

(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  
2025年2月27日(27.02.2025)



(10) 国際公開番号  
**WO 2025/041292 A1**

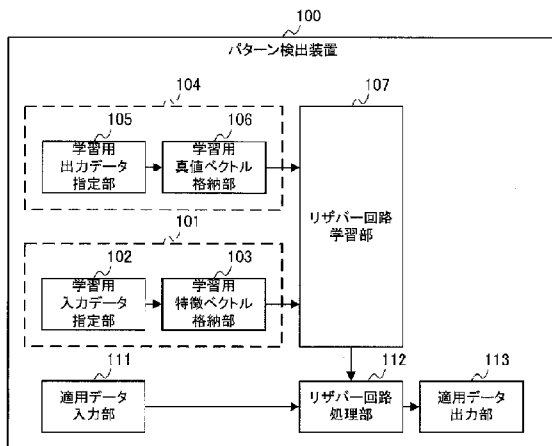
- (51) 国際特許分類:  
**G06T 7/00** (2017.01)
- (21) 国際出願番号: PCT/JP2023/030253
- (22) 国際出願日: 2023年8月23日(23.08.2023)
- (25) 国際出願の言語: 日本語
- (26) 国際公開の言語: 日本語
- (71) 出願人:三菱電機株式会社(MITSUBISHI ELECTRIC CORPORATION) [JP/JP]; 〒1008310 東京都千代田区丸の内二丁目7番3号 Tokyo (JP).
- (72) 発明者:鹿毛 裕史(KAGE Hiroshi); 〒1008310 東京都千代田区丸の内二丁目7番3号 三菱電機株式会社内 Tokyo (JP).
- (74) 代理人:山形 洋一, 外(YAMAGATA Yoichi et al.); 〒1510053 東京都渋谷区代々木2丁目

16番2号 甲田ビル4階 弁理士法人 山形・佐藤特許事務所 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, CV, CZ, DE, DJ, DK, DM, DO, DZ, EC, EE, EG, ES, FI, GB, GD, GE, GH, GM, GT, HN, HR, HU, ID, IL, IN, IQ, IR, IS, IT, JM, JO, JP, KE, KG, KH, KN, KP, KR, KW, KZ, LA, LC, LK, LR, LS, LU, LY, MA, MD, MG, MK, MN, MU, 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, CV, GH, GM, KE, LR, LS, MW, MZ, NA, RW, SC, SD, SL, ST, SZ, TZ, UG,

(54) Title: TRAINING DEVICE, INFERENCE DEVICE, TRAINING INFERENCE DEVICE, PROGRAM, TRAINING INFERENCE SYSTEM, TRAINING METHOD, AND INFERENCE METHOD

(54) 発明の名称: 学習装置、推論装置、学習推論装置、プログラム、学習推論システム、学習方法及び推論方法



- 100 Pattern detection device
- 102 Training input data designation unit
- 103 Training feature vector storage unit
- 105 Training output data designation unit
- 106 Training true value vector storage unit
- 107 Reservoir circuit training unit
- 111 Applicable data input unit
- 112 Reservoir circuit processing unit
- 113 Applicable data output unit

(57) Abstract: In the present invention, a pattern detection device (100) comprises: a training data generation unit (101) that generates training data in which a plurality of feature vectors corresponding respectively to a plurality of training target images are arranged in time series; a true value data construction unit (104) that constructs true value data in which a plurality of true value vectors, each indicating true/false for each of the plurality of training target images, are arranged so as to correspond to the time series of the plurality of feature vectors; and a reservoir circuit training unit (107) that uses the training data and the true value data to train a three-layer neural network using reservoir computing.



WO 2025/041292 A1

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, ME, 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))

---

(57) 要約：パターン検出装置 (100) は、複数の学習対象画像のそれぞれに対応する複数の特徴ベクトルが時系列で配置された学習データを生成する学習データ生成部 (101) と、その複数の学習対象画像のそれぞれの正偽を示す複数の真値ベクトルが、その複数の特徴ベクトルの時系列に対応するように配置された真値データを構築する真値データ構築部 (104) と、学習データ及び真値データを用いて、リザパーコンピューティングを利用した三層ニューラルネットワークの学習を行うリザパー回路学習部 (107) とを備える。

## 明 細 書

発明の名称：

学習装置、推論装置、学習推論装置、プログラム、学習推論システム、学習方法及び推論方法

### 技術分野

[0001] 本開示は、学習装置、推論装置、学習推論装置、プログラム、学習推論システム、学習方法及び推論方法に関する。

### 背景技術

[0002] 機械学習は、CNN (Convolutional Neural Network) と、RNN (Recurrent Neural Network) に分かれる。

CNNでは、深層学習技術として静的パターン検出の高精度化が進んでいる。一方、RNNは、CNNが有さない再帰的結合を持つため、時系列信号学習に専ら利用されてきた。

[0003] 一般に、CNNは、RNNに比べて大規模のハードウェアリソースを必要とするのに対し、RNNの一技術であるリザーブコンピューティングは、CNN及びRNNの他の手法と比べて、低リソースで学習が可能という利点を持つ。また、リザーブコンピューティングは、中間層内部を学習する必要がないことから、中間層を一般の物理媒体で回路実装できるという利点も持つ。

[0004] リザーブコンピューティングは、時系列信号学習に数多く応用されてきたが、リザーブコンピューティングを静的な二次元パターンの学習及び検出に応用することで、リザーブコンピューティングの適用範囲を拡大することができる。そうした技術の例として、リザーブコンピューティングを利用した二次元パターン検出学習の実装手法が非特許文献1に示されている。

### 先行技術文献

#### 非特許文献

[0005] 非特許文献1: Paugam-Moisy et al., “Delay learning and polychronization for reservoir computing”, Neurocomputing 71 (7-9), pp. 1143-1158, 2008.

## 発明の概要

### 発明が解決しようとする課題

[0006] 従来の技術では、リザーバーコンピューティングの中間層ユニット間の結合定数を学習する必要があるため、本来のリザーバーコンピューティングが持つ、中間層の構築に一般の物理媒体が利用できるという特徴が失われる。このため、仮に中間層構築に利用できる物理媒体があったとしても、それによる学習ネットワークの構築の難易度が上がるという問題がある。

[0007] そこで、本開示の一又は複数の態様は、リザーバーコンピューティングによる学習ネットワークを容易に構築することができるようにすることを目的とする。

### 課題を解決するための手段

[0008] 本開示の一態様に係る学習装置は、複数の学習対象画像のそれぞれに対応する複数の特徴ベクトルが時系列で配置された学習データを生成する学習データ生成部と、前記複数の学習対象画像のそれぞれの正偽を示す複数の真値ベクトルが、前記複数の特徴ベクトルの時系列に対応するように配置された真値データを構築する真値データ構築部と、前記学習データ及び前記真値データを用いて、リザーバーコンピューティングを利用した三層ニューラルネットワークの学習を行う学習部と、を備えることを特徴とする。

[0009] 本開示の一態様に係る推論装置は、推論対象となる画像である推論対象画像から特徴ベクトルを適用データとして生成する適用データ生成部と、複数の学習対象画像のそれぞれに対応する複数の特徴ベクトルが時系列で配置された学習データと、前記複数の学習対象画像のそれぞれの正偽を示す複数の真値ベクトルが、前記複数の特徴ベクトルの時系列に対応するように配置された真値データとを用いて、リザーバーコンピューティングを利用した三層ニ

ューラルネットワークの学習を行い、前記学習の結果として取得された、前記三層ニューラルネットワークの結合定数を用いて、学習済み三層ニューラルネットワークを生成し、前記適用データを前記学習済み三層ニューラルネットワークに入力することで、前記推論対象画像の正偽を推論する処理部と、を備えることを特徴とする。

[0010] 本開示の一態様に係る学習推論装置は、複数の学習対象画像のそれぞれに対応する複数の特徴ベクトルが時系列で配置された学習データを生成する学習データ生成部と、前記複数の学習対象画像のそれぞれの正偽を示す複数の真値ベクトルが、前記複数の特徴ベクトルの時系列に対応するように配置された真値データを構築する真値データ構築部と、前記学習データ及び前記真値データを用いて、リザーブコンピューティングを利用した三層ニューラルネットワークの学習を行い、前記三層ニューラルネットワークの結合定数と、前記学習の結果として取得する学習部と、推論対象となる画像である推論対象画像から特徴ベクトルを適用データとして生成する適用データ生成部と、前記取得された結合定数を用いて、学習済み三層ニューラルネットワークを生成し、前記適用データを前記学習済み三層ニューラルネットワークに入力することで、前記推論対象画像の正偽を推論する処理部と、を備えることを特徴とする。

[0011] 本開示の第1の態様に係るプログラムは、コンピュータを、複数の学習対象画像のそれぞれに対応する複数の特徴ベクトルが時系列で配置された学習データを生成する学習データ生成部、前記複数の学習対象画像のそれぞれの正偽を示す複数の真値ベクトルが、前記複数の特徴ベクトルの時系列に対応するように配置された真値データを構築する真値データ構築部、及び、前記学習データ及び前記真値データを用いて、リザーブコンピューティングを利用した三層ニューラルネットワークの学習を行う学習部、として機能させることを特徴とする。

[0012] 本開示の第2の態様に係るプログラムは、コンピュータを、推論対象となる画像である推論対象画像から特徴ベクトルを適用データとして生成する適

用データ生成部、及び、複数の学習対象画像のそれぞれに対応する複数の特徴ベクトルが時系列で配置された学習データと、前記複数の学習対象画像のそれぞれの正偽を示す複数の真値ベクトルが、前記複数の特徴ベクトルの時系列に対応するように配置された真値データとを用いて、リザバーコンピューティングを利用した三層ニューラルネットワークの学習を行い、前記学習の結果として取得された、前記三層ニューラルネットワークの結合定数を用いて、学習済み三層ニューラルネットワークを生成し、前記適用データを前記学習済み三層ニューラルネットワークに入力することで、前記推論対象画像の正偽を推論する処理部、として機能させることを特徴とする。

[0013] 本開示の一態様に係る学習推論システムは、複数の学習対象画像のそれぞれに対応する複数の特徴ベクトルが時系列で配置された学習データを生成する学習データ生成部と、前記複数の学習対象画像のそれぞれの正偽を示す複数の真値ベクトルが、前記複数の特徴ベクトルの時系列に対応するように配置された真値データを構築する真値データ構築部と、前記学習データ及び前記真値データを用いて、リザバーコンピューティングを利用した三層ニューラルネットワークの学習を行い、前記三層ニューラルネットワークの結合定数と、前記学習の結果として取得する学習部と、推論対象となる画像である推論対象画像から特徴ベクトルを適用データとして生成する適用データ生成部と、前記取得された結合定数を用いて、学習済み三層ニューラルネットワークを生成し、前記適用データを前記学習済み三層ニューラルネットワークに入力することで、前記推論対象画像の正偽を推論する処理部と、を備えることを特徴とする。

[0014] 本開示の一態様に係る学習方法は、複数の学習対象画像のそれぞれに対応する複数の特徴ベクトルが時系列で配置された学習データを生成し、前記複数の学習対象画像のそれぞれの正偽を示す複数の真値ベクトルが、前記複数の特徴ベクトルの時系列に対応するように配置された真値データを構築し、前記学習データ及び前記真値データを用いて、リザバーコンピューティングを利用した三層ニューラルネットワークの学習を行うことを特徴とする。

[0015] 本開示の一態様に係る推論方法は、推論対象となる画像である推論対象画像から特徴ベクトルを適用データとして生成し、複数の学習対象画像のそれぞれに対応する複数の特徴ベクトルが時系列で配置された学習データと、前記複数の学習対象画像のそれぞれの正偽を示す複数の真値ベクトルが、前記複数の特徴ベクトルの時系列に対応するように配置された真値データとを用いて、リザーブコンピューティングを利用した三層ニューラルネットワークの学習を行い、前記学習の結果として取得された、前記三層ニューラルネットワークの結合定数を用いて、学習済み三層ニューラルネットワークを生成し、前記適用データを前記学習済み三層ニューラルネットワークに入力することで、前記推論対象画像の正偽を推論することを特徴とする。

### 発明の効果

[0016] 本開示の一又は複数の態様によれば、リザーブコンピューティングによる学習ネットワークを容易に構築することができる。

### 図面の簡単な説明

[0017] [図1]実施の形態1に係る学習推論装置としてのパターン検出装置の構成を概略的に示すブロック図である。

[図2]パターンの検出対象を含むサンプル画像である学習用画像の一例を示す概略図である。

[図3]学習用画像から、正画像又は偽画像を判定する複数の部分画像を抽出する例を示す概略図である。

[図4]学習用画像セットの一例を説明するための概略図である。

[図5]実施の形態1における学習フェーズでの処理を説明するための概略図である。

[図6]実施の形態1において、複数枚の学習用画像を学習する例を説明するための概略図である。

[図7]実施の形態1における適用フェーズでの処理を説明するための概略図である。

[図8]コンピュータの構成を概略的に示すブロック図である。

[図9]実施の形態2に係る学習推論装置としてのパターン検出装置の構成を概略的に示すブロック図である。

[図10]実施の形態2における学習フェーズにおける学習用入力データ指定部及び直交フィルタ適用部での処理を説明するための概略図である。

[図11]二次元のWalsh-Hadamardフィルタの階数 $N=8$ の例を示す概略図である。

[図12]実施の形態2における適用フェーズでの処理を説明するための概略図である。

[図13]実施の形態3に係るパターン検出装置の構成を概略的に示すブロック図である。

[図14]実施の形態3における学習フェーズにおける学習用入力データ指定部、直交フィルタ適用部及び値域変換部での処理を説明するための概略図である。

[図15]双曲線正接関数を示すグラフである。

[図16]実施の形態3における適用フェーズでの処理を説明するための概略図である。

### 発明を実施するための形態

[0018] 実施の形態1.

図1は、実施の形態1に係る学習推論装置としてのパターン検出装置100の機能構成を概略的に示すブロック図である。

パターン検出装置100は、学習データ生成部101と、真値データ構築部104と、リザーバ回路学習部107と、適用データ入力部111と、リザーバ回路処理部112と、適用データ出力部113とを備える。

[0019] パターン検出装置100は、リザーバコンピューティングの実装形態として離散時間実装版であるEcho State Networkを利用した処理プロセスに関し、学習フェーズと、適用フェーズとからなる2つのフェーズで動作する。

[0020] 学習データ生成部101は、複数の学習対象画像のそれぞれに対応する複

数の特徴ベクトルが時系列で配置された学習データを生成する。

実施の形態1では、学習データ生成部101は、二次元画像である複数の学習対象画像の各々において予め定められた順番で画素値を抽出して、抽出された順番でその抽出された画素値を並べることで複数の特徴ベクトルの各々を生成する。

学習データ生成部101は、学習用入力データ指定部102と、学習用特徴ベクトル格納部103とを備える。

[0021] 学習用入力データ指定部102は、学習フェーズにおいて、一つの学習用画像を変換して特徴ベクトルを生成する。なお、学習用画像に含まれる個々の部分画像を学習対象画像ともいう。学習用入力データ指定部102は、複数の学習対象画像を変換して、複数の特徴ベクトルを生成する。そして、学習用入力データ指定部102は、学習フェーズにおいて、これらの複数の特徴ベクトルが一定の時間長を持つように構成することで、学習データとしての学習用特徴ベクトルを生成する。

[0022] 学習用特徴ベクトル格納部103は、学習フェーズにおいて、学習用入力データ指定部102で生成された学習用特徴ベクトルを記憶する。

[0023] 真値データ構築部104は、複数の学習対象画像のそれぞれの正偽を示す複数の真値ベクトルが、複数の学習対象画像から生成された複数の特徴ベクトルの時系列に対応するように配置された真値データを構築する。

真値データ構築部104は、学習用出力データ指定部105と、学習用真値ベクトル格納部106とを備える。

[0024] 学習用出力データ指定部105は、学習フェーズにおいて、学習用特徴ベクトルに含まれる個々の特徴ベクトルに対応した真値データを示す真値ベクトルを、学習用入力データ指定部102において生成された学習用特徴ベクトルに含まれている個々の特徴ベクトルが持つ真値と一対一に対応するように、学習用真値ベクトルとして生成する。

[0025] 学習用真値ベクトル格納部106は、学習フェーズにおいて、学習用出力データ指定部105により生成された学習用真値ベクトルに含まれている個

々の真値ベクトルが、学習用特徴ベクトル格納部103において記憶されている学習用特徴ベクトルに含まれている個々の特徴ベクトルに対応するように記憶する。

そして、学習用真値ベクトル格納部106は、真値データとしての学習用真値ベクトルを、リザーバ回路学習部107に入力する。

[0026] リザーバ回路学習部107は、学習データ生成部101で生成された学習データ及び真値データ構築部104で構築された真値データを用いて、リザーバコンピューティングを利用した三層ニューラルネットワークの学習を行う学習部として機能する。

[0027] リザーバ回路学習部107は、学習フェーズにおいて、学習用特徴ベクトル格納部103に保持されている学習用特徴ベクトルと、学習用真値ベクトル格納部106に保持されている学習用真値ベクトルとを元に、三層ニューラルネットワークに対してEcho State Network学習アルゴリズムを適用する。

そして、リザーバ回路学習部107は、その三層ニューラルネットワークの結合定数を、Echo State Network学習アルゴリズムによる学習結果として保存する。

[0028] 実施の形態1における適用データ入力部111は、推論対象となる画像である推論対象画像から特徴ベクトルを適用データとして生成する適用データ生成部として機能する。

実施の形態1では、適用データ入力部111は、二次元画像である推論対象画像において予め定められた順番で画素値を抽出して、抽出された順番でその抽出された画素値を並べることで適用データを生成する。

[0029] 例えば、適用データ入力部111は、適用フェーズにおいて、新たに二次元画像の入力を受け付けて、その二次元画像を変換することで、その特徴ベクトルを取得する。ここでの二次元画像が推論対象画像となる。

[0030] リザーバ回路処理部112は、リザーバ回路学習部107での学習の結果として取得された、三層ニューラルネットワークの結合定数を用いて、学習

済み三層ニューラルネットワークを生成し、適用データ入力部111からの適用データをその学習済み三層ニューラルネットワークに入力することで、推論対象画像の正偽を推論する処理部として機能する。

[0031] 例えば、リザーバ回路処理部112は、適用フェーズにおいて、リザーバ回路学習部107に保存された結合定数を利用して、学習済み三層ニューラルネットワークを構築する。リザーバ回路処理部112は、学習済み三層ネットワークに対して学習済みのEcho State Networkを適用する。後述の図7に示すとおり、学習済みのEcho State Networkは、入力層112a、中間層112b及び出力層112cを備える。

そして、リザーバ回路処理部112は、適用データ入力部111で取得された特徴ベクトルを、入力データとして、入力層112aに入力する。

[0032] 適用データ出力部113は、出力層112cからの出力データを取得し、判定結果として出力する。

[0033] 本実施の形態では、パターン検出対象として二次元画像を例として、説明する。

学習用画像から抽出された複数の部分画像を学習用入力画像セットとする。なお、複数の部分画像の各々が学習対象画像となる。

複数の部分画像の内、検出対象を含む部分画像を正画像 (true)、それ以外の部分画像を偽画像 (false) として、部分画像が正画像の場合、真値ベクトル  $(1, 0)^T$  (Tはベクトルの転置) を、部分画像が偽画像の場合、真値ベクトル  $(0, 1)^T$  を、2個の出力層ユニット数における真値データとして、学習用入力画像セットに含まれている複数の部分画像に対応付けた学習用出力データセットとする。

ここでは、学習用入力画像セットと、学習用出力データセットとから構成される学習用画像セットを、Echo State Networkで学習した際の動作例について、学習フェーズと、適用フェーズとに分けて説明する。

[0034] まず、学習フェーズについて説明する。

図2は、パターンの検出対象を含むサンプル画像である学習用画像の一例を示す概略図である。

ここでは、検出対象の例として、学習用画像中に存在する6個のりんごを学習するものとする。

[0035] このため、例えば、図3に示されているように、学習用画像IMから、正画像又は偽画像を判定するために、複数の矩形枠を指定して、その複数の矩形枠内の画像が部分画像P01~P12として抽出される。

[0036] 図4は、学習用画像セットの一例を説明するための概略図である。

学習用画像セットは、検知対象である正画像が「true」として示されており、非検知対象である偽画像が「false」として示されている。

[0037] 図4に示されている正画像は、図3に示されている学習用画像IM中に存在する6個のりんごを含む矩形枠から抽出された部分画像である。この正画像を検出対象として学習するために、真値ベクトル(1, 0)<sup>T</sup>が真値データとして与えられる。

[0038] また、図4に示されている偽画像は、図3に示されている学習用画像IM中に存在する6個のりんごを含まない領域から、ランダムに指定された矩形枠から抽出された部分画像である。この偽画像を検出対象として学習するために、真値ベクトル(0, 1)<sup>T</sup>が真値データとして与えられる。

[0039] ここでは、学習用画像セットから、正画像又は偽画像を真値として持つ一つの部分画像を、Echo State Networkで学習する場合の処理について、図5を用いて説明する。

[0040] 図5は、学習フェーズでの処理を説明するための概略図である。

まず、Echo State Networkの学習に用いる一つの部分画像を示す二次元画像データが、学習用入力データ指定部102が有する学習画像入力バッファ102aに格納される。

[0041] 次に、学習画像入力バッファ102aに格納されている二次元画像データで示される部分画像を特徴ベクトル化するために、学習用入力データ指定部

102は、その部分画像の解像度を変換して、変換後のデータを特徴ベクトル変換用画像バッファ102bに格納する。

[0042] 次に、学習用入力データ指定部102は、解像度変換された変換部分画像を特徴ベクトル化して特徴ベクトル用バッファ102cに保存する。この変換部分画像をベクトル化するためには、学習用入力データ指定部102は、例えば、変換部分画像の左上隅画素をスタートとして順に左行方向に1画素ずつ画素値を読み出し、順次上端行から下端行へ進み、右下端画素まで画素値を読み出すことにより、ベクトル化すればよい。

[0043] 次に、学習用入力データ指定部102に入力された一つの部分画像が持つ真値、言い換えると、検出対象を含む画像であれば正画像、そうでなければ偽画像に対応付けられた真値ベクトルが、学習用出力データ指定部105が有する真値ベクトル格納バッファ105aに格納される。

[0044] ここで、真値ベクトルの要素数は、1個以上の数が指定されればよい。例えば、真値ベクトル要素数を2個として、正画像には、列ベクトル(1, 0)<sup>T</sup>、偽画像には列ベクトル(0, 1)<sup>T</sup>を対応付けて、学習が行われればよい。

[0045] 以上のように、特徴ベクトル用バッファ102cに保存された、部分画像から得られる特徴ベクトルと、真値ベクトル格納バッファ105aに保存された真値ベクトルと、リザーバ回路学習部107が有するEcho State Networkに関して適切なネットワーク初期設定を行えば、下記の参考文献1に記載された学習アルゴリズムにより、正画像と、偽画像とを併せて2枚の画像をEcho State Networkで学習できる。

参考文献1: Lukoševičius, “A Practical Guide to Applying Echo State Networks”, Lecture Notes in Computer Science, vol. 7700, pp. 659–686, 2012

[0046] ここで、Echo State Networkの学習は、中間層から出力層に至る結合定数のみを学習すればよく、その具体的計算手法について説明する。

まず、リザーバ回路学習部107は、Echo State Netwo

$r$   $k$  の入力層 107 a、中間層 107 b 及び出力層 107 c を相互に結合する結線について、入力層 107 a から中間層 107 b への結合定数行列を  $W_{in}$ 、中間層 107 b の内部ユニットの相互的な結合定数行列を  $W_{res}$ 、出力層 107 c から中間層 107 b への結合定数行列を  $W_{fb}$  とする。また、離散時刻  $k$  における入力層 107 a への入力信号を  $u[k]$ 、中間層 107 b の内部ユニットの状態を  $x[k]$ 、出力層 107 c の出力信号を  $y[k]$  としたとき、下記の (1) 式の関係がある。

[0047] [数1]

$$x[k+1] = (1 - \lambda)x[k] + \lambda \tanh(W_{in} \cdot u[k] + W_{res} \cdot x[k] + W_{fb} \cdot y[k]) \quad (1)$$

[0048] (1) 式において、 $\lambda$  は、leaking rate と呼ばれ、1 時刻前の  $x[k]$  の活動を  $x[k+1]$  の活動にどの程度反映させるか、言い換えると、過去の間層の内部状態履歴をどれだけ時間軸方向に引きずるかを意味する。 $\lambda = 1$  のとき、 $x[k]$  は、 $x[k+1]$  の更新に一切反映されない、言い換えると、内部状態履歴を時間軸方向に一切引きずらないことを意味する。

[0049] さらに、中間層 107 b から出力層 107 c への結合定数行列を  $W_{out}$ 、時刻 1 から  $T$  までの  $u[k]$  と、 $x[k]$  とを列ベクトルとしてまとめた行列を  $X$ 、真値データである  $y[k]$  を列ベクトルとしてまとめた行列を  $Y_{target}$  としたとき、 $X$  と、 $Y_{target}$  とには、下記の (2) 式の関係がある。

[0050] [数2]

$$Y_{target} = W_{out} \cdot X \quad (2)$$

[0051] 上記の参考文献 1 に記載されている Ridge Regression を用いて、(1) 式を  $W_{out}$  について解くと、下記の (3) 式のようなになる。

[0052] [数3]

$$W_{out} = Y_{target} \cdot X^T (XX^T + \beta I)^{-1} \quad (3)$$

[0053] これにより、部分画像から導いた特徴ベクトルと、中間層 107 b の内部状態から構成される  $X$  と、真値ベクトルから構成される  $Y_{target}$  とから、 $W$

$w_{out}$ を算出することができる。

[0054] なお、(3)式は、Ridge Regressionの計算プロセスを示しており、 $\beta$ は、Ridge Regressionにおける最適化パラメータである。

仮に、(2)式に対してRidge Regressionを利用せず、Moore-Penroseの擬似逆行列を利用して、 $W_{out}$ を直接算出する場合の解は、下記の(4)式で得られる。

[0055] [数4]

$$W_{out} = Y_{target} \cdot X^+ \quad \text{ここで } X^+ \text{ は } X \text{ の擬似逆行列で } X^+ = X^T (XX^T)^{-1} \quad (4)$$

[0056] しかしながら、(4)式は、 $X$ の次元が大きい場合に擬似逆行列の計算量が嵩むため、Ridge Regressionを利用して擬似逆行列計算を回避し、計算量を抑え込む。この場合のRidge Regressionによる最適化計算は、下記の(5)式で与えられる。

[0057] [数5]

$$\operatorname{argmin}_{W_{out}} \left( \|Y_{target} - W_{out} \cdot X\|^2 + \beta \|W_{out}\|^2 \right) \quad (5)$$

[0058] (5)式で、仮に $\beta \|W_{out}\|^2$ の項がない場合、 $W_{out}$ のノルムサイズが巨大になると、Echo State Networkの出力が不安定になる。このため、(5)式の計算過程に $\beta \|W_{out}\|^2$ の項を含めて最適化計算を実行し、ノルムサイズが調節された $W_{out}$ を得る。

[0059] 以上では、一つの部分画像をEcho State Networkに学習させる例を説明したが、ここでは、正画像又は偽画像の真値が付与された複数枚の学習用画像をEcho State Networkで学習する例について、図6を用いて説明する。

[0060] なお、図6においては、Echo State Networkに学習させる複数枚の二次元画像である学習用画像として、いずれも、学習用入力データ指定部102によって変換された特徴ベクトルが利用される。個々の二次元画像を特徴ベクトルに変換する過程については、図5を用いて説明した

上述の手続きが利用されればよい。

[0061] 図6において、学習用入力データ指定部102には、 $n$ 枚 ( $n$ は、2以上の整数)の正画像 $T_1, T_2, \dots, T_n$ と、 $m$ 枚 ( $m$ は、2以上の整数)の偽画像 $F_1, F_2, \dots, F_m$ が特徴ベクトルの形式で時系列順に格納されている。さらに、個々の正画像及び偽画像については、いずれも、特徴ベクトルが1枚連続して格納されている。

[0062] 言い換えると、学習用入力データ指定部102には、合計 $l \times (n + m)$ 個の特徴ベクトルが時系列順に格納され、上記の(2)式における行列 $X$ の列ベクトルを構成している。この時系列順に呼応する形で、学習用出力データ指定部105には個々の正画像及び偽画像に対応付けられた合計 $l \times (n + m)$ 個の真値ベクトルが、時系列順に格納され、上記の(2)式における行列 $Y_{target}$ の列ベクトルを構成している。

[0063] 具体的な真値ベクトルとして、上述同様、正画像には、列ベクトル $(1, 0)^T$ 、偽画像には、列ベクトル $(0, 1)^T$ が対応付けられればよい。

[0064] 次に、実施の形態1における適用フェーズについて、図7を用いて説明する。

まず、一つの部分画像を示す二次元画像データが、適用データ入力部111が有する適用画像入力バッファ111aに格納される。

[0065] 次に、適用画像入力バッファ111aに格納されている二次元画像データで示される部分画像を特徴ベクトル化するために、適用データ入力部111は、その部分画像の解像度を変換して、変換後のデータを特徴ベクトル変換用画像バッファ111bに格納する。

[0066] 次に、適用データ入力部111は、解像度変換された変換部分画像を特徴ベクトル化して特徴ベクトル用バッファ111cに保存する。この変換部分画像をベクトル化するためには、適用データ入力部111は、例えば、変換部分画像の左上隅画素をスタートとして順に左行方向に1画素ずつ画素値を読み出し、順次上端行から下端行へ進み、右下端画素まで画素値を読み出すことにより、ベクトル化すればよい。

[0067] リザーバー回路処理部112は、リザーバー回路学習部107での学習の結果として取得された、三層ニューラルネットワークの結合定数を用いて、学習済み三層ニューラルネットワークを生成する。リザーバー回路処理部112は、学習済み三層ニューラルネットワークに対して学習済みのEcho State Networkを適用する。学習済みのEcho State Networkを有したリザーバー回路処理部112は、新たな二次元画像を列ベクトルとして適用データ入力部111が構築した特徴ベクトルの入力を受け入れる。

学習済みのEcho State Networkは、入力層112a、中間層112b及び出力層112cを備える。そして、リザーバー回路処理部112は、学習済みのEcho State Networkにより出力ベクトルを算出して、適用データ出力部113の出力ベクトル格納バッファ113aに、その出力ベクトルを格納する。

[0068] そして、適用データ出力部113では、判定回路113bが、出力ベクトルが検知対象であることを意味する正画像か、あるいは非検知対象である偽画像かを判定する。この正画像あるいは偽画像の判定については、判定回路113bは、例えば、要素数2の出力ベクトルに対し、各要素についてしきい値判定を適用して判定してもよく、あるいは線形分離又はその他の機械学習手法を利用して判定を行ってもよい。

[0069] 以上により、リザーバーコンピューティングによる学習ネットワークを容易に構築することができる。そして、Echo State Networkを利用して静的な二次元画像に含まれる特定の対象を、部分画像の矩形位置として検出することが可能になる。この識別能力をさらに高めるために、下記の参考文献2に記載されたアンサンブル学習と呼ばれる機械学習の手法が知られており、識別性能の低い識別関数を複数組み合わせることで、高い識別性能を確保することができる。このアンサンブル学習を利用して、学習済みのEcho State Networkを一つの識別関数と見て、複数のEcho State Networkを組み合わせることにより、より

高精度の識別関数を構築することができる。

参考文献2：1. D. Miénye and Y. Sun, “A Survey of Ensemble Learning: Concepts, Algorithms, Applications, and Prospects”, IEEE Access Vol. 10, pp. 99129–99149, 2022.

[0070] なお、実施の形態1では、リザーブコンピューティング回路への入力パターンを列ベクトルとして表現し、各列ベクトルが一定の時間長を持って入力パターンを構成し、出力データには入力パターンの識別カテゴリに相当する教師信号を対応づけることにより、リザーブコンピューティング回路の学習でリザーブコンピューティング回路の中間層が持つ動的平衡点に入力パターンを対応付けることができる。これにより、リザーブコンピューティング回路を利用してパターン検出を実現することが可能になる。

[0071] 以上に記載されたパターン検出装置100は、例えば、図8に示されているようなコンピュータ10により実現することができる。

コンピュータ10は、HDD (Hard Disk Drive) 又はSSD (Solid State Drive) 等のストレージ11と、メモリ12と、CPU (Central Processing Unit) 等のプロセッサ13と、処理回路14と、リザーブ回路15とを備える。

[0072] 処理回路14は、単回路、複合回路、プログラムで動作するプロセッサ、プログラムで動作する並列プロセッサ、ASIC (Application Specific Integrated Circuit) 又はFPGA (Field Programmable Gate Array) 等により構成される。

[0073] 例えば、学習用入力データ指定部102、学習用出力データ指定部105及び適用データ入力部111は、処理回路14により構成することができる。

学習用特徴ベクトル格納部103及び学習用真値ベクトル格納部106は

、メモリ12により構成することができる。

リザーバ回路学習部107及びリザーバ回路処理部112は、ストレージ11に記憶されているプログラムをメモリ12にロードして、そのプログラムをプロセッサ13が実行して、プロセッサ13がリザーバ回路15を利用することで構成することができる。

適用データ出力部113は、ストレージ11に記憶されているプログラムをメモリ12にロードして、そのプログラムをプロセッサ13が実行することで実現することができる。

[0074] 以上のプログラムは、図示しないリーダ／ライタを介して、図示しない記録媒体から、あるいは、図示しない通信I/F (InterFace) を介してネットワークから、ストレージ11にダウンロードされ、それから、メモリ12上にロードされてプロセッサ13により実行されてもよい。また、リーダ／ライタを介して、図示しない記録媒体から、あるいは、図示しない通信I/Fを介してネットワークから、メモリ12上に直接ロードされ、プロセッサ13により実行されてもよい。

言い換えると、プログラムは、記録媒体等のプログラムプロダクトにより提供されてもよい。

以上のように、パターン検出装置100は、処理回路網により実現することができる。

[0075] 実施の形態2.

図9は、実施の形態2に係る学習推論装置としてのパターン検出装置200の構成を概略的に示すブロック図である。

パターン検出装置200は、学習データ生成部201と、真値データ構築部104と、リザーバ回路学習部107と、適用データ生成部210と、リザーバ回路処理部112と、適用データ出力部113とを備える。

実施の形態2では、学習データ生成部201及び適用データ生成部210の一部として機能する直交フィルタ適用部220が設けられている。

[0076] 実施の形態2に係るパターン検出装置200の真値データ構築部104、

リザーブ回路学習部 107、リザーブ回路処理部 112 及び適用データ出力部 113 は、実施の形態 1 に係るパターン検出装置 100 の真値データ構築部 104、リザーブ回路学習部 107、リザーブ回路処理部 112 及び適用データ出力部 113 と同様である。

[0077] 但し、実施の形態 2 に係るパターン検出装置 200 のリザーブ回路処理部 112 は、適用フェーズにおいて、直交フィルタ適用部 220 においてフィルタ処理された特徴ベクトルを、入力データとして、入力層 112 a に入力する。

[0078] 学習データ生成部 201 は、複数の学習対象画像のそれぞれに対応する複数の特徴ベクトルが時系列で配置された学習データを生成する。

実施の形態 2 では、学習データ生成部 201 は、二次元画像である複数の学習対象画像の各々に対して直交フィルタを適用した結果である処理画像において予め定められた順番で画素値を抽出して、抽出された順番でその抽出された画素値を並べることで複数の特徴ベクトルの各々を生成する。

[0079] 学習データ生成部 201 は、学習用入力データ指定部 202 と、直交フィルタ適用部 220 と、学習用特徴ベクトル格納部 103 とを備える。

実施の形態 2 に係るパターン検出装置 200 の学習用特徴ベクトル格納部 103 は、実施の形態 1 に係るパターン検出装置 100 の学習用特徴ベクトル格納部 103 と同様である。

[0080] 学習用入力データ指定部 202 は、学習フェーズにおいて、一つの学習用画像の解像度を変換した画像を、直交フィルタ適用部 220 に与える。

[0081] 適用データ生成部 210 は、二次元画像である推論対象画像に対して直交フィルタを適用した結果である処理画像において予め定められた順番で画素値を抽出して、抽出された順番でその抽出された画素値を並べることで適用データを生成する。

適用データ生成部 210 は、適用データ入力部 211 と、直交フィルタ適用部 220 とを備える。

[0082] 適用データ入力部 211 は、適用フェーズにおいて、新たに二次元画像の

入力を受け付けて、その二次元画像の解像度を変換した画像を、直交フィルタ適用部220に与える。

[0083] 直交フィルタ適用部220は、学習用入力データ指定部202からの画像に直交フィルタを適用して特徴ベクトルを生成する。そして、直交フィルタ適用部220は、フィルタ処理された複数の特徴ベクトルが一定の時間長を持つように構成することで、学習用特徴ベクトルを生成し、その特徴ベクトルを学習用特徴ベクトル格納部103に与える。

また、直交フィルタ適用部220は、適用データ入力部211からの画像に直交フィルタを適用して特徴ベクトルを生成し、その特徴ベクトルをリザーバ回路処理部112に与える。

[0084] 図10は、実施の形態2における学習フェーズにおける学習用入力データ指定部202及び直交フィルタ適用部220での処理を説明するための概略図である。

ここでは、直交フィルタ適用部220で用いる直交フィルタとして、フィルタ係数が「1」と、「-1」との2値からなるWalsh-Hadamardフィルタが利用される例を示す。また、実施の形態1と同様に、学習用入力データ指定部202に保持されている入力データを変換する動作のうち、学習用画像セットから正画像又は偽画像を真値として持つ一つの画像をEcho State Networkで学習する場合の学習フェーズでの処理について説明する。

[0085] まず、Echo State Networkの学習に用いる一つの部分画像を示す二次元画像データが、学習用入力データ指定部202が有する学習画像入力バッファ202aに格納される。

[0086] 次に、学習画像入力バッファ202aに格納されている二次元画像データで示される部分画像を特徴ベクトル化するために、学習用入力データ指定部202は、その部分画像の解像度を変換して、変換後のデータを特徴ベクトル変換用画像バッファ202bに格納する。

[0087] 次に、直交フィルタ適用部220の直交フィルタ適用処理ユニット220

aは、特徴ベクトル変換用画像バッファ202bに格納されている二次元画像に対し、フィルタ処理を行い、その結果を直交フィルタ出力バッファ220bに格納する。

[0088] 次に、直交フィルタ適用部220は、直交フィルタ出力バッファ220bに保存されているデータから、実施の形態1と同様に、特徴ベクトルを生成し、その特徴ベクトルを、特徴ベクトル用バッファ220cに格納する。

[0089] 以降、Echo State Networkによる学習フェーズの処理は実施の形態1と同様である。ここで、直交フィルタ適用部220が有する直交フィルタ適用処理ユニット220aにおいて使用する直交フィルタの例として、下記の参考文献3に記載されているWalsh-Hadamardフィルタがある。

[0090] 参考文献3：Y. Hel-Or and H. Hel-Or, "Real-Time Pattern Matching Using Projection Kernels", IEEE Transactions on Pattern Analysis and Machine Intelligence, 27 (9), pp. 1430-1445, 2005.

[0091] Walsh-Hadamardフィルタは、1次元として定義され、さらに1次元と1次元の積として二次元のWalsh-Hadamardフィルタを定義することができる。

[0092] 図11は、二次元のWalsh-Hadamardフィルタの階数 $N=8$ の例であり、 $8 \times 8$ 個の係数からなる1個の要素フィルタを、空間周波数を細かくする形で縦方向及び横方向に $8 \times 8$ 個の要素フィルタを並べたもので、縦横 $8 \times 8$ 画素の画像に適用可能である。

[0093] ここでWalsh-Hadamardフィルタの階数 $N$ は2のべき乗である必要があり、 $N=2, 4, 8, 16, 32, \dots$ を取り得る。

図11に示されている個々のフィルタについて、白は「+1」、黒は「-1」の係数を意味する。言い換えると、このWalsh-Hadamard

フィルタを8×8画素の画像に適用する際は乗算を必要とせず、加減算だけでフィルタ演算がなされるため、空間周波数分解の高速演算が可能になる。

[0094] 次に、実施の形態2における適用フェーズについて、図12を用いて説明する。

まず、一つの部分画像を示す二次元画像データが、適用データ入力部211が有する適用画像入力バッファ211aに格納される。

[0095] 次に、適用画像入力バッファ211aに格納されている二次元画像データで示される部分画像を特徴ベクトル化するために、適用データ入力部211は、その部分画像の解像度を変換して、変換後のデータを特徴ベクトル変換用画像バッファ211bに格納する。

[0096] 次に、直交フィルタ適用部220の直交フィルタ適用処理ユニット220aは、特徴ベクトル変換用画像バッファ211bに格納されている二次元画像に対し、フィルタ処理を行い、その結果を直交フィルタ出力バッファ220bに格納する。

[0097] 次に、直交フィルタ適用部220は、直交フィルタ出力バッファ220bに保存されているデータから、実施の形態1と同様に、特徴ベクトルを生成し、その特徴ベクトルを、特徴ベクトル用バッファ220cに格納する。

[0098] 学習済みのEcho State Networkを有したリザーバ回路処理部112は、新たな二次元画像を列ベクトルとして直交フィルタ適用部220が構築した特徴ベクトルの入力を受け入れる。

学習済のEcho State Networkは、入力層112a、中間層112b及び出力層112cを備える。そして、リザーバ回路処理部112は、学習済みのEcho State Networkにより出力ベクトルを算出して、適用データ出力部113の出力ベクトル格納バッファ113aに、その出力ベクトルを格納する。

[0099] そして、適用データ出力部113では、判定回路113bが、出力ベクトルが検知対象であることを意味する正画像か、あるいは非検知対象である偽画像かを判定する。

[0100] なお、実施の形態2においては、実施の形態1と同様、学習フェーズにおいて、学習用入力データ指定部202に複数枚の学習用画像、学習用出力データ指定部105に、個々の学習用画像に紐づけられた真値ベクトルを複数個束ねて格納した上で、リザーブ回路学習部107がEcho State Networkの学習を行ってもよい。

[0101] なお、実施の形態2では、直交フィルタ適用部220で用いる直交フィルタとして、Walsh-Hadamardフィルタを利用した例を説明したが、別の直交フィルタが利用されてもよい。例えば、上記の参考文献3で紹介されている、離散コサイン変換(DCT: Discrete Cosine Transform)又は高速フーリエ変換(FFT: Fast Fourier Transform)を使って、二次元画像が特徴ベクトルに変換されてもよい。

[0102] なお、実施の形態2では、リザーブコンピューティング回路に学習させる学習用パターンを特徴空間にマッピングしたときに、直交変換を利用して、真値の異なる学習用パターンの特徴空間内における距離を拡大することができるため、リザーブコンピューティングによる学習ネットワークを容易に構築することができるとともに、リザーブコンピューティング回路を利用したパターン検出の識別性能を向上させることが可能になる。

[0103] 以上に記載されたパターン検出装置200も、図8に示されているようなコンピュータ10で実現することができる。

例えば、直交フィルタ適用部220も、ストレージ11に記憶されているプログラムをメモリ12にロードして、そのプログラムをプロセッサ13が実行すること、又は、処理回路14により構成することができる。

[0104] 実施の形態3.

図13は、実施の形態3に係るパターン検出装置300の構成を概略的に示すブロック図である。

パターン検出装置300は、学習データ生成部301と、真値データ構築部104と、リザーブ回路学習部107と、適用データ生成部310と、リ

ザバー回路処理部 1 1 2 と、適用データ出力部 1 1 3 とを備える。

実施の形態 3 では、学習データ生成部 3 0 1 及び適用データ生成部 3 1 0 の一部として機能する直交フィルタ適用部 3 2 0 及び値域変換部 3 2 1 が設けられている。

[0105] 実施の形態 3 に係るパターン検出装置 3 0 0 の真値データ構築部 1 0 4、リザバー回路学習部 1 0 7、リザバー回路処理部 1 1 2 及び適用データ出力部 1 1 3 は、実施の形態 1 に係るパターン検出装置 1 0 0 の真値データ構築部 1 0 4、リザバー回路学習部 1 0 7、リザバー回路処理部 1 1 2 及び適用データ出力部 1 1 3 と同様である。

但し、実施の形態 3 に係るパターン検出装置 3 0 0 のリザバー回路処理部 1 1 2 は、適用フェーズにおいて、値域変換部 3 2 1 において変換処理された特徴ベクトルを、入力データとして、入力層 1 1 2 a に入力する。

[0106] 学習データ生成部 3 0 1 は、複数の学習対象画像のそれぞれに対応する複数の特徴ベクトルが時系列で配置された学習データを生成する。

実施の形態 3 では、学習データ生成部 3 0 1 は、二次元画像である複数の学習対象画像の各々に対して直交フィルタを適用した結果である処理画像に対して、画素値を予め定められた値域内に変換する関数を適用した結果である変換画像において予め定められた順番で画素値を抽出して、抽出された順番でその抽出された画素値を並べることで複数の特徴ベクトルの各々を生成する。

[0107] 学習データ生成部 3 0 1 は、学習用入力データ指定部 2 0 2 と、直交フィルタ適用部 3 2 0 と、値域変換部 3 2 1 と、学習用特徴ベクトル格納部 1 0 3 とを備える。

実施の形態 3 に係るパターン検出装置 3 0 0 の学習用入力データ指定部 2 0 2 は、実施の形態 2 に係るパターン検出装置 2 0 0 の学習用入力データ指定部 2 0 2 と同様である。

また、実施の形態 3 に係るパターン検出装置 3 0 0 の学習用特徴ベクトル格納部 1 0 3 は、実施の形態 1 に係るパターン検出装置 3 0 0 の学習用特徴

ベクトル格納部 103 と同様である。

[0108] 適用データ生成部 310 は、推論対象となる画像である推論対象画像から特徴ベクトルを適用データとして生成する。

実施の形態 3 では、適用データ生成部 310 は、二次元画像である推論対象画像に対して直交フィルタを適用した結果である処理画像に対して、画素値を予め定められた値域内に変換する関数を適用した結果である変換画像において予め定められた順番で画素値を抽出して、抽出された順番でその抽出された画素値を並べることで適用データを生成する。

[0109] 適用データ生成部 310 は、適用データ入力部 211 と、直交フィルタ適用部 320 と、値域変換部 321 とを備える。

実施の形態 3 に係るパターン検出装置 300 の適用データ入力部 211 は、実施の形態 3 に係るパターン検出装置 200 の適用データ入力部 211 と同様である。

[0110] 直交フィルタ適用部 320 は、学習用入力データ指定部 202 からの画像に直交フィルタを適用して、フィルタ処理後の画像データを値域変換部 321 に与える。

また、直交フィルタ適用部 320 は、適用データ入力部 211 からの画像に直交フィルタを適用して、フィルタ処理後の画像データを値域変換部 321 に与える。

[0111] 値域変換部 321 は、学習フェーズにおいて、学習用入力データ指定部 202 からの画像に対して直交フィルタ適用部 320 によりフィルタ処理された画像データに値域を変換する関数を適用して、特徴ベクトルを生成する。そして、値域変換部 321 は、そのような関数が適用された複数の特徴ベクトルが一定の時間長を持つように構成することで、学習用特徴ベクトルを生成し、その特徴ベクトルを学習用特徴ベクトル格納部 103 に与える。

また、値域変換部 321 は、学習フェーズにおいて、適用データ入力部 211 からの画像に対して直交フィルタ適用部 320 によりフィルタ処理された画像データに値域を変換する関数を適用して、特徴ベクトルを生成し、そ

の特徴ベクトルをリザーバ回路処理部 112 に与える。

[0112] 図 14 は、実施の形態 3 における学習フェーズにおける学習用入力データ指定部 202、直交フィルタ適用部 320 及び値域変換部 321 での処理を説明するための概略図である。

ここでは、実施の形態 2 と同様に、直交フィルタ適用部 320 で用いる直交フィルタとして、フィルタ係数が「1」と、「-1」との 2 値からなる Walsh-Hadamard フィルタが利用される例を示す。

そして、値域変換部 321 で用いる値域変換のための非線形関数として、双曲線正接関数 ( $\tanh(x)$ ) が利用され、直交フィルタ適用部 320 から出力される、Walsh-Hadamard フィルタの出力値を「-1」から「1」の間に収めて、特徴ベクトルを構築する動作について説明する。

[0113] まず、Echo State Network の学習に用いる一つの部分画像を示す二次元画像データが、学習用入力データ指定部 202 が有する学習画像入力バッファ 202a に格納される。

[0114] 次に、学習画像入力バッファ 202a に格納されている二次元画像データで示される部分画像を特徴ベクトル化するために、学習用入力データ指定部 202 は、その部分画像の解像度を変換して、変換後のデータを特徴ベクトル変換用画像バッファ 202b に格納する。

[0115] 次に、直交フィルタ適用部 320 の直交フィルタ適用処理ユニット 320a は、特徴ベクトル変換用画像バッファ 202b に格納されている二次元画像に対し、フィルタ処理を行い、その結果を直交フィルタ出力バッファ 320b に格納する。

[0116] 次に、値域変換部 321 では、直交フィルタ出力バッファ 320b に格納されているフィルタ処理された画像データの値を、値域変換関数適用処理ユニット 321a が有する値域変換関数により変換し、変換された値を有するデータが値域変換関数出力バッファ 321b に格納される。

[0117] そして、値域変換部 321 は、値域変換関数出力バッファ 321b に保存

されているデータから、実施の形態1と同様に、特徴ベクトルを生成し、その特徴ベクトルを、特徴ベクトル用バッファ321cに格納する。

[0118] ここで、値域変換関数適用処理ユニット321aが有する値域変換関数の例として、双曲線正接関数 (hyperbolic tangent) がある。

双曲線正接関数  $\tanh(x)$  は、下記の(6)式で示され、図15は、そのグラフを示す。

[0119] [数6]

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (6)$$

[0120] 実施の形態2においては、直交フィルタ適用部220の算出結果である直交フィルタ出力バッファ220bの各値から直接特徴ベクトルが構築されているが、実施の形態3においては、値域変換部321によって、入力画像に対する直交フィルタの適用値の分布が大きくばらつく場合であっても、 $\tanh(x)$  が値域を  $-1 < f(x) < 1$  の間に収めるため、リザーブ回路学習部107の学習時の動作を安定させることができる。

[0121] 次に、実施の形態3における適用フェーズについて、図16を用いて説明する。

まず、一つの部分画像を示す二次元画像データが、適用データ入力部211が有する適用画像入力バッファ211aに格納される。

[0122] 次に、適用画像入力バッファ211aに格納されている二次元画像データで示される部分画像を特徴ベクトル化するために、適用データ入力部211は、その部分画像の解像度を変換して、変換後のデータを特徴ベクトル変換用画像バッファ211bに格納する。

[0123] 次に、直交フィルタ適用部320の直交フィルタ適用処理ユニット320aは、特徴ベクトル変換用画像バッファ211bに格納されている二次元画像に対し、フィルタ処理を行い、その結果を直交フィルタ出力バッファ320bに格納する。

[0124] 次に、値域変換部321では、直交フィルタ出力バッファ320bに格納されているフィルタ処理された画像データの値を、値域変換関数適用処理ユニット321aが有する値域変換関数により変換し、変換された値を有するデータが値域変換関数出力バッファ321bに格納される。

[0125] そして、値域変換部321は、値域変換関数出力バッファ321bに保存されているデータから、実施の形態1と同様に、特徴ベクトルを生成し、その特徴ベクトルを、特徴ベクトル用バッファ321cに格納する。

[0126] 学習済みのEcho State Networkを有したリザーバ回路処理部112は、新たな二次元画像を列ベクトルとして値域変換部321が構築した特徴ベクトルの入力を受け入れる。

学習済のEcho State Networkは、入力層112a、中間層112b及び出力層112cを備える。そして、リザーバ回路処理部112は、学習済みのEcho State Networkにより出力ベクトルを算出して、適用データ出力部113の出力ベクトル格納バッファ113aに、その出力ベクトルを格納する。

[0127] そして、適用データ出力部113では、判定回路113bが、出力ベクトルが検知対象であることを意味する正画像か、あるいは非検知対象である偽画像かを判定する。

[0128] なお、実施の形態3においても、実施の形態1と同様、学習フェーズにおいて、学習用入力データ指定部202に複数枚の学習用画像、学習用出力データ指定部105に、個々の学習用画像に紐づけられた真値ベクトルを複数個束ねて格納した上で、リザーバ回路学習部107がEcho State Networkの学習を行ってもよい。

[0129] 以上のように、実施の形態3によれば、学習済みのEcho State Networkを有したリザーバ回路処理部112に特徴ベクトルを入力する前に、値域変換部321によって特徴ベクトルを構成する各要素の値を「-1」から「1」の間に収めることができるため、リザーバコンピューティングによる学習ネットワークを容易に構築することができるとともに、リ

ザバー回路処理部 112 の処理動作を安定させることができる。

[0130] なお、実施の形態 3 では、リザバーコンピューティング回路に入力する入力データの値域を狭めることにより、リザバーコンピューティング回路の動作が安定するため、リザバーコンピューティング回路を利用したパターン検出の識別性能を向上させることが可能になる。

[0131] 以上に記載された実施の形態 1～3 では、パターン検出装置 100～300 は、学習フェーズ及び推論フェーズの両方の処理を行う装置として説明したが、実施の形態 1～3 は、以上のような装置に限定されない。

例えば、実施の形態 1～3 は、学習フェーズでの処理を行う学習装置及び推論フェーズでの処理を行う推論装置として構成することもできる。

また、実施の形態 1～3 に係るパターン検出装置 100～300 が行っている処理を、ネットワークに接続されて、互いにデータを送受信することのできる複数のコンピュータが分散して行ってもよい。言い換えると、実施の形態 1～3 は、複数のコンピュータからなる学習推論システムとしてのパターン検出システムとして構成されてもよい。

## 符号の説明

[0132] 100, 200, 300 パターン検出装置、 101, 201, 301 学習データ生成部、 102, 202 学習用入力データ指定部、 103 学習用特徴ベクトル格納部、 104 真値データ構築部、 105 学習用出力データ指定部、 106 学習用真値ベクトル格納部、 107 リザバー回路学習部、 210, 310 適用データ生成部、 111, 211 適用データ入力部、 112 リザバー回路処理部、 113 適用データ出力部、 220, 320 直交フィルタ適用部、 321 値域変換部。

## 請求の範囲

- [請求項1] 複数の学習対象画像のそれぞれに対応する複数の特徴ベクトルが時系列で配置された学習データを生成する学習データ生成部と、  
前記複数の学習対象画像のそれぞれの正偽を示す複数の真値ベクトルが、前記複数の特徴ベクトルの時系列に対応するように配置された真値データを構築する真値データ構築部と、  
前記学習データ及び前記真値データを用いて、リザバーコンピューティングを利用した三層ニューラルネットワークの学習を行う学習部と、を備えること  
を特徴とする学習装置。
- [請求項2] 前記複数の学習対象画像の各々は、二次元画像であり、  
前記学習データ生成部は、前記二次元画像において予め定められた順番で画素値を抽出して、抽出された順番で前記抽出された画素値を並べることで前記複数の特徴ベクトルの各々を生成すること  
を特徴とする請求項1に記載の学習装置。
- [請求項3] 前記複数の学習対象画像の各々は、二次元画像であり、  
前記学習データ生成部は、前記二次元画像に対して直交フィルタを適用した結果である処理画像において予め定められた順番で画素値を抽出して、抽出された順番で前記抽出された画素値を並べることで前記複数の特徴ベクトルの各々を生成すること  
を特徴とする請求項1に記載の学習装置。
- [請求項4] 前記複数の学習対象画像の各々は、二次元画像であり、  
前記学習データ生成部は、前記二次元画像に対して直交フィルタを適用した結果である処理画像に対して、画素値を予め定められた値域内に変換する関数を適用した結果である変換画像において予め定められた順番で画素値を抽出して、抽出された順番で前記抽出された画素値を並べることで前記複数の特徴ベクトルの各々を生成すること  
を特徴とする請求項1に記載の学習装置。

[請求項5] 推論対象となる画像である推論対象画像から特徴ベクトルを適用データとして生成する適用データ生成部と、

複数の学習対象画像のそれぞれに対応する複数の特徴ベクトルが時系列で配置された学習データと、前記複数の学習対象画像のそれぞれの正偽を示す複数の真値ベクトルが、前記複数の特徴ベクトルの時系列に対応するように配置された真値データとを用いて、リザバーコンピューティングを利用した三層ニューラルネットワークの学習を行い、前記学習の結果として取得された、前記三層ニューラルネットワークの結合定数を用いて、学習済み三層ニューラルネットワークを生成し、前記適用データを前記学習済み三層ニューラルネットワークに入力することで、前記推論対象画像の正偽を推論する処理部と、を備えること

を特徴とする推論装置。

[請求項6] 前記推論対象画像は、二次元画像であり、

前記適用データ生成部は、前記二次元画像において予め定められた順番で画素値を抽出して、抽出された順番で前記抽出された画素値を並べることで前記適用データを生成すること

を特徴とする請求項5に記載の推論装置。

[請求項7] 前記推論対象画像は、二次元画像であり、

前記適用データ生成部は、前記二次元画像に対して直交フィルタを適用した結果である処理画像において予め定められた順番で画素値を抽出して、抽出された順番で前記抽出された画素値を並べることで前記適用データを生成すること

を特徴とする請求項5に記載の推論装置。

[請求項8] 前記推論対象画像は、二次元画像であり、

前記適用データ生成部は、前記二次元画像に対して直交フィルタを適用した結果である処理画像に対して、画素値を予め定められた値域内に変換する関数を適用した結果である変換画像において予め定めら

れた順番で画素値を抽出して、抽出された順番で前記抽出された画素値を並べることで前記適用データを生成すること

を特徴とする請求項5に記載の推論装置。

[請求項9]

複数の学習対象画像のそれぞれに対応する複数の特徴ベクトルが時系列で配置された学習データを生成する学習データ生成部と、

前記複数の学習対象画像のそれぞれの正偽を示す複数の真値ベクトルが、前記複数の特徴ベクトルの時系列に対応するように配置された真値データを構築する真値データ構築部と、

前記学習データ及び前記真値データを用いて、リザバーコンピューティングを利用した三層ニューラルネットワークの学習を行い、前記三層ニューラルネットワークの結合定数と、前記学習の結果として取得する学習部と、

推論対象となる画像である推論対象画像から特徴ベクトルを適用データとして生成する適用データ生成部と、

前記取得された結合定数を用いて、学習済み三層ニューラルネットワークを生成し、前記適用データを前記学習済み三層ニューラルネットワークに入力することで、前記推論対象画像の正偽を推論する処理部と、を備えること

を特徴とする学習推論装置。

[請求項10]

コンピュータを、

複数の学習対象画像のそれぞれに対応する複数の特徴ベクトルが時系列で配置された学習データを生成する学習データ生成部、

前記複数の学習対象画像のそれぞれの正偽を示す複数の真値ベクトルが、前記複数の特徴ベクトルの時系列に対応するように配置された真値データを構築する真値データ構築部、及び、

前記学習データ及び前記真値データを用いて、リザバーコンピューティングを利用した三層ニューラルネットワークの学習を行う学習部、として機能させること

を特徴とするプログラム。

[請求項11]

コンピュータを、

推論対象となる画像である推論対象画像から特徴ベクトルを適用データとして生成する適用データ生成部、及び、

複数の学習対象画像のそれぞれに対応する複数の特徴ベクトルが時系列で配置された学習データと、前記複数の学習対象画像のそれぞれの正偽を示す複数の真値ベクトルが、前記複数の特徴ベクトルの時系列に対応するように配置された真値データとを用いて、リザバーコンピューティングを利用した三層ニューラルネットワークの学習を行い、前記学習の結果として取得された、前記三層ニューラルネットワークの結合定数を用いて、学習済み三層ニューラルネットワークを生成し、前記適用データを前記学習済み三層ニューラルネットワークに入力することで、前記推論対象画像の正偽を推論する処理部、として機能させること

を特徴とするプログラム。

[請求項12]

複数の学習対象画像のそれぞれに対応する複数の特徴ベクトルが時系列で配置された学習データを生成する学習データ生成部と、

前記複数の学習対象画像のそれぞれの正偽を示す複数の真値ベクトルが、前記複数の特徴ベクトルの時系列に対応するように配置された真値データを構築する真値データ構築部と、

前記学習データ及び前記真値データを用いて、リザバーコンピューティングを利用した三層ニューラルネットワークの学習を行い、前記三層ニューラルネットワークの結合定数と、前記学習の結果として取得する学習部と、

推論対象となる画像である推論対象画像から特徴ベクトルを適用データとして生成する適用データ生成部と、

前記取得された結合定数を用いて、学習済み三層ニューラルネットワークを生成し、前記適用データを前記学習済み三層ニューラルネッ

トワークに入力することで、前記推論対象画像の正偽を推論する処理部と、を備えること

を特徴とする学習推論システム。

[請求項13] 複数の学習対象画像のそれぞれに対応する複数の特徴ベクトルが時系列で配置された学習データを生成し、

前記複数の学習対象画像のそれぞれの正偽を示す複数の真値ベクトルが、前記複数の特徴ベクトルの時系列に対応するように配置された真値データを構築し、

前記学習データ及び前記真値データを用いて、リザバーコンピューティングを利用した三層ニューラルネットワークの学習を行うことを特徴とする学習方法。

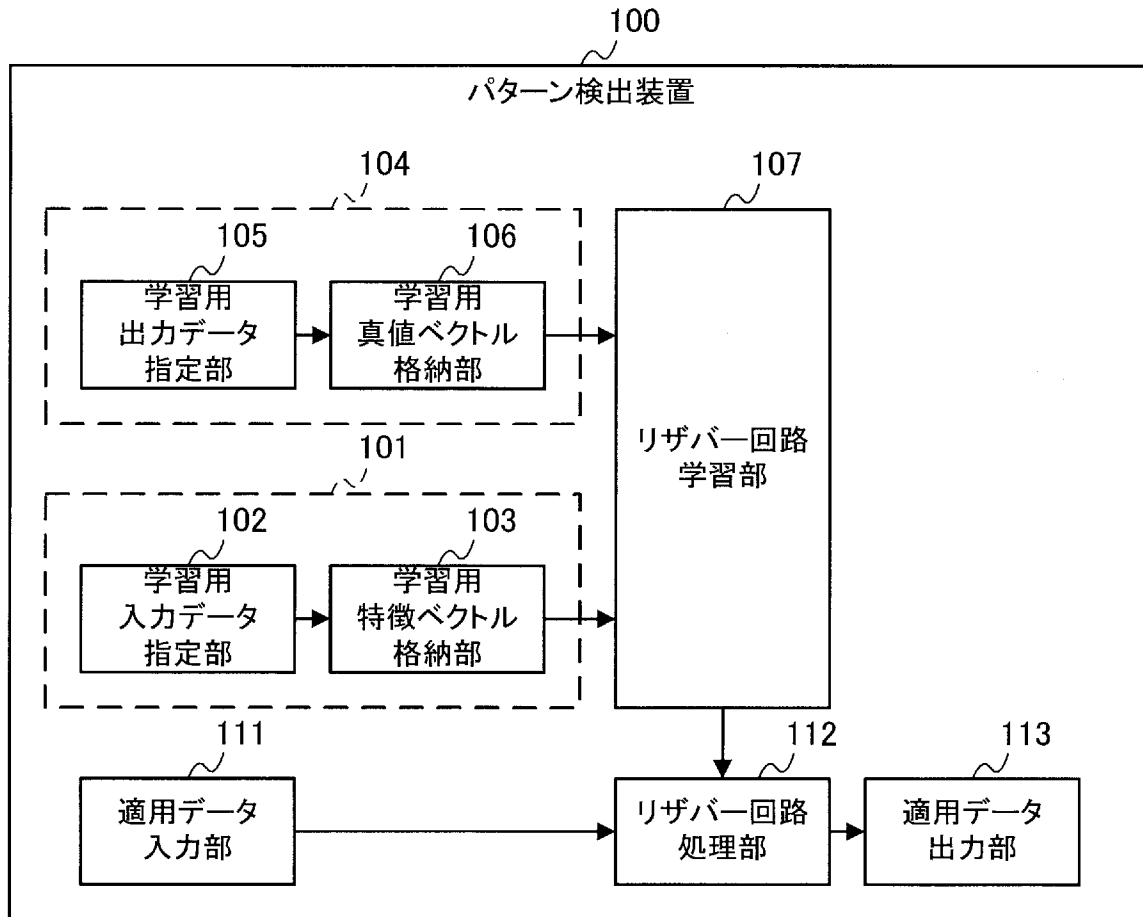
[請求項14] 推論対象となる画像である推論対象画像から特徴ベクトルを適用データとして生成し、

複数の学習対象画像のそれぞれに対応する複数の特徴ベクトルが時系列で配置された学習データと、前記複数の学習対象画像のそれぞれの正偽を示す複数の真値ベクトルが、前記複数の特徴ベクトルの時系列に対応するように配置された真値データとを用いて、リザバーコンピューティングを利用した三層ニューラルネットワークの学習を行い、前記学習の結果として取得された、前記三層ニューラルネットワークの結合定数を用いて、学習済み三層ニューラルネットワークを生成し、


前記適用データを前記学習済み三層ニューラルネットワークに入力することで、前記推論対象画像の正偽を推論すること

を特徴とする推論方法。

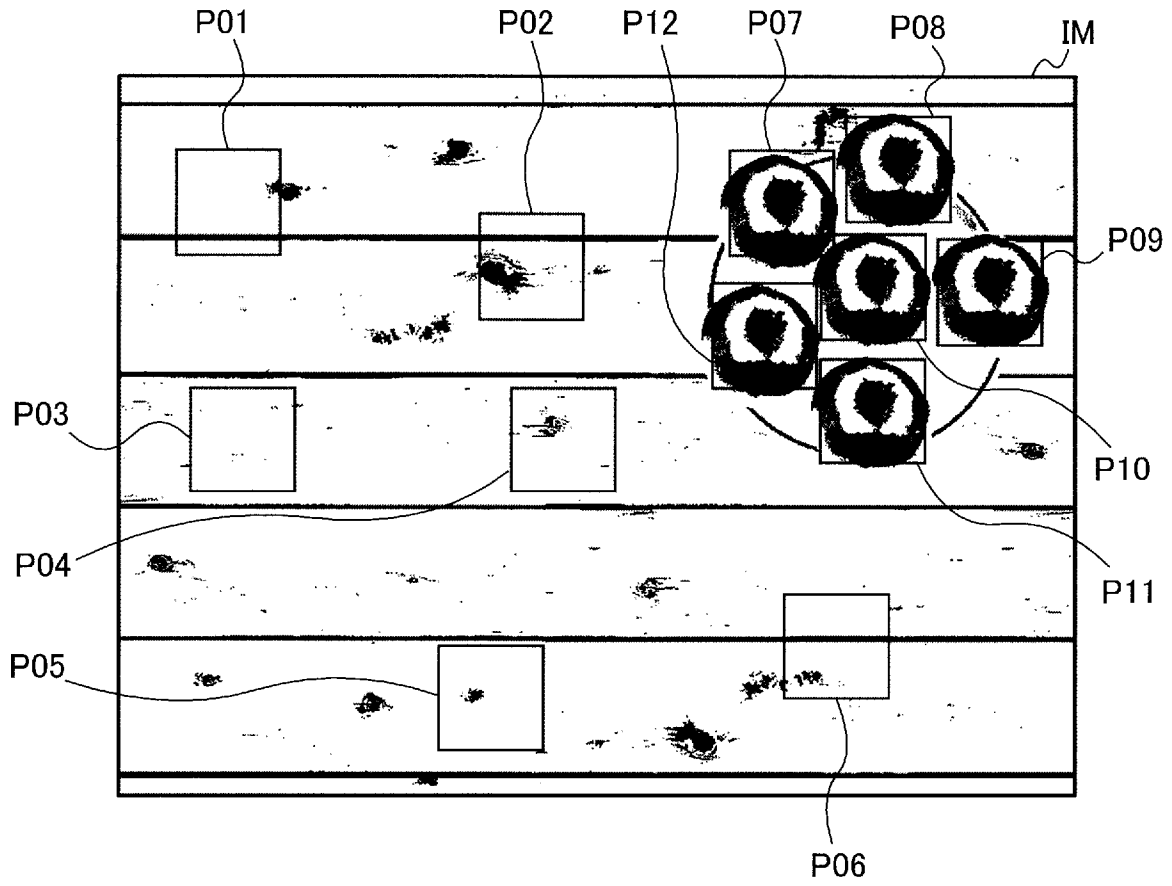
[図1]




[図2]




[図3]




[図4]




[図5]



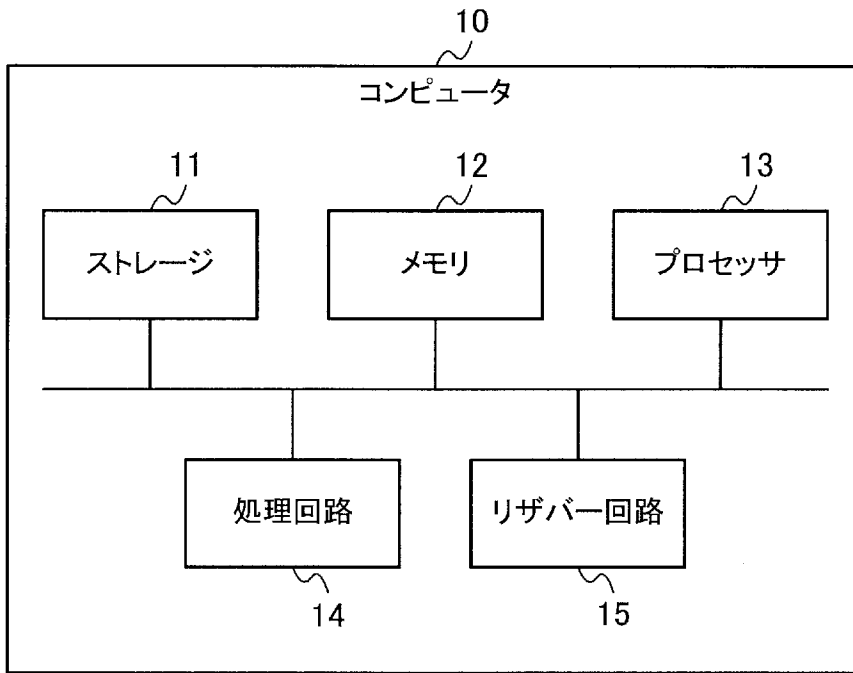
[図6]



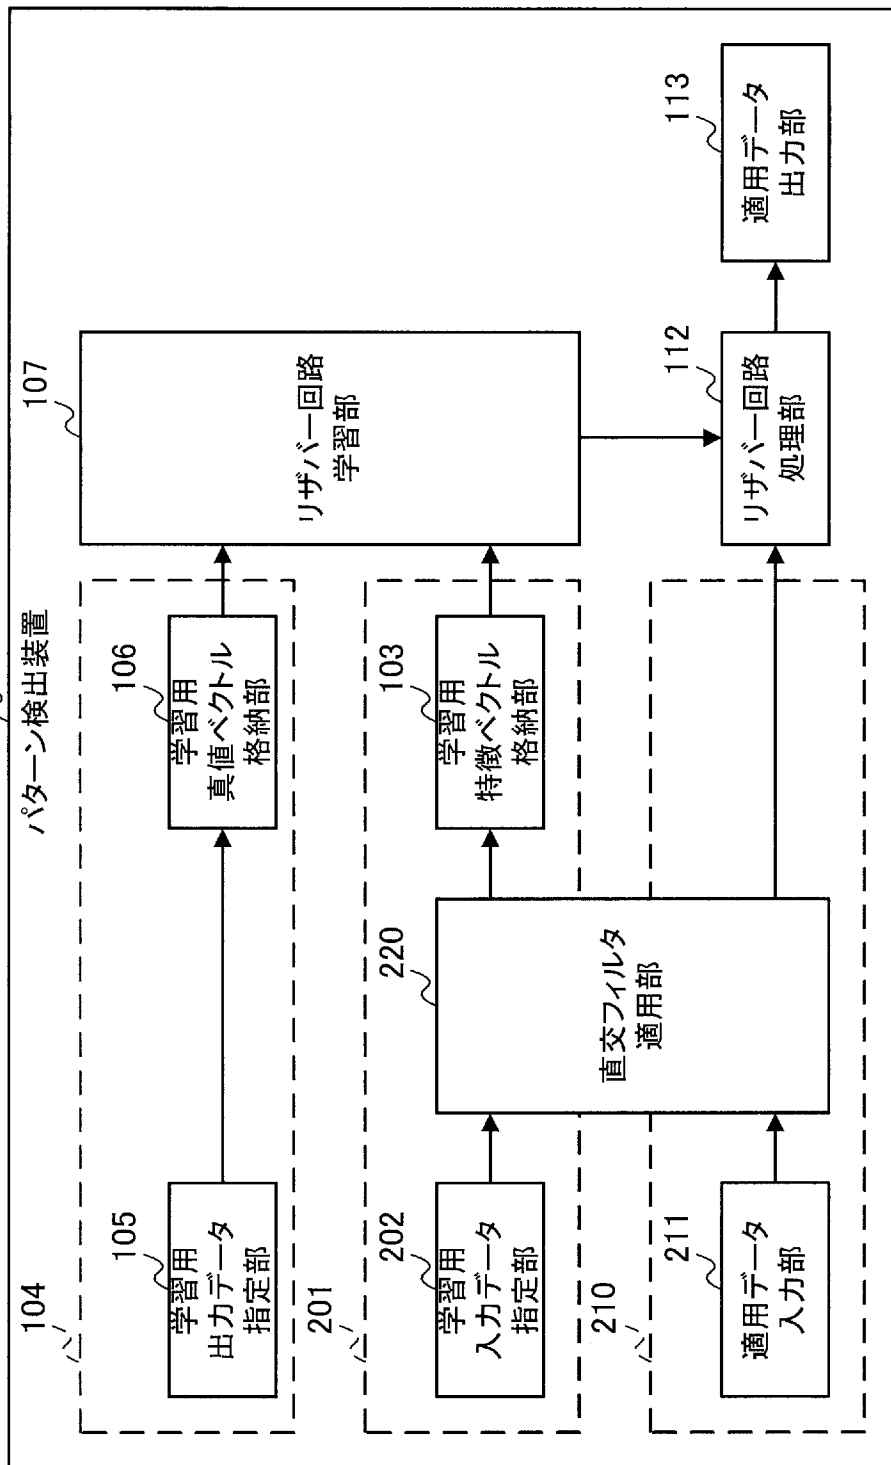
[図7]



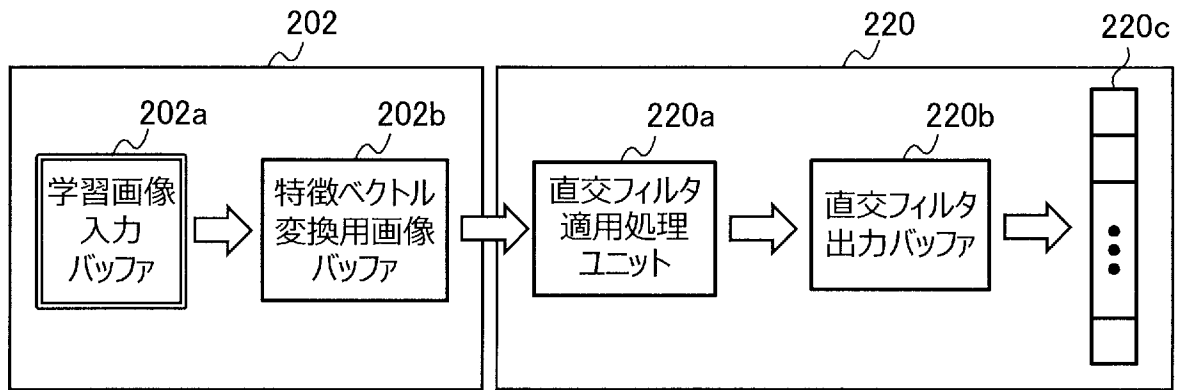
[図8]




[図9]




[図10]



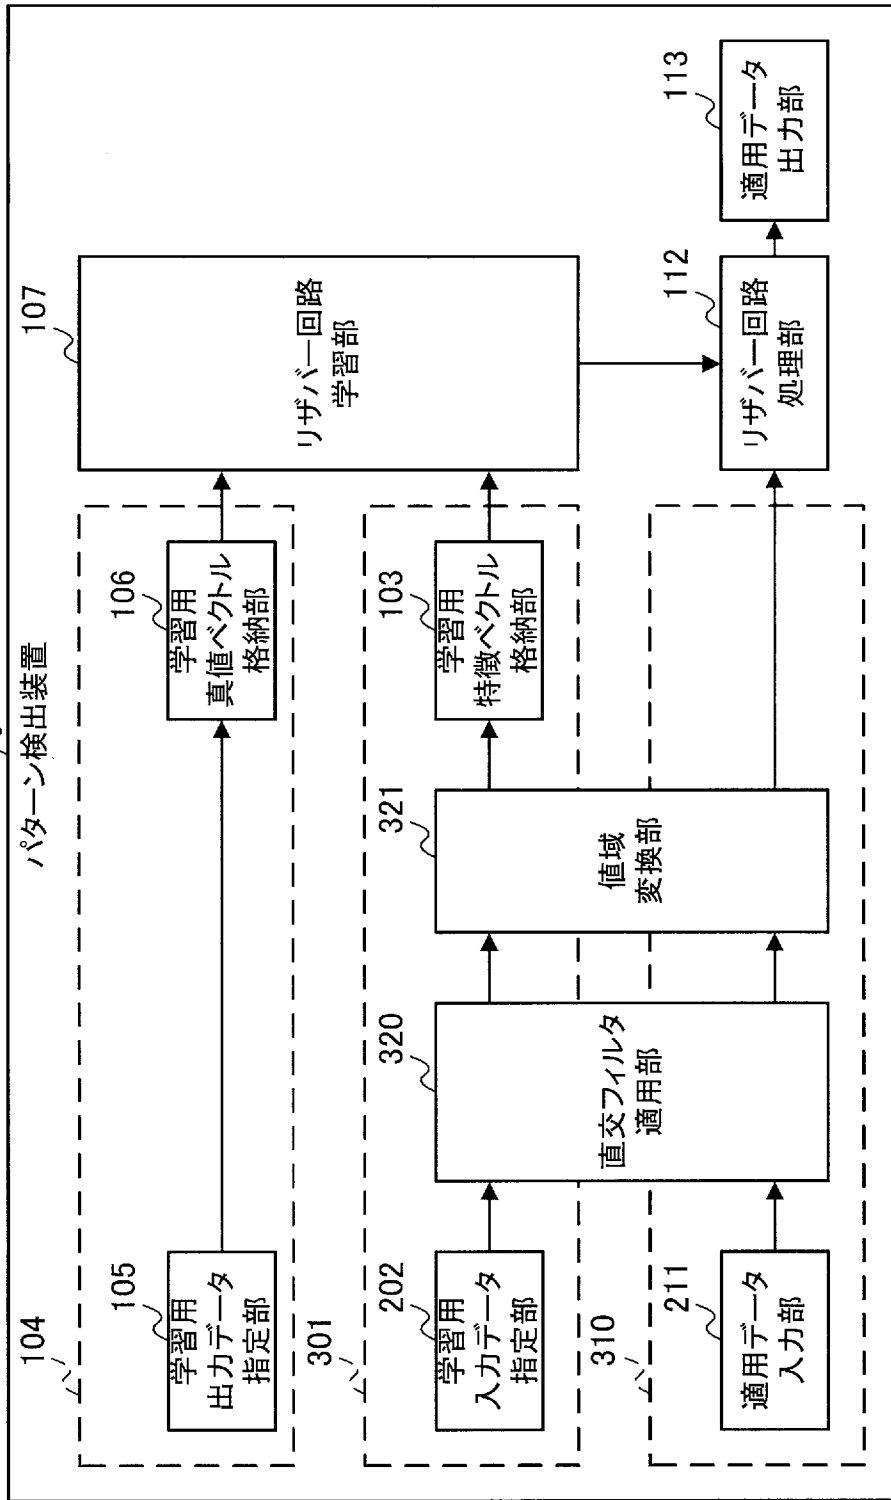
[図11]




[図12]




[図13]




[図14]



[図15]



[図16]



## INTERNATIONAL SEARCH REPORT

International application No.

**PCT/JP2023/030253**

<b>A. CLASSIFICATION OF SUBJECT MATTER</b>		
G06T 7/00(2017.01)i FI: G06T7/00 350C		
According to International Patent Classification (IPC) or to both national classification and IPC		
<b>B. FIELDS SEARCHED</b>		
Minimum documentation searched (classification system followed by classification symbols) G06T7/00		
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 1971-2023 Registered utility model specifications of Japan 1996-2023 Published registered utility model applications of Japan 1994-2023		
Electronic data base consulted during the international search (name of data base and, where practicable, search terms used)		
<b>C. DOCUMENTS CONSIDERED TO BE RELEVANT</b>		
Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
A	JP 2023-87931 A (KYUSHU INST TECH) 26 June 2023 (2023-06-26) paragraphs [0051]-[0059], fig. 9-10	1-14
A	US 2020/0082540 A1 (VOLVO CAR CORPORATION) 12 March 2020 (2020-03-12) paragraph [0044], fig. 2	1-14
A	CN 112686801 A (JINLING INSTITUTE OF TECHNOLOGY) 20 April 2021 (2021-04-20) paragraph [0059], fig. 2	1-14
<input type="checkbox"/> Further documents are listed in the continuation of Box C. <input checked="" type="checkbox"/> 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 <b>17 October 2023</b>		Date of mailing of the international search report <b>31 October 2023</b>
Name and mailing address of the ISA/JP <b>Japan Patent Office (ISA/JP) 3-4-3 Kasumigaseki, Chiyoda-ku, Tokyo 100-8915 Japan</b>		Authorized officer  Telephone No.

**INTERNATIONAL SEARCH REPORT**  
**Information on patent family members**

International application No.

**PCT/JP2023/030253**

Patent document cited in search report			Publication date (day/month/year)	Patent family member(s)	Publication date (day/month/year)
JP	2023-87931	A	26 June 2023	(Family: none)	
US	2020/0082540	A1	12 March 2020	EP 3620976	A1
CN	112686801	A	20 April 2021	(Family: none)	

A. 発明の属する分野の分類（国際特許分類（IPC）） G06T 7/00(2017.01)i FI: G06T7/00 350C		
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）） G06T7/00 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 1971-2023年 日本国実用新案登録公報 1996-2023年 日本国登録実用新案公報 1994-2023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	JP 2023-87931 A (国立大学法人九州工業大学) 26.06.2023 (2023 - 06 - 26) 段落[0051]-[0059], 図9-10	1-14
A	US 2020/0082540 A1 (VOLVO CAR CORPORATION) 12.03.2020 (2020 - 03 - 12) 段落[0044], 図2	1-14
A	CN 112686801 A (JINLING INSTITUTE OF TECHNOLOGY) 20.04.2021 (2021 - 04 - 20) 段落[0059], 図2	1-14
<input type="checkbox"/> C欄の続きにも文献が列挙されている。 <input checked="" type="checkbox"/> 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、一般的な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 17.10.2023	国際調査報告の発送日 31.10.2023	
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） 千葉 久博 5H 3991 電話番号 03-3581-1101 内線 3531	

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/JP2023/030253

引用文献	公表日	パテントファミリー文献	公表日
JP 2023-87931 A	26.06.2023	(ファミリーなし)	
US 2020/0082540 A1	12.03.2020	EP 3620976 A1	
CN 112686801 A	20.04.2021	(ファミリーなし)	