

(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
2020年8月6日(06.08.2020)



(10) 国際公開番号

WO 2020/158032 A1

(51) 国際特許分類:
G06N 3/04 (2006.01)

(21) 国際出願番号: PCT/JP2019/034216

(22) 国際出願日: 2019年8月30日(30.08.2019)

(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 2019-011981 2019年1月28日(28.01.2019) JP

(71) 出願人: 日本電信電話株式会社 (NIPPON TELEGRAPH AND TELEPHONE CORPORATION) [JP/JP]; 〒1008116 東京都千代田区大手町一丁目5番1号 Tokyo (JP).

(72) 発明者: 村田 伸(MURATA, Shin); 〒1808585 東京都武蔵野市緑町三丁目9番11号 NTT 知的財産センタ内 Tokyo (JP). 小泉 悠馬 (KOIZUMI, Yuma); 〒1808585 東京都武蔵野市

緑町三丁目9番11号 NTT 知的財産センタ内 Tokyo (JP). 原田 登(HARADA, Noboru); 〒1808585 東京都武蔵野市緑町三丁目9番11号 NTT 知的財産センタ内 Tokyo (JP).


(74) 代理人: 中尾 直樹, 外 (NAKAO, Naoki et al.); 〒1600022 東京都新宿区新宿三丁目1番22号 新宿NSOビル6階 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, JP, KE, KG, KH, KN, KP, KR, KW, KZ, LA, LC, LK, LR, LS, LU, LY, MA, MD, ME, MG, MK, MN, MW, MX, MY, MZ, NA, NG, NI, NO, NZ, OM, PA, PE, PG, PH, PL, PT, QA, RO, RS, RU, RW, SA, SC, SD, SE, SG, SK, SL,

(54) Title: ESTIMATION DEVICE, LEARNING DEVICE, METHOD FOR THESE, AND PROGRAM

(54) 発明の名称: 推定装置、学習装置、それらの方法、およびプログラム

【図7】



220 Estimation unit
AA Observed quantity
BB State
CC Sequential data

(57) Abstract: This estimation device comprises: a state estimation unit which estimates a state from an observed quantity using an encoder; an observed quantity estimation unit which estimates an observed quantity from a state using a decoder; and a future observed quantity estimation unit which estimates a future observed quantity, which is the value of an observed quantity that has changed due to a time transition, using a parameter K that represents a time development. The parameters of the encoder, the parameters of the decoder, and the parameter K are optimized at the same time.

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))

(57) 要約: 推定装置は、エンコーダを用いて、観測量から状態を推定する状態推定部と、デコーダとを用いて、状態から観測量を推定する観測量推定部と、時間展開を表すパラメータKを用いて、観測量が時間推移により変動した値である未来観測量を推定する未来観測量推定部と、を有し、エンコーダのパラメータと、デコーダのパラメータと、パラメータKとは、同時に最適化されたものである。

明 細 書

発明の名称：

推定装置、学習装置、それらの方法、およびプログラム

技術分野

[0001] 本発明は、状態空間モデルを用いて観測量から状態を推定する推定装置、学習装置、それらの方法、およびプログラムに関する。

背景技術

[0002] 系列データから対象の性質を解析するために、状態空間モデルと呼ばれる枠組みが広く用いられている。状態空間モデルは、観測できない隠れた「状態モデル」と観測した結果である「観測モデル」からなり、状態と呼ばれる量が時間発展し、それらの状態から観測過程を通じて観測量（たとえば電流・音圧・画像などの「量」）の系列データが生成されると考えるモデルである。

[0003] 状態は非線形で時間推移（時間発展）するものであり、観測量は状態の時間推移に伴い非線形で時間推移する観測処理を行うことで得る（観測過程を通じて得る）ことができるものである。観測過程と時間発展の非線形性から、事前の仮定なしに状態空間モデルを観測量だけからすべて学習することは困難である。一方、近年研究が進んでいるKoopmanモード分解と呼ばれる手法は、状態空間モデルを別の領域（関数空間）で考えることにより、上述の非線形性を回避することが可能である（非特許文献1、2参照）。

先行技術文献

非特許文献

[0004] 非特許文献1: Matthew O. Williams, Clarence W. Rowley, and Ioannis G. Kevrekidis., "A Kernel-Based Approach to Data-Driven Koopman Spectral Analysis", Journal of Computational Dynamic, 2:247-265, 2015. arXiv: 1411.2260.

非特許文献2: Matthew O. Williams, Ioannis G. Kevrekidis, and Clarence

W. Rowley., "A Data-Driven Approximation of the Koopman Operator: Extending Dynamic Mode Decomposition", Journal of Nonlinear Science, 25 (6):1307-1346, 2015.

発明の概要

発明が解決しようとする課題

[0005] しかしながら、状態が未知の場合にはKoopmanモード分解を適用できないため、依然として観測量だけから観測過程・時間発展・状態の全てを学習することはできない。

[0006] 本発明は、観測量だけから観測過程・時間発展・状態を学習する学習装置、観測量だけから学習した観測過程・時間発展・状態を用いて、観測量から状態を推定する推定装置、それらの方法、およびプログラ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

[0007] 上記の課題を解決するために、本発明の一態様によれば、推定装置は、エンコーダを用いて、観測量から状態を推定する状態推定部と、デコーダを用いて、状態から観測量を推定する観測量推定部と、時間展開を表すパラメータ K を用いて、観測量が時間推移により変動した値である未来観測量を推定する未来観測量推定部と、を有し、エンコーダのパラメータと、デコーダのパラメータと、パラメータ K とは、同時に最適化されたものである。

発明の効果

[0008] 本発明によれば、観測量だけから観測過程・時間発展・状態を学習することができる。また、観測量だけから学習した観測過程・時間発展・状態を用いて、観測量から状態を推定することができるという効果を奏する。

図面の簡単な説明

[0009] [図1]第一実施形態の概要を示す図。

[図2]図2 Aは従来技術の空間状態モデルを説明するための図、図2 Bは第一実施形態のオートエンコーダの枠組みを説明するための図。

[図3]第一実施形態に係る推定システムの構成例を示す図。

[図4]第一実施形態に係る学習装置の機能ブロック図。

[図5]第一実施形態に係る学習装置の処理フローの例を示す図。

[図6]学習段階のアルゴリズムを説明するための図。

[図7]第一実施形態に係る推定装置の機能ブロック図。

[図8]第一実施形態に係る推定装置の処理フローの例を示す図。

[図9]推定段階のアルゴリズムを説明するための図。

[図10]実際に画像データに基づくデータの系列データを入力としてパラメータを学習し、系列データの生成を行なった例を示す図。

[図11]状態に対応する観測量を予測するアルゴリズムを説明するための図。

[図12]第二実施形態に係る異常検知装置の機能ブロック図。

[図13]第二実施形態に係る異常検知装置の前処理の処理フローの例を示す図。

[図14]第二実施形態に係る異常検知装置の異常検知処理の処理フローの例を示す図。

[図15]第三実施形態の概要を示す図。

[図16]第三実施形態に係る学習装置の機能ブロック図。

[図17]第三実施形態に係る推定装置の推定部の機能ブロック図。

[図18]第三実施形態に係る推定装置の推定部の処理フローの例を示す図。

発明を実施するための形態

[0010] 以下、本発明の実施形態について、説明する。なお、以下の説明に用いる図面では、同じ機能を持つ構成部や同じ処理を行うステップには同一の符号を記し、重複説明を省略する。以下の説明において、テキスト中で使用する記号「 $\wedge$ 」等は、本来直後の文字の真上に記載されるべきものであるが、テキスト記法の制限により、当該文字の直前に記載する。式中においてはこれらの記号は本来の位置に記述している。また、ベクトルや行列の各要素単位で行われる処理は、特に断りが無い限り、そのベクトルやその行列の全ての要素に対して適用されるものとする。

[0011] <第一実施形態のポイント>

本実施形態は、時間発展と観測過程だけでなく、同時に観測過程の「逆関数」を学習することで、観測量だけから観測過程・時間発展・状態の全てを学習することを可能とする。具体的にはオートエンコーダネットワーク(参考文献1 参照)を用いる。

(参考文献1) G. E. Hinton, "Reducing the Dimensionality of Data with Neural Networks", Science, 313(5786):504-507, July 2006.

[0012] オートエンコーダはある入力をエンコーダと呼ばれるネットワークで低次元に変換し、デコーダと呼ばれるネットワークで復元する。ここで、エンコーダを「逆関数」、デコーダを観測過程とみなすことで、両方を同時に学習可能としたことが本実施形態の基礎技術である。上述したように、状態空間モデルは、時間経過で変化するかつ観測不能な状態から観測量を推定する観測モデルと、時間経過で変化する状態を推定する状態モデルからなる。つまり、状態空間モデルは状態から観測量を推定することが前提となる。しかしながら、前述したように状態が未知である場合にはそのようなモデルを構築することができないため、オートエンコーダの枠組みを利用し、エンコーダを観測量から状態を推定するモデルとし、デコーダを状態から観測量を推定するモデルとして学習することで、状態から観測量を推定するモデルの構築を可能とした。入出力を逆転させたモデルを学習するように構築したと言い換えてもよい。

[0013] 以下で本実施形態の基礎技術の説明をする。

[0014] 状態 x_t を考える。このとき状態は抽象・具体を問わない。状態は次のように時間発展する。

$$x_{t+1} = f(x_t) \quad (1)$$

この状態 x_t から、観測量 y_t が観測過程、

$$y_t = g(x_t) \quad (2)$$

を通じて得られる。このとき、観測量は何らかの方法で数値化されるもの（たとえば電流電圧、温度、音圧、画像など）であり、マイクロホンアレイで

得られるような多次元データでもよい。

[0015] 状態空間モデルの枠組みにおける目標は、観測量の系列データ $\{y_1, \dots, y_T\}$ が得られたときに、

- ・ 状態の系列データ $\{x_1, \dots, x_T\}$
- ・ 時間発展の関数 $f(x_t)$
- ・ 観測過程の関数 $g(x_t)$

を決定することである。

[0016] ただし、観測量だけから状態空間モデルをすべて決めるのは一般には難しい。これは、時間発展 $f(x_t)$ と観測過程 $g(x_t)$ が一般に非線形であり、事前知識なしに定めることが困難なことが一因である。

[0017] Koopmanモード分解は、前述の非線形性を回避可能な手法である。

(Koopmanモード分解)

基底関数

[0018] [数1]

$$\Psi(x) \equiv [\psi_1(x), \dots, \psi_r(x), \dots]$$

[0019] で観測過程の関数を

[0020] [数2]

$$g(x_t) = \sum_{r=1}^{\infty} b_r \psi_r(x_t) = B\Psi(x_t) \quad (3)$$

[0021] のように展開する。このとき、Koopman作用素の考え方をを用いると、基底関数の時間発展は

$$\Psi(x_{t+1}) = \Psi(f(x_t)) = K\Psi(x_t) \quad (4)$$

のように書き直すことができる。

[0022] まとめると適切な変換 $z_t = \Psi(x_t)$ を用いて（無限次元の）関数空間上で議論をすることで、元の状態空間モデル

[0023] [数3]

$$\begin{cases} x_{t+1} = f(x_t) \\ y_t = g(x_t) \end{cases} \quad (5)$$

[0024] が、線形の状態空間モデル

[0025] [数4]

$$\begin{cases} z_{t+1} = Kz_t \\ y_t = Bz_t \end{cases} \quad (6)$$

[0026] と書き直せる。

[0027] 前述の通り、状態空間モデルでは時間発展と観測過程の非線形性から、事前情報なしに生成モデルを学習することは困難である。一方、Koopmanモード分解は、上記の非線形性を、関数空間上で議論することで回避することが可能である。しかし、Koopmanモード分解は、状態 x_t が既知な場合に適用可能である。そのため、Koopmanモード分解を用いても、観測量の系列データだけから、時間発展・観測過程・状態を学習することは困難である。

[0028] そこで本実施形態では、Koopmanモード分解の枠組みに基づく、新たな状態推定手法を考案する。本実施形態を用いることで、観測量の系列データだけから、時間発展・観測過程・状態のすべてを同時に学習することが可能となる。

[0029] (基本的なアイデア)

図1に本実施形態の概要を記載している。観測量の系列データ $\{y_t\}$ を入力とし、状態 x_t 、観測過程 (Ψ, B) 、時間発展 K を学習する。学習後はある観測量 y_t から予測した観測量の系列データ $\hat{y}_1^{(t)}, \hat{y}_2^{(t)}, \dots$ や状態 x_t を出力する。

[0030] 状態 x_t から観測量 $\hat{y}_t$ は

[0031] [数5]

$$\begin{cases} \hat{z}_t = \Psi(x_t) \\ \hat{y}_t = B\hat{z}_t \end{cases} \quad (7)$$

[0032] と生成されるので、現在の観測量 y_t から状態 x_t を推定するには上記の逆問題を解く必要がある。すなわち、

[0033] [数6]

$$\begin{cases} z_t = B^{-1}(y_t) \\ x_t = \Psi^{-1}(z_t) \end{cases} \quad (8)$$

[0034] である。 $B^{-1}(\cdot)$ は B の擬似逆行列や、Ridge回帰で解析的に求めることができる。一方で、基底関数 $\Psi(\cdot)$ の逆関数 $\Psi^{-1}(\cdot)$ は一般に求めることは困難である。ここで、逆関数・基底関数・状態を決めるためにオートエンコーダネットワークの枠組みを利用した実装例を説明する。オートエンコーダネットワークはデータの次元削減に使われるニューラルネットワークであり、エンコーダを通して入力が入力層に写され、デコーダを通じて復元される。すなわち、

[0035] [数7]

$$\begin{cases} x = \Phi^{-1}(z; w_{enc}) \\ z = \Phi(x; w_{dec}) \end{cases} \quad (9)$$

[0036] である。ここで、エンコーダ Φ^{-1} を基底関数の逆関数 $\Psi^{-1}(\cdot)$ 、デコーダ Φ を基底関数 $\Psi(\cdot)$ とみなす。

[0037] 別の言い方をすると、従来技術では、状態 x_t を基底で $\hat{z}_t$ に変換し、 $\hat{z}_t$ と係数 B から予測した観測量 $\hat{y}_t$ を導くような空間状態モデルになるよう、時間経過に応じて線形変換されるような基底を得ていた(図1、図2A参照)。一方、本実施形態では、観測量 y_t を入力し状態 x_t を出力するエンコーダ、状態 x_t を入力し観測量 $\hat{y}_t$ を出力するデコーダ、となるようオートエンコーダの枠組みを用いて学習する(図1、図2B参照)。

[0038] <第一実施形態>

本実施形態は二段階に分かれている。一つは観測量の時系列データから時間発展と観測過程ならびにその逆関数を学習する段階(以下、学習段階ともいう)である。一つは観測量から状態を取得する段階(以下、状態取得段階ともいう)である。

[0039] 本実施形態に係る状態取得システムは、学習装置100と状態取得装置200とを含む(図3参照)。なお、状態取得装置200は、観測量から状態、または、状態から観測量を推定するので、推定装置200ともいう。同様に、状態取得段階を推定段階、状態取得システムを推定システムともいう。

[0040] 学習装置100により前述の学習段階を実行し、推定装置200により前

述の推定段階を実行する。まず、学習段階について説明する。

[0041] (学習段階)

図4は学習装置100の機能ブロック図を、図5はその処理フローの例を示す。学習装置100は、初期化部110、推定部120、目的関数計算部130、パラメータ更新部140とを含む。

[0042] 学習装置100は、学習用の観測量の系列データ $\{y_t^{(L)}\}$ を入力とし、学習結果であるパラメータ(w_{enc}, w_{dec}, K, B)を出力する。 w_{enc} はエンコーダで用いられるパラメータ(逆関数 Ψ^{-1} のパラメータ)を、 w_{dec} はデコーダで用いられるパラメータ(基底関数 Ψ のパラメータ)を、 K は時間発展を表すパラメータ、 B は展開係数を表す。

[0043] 学習段階は図6のアルゴリズム1のように行われる。学習用の観測量が画像データに基づくデータである例を示す。ここでは、入力データとして画像データに基づくデータからなる系列データ $\{y_t\}$ (e.g. 動画データ)を考える。画像データに基づくデータ y_t は、例えば、各画素の画素値からなる、画素数だけの次元を持つデータでもよいし、画像データから得られる特徴量や動画データから得られる特徴量等でもよい。画像データに基づくデータを入力データとする場合、状態は、観測量 y_t に対応する抽象的な状態を表し、この抽象的な状態が物理的な意味を持つ値(例えば、観測量に比べ低次元の値)となり得る。例えば、状態は、画像データに表れる周期的な模様や物体の大きさや位置に類する量、画像データからなる動画データ内での動体の位相に類する量(周期的に動作する場合)を表す。

[0044] <初期化部110>

初期化部110は、学習に先立ち、推論に用いるパラメータ $w_{enc}^{(k)}, w_{dec}^{(k)}, K^{(k)}, B^{(k)}$ を初期化し(S110)、初期化したパラメータ $w_{enc}^{(0)}, w_{dec}^{(0)}, K^{(0)}, B^{(0)}$ を推定部120に出力する。また、更新回数を示すインデックス k を $k=0$ とする。

[0045] <推定部120>

推定部120は、学習用の観測量の系列データ $\{y_t^{(L)}\}$ と初期化または更新したパラメータ $w_{enc}^{(k)}, w_{dec}^{(k)}, K^{(k)}, B^{(k)}$ を入力とし、(1)基底関数の値の推定(推定値

z_t)、(2)状態の推定(推定値 x_t)、(3)再構成した基底関数の値の推定(推定値 $\hat{z}_t$)、(4)基底関数の予測(予測値 $\hat{z}_\tau^{(t)}$)、(5)観測量の予測(予測値 $\hat{y}_\tau^{(t)}$)を行い(S 1 2 0)、推定値 z_t 、 x_t 、 $\hat{z}_t$ 、予測値 $\hat{z}_\tau^{(t)}$ 、 $\hat{y}_\tau^{(t)}$ を出力する。以下、推定および予測を合わせて推定ともいう。以下、推定の詳細を説明する。

[0046] (1)まず、推定部 1 2 0 は、現在の展開係数 $B^{(k)}$ を用いて基底関数の値 z_t を推定する。すなわち、 $z_t = B^{(k)}(y_t^{(L)})$ である。ここで、 $B^{(k)}(\cdot)$ は回帰問題を解くことを表す。本実施形態ではRidge回帰の問題として $B^{(k)}(\cdot) = (B^{(k)T}B^{(k)} + \sigma I)^{-1}B^{(k)T} \cdot$ とするが、擬似逆行列を用いた通常の線形回帰やLASSOなどのスパース推定アルゴリズムを用いてもよい。ただし、 σ はRidge回帰における所定の重みパラメータである。

[0047] (2)次に、式(9)のニューラルネットワークを用いて、状態の推定を $x_t = \Phi^{-1}(z_t; w_{enc}^{(k)})$ として行う。

[0048] (3)更に、式(9)のニューラルネットワークを用いて、再構成された基底関数の値の推定を $\hat{z}_t = \Phi(x_t; w_{dec}^{(k)})$ として行う。

[0049] (4)次に $\tau = 0, \dots, T$ として、基底関数の値の線形予測を行い、基底関数の値の予測値 $\hat{z}_\tau^{(t)} = K^{(k)} \tau \hat{z}_t$ を得る。

[0050] (5)予測値 $\hat{z}_\tau^{(t)}$ をもとに、観測量の予測値 $\hat{y}_\tau^{(t)} = B^{(k)} \hat{z}_\tau^{(t)}$ を得る。

[0051] <目的関数計算部 1 3 0>

目的関数計算部 1 3 0 は、学習用の観測量の系列データ $\{y_{t+\tau}^{(L)}\}$ と、推定値の系列データ $\{z_{t+\tau}\}$ 、 $\{x_{t+\tau}\}$ 、 $\{\hat{z}_{t+\tau}\}$ 、予測値の系列データ $\{\hat{z}_\tau^{(t)}\}$ 、 $\{\hat{y}_\tau^{(t)}\}$ 、パラメータ $w_{enc}^{(k)}$ 、 $w_{dec}^{(k)}$ を入力とし、目的関数の値 $J(\Theta)$ を計算し(S 1 3 0)、出力する。なお、 Θ はパラメータ $w_{enc}^{(k)}$ 、 $w_{dec}^{(k)}$ 、 $K^{(k)}$ 、 $B^{(k)}$ の集合である。

[0052] (i)まず、観測量の予測誤差を次式により求める。

[0053] [数8]

$$J_1 = E \left[\sum_{\tau=0}^T \delta_\tau \left\| \hat{y}_\tau^{(t)} - y_{t+\tau}^{(L)} \right\|^2 \right]$$

[0054] ただし、 δ_τ は $0 < \delta_\tau < 1$ であり、現時点 t から近い時刻 $t+\tau$ の誤差ほど大きく評価するように設定するための重みパラメータであり、 $E[\cdot]$ は期待値計算を表

す。

[0055] (ii)また、基底関数の予測誤差を次式により求める。

[0056] [数9]

$$J_2 = E \left[\sum_{\tau=0}^T \delta_{\tau} \left\| \hat{z}_{\tau}^{(t)} - z_{t+\tau} \right\|^2 \right]$$

[0057] (iii)また、正則化項として、ニューラルネットワークの重みに対する正則化項 Ω_1 を導入する。なお、 $\Omega_1 = ||w_{enc}^{(k)}||_2^2 + ||w_{dec}^{(k)}||_2^2$ である。

[0058] (iv)また、状態に構造を導入する。本実施形態では滑らかさ $\Omega_2 = E[||x_{t+1} - x_t||_2^2]$ と非ガウス性 $\Omega_3 = E[\log \cosh(x_t)]$ を導入する。ただし、 $\cosh(\cdot)$ は双曲線関数を表す。

[0059] (v)以上の項を重みづけした目的関数 $J(\Theta) = aJ_1 + bJ_2 + p_1\Omega_1 + p_2\Omega_2 + p_3\Omega_3$ の値を求める。ただし、 a, b, p_1, p_2, p_3 は、それぞれ $J_1, J_2, \Omega_1, \Omega_2, \Omega_3$ をどの程度重視するかを決定するためのパラメータであり、実験結果やシミュレーション結果等を用いて適宜設定する。

[0060] <パラメータ更新部140>

パラメータ更新部140は、目的関数 $J(\Theta)$ を受け取り、各パラメータ $w_{enc}^{(k)}, w_{dec}^{(k)}, K^{(k)}, B^{(k)}$ を更新する(S140)。例えば、Back propagationを用いて各パラメータに対する勾配 $\Delta_{\Theta}J$ を計算し、各パラメータ $w_{enc}^{(k)}, w_{dec}^{(k)}, K^{(k)}, B^{(k)}$ を更新する($\Theta^{(k+1)} = \Theta^{(k)} + \Delta_{\Theta}J$)。

[0061] 所定の条件（例えば、所定の回数のループを終えるか、目的関数に変化しなくなる等）を満たさない場合には(S141のnoの場合)、更新したパラメータ $w_{enc}^{(k+1)}, w_{dec}^{(k+1)}, K^{(k+1)}, B^{(k+1)}$ を推定部120に、正則化項 Ω_1 算出用に更新したパラメータ $w_{enc}^{(k+1)}, w_{dec}^{(k+1)}$ を目的関数計算部130に出力し、 $k \leftarrow k+1$ とし、S120～S140を繰り返す。

[0062] 所定の条件を満たす場合には(S141のyesの場合)、パラメータの更新を打ち切り、モデルの学習を終える。最新の各パラメータ $w_{enc}^{(k)}, w_{dec}^{(k)}, K^{(k)}, B^{(k)}$ を学習結果であるパラメータ(w_{enc}, w_{dec}, K, B)として、推定装置200に出力する。

[0063] (推定段階)

図7は推定装置200の機能ブロック図を、図8はその処理フローの例を示す。推定装置200は、推定部220を含む。

[0064] なお、推定装置200は、推定、予測に先立ち、学習装置100から受け取ったパラメータ(w_{enc} , w_{dec} , K , B)を推定部220に設定する。

[0065] (アルゴリズム2)

図9のアルゴリズム2を実行する場合、推定装置200は、観測量 y_t を入力とし、観測量 y_t に対応する状態を推定し、 y_t 以降の観測量の系列データを予測し、推定値 x_t 、予測した系列データ $\{\hat{y}_{\tau}^{(t)}\}$ を出力する。図9のアルゴリズム2では、推定部220に適当な画像データに基づくデータを観測量 y_t として、 T ステップ先の画像データまで予測することができる。例えば、観測量の系列データ $y_t, y_{t+1}, \dots, y_{t+N}$ を入力とし、推定値の系列データ $x_t, x_{t+1}, \dots, x_{t+N}$ と、予測した N 個の系列データ $\{\hat{y}_{\tau}^{(t)}\}, \{\hat{y}_{\tau}^{(t+1)}\}, \dots, \{\hat{y}_{\tau}^{(t+N)}\}$ を出力してもよい。

[0066] <推定部220>

推定部220は、観測量 y_t を入力とし、観測量 y_t に対して所定の処理を行うことで状態を推定する(S220)。本実施形態では、所定の処理は、(1)基底関数の値の推定(推定値 z_t)、(2)状態の推定(推定値 x_t)である。さらに、推定部220は、(3)再構成した基底関数の値の推定(推定値 $\hat{z}_t$)、(4)基底関数の予測(予測値 $\hat{z}_{\tau}^{(t)}$)、(5)観測量の予測(予測値 $\hat{y}_{\tau}^{(t)}$)を行い(S220)、推定値 x_t 、予測値の系列データ $\{\hat{y}_{\tau}^{(t)}\}$ を出力する。

[0067] (1)まず、推定部220は、展開係数 B を用いて基底関数の値 z_t を推定する。すなわち、 $z_t = B^+(y_t)$ である。

[0068] (2)次に、式(9)のニューラルネットワークを用いて、状態の推定を $x_t = \Phi^{-1}(z_t; w_{enc})$ として行う。

[0069] (3)更に、式(9)のニューラルネットワークを用いて、再構成された基底関数の値の推定を $\hat{z}_t = \Phi(x_t; w_{dec})$ として行う。

[0070] (4)次に $\tau = 0, \dots, T$ として、基底関数の値の線形予測を行い基底関数の値の予測値 $\hat{z}_{\tau}^{(t)} = K^{\tau} \hat{z}_t$ を得る。

[0071] (5) 予測値 $\hat{z}_\tau^{(t)}$ をもとに、観測量の予測値 $\hat{y}_\tau^{(t)} = B\hat{z}_\tau^{(t)}$ を得る。

[0072] なお、上述の(3)～(5)の処理は、状態から観測量を得る処理であり、上述の(1), (2)の処理の逆処理と言える。

[0073] 図10は、実際に画像データに基づくデータの系列データを入力としてパラメータを学習し、系列データの生成を行なった例を示す。

[0074] 図10の上段は実際の画像データに基づくデータの系列データ(学習用の観測量の系列データ)である。一方で下段は、上段左端”Input”として与えられた画像データをアルゴリズム2の y_t として入力し、 $\tau=1, \dots, 10$ だけ生成した系列データ(予測した系列データ)である。

[0075] (アルゴリズム3)

図11のアルゴリズム3を実行する場合、推定装置200は、状態 x_t を入力とし、状態 x_t に対応する観測量を予測し、予測した系列データ $\{\hat{y}_\tau^{(t)}\}$ を出力する。図11のアルゴリズム3では、推定部220に適当な状態 x_t を与え、Tステップ先の画像まで予測することができる。

[0076] 推定部220は、ある状態 x_t を入力とし、(1)再構成した基底関数の値の推定(推定値 $\hat{z}_t$)、(2)基底関数の予測(予測値 $\hat{z}_\tau^{(t)}$)、(3)観測量の予測(予測値 $\hat{y}_\tau^{(t)}$)を行い(S220)、予測値の系列データ $\{\hat{y}_\tau^{(t)}\}$ を出力する。

[0077] (1)式(9)のニューラルネットワークを用いて、再構成された基底関数の値の推定を $\hat{z}_t = \Phi(x_t; w_{dec})$ として行う。

[0078] (2)次に $\tau=0, \dots, T$ として、基底関数の値の線形予測を行い、基底関数の値の予測値 $\hat{z}_\tau^{(t)} = K^\tau \hat{z}_t$ を得る。

[0079] (3)予測値 $\hat{z}_\tau^{(t)}$ をもとに、観測量の予測値 $\hat{y}_\tau^{(t)} = B\hat{z}_\tau^{(t)}$ を得る。

[0080] <効果>

学習段階では、観測量だけから観測過程・時間発展・状態を学習することができる。

[0081] 推定段階では、観測量だけから学習した観測過程・時間発展・状態(学習したモデル)を用いて、観測量から状態を推定することができる。また、推定した状態や与えられた状態から観測量を予測することができる。すなわち

、現在の観測量から状態を推定し、時間発展をシミュレートし、その状態を観測することで、系列データを予測できる。また、観測量や状態を与えることで、人工的にデータ（状態、観測量）を生成することができる。

[0082] センサなどで観測される系列データから状態を推定することができ、観測量の分析等に用いることができる。また、視覚的に把握しづらい(例えば次元数が多い)系列データから、(例えば次元数が少ない)状態を推定し、推定した状態を提示することで観測量を視覚的に把握しやすいものに変換する（可視化）ことができる。

[0083] さらに予測した値と実際の観測量との距離を適切に定義することで、系列データの異常検知へと応用することも可能である。

[0084] <変形例>

本実施形態では、観測量が画像データに基づくデータの場合について説明したが、他のデータであってもよい。例えば、音響データに基づくデータ、振動データに基づくデータ、音響データに基づくデータと振動データに基づくデータとの組合せなどが考えられる。以下に、より詳しく説明する。

[0085] （音響データ）

観測量を音響データに基づくデータとした場合、マイクから取れた音圧の波形データまたはその特徴量（STFT や log-Mel power など）を入力 y_t とする。なお、マイクロホンアレイで收音する場合、音圧の波形データまたはその特徴量を素子数分だけ結合したベクトルを入力 y_t とする。

[0086] この場合、状態は、観測量 y_t に対応する抽象的な状態を表し、この抽象的な状態が物理的な意味を持つ値(例えば、観測量に比べ低次元の値)となり得る。例えば、状態は、音源の波形に類する量、音源位置に類する量（音源が動く場合）、位相に類する量（周期的な音の場合）を表す。

[0087] （振動データ）

観測量を振動データに基づくデータとした場合、振動ピックアップから取れた加速度の波形データまたはその特徴量（STFT や log-Mel power など）を入力 y_t とする。複数の振動ピックアップでの収録する場合、波形データや特徴

量を素子数分だけ結合したベクトルを入力とする。

[0088] この場合、状態は、観測量 y_t に対応する抽象的な状態を表し、この抽象的な状態が物理的な意味を持つ値(例えば、観測量に比べ低次元の値)となり得る。例えば、状態は、振動のモードに類する量、位相に類する量(準周期的に動く物体の振動の場合)などを表す。

[0089] (音響・振動データ)

観測量を上述の音響データに基づくデータと振動データに基づくデータとの組合せとした場合、振動ピックアップから取れた加速度の波形データまたはその特徴量とマイクから取れた音圧の波形データまたはその特徴量を素子数分だけ結合したベクトルを入力 y_t とする。

[0090] この場合、状態 x_t は、観測量 y_t に対応する抽象的な状態を表し、この抽象的な状態が物理的な意味を持つ値(例えば、観測量に比べ低次元の値)となり得る。例えば、状態は、音源(振動源)の波形に類する量、振動のモードに類する量などを表す。

[0091] <第二実施形態>

第一実施形態と異なる部分を中心に説明する。

[0092] 本実施形態では、本発明を異常検知に適用する。

[0093] 図12は本実施形態に係る異常検知装置の機能ブロック図を示す。

[0094] まず、第一実施形態で説明した方法により、学習装置100は、学習用の観測量の系列データ $\{y_t^{(L)}\}$ を入力とし、パラメータ(w_{enc} , w_{dec} , K , B)を学習し、出力する。

[0095] 第一実施形態で説明した方法により、推定装置200は、推定、予測に先立ち、学習装置100から受け取ったパラメータ(w_{enc} , w_{dec} , K , B)を推定部220に設定する。

[0096] <異常検知装置300>

異常検知装置300は、誤差ベクトル計算部310と平均分散共分散行列計算部320と検知部330とを含む(図12参照)。

[0097] 異常検知装置300は、異常検知処理と、異常検知処理の前に予めパラメ

ータを求める前処理とを実行する。まず、前処理について説明する。

[0098] <前処理>

まず、正常時の観測量のデータセット $D_{\text{normal}} = \{y_1, y_2, \dots, y_{T-1}\}$ を用意する。ただし、下付き添え字 A_B は A_B を意味する。ここから、系列の長さ L の部分系列 $D_t = \{y_{t+1}, \dots, y_{t+L}\}$ 、 $t=1, 2, \dots, T_1-L$ を取り出す。

[0099] 次に、第一実施形態で説明した方法により、推定装置200は、観測量 y_t を入力とし、 y_t 以降の観測量の系列データを予測し、長さ L の予測した系列データ $P_t = \{\hat{y}^{(t)}_1, \dots, \hat{y}^{(t)}_L\}$ を出力する。

[0100] 図13は前処理の処理フローの例を示す。

[0101] 異常検知処理に先立ち、異常検知装置300は、正常時の観測量のデータセット D_{normal} から得られる T_1-L 個の部分系列 D_t と T_1-L 個の予測した系列データ P_t とを入力とし、後述する平均 μ と分散共分散行列 S とを計算しておく。

[0102] 誤差ベクトル計算部310は、 T_1-L 個の部分系列 $D_t = \{y_{t+1}, \dots, y_{t+L}\}$ と T_1-L 個の系列データ $P_t = \{\hat{y}^{(t)}_1, \dots, \hat{y}^{(t)}_L\}$ とを入力とし、部分系列 $D_t = \{y_{t+1}, \dots, y_{t+L}\}$ と予測した系列データ $P_t = \{\hat{y}^{(t)}_1, \dots, \hat{y}^{(t)}_L\}$ の各要素で誤差を計算し（S310-A）、誤差ベクトル $e_t = [e^{(t)}_1 \dots e^{(t)}_L]^T$ を出力する。なお、 $e^{(t)}_i = y_{t+i} - \hat{y}^{(t)}_i$ 、 $i=1, \dots, L$ である。観測量 y_t を入力としたとき（ここでは、観測量 y_t から予測した系列データ $P_t = \{\hat{y}^{(t)}_1, \dots, \hat{y}^{(t)}_L\}$ と系列データ P_t に対応する部分系列 $D_t = \{y_{t+1}, \dots, y_{t+L}\}$ を入力としたとき）の誤差ベクトルを $e_t = [e^{(t)}_1 \dots e^{(t)}_L]^T$ と定める。このとき、誤差ベクトル e_t は観測量 y_t の次元が D のとき（ $D \times L$ ）の長さのベクトルである。上記の誤差ベクトルの計算を T_1-L 個の部分系列 D_t 及び系列データ P_t すべてに対して計算する。

[0103] 平均分散共分散行列計算部320は、 T_1-L 個の誤差ベクトル $e_t = [e^{(t)}_1 \dots e^{(t)}_L]^T$ を入力とし、平均 μ と分散共分散行列 S を次式により計算し（S320）、検知部330に出力する。

[0104]

[数10]

$$\mu = \frac{1}{T_1 - L} \sum_{t=1}^{T_1-L} e_t$$

[0105] [数11]

$$S = \frac{1}{T_1 - L} \sum_{t=1}^{T_1-L} (e_t - \mu)(e_t - \mu)^T$$

[0106] <異常検知処理>

異常検知の対象となる観測量のデータセット $D_{new}=\{y'_{1}, y'_{2}, \dots, y'_{T_2}\}$ が得られたとき、前処理のときと同様に、系列の長さ L の部分系列 $D'_{t'}=\{y'_{t'+1}, \dots, y'_{t'+L}\}$ 、 $t'=1, 2, \dots, T_2-L$ を取り出す。

[0107] 次に、第一実施形態で説明した方法により、推定装置200は、観測量 $y'_{t'}$ を入力とし、 $y'_{t'}$ 以降の観測量の系列データを予測し、長さ L の予測した系列データ $P'_{t'}=\{\hat{y}'^{(t')}_1, \dots, \hat{y}'^{(t')}_L\}$ を出力する。

[0108] 図14は異常検知処理の処理フローの例を示す。

[0109] 異常検知処理時には、異常検知装置300は、異常検知の対象となる観測量のデータセット D_{new} から得られる T_2-L 個の部分系列 $D'_{t'}$ と T_2-L 個の予測した系列データ $P'_{t'}=\{\hat{y}'^{(t')}_1, \dots, \hat{y}'^{(t')}_L\}$ とを入力とし、部分系列 $D'_{t'}$ と系列データ $P'_{t'}$ に対する検知結果を出力する。なお、系列データ $P'_{t'}$ は観測量 $y'_{t'}$ から予測したものであり、部分系列 $D'_{t'}$ は系列データ $P'_{t'}$ に対応するものなので、部分系列 $D'_{t'}$ と系列データ $P'_{t'}$ に対する検知結果は、観測量 $y'_{t'}$ に対する検知結果といってもよい。

[0110] 誤差ベクトル計算部310は、 T_2-L 個の部分系列 $D'_{t'}=\{y'_{t'+1}, \dots, y'_{t'+L}\}$ と T_2-L 個の系列データ $P_{t'}=\{\hat{y}'^{(t')}_1, \dots, \hat{y}'^{(t')}_L\}$ とを入力とし、部分系列 $D'_{t'}=\{y'_{t'+1}, \dots, y'_{t'+L}\}$ と予測した系列データ $P_{t'}=\{\hat{y}'^{(t')}_1, \dots, \hat{y}'^{(t')}_L\}$ の各要素で誤差を計算し（S310-B）、誤差ベクトル $e'_{t'}=[e'^{(t')}_1 \dots e'^{(t')}_L]^T$ を出力する。なお、 $e'^{(t')}$

$y_i = y'_{t'+i} - \hat{y}'^{(t')}_i, i=1, \dots, L$ である。

[0111] 検知部330は、異常検知に先立ち平均 μ と分散共分散行列 S を受け取っておく。

[0112] 検知部330は、 T_2-L 個の誤差ベクトル $e'_t = [e'^{(t')}_1 \dots e'^{(t')}_L]^T$ を入力とし、平均 μ と分散共分散行列 S と誤差ベクトル e'_t とを用いて、各時刻 $t'=1, \dots, T_2-L$ における以下の異常度合い L_t を計算する（S330-1）。

$$L_t = \log \det(S) + (e'_t - \mu)^T S^{-1} (e'_t - \mu)$$

この異常度合い L_t は誤差ベクトルを正規分布でフィッティングしたときの負の対数尤度に比例する量である。

[0113] 次に、検知部330は、異常度合い L_t に対応する値と閾値 p との大小関係に基づき、異常か否かを判定し、異常を検知し（S330-2）、検知結果を出力する。例えば、異常度合い $L_t > p$ のとき異常と判定し、 $L_t \leq p$ のとき異常ではないと判定する。閾値 p は、実験やシミュレーション等により予め適切にさだめておく。

[0114] 以上の構成により、本発明を異常検知に適用することができる。

[0115] <第三実施形態>

第一実施形態と異なる部分を中心に説明する。

[0116] 第一実施形態では、状態 x_t から観測量の予測(予測値 $\hat{y}_t^{(t)}$)を出力する関数に逆関数が存在する場合を検討している。しかし、例えば、状態 x_t が観測量の予測(予測値 $\hat{y}_t^{(t)}$)より低次元な場合、観測量 y_t から状態 x_t を推定する逆関数が存在するかは定かではない。

[0117] また、基底関数の値 z_t の次元より観測量 y_t の次元が少ない場合、観測量 y_t から基底関数の値 z_t を定める問題は劣決定問題であり、適切に正則化項を導入する必要がある。

[0118] そこで、本実施形態では、生成モデルを考えることで、逆関数を考えることなく観測量から状態を推定する。図15に提案するモデルを示す。図15の右(破線部分)がKoopmanモード分解の数値計算手法である拡張動的モード分解(EDMD)部分を表す。

[0119] まず、観測量 y_t と y_{t+1} からニューラルネットワークを用いて平均と分散パラメータを推定する($(\sigma_t, \mu_t) \leftarrow \Psi(y_t, y_{t+1})$)。この処理が変分オートエンコーダのエンコードに相当し、この処理を実現する部分をエンコーダと呼ぶ。

[0120] 次に、得られた平均の推定値 μ_t と分散パラメータの推定値 σ_t に従う多変量正規分布から潜在変数(状態 x_t)をサンプリングする。なお、図中の e_t は平均0, 分散1の正規分布から得られる乱数である。

[0121] 以降の処理は第一実施形態と同様である。以下に概略を説明する。

[0122] (3)再構成した基底関数の値の推定(推定値 $\hat{z}_t \leftarrow \Psi(x_t)$)、(4)基底関数の予測(予測値 $\hat{z}_\tau^{(t)} = K^\tau \hat{z}_t$)、(5)観測量の予測(予測値 $\hat{y}_\tau^{(t)} = B \hat{z}_\tau^{(t)}$)を行い、推定値 x_t 、予測値の系列データ $\{\hat{y}_\tau^{(t)}\}$ を出力する。状態 x_t から観測量の予測値 $\hat{y}_\tau^{(t)}$ を得る処理が変分オートエンコーダのデコードに相当し、この処理を実現する部分をデコーダと呼ぶ。

[0123] 通常の変分オートエンコーダは、ニューラルネットワークの重みパラメータ θ を次の目的関数を最小化するように学習する。

[0124] [数12]

$$\begin{aligned} L(\theta) &= \sum_{\tau=0}^T \left(\|y_{t+\tau} - \Psi_{\theta}(x_{t+\tau})\|^2 \right. \\ &\quad \left. + KL[N(\mu_{\theta}(y_{t+\tau}), \Sigma_{\theta}(y_{t+\tau}) | N(0, I)) \right] \end{aligned}$$

[0125] ただし、 $KL[A|B]$ は分布A、BのKullback-Leibler divergenceを表し、 $N(\mu, \sigma)$ は平均 μ 、分散 σ の分布を表し、 $\mu_{\theta}(y_t)$ 、 $\Sigma_{\theta}(y_t)$ はそれぞれ重みパラメータ θ のニューラルネットワークに観測量 $y_{t+\tau}$ を与えて推定した平均、分散パラメータを表す。

[0126] 一方、本実施形態の変分オートエンコーダでは展開係数B、パラメータKも重みパラメータ θ と同時に学習し、最適化する。すなわち、

[0127]

[数13]

$$L(B, K, \theta) = E \left[\sum_{\tau=0}^T \left\| y_{t+\tau} - \hat{y}_{\tau}^{(t)} \right\|^2 + KL \left[N(\mu_{\theta}(y_t, y_{t+1}), \Sigma_{\theta}(y_t, y_{t+1})) | N(0, I) \right] \right]$$

[0128] を最小化する。ただし、 $\hat{y}_{\tau}^{(t)} = BK^{\tau} \hat{z}_t$ であり、 $\mu_{\theta}(y_{t+\tau}, y_{t+\tau+1})$ 、 $\Sigma_{\theta}(y_{t+\tau}, y_{t+\tau+1})$ はそれぞれ重みパラメータ θ のニューラルネットワークに観測量 $y_{t+\tau}, y_{t+\tau+1}$ を与えて推定した平均、分散パラメータを表す。第一実施形態と本実施形態との差分としては次の二点が挙げられる。

[0129] 第一実施形態は逆関数を仮定していたが、本実施形態は確率的な生成モデルを仮定している。

[0130] 第一実施形態では再構成誤差を目的関数として最小化していたが、本実施形態は再構成誤差に分布の近さを測るKullback-Leibler divergence 項が追加されている。

[0131] 以下、本実施形態を実現する推定システムについて説明する。

[0132] 本実施形態に係る推定システムは、学習装置100と推定装置200とを含む(図3参照)。

[0133] 学習装置100により学習段階を実行し、推定装置200により推定段階を実行する。まず、学習段階について説明する。

[0134] (学習段階)

図16は学習装置100の機能ブロック図を、図5はその処理フローの例を示す。学習装置100は、初期化部110、推定部120、目的関数計算部130、パラメータ更新部140とを含む。

[0135] 学習装置100は、学習用の観測量の系列データ $\{y_t\}$ を入力とし、学習結果であるパラメータ(w_{enc}, w_{dec}, K, B)を出力する。 w_{enc} はエンコーダで用いられるパラメータを、 w_{dec} はデコーダで用いられるパラメータ(基底関数 ψ のパラメータ)を、 K は時間発展を表すパラメータ、 B は展開係数を表す。

[0136] 学習段階は以下のように行われる。

[0137] 初期化部 1 1 0 およびパラメータ更新部 1 4 0 の処理内容は第一実施形態と同様なので、説明を省略する。ただし、パラメータ更新部 1 4 0 では、目的関数 $J(\Theta^{(k)})$ に代えて、目的関数 $L(B^{(k)}, K^{(k)}, \theta^{(k)})$ を受け取り、処理を行う。

[0138] <推定部 1 2 0>

推定部 1 2 0 は、学習用の観測量の系列データ $\{y_t\}$ と初期化または更新したパラメータ $w_{\text{enc}}^{(k)}, w_{\text{dec}}^{(k)}, K^{(k)}, B^{(k)}$ を入力とし、(1)状態の平均と分散パラメータの推定(推定値 σ_t, μ_t)、(2)状態の推定(推定値 x_t)、(3)再構成した基底関数の値の推定(推定値 $\hat{z}_t$)、(4)基底関数の予測(予測値 $\hat{z}_\tau^{(t)}$)、(5)観測量の予測(予測値 $\hat{y}_\tau^{(t)}$)を行い(S 1 2 0)、予測値 $\hat{y}_\tau^{(t)}$ を出力する。(3)~(5)は第一実施形態と同様なので、(1), (2)について説明する。

[0139] (1)まず、推定部 1 2 0 は、学習用の観測量の系列データ $\{y_t\}$ と現在のパラメータ $w_{\text{enc}}^{(k)}$ とからニューラルネットワークを用いて、状態の平均と分散パラメータとを推定する。すなわち、 $(\sigma_t, \mu_t) = \tilde{\Psi}(y_t; w_{\text{enc}}^{(k)})$ である。なお、本実施形態では、ニューラルネットワークを用いるため、入力を2つ以上の学習用の観測量 y_t としてもよい。例えば、 $(\sigma_t, \mu_t) = \tilde{\Psi}(y_t, y_{t+1}; w_{\text{enc}}^{(k)})$ として、2つの学習用の観測量 y_t, y_{t+1} から状態の平均と分散パラメータとを推定してもよい。このように、2つ以上の学習用の観測量を用いて状態の平均と分散パラメータとを推定することで、状態の特徴をより捉えやすくなると考えられる。

[0140] (2)次に、 (σ_t, μ_t) に従う多変量正規分布から状態 x_t をサンプリングする。

[0141] <目的関数計算部 1 3 0>

目的関数計算部 1 3 0 は、学習用の観測量の系列データ $\{y_{t+\tau}\}$ と、予測値の系列データ $\{\hat{y}_\tau^{(t)}\}$ 、パラメータ $w_{\text{enc}}^{(k)}$ を入力とし、目的関数の値 $L(B^{(k)}, K^{(k)}, \theta^{(k)})$ を計算し(S 1 3 0)、出力する。なお、 $\theta^{(k)}$ はパラメータ $w_{\text{enc}}^{(k)}, w_{\text{dec}}^{(k)}$ の集合である。

[0142] [数14]

$$L(B, K, \theta) = E \left[c \sum_{\tau=0}^T \|y_{t+\tau} - \hat{y}_\tau^{(t)}\|^2 + dKL[N(\mu_\theta(y_t, y_{t+1}), \Sigma_\theta(y_t, y_{t+1})) | N(0, I)] \right]$$

[0143] ただし、 $\hat{y}_\tau^{(t)} = B^{(k)} K^{(k)} \tau \hat{z}_t$ である。なお、ここでは、 $K^{(k)}$ を同時に更新するために、すくなくとも2つ以上の時系列の観測量 y_τ と $y_{\tau+1}$ とを必要とし、 T は1以上の整数の何れかとする。 c, d は、各項をどの程度重視するかを決定するためのパラメータであり、実験結果やシミュレーション結果等を用いて適宜設定する。

[0144] (推定段階)

図7は推定装置200の機能ブロック図を、図8はその処理フローの例を示す。推定装置200は、推定部220を含む。

[0145] なお、推定装置200は、推定、予測に先立ち、学習装置100から受け取ったパラメータ(w_{enc}, w_{dec}, K, B)を推定部220に設定する。

[0146] (観測量から状態を推定し、観測量を予測)

観測量から状態を推定し、観測量を予測する場合(第一実施形態のアルゴリズム2の場合)、推定装置200は、観測量 y_t を入力とし、観測量 y_t に対応する状態を推定し、 y_t 以降の観測量の系列データを予測し、推定値 x_t 、予測した系列データ $\{\hat{y}_\tau^{(t)}\}$ を出力する。例えば、観測量の系列データ $y_t, y_{t+1}, \dots, y_{t+N}$ を入力とし、推定値の系列データ $x_t, x_{t+1}, \dots, x_{t+N}$ と、予測したN個の系列データ $\{\hat{y}_\tau^{(t)}\}, \{\hat{y}_\tau^{(t+1)}\}, \dots, \{\hat{y}_\tau^{(t+N)}\}$ を出力してもよい。

[0147] <推定部220>

推定部220は、観測量 y_t を入力とし、観測量 y_t に対して所定の処理を行うことで状態を推定する(S220)。本実施形態では、所定の処理は、状態の平均と分散パラメータの推定(推定値 σ_t, μ_t)、(2)状態の推定(推定値 x_t)である。さらに、推定部220は、(3)再構成した基底関数の値の推定(推定値 $\hat{z}_t$)、(4)基底関数の予測(予測値 $\hat{z}_\tau^{(t)}$)、(5)観測量の予測(予測値 $\hat{y}_\tau^{(t)}$)を行い(S220)、推定値 x_t 、予測値の系列データ $\{\hat{y}_\tau^{(t)}\}$ を出力する。(3)~(5)は第一実施形態と同様なので、(1), (2)について説明する。

[0148] (1)まず、推定部220は、観測量 y_t とパラメータ w_{enc} とからニューラルネットワークを用いて、状態の平均と分散パラメータとを推定する。すなわち、(σ_t, μ_t)= $\Psi(y_t; w_{enc})$ である。なお、本実施形態では、入力を2つ以上の観測量

y_t としてもよく、学習装置100で学習したニューラルネットワークに対応する個数の観測量 y_t を入力とする。

[0149] (2)次に、 (σ_t, μ_t) に従う多変量正規分布から状態 x_t をサンプリングする。

[0150] (観測量から観測量を予測)

観測量から観測量を予測する場合(第一実施形態のアルゴリズム3の場合)、第一実施形態と同様である。

[0151] <効果>

第一実施形態と同様の効果を得ることができる。生成モデルを考えることで、逆関数を考えることなく状態を推定する。なお、本実施形態と第一実施形態の変形例や第二実施形態を組合せてもよい。

[0152] <その他>

第一実施形態および第三実施形態の推定部220を図17の機能ブロック図で表現することもできる。図18は推定部220の処理フローの例を示す。

[0153] 推定部220は、状態推定部221と、観測量推定部222と、未来観測量推定部223とを有する。さらに観測量推定部222は、中間値推定部222Aと、中間観測値推定部222Bとを含む。状態推定部221では、第一実施形態と第三実施形態とにおける処理内容が異なる。観測量推定部222および未来観測量推定部223では、第一実施形態と第三実施形態とにおける処理内容が同じである。

[0154] (状態推定部221)

状態推定部221は、オートエンコーダのエンコーダを用いて、観測量から状態を推定し(S221)、出力する。

[0155] 第一実施形態では、状態推定部221は、推定処理に先立ちニューラルネットワークのパラメータ w_{enc} 、展開係数 B を受け取る。状態推定部221は、観測量 y_t を入力とし、展開係数 B を用いて基底関数の値 z_t を推定する。すなわち、 $z_t=B^+(y_t)$ である。さらに、式(9)のニューラルネットワークを用いて、状態の推定を $x_t=\Phi^{-1}(z_t;w_{enc})$ として行う。

[0156] 第三実施形態では、状態推定部 2 2 1 は、推定処理に先立ちニューラルネットワークのパラメータ w_{enc} を受け取る。状態推定部 2 2 1 は、1 つ以上の観測量 y_t を入力とし、1 つ以上の観測量 y_t とパラメータ w_{enc} とからニューラルネットワークを用いて、状態の平均と分散パラメータとを推定する。例えば、2 つの観測量 y_t, y_{t+1} から $(\sigma_t, \mu_t) = \tilde{\Psi}(y_t, y_{t+1}; w_{enc})$ として、状態の平均と分散パラメータとを推定する。次に、状態推定部 2 2 1 は、 (σ_t, μ_t) に従う多変量正規分布からサンプリングすることで状態 x_t を推定する。

[0157] (観測量推定部 2 2 2)

観測量推定部 2 2 2 は、オートエンコーダのデコーダとを用いて、状態から観測量を推定し (S 2 2 2)、出力する。

[0158] なお、第一実施形態の場合、状態推定部 2 2 1 が行う処理を第一の関数で、観測量推定部 2 2 2 が行う処理を第二の関数で定義され、第一の関数は第二の関数の逆関数である。

[0159] (中間値推定部 2 2 2 A)

中間値推定部 2 2 2 A は、推定処理に先立ちニューラルネットワークのパラメータ w_{dec} を受け取る。

[0160] 中間値推定部 2 2 2 A は、状態 x_t を入力とし、式(9)のニューラルネットワークを用いて、再構成された基底関数の値の推定を $\hat{z}_t = \Phi(x_t; w_{dec})$ として行い (S 2 2 2 A)、推定値 $\hat{z}_t$ を出力する。なお、再構成された基底関数の値の推定値を中間値ともいう。

[0161] (中間観測値推定部 2 2 2 B)

中間観測値推定部 2 2 2 B は、推定処理に先立ち展開係数 B を受け取る。

[0162] 中間観測値推定部 2 2 2 B は、推定値 $\hat{z}_t$ を入力とし、推定値 $\hat{z}_t$ から、観測値を推定し (S 2 2 2 B)、推定値 $\hat{y}_t$ を出力する。以下の式において、 $\tau=0$ に対応する。

$$\hat{z}_{\tau}^{(t)} = K^{\tau} \hat{z}_t$$

$$\hat{y}_{\tau}^{(t)} = B \hat{z}_{\tau}^{(t)}$$

つまり、 $\hat{y}_t = B \hat{z}_t$ である。

[0163] (未来観測量推定部 2 2 3)

未来観測量推定部 2 2 3 は、推定処理に先立ち K 、 B を受け取る。

[0164] 未来観測量推定部 2 2 3 は、時間展開を表すパラメータ K を用いて、観測量が時間推移により変動した値である未来観測量を推定し (S 2 2 3)、出力する。

[0165] まず、未来観測量推定部 2 2 3 は、パラメータ K を用いて、推定値 $\hat{z}_t$ が時間推移により変動した値である未来中間値 $\hat{z}_\tau^{(t)}$ を得る。つまり、 $\hat{z}_\tau^{(t)} = K^\tau \hat{z}_t$ である。ただし、 $\tau = 1, \dots, T$ である。

[0166] さらに、未来観測量推定部 2 2 3 は、展開係数 B を用いて、未来中間値 $\hat{z}_\tau$ から未来観測量 $\hat{y}_\tau^{(t)}$ を推定する。つまり、 $\hat{y}_\tau^{(t)} = B \hat{z}_\tau^{(t)}$ である。

[0167] なお、第一実施形態および第三実施形態の学習装置の推定部 1 2 0 についても同様に表現することができる。ただし、学習用の観測量と、学習対象のパラメータを用いて処理を行う。

[0168] <ハードウェア構成>

学習装置および推定装置は、例えば、中央演算処理装置 (CPU: Central Processing Unit)、主記憶装置 (RAM: Random Access Memory) などを有する公知又は専用のコンピュータに特別なプログラムが読み込まれて構成された特別な装置である。学習装置および推定装置は、例えば、中央演算処理装置の制御のもとで各処理を実行する。学習装置および推定装置に入力されたデータや各処理で得られたデータは、例えば、主記憶装置に格納され、主記憶装置に格納されたデータは必要に応じて中央演算処理装置へ読み出されて他の処理に利用される。学習装置および推定装置の各処理部は、少なくとも一部が集積回路等のハードウェアによって構成されていてもよい。学習装置および推定装置が備える各記憶部は、例えば、RAM (Random Access Memory) などの主記憶装置、またはリレーショナルデータベースやキーバリューストアなどのミドルウェアにより構成することができる。ただし、各記憶部は、必ずしも学習装置および推定装置がその内部に備える必要はなく、ハードディスクや光ディスクもしくはフラッシュメモリ (Flash Memory) のような半導

体メモリ素子により構成される補助記憶装置により構成し、学習装置および推定装置の外部に備える構成としてもよい。

[0169] <その他の変形例>

本発明は上記の実施形態及び変形例に限定されるものではない。例えば、上述の各種の処理は、記載に従って時系列に実行されるのみならず、処理を実行する装置の処理能力あるいは必要に応じて並列的にあるいは個別に実行されてもよい。その他、本発明の趣旨を逸脱しない範囲で適宜変更が可能である。

[0170] <プログラム及び記録媒体>

また、上記の実施形態及び変形例で説明した各装置における各種の処理機能をコンピュータによって実現してもよい。その場合、各装置が有すべき機能の処理内容はプログラムによって記述される。そして、このプログラムをコンピュータで実行することにより、上記各装置における各種の処理機能がコンピュータ上で実現される。

[0171] この処理内容を記述したプログラムは、コンピュータで読み取り可能な記録媒体に記録しておくことができる。コンピュータで読み取り可能な記録媒体としては、例えば、磁気記録装置、光ディスク、光磁気記録媒体、半導体メモリ等のようなものでもよい。

[0172] また、このプログラムの流通は、例えば、そのプログラムを記録したDVD、CD-ROM等の可搬型記録媒体を販売、譲渡、貸与等することによって行う。さらに、このプログラムをサーバコンピュータの記憶装置に格納しておき、ネットワークを介して、サーバコンピュータから他のコンピュータにそのプログラムを転送することにより、このプログラムを流通させてもよい。

[0173] このようなプログラムを実行するコンピュータは、例えば、まず、可搬型記録媒体に記録されたプログラムもしくはサーバコンピュータから転送されたプログラムを、一旦、自己の記憶部に格納する。そして、処理の実行時、このコンピュータは、自己の記憶部に格納されたプログラムを読み取り、読

み取ったプログラムに従った処理を実行する。また、このプログラムの別の実施形態として、コンピュータが可搬型記録媒体から直接プログラムを読み取り、そのプログラムに従った処理を実行することとしてもよい。さらに、このコンピュータにサーバコンピュータからプログラムが転送されるたびに、逐次、受け取ったプログラムに従った処理を実行することとしてもよい。また、サーバコンピュータから、このコンピュータへのプログラムの転送は行わず、その実行指示と結果取得のみによって処理機能を実現する、いわゆるASP (Application Service Provider) 型のサービスによって、上述の処理を実行する構成としてもよい。なお、プログラムには、電子計算機による処理の用に供する情報であってプログラムに準ずるもの（コンピュータに対する直接の指令ではないがコンピュータの処理を規定する性質を有するデータ等）を含むものとする。

[0174] また、コンピュータ上で所定のプログラムを実行させることにより、各装置を構成することとしたが、これらの処理内容の少なくとも一部をハードウェア的に実現することとしてもよい。

請求の範囲

- [請求項1] エンコーダを用いて、観測量から状態を推定する状態推定部と、
 前記デコーダとを用いて、状態から観測量を推定する観測量推定部
 と、
 時間展開を表すパラメータ K を用いて、前記観測量が時間推移によ
 り変動した値である未来観測量を推定する未来観測量推定部と、を有
 し、
 前記エンコーダのパラメータと、前記デコーダのパラメータと、前
 記パラメータ K とは、同時に最適化されたものである、
 推定装置。
- [請求項2] 請求項1の推定装置であって、
 前記状態推定部が行う処理は第一の関数で、前記観測量推定部が行
 う処理は第二の関数で定義され、
 前記第一の関数は前記第二の関数の逆関数である、
 推定装置。
- [請求項3] 請求項1の推定装置であって、
 前記エンコーダのパラメータと、前記デコーダのパラメータと、前
 記パラメータ K とは、前記状態推定部をエンコーダとし、前記観測量
 推定部をデコーダとする変分オートエンコーダにより最適化されたも
 のであり、
 前記観測量は時系列観測量である、
 推定装置。
- [請求項4] 請求項1から請求項3の何れかの推定装置であって、
 前記観測量推定部は、
 前記状態から中間値を推定する中間値推定部と、
 推定した前記中間値から、前記観測値を推定する中間観測値推定部
 と、を含み、
 前記未来観測量推定部は、前記パラメータ K を用いて得られる、前

記中間値が時間推移により変動した値である未来中間値から前記未来観測量を推定する、

推定装置。

[請求項5] 請求項2の推定装置で用いるパラメータを学習する学習装置であって、

前記第二の関数は前記オートエンコーダのデコーダのパラメータである、基底関数のパラメータを用い、前記第一の関数は前記オートエンコーダのエンコーダのパラメータである、前記基底関数の逆関数のパラメータを用い、

学習用の観測量の系列データと、前記基底関数のパラメータ、前記逆関数のパラメータ、前記パラメータK、展開係数とを用いて、(1)基底関数の値の推定、(2)状態の推定、(3)再構成した基底関数の値の推定、(4)基底関数の予測、(5)観測量の予測を行う推定部と、

前記学習用の観測量の系列データと、基底関数の推定値の系列データ、状態の推定値の系列データ、再構成した基底関数の推定値の系列データ、基底関数の予測値の系列データ、観測量の予測値の系列データを用いて、(i)観測量の予測誤差、(ii)基底関数の予測誤差、(iii)前記基底関数のパラメータ、前記逆関数のパラメータに基づくニューラルネットワークの重みに対する正則化項、(iv)前記状態の構造を求め、求めた値から目的関数の値を求める目的関数計算部と、

前記目的関数に基づき、前記基底関数のパラメータ、前記逆関数のパラメータ、前記パラメータK、前記展開係数とを更新する更新部とを含み、

前記状態は非線形で時間推移するものであり、

前記観測量は状態の時間推移に伴い非線形で時間推移する観測処理を行うことで得ることができるものである、

学習装置。

[請求項6] エンコーダを用いて、観測量から状態を推定する状態推定ステップ

と、

前記デコーダとを用いて、状態から観測量を推定する観測量推定ステップと、

時間展開を表すパラメータ K を用いて、前記観測量が時間推移により変動した値である未来観測量を推定する未来観測量推定ステップと、を有し、

前記エンコーダのパラメータと、前記デコーダのパラメータと、前記パラメータ K とは、同時に最適化されたものである、

推定方法。

[請求項7] 請求項1から請求項4の何れかの推定装置、または、請求項5の学習装置としてコンピュータを機能させるためのプログラム。

[図1]





図1

[図2]



[図3]




図3

[図4]




図4

[図5]




図5

[図6]






図6

[図7]



[図8]


8
[図]

[図9]

アルゴリズム 2 推論アルゴリズム 1	
入力: 系列データ $\{y_t\}$	
出力: 予測された系列 $\{\hat{y}_T^{(t)}\}$, 推定された状態 $\{x_t\}$	
procedure 将来予測・推定	
基底関数の値の推定: $z_t = B^\dagger y_t$	
状態の推定: $x_t = \Psi^{-1}(z_t)$	
基底関数の再構成: $\hat{z}_t = \Psi(x_t)$	
基底関数の予測: $\hat{z}_T^{(t)} = K^T \hat{z}_t$	
観測量の予測: $\hat{y}_T^{(t)} = B \hat{z}_T^{(t)}$	

図9

[図10]



[図11]

アルゴリズム 3 推論アルゴリズム 2	
入力: 状態 $\{x_t\}$	
出力: 予測された系列 $\{\hat{y}_T^{(t)}\}$	
procedure 将来予測・推定	
基底関数の再構成: $\hat{z}_t = \Psi(x_t)$	
基底関数の予測: $\hat{z}_T^{(t)} = K^T \hat{z}_t$	
観測量の予測: $\hat{y}_T^{(t)} = B \hat{z}_T^{(t)}$	

図11

[図12]





図12

[図13]



[図14]




図14

[図15]




図15

[図16]




図16

[図17]




図17

[図18]




図18

INTERNATIONAL SEARCH REPORT

International application No.

PCT/JP2019/034216

A. CLASSIFICATION OF SUBJECT MATTER Int. Cl. G06N3/04 (2006.01) 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. G06N3/04 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 1971-2019 Registered utility model specifications of Japan 1996-2019 Published registered utility model applications of Japan 1994-2019 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.
X A	JP 2019-502212 A (PREFERRED NETWORKS, INC.) 24 January 2019, paragraphs [0015]-[0037], fig. 2-8 & WO 2017/122784 A1, paragraphs [0015]-[0037], fig. 2-8	1-4, 6-7 5
X A	WO 2018/052875 A1 (GOOGLE LLC) 22 March 2018, paragraphs [0029]-[0056], fig. 1-3 & JP 2019-530926 A, paragraphs [0027]-[0054], fig. 1-3 & CN 1099964237 A	1-2, 4, 6-7 3, 5
☒ Further documents are listed in the continuation of Box C. ☐ See patent family annex.		
* Special categories of cited documents: "A" document defining the general state of the art which is not considered to be of particular relevance "E" earlier application or patent but published on or after the international filing date "L" document which may throw doubts on priority claim(s) or which is cited to establish the publication date of another citation or other special reason (as specified) "O" document referring to an oral disclosure, use, exhibition or other means "P" document published prior to the international filing date but later than the priority date claimed "T" later document published after the international filing date or priority date and not in conflict with the application but cited to understand the principle or theory underlying the invention "X" document of particular relevance; the claimed invention cannot be considered novel or cannot be considered to involve an inventive step when the document is taken alone "Y" document of particular relevance; the claimed invention cannot be considered to involve an inventive step when the document is combined with one or more other such documents, such combination being obvious to a person skilled in the art "&" document member of the same patent family		
Date of the actual completion of the international search 19.11.2019		Date of mailing of the international search report 26.11.2019
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/JP2019/034216

C (Continuation). DOCUMENTS CONSIDERED TO BE RELEVANT

Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
A	石黒慎他, リアルタイム人口を用いた Stacked denoising Autoencoders によるタクシー将来需要予測, 情報処理学会論文誌 (ジャーナル), 15 January 2019, vol. 60, no. 1, pp. 118-128, ISSN:1882-7764 (ISHIGURO, Shin et al. Taxi Demand Forecast with Stacked denoising Autoencoders Using Real-time Population Data. Transactions of the Information Processing Society of Japan (Journal).)	1-7

A. 発明の属する分野の分類（国際特許分類（I P C））

Int.Cl. G06N3/04 (2006.01) 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. G06N3/04

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	1971-2019年
日本国実用新案登録公報	1996-2019年
日本国登録実用新案公報	1994-2019年

国際調査で利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
X	JP 2019-502212 A (株式会社 Preferred Networks) 2019.01.24, 段落[0015]-[0037], 図 2-8	1-4, 6-7
A	& WO 2017/122784 A1, Paragraphs[0015]-[0037], Figures 2-8	5
X	WO 2018/052875 A1 (GOOGLE LLC) 2018.03.22, Paragraphs[0029]-[0056], Figures 1-3	1-2, 4, 6-7
A	& JP 2019-530926 A, 段落[0027]-[0054], 図 1-3 & CN 109964237 A	3, 5

☒ 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

19.11.2019

国際調査報告の発送日

26.11.2019

国際調査機関の名称及びあて先

日本国特許庁（I S A/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）

三坂 敏夫

電話番号 03-3581-1101 内線 3545

5 B

4 1 7 8

C (続き) . 関連すると認められる文献		
引用文献の カテゴリ*	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	石黒 慎 他, リアルタイム人口を用いた Stacked denoising Autoencoders によるタクシー将来需要予測, 情報処理学会 論文誌 (ジャーナル) , 2019.01.15, 第 60 巻 第 1 号, 第 118 頁-第 128 頁, ISSN:1882-7764	1-7