

(19) 日本国特許庁(JP)

(12) 公開特許公報(A)

(11) 特許出願公開番号

特開2016-62544

(P2016-62544A)

(43) 公開日 平成28年4月25日 (2016.4.25)

(51) Int.Cl.
G06N 99/00 (2010.01)

F I
G06N 99/00 153

テーマコード (参考)

審査請求 有 請求項の数 13 O L (全 18 頁)

(21) 出願番号 特願2014-192511 (P2014-192511)
(22) 出願日 平成26年9月22日 (2014.9.22)

(71) 出願人 390009531
インターナショナル・ビジネス・マシー
ズ・コーポレーション
INTERNATIONAL BUSIN
ESS MACHINES CORPOR
ATION
アメリカ合衆国10504 ニューヨーク
州 アーモンク ニュー オーチャード
ロード
New Orchard Road, A
rmonk, New York 105
04, United States o
f America

(74) 代理人 100108501
弁理士 上野 剛史

最終頁に続く

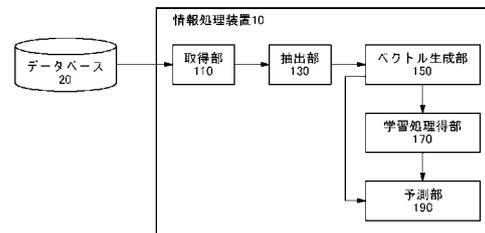
(54) 【発明の名称】 情報処理装置、プログラム、及び情報処理方法

(57) 【要約】 (修正有)

【課題】 ドライブレコーダで記録された道路の動画のよ
うな区間ごとのデータセットから、データセットに対応
するラベルをより正確に予測可能な予測モデルを提供す
る。

【解決手段】 複数の学習対象のデータセットとデータセ
ットに割り付けられた学習用のラベルとを有する学習デ
ータを用いて、予測対象のデータセットに割り付けるべ
きラベルを予測する予測モデルを学習する情報処理装置
10であって、学習データにおける複数の学習対象のデ
ータセットのそれぞれから複数のサブセットを抽出する
抽出部130と、複数の学習対象のデータセットのそれ
ぞれにおいて、複数のサブセットのそれぞれを重みづけ
てラベルの予測に反映する予測モデルを学習する学習処
理部170と、を備える。

【選択図】 図2



【特許請求の範囲】**【請求項 1】**

複数の学習対象のデータセットとそれぞれの前記学習対象のデータセットに割り付けられた学習用のラベルとを有する学習データを用いて、予測対象のデータセットに割り付けらるべきラベルを予測する予測モデルを学習する情報処理装置であって、

前記学習データにおける前記複数の学習対象のデータセットのそれぞれから複数のサブセットを抽出する抽出部と、

前記複数の学習対象のデータセットのそれぞれにおいて、前記複数のサブセットのそれぞれを重みづけてラベルの予測結果に反映する前記予測モデルを学習する学習処理部と、
を備える情報処理装置。

10

【請求項 2】

前記学習処理部は、前記サブセットごとに異なる重み係数を割り当てることにより、前記サブセットごとに重みづけて前記ラベルの予測結果に反映させる予測モデルを学習する、

請求項 1 に記載の情報処理装置。

【請求項 3】

前記サブセットのそれぞれについて、複数の特徴量を含む特徴ベクトルを生成する特徴ベクトル生成部を更に備え、

前記学習処理部は、前記特徴ベクトルの前記複数の特徴量のそれぞれに対応する複数の回帰係数を含む回帰ベクトルと、前記サブセットごとの前記重み係数とを用いる予測モデルを学習する、

20

請求項 2 に記載の情報処理装置。

【請求項 4】

前記学習処理部は、前記回帰ベクトル及び前記重み係数の事前分布と前記学習データとを用いてベイズ推定を実行し、前記回帰ベクトル及び前記重み係数の事後確率分布を学習結果として出力する、

請求項 3 に記載の情報処理装置。

【請求項 5】

前記学習処理部は、前記特徴ベクトル及び前記回帰ベクトルに基づいて前記サブセットごとに予測されるラベルと、前記学習データの対応する前記学習対象のデータセットに割り付けられた学習用のラベルとの誤差を示す項に、前記重み係数を乗じる予測モデルを用いる、

30

請求項 4 に記載の情報処理装置。

【請求項 6】

前記学習処理部は、出力された前記回帰ベクトル及び前記重み係数の事後確率分布を事前分布として用いて、追加で入力された学習データに対する前記回帰ベクトル及び前記重み係数の事後確率分布を出力する、

請求項 4 又は 5 に記載の情報処理装置。

【請求項 7】

前記複数の学習対象のデータセットのそれぞれは、経時的に観測される時系列データセットであり、前記抽出部は、前記複数のサブセットとして時系列上で連続する複数のデータ列を抽出する、

40

請求項 1 から 6 のいずれか 1 項に記載の情報処理装置。

【請求項 8】

前記抽出部は、複数の区間における複数の説明変数の値の組を含む前記データ列を抽出する、

請求項 7 に記載の情報処理装置。

【請求項 9】

前記抽出部は、時系列上で互いに一部が重複する前記複数のデータ列を抽出する、

請求項 7 又は 8 に記載の情報処理装置。

50

【請求項 10】

複数の前記予測対象のデータセットを有する予測対象データを取得する取得部と、前記予測モデルに基づき、前記予測対象のデータセットに対応するラベルを予測する予測部とを更に備える、

請求項 1 から 9 のいずれか 1 項に記載の情報処理装置。

【請求項 11】

前記学習処理部は、前記予測部が前記予測対象データが得られる度前記予測対象データに基づいて更に予測モデルを学習する、

請求項 10 に記載の情報処理装置。

【請求項 12】

コンピュータを、請求項 1 から 11 のいずれか 1 項に記載の情報処理装置として機能させるプログラム。

【請求項 13】

コンピュータにより実行される、複数の学習対象のデータセットとそれぞれの前記学習対象のデータセットに割り付けられた学習用のラベルとを有する学習データを用いて、予測対象のデータセットに割り付けるべきラベルを予測する予測モデルを学習する情報処理方法であって、

前記学習データにおける前記複数の学習対象のデータセットのそれぞれから複数のサブセットを抽出する抽出段階と、

前記複数の学習対象のデータセットのそれぞれにおいて、前記複数のサブセットのそれぞれを重みづけてラベルの予測に反映する前記予測モデルを学習する学習処理段階と、
を備える情報処理方法。

【発明の詳細な説明】

【技術分野】

【0001】

本発明は、機械学習を行う情報処理装置、プログラム、及び情報処理方法に関する。

【背景技術】

【0002】

車両に搭載した機器で路面等を撮影し、交通状況及び道路状態を分析する方法として、特許文献 1 及び 2 が知られている。また、ドライブレコーダに記録された動画等から導出した道路の特徴に基づき、区間ごとの道路の健全性を示す M C I (道路の維持管理指数) を推測することが知られている (非特許文献 1)。しかし、道路全体の特徴がまんべんなく M C I に反映されるとは限らず、道路全体の特徴から M C I を予測する従来の回帰分析を用いた手法では、M C I を正確に予測することができなかった。

[特許文献 1] 特開 2012-7922 号公報

[特許文献 2] 特開平 10-204821 号公報

[非特許文献 1] 社会インフラの効率的な維持管理の実現、村上茂之等、P. 30 ~ 637、F U J I T S U . 64, 6, 11, 2013

(<http://img.jp.fujitsu.com/downloads/jp/jmag/vol64-6/paper04.pdf>を参照。)

【発明の概要】

【発明が解決しようとする課題】

【0003】

例えば、ドライブレコーダで記録された道路の動画のような区間ごとのデータセットから、データセットに対応する M C I 等のラベルをより正確に予測可能な予測モデル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】

【0004】

本発明の第 1 の態様においては、複数の学習対象のデータセットとそれぞれの学習対象のデータセットに割り付けられた学習用のラベルとからなる学習データを用いて、予測対象のデータセットに割り付けるべきラベルを予測する予測モデルを学習する情報処理装置

10

20

30

40

50

であって、学習データにおける複数の学習対象のデータセットのそれぞれから複数のサブセットを抽出する抽出部と、複数の学習対象のデータセットのそれぞれにおいて、複数のサブセットのそれぞれを重みづけてラベルの予測に反映する予測モデルを学習する学習処理部と、を備える情報処理装置、当該情報処理装置に用いるプログラム、及び、当該情報処理を提供する。

【0005】

なお、上記の発明の概要は、本発明の必要な特徴の全てを列挙したものではない。また、これらの特徴群のサブコンビネーションもまた、発明となりうる。

【図面の簡単な説明】

【0006】

10

【図1】道路状態及びMCIの関係の一例を示す。

【図2】本実施形態の情報処理装置10のブロック図を示す。

【図3】本実施形態の情報処理装置10による学習処理のフローを示す。

【図4】本実施形態に係るデータセット及びサブセットの一例を示す。

【図5】本実施形態の情報処理装置10によるラベル予測の処理フローを示す。

【図6】本実施形態の情報処理装置10による予測精度を示す。

【図7】コンピュータ1900のハードウェア構成の一例を示す。

【発明を実施するための形態】

【0007】

以下、発明の実施の形態を通じて本発明を説明するが、以下の実施形態は特許請求の範囲にかかる発明を限定するものではない。また、実施形態の中で説明されている特徴の組み合わせの全てが発明の解決手段に必須であるとは限らない。

20

【0008】

図1は、道路状態及びMCIの関係の一例を示す。MCIは、修繕等の目安とするために、区間ごとの舗装路面の状態を定量的に評価した値である。MCIは、路面のひびわれ率、わだち掘れ量、及び/又は縦断凹凸量に基づいて算出される値であり、例えば、5未満となる場合に道路の修繕が通常必要と考えられている。

【0009】

MCIは、専用の測定機器を搭載した測定車等により正確な値が定期的に測定される。一方で、例えば汎用の乗用車のドライブレコーダの動画等を分析してMCIを推測することにより、道路状態を簡易的に適宜評価することができる。この前提として、専用の測定車で測定した正確なMCIと、ドライブレコーダの動画等との関係を予め学習することが望ましい。

30

【0010】

図1(a)~(d)は、学習に用いられる区間ごとの道路の路面状態の例と、各道路に対応して付与されるMCIの一例とを示す。図1(a)は、区間全体で比較的大きな凹凸が多数発生しており、その結果MCIが3となる道路を示す。図1(b)は、区間中の1か所に大きな穴が空いているが、他の区間は平坦であり、その結果MCIが3.1となる道路を示す。図1(c)は、区間中の2か所に大きな穴が空いているが、他の区間は平坦であり、その結果MCIが2.9となる道路を示す。図1(d)は、区間中に大きな凹凸及び穴もなく、その結果MCIが6となる道路を示す。

40

【0011】

ここで、図1(a)ではまんべんなく欠陥が生じているのに対し、図1(b)~(c)では一部のみに欠陥が生じており、両者の道路の特徴は全体的に似ていない。従って、図1(a)及び図1(b)又は(c)の道路からは、全く異なった特徴が抽出される。しかし、MCIの学習においては、全く異なる図1(a)~(c)の特徴からほぼ同一の値のMCIを予測する予測モデルを学習する必要がある。

【0012】

一方で、図1(b)~(c)のような一部にのみ欠陥を含む道路と、図1(d)のような欠陥がほぼ無い道路とは道路の大部分において特徴が類似する。従って、図1(b)又

50

は(c)と図1(d)の道路からは、類似した特徴が抽出される。しかし、MCIの学習においては、類似する図1(b)~(d)の特徴から全く異なる値のMCIを予測する予測モデルを学習する必要がある。

【0013】

このように、MCIを算出する計算ルールは非線形かつ煩雑であり、ドライブレコーダのような簡易的な測定データを学習データとしてMCIを正確に予測する予測モデルを生成することは困難であった。本発明に係る情報処理装置は、このような簡易的に測定されたデータセットとラベル割り付けとの非線形な関係をより正確に学習する。

【0014】

図2は、本実施形態に係る情報処理装置10のブロック図を示す。情報処理装置10は、複数の学習対象のデータセットとそれぞれの前記学習対象のデータセットに対して予め割り付けられた学習用のラベルとを有する学習データを用いて、予測対象のデータセットに割り付けるべきラベルを予測する予測モデルを学習し、学習した予測モデルに基づいて予測対象データからラベルを予測する。情報処理装置10は、特徴量取得部110、抽出部130、ベクトル生成部150、学習処理部170、及び、予測部190を備える。

10

【0015】

取得部110は、情報処理装置10の処理に用いるデータを取得する。例えば、取得部110は、外部のデータベース20等から複数の学習対象のデータセットに対して学習用のラベルが割り付けられた学習データを取得する。一例として、情報処理装置10は、複数のデータセットとしてドライブレコーダで撮影した複数の区間ごとの道路の動画を含み、ラベルとして各区間の測定済みのMCIを含む学習データを取得する。

20

【0016】

また、例えば、取得部110は、外部のデータベース20等から予測対象となる複数の予測対象のデータセットを有する予測対象データを取得してよい。取得部110は、取得した学習データ及び予測対象データを抽出部130に供給する。

【0017】

抽出部130は、学習データ及び予測対象データにおける複数のデータセットのそれぞれから複数のサブセットを抽出する。例えば、抽出部130は、複数のデータセットとして取得した区間ごとの道路の動画等を予め定められた時間で分割したものを、複数のサブセットとして抽出する。抽出部130は、複数のデータセットについて抽出した複数のサブセットを、ベクトル生成部150に供給する。

30

【0018】

ベクトル生成部150は、学習データ及び予測対象データに係るサブセットのそれぞれについて、サブセットの特徴を表す複数の特徴量を含む特徴ベクトルを生成する。例えば、ベクトル生成部150は、各サブセットに含まれる道路の動画のデータ(例えば、道路の輝度情報等)を複数の特徴量に変換し、複数の特徴量を含む特徴ベクトルをサブセットごとに生成する。ベクトル生成部150の具体的な処理内容は後述する。ベクトル生成部150は、学習データについて生成した特徴ベクトルを学習処理部170に供給し、予測対象データについて生成した特徴ベクトルを予測部190に供給する。

【0019】

学習処理部170は、複数の学習対象のデータセットのそれぞれにおいて、複数のサブセットのそれぞれを重みづけてラベルの予測に反映する予測モデルを学習する。これにより、学習処理部170は、ラベルの予測に重く反映させるサブセット、及び、ラベルの予測にあまり反映させないサブセットを区別した上で、複数のサブセットからラベルを予測する予測モデルを構築する。学習処理部170の具体的な処理内容は後述する。学習処理部170は、学習した結果得られた予測モデルを予測部190に供給する。

40

【0020】

予測部190は、学習処理部170が学習した予測モデルに基づき、予測対象データのデータセットに対応するラベルを予測する。例えば、予測部190は、予測対象データの複数のデータセットについて生成された特徴ベクトルを予測モデルに適用し、予測対象デ

50

ータのデータセットに対応するラベルを予測する。予測部 190 の具体的な処理内容は後述する。

【0021】

このように、情報処理装置 10 は、ラベル割り付けの対象となるデータセットから複数のサブセットを抽出し、サブセットごとに異なる重みづけをして予測モデルを生成する。これにより、情報処理装置 10 は、サブセットのうち、ラベルにより大きな影響を与える部分をより大きな割合で予測に用いることができ、データセット全体を均等に予測に用いる方法よりも正確な予測モデルを学習することができる。

【0022】

図 3 は、本実施形態の情報処理装置 10 の学習処理部 170 による学習処理のフローを示す。情報処理装置 10 は、学習処理に用いる学習データとして、一定の手順に従って複数のサブセットが抽出可能なデータセット、及び、データセットに対して割り当てられるべきラベルを用いる。以下の説明では、一例として、情報処理装置 10 が、データセットとしてドライブレコーダから取得した道路の動画等を用い、ラベルとして専用の測定機器で予め測定された MCI を用いた場合について説明する。これ以外にも、情報処理装置 10 は、製品の製造工程の画像と製品の欠陥度等の、様々なデータセットとラベルとの非線形な組を学習データとして用いることができる。

10

【0023】

まず、S110 において、取得部 110 が、学習データとして、複数の学習対象のデータセット、及び、データセットのそれぞれに割り付けるべき学習用のラベルを取得する。例えば、取得部 110 は、まず、情報処理装置 10 の外部又は内部に設けられたデータベース 20 から乗用車に搭載されたドライブレコーダで撮影した動画、同乗用車に搭載された加速度センサが測定した時系列上の加速度データ、及び、同乗用車に搭載された GPS による位置データを取得する。

20

【0024】

次に、取得部 110 は、各時刻における乗用車の位置を GPS から取得し、一の MCI が予め割り当てられた道路の第 1 区間長さ（例えば 100 m）ごとに、動画及び加速度データを分割する。取得部 110 は、複数個（例えば、N 個）に分割された動画及び加速度データを、複数のデータセットとし、各区間に対応する予め測定された MCI を割り付けるべきラベルとする。取得部 110 は、取得した学習データを抽出部 130 に供給する。

30

【0025】

次に、S120 において、抽出部 130 が、学習データにおける複数のデータセットのそれぞれから複数のサブセットを抽出する。例えば、抽出部 130 は、経時的に観測される時系列データセットから複数のサブセットとして時系列上で連続する複数のデータ列を抽出する。一例として、抽出部 130 は、道路の第 2 区間長さ（例えば 10 m）ごとに、データセットの動画及び加速度データを時系列上で分割し、第 2 区間ごとの複数のデータ列から、各サブセットとして予め定められた数（例えば、3 個）のデータ列を抽出する。

【0026】

ここで、抽出部 130 は、スライディングウィンドウを用いて、時系列上で互いに一部が重複する又は重複しない複数のデータ列を抽出してよい。例えば、抽出部 130 は、それぞれのデータセットに含まれる動画及び加速度データから、時間的な重複を含む複数（例えば D 個）のサブセットを抽出する。

40

【0027】

抽出部 130 は、データ列として複数の説明変数の値の組を抽出してよい。一例として、抽出部 130 は、それぞれのデータ列として、第 2 区間長さごとの動画に含まれる道路画像の輝度情報及び輝度の勾配（エッジ）情報等、及び、加速度データ中に含まれる XYZ 軸上の加速度等を抽出してよい。抽出部 130 は、抽出した複数のサブセットをベクトル生成部 150 に供給する。

【0028】

次に、S130 において、ベクトル生成部 150 は、サブセットのそれぞれについて、

50

複数の特徴量を含む特徴ベクトルを生成する。例えば、ベクトル生成部 150 は、 n 番目 ($n = 1 \sim N$) のデータセットにおける、 d 番目 ($d = 1 \sim D$) のサブセットに含まれる複数のデータ列に基づいて、複数の特徴量を要素として含む特徴ベクトル $x_{n,d}$ を生成する。

【0029】

例えば、ベクトル生成部 150 は、サブセット中のデータ列に含まれる輝度情報及び輝度の勾配 (エッジ) 情報等、並びに、XYZ 軸上の加速度等の説明変数の基本統計量 (平均、及び / 又は、標準偏差等) を算出し、取得した値を特徴量とする特徴ベクトル $x_{n,d}$ を生成してよい。

【0030】

これに代えて、ベクトル生成部 150 は、サブセット中の複数のデータ列から *Bag of Words* に基づいて特徴ベクトル $x_{n,d}$ を生成してよい。例えば、ベクトル生成部 150 は、サブセット中の説明変数において、予め定められた値の複数種のパターンを定義し、サブセット中で検出された複数種のパターンの出現頻度 (ヒストグラム) を特徴量として有する特徴ベクトル $x_{n,d}$ を生成してよい。ベクトル生成部 150 は、生成した特徴ベクトルを学習処理部 170 に供給する。

【0031】

次に、S140 において、学習処理部 170 は、複数のデータセットのそれぞれにおいて、複数のサブセットのそれぞれを重みづけてラベルの予測に反映する予測モデルを学習する。例えば、学習処理部 170 は、サブセットごとに異なる重み係数 $w_{n,d}$ を割り当て、当該サブセットごとの重み係数 $w_{n,d}$ と、特徴ベクトル $x_{n,d}$ と、複数の特徴量のそれぞれに対応する複数の回帰係数を含む回帰ベクトル w とを用いて予測モデルを学習する。これにより、学習処理部 170 は、サブセットごとに重みづけてラベルの予測結果に反映させる予測モデルを学習する。

【0032】

ここで、学習処理部 170 は、回帰ベクトル w 及び重み係数 $w_{n,d}$ の事前分布と、及び、学習データ D を用いて重み付きのベイズ推定を実行し、回帰ベクトル w 及び重み係数 $w_{n,d}$ の事後確率分布を学習結果として出力してよい。

【0033】

一例として、学習処理部 170 は、数式 1 に示す予測モデルに基づいて、回帰ベクトル w 及び重み係数 $w_{n,d}$ を学習してよい。

【数 1】

$$p(Y|\mathcal{X}, w, \beta, \eta) = (2\pi\beta^{-1})^{-\frac{N}{2}} \exp\left(-\frac{\beta}{2} \sum_n^N \sum_d^{D_n} \eta_{n,d} L(y_n, w^T x_{n,d})\right) \dots \text{数式1}$$

【0034】

ここで、 $p(Y|\mathcal{X}, w, \beta, \eta)$ は、 N 個のデータセット X_n の全体からなる集合 \mathcal{X} 、 w 、 β 、 η の値を所与としたときの、 N 個のラベル y_n の全体からなる集合 Y の確率分布を示す。集合 X_n は学習データにおける n 番目のデータセットを示し、 D_n は n 番目のデータセットから抽出されるサブセットの個数を示し、ベクトル $x_{n,d}$ は X_n における d 番目のサブセットに対応する特徴ベクトルを示し、 y_n は学習データで X_n に割り付けられるラベルを示し、 $w_{n,d}$ は $w_{n,1} \sim w_{n,D_n}$ の総和が 1 となる各サブセットの重み係数を示し、 β はノイズの精度を示す。また、 $L(\cdot)$ は誤差関数であり、例えば、 $L(a, b) = (a - b)^2$ となる二乗誤差であってよい。

【0035】

数式 1 に示すように、学習処理部 170 は、特徴ベクトル $x_{n,d}$ 及び回帰ベクトル w に基づいてサブセット d ごとに予測されるラベル ($w^T x_{n,d}$) と、学習データの対応するデータセットに割り付けられたラベル y_n との誤差を示す項 $L(y_n, w^T x_{n,d})$ に、重み係数 $w_{n,d}$ を乗じた値の $n = 1 \sim N$ 及び $d = 1 \sim D_n$ の総和に応じた数を指数とする指数関数の値を、学習データにおけるラベル y_n の集合 Y の確率分布 $p(Y|\mathcal{X}, w, \beta, \eta)$ とする予測モデルを用いてよい。

10

20

30

40

50

【0036】

学習処理部170は、上記予測モデルを用いて、 $n = N$ のデータ全体を所与としたときの回帰ベクトル w の事後確率分布 $p(w | Y)$ 及び重み係数の事後確率分布 $p(w | Y)$ を算出する。例えば、学習処理部170は、学習データ集合におけるラベル Y の確率分布 $p(Y | w, \dots)$ に回帰ベクトル w の事前確率分布 $p(w)$ を乗じ、不要なパラメータ \dots について周辺化したものを、正規化定数となるラベル Y の周辺分布 $p(Y | \dots)$ で除することにより、回帰ベクトル w の事後確率分布 $p(w | Y)$ を算出してよい。一例として、学習処理部170は、回帰ベクトル w の事後確率分布を $p(w | Y) = [p(Y | w, \dots) \times p(w, \dots) d w] / [p(Y | \dots) \times p(w, \dots) d w]$ を用いて算出してよい。

10

【0037】

また、例えば、学習処理部170は、学習データ集合におけるラベル y_n の集合 Y の確率分布 $p(Y | w, \dots)$ に重み係数の事前確率分布 $p(w)$ を乗じ、不要なパラメータ w, \dots について周辺化したものを、正規化定数となる Y の周辺分布 $p(Y | \dots)$ で除することにより、重み係数の事後確率分布 $p(w | Y)$ を算出してよい。一例として、学習処理部170は、重み係数の事後確率分布を $p(w | Y) = [p(Y | w, \dots) \times p(w, \dots) d w] / [p(Y | \dots) \times p(w, \dots) d w]$ を用いて算出してよい。

【0038】

学習処理部170は、変分ベイズ法を用いて高速に回帰ベクトル w 及び重み係数を算出してよく、これに加えて/代えて、マルコフ連鎖モンテカルロ法(MCMC法)等のサンプリングにより回帰ベクトル w 及び重み係数を算出してもよい。

20

【0039】

また、学習処理部170は、ARD(Automatic Relevance Determination)を用いて、説明変数の選択を同時に行ないながら、予測モデルを構築してもよい。例えば、学習処理部170は、回帰ベクトル w の事前分布 $p(w)$ に疎なモデル(ARD事前分布)を用いることにより、複数の説明変数のうちラベルの予測に用いるものと用いないものを区別することができる。これにより、学習処理部170は、ラベルの予測に害をなす冗長な説明変数の影響(多重共線性等の悪い影響)を排除することができる。

30

【0040】

また、学習処理部170は、数式1に示す線形な予測モデルを用いることに代えて、非線形な予測モデルを用いてよい。例えば、学習処理部170は、特徴ベクトル $x_{n,d}$ の代わりに、特徴ベクトル $x_{n,d}$ を基底関数に入力したベクトル $\phi(x_{n,d})$ を用いてよい。これにより、学習処理部170は、非線形な予測モデルを学習することが可能となる。一例として、学習処理部170は、数式2に示す予測モデルに基づいて、回帰ベクトル w 及び重み係数 $\eta_{n,d}$ を学習してよい。

【数2】

$$p(Y | \mathcal{X}, w, \beta, \eta) = \frac{1}{N} \exp \left(-\frac{\beta}{2} \sum_n^N \sum_d^{D_n} \eta_{n,d} L(y_n, w^T \phi(x_{n,d})) \right) \dots \text{数式2}$$

40

【0041】

ここで、学習処理部170は、カーネル法を用いて非線形な予測モデルを学習してよい。例えば、学習処理部170は、基底関数 $\phi(x_{n,d})$ として、 $\phi(x_{n,d}) = (\exp(-|x_{n,d} - x_{(1)}|^2), \exp(-|x_{n,d} - x_{(2)}|^2), \dots, \exp(-|x_{n,d} - x_{(M)}|^2))$ を用いてよい。ここでベクトル $x_{(1)}, x_{(2)}, \dots, x_{(M)}$ は、予め定められたパターンの値を有するベクトルであり、例えば、過去に測定された道路の動画特徴及び加速度の値に対応したパターンであってよい。

【0042】

学習処理部170は、特徴ベクトル $x_{n,d}$ と過去の測定結果に対応するベクトル $x_{(m)}$

50

1)、 $x(2) \dots x(M)$ とを比較し、両者が一致する成分を回帰ベクトル w に適用する基底関数 $(x_{n,d})$ として出力する。これにより、学習処理部170は、過去に測定された道路の動画等に基づいて適切な回帰ベクトル w を学習することができる。

【0043】

別の一例として、学習処理部170は、 $(x_{n,d}) = (x_1^1 + x_2^1 + x_3^1 + \dots + x_z^1, x_1^2 + x_2^2 + x_3^2 + \dots + x_z^2, \dots, x_1^M + x_2^M + x_3^M + \dots + x_z^M)$ (x_1, x_2, \dots, x_z は定数で x_1, x_2, \dots, x_M は特徴ベクトル $x_{n,d}$ の各要素)等を用いることで、線形モデルと非線形モデルの混合モデルとなる予測モデルを用いてよい。

【0044】

更に、学習処理部170は、既に学習済みの学習データに加えて追加で入力された学習データを更に用いて、回帰ベクトル及び重み係数を学習してよい。例えば、学習処理部170は、学習データに基づき出力した回帰ベクトル及び重み係数の事後確率分布を事前分布として用い、追加で入力された学習データに対する回帰ベクトル及び重み係数の事後確率分布を出力してよい。

【0045】

学習処理部170は、重み付きのベイズ推定を用いる代わりに、重み付きの最小二乗法又は重み付き最尤推定法等により、回帰ベクトル w 及び重み係数を学習してもよい。

【0046】

次に、S150において、学習処理部170は、学習の結果を出力する。例えば、学習処理部170は、学習の結果得られた回帰ベクトル w 及び重み係数を情報処理装置10の表示画面に表示し、及び/又は、情報処理装置10の内部/外部の記憶装置に格納してよい。また、学習処理部170は、学習の結果得られた回帰ベクトル w 及び重み係数を予測部190に供給する。

【0047】

このように情報処理装置10は、ラベル付けの対象となるデータセットから複数のサブセットを抽出し、データセット及びサブセットごとの重み係数 $w_{n,d}$ と回帰ベクトル w とを同時に学習する。これにより、情報処理装置10は、各サブセットのラベルへの影響の度合い(すなわち、重み係数 $w_{n,d}$)を学習する。

【0048】

すなわち、情報処理装置10は、データセットのうち割り当てられるラベルに与える影響が大きい部分を特定する。これにより、情報処理装置10は、ラベルへの影響が少ないサブセットによるラベルの予測への誤差を低減するので、より正確に回帰ベクトル w を学習することができる。

【0049】

例えば、情報処理装置10によると、道路のうち割り当てられたMCIを代表する部分を特定することができる。一例として、情報処理装置10によると、図1(a)については区間全体をMCIを代表する部分として特定し、図1(b)及び(c)については穴の空いた部分をMCIを代表する部分として特定する。これにより、情報処理装置10は、全く異なる図1(a)~(c)の特徴からほぼ同一の値のMCIを予測する予測モデルを学習し、類似する図1(b)~(d)の特徴から全く異なる値のMCIを予測する予測モデルを学習することができる。情報処理装置10によると、MCIが低いデータセットのうち、重み係数 $w_{n,d}$ が大きい部分を実際に修理が必要な部分として特定することができるので、道路の検査負担を低減することができる。

【0050】

図4は、本実施形態に係る学習データのデータセット及びサブセットの一例を示す。取得部110は、図示するように、データセット1、データセット2、...データセットNを含むN個のデータセットを取得してよい。取得部110は、各データセットとして、説明変数の組をデータ列ごとに取得する。例えば、道路のMCIを学習する場合、一のデータセットが10個のデータ列を含むとすると、取得部110は、各データセットとして、V

10

20

30

40

50

個の説明変数（道路の輝度情報等）を含むデータ列を第2区間長さ（例えば10m）ごとに10個取得する。

【0051】

抽出部120は、各データセット（例えば、データセット1）から、サブセット1、サブセット2、サブセット3、...サブセットDを含むD個のサブセットを抽出する。抽出部120は、各サブセット1～DとしてV個の説明変数からなるデータ列をL個取得してよい。例えば、抽出部120は、連続する3個のデータ列（例えば、10m×3の道路に対応）に係る説明変数の組を各サブセットとして取得する。

【0052】

ここで、抽出部120は、互いに重複するデータ列を含む説明変数の組を各サブセットとして取得してよい。例えば、図示するように、抽出部120は、1～3番目のデータ列に係る説明変数 $d_{1,1} \sim d_{3,v}$ の組をサブセット1として取得し、2～4番目のデータ列に係る説明変数 $d_{2,1} \sim d_{4,v}$ の組をサブセット2として取得し、3～5番目のデータ列に係る説明変数 $d_{3,1} \sim d_{5,v}$ の組をサブセット3として取得し、...D～D+2番目のデータ列に係る説明変数 $d_{D,1} \sim d_{D+2,v}$ の組をサブセットDとして取得してよい。

10

【0053】

図5は、本実施形態の情報処理装置10の予測部190によるラベル予測の処理フローを示す。本実施形態において、情報処理装置10は、S210～S250の処理を実行することにより、予測モデルに基づくシミュレーションを実行する。

20

【0054】

まず、S210において、取得部110が、予測対象となる複数のデータセットを有する予測対象データを取得する。ここで、取得部110は、S110で複数のデータセットを取得したのと同様の手法により、予測対象の複数のデータセットを取得してよい。取得部110は、取得した予測対象データを抽出部130に供給する。

【0055】

次に、S220において、抽出部130が、予測対象データにおける複数のデータセットのそれぞれから予測対象の複数のサブセットを抽出する。抽出部130は、S120における学習データからの複数のサブセットの抽出と同様の手法により、予測対象の複数のサブセットを抽出してよい。抽出部130は、抽出した予測対象の複数のサブセットをベクトル生成部150に供給する。

30

【0056】

次に、S230において、ベクトル生成部150は、予測対象のサブセットのそれぞれについて、複数の特徴量を含む特徴ベクトルを生成する。ベクトル生成部150は、S130における同様の手法により、予測対象のサブセットについて特徴ベクトルを生成してよい。ベクトル生成部150は、生成した特徴ベクトルを予測部190に供給する。

【0057】

S240において、予測部190は、学習処理部170が学習した予測モデルに基づき予測対象データの複数の予測対象のデータセットに対応するラベルを予測する。例えば、予測部190は、数式3の予測モデルに基づき、学習された回帰ベクトル w を用いて、予測対象のデータセット $X_{n'}$ に対応するラベル $y_{n'}$ 及び重み係数 $\eta_{n',d}$ を同時に予測してよい。

40

【数3】

$$p(y_{n'} | X_{n'}, w, \beta, \eta) = (2\pi\beta^{-1})^{-\frac{N}{2}} \exp\left(-\frac{\beta}{2} \sum_d^{Dn} \eta_{n',d} L(y_{n'}, w^T x_{n',d})\right) \dots \text{数式3}$$

【0058】

例えば、予測部190は、学習された w と η を入力した確率 $p(y_{n'} | X_{n'}, w, \eta, \beta)$ に最大値を与えるラベル $y_{n'}$ 及び重み係数 $\eta_{n',d}$ の組におけるラベル $y_{n'}$ を予測対象データのデータセット $X_{n'}$ から予測されるラベルとしてよい。

50

【0059】

また、例えば、予測部190は、学習結果に含まれる回帰ベクトル w の事後確率分布を $p(w|Y, \chi)$ とし、重み係数 w_n, d の事前確率分布を $p(\eta)$ とすることにより、回帰ベクトル w 及び重み係数 w_n, d を周辺化し、数式4により、ラベル $y_{n'}$ の確率分布 $p(y_{n'}|X_{n'}, Y, \chi, \beta)$ を算出してもよい。また、予測部190は、ノイズパラメータ β の事後確率分布を $p(\beta|Y, \chi)$ とし、回帰ベクトル w 、重み係数 w_n, d 、及びノイズパラメータ β の1つ、2つ、又は全て(例えば、重み係数 w_n, d とノイズパラメータ β)を周辺化してもよい。

【数4】

$$p(y_{n'}|X_{n'}, Y, \chi, \beta) = \int p(y_{n'}|X_{n'}, w, \beta, \eta) p(\eta) p(w|Y, \chi) d\eta dw \quad \dots \text{数式4}$$

10

【0060】

また、予測部190は、重み係数 w_n, d を予測せずにラベル $y_{n'}$ のみを予測することで、簡易的な予測をしてもよい。例えば、予測部190は、各サブセット毎の予測値(w_n, d)の $n=1$ から $n=N$ における平均値及び/又は中央値等を予測値とし、ラベル $y_{n'}$ を予測してよい。

【0061】

次にS250において、予測部190は、予測結果を出力する。例えば、予測部190は、予測により得られたラベル $y_{n'}$ を情報処理装置10の表示画面に表示し、及び/又は、情報処理装置10の内部/外部の記憶装置に格納してよい。

20

【0062】

また、予測部190は、予測対象データが得られる度に予測対象データ、及び、予測対象データから予測したラベル $y_{n'}$ を学習処理部170に供給してもよい。学習処理部170は、予測部が予測対象データ及び予測対象データに対応して予測したラベルを追加の学習データとし、追加の学習データに基づいて更に予測モデルを学習してよい。これにより、情報処理装置10は、予測対象データを用いて、予測結果が更に正確になるように予測モデルを更新することができる。

【0063】

このように情報処理装置10は、学習処理部170が学習した重み係数 w_n, d 及び回帰ベクトル w を用いて、予測対象データ $X_{n'}$ から対応するラベル $y_{n'}$ を予測する。これにより、情報処理装置10は、サブセットごとのラベルへの影響を考慮して回帰された回帰ベクトル w を用いて、より正確にラベル $y_{n'}$ を予測することができる。

30

【0064】

図6は、本実施形態の情報処理装置10による予測精度を示す。図6には、ドライブレコーダ等から得られた異なる4個のデータセット1~4に対して、従来の疎な線形回帰法によりラベル(MCI)を予測した場合のAUC(Area Under Curve)と、本実施形態の情報処理装置10でフルベイズなモデリングで、ARD事前分布及び変分ベイズ実装により予測モデルを構築した場合のAUCとを交差検定で評価した結果が示される。AUCは、MCIが5以上か5未満を正確に予測できた割合を示す。

【0065】

データセットに含まれる説明変数として、加速度センサから得られる7変数×1秒毎のデータ及びドライブレコーダ(カメラ)から得られる90変数×0.1秒毎のデータを用い、ラベルとして100m単位に記録される500個のMCI値を用いた。データセット1~2に対応するMCIとデータセット3~4では、対応するMCIの算出に異なる算出式を用いた。また、データセット1及び3には、ヒューリスティクスを用いた前処理をし、データセット2及び4には前処理をしていない。

40

【0066】

図示するように、データセット1~4のいずれにおいても、本実施形態の方法によると、従来の線形回帰と比較して数%程度高いAUCが得られる。従って、本実施形態の情報処理装置10は従来の方法と比較して高い精度でラベルを予測できることが示される。

50

【 0 0 6 7 】

上記本実施形態では、情報処理装置 10 は、学習データ及び予測対象データから 1 種類の特徴ベクトル $x_{n,d}$ を生成し、学習データ及び予測対象データに対して 1 種類の重み係数 $w_{n,d}$ を用いた。これに代えた変形例として、情報処理装置 10 は、複数種類の特徴ベクトル $x^1_{n,d}$ 及び $x^2_{n,d}$...、及び、対応する複数種類の重み係数 $w^1_{n,d}$ 、 $w^2_{n,d}$... を用いてもよい。例えば、情報処理装置 10 は、ドライブレコーダの動画の特徴をベクトル化した特徴ベクトル $x^1_{n,d}$ を生成し、加速度センサの測定値の特徴をベクトル化した特徴ベクトル $x^2_{n,d}$ を生成し、それぞれの特徴ベクトルごとに重み係数 $w^1_{n,d}$ 、 $w^2_{n,d}$ を学習してよい。

【 0 0 6 8 】

これにより、情報処理装置 10 は、データセットに含まれる説明変数のグループごとに異なる重みづけをして、ラベルを学習することができる。例えば、情報処理装置 10 は、データセットのある部分ではドライブレコーダの動画がラベルに対して大きく影響するが、別の部分では加速度の値がラベルに大きく影響するような場合に、より正確に学習データに対するラベルを学習することができる。

【 0 0 6 9 】

図 7 は、情報処理装置 10 として機能するコンピュータ 1900 のハードウェア構成の一例を示す。本実施形態に係るコンピュータ 1900 は、ホスト・コントローラ 2082 により相互に接続される CPU 2000、RAM 2020、グラフィック・コントローラ 2075、及び表示装置 2080 を有する CPU 周辺部と、入出力コントローラ 2084 によりホスト・コントローラ 2082 に接続される通信インターフェイス 2030、ハードディスクドライブ 2040、及び CD-ROM ドライブ 2060 を有する入出力部と、入出力コントローラ 2084 に接続される ROM 2010、フレキシブルディスク・ドライブ 2050、及び入出力チップ 2070 を有するレガシー入出力部を備える。

【 0 0 7 0 】

ホスト・コントローラ 2082 は、RAM 2020 と、高い転送レートで RAM 2020 をアクセスする CPU 2000 及びグラフィック・コントローラ 2075 とを接続する。CPU 2000 は、ROM 2010 及び RAM 2020 に格納されたプログラムに基づいて動作し、各部の制御を行う。グラフィック・コントローラ 2075 は、CPU 2000 等が RAM 2020 内に設けたフレーム・バッファ上に生成する画像データを取得し、表示装置 2080 上に表示させる。これに代えて、グラフィック・コントローラ 2075 は、CPU 2000 等が生成する画像データを格納するフレーム・バッファを、内部に含んでもよい。

【 0 0 7 1 】

入出力コントローラ 2084 は、ホスト・コントローラ 2082 と、比較的高速な入出力装置である通信インターフェイス 2030、ハードディスクドライブ 2040、CD-ROM ドライブ 2060 を接続する。通信インターフェイス 2030 は、有線又は無線によりネットワークを介して他の装置と通信する。また、通信インターフェイスは、通信を行うハードウェアとして機能する。ハードディスクドライブ 2040 は、コンピュータ 1900 内の CPU 2000 が使用するプログラム及びデータを格納する。CD-ROM ドライブ 2060 は、CD-ROM 2095 からプログラム又はデータを読み取り、RAM 2020 を介してハードディスクドライブ 2040 に提供する。

【 0 0 7 2 】

また、入出力コントローラ 2084 には、ROM 2010 と、フレキシブルディスク・ドライブ 2050、及び入出力チップ 2070 の比較的低速な入出力装置とが接続される。ROM 2010 は、コンピュータ 1900 が起動時に実行するブート・プログラム、及び / 又は、コンピュータ 1900 のハードウェアに依存するプログラム等を格納する。フレキシブルディスク・ドライブ 2050 は、フレキシブルディスク 2090 からプログラム又はデータを読み取り、RAM 2020 を介してハードディスクドライブ 2040 に提供する。入出力チップ 2070 は、フレキシブルディスク・ドライブ 2050 を入出力コ

10

20

30

40

50

ントローラ 2084 へと接続するとともに、例えばパラレル・ポート、シリアル・ポート、キーボード・ポート、マウス・ポート等を介して各種の入出力装置を入出力コントローラ 2084 へと接続する。

【0073】

RAM 2020 を介してハードディスクドライブ 2040 に提供されるプログラムは、フレキシブルディスク 2090、CD-ROM 2095、又は IC カード等の記録媒体に格納されて利用者によって提供される。プログラムは、記録媒体から読み出され、RAM 2020 を介してコンピュータ 1900 内のハードディスクドライブ 2040 にインストールされ、CPU 2000 において実行される。

【0074】

コンピュータ 1900 にインストールされ、コンピュータ 1900 を情報処理装置 10 として機能させるプログラムは、取得モジュール、抽出モジュール、ベクトル生成モジュール、学習処理モジュール、及び、予測モジュールを備える。これらのプログラム又はモジュールは、CPU 2000 等に働きかけて、コンピュータ 1900 を、特徴量取得部 110、抽出部 130、ベクトル生成部 150、学習処理部 170、及び、予測部 190 としてそれぞれ機能させてよい。

【0075】

これらのプログラムに記述された情報処理は、コンピュータ 1900 に読み込まれることにより、ソフトウェアと上述した各種のハードウェア資源とが協働した具体的手段である特徴量取得部 110、抽出部 130、ベクトル生成部 150、学習処理部 170、及び、予測部 190 として機能する。そして、これらの具体的手段によって、本実施形態におけるコンピュータ 1900 の使用目的に応じた情報の演算又は加工を実現することにより、使用目的に応じた特有の情報処理装置 10 が構築される。

【0076】

一例として、コンピュータ 1900 と外部の装置等との間で通信を行う場合には、CPU 2000 は、RAM 2020 上にロードされた通信プログラムを実行し、通信プログラムに記述された処理内容に基づいて、通信インターフェイス 2030 に対して通信処理を指示する。通信インターフェイス 2030 は、CPU 2000 の制御を受けて、RAM 2020、ハードディスクドライブ 2040、フレキシブルディスク 2090、又は CD-ROM 2095 等の記憶装置上に設けた送信バッファ領域等に記憶された送信データを読み出してネットワークへと送信し、もしくは、ネットワークから受信した受信データを記憶装置上に設けた受信バッファ領域等へと書き込む。このように、通信インターフェイス 2030 は、DMA (ダイレクト・メモリ・アクセス) 方式により記憶装置との間で送受信データを転送してもよく、これに代えて、CPU 2000 が転送元の記憶装置又は通信インターフェイス 2030 からデータを読み出し、転送先の通信インターフェイス 2030 又は記憶装置へとデータを書き込むことにより送受信データを転送してもよい。

【0077】

また、CPU 2000 は、ハードディスクドライブ 2040、CD-ROM ドライブ 2060 (CD-ROM 2095)、フレキシブルディスク・ドライブ 2050 (フレキシブルディスク 2090) 等の外部記憶装置に格納されたファイルまたはデータベース等の中から、全部または必要な部分を DMA 転送等により RAM 2020 へと読み込ませ、RAM 2020 上のデータに対して各種の処理を行う。そして、CPU 2000 は、処理を終えたデータを、DMA 転送等により外部記憶装置へと書き戻す。このような処理において、RAM 2020 は、外部記憶装置の内容を一時的に保持するものとみなせるから、本実施形態においては RAM 2020 及び外部記憶装置等をメモリ、記憶部、または記憶装置等と総称する。

【0078】

例えば、情報処理装置 10 の記憶部は、特徴量取得部 110、抽出部 130、ベクトル生成部 150、学習処理部 170、及び、予測部 190 から受け取った / へ提供するデータを適宜記憶してよい。例えば、記憶部は、取得部 110 から入力されたデータを受け取

10

20

30

40

50

って記憶してよい。また、記憶部は、学習処理部 170 が学習した結果等を記憶してよい。

【0079】

なお、本実施形態の説明において、一の構成要素（例えば、取得部 110）から別の構成要素（例えば、抽出部 120）に情報（例えば、複数のデータセット）を供給したと記載するときは、一の構成要素から別の構成要素に直接情報を受け渡すことだけでなく、記憶部への情報の格納及び情報の読み出しを介して情報を渡すことをも含んでよい。

【0080】

本実施形態における各種のプログラム、データ、テーブル、データベース等の各種の情報は、このような記憶装置上に格納されて、情報処理の対象となる。なお、CPU 2000 は、RAM 2020 の一部をキャッシュメモリに保持し、キャッシュメモリ上で読み書きを行うこともできる。このような形態においても、キャッシュメモリは RAM 2020 の機能の一部を担うから、本実施形態においては、区別して示す場合を除き、キャッシュメモリも RAM 2020、メモリ、及び / 又は記憶装置に含まれるものとする。

【0081】

また、CPU 2000 は、RAM 2020 から読み出したデータに対して、プログラムの命令列により指定された、本実施形態中に記載した各種の演算、情報の加工、条件判断、情報の検索・置換等を含む各種の処理を行い、RAM 2020 へと書き戻す。例えば、CPU 2000 は、条件判断を行う場合においては、本実施形態において示した各種の変数が、他の変数または定数と比較して、大きい、小さい、以上、以下、等しい等の条件を満たすか否かを判断し、条件が成立した場合（又は不成立であった場合）に、異なる命令列へと分岐し、またはサブルーチンを呼び出す。

【0082】

また、CPU 2000 は、記憶装置内のファイルまたはデータベース等に格納された情報を検索することができる。例えば、第 1 属性の属性値に対し第 2 属性の属性値がそれぞれ対応付けられた複数のエントリが記憶装置に格納されている場合において、CPU 2000 は、記憶装置に格納されている複数のエントリの中から第 1 属性の属性値が指定された条件と一致するエントリを検索し、そのエントリに格納されている第 2 属性の属性値を読み出すことにより、所定の条件を満たす第 1 属性に対応付けられた第 2 属性の属性値を得ることができる。

【0083】

以上、本発明を実施の形態を用いて説明したが、本発明の技術的範囲は上記実施の形態に記載の範囲には限定されない。上記実施の形態に、多様な変更または改良を加えることが可能であることが当業者に明らかである。その様な変更または改良を加えた形態も本発明の技術的範囲に含まれ得ることが、特許請求の範囲の記載から明らかである。

【0084】

特許請求の範囲、明細書、および図面中において示した装置、システム、プログラム、および方法における動作、手順、ステップ、および段階等の各処理の実行順序は、特段「より前に」、「先立って」等と明示しておらず、また、前の処理の出力を後の処理で用いるのでない限り、任意の順序で実現しうることに留意すべきである。特許請求の範囲、明細書、および図面中の動作フローに関して、便宜上「まず」、「次に、」等を用いて説明したとしても、この順で実施することが必須であることを意味するものではない。

【符号の説明】

【0085】

10 情報処理装置、20 データベース、110 取得部、130 抽出部、150 ベクトル生成部、170 学習処理部、190 予測部、1900 コンピュータ、2000 CPU、2010 ROM、2020 RAM、2030 通信インターフェイス、2040 ハードディスクドライブ、2050 フレキシブルディスク・ドライブ、2060 CD-ROMドライブ、2070 入出力チップ、2075 グラフィック・コントローラ、2080 表示装置、2082 ホスト・コントローラ、2084 入出

10

20

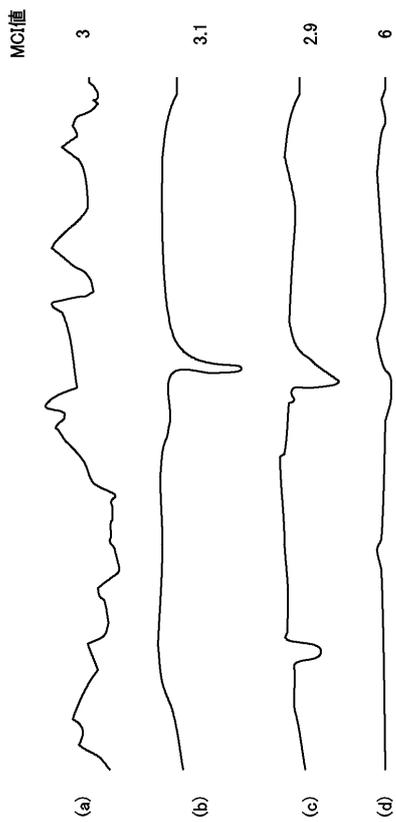
30

40

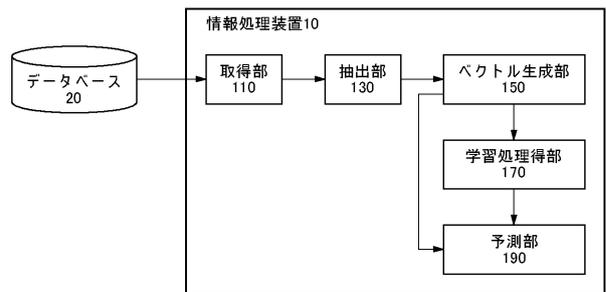
50

カコントローラ、2090 フレキシブルディスク、2095 CD-ROM

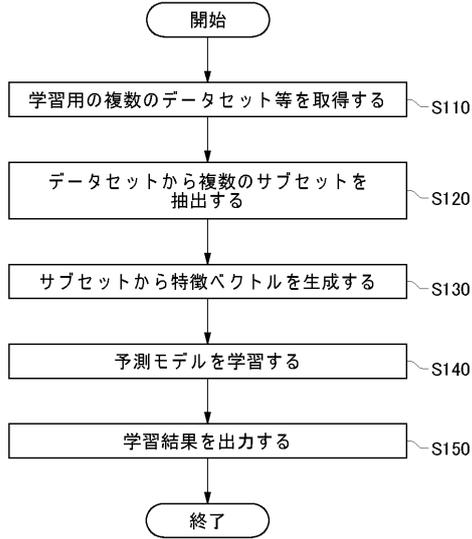
【図1】



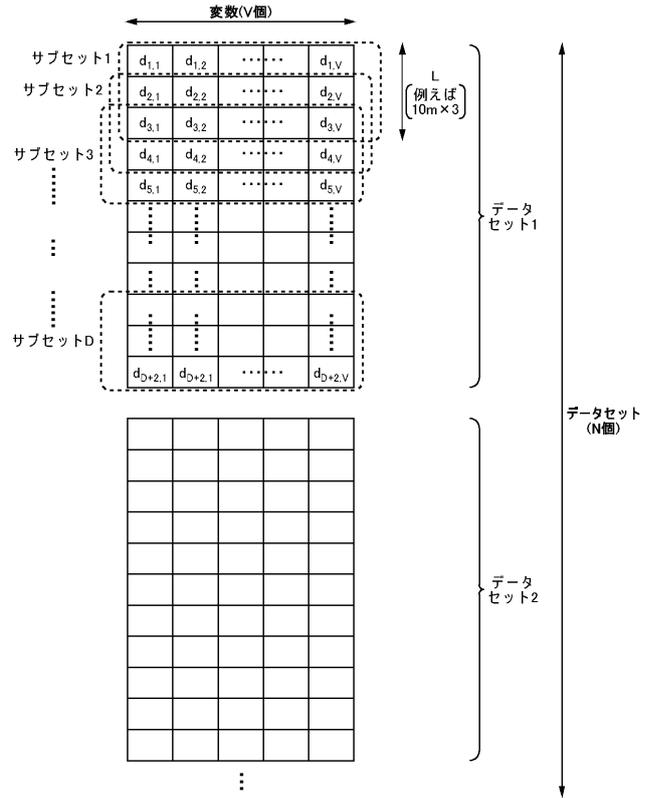
【図2】



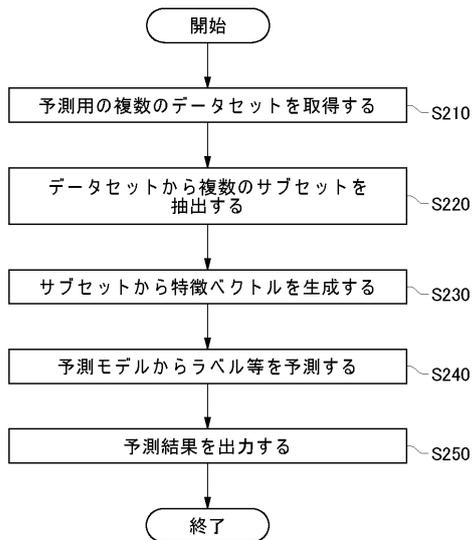
【 図 3 】



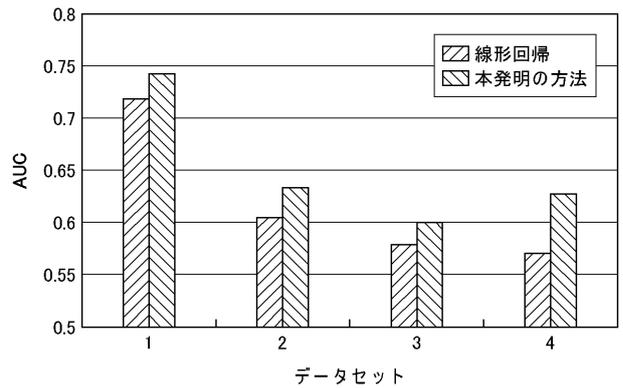
【 図 4 】



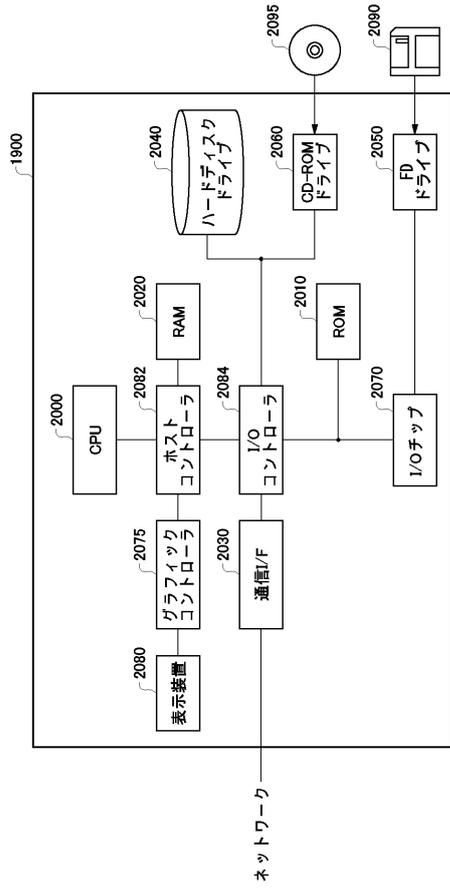
【 図 5 】



【 図 6 】



【 図 7 】



フロントページの続き

(74)代理人 100112690

弁理士 太佐 種一

(74)復代理人 100143502

弁理士 明石 英也

(72)発明者 勝木 孝行

東京都江東区豊洲五丁目6番52号 NBF豊洲チャンネルフロント 日本アイ・ビー・エム株式会
社 東京基礎研究所内

(72)発明者 篠原 祐真

東京都江東区豊洲五丁目6番52号 NBF豊洲チャンネルフロント 日本アイ・ビー・エム株式会
社 東京基礎研究所内