 以上のように、SVMを用いた機械学習により、汎化性能を高めつつ、複数の時系列データの相関関係を特定することができるようになる。なお、説明を簡単にするためラベルとの関係が述べられていないが、第3の実施の形態においても、各ラベルについて処理が実行されてもよい。

[0133] [実施の形態4]

第1乃至第3の実施の形態においては機械学習の結果に基づき関連度が算出されるが、第4の実施の形態においては、機械学習以外の方法で関連度が算出される。

[0134] 図37は、第4の実施の形態の情報処理装置1の機能ブロック図である。情報処理装置1は、時系列データ格納部101と、第1生成部103と、第1データ格納部121と、データ処理部123と、第2データ格納部125と、第2生成部111と、関連度格納部113と、判定部115と、判定結果格納部117とを含む。

[0135] 第1生成部103、データ処理部123、第2生成部111および判定部115は、例えば、図40に示したメモリ2501にロードされたプログラムが図40に示したCPU2503により実行されることで実現される。時系列データ格納部101、第1データ格納部121、第2データ格納部125、関連度格納部113および判定結果格納部117は、例えば、図40に示したHDD2505又はメモリ2501に設けられる。

[0136] 第1生成部103は、時系列データ格納部101に格納されているデータに基づき処理を実行し、処理結果を第1データ格納部121に格納する。データ処理部123は、第1データ格納部121に格納されているデータに基づき処理を実行し、処理結果を第2データ格納部125に格納する。第2生成部111は、第2データ格納部125に格納されているデータに基づき処理を実行し、処理結果を関連度格納部113に格納する。判定部115は、関連度格納部113に格納されているデータに基づき処理を実行し、処理結

果を判定結果格納部 117 に格納する。

[0137] 図 38 は、第 4 の実施の形態の情報処理装置 1 が実行する処理の処理フローを示す図である。ここでは、ラベルが 2 つであることを前提として処理を説明する。

[0138] 第 1 生成部 103 は、時系列データ格納部 101 に格納されている複数のデータセットのうち 1 つのデータセットを特定する。そして、第 1 生成部 103 は、特定したデータセットに含まれる複数の時系列データの各々を、値の平均が 0 になるように平行移動する（図 38：ステップ S111）。

[0139] 第 1 生成部 103 は、ステップ S111 の処理が実行された全時系列データの振幅の幅が同じになるように正規化を実行する（ステップ S113）。

[0140] 第 1 生成部 103 は、 α の各値について、正規化された複数の時系列データから拡張アトラクタを生成する（ステップ S117）。第 1 生成部 103 は、生成した拡張アトラクタをメモリ 2501 に格納する。拡張アトラクタの生成は、第 1 の実施の形態と同様である。

[0141] 第 1 生成部 103 は、ステップ S117 において生成された拡張アトラクタを用いて、拡張ベクトル生成処理を実行する（ステップ S119）。拡張ベクトル生成処理については、図 6 乃至図 10 を用いて説明したとおりであるので、ここでは説明を省略する。

[0142] なお、説明を簡単にするため複数のデータセットのうち 1 つのデータセットについてステップ S111 乃至 S119 の処理が実行される例を示したが、実際には、複数のデータセットの各々について処理が実行されて複数の拡張ベクトルが生成される。

[0143] そして、データ処理部 123 は、ステップ S119 の処理によって第 1 データ格納部 121 に格納された複数の拡張ベクトルのうちラベル 1 の分類に属する拡張ベクトルの各要素の平均および分散を算出する（ステップ S121）。

[0144] データ処理部 123 は、ステップ S119 の処理によって第 1 データ格納部 121 に格納された複数の拡張ベクトルのうちラベル 2 の分類に属する拡

張ベクトルの各要素の平均および分散を算出する（ステップS 1 2 3）。

[0145] データ処理部 1 2 3 は、各要素について、ラベル 1 についての分布とラベル 2 についての分布とを正規分布と仮定して 2 つの正規分布が重なる部分の面積 S を算出する（ステップS 1 2 5）。データ処理部 1 2 3 は、各要素についての面積 S を第 2 データ格納部 1 2 5 に格納する。ステップS 1 2 5 においては、例えば図 3 9 に示すような 2 つの正規分布について、重なっている部分（ハッチされた部分）である面積 S が各要素について算出される。なお、図 3 9 において横軸は確率変数を表し、縦軸は確率密度を表す。

[0146] 第 2 生成部 1 1 1 は、ラベル 1 に関する関連度を $(1 - S)$ として算出し（ステップS 1 2 7）、ラベル 1 に関する関連度を関連度格納部 1 1 3 に格納する。なお、ラベル 2 に関する関連度も、同様に $(1 - S)$ として算出され、関連度格納部 1 1 3 に格納される。ラベルの数が 3 以上である場合には、ラベル 1 に関する関連度は、他のラベルに対する関連度の平均値として算出される。例えばラベルの数が 3 である場合、ラベル 1 に関する関連度は、ラベル 2 に対する関連度とラベル 3 に対する関連度との平均値として算出される。

[0147] ステップS 1 2 7 の処理により、ラベル 1 及びラベル 2 について関連度のベクトルが生成される。以降、各ラベルについて図 3 6 に示した端子 E 以降の処理が実行される。

[0148] 以上のような処理を実行すれば、機械学習を実行しない場合においても、複数の時系列データの相関関係を特定することができるようになる。

[0149] 以上本発明の一実施の形態を説明したが、本発明はこれに限定されるものではない。例えば、上で説明した情報処理装置 1 の機能ブロック構成は実際のプログラムモジュール構成に一致しない場合もある。

[0150] また、上で説明したデータ構成は一例であって、上記のような構成でなければならないわけではない。さらに、処理フローにおいても、処理結果が変わらなければ処理の順番を入れ替えることも可能である。さらに、並列に実行させるようにしても良い。

[0151] なお、上で述べた情報処理装置 1 は、コンピュータ装置であって、図 40 に示すように、メモリ 2501 と CPU 2503 と HDD 2505 と表示装置 2509 に接続される表示制御部 2507 とリムーバブル・ディスク 2511 用のドライブ装置 2513 と入力装置 2515 とネットワークに接続するための通信制御部 2517 とがバス 2519 で接続されている。オペレーティング・システム（OS：Operating System）及び本実施例における処理を実施するためのアプリケーション・プログラムは、HDD 2505 に格納されており、CPU 2503 により実行される際には HDD 2505 からメモリ 2501 に読み出される。CPU 2503 は、アプリケーション・プログラムの処理内容に応じて表示制御部 2507、通信制御部 2517、ドライブ装置 2513 を制御して、所定の動作を行わせる。また、処理途中のデータについては、主としてメモリ 2501 に格納されるが、HDD 2505 に格納されるようにしてもよい。本発明の実施例では、上で述べた処理を実施するためのアプリケーション・プログラムはコンピュータ読み取り可能なリムーバブル・ディスク 2511 に格納されて頒布され、ドライブ装置 2513 から HDD 2505 にインストールされる。インターネットなどのネットワーク及び通信制御部 2517 を経由して、HDD 2505 にインストールされる場合もある。このようなコンピュータ装置は、上で述べた CPU 2503、メモリ 2501 などのハードウェアと OS 及びアプリケーション・プログラムなどのプログラムとが有機的に協働することにより、上で述べたような各種機能を実現する。

[0152] 以上述べた本発明の実施の形態をまとめると、以下のようになる。

[0153] 本実施の形態の第 1 の態様に係るデータ生成方法は、（A）複数の時系列データと、複数の時系列データそれぞれの寄与率とにより生成される座標で表された点の集合に対するパーシステントホモロジ処理により、寄与率に対応したベッチ数系列を生成し、（B）複数の寄与率に対してそれぞれ生成された複数のベッチ数系列から特徴画像を生成し、（C）特徴画像と、複数の時系列データに対応した分類とを対応付けた機械学習データを生成する処理

を含む。

[0154] 複数の時系列データに対する機械学習に適した特徴情報を生成できるようになる。

[0155] また、本データ生成方法は、(D) 生成された機械学習データに基づき、複数の分類のうち特定の分類への影響の度合いを表す関連度と寄与率との関係についての第1のデータを生成し、(E) 第1のデータに基づき、特定の分類に関して、複数の時系列データの相関関係についての第2のデータを生成する処理をさらに含んでもよい。

[0156] 特定の分類に関して複数の時系列データの相関関係を特定することができるようになる。

[0157] また、機械学習データは、畳み込みニューラルネットワークに基づく機械学習データであってもよい。そして、第1のデータを生成する処理において、(d1) 機械学習データに含まれる、最終特徴層と識別層との間の重み行列の要素の絶対値に基づき、特定の分類に対する関連度を複数の寄与率の値それぞれについて算出してもよい。

[0158] 畳み込みニューラルネットワークに基づく機械学習は、他の機械学習と比較して、特徴画像に含まれる画素間の位置関係が考慮されるので、機械学習の分類性能を向上させることができるようになる。また、最終特徴層と識別層との間の重み行列は識別層における各分類に直接影響するので、上で述べた処理を実行すれば、識別層における特定の分類に対する関連度を適切に算出できるようになる。

[0159] また、機械学習データは、単層の学習モデルに基づく機械学習データであってもよい。

[0160] 第1のデータに対して直接学習を実行できるようになる。

[0161] また、第2のデータを生成する処理において、(e1) 第1のデータに含まれる関連度の最大値、最小値、並びに最大値及び最小値の位置に基づき、複数の時系列データの各々が独立して特定の分類に影響することを示す第1の関係データ、複数の時系列データのうちいずれかが特定の分類に影響する

ことを示す第2の関係データ、複数の時系列データの各々が特定の分類に影響し、かつ、複数の時系列データが時間相関を有することを示す第3の関係データ、又は複数の時系列データの各々が特定の分類に影響し、かつ、複数の時系列データが時間相関を有しないことを示す第4の関係データを生成してもよい。

[0162] また、第2のデータを生成する処理において、(e 1 1) 最小値に対する最大値の割合が所定値以下である場合に、第1の関係データを生成し、(e 1 2) 最大値及び最小値が第1のデータに含まれる関連度の列の端に位置する場合に、第2の関係データを生成し、(e 1 3) 最大値が第1のデータに含まれる関連度の列の中央に位置する場合に、第3の関係データを生成し、(e 1 4) 最小値が第1のデータに含まれる関連度の列の中央に位置する場合に、第4の関係データを生成してもよい。

[0163] また、複数の時系列データは正規化された複数の時系列データであってもよい。

[0164] 複数の時系列データを平等に取り扱うことができるようになる。

[0165] 本実施の形態の第2の態様に係るデータ生成装置は、(F) 複数の時系列データと、複数の時系列データそれぞれの寄与率とにより生成される座標で表された点の集合に対するパーシステントホモロジ処理により、寄与率に対応したベッチ数系列を生成し、複数の寄与率に対してそれぞれ生成された複数のベッチ数系列から特徴画像を生成する第1生成部（実施の形態における第1生成部103は、上記第1生成部の一例である）と、(G) 特徴画像と、複数の時系列データに対応した分類とを対応付けた機械学習データを生成する第2生成部（実施の形態における機械学習部107は、第2生成部の一例である）とを有する。

[0166] なお、上記方法による処理をプロセッサに行わせるためのプログラムを作成することができ、当該プログラムは、例えばフレキシブルディスク、CD-ROM、光磁気ディスク、半導体メモリ、ハードディスク等のコンピュータ読み取り可能な記憶媒体又は記憶装置に格納される。尚、中間的な処理結

果はメインメモリ等の記憶装置に一時保管される。

符号の説明

[0167]	1	情報処理装置	101	時系列データ格納部
	103	第1生成部	105	画像データ格納部
	107	機械学習部	109	学習データ格納部
	111	第2生成部	113	関連度格納部
	115	判定部	117	判定結果格納部
	119	ベクトルデータ格納部	121	第1データ格納部
	123	データ処理部	125	第2データ格納部

請求の範囲

- [請求項1] コンピュータに、
- 複数の時系列データと、前記複数の時系列データそれぞれの寄与率とにより生成される座標で表された点の集合に対するパーシステントホモロジ処理により、前記寄与率に対応したベッチ数系列を生成し、
- 複数の寄与率に対してそれぞれ生成された複数のベッチ数系列から特徴画像を生成し、
- 前記特徴画像と、前記複数の時系列データに対応した分類とを対応付けた機械学習データを生成する、
- 処理を実行させるデータ生成プログラム。
- [請求項2] 前記コンピュータに、
- 生成された前記機械学習データに基づき、複数の分類のうち特定の分類への影響の度合いを表す関連度と前記寄与率との関係についての第1のデータを生成し、
- 前記第1のデータに基づき、前記特定の分類に関して、前記複数の時系列データの相関関係についての第2のデータを生成する、
- 処理をさらに実行させる請求項1記載のデータ生成プログラム。
- [請求項3] 前記機械学習データは、畳み込みニューラルネットワークに基づく機械学習データであり、
- 前記第1のデータを生成する処理において、
- 前記機械学習データに含まれる、最終特徴層と識別層との間の重み行列の要素の絶対値に基づき、前記特定の分類に対する関連度を前記複数の寄与率の値それぞれについて算出する、
- 請求項2記載のデータ生成プログラム。
- [請求項4] 前記機械学習データは、単層の学習モデルに基づく機械学習データである、
- 請求項1記載のデータ生成プログラム。
- [請求項5] 前記第2のデータを生成する処理において、

前記第 1 のデータに含まれる関連度の最大値、最小値、並びに最大値及び最小値の位置に基づき、前記複数の時系列データの各々が独立して前記特定の分類に影響することを示す第 1 の関係データ、前記複数の時系列データのうちいずれかが前記特定の分類に影響することを示す第 2 の関係データ、前記複数の時系列データの各々が前記特定の分類に影響し、かつ、前記複数の時系列データが時間相関を有することを示す第 3 の関係データ、又は前記複数の時系列データの各々が前記特定の分類に影響し、かつ、前記複数の時系列データが時間相関を有しないことを示す第 4 の関係データを生成する、

請求項 2 記載のデータ生成プログラム。

[請求項 6]

前記第 2 のデータを生成する処理において、

前記最小値に対する前記最大値の割合が所定値以下である場合に、前記第 1 の関係データを生成し、

前記最大値及び前記最小値が前記第 1 のデータに含まれる関連度の列の端に位置する場合に、前記第 2 の関係データを生成し、

前記最大値が前記第 1 のデータに含まれる関連度の列の中央に位置する場合に、前記第 3 の関係データを生成し、

前記最小値が前記第 1 のデータに含まれる関連度の列の中央に位置する場合に、前記第 4 の関係データを生成する、

請求項 5 記載のデータ生成プログラム。

[請求項 7]

前記複数の時系列データは正規化された複数の時系列データである、

請求項 1 乃至 6 のいずれか 1 つ記載のデータ生成プログラム。

[請求項 8]

コンピュータが、

複数の時系列データと、前記複数の時系列データそれぞれの寄与率とにより生成される座標で表された点の集合に対するパーシステントホモロジ処理により、前記寄与率に対応したベッチ数系列を生成し、

複数の寄与率に対してそれぞれ生成された複数のベッチ数系列から

特徴画像を生成し、

前記特徴画像と、前記複数の時系列データに対応した分類とを対応付けた機械学習データを生成する、

処理を実行するデータ生成方法。


[請求項9]

複数の時系列データと、前記複数の時系列データそれぞれの寄与率とにより生成される座標で表された点の集合に対するパーシステントホモロジ処理により、前記寄与率に対応したベッチ数系列を生成し、複数の寄与率に対してそれぞれ生成された複数のベッチ数系列から特徴画像を生成する第1生成部と、


前記特徴画像と、前記複数の時系列データに対応した分類とを対応付けた機械学習データを生成する第2生成部と、

を有するデータ生成装置。


[図1]




[図2]



[図3]




[図4]




[図5]

α
0.0
0.1
0.2
0.3
0.4
$\vdots$
1.0

[図6]




[図7]




[図8]

次元	発生半径	消滅半径
1	0.10	0.12
1	0.11	0.14
1	0.12	0.13
1	0.12	0.15
⋮	⋮	⋮


[図9]




[図10]




[図11]




[図12]




[図13]




[図14]




[図15]




[図16]





[図17]




[図18]




[図19]




[図20]




[図21]




[図22]





[図23]





[図24]





[図25]




[図26]




[図27]




[図28]




[図29]




[図30]




[図31]



[図32]




[図33]




[図34]




[図35]




[図36]




[図37]




[図38]



[図39]



[図40]



INTERNATIONAL SEARCH REPORT

International application No.

PCT/JP2018/007041

A. CLASSIFICATION OF SUBJECT MATTER

Int.Cl. G06N99/00 (2010.01)i, G06T7/00 (2017.01)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)

Int.Cl. G06N3/00-99/00, G06T7/00, G06F17/16-17/18, G06F17/30, G06F19/00

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 1971-2018

Registered utility model specifications of Japan 1996-2018

Published registered utility model applications of Japan 1994-2018

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.
A	US 9430688 B1 (THE BOEING COMPANY) 30 August 2016, entire text, all drawings (Family: none)	1-9
A	梅田裕平, データの形が教えてくれることトポロジカル・データ・アナリシスとその応用一, 情報処理, 15 October 2016, vol. 57, no. 11, pp. 1122-1127, ISSN 0447-8053, (UMEDA, Yuhei, "What the Shape of Data Tells - Topological Data Analysis and Its Application -", Information Processing Society of Japan)	1-9
P, A	JP 2017-97643 A (FUJITSU LTD.) 01 June 2017, entire text, all drawings & US 2017/0147946 A1, entire text, all drawings	1-9

☐ Further documents are listed in the continuation of Box C.	☐ See patent family annex.
---	---

* Special categories of cited documents:	"I" 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
"A" document defining the general state of the art which is not considered to be of particular relevance	"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
"E" earlier application or patent but published on or after the international filing date	"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
"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)	"&" document member of the same patent family
"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	

Date of the actual completion of the international search 02 May 2018 (02.05.2018)	Date of mailing of the international search report 22 May 2018 (22.05.2018)
Name and mailing address of the ISA/ Japan Patent Office 3-4-3, Kasumigaseki, Chiyoda-ku, Tokyo 100-8915, Japan	Authorized officer Telephone No.

A. 発明の属する分野の分類（国際特許分類（IPC））

Int.Cl. G06N99/00(2010.01)i, G06T7/00(2017.01)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（IPC））

Int.Cl. G06N3/00-99/00, G06T7/00, G06F17/16-17/18, 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	1971-2018年
日本国実用新案登録公報	1996-2018年
日本国登録実用新案公報	1994-2018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
A	US 9430688 B1 (THE BOEING COMPANY) 2016.08.30, 全文, 全図 (ファミリーなし)	1-9
A	梅田裕平, データの形が教えてくれること ー トポロジカル・データ・アナリシスとその応用ー, 情報処理, 2016.10.15, 第57巻, 第11号, pp.1122-1127, ISSN 0447-8053	1-9

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

02.05.2018

国際調査報告の発送日

22.05.2018

国際調査機関の名称及びあて先

日本国特許庁（ISA/J P）

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）

多賀 実

5B

9367

電話番号 03-3581-1101 内線 3545

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
P, A	JP 2017-97643 A (富士通株式会社) 2017.06.01, 全文, 全図 & US 2017/0147946 A1, 全文, 全図	1 - 9