

(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
2023年11月16日(16.11.2023)



(10) 国際公開番号

WO 2023/218642 A1

(51) 国際特許分類:
G06N 20/00 (2019.01)

(21) 国際出願番号: PCT/JP2022/020230

(22) 国際出願日: 2022年5月13日(13.05.2022)

(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: 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: 大川 真耶 (OKAWA, Maya); 〒1808585 東京都武蔵野市緑町3丁目9-11 NTT 知的財産センタ内 Tokyo (JP). 浅見 太一 (ASAMI, Taichi); 〒1808585 東京都武蔵野市緑町3丁目9-11 NTT 知的財産センタ内 Tokyo (JP).


(74) 代理人: 弁理士法人鈴榮特許総合事務所 (SUZUYE & SUZUYE); 〒1050014 東京都港区芝三丁目23番1号 セレスティン芝三井ビルディング11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, IQ, IR, IS, IT, JM, JO, JP, KE, KG, KH, KN, KP, KR, KW, KZ, LA, LC, LK, LR, LS, LU, LY, MA, MD, ME, MG, MK, MN, MW, MX, MY, MZ, NA, NG, NI, NO, NZ, OM, PA, PE, PG, PH, PL, PT, QA, RO, RS, RU, RW, SA, SC, SD, SE, SG, SK, SL, ST, SV, SY, TH, TJ, TM, TN, TR, TT, TZ, UA, UG, US, UZ, VC, VN, WS, ZA, ZM, ZW.

(84) 指定国(表示のない限り、全ての種類の広域保護が可能): ARIPO (BW, GH, GM, KE, LR, LS,

(54) Title: EVENT PREDICTION DEVICE, METHOD, AND PROGRAM

(54) 発明の名称: イベント予測装置、方法およびプログラム



1A Control unit
2A Program storage unit
3A Data storage unit
4A Input/output interface unit
11A Operation information reception processing part
12A Parameter estimation processing part
13A Infectious disease occurrence prediction processing part
14A Prediction information output processing part
31A Infectious disease occurrence history storage part
32A Parameter storage part
IDA Input device
ODA Output device
SVA Infectious disease occurrence prediction device

(57) Abstract: An embodiment of the present invention is configured such that when estimating parameters of a prediction model for predicting the occurrence of an event to be predicted, a point process model, in which an intensity function of a point process representing the occurrence probability of the event is presented by using the derivative of a neural network, is defined, and relational expressions for parameter estimation, which are represented by an item representing likelihood in the point process model and restriction items formed from differential equations representing a predetermined theoretical model reflecting domain knowledge pertaining to the event, are defined. Next, parameters of the theoretical model and parameters of the point process model are estimated on the basis of information representing past event occurrence history and the relational expressions such that a likelihood value obtained by adding the restriction items to the item representing the likelihood in the point process model becomes the smallest.



MW, MZ, NA, RW, SC, 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：この発明の一態様は、予測対象となるイベントの発生を予測する予測モデルのパラメータを推定する際に、前記イベントの発生確率を表す点過程の強度関数をニューラルネットワークの微分を用いて表した点過程モデルを定義し、前記点過程モデルの尤度を表す項と、前記イベントに関するドメイン知識を反映した所定の理論モデルを表す微分方程式からなる制約項とにより表されるパラメータ推定のための関係式を定義する。そして、過去のイベント発生履歴を表す情報と、前記関係式とに基づいて、前記点過程モデルの尤度を表す項に前記制約項を加算した尤度値が最小になるような前記理論モデルのパラメータおよび前記点過程モデルのパラメータを推定するようにしたものである。

明 細 書

発明の名称： イベント予測装置、方法およびプログラム

技術分野

[0001] この発明の一態様は、未来におけるイベントの発生を予測するイベント予測装置、方法およびプログラムに関する。

背景技術

[0002] 近年、イベント系列をモデル化しこのモデルを用いて未来におけるイベントの発生を予測する技術が注目されている。例えば、感染症の発生を予測する技術がその1つとしてあげられる。この技術を使用すると、感染症拡大の予兆を早期に把握することができ、感染症の蔓延と拡大を防ぐこと可能となる。また、例えばオンラインショッピングサイトにおけるユーザの購買行動を予測する技術も検討されている。この技術を使用すると、商品管理の最適化が可能となる。予測対象となるイベントには、ほかに、例えば犯罪の発生、地震や豪雨等の災害の発生、タクシーの乗降客の発生等があげられる。

[0003] イベント系列のモデル化には、一般にドメイン知識を反映した理論モデルが用いられている。例えば、感染症発生モデル化には、感染症数理（SIR）モデルと呼ばれる理論モデルが用いられる。SIR モデルでは、人口集団を感染のステージにより未感染者（Susceptible）、感染者（Infected）、免疫獲得者または隔離者（Recovered/Removed）の3種類に分け、各々のステージに属する人口の時間変化を疫学的知見に基づいてモデル化する。最も単純なSIRモデルは以下に示す常微分方程式により記述される。

[0004] [数1]

$$\frac{dS(t)}{dt} = -\beta S(t)I(t) \quad (1)$$

$$\frac{dI(t)}{dt} = \beta S(t)I(t) - \gamma I(t) \quad (2)$$

$$\frac{dR(t)}{dt} = \gamma I(t). \quad (3)$$

[0005] ここで、 $S(t)$ 、 $I(t)$ 、 $R(t)$ はそれぞれ時刻 t における未感染者（Susceptible

ble)、感染者 (Infected)、免疫獲得者または隔離者 (Recovered/Removed) の人数、 β は単位時間あたりの感染率、 γ は感染者の回復率を表す係数である。

[0006] その他、疫学分野の理論モデルとしては、(1)－(3) 式のSIR モデルをベースとして、さらに潜伏期間を考慮したSEIR モデルや、ワクチン接種を考慮した拡張モデル等も提案されている。

[0007] 一方、マーケティング分野においては、ロトカ・ヴォルテラ方程式を用いて競合サービス間のシェアの奪い合いをモデル化するアプローチが提案されている。ロトカ・ヴォルテラ方程式は、例えば2つの競合サービスを考えた場合、以下のように記述できる。

[0008] [数2]

$$\frac{dx(t)}{dt} = ax(t) - bx(t)y(t) \quad (4)$$

$$\frac{dy(t)}{dt} = cx(t)y(t) - dy(t) \quad (5)$$

[0009] ここで、 $x(t)$ は時刻 t における1つ目のサービスのシェア、 $y(t)$ は2つ目のサービスのシェアをそれぞれ表す。 a 、 b 、 c 、 d は正の定数である。

[0010] ロトカ・ヴォルテラ方程式は、元々は生物学分野において捕食者と被食者の増殖関係を記述する目的で提唱されたモデルであるが、近年マーケティング・経済分野における援用が進んでおり、その有効性が確かめられている。

[0011] ところで、これらの理論モデルは、これまでエージェント・ベース・モデルあるいは微分方程式ソルバーを用いて解析されてきた。SIR モデルやロトカ・ヴォルテラ方程式に代表される理論モデルは解釈性が高く、イベントの発生をモデル化する際にドメイン知識を反映させることができるという利点がある。しかし、データからのパラメータの学習が容易でないため、予測精度に限界がある。

[0012] 近年、感染症や購買行動などのイベントの発生に関して、精密な時刻情報付きのデータが入手可能になっている。例えば、感染症サーベイランス（調査監視）システムの拡充やSocial Network Service (SNS) の利活用が進んだ

ことで、感染症の発生に関する大規模なデータが蓄積されつつある。これらのデータを用いてSIR モデルやロトカ・ヴォルテラ方程式等の理論モデルのキャリブレーションを行う場合、手作業でモデルの選択やパラメータの設定を行う必要があり、手間と時間がかかる。

[0013] また、大規模なイベント系列のデータを活用する試みとして、機械学習モデルに基づくアプローチが多数提案され、注目を集めている。例えば、点過程と呼ばれる確率的生成モデルを用いる手法が提案されている。点過程の枠組みでは、感染症の発生や購買行動等のイベントの発生確率を強度関数と呼ばれる関数でモデル化し、イベントの発生履歴を用いて強度関数のパラメータを推定する。

[0014] 感染症のモデル化では、特にHawkes 過程と呼ばれる点過程が広く用いられている。Hawkes 過程においては、強度関数の設計時に、イベントが発生する度に跳ね上がり時間と共に減衰する関数形を仮定する。これにより、イベントの発生が次の発生を誘発するメカニズムを明示的にモデル化することができる。オンラインショッピングサイトにおける購買履歴など、マーケティング分野におけるイベント系列のモデル化にもHawkes 過程ベースの手法が広く用いられている。

[0015] さらに、複数のサービス間のシェアの奪い合いを記述するため、Hawkes 過程を拡張したモデルも提案されている（例えば非特許文献1を参照）。この手法は、過去の購買行動の影響だけでなく、他のサービスの成長の影響を考慮して未来の購買行動を予測することができる。しかし、これらHawkes 過程に基づく手法は、時間減衰の仕方について単純な関数形を仮定しているため、柔軟性に欠ける。

[0016] また、最近では、深層学習モデルを用いたアプローチも多数提案されている。例えば、感染症予測においては、現在時刻までに観測された感染者数の推移に基づいて未来の時刻における感染症の発生者数を予測する手法が提案されている（例えば、非特許文献2を参照）。

[0017] 一方、購買行動の予測においては、回帰型ニューラルネットワーク（Recur

rent Neural Network: RNN) 等の深層学習モデルを用いたアプローチが提案されている。しかし、深層学習モデルの使用する場合には、時系列の柔軟なモデル化が可能となる一方、疫学・マーケティングの各分野におけるドメイン知識を考慮することができないという別の課題がある。

先行技術文献

非特許文献

[0018] 非特許文献1: Zarezade, Ali, et al. "Correlated cascades: Compete or cooperate." Thirty-First AAAI Conference on Artificial Intelligence. 2017.

非特許文献2: Rahimi, Iman, Fang Chen, and Amir H. Gandomi. "A review on COVID-19 forecasting models." Neural Computing and Applications (2021): 1-11.

発明の概要

発明が解決しようとする課題

[0019] 上記したように、イベント系列のモデル化・予測には、SIR モデルやロトカ・ヴォルテラ方程式を始めとする理論モデル、点過程や深層学習を始めとする機械学習モデル等の様々な手法が提案されてきた。しかし、これらの手法では、大規模なデータとドメイン知識の双方を十分に活用することが困難である。

[0020] この発明は上記事情に着目してなされたもので、イベント系列のモデル化・予測において、大規模なデータとドメイン知識の双方を十分に活用することを可能にした技術を提供しようとするものである。

課題を解決するための手段

[0021] 上記課題を解決するためにこの発明に係るイベント予測装置または方法の一態様は、予測対象となるイベントに関する過去の発生履歴を表す情報を取得する処理部または過程と、学習フェーズにおいて、前記イベントの発生を予測する予測モデルのパラメータを推定する処理部または過程とを具備する

。そして、前記パラメータを推定する際に、前記イベントの発生確率を表す点過程の強度関数をニューラルネットワークの微分を用いて表す点過程モデルを定義する処理と、前記点過程モデルの尤度を表す項と、前記イベントに関するドメイン知識を反映した所定の理論モデルを表す微分方程式からなる制約項とにより表されるパラメータ推定のための関係式を定義する処理と、前記過去の発生履歴を表す情報と、前記関係式とに基づいて、前記点過程モデルの尤度を表す項に前記制約項を加算した尤度値が最小になるような前記理論モデルのパラメータおよび前記点過程モデルのパラメータを推定する処理を行うようにしたものである。

[0022] この発明の一態様によれば、ニューラルネットワークに基づく点過程のパラメータを学習する際に、イベント発生に関する理論モデルを表す微分方程式を損失関数の制約として課すことで、ニューラルネットワークに基づく点過程の枠組みにイベントの分野に関する事前知識を取り入れることができる。また、同時に過去の大規模なイベント発生履歴のデータを活用することができ、これにより高精度のイベント予測が可能な予測モデルを生成することが可能となる。

発明の効果

[0023] すなわちこの発明の一態様によれば、イベント系列のモデル化・予測において、大規模なデータとドメイン知識の双方を十分に活用することが可能な技術を提供することができる。

図面の簡単な説明

[0024] [図1]図1は、この発明に係るイベント予測装置の第1の実施形態である感染症発生予測装置のハードウェア構成の一例を示すブロック図である。

[図2]図2は、この発明の第1の実施形態における感染症発生予測装置のソフトウェア構成の一例を示すブロック図である。

[図3]図3は、図2に示した感染症発生予測装置において管理される感染症発生履歴情報の一例を示す図である。

[図4]図4は、図2に示した感染症発生予測装置の制御部が実行する、感染症

発生予測モデルのパラメータ推定処理および感染症発生予測処理の処理手順と処理内容の一例を示すフローチャートである。

[図5]図5は、図4に示す処理手順のうちパラメータ推定処理の処理手順と処理内容の一例を示すフローチャートである。

[図6]図6は、この発明に係るイベント予測装置の第2の実施形態である購買行動予測装置のソフトウェア構成の一例を示すブロック図である。

[図7]図7は、図6に示した購買行動予測装置において管理される購買行動履歴情報の一例を示す図である。

[図8]図8は、図6に示した購買行動予測装置の制御部が実行する、購買行動予測モデルのパラメータ推定処理および購買行動予測処理の処理手順と処理内容の一例を示すフローチャートである。

[図9]図9は、図8に示す処理手順のうちパラメータ推定処理の処理手順と処理内容の一例を示すフローチャートである。

発明を実施するための形態

[0025] 以下、図面を参照してこの発明に係わる実施形態を説明する。

[0026] [第1の実施形態]

(構成例)

図1および図2は、それぞれこの発明に係るイベント予測装置の第1の実施形態である、感染症発生予測装置SVAのハードウェア構成およびソフトウェア構成の一例を示すブロック図である。

[0027] 感染症発生予測装置SVAは、例えばクラウドまたはWeb上に配置されるサーバコンピュータ、またはユーザが所有するパーソナルコンピュータからなる。感染症発生予測装置SVAは、中央処理ユニット（Central Processing Unit：CPU）等のハードウェアプロセッサを使用した制御部1Aを備え、この制御部1Aに対し、バス5Aを介して、プログラム記憶部2Aおよびデータ記憶部3Aを有する記憶ユニットと、入出力インタフェース（以後インタフェースをI/Fと称する）部4Aを接続したものとなっている。

[0028] 入出力I/F部4Aには、入力デバイスIDAおよび出力デバイスODA

が接続される。入力デバイス I D A は、例えばキーボードおよびマウスを備え、感染症発生予測処理に係る種々操作情報を入力するために使用される。出力デバイス O D A は、例えば表示デバイスを有し、制御部 1 A により生成された予測情報等を表示するために用いられる。なお、出力デバイス O D A としては、他にプリンタや外部記憶デバイス等が用いられてもよい。

[0029] 入出力 I / F 部 4 A は、例えば通信インタフェース機能を有し、上記入力デバイス I D A において入力された操作情報をネットワークまたは信号ケーブルを介して受信すると共に、制御部 1 A により生成された各種情報を上記ネットワークまたは信号ケーブルを介して出力デバイス O D A へ出力する。

[0030] プログラム記憶部 2 A は、例えば、記憶媒体として S S D (Solid State Drive) 等の随時書込みおよび読出しが可能な不揮発性メモリと、R O M (Read Only Memory) 等の不揮発性メモリとを組み合わせ構成したもので、O S (Operating System) 等のミドルウェアに加えて、一実施形態に係る各種制御処理を実行するために必要なアプリケーション・プログラムを格納する。なお、以後 O S と各アプリケーション・プログラムとをまとめてプログラムと称する。

[0031] データ記憶部 3 A は、例えば、記憶媒体として、S S D 等の随時書込みおよび読出しが可能な不揮発性メモリと、R A M (Random Access Memory) 等の揮発性メモリとを組み合わせたもので、その記憶領域に、第 1 の実施形態を実施するために用いる記憶部として、感染症発生履歴記憶部 3 1 A と、パラメータ記憶部 3 2 A とを備える。

[0032] 感染症発生履歴記憶部 3 1 A は、解析対象となる過去の感染症発生履歴を表す情報を取得し、取得した上記感染症発生履歴を表す情報を記憶するために用いられる。感染症発生履歴を表す情報は、感染症の発生時刻と補助情報とからなる時系列のデータとして表される。例えば、時刻 T までに観測された感染症の発生履歴を表す情報は

$$D = \{(t_i, m_i)\}_{i=1}^T$$

で表される。

[0033] ここで、 t_i は症例の観測時刻、 m_i は補助情報、 I はデータ数である。補助情報としては、例えば感染症の観測場所（国や地域）、発症者の属性等が与えられる。第1の実施形態では、感染症の発生場所 $m_i \in M$ が補助情報として与えられるケースを想定する。ここで、 M は地域の集合を示す。図3は、感染症発生履歴の一例を示す図である。

[0034] なお、感染症発生履歴記憶部31Aは、感染症発生予測装置SVA内に設けずに、クラウド上またはWeb上に配置されている他のデータベースサーバ等に設けられていてもよい。

[0035] パラメータ記憶部32Aは、制御部1Aのパラメータ推定処理により推定された最適パラメータの組を保存するために用いられる。なお、パラメータ記憶部32Aについても、クラウド上またはWeb上の他のデータベースサーバや、他のパーソナルコンピュータ等に設けられていてもよく、また学習モデルなどの他のデータを格納する記憶装置の記憶エリアの一部に設けられてもよい。

[0036] 制御部1Aは、第1の実施形態を実施するために必要な処理機能として、操作情報受付処理部11Aと、パラメータ推定処理部12Aと、感染症発生予測処理部13Aと、予測情報出力処理部14Aとを備える。これらの処理部11A～14Aは、何れもプログラム記憶部2Aに格納されたアプリケーション・プログラムを制御部1Aのハードウェアプロセッサに実行させることにより実現される。

[0037] なお、上記アプリケーション・プログラムは、プログラム記憶部2Aに事前に格納しておく以外に、必要時に外部のアプリケーション・サーバ等からダウンロードしてプログラム記憶部2Aに記憶されるようにしてもよい。また、上記処理部11A～14Aの一部または全部は、LSI (Large Scale Integration) やASIC (Application Specific Integrated Circuit) 等のハードウェアを用いて実現されてもよい。

[0038] 操作情報受付処理部11Aは、入力デバイスIDAにおいて入力された操作情報を入出力I/F部4Aを介して受け取る。操作情報には、例えば感染

症発生履歴記憶部 3 1 A に対する感染症発生履歴の登録、登録された上記感染症発生履歴の修正および削除等を行う操作コマンドが含まれる。

[0039] パラメータ推定処理部 1 2 A は、上記感染症発生履歴記憶部 3 1 A に記憶されている感染症発生履歴を表す情報に基づいて、感染症の発生予測モデルに設定する最適パラメータを推定し、推定された最適パラメータをパラメータ記憶部 3 2 A に保存する処理を行う。このパラメータの推定処理の一例については、動作例において説明する。

[0040] 感染症発生予測処理部 1 3 A は、上記パラメータ記憶部 3 2 A に保存された最適パラメータが反映された感染症発生予測モデルを用いて、未来における感染症の発生状況を予測し、予測結果を予測情報出力処理部 1 4 A に出力する。

[0041] 予測情報出力処理部 1 4 A は、上記感染症発生状況の予測結果を出力するための情報を生成し、生成した上記予測情報を入出力 I / F 部 4 A から出力デバイス O D A へ出力する。

[0042] (動作例)

次に、以上のように構成された感染症発生予測装置 S V A の動作例を説明する。

[0043] 図 4 は、感染症発生予測装置 S V A の制御部 1 A が実行する、感染症発生予測モデルのパラメータ推定処理および学習済の予測モデルを用いた感染症発生予測処理の処理手順と処理内容の一例を示すフローチャートである。

[0044] (1) 感染症発生履歴の管理

例えば、管理者が新たに観測された感染症発生履歴を、その登録要求と共に入力デバイス I D A から入力したとする。そうすると、感染症発生予測装置 S V A の制御部 1 A は、操作情報受付処理部 1 1 A の制御の下、ステップ S 1 0 により上記登録要求を検出してステップ S 1 1 に移行し、ここで上記新たに観測された感染症発生履歴を取得する。そして、操作情報受付処理部 1 1 A は、ステップ S 1 2 において、取得した上記感染症発生履歴を感染症発生履歴記憶部 3 1 A に登録する。

[0045] なお、感染症発生履歴記憶部 3 1 A に登録された上記感染症発生履歴を管理者が修正または削除する処理も、操作情報受付処理部 1 1 A の制御の下で同様に行われる。

[0046] (2) パラメータの推定

感染症発生予測モデルの学習フェーズが設定された状態で、管理者が入力デバイス I D A においてパラメータの推定要求を入力したとする。そうすると、感染症発生予測装置 S V A の制御部 1 A は、ステップ S 1 3 により上記パラメータ推定要求を受け取ると、以後パラメータ推定処理部 1 2 A の制御の下、ステップ S 1 4 において以下のようにパラメータ推定処理を実行する。

[0047] 図 5 は、パラメータ推定処理部 1 2 A が実行するパラメータ推定処理の処理手順と処理内容の一例を示すフローチャートである。

[0048] パラメータ推定処理部 1 2 A は、感染症発生履歴記憶部 3 1 A に記憶された感染症発生履歴に基づいて、先ず各地域における感染症の発生確率を表す点過程の強度関数 $\lambda_m(t)$ を導入する。

[0049] すなわち、パラメータ推定処理部 1 2 A は、地域 m の強度関数を時刻 t を入力とするブラックボックス関数を用いて設計する。このとき、強度関数の柔軟性を担保するため、強度関数 $\lambda_m(t)$ をニューラルネットワークを用いて記述する。但し、強度関数 $\lambda_m(t)$ を直接ニューラルネットワークでモデル化しようとする、点過程の対数尤度に含まれる積分の計算が困難になる場合がある。

[0050] そこで、パラメータ推定処理部 1 2 A は、ステップ S 1 4 0 において、点過程の尤度に含まれる強度関数の積分を解析的に計算する。そのためにパラメータ推定処理部 1 2 A は、 $\lambda_m(t)$ を直接ニューラルネットでモデル化する代わりに、その積分 $\Lambda_m(t)$ を、時刻 t 、場所 m を入力とするニューラルネットワークにより、

[数3]

$$\Lambda_m(t) = f(t, m; \theta_f). \quad (6)$$

のように定式化する。ここで、 θ_f はニューラルネット $f(\cdot)$ のパラメータである。

[0051] この定式化の下で、強度関数 $\lambda_m(t)$ は、

[数4]

$$\lambda_m(t) = f'(t, m; \theta_f). \quad (7)$$

のように書き表すことができる。

[0052] ここで、 $f'(t, m; \theta_f)$ はニューラルネットワーク $f(t, m; \theta_f)$ の微分であり、

[数5]

$$f'(t, m; \theta_f) = \frac{df(t, m; \theta_f)}{dt}. \quad (8)$$

のように定義される。

[0053] このとき、強度関数 $\lambda_m(t)$ は、先に述べた(1)－(3)式で定義されるSIRモデルにおける変数 $I(t)$ に対応している。従って、パラメータ推定処理部12Aは、ステップS141において、SIRモデルの(3)式に含まれる $I(t)$ を $\lambda_m(t)$ で置き換え、(7)式を代入することで、地域 m における免疫獲得者・隔離者の人数 $R_m(t)$ を

[数6]

$$R_m(t) = \int \gamma f'(t, m, \theta_f) dt = \gamma f(t, m, \theta_f) \quad (9)$$

として定義する。

[0054] 続いてパラメータ推定処理部12Aは、ステップS142において、地域 m における未感染者の人口を $S_m(t)$ で定義する。すなわち、地域 m における未感染者の人口 $S_m(t)$ は、地域 m の人口 N_m と感染者の発生確率 $\lambda_m(t)$ 、免疫獲得者・隔離者の人数 $R_m(t)$ を用いて、

[数7]

$$S_m(t) = N_m - \lambda_m(t) - R_m(t). \quad (10)$$

と書き表すことができる。

[0055] この場合、人口 N_m はパラメータとして推定することもできるが、第1の実施例では人口調査などによる所与の値を用いる。同様に、SIR モデルの(2)式は、

[数8]

$$\frac{d\lambda_m(t)}{dt} = \beta S_m(t)\lambda_m(t) - \gamma\lambda_m(t). \quad (11)$$

と書き換えることができる。

[0056] ところで、予測モデルを学習する際にパラメータ推定処理部12Aは、次式で定義される尤度 L を最小化するようなSIR モデルのパラメータ $\{\beta, \gamma\}$ 、ニューラルネットワークのパラメータ θ_f を推定する。

[0057] [数9]

$$\mathcal{L}(\theta_f, \beta; \mathcal{D}) = \mathcal{L}_{\text{data}}(\theta_f; \mathcal{D}) + \alpha \mathcal{L}_{\text{ode}}(\theta_f, \beta, \gamma). \quad (12)$$

[0058] ここで、 L_{data} はデータに対する学習モデルの当てはまりの良さを表す尤度、 L_{ode} は微分方程式による制約を表す項である。 α は第二項の重要度を表すハイパーパラメータである。

[0059] パラメータ推定処理部12Aは、ステップS143において、上記(12)式の右辺第一項に示す点過程の尤度を、

[数10]

$$\begin{aligned} \mathcal{L}_{\text{data}}(\theta_f; \mathcal{D}) &= \sum_{i=1}^I \lambda_{m_i}(t_i) - \sum_{m \in \mathcal{M}} \int_0^T \lambda_m(\tau) d\tau \\ &= \sum_{i=1}^I \lambda_{m_i}(t_i) - \sum_{m \in \mathcal{M}} (\Lambda_m(T) - \Lambda_m(0)). \end{aligned} \quad (13)$$

のように定義する。ここで、 $\mathcal{D} = \{(t_i, m_i)\}_{i=1}^I$ は感染症の発生履歴、 I はデータの数それぞれを示す。

[0060] 上記(12)式に含まれるブラックボックス関数 $\lambda_m(\cdot)$ とその積分 $\Lambda_m(\cdot)$ は、ニューラルネットワーク $f(t, m)$ と、その微分 $f'(t, m) = df(t, m)/dt$ とを用いて、

[数11]

$$\mathcal{L}_{\text{data}}(\theta_f; \mathcal{D}) = \sum_{i=1}^I f'(t_i, m_i) - \sum_{m \in \mathcal{M}} (f(T, m) - f(0, m)). \quad (14)$$

と書き表すことができる。

[0061] なお、上記(14) 式の第一項に含まれるニューラルネットワークの微分 $f'_m(t)$ は、例えばPyTorch 等の深層学習パッケージで実装されている自動微分を用いることで容易に計算することができる。

[0062] また、パラメータ推定処理部12Aは、ステップS144において、上記(12) 式の右辺第二項を、上記(11) 式の右辺と左辺との差を用いて、

[数12]

$$\mathcal{L}_{\text{ode}}(\theta_f, \beta, \gamma) = \frac{1}{J} \sum_{j=1}^J \sum_{m \in \mathcal{M}} \left(\left. \frac{d\lambda_m(t)}{dt} \right|_{t=\tau_j} - \beta S_m(\tau_j) \lambda_m(\tau_j) - \gamma \lambda_m(\tau_j) \right)^2. \quad (15)$$

と定義する。

[0063] ここで、 $\{\tau_1, \dots, \tau_J\}$ はあらかじめ定義された時間軸上の代表点である。 $\mathcal{L}_{\text{ode}}$ はJ 個の代表点における微分方程式の誤差を表す。この例では、誤差の指標として平均二乗誤差を用いたが、他の誤差関数を用いることもできる。

[0064] 上記式は、微分方程式である上記(11) 式の左辺と右辺の差を取って代表点の時刻 τ_j を代入したものである。上記(15) 式の制約項を尤度L に加えることで、出力が上記(2) 式で定義される微分方程式に従うような強度関数 $\lambda(\cdot)$ のパラメータを学習することができる。

[0065] パラメータ推定処理部12Aは、ステップS145において、上記(15) 式を、ニューラルネットワーク $f(t, m)$ の、一階微分 $f'_m(t, m) = df(t, m)/dt$ および二階微分 $f''_m(t, m) = d^2 f(t, m)/dt^2$ を用いて、

[数13]

$$\mathcal{L}_{\text{ode}}(\theta_f, \theta_h, \beta, \gamma) = \frac{1}{J} \sum_{j=1}^J \sum_{m \in \mathcal{M}} \left(f''(\tau_j, m) - \beta(N_m - f'(\tau_j, m) - \gamma f(\tau_j, m)) f'(\tau_j, m) - \gamma f'(\tau_j, m) \right)^2. \quad (16)$$

と定義する。

[0066] なお、第1の実施形態では、SIR モデルを用いた場合を例にとって説明したが、他にSEIR モデルなどの任意の理論モデルを適用することができる。また、パラメータの最適化にはどのような方法を用いてもよいが、上記(14) 式、(16) 式に含まれるニューラルネットワークの微分を効率良く計算するため、誤差逆伝播法を用いるとよい。

[0067] パラメータ推定処理部12Aは、ステップS146において、最適パラメータ、つまり尤度 L を最小化するようなSIR モデルのパラメータ $\{\beta, \gamma\}$ と、ニューラルネットワークのパラメータ θ_f を推定し、推定したパラメータをステップS147によりパラメータ記憶部32Aに保存する。

[0068] (3) 感染症発生の予測とその予測結果の出力

上記のように感染症発生予測モデルに対する最適パラメータの推定処理が終了すると、感染症発生予測装置SVAの制御部1Aは予測フェーズに移行する。

[0069] 予測フェーズにおいて、入力デバイスIDAから予測要求が入力されると、感染症発生予測装置SVAの制御部1Aは、感染症発生予測処理部13Aの制御の下、ステップS15により上記予測要求を検出してステップS16に移行し、ここで先ず予測条件を取得する。予測条件としては、例えば予測対象となる未来の時間帯が指定される。

[0070] 感染症発生予測処理部13Aは、続いてステップS17において、上記最適パラメータが設定された感染症発生予測モデルに対し、上記予測条件を説明変数として入力する。そして、当該感染症発生予測モデルを用いて、上記時間帯における感染症の発生時刻および発生場所を予測し、その予測結果を得る。

[0071] 最後に、感染症発生予測装置SVAの制御部1Aは、予測情報出力処理部14Aの制御の下、ステップS18において、上記感染症発生予測処理部13Aにより得られた予測結果を表示するためのデータを生成し、生成した表示データを入出力I/F部4Aから出力デバイスODAへ出力する。この結果、出力デバイスODAには、例えば、上記予測対象として指定した未来の

時間帯における感染症の発生場所（国や地域）とその発生時刻が、例えばマップ上に表示される。なお、上記予測結果の出力形態は任意の形態を採用できる。

[0072] （作用・効果）

以上述べたように第1の実施形態では、各地域 m における感染症の発生確率を表す点過程の強度関数 $\lambda_m(t)$ をニューラルネットワークの微分として定義し、上記強度関数 $\lambda_m(t)$ をSIRモデルの感染者数に置き換えることで、地域 m における免疫獲得者・隔離者の人数 $R_m(t)$ および未感染者の人口 $S_m(t)$ を定義する。また、尤度 $L(\theta_f, \beta; D)$ を、点過程の尤度 $L_{data}(\theta_f, ; D)$ と、SIRモデルを表す微分方程式の制約を表す $\alpha L_{ode}(\theta_f, \beta, \gamma)$ とにより定義する。そして、強度関数のパラメータを学習する学習フェーズにおいて、上記定義した関係式に過去の感染症発生履歴を適用し、上記尤度 $L(\theta_f, \beta; D)$ を最小化するようなSIRモデルのパラメータ $\{\beta, \gamma\}$ と、ニューラルネットワークのパラメータ θ_f を推定する。また、予測フェーズにおいては、推定された上記各パラメータが設定された感染症発生予測モデルを用いて、未来の時間帯における感染症の発生状況を予測し、その予測結果を出力するようにしている。

[0073] 従って、第1の実施形態によれば、ニューラルネットワークに基づく点過程のパラメータを学習する際に、SIRモデルを表す微分方程式を損失関数の制約として課すことで、ニューラルネットワークに基づく点過程の枠組みに感染症予測分野の事前知識を取り入れることができる。また、同時に過去の大規模な感染症発生履歴のデータを活用することができ、これにより高精度の感染症発生予測が可能になる。

[0074] [第2の実施形態]

（構成例）

図6は、この発明に係るイベント予測装置の第2の実施形態である、購買行動予測装置SVBのソフトウェア構成の一例を示すブロック図である。なお、購買行動予測装置SVBのハードウェア構成については、第1の実施形

態において図 1 で説明したものと同一なので、再度の説明は省略する。

[0075] 購買行動予測装置 S V B も、先に述べた感染症発生予測装置 S V A と同様に、例えばクラウドまたは W e b 上に配置されるサーバコンピュータ、またはユーザが所有するパーソナルコンピュータからなる。購買行動予測装置 S V B は、中央処理ユニット（C P U）等のハードウェアプロセッサを使用した制御部 1 B を備え、この制御部 1 B に対し、バス 5 B を介して、プログラム記憶部 2 B およびデータ記憶部 3 B を有する記憶ユニットと、入出力 I / F 部 4 B を接続したものとなっている。

[0076] 入出力 I / F 部 4 B には、入力デバイス I D B および出力デバイス O D B が接続される。入力デバイス I D B は、例えばキーボードおよびマウスを備え、購買行動の予測処理に係る種々操作情報を入力するために使用される。出力デバイス O D B は、例えば表示デバイスを有し、制御部 1 B により生成された予測情報等を表示するために用いられる。なお、出力デバイス O D B としては、他にプリンタや外部記憶デバイス等が用いられてもよい。

[0077] 入出力 I / F 部 4 B は、例えば通信インタフェース機能を有し、上記入力デバイス I D B において入力された操作情報をネットワークまたは信号ケーブルを介して受信すると共に、制御部 1 B により生成された各種情報を上記ネットワークまたは信号ケーブルを介して出力デバイス O D B へ出力する。

[0078] プログラム記憶部 2 B は、例えば、記憶媒体として S S D 等の随時書込みおよび読出しが可能な不揮発性メモリと、R O M 等の不揮発性メモリとを組み合わせて構成したもので、O S 等のミドルウェアに加えて、一実施形態に係る各種制御処理を実行するために必要なアプリケーション・プログラムを格納する。なお、以後 O S と各アプリケーション・プログラムとをまとめてプログラムと称する。

[0079] データ記憶部 3 B は、例えば、記憶媒体として、S S D 等の随時書込みおよび読出しが可能な不揮発性メモリと、R A M 等の揮発性メモリと組み合わせたもので、その記憶領域に、第 2 の実施形態を実施するために用いる記憶部として、購買行動履歴記憶部 3 1 B と、パラメータ記憶部 3 2 B とを備え

る。

[0080] 購買行動履歴記憶部 3 1 B は、解析対象となる過去の購買行動履歴を表す情報を取得し、取得した上記購買行動履歴を表す情報を記憶するために用いられる。購買行動履歴情報は、購買行動が行われた時刻と補助情報とからなる時系列のデータとして表される。例えば、時刻 T までに観測された購買行動は

$$D = \{(t_i, m_i)\}_{i=1}^I$$

で表される。

[0081] ここで、 t_i は購買行動が行われた時刻、 m_i は補助情報、 I はデータ数である。第 2 の実施形態では、例えば購買行動の対象となった商品またはサービスの種類 $m_i \in M$ が補助情報として与えられるケースを想定する。ここで、 M は商品またはサービスの集合を示す。図 7 は、購買行動履歴の一例を示す図である。

[0082] なお、購買行動履歴記憶部 3 1 B は、購買行動予測装置 S V B 内に設けずに、クラウド上または Web 上の他のデータベースサーバやパーソナルコンピュータ等に設けられてもよい。

[0083] パラメータ記憶部 3 2 B は、制御部 1 B のパラメータ推定処理により推定された最適パラメータの組を保存するために用いられる。なお、パラメータ記憶部 3 2 B についても、クラウドまたは Web 上の他のデータベースサーバや、他のパーソナルコンピュータ等に設けられていてもよく、また学習モデルなどの他のデータを格納する記憶装置の記憶エリアの一部に設けられてもよい。

[0084] 制御部 1 B は、第 2 の実施形態を実施するために必要な処理機能として、操作情報受付処理部 1 1 B と、パラメータ推定処理部 1 2 B と、購買行動予測処理部 1 3 B と、予測情報出力処理部 1 4 B とを備える。これらの処理部 1 1 B ~ 1 4 B は、何れもプログラム記憶部 2 B に格納されたアプリケーション・プログラムを制御部 1 B のハードウェアプロセッサに実行させることにより実現される。

[0085] なお、第2の実施形態においても、アプリケーション・プログラムは、プログラム記憶部2Bに事前に格納しておく以外に、必要時に外部のアプリケーション・サーバ等からダウンロードしてプログラム記憶部2Bに記憶されるようにしてもよい。また、上記処理部11B～14Bの一部または全部は、LSIやASIC等のハードウェアを用いて実現されてもよい。

[0086] 操作情報受付処理部11Bは、入力デバイスIDBにおいて入力された操作情報を入出力I/F部4Bを介して受付ける。操作情報には、例えば購買行動履歴記憶部31Bに対する購買行動履歴の登録、登録された上記購買行動履歴の修正および削除等を行う操作コマンドが含まれる。

[0087] パラメータ推定処理部12Bは、上記購買行動履歴記憶部31Bに記憶されている購買行動履歴を表す情報に基づいて、購買行動予測モデルに設定する最適パラメータを推定し、推定された最適パラメータをパラメータ記憶部32Bに記憶させる処理を行う。このパラメータの推定処理の一例については、動作例において説明する。

[0088] 購買行動予測処理部13Bは、上記パラメータ記憶部32Bに記憶された最適パラメータが反映された購買行動予測モデルを用いて、ユーザの未来における購買行動を予測し、その予測結果を予測情報出力処理部14Bに出力する。

[0089] 予測情報出力処理部14Bは、上記未来の購買行動の予測結果を表示するための情報を生成し、生成した上記予測情報を入出力I/F部4Bから出力デバイスODBへ出力する。

[0090] (動作例)

次に、以上のように構成された購買行動予測装置SVBの動作例を説明する。

[0091] 図8は、購買行動予測装置SVBの制御部1Bが実行する、購買行動予測モデルのパラメータ推定処理および学習済の購買行動予測モデルを用いた購買行動予測処理の処理手順と処理内容の一例を示すフローチャートである。

[0092] (1) 購買行動履歴の管理

例えば、管理者が新たに収集した購買行動履歴を、その登録要求と共に入力デバイス I D B から入力したとする。そうすると、購買行動予測装置 S V B の制御部 1 B は、操作情報受付処理部 1 1 B の制御の下、ステップ S 2 0 により上記登録要求を検出してステップ S 2 1 に移行し、ここで上記新たに収集された購買行動履歴を取得する。そして、操作情報受付処理部 1 1 B は、ステップ S 2 2 において、取得した上記購買行動履歴を購買行動履歴記憶部 3 1 B に登録する。

[0093] なお、購買行動履歴記憶部 3 1 B に記憶された上記購買行動履歴を管理者が修正または削除する処理も、操作情報受付処理部 1 1 B の制御の下で同様に行われる。

[0094] (2) パラメータの推定

購買行動予測モデルの学習フェーズにおいて、管理者が入力デバイス I D B においてパラメータの推定要求を入力したとする。そうすると、購買行動予測装置 S V B の制御部 1 B は、ステップ S 2 3 により上記パラメータ推定要求を受け取ると、以後パラメータ推定処理部 1 2 B の制御の下、ステップ S 2 4 において以下のようにパラメータ推定処理を実行する。

[0095] 図 9 は、パラメータ推定処理部 1 2 B が実行するパラメータ推定処理の処理手順と処理内容の一例を示すフローチャートである。

[0096] パラメータ推定処理部 1 2 B は、購買行動履歴記憶部 3 1 B に記憶された購買行動履歴に基づいて、先ず商品またはサービス別の購買確率を表す点過程の強度関数 $\lambda_m(t)$ を導入する。

[0097] すなわち、パラメータ推定処理部 1 2 B は、商品またはサービス m の強度関数を時刻 t を入力とするブラックボックス関数を用いて設計する。このとき、強度関数の柔軟性を担保するため、強度関数 $\lambda_m(t)$ をニューラルネットワークを用いて記述する。但し、強度関数 $\lambda_m(t)$ を直接ニューラルネットワークでモデル化しようとする、点過程の対数尤度に含まれる積分の計算が困難になる場合がある。

[0098] そこで、パラメータ推定処理部 1 2 B は、ステップ S 2 4 0 において、点

過程の尤度に含まれる強度関数の積分を解析的に計算するため、 $\lambda_m(t)$ を直接ニューラルネットでモデル化する代わりに、その積分 $\Lambda_m(t)$ を、時刻 t 、商品またはサービス m を入力とするニューラルネットワークにより、

[数14]

$$\Lambda_m(t) = f(t, m; \theta_f). \quad (17)$$

のように定式化する。ここで、 θ_f はニューラルネット $f(\cdot)$ のパラメータである。

[0099] この定式化の下で、強度関数 $\lambda_m(t)$ は、

[数15]

$$\lambda_m(t) = f'(t, m; \theta_f). \quad (18)$$

のように書き表すことができる。

[0100] ここで、 $f'(t, m; \theta_f)$ はニューラルネットワーク $f(t, m; \theta_f)$ の微分であり、

[数16]

$$f'(t, m; \theta_f) = \frac{df(t, m; \theta_f)}{dt}. \quad (19)$$

のように定義される。

[0101] このとき、1種類目の商品またはサービス $m=0$ の強度関数 $\lambda_0(t)$ は、先に述べた(4) 式および(5) 式で定義されるロトカ・ヴォルテラ方程式における変数 $x(t)$ に対応している。同様に、2種類目の商品またはサービスの購買確率を表す強度関数 $\lambda_1(t)$ は、ロトカ・ヴォルテラ方程式における変数 $y(t)$ に対応している。従って、パラメータ推定処理部12Bは、ステップS241、S242において、ロトカ・ヴォルテラ方程式の(4) 式に含まれる $x(t)$ を $\lambda_0(t)$ で、また(5) 式に含まれる $y(t)$ を $\lambda_1(t)$ でそれぞれ置き換えることで、1種類目の商品またはサービス $m=0$ の購買確率の変化を、

[数17]

$$\frac{d\lambda_0(t)}{dt} = a\lambda_0(t) - b\lambda_0(t)\lambda_1(t) \quad (20)$$

と定義する。

[0102] 同様に、2種類目の商品またはサービス $m = 1$ の購買確率の変化を、
[数18]

$$\frac{d\lambda_1(t)}{dt} = c\lambda_0(t)\lambda_1(t) - d\lambda_1(t) \quad (21)$$

と定義する。

[0103] ところで、予測モデルを学習する際に、パラメータ推定処理部 12B は、次式で定義される尤度 L を最小化するようなロトカ・ヴォルテラ方程式のパラメータ $\{a, b, c, d\}$ 、ニューラルネットワークのパラメータ θ_f を推定する。

[0104] [数19]

$$\mathcal{L}(\theta_f, a, b, c, d; \mathcal{D}) = \mathcal{L}_{\text{data}}(\theta_f; \mathcal{D}) + \alpha \mathcal{L}_{\text{ode}}(\theta_f, a, b, c, d). \quad (22)$$

[0105] ここで、 L_{data} はデータに対する学習モデルの当てはまりの良さを表す尤度、 L_{ode} は微分方程式による制約を表す項である。 α は第二項の重要度を表すハイパーパラメータである。

[0106] パラメータ推定処理部 12B は、ステップ S 243 において、上記(22)式の右辺第一項に示す点過程の尤度を、
[数20]

$$\begin{aligned} \mathcal{L}_{\text{data}}(\theta_f; \mathcal{D}) &= \sum_{i=1}^I \lambda_{m_i}(t_i) - \sum_{m \in \mathcal{M}} \int_0^T \lambda_m(\tau) d\tau \\ &= \sum_{i=1}^I \lambda_{m_i}(t_i) - \sum_{m \in \mathcal{M}} (\Lambda_m(T) - \Lambda_m(0)). \end{aligned} \quad (23)$$

のように定義する。ここで、 $\mathcal{D} = \{(t_i, m_i)\}_{i=1}^I$ は購買行動履歴、 I はデータの数をそれぞれ示す。

[0107] 上記(22)式に含まれるブラックボックス関数 $\lambda_m(\cdot)$ とその積分 $\Lambda_m(\cdot)$ は、ニューラルネットワーク $f(t, m)$ と、その微分 $f'(t, m) = df(t, m)/dt$ を用いて、

[数21]

$$\mathcal{L}_{\text{data}}(\theta_f; \mathcal{D}) = \sum_{i=1}^I f'(t_i, m_i) - \sum_{m \in \mathcal{M}} (f(T, m) - f(0, m)). \quad (24)$$

と書き表すことができる。

[0108] なお、上記(24)式の第一項に含まれるニューラルネットワークの微分 $f'_m(t)$ は、例えばPyTorch等の深層学習パッケージで実装されている自動微分を用いることで容易に計算することができる。

[0109] また、パラメータ推定処理部12Bは、ステップS244において、上記(22)式の右辺第二項を、上記(20)式および(21)式の右辺と左辺との差を用いて、

[数22]

$$\begin{aligned} \mathcal{L}_{\text{ode}}(\theta_f, a, b, c, d) = \frac{1}{J} \sum_{j=1}^J & \left[\left(\left. \frac{d\lambda_0(t)}{dt} \right|_{t=\tau_j} - a\lambda_0(\tau_j) + b\lambda_0(\tau_j)\lambda_1(\tau_j) \right)^2 \right. \\ & \left. + \left(\left. \frac{d\lambda_1(t)}{dt} \right|_{t=\tau_j} - c\lambda_0(\tau_j)\lambda_1(\tau_j) + d\lambda_1(\tau_j) \right)^2 \right]. \end{aligned} \quad (25)$$

と定義する。

[0110] ここで、 $\{\tau_1, \dots, \tau_J\}$ はあらかじめ定義された時間軸上の代表点である。 $\mathcal{L}_{\text{ode}}$ はJ個の代表点における微分方程式の誤差を表す。この例では、誤差の指標として平均二乗誤差を用いたが、他の誤差関数を用いることもできる。

[0111] 上式は、微分方程式である上記(20)式および(21)式の左辺と右辺との差を取って代表点の時刻 τ_j を代入したものである。上記(25)式の制約項を尤度Lに加えることで、出力が先に述べた(4)式、(5)式で定義される微分方程式に従うような強度関数 $\lambda(\cdot)$ のパラメータを学習することができる。

[0112] パラメータ推定処理部12Bは、ステップS245において、上記(25)式を、ニューラルネットワーク $f(t, m)$ の一階微分 $f'(t, m) = df(t, m)/dt$ 、および二階微分 $f''(t, m) = d^2 f(t, m)/dt^2$ を用いて、

[数23]

$$\mathcal{L}_{\text{ode}}(\theta_f, a, b, c, d) = \frac{1}{J} \sum_{j=1}^J \left[\left(f''(\tau_j, 0) - a f'(\tau_j, 0) + b f'(\tau_j, 0) f'(\tau_j, 1) \right)^2 + \left(f''(\tau_j, 1) - c f'(\tau_j, 0) f'(\tau_j, 1) + d f'(\tau_j, 1) \right)^2 \right]. \quad (26)$$

と定義する。

[0113] なお、第2の実施形態では、ロトカ・ヴォルテラ方程式を用いた場合を例にとって説明したが、他の同様の理論モデルを適用することも可能である。また、パラメータの最適化にはどのような方法を用いてもよいが、上記(26)式に含まれるニューラルネットワークの微分を効率良く計算するため、誤差逆伝播法を用いるとよい。

[0114] パラメータ推定処理部12Bは、ステップS246において、尤度Lを最小化するようなロトカ・ヴォルテラ方程式のパラメータ {a, b, c, d} と、ニューラルネットワークのパラメータ θ_f をそれぞれ推定し、推定した最適なパラメータをステップS247によりパラメータ記憶部32Bに記憶させる。

[0115] (3) 購買行動の予測とその予測結果の出力

上記のように購買行動予測モデルに対する最適パラメータの推定処理が終了すると、購買行動予測装置SVBの制御部1Bは予測フェーズに移行する。

[0116] 予測フェーズにおいて、入力デバイスIDBから予測要求が入力されると、購買行動予測装置SVBの制御部1Bは、購買行動予測処理部13Bの制御の下、ステップS25により上記予測要求を検出してステップS26に移行し、ここで先ず予測条件を取得する。予測条件としては、例えば予測対象とする未来の時間帯が指定される。

[0117] 購買行動予測処理部13Bは、続いてステップS27において、上記最適パラメータが設定された感染症発生予測モデルに対し、上記予測条件を説明変数として入力する。そして、当該購買行動予測モデルを用いて、上記時間

帯における購買行動の対象となる商品またはサービスと、購買時刻を予測し、その予測結果を得る。

[0118] 最後に、購買行動予測装置SVBの制御部1Bは、予測情報出力処理部14Bの制御の下、ステップS28において、上記購買行動予測処理部13Bにより得られた予測結果を表示するためのデータを生成し、生成した表示データを入出力I/F部4Bから出力デバイスODBへ出力する。この結果、出力デバイスODBには、例えば、上記予測対象として指定した未来の時間帯における購買行動の対象となる商品またはサービス名とその購買時刻が表示される。なお、上記予測結果の出力形態は任意の形態を採用できる。

[0119] (作用・効果)

以上述べたように第2の実施形態では、各商品またはサービス m の購買確率を表す点過程の強度関数 $\lambda_m(t)$ をニューラルネットワークの微分として定義し、上記強度関数 $\lambda_m(t)$ をロトカ・ヴォルテラ方程式の変数 $x(t)$ 、 $y(t)$ に置き換えることで、1種類目の商品またはサービス $m=0$ および2種類目の商品またはサービス $m=1$ のそれぞれの購買確率を定義する。また、尤度 $L(\theta_f, a, b, c, d; D)$ を、点過程の尤度 $L_{data}(\theta_f; D)$ と、微分方程式の制約を表す $\alpha L_{ode}(\theta_f, a, b, c, d)$ とにより定義する。そして、学習フェーズにおいて、上記定義した関係式に過去の購買行動履歴を適用することで、上記尤度 $L(\theta_f, a, b, c, d; D)$ を最小化するようなロトカ・ヴォルテラ方程式のパラメータ $\{a, b, c, d\}$ と、ニューラルネットワークのパラメータ θ_f をそれぞれ推定する。また、予測フェーズにおいては、推定された上記各パラメータが設定された購買行動予測モデルを用いて、未来の時間帯における対象商品またはサービスの購買行動を予測し、その予測結果を出力するようにしている。

[0120] 従って、第2の実施形態によれば、ニューラルネットワークに基づく点過程のパラメータを学習する際に、点過程の尤度にロトカ・ヴォルテラ方程式を表す微分方程式を損失関数の制約として課すことで、ニューラルネットワークに基づく点過程の枠組みに購買行動に関する事前知識を取り入れること

ができる。また、同時に過去の大規模な購買行動履歴のデータを活用することができ、これにより高精度の購買行動予測が可能になる。

[0121] [その他の実施形態]

(1) 感染症発生予測装置SVAおよび購買行動予測装置SVBが備える各処理機能および記憶部は、1台の情報処理装置に配置されてもよいが、サーバやパーソナルコンピュータ等の複数台の情報処理装置に分散して配置されてもよい。例えば、パラメータ推定処理部とイベント予測処理部を異なる情報装置に配置し、一方の情報処理装置により推定されたパラメータを、必要に応じて他方の情報処理装置に転送して学習モデルに設定するようにしてもよい。

[0122] (2) 前記第1および第2の実施形態では、それぞれ感染症の発生予測および購買行動の予測を行う場合を例にとって説明した。しかし、それに限らず、犯罪の発生予測や、地震、豪雨および強風等による災害の発生予測、タクシーの配車要求の予測等、様々なイベントの予測にもこの発明は適用可能である。

[0123] (3) その他、理論モデルの種類やイベント予測装置の処理機能については、この発明の要旨を逸脱しない範囲で種々変形して実施可能である。

[0124] 以上、この発明の実施形態を詳細に説明してきたが、前述までの説明はあらゆる点においてこの発明の例示に過ぎない。この発明の範囲を逸脱することなく種々の改良や変形を行うことができることは言うまでもない。つまり、この発明の実施にあたって、実施形態に応じた具体的構成が適宜採用されてもよい。

[0125] 要するにこの発明は、上記実施形態そのままに限定されるものではなく、実施段階ではその要旨を逸脱しない範囲で構成要素を変形して具体化できる。また、上記実施形態に開示されている複数の構成要素の適宜な組み合わせにより種々の発明を形成できる。例えば、実施形態に示される全構成要素から幾つかの構成要素を削除してもよい。さらに、異なる実施形態に亘る構成要素を適宜組み合わせてもよい。

符号の説明

- [0126] S V A…感染症発生予測装置
S V B…購買行動予測装置
I D A, I D B…入力デバイス
O D A, O D B…出力デバイス
1 A, 1 B…制御部
2 A, 2 B…プログラム記憶部
3 A, 3 B…データ記憶部
4 A, 4 B…入出力 I / F 部
5 A, 5 B…バス
1 1 A, 1 1 B…操作情報受付処理部
1 2 A, 1 2 B…パラメータ推定処理部
1 3 A…感染症発生予測処理部
1 3 B…購買行動予測処理部
1 4 A, 1 4 B…予測情報出力処理部
3 1 A…感染症発生履歴記憶部
3 1 B…購買行動履歴記憶部
3 2 A, 3 2 B…パラメータ記憶部

請求の範囲

- [請求項1] 予測対象となるイベントに関する過去の発生履歴を表す情報を取得するイベント発生履歴取得処理部と、
- 学習フェーズにおいて、前記イベントの発生を予測する予測モデルのパラメータを推定するパラメータ推定処理部と
- を具備し、
- 前記パラメータ推定処理部は、
- 前記イベントの発生確率を表す点過程の強度関数をニューラルネットワークの微分を用いて表した点過程モデルを定義する処理と、
- 前記点過程モデルの尤度を表す項と、前記イベントに関するドメイン知識を反映した所定の理論モデルを表す微分方程式からなる制約項とにより表されるパラメータ推定のための関係式を定義する処理と、
- 前記過去の発生履歴を表す情報と、前記関係式とに基づいて、前記点過程モデルの尤度を表す項に前記制約項を加算した尤度値が最小になるような前記理論モデルのパラメータおよび前記点過程モデルのパラメータを推定する処理と
- を行うイベント予測装置。
- [請求項2] 前記パラメータ推定処理部は、
- 感染症の発生確率を表す点過程の強度関数をニューラルネットワークの微分を用いて表した点過程モデルを定義する処理と、
- 前記点過程モデルの尤度を表す項と、前記感染症の発生に関するドメイン知識を反映した理論モデルを表す微分方程式からなる制約項とにより表される前記関係式を定義する処理と、
- 過去の感染症発生履歴を表す情報と、前記関係式とに基づいて、前記点過程モデルの尤度を表す項に前記制約項を加算した尤度値が最小になるような前記理論モデルのパラメータおよび前記点過程モデルのパラメータを推定する処理と

を行う、請求項1に記載のイベント予測装置。

[請求項3]

前記パラメータ推定処理部は、

商品またはサービスの購買確率を表す点過程の強度関数をニューラルネットワークの微分を用いて表した点過程モデルを定義する処理と、

前記点過程モデルの尤度を表す項と、前記商品またはサービスの購買行動に関するドメイン知識を反映した理論モデルを表す微分方程式からなる制約項とにより表される前記関係式を定義する処理と、

過去の感染症発生履歴を表す情報と、前記関係式とに基づいて、前記点過程モデルの尤度を表す項に前記制約項を加算した尤度値が最小になるような前記理論モデルのパラメータおよび前記点過程モデルのパラメータを推定する処理と

を行う、請求項1に記載のイベント予測装置。

[請求項4]

前記イベントの未来の予測条件を表す情報を取得する条件取得処理部と、

推定された前記パラメータを取得して前記予測モデルに設定し、前記パラメータが設定された前記予測モデルに前記予測条件を表す情報を説明変数として入力して、前記予測モデルから目的変数として出力されるイベント予測結果を表す情報を出力する予測処理部と

をさらに具備する請求項1に記載のイベント予測装置。

[請求項5]

情報処理装置が実行するイベント予測方法であって、

予測対象となるイベントに関する過去の発生履歴を表す情報を取得する過程と、

学習フェーズにおいて、前記イベントの発生を予測する予測モデルのパラメータを推定する過程と

を具備し、

前記パラメータを推定する過程は、

前記イベントの発生確率を表す点過程の強度関数をニューラルネ

ットワークの微分を用いて表した点過程モデルを定義する過程と、


前記点過程モデルの尤度を表す項と、前記イベントに関するドメイン知識を反映した所定の理論モデルを表す微分方程式からなる制約項とにより表されるパラメータ推定のための関係式を定義する過程と、

前記過去の発生履歴を表す情報と、前記関係式とに基づいて、前記点過程モデルの尤度を表す項に前記制約項を加算した尤度値が最小になるような前記理論モデルのパラメータおよび前記点過程モデルのパラメータを推定する過程と


を備えるイベント予測方法。

[請求項6] 請求項1乃至4のいずれかに記載のイベント予測装置が具備する前記各処理部が行う処理の少なくとも1つを、前記イベント予測装置が備えるプロセッサに実行させるプログラム。

[図1]




[図2]




[図3]

感染症発生履歴	
時刻	場所
2020/4/1 12:35	相模原市
2020/4/1 18:07	横浜市
2020/4/2 10:46	横浜市
...	
2020/8/30 22:58	鎌倉市


[図4]



[図5]




[図6]




[図7]

購買行動履歴	
時刻	商品又はサービスの種類
2020/4/1 12:35	0
2020/4/1 18:07	1
2020/4/2 10:46	1
...	
2020/8/30 22:58	0

[図8]



[図9]



INTERNATIONAL SEARCH REPORT

International application No.

PCT/JP2022/020230

A. CLASSIFICATION OF SUBJECT MATTER**G06N 20/00**(2019.01)i

FI: G06N20/00

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

B. FIELDS SEARCHED

Minimum documentation searched (classification system followed by classification symbols)

G06N 3/00-99/00

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 1971-2022

Registered utility model specifications of Japan 1996-2022

Published registered utility model applications of Japan 1994-2022

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	保住純ほか. 複数周期に着目した畳み込みネットワークによる小売時系列データの予測手法. 情報処理学会論文誌(ジャーナル). [online], 15 November 2021, vol. 62, no. 11, pp. 1829-1839, (HOZUMI, Jun et al. Retail Time-Series Prediction Model by Multi-Window Convolution. Transactions of the Information Processing Society of Japan.) abstract, sections 1, 3	1-6
A	OKAWA, Maya et al. Dynamic Hawkes Processes for Discovering Time-evolving Communities' States behind Diffusion Processes. arXiv [online], 06 June 2021, [retrieved on 14 July 2022], <URL:https://arxiv.org/pdf/2105.11152.pdf> abstract	1-6
A	WO 2021/100109 A1 (NIPPON TELEGRAPH AND TELEPHONE CORP.) 27 May 2021 (2021-05-27) entire text, all drawings	1-6

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

* Special categories of cited documents:

“A” document defining the general state of the art which is not considered to be of particular relevance

“E” earlier application or patent but published on or after the international filing date

“L” document which may throw doubts on priority claim(s) or which is cited to establish the publication date of another citation or other special reason (as specified)

“O” document referring to an oral disclosure, use, exhibition or other means

“P” document published prior to the international filing date but later than the priority date claimed

“T” later document published after the international filing date or priority date and not in conflict with the application but cited to understand the principle or theory underlying the invention

“X” document of particular relevance; the claimed invention cannot be considered novel or cannot be considered to involve an inventive step when the document is taken alone

“Y” document of particular relevance; the claimed invention cannot be considered to involve an inventive step when the document is combined with one or more other such documents, such combination being obvious to a person skilled in the art

“&” document member of the same patent family

Date of the actual completion of the international search

14 July 2022

Date of mailing of the international search report

26 July 2022

Name and mailing address of the ISA/JP

Japan Patent Office (ISA/JP)
3-4-3 Kasumigaseki, Chiyoda-ku, Tokyo 100-8915
Japan

Authorized officer

Telephone No.

INTERNATIONAL SEARCH REPORT
Information on patent family members

International application No.

PCT/JP2022/020230

Patent document cited in search report			Publication date (day/month/year)	Patent family member(s)	Publication date (day/month/year)
WO	2021/100109	A1	27 May 2021	(Family: none)	

A. 発明の属する分野の分類（国際特許分類（IPC）） G06N 20/00(2019.01)i FI: G06N20/00										
B. 調査を行った分野										
調査を行った最小限資料（国際特許分類（IPC）） G06N 3/00-99/00										
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 <table border="0"> <tr> <td>日本国実用新案公報</td> <td>1922 - 1996年</td> </tr> <tr> <td>日本国公開実用新案公報</td> <td>1971 - 2022年</td> </tr> <tr> <td>日本国実用新案登録公報</td> <td>1996 - 2022年</td> </tr> <tr> <td>日本国登録実用新案公報</td> <td>1994 - 2022年</td> </tr> </table>			日本国実用新案公報	1922 - 1996年	日本国公開実用新案公報	1971 - 2022年	日本国実用新案登録公報	1996 - 2022年	日本国登録実用新案公報	1994 - 2022年
日本国実用新案公報	1922 - 1996年									
日本国公開実用新案公報	1971 - 2022年									
日本国実用新案登録公報	1996 - 2022年									
日本国登録実用新案公報	1994 - 2022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	保住 純ほか、複数周期に着目した畳み込みネットワークによる小売時系列データの予測手法、情報処理学会 論文誌（ジャーナル）[online], 2021.11.15, Vol.62, No.11, pp.1829-1839 概要、第1節、第3節	1-6								
A	OKAWA, Maya et al., Dynamic Hawkes Processes for Discovering Time-evolving Communities' States behind Diffusion Processes, arXiv [online], 2021.06.06, [検索日 2022.07.14], <URL:https://arxiv.org/pdf/2105.11152.pdf> Abstract	1-6								
A	WO 2021/100109 A1（日本電信電話株式会社）27.05.2021（2021 - 05 - 27） 全文、全図	1-6								
☐ C欄の続きにも文献が列挙されている。 ☒ パテントファミリーに関する別紙を参照。										
<table border="0"> <tr> <td> * 引用文献のカテゴリー “A” 特に関連のある文献ではなく、一般的技术水準を示すもの “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 </td> <td> “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 </td> </tr> </table>			* 引用文献のカテゴリー “A” 特に関連のある文献ではなく、一般的技术水準を示すもの “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						
* 引用文献のカテゴリー “A” 特に関連のある文献ではなく、一般的技术水準を示すもの “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 14.07.2022	国際調査報告の発送日 26.07.2022									
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） 山本 俊介 5B 5087 電話番号 03-3581-1101 内線 3545									

国際調査報告
パテントファミリーに関する情報

国際出願番号

PCT/JP2022/020230

引用文献			公表日	パテントファミリー文献	公表日
WO	2021/100109	A1	27.05.2021	(ファミリーなし)	