

(19) 日本国特許庁(JP)

(12) 特許公報(B2)

(11) 特許番号

特許第5382436号
(P5382436)

(45) 発行日 平成26年1月8日(2014.1.8)

(24) 登録日 平成25年10月11日(2013.10.11)

(51) Int.Cl. F I
GO6N 5/04 (2006.01) GO6N 5/04 550J
GO6Q 50/10 (2012.01) GO6Q 50/10 180

請求項の数 8 (全 27 頁)

(21) 出願番号	特願2009-180780 (P2009-180780)	(73) 特許権者	000002185 ソニー株式会社 東京都港区港南1丁目7番1号
(22) 出願日	平成21年8月3日(2009.8.3)	(74) 代理人	100082131 弁理士 稲本 義雄
(65) 公開番号	特開2011-34402 (P2011-34402A)	(74) 代理人	100121131 弁理士 西川 孝
(43) 公開日	平成23年2月17日(2011.2.17)	(72) 発明者	伊藤 真人 東京都港区港南1丁目7番1号 ソニー株式会社内
審査請求日	平成24年6月13日(2012.6.13)	(72) 発明者	佐部 浩太郎 東京都港区港南1丁目7番1号 ソニー株式会社内

最終頁に続く

(54) 【発明の名称】 データ処理装置、データ処理方法、およびプログラム

(57) 【特許請求の範囲】

【請求項1】

ウェアラブルセンサから時系列データを取得する取得手段と、
 取得された前記時系列データから、ユーザの活動状態を表す活動モデルを、確率的状態遷移モデルとして学習する活動モデル学習手段と、
 前記活動モデル学習手段により得られた前記ユーザの活動モデルを用いて、現在のユーザの活動状態を認識する認識手段と、
 前記認識手段により認識された前記現在のユーザの活動状態から、現在から所定時間経過後のユーザの活動状態を予測する予測手段と
 を備え、

前記予測手段は、前記確率的状態遷移モデルの各時刻での各状態の観測確率を等確率と仮定して、前記確率的状態遷移モデルの状態遷移確率に基づいて所定時間経過後の前記各状態の生起確率を計算することにより、前記所定時間経過後のユーザの活動状態を予測する

データ処理装置。

【請求項2】

前記予測手段は、前記確率的状態遷移モデルの各時刻での各状態の観測確率を等確率と仮定して前記所定時間経過後の前記各状態の生起確率を計算する代わりに、前記確率的状態遷移モデルの状態遷移確率に基づいて乱数を用いて試行的に決定した前記確率的状態遷移モデルの前記所定時間経過後までの各状態の生起確率を計算することにより、ユーザの

活動状態を予測する

請求項 1 に記載のデータ処理装置。

【請求項 3】

前記予測手段は、所定時間経過後の生起確率が最大となっている前記活動状態、または、所定の閾値以上となっている前記活動状態を、前記所定時間経過後のユーザの活動状態と予測する

請求項 1 に記載のデータ処理装置。

【請求項 4】

前記確率的状態遷移モデルは、スパース制約を与えた隠れ状態を含む確率的状態遷移モデルである

請求項 3 に記載のデータ処理装置。

【請求項 5】

前記認識手段により認識された前記現在のユーザの活動状態に対応する制御対象装置の処理を学習する対応処理学習手段と、

前記対応処理学習手段の学習結果に基づいて、前記予測手段により予測された前記所定時間経過後のユーザの活動状態に対応する前記制御対象装置の処理を選択し、前記制御対象装置が選択された処理を行うように制御する選択手段と

をさらに備える

請求項 4 に記載のデータ処理装置。

【請求項 6】

取得された前記時系列データに対して所定の前処理を行う前処理手段をさらに備える

請求項 5 に記載のデータ処理装置。

【請求項 7】

時系列データを処理するデータ処理装置が、

ウェアラブルセンサから前記時系列データを取得し、

取得された前記時系列データから、ユーザの活動状態を表す活動モデルを、確率的状態遷移モデルとして学習し、

学習により得られた前記ユーザの活動モデルを用いて、現在のユーザの活動状態を認識し、

認識された前記現在のユーザの活動状態から、現在から所定時間経過後のユーザの活動状態を予測する

ステップを含み、

前記所定時間経過後のユーザの活動状態の予測においては、前記確率的状態遷移モデルの各時刻での各状態の観測確率を等確率と仮定して、前記確率的状態遷移モデルの状態遷移確率に基づいて所定時間経過後の前記各状態の生起確率を計算することにより、前記所定時間経過後のユーザの活動状態を予測する

データ処理方法。

【請求項 8】

コンピュータに、

ウェアラブルセンサから時系列データを取得する取得手段と、

取得された前記時系列データから、ユーザの活動状態を表す活動モデルを、確率的状態遷移モデルとして学習する活動モデル学習手段と、

前記活動モデル学習手段により得られた前記ユーザの活動モデルを用いて、現在のユーザの活動状態を認識する認識手段と、

前記認識手段により認識された前記現在のユーザの活動状態から、現在から所定時間経過後のユーザの活動状態を予測する予測手段

として機能させ、

前記予測手段は、前記確率的状態遷移モデルの各時刻での各状態の観測確率を等確率と仮定して、前記確率的状態遷移モデルの状態遷移確率に基づいて所定時間経過後の前記各状態の生起確率を計算することにより、前記所定時間経過後のユーザの活動状態を予測す

10

20

30

40

50

る

プログラム。

【発明の詳細な説明】

【技術分野】

【0001】

本発明は、データ処理装置、データ処理方法、およびプログラムに関し、特に、未来の所望の時刻におけるユーザの活動状態の複数の可能性を確率的に予測するデータ処理装置、データ処理方法、およびプログラムに関する。

【背景技術】

【0002】

近年、ユーザが身に着けられるセンサであるウェアラブルセンサから得られる時系列データを用いてユーザの状態をモデル化して学習し、学習により得られたモデルを用いて現在のユーザの状態を認識する研究が盛んである。例えば、非特許文献1では、ユーザの活動を予めいくつかの活動モデル(ラベル)として定義することなく、単に時系列に撮り貯めた撮像データから、現在のユーザの活動場所を認識する方法が提案されている。また、センサから得られたセンサデータに基づいて、ユーザの次の時刻の行動を予測する予測方法が提案されている(例えば、特許文献1, 2、非特許文献1)。

【先行技術文献】

【特許文献】

【0003】

【特許文献1】特開2006-134080号公報

【特許文献2】特開2008-204040号公報

【非特許文献】

【0004】

【非特許文献1】“Life Patterns: structure from wearable sensors”, Brian Patrick Clarkson, Doctor Thesis, MIT, 2002

【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、従来の技術では、単にユーザの次の時刻の行動を予測することができるのみであり、現在から所定時間経過した未来の時刻におけるユーザの活動状態の複数の可能性を確率的に予測することはできなかった。

【0006】

本発明は、このような状況に鑑みてなされたものであり、未来の所望の時刻におけるユーザの活動状態の複数の可能性を確率的に予測することができるようにするものである。

【課題を解決するための手段】

【0007】

本発明の一側面のデータ処理装置は、ウェアラブルセンサから時系列データを取得する取得手段と、取得された前記時系列データから、ユーザの活動状態を表す活動モデルを、確率的状態遷移モデルとして学習する活動モデル学習手段と、前記活動モデル学習手段により得られた前記ユーザの活動モデルを用いて、現在のユーザの活動状態を認識する認識手段と、前記認識手段により認識された前記現在のユーザの活動状態から、現在から所定時間経過後のユーザの活動状態を予測する予測手段とを備え、前記予測手段は、前記確率的状態遷移モデルの各時刻での各状態の観測確率を等確率と仮定して、前記確率的状態遷移モデルの状態遷移確率に基づいて所定時間経過後の前記各状態の生起確率を計算することにより、前記所定時間経過後のユーザの活動状態を予測する。

【0008】

本発明の一側面のデータ処理方法は、時系列データを処理するデータ処理装置が、ウェアラブルセンサから前記時系列データを取得し、取得された前記時系列データから、ユーザの活動状態を表す活動モデルを、確率的状態遷移モデルとして学習し、学習により得ら

10

20

30

40

50

れた前記ユーザの活動モデルを用いて、現在のユーザの活動状態を認識し、認識された前記現在のユーザの活動状態から、現在から所定時間経過後のユーザの活動状態を予測するステップを含み、前記所定時間経過後のユーザの活動状態の予測においては、前記確率的状態遷移モデルの各時刻での各状態の観測確率を等確率と仮定して、前記確率的状態遷移モデルの状態遷移確率に基づいて所定時間経過後の前記各状態の生起確率を計算することにより、前記所定時間経過後のユーザの活動状態を予測する。

【0009】

本発明の一側面のプログラムは、コンピュータに、ウェアラブルセンサから時系列データを取得する取得手段と、取得された前記時系列データから、ユーザの活動状態を表す活動モデルを、確率的状態遷移モデルとして学習する活動モデル学習手段と、前記活動モデル学習手段により得られた前記ユーザの活動モデルを用いて、現在のユーザの活動状態を認識する認識手段と、前記認識手段により認識された前記現在のユーザの活動状態から、現在から所定時間経過後のユーザの活動状態を予測する予測手段として機能させ、前記予測手段は、前記確率的状態遷移モデルの各時刻での各状態の観測確率を等確率と仮定して、前記確率的状態遷移モデルの状態遷移確率に基づいて所定時間経過後の前記各状態の生起確率を計算することにより、前記所定時間経過後のユーザの活動状態を予測する。

【0010】

本発明の一側面においては、ウェアラブルセンサから時系列データが取得され、取得された時系列データから、ユーザの活動状態を表す活動モデルが確率的状態遷移モデルとして学習され、学習により得られたユーザの活動モデルを用いて、現在のユーザの活動状態が認識され、認識された現在のユーザの活動状態から、現在から所定時間経過後のユーザの活動状態が予測される。所定時間経過後のユーザの活動状態の予測においては、確率的状態遷移モデルの各時刻での各状態の観測確率を等確率と仮定して、確率的状態遷移モデルの状態遷移確率に基づいて所定時間経過後の各状態の生起確率を計算することにより、所定時間経過後のユーザの活動状態が予測される。

【発明の効果】

【0011】

本発明の一側面によれば、未来の所望の時刻におけるユーザの活動状態の複数の可能性を確率的に予測することができる。

【図面の簡単な説明】

【0012】

【図1】本発明を適用したデータ処理システムの一実施の形態の構成例を示すブロック図である。

【図2】図1のデータ処理装置の詳細な構成例を示すブロック図である。

【図3】ユーザ活動モデル学習処理を説明するフローチャートである。

【図4】対応処理学習処理を説明するフローチャートである。

【図5】ユーザ活動予測制御処理を説明するフローチャートである。

【図6】HMMの例を示す図である。

【図7】left-to-right型のHMMの例を示す図である。

【図8】スパース制約を与えたHMMを示す図である。

【図9】第1の実験の概要について説明する図である。

【図10】第1の実験例に用いたデータ処理装置の構成例を示すブロック図である。

【図11】前処理部の処理結果を示す図である。

【図12】前処理部の処理結果を示す図である。

【図13】ユーザ活動モデル学習部の学習結果を示す図である。

【図14】ユーザ活動モデル学習部の学習結果を示す図である。

【図15】ユーザ活動認識部の認識結果を示す図である。

【図16】ユーザ活動予測部の予測結果を示す図である。

【図17】対応処理学習部の学習テーブルを説明する図である。

【図18】対応処理選択部の選択処理を説明する図である。

10

20

30

40

50

【図19】実験2におけるデータ処理装置の認識結果および予測結果を説明する図である。

【図20】実験2におけるデータ処理装置の認識結果および予測結果を説明する図である。

【図21】本発明を適用したコンピュータの一実施の形態の構成例を示すブロック図である。

【発明を実施するための形態】

【0013】

[本発明を適用した実施の形態の構成例]

図1は、本発明を適用した実施の形態であるデータ処理システムの構成例を示すブロック図である。

【0014】

図1のデータ処理システムは、ウェアラブルセンサ1、データ処理装置2、および制御対象装置3により構成されている。

【0015】

ウェアラブルセンサ1は、ユーザ自身が身に着けられるセンサであり、例えば、カメラ、マイクロホン、GPS(Global Positioning System)受信機、時計、加速度センサ、ジャイロセンサ、生体情報センサなどである。ウェアラブルセンサ1は、センシングにより得られた時系列データ(以下、センサデータともいう)を、データ処理装置2に出力する。

【0016】

データ処理装置2は、ユーザが携帯可能なサイズの装置であり、ウェアラブルセンサ1から供給される時系列データに基づいて、ユーザの活動状態(行動・活動パターンを表した状態)を確率的状態遷移モデルとして学習する。学習に使用される確率的状態遷移モデルとしては、例えば、エルゴディックHMM(Hidden Markov Model)などの、隠れ状態を含む確率的状態遷移モデルを採用することができる。エルゴディックHMMについては、図6等を参照して後述する。

【0017】

データ処理装置2は、学習した確率的状態遷移モデルを用いて、最初に、現在のユーザの活動状態を認識する。次に、データ処理装置2は、現在までに得られたセンサデータから、学習した確率的状態遷移モデルを用いて、未来の所望の時刻までの各状態の生起確率を予測することにより、未来の所望の時刻におけるユーザの活動状態を予測する。そして、データ処理装置2は、予測したユーザの活動状態に応じた所定の処理を制御対象装置3に行わせるため、制御対象装置3に制御信号を出力する。

【0018】

なお、データ処理装置2が行う処理の一部は、無線通信及びインターネット等のネットワークを介した通信により遠隔にある装置にデータを送信し、そこで実行させることも可能である。

【0019】

制御対象装置3は、データ処理装置2によって制御される対象の装置であり、例えば、ディスプレイ、スピーカ、AV機器、照明機器、空調機器等の家電製品である。或いは、制御対象装置3は、ディスプレイ、スピーカ、AV機器、照明機器、空調機器等の制御を行うコントローラなどであってもよい。したがって、制御対象装置3は、1つに限らず、複数存在する場合がある。

【0020】

なお、ウェアラブルセンサ1とデータ処理装置2は、ウェアラブル(wearable)なものである必要があるが、制御対象装置3は、ウェアラブルなものであるとは限らない。勿論、制御対象装置3もウェアラブルなものであってもよい。また、データ処理装置2と制御対象装置3との間の信号のやりとりは、有線でも無線でも構わない。

【0021】

以上のように構成されるデータ処理システムによれば、次のようなことが可能である。

10

20

30

40

50

【 0 0 2 2 】

例えば、ユーザが自宅に居る場合の活動状態を、確率的状態遷移モデルとして学習した場合には、データ処理装置 2 は、ユーザが「リビングに居る」、「キッチンに居る」などの現在の活動状態を認識する。そして、データ処理装置 2 は、ユーザの所定時間経過後の活動状態を、確率的状態遷移モデルに基づいて予測する。例えば、データ処理装置 2 は、「所定時間経過後にはキッチンに居る」、「所定時間経過後にリビングに移動する」などの活動状態を予測する。

【 0 0 2 3 】

そして、データ処理装置 2 は、予測した活動状態に対応する制御対象装置 3 の制御を行う。例えば、データ処理装置 2 は、ユーザの現在の活動状態を「キッチンに居る」と認識し、「所定時間経過後にリビングに移動する」と予測した場合、制御対象装置 3 としての、リビングの照明機器や空調機器をオンさせる。また、データ処理装置 2 は、リビングのテレビジョン受像機（以下、単にテレビと称する）、記録再生装置、オーディオステレオなどのAV機器をオンさせることができる。

10

【 0 0 2 4 】

また、ユーザがオフィスにいる場合の活動状態を、確率的状態遷移モデルとして学習した場合には、データ処理装置 2 は、ユーザが「オフィス（自分の机）に居る」、「会議室に居る」などの現在の活動状態を認識することができる。そして、予測した所定時間経過後の活動状態に応じて、「会議室等の各場所の空調機器をオンさせる」、「コピー機をオンさせる」、「エレベータを自分のいるフロアに移動させる」などの制御を行うことができる。即ち、この場合の制御対象装置 3 は、空調機器、コピー機、エレベータなどである。

20

【 0 0 2 5 】

さらに例えば、ユーザがショップ内で買い物をしているような場面では、ユーザの現在の活動状態を認識して、即ち、ユーザが現在見ている商品等を予測して、その商品情報を制御対象装置 3 としてのディスプレイに表示させることができる。あるいは、進行方向先に陳列されている商品のお勧め商品などの情報を、制御対象装置 3 としてのディスプレイに表示させることができる。

【 0 0 2 6 】

また、ユーザが通勤・通学等で移動する移動経路を活動状態のモデルとして学習した場合には、データ処理装置 2 は、例えば、ユーザが駅に向かうことを予測したとき、時刻表を制御対象装置 3 としてのディスプレイに表示させることができる。また、データ処理装置 2 は、移動経路から立ち寄る店舗を予測して、その店舗の詳細情報（営業時間やセール情報など）を表示させたりすることができる。

30

【 0 0 2 7 】

以上のようなユーザの活動状態の予測とそれに対応する制御処理を可能とする、データ処理装置 2 の詳細について説明する。

【 0 0 2 8 】

〔データ処理装置 2 の詳細構成例〕

図 2 は、データ処理装置 2 の詳細な構成例を示すブロック図である。

40

【 0 0 2 9 】

センサ入力部 1 1₁ は、ウェアラブルセンサ 1 が出力するセンサデータを取得し、前処理部 1 2₁ に供給する。センサ入力部 1 1₂ および 1 1₃ も同様である。ただし、センサ入力部 1 1₁ 乃至 1 1₃ が取得するセンサデータはそれぞれ異なる。従って、データ処理装置 2 は、複数のウェアラブルセンサ 1 からセンサデータを取得することができ、取得対象のウェアラブルセンサ 1 の数に応じたセンサ入力部 1 1 および前処理部 1 2 を設けることができる。なお、取得対象のウェアラブルセンサ 1 の数は、1 つでも勿論良い。以下では、センサ入力部 1 1₁ 乃至 1 1₃ および前処理部 1 2₁ 乃至 1 2₃ それぞれを特に区別する必要がない場合、単に、センサ入力部 1 1 および前処理部 1 2 と称する。

【 0 0 3 0 】

50

前処理部 1 2₁乃至 1 2₃それぞれは、センサ入力部 1 1₁乃至 1 1₃から供給されたセンサデータに対して、画像特徴量の抽出処理、ローパスフィルタ処理等のデータの特性に応じた前処理を施し、ユーザ活動モデル学習部 1 3およびユーザ活動認識部 1 5に供給する。即ち、前処理部 1 2₁乃至 1 2₃それぞれは、ユーザ活動モデル学習部 1 3およびユーザ活動認識部 1 5に供給するのに最適なデータに変換し、変換後のセンサデータをユーザ活動モデル学習部 1 3およびユーザ活動認識部 1 5に供給する。

【 0 0 3 1 】

ユーザ活動モデル学習部 1 3は、前処理部 1 2₁乃至 1 2₃それぞれから供給されるセンサデータに基づいて、ユーザの活動状態をモデル化した確率的状態遷移モデル（ユーザ活動モデル）を学習する。本実施の形態では、確率的状態遷移モデルとして、エルゴディックHMMにスパース制約を与えたものを採用する。ユーザ活動モデル学習部 1 3は、学習の結果得られたユーザ活動モデルのパラメータを、ユーザ活動モデルパラメータ記憶部 1 4に供給する。ユーザ活動モデルパラメータ記憶部 1 4は、ユーザ活動モデル学習部 1 3から供給されるパラメータを記憶し、必要に応じて、ユーザ活動認識部 1 5およびユーザ活動予測部 1 6に供給する。

10

【 0 0 3 2 】

なお、スパース制約を与えたエルゴディックHMM、エルゴディックHMMのパラメータの算出方法等については、図 6 乃至図 8 を参照して後述する。

【 0 0 3 3 】

ユーザ活動認識部 1 5は、センサ入力部 1 1および前処理部 1 2を介して新たなセンサデータが入力されたとき、学習により得られたユーザ活動モデルに基づいて、現在のユーザの活動状態（以下、ユーザ活動状態とも称する）を認識（特定）する。ユーザ活動認識部 1 5は、認識した現在のユーザ活動状態を表す状態IDをユーザ活動予測部 1 6および対応処理学習部 1 8に供給する。

20

【 0 0 3 4 】

ユーザ活動予測部 1 6は、学習により得られたユーザ活動モデルに基づいて、所定時間経過後のユーザの活動状態を予測する。具体的には、ユーザ活動予測部 1 6には、現在のユーザの状態を表す状態IDが供給される。ユーザ活動予測部 1 6は、現在時刻 T ($T > 0$)のユーザの活動状態から、所定時間経過後の時刻 $T+N$ ($N > 0$)において、生起確率が最大となっている活動状態、または、生起確率が所定の閾値以上となっている活動状態を決定する。そして、ユーザ活動予測部 1 6は、決定された活動状態を表す状態IDを、時刻 $T+N$ におけるユーザの活動状態の予測結果として対応処理選択部 1 9に供給する。

30

【 0 0 3 5 】

対応処理取得部 1 7は、制御対象装置 3 に対してデータ処理装置 2 が行う制御のそれぞれに処理IDを付し、制御対象装置 3 において処理IDを付した制御が行われた場合に、その処理IDを取得して対応処理学習部 1 8に供給する。

【 0 0 3 6 】

対応処理学習部 1 8は、処理IDと状態IDとを対応付けた学習テーブルを記憶する。対応処理学習部 1 8は、対応処理取得部 1 7から処理IDが供給された場合に、学習テーブルの現在のユーザの活動状態を表す状態IDのところの、供給された処理IDのカウントをカウントアップする。その結果、ユーザの活動状態の状態IDごとの、処理IDの頻度がカウントされる。これにより、対応処理学習部 1 8は、ユーザがどのような活動状態にいるとき、制御対象装置 3 に対してどのような操作（制御）を行うかを学習する。即ち、対応処理学習部 1 8は、現在のユーザの活動状態を表す状態IDに対応する制御対象装置 3 の処理を学習する。

40

【 0 0 3 7 】

対応処理選択部 1 9には、所定時間経過後の時刻 $T+N$ における、ユーザの活動状態の予測結果としての状態IDが、ユーザ活動予測部 1 6から供給される。対応処理選択部 1 9は、対応処理学習部 1 8に記憶された学習結果から、ユーザ活動予測部 1 6から供給される状態IDに対応する処理の処理IDを選択（決定）する。対応処理選択部 1 9は、選択した処

50

理IDを対応処理出力部20に供給する。

【0038】

対応処理出力部20は、対応処理選択部19から供給された処理IDに対応する制御を制御対象装置3に対して行う。

【0039】

[ユーザ活動モデル学習処理]

図3は、データ処理装置2によるユーザ活動モデル学習処理のフローチャートである。

【0040】

初めに、ステップS1において、センサ入力部11は、ウェアラブルセンサ1が出力するセンサデータを取得し、前処理部12に供給する。

10

【0041】

ステップS2において、前処理部12は、センサ入力部11から供給されたセンサデータに対して前処理を施し、処理後のセンサデータをユーザ活動モデル学習部13に供給する。

【0042】

ステップS3において、ユーザ活動モデル学習部13は、前処理部12から供給されるセンサデータに基づいて、ユーザ活動モデルを学習する。即ち、ユーザ活動モデル学習部13は、ユーザ活動モデルとしての確率的状態遷移モデルのパラメータを算出する。

【0043】

ステップS4において、ユーザ活動モデルパラメータ記憶部14は、ユーザ活動モデル学習部13による学習の結果得られたユーザ活動モデルのパラメータ(ユーザ活動モデルパラメータ)を記憶して、処理を終了する。

20

【0044】

[対応処理学習処理]

図4は、ユーザの活動状態に対応する制御対象装置3の処理を学習する対応処理学習処理のフローチャートである。この処理は、図3によるユーザ活動モデル学習処理によりユーザ活動モデルが決定された後に実行することができる。

【0045】

初めに、ステップS11において、センサ入力部11は、ウェアラブルセンサ1が出力するセンサデータを取得し、前処理部12に供給する。

30

【0046】

ステップS12において、前処理部12は、センサ入力部11から供給されたセンサデータに対して前処理を施し、処理後のセンサデータをユーザ活動認識部15に供給する。

【0047】

ステップS13において、ユーザ活動認識部15は、ユーザ活動モデルのパラメータを、ユーザ活動モデルパラメータ記憶部14から読み出す。

【0048】

ステップS14において、ユーザ活動認識部15は、読み出したパラメータに基づくユーザ活動モデルに基づいて、現在のユーザ活動状態を認識(特定)する。ユーザ活動認識部15は、認識結果としてのユーザの活動状態を表す状態IDを対応処理学習部18に供給する。

40

【0049】

ステップS15において、対応処理取得部17は、制御対象装置3において行われた処理の処理IDを取得して対応処理学習部18に供給する。ステップS14とS15の処理は並行して行われる。

【0050】

ステップS16において、対応処理学習部18は、対応処理取得部17から供給された処理IDと、ユーザ活動認識部15から供給された現在のユーザ活動状態を表す状態IDを学習テーブルに対応付けて記憶し、処理を終了する。

【0051】

50

以上の処理を繰り返し実行することにより、データ処理装置 2 は、ユーザがどんな状態にいるとき、制御対象装置 3 に対してどのような操作（制御）を行うかを学習することができる。

【 0 0 5 2 】

[ユーザ活動予測制御処理]

図 5 は、入力されたセンサデータに基づいてユーザ活動状態を予測し、予測したユーザ活動状態に応じた制御対象装置 3 の制御を行うユーザ活動予測制御処理のフローチャートである。この処理は、図 3 のユーザ活動モデル学習処理と図 4 の対応処理学習処理の実行後、または、図 4 の対応処理学習処理と並列に実行することができる。

【 0 0 5 3 】

初めに、ステップ S 2 1 において、センサ入力部 1 1 は、ウェアラブルセンサ 1 が出力するセンサデータを取得し、前処理部 1 2 に供給する。

【 0 0 5 4 】

ステップ S 2 2 において、前処理部 1 2 は、センサ入力部 1 1 から供給されたセンサデータに対して前処理を施し、処理後のセンサデータをユーザ活動認識部 1 5 に供給する。ステップ S 2 1 と S 2 2 の処理は、図 4 のステップ S 1 1 と S 1 2 の処理と同一であり、図 5 の処理が図 4 の処理と並列に実行される場合には、ステップ S 1 1 と S 2 1、ステップ S 1 2 と S 2 2 は、それぞれ 1 つの処理として実行することができる。

【 0 0 5 5 】

ステップ S 2 3 において、ユーザ活動予測部 1 6 は、ユーザ活動モデルのパラメータを、ユーザ活動モデルパラメータ記憶部 1 4 から読み出す。またステップ S 2 3 では、ユーザ活動認識部 1 5 も、ユーザ活動モデルのパラメータを、ユーザ活動モデルパラメータ記憶部 1 4 から読み出す。

【 0 0 5 6 】

ステップ S 2 4 において、ユーザ活動認識部 1 5 は、読み出したパラメータに基づくユーザ活動モデルから、現在のユーザ活動状態を認識する。そして、ユーザ活動認識部 1 5 は、認識結果としてのユーザの活動状態を表す状態 ID を対応処理学習部 1 8 に供給する。

【 0 0 5 7 】

ステップ S 2 5 において、ユーザ活動予測部 1 6 は、現在時刻 T のユーザの活動状態を起点として、所定時間経過後の時刻 T + N のユーザ活動状態を予測する。ユーザ活動予測部 1 6 は、予測結果である、所定時間経過後のユーザの活動状態を表す状態 ID を対応処理選択部 1 9 に供給する。

【 0 0 5 8 】

ステップ S 2 6 において、対応処理選択部 1 9 は、ユーザ活動予測部 1 6 から供給された状態 ID に対応する処理 ID を、図 4 の処理により対応処理学習部 1 8 に記憶された学習テーブルから選択する。即ち、対応処理選択部 1 9 は、時刻 T + N に予測されるユーザの活動状態に対応する制御対象装置 3 の制御を選択する。選択された処理 ID は、対応処理出力部 2 0 に供給される。

【 0 0 5 9 】

ステップ S 2 7 において、対応処理出力部 2 0 は、対応処理選択部 1 9 から供給された処理 ID に対応する制御を制御対象装置 3 に対して行い、処理を終了する。

【 0 0 6 0 】

以上のように、データ処理装置 2 においては、図 3 のユーザ活動モデル学習処理によりユーザ活動モデルのパラメータが算出され、算出されたパラメータを用いたユーザ活動モデルによって、現在のユーザの活動状態が認識される。そして、現在のユーザの活動状態から、未来の所定の時刻 T + N におけるユーザの活動状態が予測され、予測されたユーザの活動状態に応じた制御対象装置 3 の制御が行われる。

【 0 0 6 1 】

[エルゴディック HMM について]

次に、データ処理装置 2 が、学習モデルとして採用するエルゴディック HMM について説

10

20

30

40

50

明する。

【 0 0 6 2 】

図 6 は、HMMの例を示している。

【 0 0 6 3 】

HMMは、状態と状態間遷移とを有する状態遷移モデルである。

【 0 0 6 4 】

図 6 は、3 状態のHMMの例を示している。

【 0 0 6 5 】

図 6 において（以降の図においても同様）、丸印は、状態（上述のユーザの活動状態に対応する）を表し、矢印は、状態遷移を表す。

10

【 0 0 6 6 】

また、図 6 において、 s_i （図 6 では、 $i=1,2,3$ ）は、状態を表し、 a_{ij} は、状態 s_i から状態 s_j への状態遷移確率を表す。さらに、 $b_j(x)$ は、状態 s_j への状態遷移時に、観測値 x が観測される出力確率密度関数を表し、 π_i は、状態 s_i が初期状態である初期確率を表す。

【 0 0 6 7 】

なお、出力確率密度関数 $b_j(x)$ としては、例えば、混合正規確率分布等が用いられる。

【 0 0 6 8 】

ここで、HMM（連続HMM）は、状態遷移確率 a_{ij} 、出力確率密度関数 $b_j(x)$ 、及び初期確率 π_i によって定義される。これらの状態遷移確率 a_{ij} 、出力確率密度関数 $b_j(x)$ 、及び初期確率 π_i を、HMMのパラメータ $\theta = \{a_{ij}, b_j(x), \pi_i, i=1,2, \dots, M, j=1,2, \dots, M\}$ という。Mは、HMMの状態数を表す。

20

【 0 0 6 9 】

HMMのパラメータ θ を推定する方法としては、Baum-Welchの再尤推定法が広く利用されている。Baum-Welchの再尤推定法は、EMアルゴリズム(EM(Expectation-Maximization) algorithm)に基づくパラメータの推定方法である。

【 0 0 7 0 】

Baum-Welchの再尤推定法によれば、観測される時系列データ $x=x_1, x_2, \dots, x_T$ に基づき、その時系列データが観測（生起）される確率である生起確率から求まる尤度を最大化するように、HMMのパラメータ θ の推定が行われる。ここで、 x_t は、時刻 t に観測される信号（サンプル値）を表し、 T は、時系列データの長さ（サンプル数）を表す。

30

【 0 0 7 1 】

Baum-Welchの再尤推定法については、例えば、“パターン認識と機械学習（下）”，C. M. ビショップ著，P. 333（英語原書：“Pattern Recognition and Machine Learning (Information Science and Statistics)” , Christopher M. BishopSpringer, New York, 2006.）（以下、文献Aと称する）に記載されている。

【 0 0 7 2 】

センサ入力部 1 1 が取得したセンサデータが、時系列データ $x=x_1, x_2, \dots, x_T$ として、前処理部 1 2 に供給される。そして、前処理部 1 2 により所定の処理が施された後のセンサデータが、時系列データ $x'=x_1', x_2', \dots, x_T'$ として、ユーザ活動モデル学習部 1 3 に供給される。

40

【 0 0 7 3 】

したがって、ユーザ活動モデル学習部 1 3 は、前処理後のセンサデータ $x'=x_1', x_2', \dots, x_T'$ を用い、ユーザ活動モデルを表すHMMのパラメータ θ を推定する。

【 0 0 7 4 】

なお、Baum-Welchの再尤推定法は、尤度最大化に基づくパラメータ推定方法ではあるが、最適性を保証するものではなく、HMMの構造やパラメータ θ の初期値によっては、局所解に収束することがある。

【 0 0 7 5 】

HMMは、音声認識で広く利用されているが、音声認識で利用されるHMMでは、一般に、状態の数や状態遷移の仕方等はあらかじめ決定される。

50

【 0 0 7 6 】

図 7 は、音声認識で利用されるHMMの例を示している。

【 0 0 7 7 】

図 7 のHMMは、left-to-right型と呼ばれる。

【 0 0 7 8 】

図 7 では、状態数は 3 になっており、状態遷移は、自己遷移（状態 s_i から状態 s_i への状態遷移）と、左から右隣の状態への状態遷移とのみを許す構造に制約されている。

【 0 0 7 9 】

図 7 のHMMのように、状態遷移に制約があるHMMに対して、図 6 に示した、状態遷移に制約がないHMM、すなわち、任意の状態 s_i から任意の状態 s_j への状態遷移が可能なHMMは、エルゴディック(Ergodic)HMMと呼ばれる。

10

【 0 0 8 0 】

エルゴディックHMMは、構造としては最も自由度の高いHMMであるが、状態数が多くなると、パラメータの推定が困難となる。

【 0 0 8 1 】

例えば、エルゴディックHMMの状態数が、1 0 0 0 である場合、状態遷移の数は、1 0 0 万（= 1 0 0 0 × 1 0 0 0）となる。

【 0 0 8 2 】

したがって、この場合、パラメータのうち、例えば、状態遷移確率 a_{ij} については、1 0 0 万個の状態遷移確率 a_{ij} を推定することが必要となる。

20

【 0 0 8 3 】

そこで、状態に対して設定する状態遷移には、例えば、スパース(Sparse)な構造であるという制約（スパース制約）をかけることができる。

【 0 0 8 4 】

ここで、スパースな構造とは、任意の状態から任意の状態への状態遷移が可能なエルゴディックHMMのような密な状態遷移ではなく、ある状態から状態遷移することができる状態が非常に限定されている構造である。なお、ここでは、スパースな構造であっても、他の状態への状態遷移は、少なくとも 1 つ存在し、また、自己遷移は存在することとする。

【 0 0 8 5 】

図 8 は、スパース制約を与えたHMMを示している。

30

【 0 0 8 6 】

ここで、図 8 では、2 つの状態を結ぶ双方向の矢印は、その 2 つの状態の一方から他方への状態遷移と、他方から一方への状態遷移とを表す。また、図 8 において、各状態は、自己遷移が可能であり、その自己遷移を表す矢印の図示は、省略されている。

【 0 0 8 7 】

図 8 では、1 6 個の状態が、2 次元空間上に格子状に配置されている。すなわち、図 8 では、横方向に、4 個の状態が配置され、縦方向にも、4 個の状態が配置されている。

【 0 0 8 8 】

いま、横方向に隣接する状態どうしの距離、及び、縦方向に隣接する状態どうしの距離を、いずれも 1 とすると、図 8 A は、距離が 1 以下の状態への状態遷移は可能とし、他の状態への状態遷移はできないというスパース制約を与えたHMMを示している。

40

【 0 0 8 9 】

また、図 8 B は、距離が 2 以下の状態への状態遷移は可能とし、他の状態への状態遷移はできないというスパース制約を与えたHMMを示している。

【 0 0 9 0 】

ユーザ活動認識部 1 5 は、学習により得られたユーザ活動モデル（HMM）に対して、ビタビ法を適用し、前処理部 1 2 からの処理後センサデータ x'_1, x'_2, \dots, x'_T が観測される尤度を最も大にする状態遷移の過程（状態の系列）（パス）（以下、最尤パスともいう）を求める。これにより、現在のユーザの活動状態が認識される。

【 0 0 9 1 】

50

ここで、ビタビ法とは、各状態 s_i を始点とする状態遷移のパスの中で、時刻 t に、状態 s_i から状態 s_j に状態遷移する状態遷移確率 a_{ij} と、その状態遷移において、処理後センサデータ $x' = x_1', x_2', \dots, x_T'$ のうちの時刻 t のサンプル値 x'_t が観測される確率（出力確率密度関数 $b_j(x)$ から求められる出力確率）とを、処理後時系列データ x' の長さ T に亘って累積した値（生起確率）を最大にするパス（最尤パス）を決定するアルゴリズムである。

【0092】

ユーザ活動予測部16は、学習により得られたユーザ活動モデル（HMM）に対して、フォワードバックワードアルゴリズム（Forward-Backward algorithm）を適用し、ユーザ活動認識部15で認識された現在のユーザ活動状態を起点として、時刻 $T+N$ までの各状態 s_i の生起確率を計算することができる。なお、ユーザ活動予測部16は、生起確率を計算する際、各時刻での各状態 s_i の観測確率を等確率と仮定して時刻 $T+N$ までの各状態 s_i の生起確率を状態遷移確率 a_{ij} に基づいて計算する方法か、または、状態遷移確率 a_{ij} に基づいて乱数を用いて試行的に決定した時刻 $T+N$ までの各状態 s_i の生起確率を計算する方法のいずれかを採用することができる。

10

【0093】

ここで、フォワードバックワードアルゴリズムとは、各状態 s_i に至る確率を、時間方向に前向きに伝搬することで求められる前向き確率 $f_i(t)$ と、後ろ向きに伝搬することで求められる後ろ向き確率 $b_i(t)$ とを統合した確率値を計算するアルゴリズムである。なお、前向き確率 $f_i(t)$ を計算するフォワードアルゴリズム、もしくは、後ろ向き確率 $b_i(t)$ を計算するバックワードアルゴリズムのいずれかのみを用いることもできる。

20

【0094】

ビタビ法については上述の文献AのP.347に、フォワードバックワードアルゴリズムについては上述の文献AのP.336に記載されている。

【0095】

[第1の実験例]

次に、データ処理装置2による、ユーザ活動モデルの学習および予測制御の具体例について説明する。最初に、図9を参照して第1の実験の概要について説明する。

【0096】

第1の実験では、ユーザがウェアラブルセンサ1としてカメラを携帯し、ユーザが視認する画像（映像）のデータが時系列データとして取得される。ユーザは、図9に示される住居内において、（1）リビングでテレビを視聴する、（2）ダイニングで食事する、（3）書斎で考えごとをする、（4）キッチンで料理する、（5）洗面所でメイクする、の活動（行動）をする。また、ユーザは、移動先の部屋で、部屋の照明をつける、テレビのスイッチを入れるなどの操作を制御対象装置3としての照明機器、テレビジョン受像機などに対して行う。

30

【0097】

データ処理装置2は、ユーザの活動とともに取得された画像の時系列データに基づいて、ユーザの活動状態をエルゴディックHMMに学習させる。そして、学習後の検証として、ユーザが行動することにより得られる新たな画像の時系列データを入力させ、ユーザ活動認識部15によるユーザ活動状態の認識と、実際のユーザの活動との比較を行った。なお、ウェアラブルセンサ1としてのカメラからデータ処理装置2が取得するのは画像の時系列データのみであり、ユーザの活動に関するラベル付けのようなものは行わない。ただし、学習後の検証として実際のユーザの活動と認識結果とを比較するため、今回の実験では、取得された各画像に対し、住居内の位置を示す擬似座標を付加した。また、学習後の各状態に対しても、その状態に割り当てられた入力画像の擬似座標の平均値を対応付け、認識結果の各状態を擬似座標で確認できるようにした。

40

【0098】

[第1の実験例におけるデータ処理装置2の構成]

図10は、第1の実験例に用いたデータ処理装置2の構成例を示すブロック図である。

【0099】

50

センサ入力部 1 1 - 1 は、ウェアラブルセンサ 1 としてのカメラが出力した時系列の画像データをセンサデータとして取得し、前処理部 1 2 - 1 に供給する。

【 0 1 0 0 】

前処理部 1 2 - 1 は、センサ入力部 1 1 - 1 から供給される画像データに対し、画像特徴量を抽出する。即ち、前処理部 1 2 - 1 は、画像の時系列データを、画像特徴量の時系列データに変換する。さらに前処理部 1 2 - 1 は、画像特徴量の時系列データの次元数を圧縮し、次元圧縮後の画像特徴量の時系列データを、ユーザ活動モデル学習部 1 3 - 1 およびユーザ活動認識部 1 5 - 1 に供給する。

【 0 1 0 1 】

前処理部 1 2 - 1 は、抽出する画像特徴量として、例えば、GISTと呼ばれる特徴量を採用することができる。GISTについては、“Context-based vision system for place and object recognition”, A. Torralba, K. P. Murphy, W. T. Freeman and M. A. Rubin, IEEE Intl. Conference on Computer Vision (ICCV), Nice, France, October 2003. に、その詳細が記載されている。

【 0 1 0 2 】

なお、画像特徴量は、GISTに限定されるものではなく、例えば、HLCA (局所高次相関) や、LBP (Local Binary Patterns)、カラーヒストグラム、エッジヒストグラム等を採用することも可能である。

【 0 1 0 3 】

HLCAについては、例えば、N. Otsu, T. Kurita, "A new scheme for practical flexible and intelligent vision systems", Proc. IAPR Workshop on Computer Vision, pp.431-435, 1988に、詳細が記載されている。LBPについては、例えば、Ojala T, Pietikainen M & Maenpaa T, "Multiresolution gray-scale and rotation invariant texture classification with Local Binary Patterns", IEEE Transactions on Pattern Analysis and Machine Intelligence 24(7):971-987に、詳細が記載されている (Pietikainen、及び、Maenpaaの"a"は、正確には、"a"の上部に、"・"を付加した文字)。

【 0 1 0 4 】

また、前処理部 1 2 - 1 は、主成分分析 (PCA (principal component analysis)) を行うことにより、画像特徴量の時系列データの次元圧縮を行うことができる。前処理部 1 2 - 1 は、PCAの結果に基づき、累積寄与率が、ある程度高い値 (例えば、95%等以上の値) となるように、画像特徴量 (GIST) の時系列データの次元数を圧縮 (制限) することができる。

【 0 1 0 5 】

ユーザ活動モデル学習部 1 3 - 1 は、前処理部 1 2 - 1 から供給される次元圧縮後の画像特徴量の時系列データを、上述したセンサデータ $x' = x_1', x_2', \dots, x_T'$ として、スパース制約を与えたエルゴディックHMMのパラメータを算出する。なお、状態 s_i の初期確率 π_i は、一様な値に設定することができる。例えば、M個の状態 s_i それぞれの初期確率 π_i が、 $1/M$ に設定される。

【 0 1 0 6 】

ユーザ活動モデルパラメータ記憶部 1 4 - 1 は、ユーザ活動モデル学習部 1 3 - 1 によって算出されたパラメータを記憶し、必要に応じて、ユーザ活動認識部 1 5 およびユーザ活動予測部 1 6 に供給する。

【 0 1 0 7 】

ユーザ活動認識部 1 5 - 1 は、学習により得られたユーザ活動モデル (HMM) に対して、ビタビ法を適用し、現在のユーザ活動状態を認識 (特定) する。ユーザ活動認識部 1 5 - 1 は、認識した現在のユーザ活動状態を表す状態IDをユーザ活動予測部 1 6 および対応処理学習部 1 8 に供給する。

【 0 1 0 8 】

ユーザ活動予測部 1 6 - 1 は、現在のユーザ活動状態を表す状態IDに基づいて、現在の時刻Tから所望の時間経過後の時刻T+Nにおけるユーザの活動状態を予測し、予測した活

10

20

30

40

50

動状態の状態IDを対応処理選択部19-1に供給する。ここで、ユーザ活動予測部16-1は、各状態 s_i の時刻 $T+1$ 乃至 $T+N$ にサンプル値 x'_{T+1} 乃至 x'_{T+N} が観測される確率を1と仮定して時刻 $T+N$ までの各状態 s_i の生起確率を計算する。そして、ユーザ活動予測部16-1は、所定時間経過後の時刻 $T+N$ において、生起確率が最大となっている状態、または、生起確率が所定の閾値以上となっている状態を、時刻 $T+N$ におけるユーザの活動状態であると予測する。

【0109】

対応処理取得部17-1は、各部屋の照明のオン・オフ、テレビのスイッチのオン・オフ、エアコン（エアークンディショナー）のオン・オフを示す信号を受信することにより取得し、各制御に対応する処理IDとして対応処理学習部18-1に供給する。

10

【0110】

対応処理学習部18-1は、対応処理取得部17-1から処理IDが供給されたとき、学習テーブルの現在のユーザ活動状態を表す状態IDのところの、供給された処理IDの頻度をカウントアップする。これにより、対応処理学習部18-1は、各状態IDに対する各処理IDの共起頻度をカウントする。

【0111】

対応処理選択部19-1は、ユーザ活動予測部16-1から所定の状態IDが供給されたとき、供給された状態IDに対して行うべき処理の処理IDを、対応処理学習部18-1の学習テーブルから選択（決定）する。具体的には、対応処理選択部19-1は、供給された状態IDに対して、頻度の最も高い処理IDを学習テーブルから選択し、対応処理出力部20-1に供給する。なお、対応処理選択部19-1は、供給された状態IDに対して、所定の閾値以上の頻度を有する複数の処理IDを選択するようにしてもよい。

20

【0112】

対応処理出力部20-1は、対応処理選択部19-1から供給される処理IDに応じて、制御対象装置3を制御する。例えば、対応処理出力部20-1は、ユーザが時刻 $T+N$ にリビングに居ると予測された場合には、リビングの照明とエアコンをオンするための制御信号を、制御対象装置3としての照明機器およびエアコンに送信する。

【0113】

以上のデータ処理装置2を用いた第1の実験の実験結果について、図11乃至図18を参照して説明する。

30

【0114】

[前処理部12-1の処理結果]

図11および図12は、前処理部12-1の処理結果を示している。

【0115】

図11は、センサ入力部11-1から供給された入力画像の例と、前処理部12-1で抽出された画像特徴量の時系列データ、および、次元圧縮後の画像特徴量の時系列データを示している。なお、入力画像は、紙面の制約上、撮像した画像をイラスト化したものであり、画像の濃淡の表示も省略されている。

【0116】

入力画像から抽出された画像特徴量の時系列データ（図11中央）は、1000次元程度の次元数が存在するのに対し、主成分分析による次元圧縮後の画像特徴量の時系列データ（図11右）では、50次元程度に次元数が圧縮されている。

40

【0117】

図12は、前処理部12-1による入力画像の画像特徴量の抽出処理を示している。

【0118】

図12は、グレースケール（8ビットの階調）の入力画像に対して、GISTを計算した例である。即ち、前処理部12-1は、グレースケールの入力画像に対して、ステアラブルフィルタ（steerable filter）の出力を 5×5 に分割して平均化したものを画像特徴量とした。ここで、ステアラブルフィルタのパラメータは、解像度については大、中、小の3段階、微分フィルタについては1次微分、2次微分、3次微分の3段階、方向パラメータ

50

は4方向(上、下、右、左)とした。なお、2次微分の微分フィルタには、各軸方向の方向パラメータに加えて全軸方向の方向パラメータも計算できるため、5方向のフィルタ出力となっている。

【0119】

[ユーザ活動モデル学習部13-1の学習結果]

図13および図14は、ユーザ活動モデル学習部13-1による学習の結果得られたHMMを示している。

【0120】

図13および図14では、黒丸は、サモンマップという手法を用いて、状態遷移確率 a_{ij} に基づいて遷移確率の大きい状態間ができるだけ近傍に配置されるように決定したHMMの各状態 s_j の座標 (x, y) を表し、状態 s_j に相当する。ここで、状態数 M は600としている。

10

【0121】

また、図13および図14では、状態 s_i から状態 s_j への状態遷移の状態遷移確率 a_{ij} が0より大である場合(状態 s_i から状態 s_j への状態遷移が有効な状態遷移である場合)、状態 s_i に相当する黒丸と、状態 s_j に相当する黒丸とを、直線(線分)で結んである。したがって、図13および図14において、黒丸どうしを接続する直線は、(有効な)状態遷移に相当する。

【0122】

なお、図13および図14において、状態遷移の方向を表す矢印の図示は、省略してある。

20

【0123】

図14は、図13に示した学習後のHMMに対し、(1)リビングでテレビを視聴する、(3)書斎で考えごとをする、(4)キッチンで料理する、などの各状態 s_i に属する入力画像の一部を重ねて示した図である。なお、入力画像は灰色の四角形で表現されている。

【0124】

状態 s_i 上に配置された入力画像をみると、(1)リビングでテレビを視聴する、(3)書斎で考えごとをする、(4)キッチンで料理する、など、同一のユーザ活動状態が、隣接したHMMの状態に配置されている。即ち、入力画像から認識されるユーザ活動状態が適切に認識され、分類されている。

【0125】

HMMによる学習および認識は、画像特徴量に基づくクラスタリングの一種であると言える。しかし、単に画像特徴量を用いたクラスタリングは、画像の類似性にのみ着目するものであるため、画像に類似性がないものの相関は低くなる。一方、HMMによる学習および認識では、画像の特徴量のみならず、時間の前後関係をも含めてクラスタリングするため、ある特徴量をもつ画像の次に必ず所定の特徴量をもつ画像がくる場合には、それらの画像の特徴量自体に類似性がなくても相関が高くなる。従って、HMMを用いた学習により、入力される画像にラベル付けを行わなくても、ユーザ活動状態を適切に認識し、分類することができる。

30

【0126】

[ユーザ活動認識部15-1の認識結果]

図15は、ユーザ活動認識部15-1による認識の結果を示している。

【0127】

図15は、学習に用いていない新たな入力画像をデータ処理装置2に与えたときに、ユーザ活動認識部15-1が認識した認識結果としての状態 s_i を、黒点として、図9と同様の間取り図上に示したものである。

40

【0128】

なお、勿論、認識処理には、画像データに付加した擬似座標は使用していない。また、認識結果としての状態 s_i に対応する擬似座標は、上述したように、その状態に割り当てられた入力画像の擬似座標の平均値から算出されている。

【0129】

50

図15Aにおいて、バツ印(x)は、ユーザが「(3)書斎で考えごと」をしているある時刻の入力画像の真値、即ち、入力画像に付加した擬似座標を示している。一方、丸印()は、バツ印(x)の入力画像に対するユーザ活動認識部15-1の認識結果、即ち、バツ印の入力画像を認識した状態 s_i に対応する擬似座標を示している。

【0130】

図15Bにおいて、バツ印(x)は、ユーザが「リビングに移動」をしているある時刻の入力画像の真値、即ち、入力画像に付加した擬似座標を示している。一方、丸印()は、バツ印(x)の入力画像に対するユーザ活動認識部15-1の認識結果、即ち、バツ印の入力画像を認識した状態 s_i に対応する擬似座標を示している。

【0131】

図15Bにおいて、バツ印(x)は、ユーザが「(1)リビングでテレビを視聴」をしているある時刻の入力画像の真値、即ち、入力画像に付加した擬似座標を示している。一方、丸印()は、バツ印(x)の入力画像に対するユーザ活動認識部15-1の認識結果、即ち、バツ印の入力画像を認識した状態 s_i に対応する擬似座標を示している。

【0132】

図15A乃至図15Cのいずれのユーザ活動状態においても、バツ印と丸印は非常に近く、学習されたHMMにより、ユーザの活動状態を適切に認識することができる。

【0133】

[ユーザ活動予測部16-1の予測結果]

図16は、ユーザ活動予測部16-1の予測結果を示している。

【0134】

図16A乃至図16Cは、いずれも、ユーザ活動予測部16-1が認識した現在のユーザ活動状態から3分後のユーザの活動の予測結果を、各活動状態の生起確率として示している。

【0135】

なお、各活動状態の生起確率は、次のようにして求められている。例えば、「(1)リビングでテレビを視聴している」確率は、状態 s_i に対応させた擬似座標がリビング内の所定の範囲内にある場合を「(1)リビングでテレビを視聴している」と定義し、認識結果の3分後の状態 s_j に対応する擬似座標が、定義した所定の範囲内にある確率を求めた。その他のユーザ活動状態の生起確率についても同様である。

【0136】

図16Aは、現在のユーザ活動状態が「(3)書斎で考えごと」である場合の、3分後に予測されるユーザの活動状態を示している。

【0137】

現在のユーザ活動状態が「(3)書斎で考えごと」である場合には、3分後にユーザが、そのまま「(3)書斎で考えごとをしている」確率が42.9%である。3分後にユーザが「(1)リビングでテレビを視聴している」確率が24.5%である。3分後にユーザが「(5)洗面所でメイクしている」確率が5.4%である。また、「(4)キッチンで料理をしている」および「(2)ダイニングで食事をしている」確率は、それぞれ、2.6%および0.7%である。

【0138】

図16Bは、現在のユーザ活動状態が「(1)リビングでTV視聴」である場合の、3分後に予測されるユーザの活動状態を示している。

【0139】

現在のユーザ活動状態が「(1)リビングでTV視聴」である場合、3分後にユーザが、そのまま「(1)リビングでテレビを視聴している」確率が63.6%である。3分後にユーザが「(4)キッチンで料理をしている」確率が12.3%である。3分後にユーザが「(3)書斎で考えごとをしている」確率が8.4%である。また、「(2)ダイニングで食事をしている」および「(5)洗面所でメイクしている」確率は、それぞれ、4.

10

20

30

40

50

0%および3.1%である。

【0140】

図16Cは、現在のユーザ活動状態が「(4)キッチンで料理」である場合の、3分後に予測されるユーザの活動状態を示している。

【0141】

現在のユーザ活動状態が「(4)キッチンで料理」である場合、3分後にユーザが、そのまま「(4)キッチンで料理」確率が22.2%である。3分後にユーザが「(1)リビングでテレビを視聴している」確率が38.8%である。3分後にユーザが「(2)ダイニングで食事をしている」確率が17.9%である。また、「(3)書斎で考えごとをしている」および「(5)洗面所でメイクしている」確率は、それぞれ、8.4%および3.0%である。

10

【0142】

以上のように、ユーザ活動予測部16-1によれば、学習されたHMMを用いて、現在のユーザ活動状態から、所定時間経過後のユーザの活動状態を生起確率として予測することができる。

【0143】

[対応処理学習処理および対応処理選択処理]

図17は、対応処理学習部18-1の学習処理により生成される学習テーブルの一部を示している。

【0144】

学習テーブルでは、HMMの各状態のときに制御対象装置3で行われた対応処理の頻度が、状態IDと処理IDとを対応付ける形で記憶されている。

20

【0145】

そして、図18に示されるように、ユーザ活動予測制御処理において、ユーザ活動予測部16から供給された状態IDが「5」であったとする。この場合、対応処理選択部19-1は、状態ID「5」に対して頻度の最も高い処理ID「5」を選択して、選択した処理ID「5」を対応処理出力部20-1に供給する。

【0146】

例えば、状態ID「5」が「(1)リビングでテレビを視聴している」であり、処理ID「5」が「テレビのスイッチをオンにする」であるとすると、対応処理選択部19-1は、「テレビのスイッチをオンにする」旨の信号を対応処理出力部20-1に供給する。対応処理出力部20-1は、「テレビのスイッチをオンにする」旨の信号が供給されると、電源をオンするリモートコントロール信号をテレビに送信する。

30

【0147】

以上のように、第1の実験によれば、ウェアラブルセンサ1から取得される画像データを用いて、ユーザの現在の状態を的確に認識するとともに、所望の時間経過後の未来のユーザの状態を確率的に予測することができる。また、予測結果に応じて外部の機器を制御することができる。

【0148】

[第2の実験例]

次に、第2の実験例について説明する。データ処理装置2の構成は図10と同様であるので、データ処理装置2の説明には図10のデータ処理装置2の符号を引用して説明する。

40

【0149】

第2の実験では、ウェアラブルセンサ1としてGPS受信機が用いられる。また、制御対象装置3には、例えば、携行可能な小型のディスプレイやスピーカが採用される。

【0150】

データ処理装置2は、ユーザの行動、具体的にはユーザが移動した移動経路をユーザ活動モデルとしてのエルゴディックHMMに学習させる。そして、データ処理装置2は、現在の時刻Tから所望の時間経過後の時刻T+Nにおけるユーザの行き先(位置)を予測する。

50

データ処理装置 2 は、予測した行き先に応じた情報をディスプレイに表示する。例えば、データ処理装置 2 は、予測した行き先が駅である場合、時刻表をディスプレイに表示させる。また例えば、データ処理装置 2 は、予測した行き先にユーザがよく行く店舗がある場合、その店舗の詳細情報（営業時間やセール情報など）をディスプレイに表示させる。

【 0 1 5 1 】

センサ入力部 1 1 - 1 は、ウェアラブルセンサ 1 としてのGPS受信機が出力した時系列の位置データをセンサデータとして取得し、前処理部 1 2 - 1 に供給する。前処理部 1 2 - 1 は、本実験では何も行わず、供給されたデータをそのまま出力する。しかし、前処理部 1 2 - 1 には、例えば、ローパスフィルタ処理やGPS信号を受信できないトンネル内のルートを補足する処理などを行わせることができる。

10

【 0 1 5 2 】

ユーザ活動モデル学習部 1 3 - 1、ユーザ活動モデルパラメータ記憶部 1 4 - 1、およびユーザ活動認識部 1 5 - 1 の処理は、処理対象のセンサデータ（時系列データ）が位置データであること以外、第 1 の実験例と同様であるので説明を省略する。

【 0 1 5 3 】

ユーザ活動予測部 1 6 - 1 は、現在のユーザ活動状態を表す状態IDに基づいて、所望の時間経過後の時刻 $T+N$ におけるユーザの活動状態を予測する。第 2 の実験では、ユーザ活動予測部 1 6 - 1 は、現在のユーザ活動状態を起点として、状態遷移確率 a_{ij} に基づいて乱数を用いて試行的に決定した時刻 $T+N$ までの各状態 s_i の生起確率を計算する。すなわち、ユーザ活動予測部 1 6 - 1 は、未来の所望の時刻 $T+n$ ($n=1,2,\dots,N$) にどの状態 s_i であるかを状態遷移確率 a_{ij} に基づいて乱数により順次決定しながら時刻 $T+N$ までの状態 s_i を決定することを 1 回以上試行する。そして、ユーザ活動予測部 1 6 - 1 は、1 回以上の試行の結果、所望の時刻 $T+N$ において生起確率（生起回数）が最大となっている状態、または、生起確率（生起回数）が所定の閾値以上となっている状態を、時刻 $T+N$ におけるユーザの活動状態であると予測する。

20

【 0 1 5 4 】

なお、第 2 の実験においても、第 1 の実験例と同様に、各時刻での各状態 s_i の観測確率を等確率と仮定して、状態遷移確率 a_{ij} に基づいて時刻 $T+N$ までの各状態 s_i の生起確率を計算する方法によって、時刻 $T+N$ におけるユーザの活動状態を予測することも可能である。

30

【 0 1 5 5 】

対応処理学習部 1 8 - 1 は、ユーザの現在地に対応する状態の状態IDと、ディスプレイに表示させる情報を示す処理IDとを対応付けた学習テーブルを記憶する。また、対応処理学習部 1 8 - 1 は、処理IDに紐付けたディスプレイに表示させる情報（ユーザ提示情報）も記憶する。

【 0 1 5 6 】

対応処理選択部 1 9 - 1 は、ユーザ活動予測部 1 6 から供給される状態IDに対応する処理IDを学習テーブルから選択（決定）し、選択した処理IDに対応するユーザ提示情報を対応処理学習部 1 8 - 1 から取得して対応処理出力部 2 0 - 1 に供給する。

【 0 1 5 7 】

対応処理出力部 2 0 - 1 は、対応処理選択部 1 9 - 1 から供給されるユーザ提示情報を制御対象装置 3 としてのディスプレイまたはスピーカに出力する。制御対象装置 3 は、ユーザ提示情報をディスプレイに表示したり、スピーカから音声として出力したりする。

40

【 0 1 5 8 】

図 1 9 および図 2 0 は、実験 2 におけるデータ処理装置 2 の認識結果および予測結果を示している。

【 0 1 5 9 】

図 1 9 において、地図上に示される細線の実線、点線、1 点鎖線、および 2 点鎖線は、データ処理装置 2 に学習させたユーザの移動経路を示している。

【 0 1 6 0 】

50

また、図19において、地図上に示される太線の点線は、学習後に新たに入力したユーザの移動経路（の時系列データ）を示しており、星印が、ユーザの現在地を示している。

【0161】

さらに、図19の太線の実線が、ユーザ活動認識部15-1による認識結果を示し、太線の1点鎖線が、ユーザ活動予測部16-1による予測結果を示している。

【0162】

一方、図20では、ユーザ活動モデル学習部13-1により学習された各状態 s_i が、点線の楕円状の輪で示されている。図20によれば、ユーザの移動経路のすべてが、学習されたいずれかの状態 s_i （点線の楕円状の輪）に含まれており、HMMが正確にユーザの移動経路を学習できていることがわかる。なお、第2の実験では、状態数 M は100としている。

10

【0163】

また、図20では、太線の実線の曲線が、学習後に新たに入力されたユーザの移動経路（の時系列データ）を示しており、それに対してユーザ活動認識部15-1が認識した各状態 s_i が、太線の実線の楕円状の輪で示されている。

【0164】

さらに、図20では、細線の実線が、ユーザ活動予測部16-1が所望の時刻 $T+N$ までのユーザの移動経路（活動状態）を予測した予測結果を示している。

【0165】

図20の細線の実線の楕円状の輪が、図19の太線の1点鎖線に対応し、図20の太線の実線の楕円状の輪が、図19の太線の実線に対応する。また、図20の太線の実線の曲線が図19の太線の点線に対応する。

20

【0166】

図19および図20によれば、ユーザ活動予測部16-1による予測結果として、適切な状態 s_i が選択されていることがわかる。即ち、適切な予測がなされていることがわかる。

【0167】

以上の第2の実験では、ウェアラブルセンサ1から取得される位置データを用いて、ユーザの現在の状態（現在地）を的確に認識するとともに、所望の時間経過後の未来のユーザの状態（現在地）を予測することができる。また、予測結果に応じて外部の機器を制御し、ユーザに情報提供することができる。

30

【0168】

以上、本発明を適用したデータ処理装置2によれば、ユーザの現在の行動（状態）をユーザ活動状態としての的確に認識するとともに、未来の所望の時刻におけるユーザの行動（状態）を生起確率として予測することができる。そして、予測結果に基づいて、外部の装置を制御したり、ユーザに情報を提示したりすることができる。

【0169】

従来、ユーザの行動に応じて電子機器を自動制御するインテリジェントルームを構築する場合には、目的に応じた各種のセンサを居室内に設けることが必要とされていた。本発明によれば、ウェアラブルセンサ1をユーザが身に着けてさえいれば、ユーザの活動状態を認識し、予測して、制御することができるので、簡単な構成でインテリジェントルームの構築が可能である。

40

【0170】

上述した一連の処理は、ハードウェアにより実行することもできるし、ソフトウェアにより実行することもできる。一連の処理をソフトウェアにより実行する場合には、そのソフトウェアを構成するプログラムが、コンピュータにインストールされる。ここで、コンピュータには、専用のハードウェアに組み込まれているコンピュータや、各種のプログラムをインストールすることで、各種の機能を実行することが可能な、例えば汎用のパーソナルコンピュータなどが含まれる。

【0171】

50

図 21 は、上述した一連の処理をプログラムにより実行するコンピュータのハードウェアの構成例を示すブロック図である。

【0172】

コンピュータにおいて、CPU (Central Processing Unit) 101, ROM (Read Only Memory) 102, RAM (Random Access Memory) 103 は、バス 104 により相互に接続されている。

【0173】

バス 104 には、さらに、入出力インタフェース 105 が接続されている。入出力インタフェース 105 には、入力部 106、出力部 107、記憶部 108、通信部 109、及びドライブ 110 が接続されている。

10

【0174】

入力部 106 は、キーボード、マウス、マイクロホンなどよりなる。出力部 107 は、ディスプレイ、スピーカなどよりなる。記憶部 108 は、ハードディスクや不揮発性のメモリなどよりなる。通信部 109 は、ネットワークインタフェースなどよりなる。ドライブ 110 は、磁気ディスク、光ディスク、光磁気ディスク、或いは半導体メモリなどのリムーバブル記録媒体 111 を駆動する。

【0175】

以上のように構成されるコンピュータでは、CPU 101 が、例えば、記憶部 108 に記憶されているプログラムを、入出力インタフェース 105 及びバス 104 を介して、RAM 103 にロードして実行することにより、上述した一連の処理が行われる。

20

【0176】

コンピュータ (CPU 101) が実行するプログラムは、例えば、パッケージメディア等としてのリムーバブル記録媒体 111 に記録して提供することができる。また、プログラムは、ローカルエリアネットワーク、インターネット、デジタル衛星放送といった、有線または無線の伝送媒体を介して提供することができる。

【0177】

コンピュータでは、プログラムは、リムーバブル記録媒体 111 をドライブ 110 に装着することにより、入出力インタフェース 105 を介して、記憶部 108 にインストールすることができる。また、プログラムは、有線または無線の伝送媒体を介して、通信部 109 で受信し、記憶部 108 にインストールすることができる。その他、プログラムは、ROM 102 や記憶部 108 に、あらかじめインストールしておくことができる。

30

【0178】

なお、コンピュータが実行するプログラムは、本明細書で説明する順序に沿って時系列に処理が行われるプログラムであっても良いし、並列に、あるいは呼び出しが行われたとき等の必要なタイミングで処理が行われるプログラムであっても良い。

【0179】

なお、本明細書において、フローチャートに記述されたステップは、記載された順序に沿って時系列的に行われる場合はもちろん、必ずしも時系列的に処理されなくとも、並列に、あるいは呼び出しが行われたとき等の必要なタイミングで実行されてもよい。

【0180】

なお、本明細書において、システムとは、複数の装置により構成される装置全体を表すものである。

40

【0181】

本発明の実施の形態は、上述した実施の形態に限定されるものではなく、本発明の要旨を逸脱しない範囲において種々の変更が可能である。

【符号の説明】

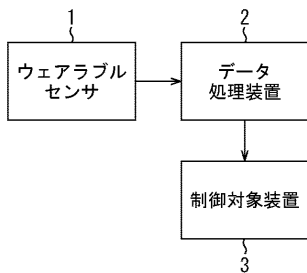
【0182】

1 ウェアラブルセンサ, 2 データ処理装置, 11 センサ入力部, 12 前処理部, 13 ユーザ活動モデル学習部, 14 ユーザ活動モデルパラメータ記憶部, 15 ユーザ活動認識部, 16 ユーザ活動予測部, 17 対応処理取得部,

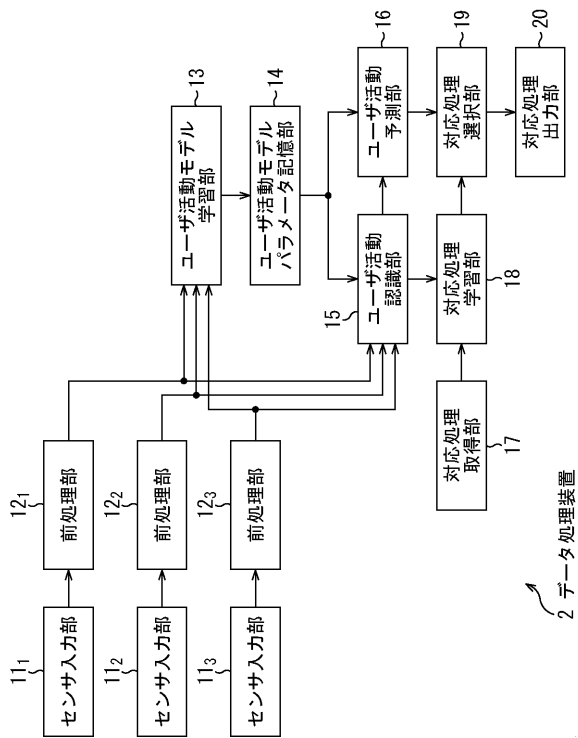
50

1 8 対応処理学習部, 1 9 対応処理選択部, 2 0 対応処理出力部

【図1】
図1

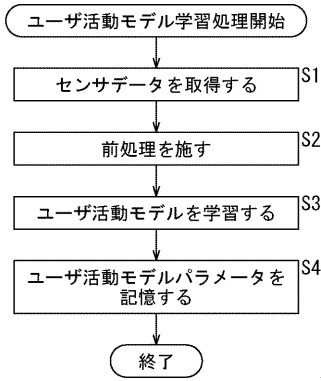


【図2】
図2



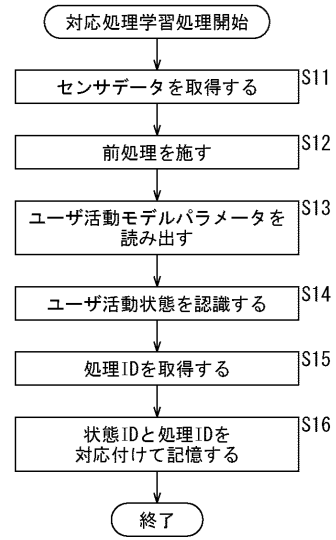
【図3】

図3



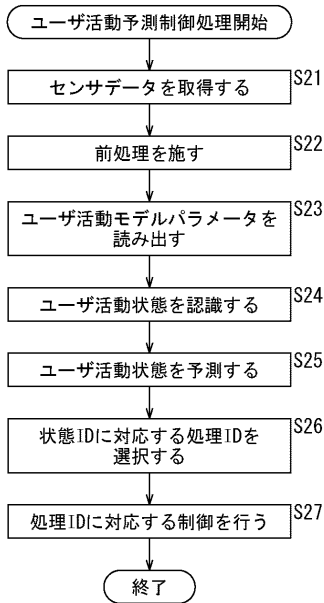
【図4】

図4



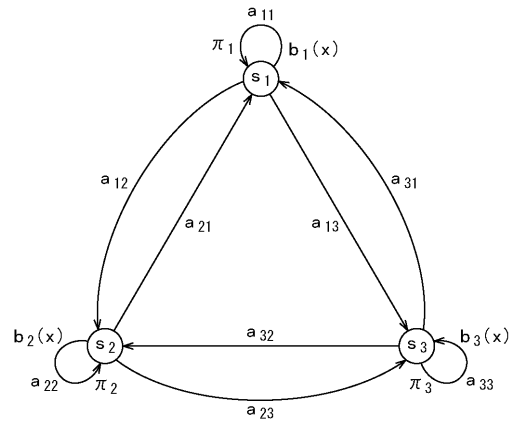
【図5】

図5



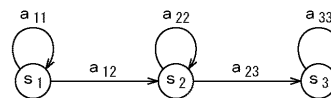
【図6】

図6



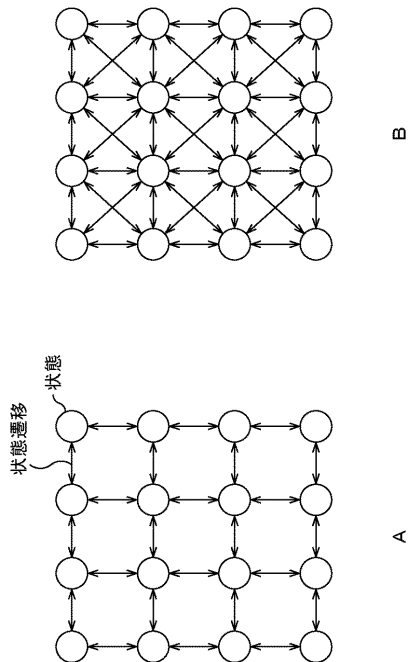
【図7】

図7



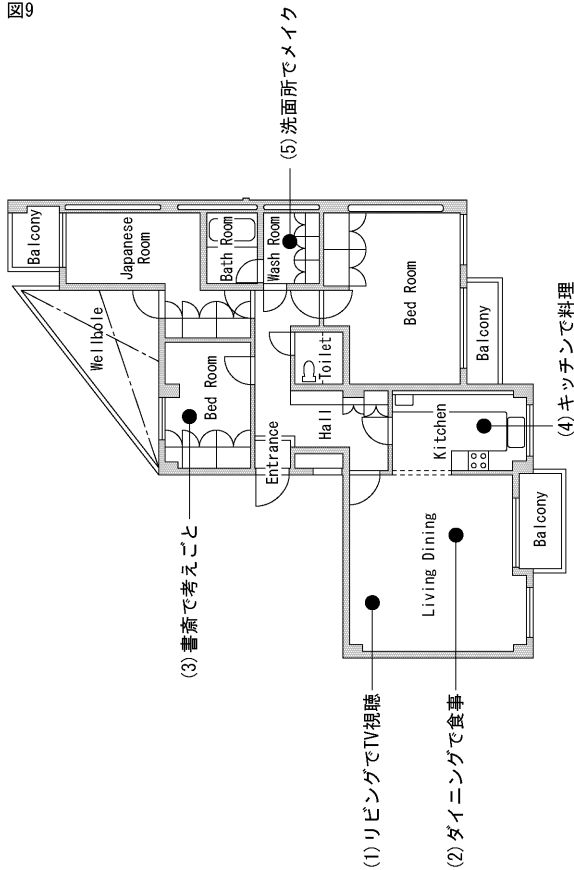
【 図 8 】

図8



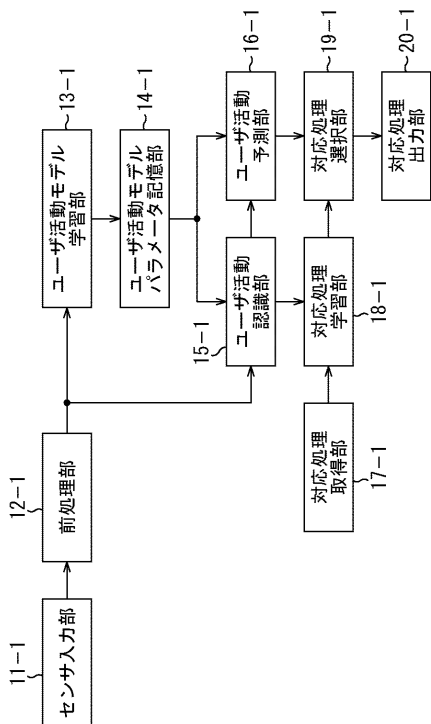
【 図 9 】

図9



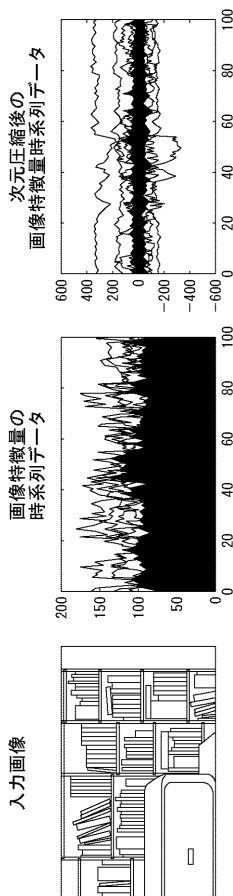
【 図 10 】

図10

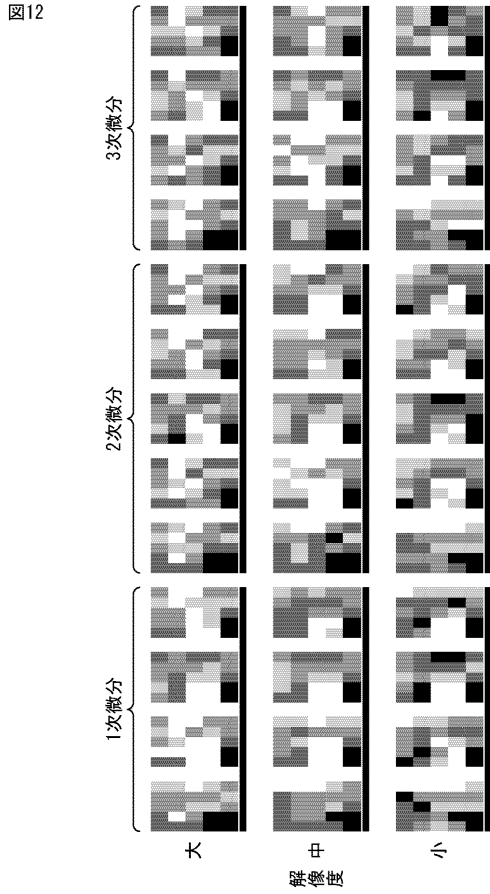


【 図 11 】

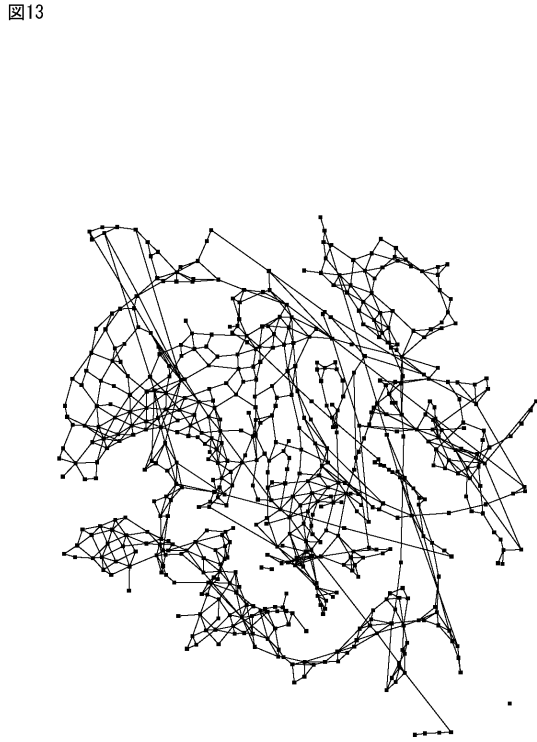
図11



【 図 1 2 】



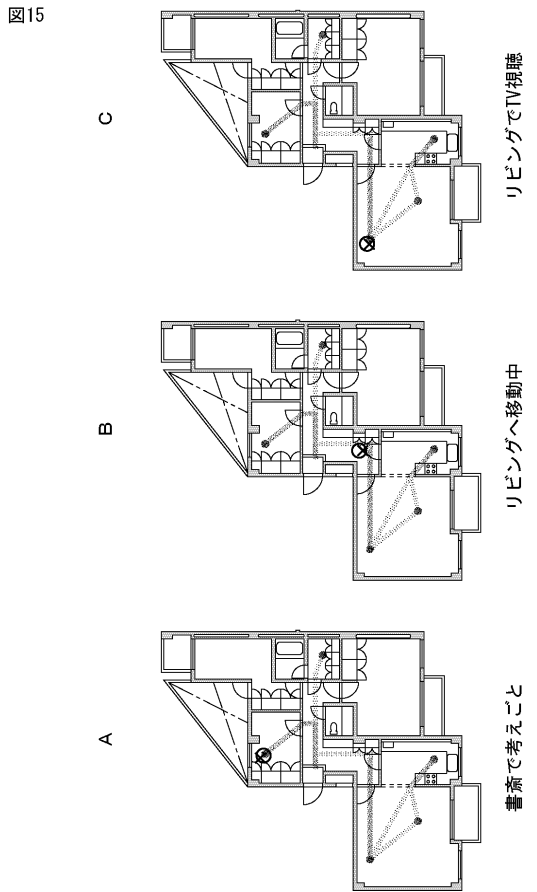
【 図 1 3 】



【 図 1 4 】

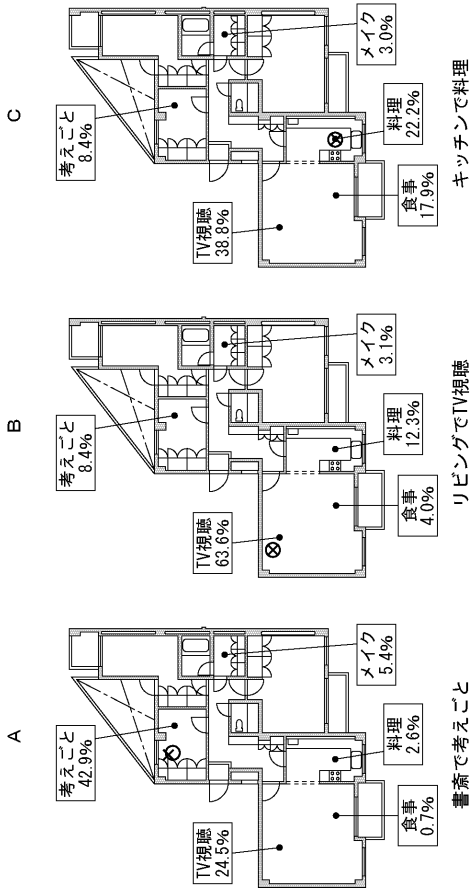


【 図 1 5 】



【図16】

図16



【図17】

図17

HMM 状態ID	対応処理ID									
	1	2	3	4	5	6	7	8	9	10
1	0	10	2	0	0	0	0	0	0	0
2	0	3	10	0	0	0	0	0	0	0
3	5	0	0	0	0	0	0	0	0	0
4	10	0	0	0	0	0	0	0	0	0
5	0	0	0	0	25	2	0	0	0	0
6	0	0	0	0	3	19	0	0	0	0
7	0	0	0	0	0	0	30	0	0	5
8	0	0	0	0	0	0	0	9	3	0
9	0	0	0	0	0	0	0	4	10	0
10	0	0	0	0	0	0	8	0	0	40

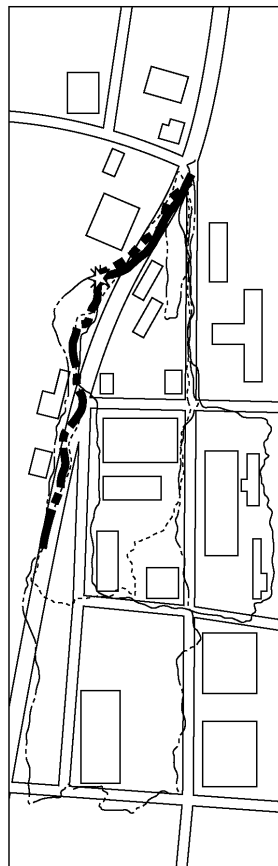
【図18】

図18

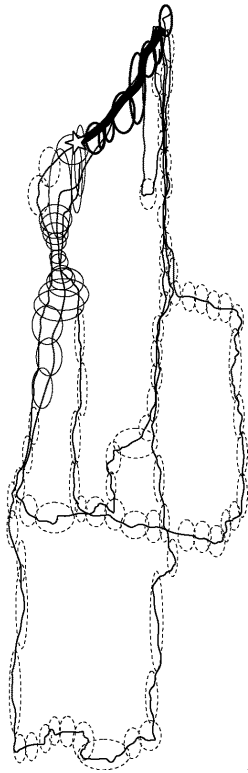
HMM 状態ID	対応処理ID									
	1	2	3	4	5	6	7	8	9	10
1	0	10	2	0	0	0	0	0	0	0
2	0	3	10	0	0	0	0	0	0	0
3	5	0	0	0	0	0	0	0	0	0
4	10	0	0	0	0	0	0	0	0	0
5	0	0	0	0	25	2	0	0	0	0
6	0	0	0	0	3	19	0	0	0	0
7	0	0	0	0	0	0	30	0	0	5
8	0	0	0	0	0	0	0	9	3	0
9	0	0	0	0	0	0	0	4	10	0
10	0	0	0	0	0	0	8	0	0	40

【図19】

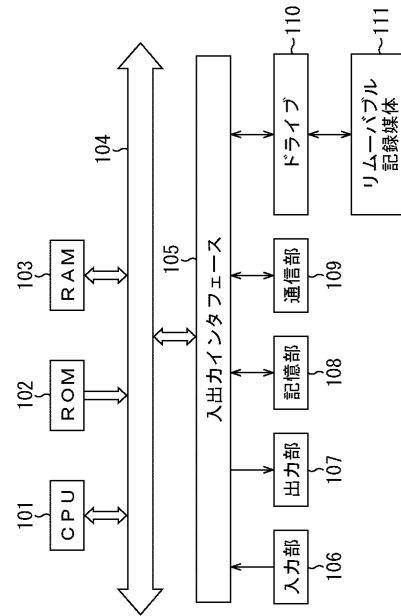
図19



【図20】
図20



【図21】
図21



フロントページの続き

- (72)発明者 鈴木 洋貴
東京都港区港南1丁目7番1号 ソニー株式会社内
- (72)発明者 横野 順
東京都港区港南1丁目7番1号 ソニー株式会社内
- (72)発明者 青山 一美
東京都港区港南1丁目7番1号 ソニー株式会社内
- (72)発明者 蓮尾 高志
東京都港区港南1丁目7番1号 ソニー株式会社内

審査官 新井 寛

- (56)参考文献 特開2007-328435(JP,A)
Brian Clarkson, et al., Recognizing User Context via Wearable Sensors, Wearable Computers, The Fourth International Symposium on, 2000年10月, p.69-75
Donald J. Patterson, et al., Inferring High-Level Behavior from Low-Level Sensors, UbiComp 2003: Ubiquitous Computing, LNCS 2864, 2003年, p.73-89

- (58)調査した分野(Int.Cl., DB名)
G06N 5/04
G06Q 50/10
IEEE Explore