

(19)日本国特許庁(JP)

(12)特許公報(B2)

(11)特許番号
特許第7520123号
(P7520123)

(45)発行日 令和6年7月22日(2024.7.22)

(24)登録日 令和6年7月11日(2024.7.11)

(51)国際特許分類

FI

B 2 5 J 19/06 (2006.01)

B 2 5 J 19/06

G 0 6 N 20/00 (2019.01)

G 0 6 N 20/00

請求項の数 20 (全41頁)

(21)出願番号	特願2022-538572(P2022-538572)	(73)特許権者	000006013
(86)(22)出願日	令和2年12月1日(2020.12.1)		三菱電機株式会社
(65)公表番号	特表2022-546644(P2022-546644 A)	(74)代理人	東京都千代田区丸の内二丁目7番3号 110001195
(43)公表日	令和4年11月4日(2022.11.4)		弁理士法人深見特許事務所
(86)国際出願番号	PCT/JP2020/045361	(72)発明者	ラフトチーブ, エミル
(87)国際公開番号	WO2021/112256		アメリカ合衆国、0 2 1 3 9 - 1 9 5 5
(87)国際公開日	令和3年6月10日(2021.6.10)		マサチューセッツ州、ケンブリッジ、ブ
審査請求日	令和4年2月21日(2022.2.21)		ロードウェイ 2 0 1、エイス・フロア
(31)優先権主張番号	16/705,602		、ケアオブ・ミツビシ・エレクトリック
(32)優先日	令和1年12月6日(2019.12.6)		・リサーチ・ラボラトリーズ・インコー
(33)優先権主張国・地域又は機関	米国(US)	(72)発明者	ポレイテッド
			ロメレス, ディエゴ
			アメリカ合衆国、0 2 1 3 9 - 1 9 5 5
			マサチューセッツ州、ケンブリッジ、ブ
			最終頁に続く

(54)【発明の名称】 人間－ロボット混在製造プロセスにおける自動異常検出のためのシステムおよび方法

(57)【特許請求の範囲】

【請求項1】

人間－ロボット混在プロセスにおいてタスクのシーケンスの中のタスクの実行時に異常を検出するためのプロセス制御システムであって、

ロボットデータ、製造プロセス（MP）データ、ヒューマンデータおよび実行可能なモデルを含むデータを格納するように構成されたメモリと、

ヒューマンワーカ（HW）のデータを収集するためのセンサから取得されたHW信号およびロボットの動作を収集するためのセンサから取得されたロボット動作信号を受信するように構成された入力インターフェイスと、

ハードウェアプロセッサとを備え、前記ハードウェアプロセッサは、

前記HW信号から、ヒューマンパフォーマンス（HP）モデルへ入力するヒューマンデータを抽出するように構成され、前記HPモデルは、事前に学習された前記HWの状態の境界に基づいて前記HWの前記状態を判断し、前記HWの前記状態は、異常の分類または異常無しを決定するために人間－ロボットインタラクション（HRI）モデルに入力され、前記ハードウェアプロセッサはさらに、

前記HRIモデルを前記ロボット動作信号、前記HW信号および分類された異常で更新するように構成され、

更新されたHRIモデルおよび前記分類された異常を使用して、前記HWと相互作用するロボットの制御アクションまたは異常アラームのタイプを決定するように構成され、前記プロセス制御システムはさらに、

前記更新されたH R Iモデルおよび前記分類された異常に基づいて、ロボットアクションを変更するために前記ロボットの前記制御アクションを出力するか、または前記異常アラームの前記タイプを前記人間-ロボット混在プロセスの管理システムに出力するための出力インターフェイスを備え、

前記H R Iモデルは、前記H Wの前記さまざまな状態と最適なロボットアクションとの間のマッピングを学習済みであるように事前に構成される、プロセス制御システム。

【請求項2】

前記H Wのための前記H Pモデルは、H Wパフォーマンスのさまざまな状態の境界を前記ヒューマンデータにより学習済みであるように事前に構成される、請求項1に記載のプロセス制御システム。

【請求項3】

前記H Pモデルは、前記H W信号を受信する前に、訓練フェーズ中に、完了した訓練タスクのH W訓練信号から構築され、前記H W訓練信号は、前記完了した訓練タスクの各々の完了した訓練タスクについてデータを含み、前記データは、訓練タスク名、各々の完了した訓練タスクについての前記H Wの複数の訓練状態、および次の順番の訓練タスクを含む、請求項1に記載のプロセス制御システム。

【請求項4】

前記H W訓練信号は、前記H W信号を得る前に、訓練動作中に、前記H Wに関連付けられたセンサから得られ、前記H W信号は、前記人間-ロボット混在プロセスの動作中に、前記H Wに関連付けられたセンサから得られる、請求項3に記載のプロセス制御システム。

【請求項5】

前記H Pモデルは、ヒューマンタスク実行(H T E)モデルおよび前記H Wの前記状態のモデルによって構築され、前記H T Eモデルは、訓練タスクのシーケンスを完了しながら訓練フェーズ中に取得されたH W訓練信号を使用して訓練された少なくとも1つの予測モデルを使用して構築され、前記H Wの前記状態の前記モデルは、前記H W訓練信号を使用して訓練された少なくとも1つの分類モデルを使用して構築され、各々の完了した訓練タスクは、前記H Wの複数の状態に関連付けられて、前記メモリに格納され、

前記予測モデルは、タスクの予測完了時刻またはヒューマンワークの動きのパターンを推論するためのモデルで、

前記分類モデルは、ワークの状態およびワークが現在取り組んでいるタスクを推論するためのモデルである、請求項1に記載のプロセス制御システム。

【請求項6】

前記少なくとも1つの予測モデルは、各々の完了したタスクについて予測完了時刻を学習して、センサから取得されたセンサデータに見られる前記H Wの動きのパターンを識別するまたは取り込むように構成され、少なくとも1つの統計モデル学習アプローチは、1つまたは複数の予測モデル、1つまたは複数の分類モデル、またはそれら両方を含み、前記H Wが少なくとも1つのタスクを完了するにあたり前記ロボットとインタラクティブに作業している間に、前記ヒューマンデータを考慮して進行中のタスクの完了時刻の推定値を生成することができる、請求項5に記載のプロセス制御システム。

【請求項7】

前記少なくとも1つの分類モデルは、完了したタスクおよび次の順番のタスクを最初に判断することによって前記H W信号から前記H Wの状態を学習するように構成され、次いでタスクの完了中にワークの視線の位置の分布を学習する視線検出アルゴリズムを使用して前記H Wの前記状態を判断する、請求項5に記載のプロセス制御システム。

【請求項8】

前記H T Eモデルの前記H W訓練信号は、各々の完了した訓練タスクについて訓練タスクを識別するタスクに関連付けられた訓練データを含み、各々の完了した訓練タスクについて、(1)前記H Wの状態に対応する予想タスク完了期間のスケールを含み、前記予想タスク完了期間のスケールは、前記スケールが最短となる最高H Wパフォーマンス予想タスク完了期間から前記スケールが最長となる最低H Wパフォーマンス予想タスク完了期間

10

20

30

40

50

までであり、(2) 前記予想タスク完了期間の前記スケールを期間閾値のタイプに関連付けることを含み、(3) 各々の完了した訓練タスクについての前記HW信号を含み、前記HW信号は、前記完了した訓練タスクの時点での前記HWのデータを含み、前記HWの前記データは、年齢、技術教育のレベル、高等教育のレベル、前記タスクを完了するスキルのレベル、雇用年数、身長、体重、精神的状態、身体障害を含む身体的状態である、請求項5に記載のプロセス制御システム。

【請求項9】

前記HW訓練信号は、慣性測定センサ、生物学的センサ、人体搭載モーションセンサ、前記HWが前記タスクを完了している環境における外部モニタ、前記訓練タスクの各訓練タスクを完了することに関連付けられた時刻情報、および視線検出器の外部モーションセンサのセンサから取得された訓練データを含む、請求項5に記載のプロセス制御システム。

10

【請求項10】

前記HW信号は、各々の完了した訓練タスクについてデータを含み、前記データは、前記HWによる動きのパターン、元気レベル、HWスキルレベルに関連付けられたスキルレベルのうちの1つまたはそれらの組み合わせである、請求項1に記載のプロセス制御システム。

【請求項11】

異常検出の分類のうちのいくつかは、前記HWの前記状態に関連付けられたロボットアクションを含み、前記ロボットアクションは、前記ロボットのさまざまなレベルの速度、X軸、Y軸およびZ軸での動き、音声告知、電話をかけること、1つまたは複数の期間にわたるロボット位置の維持、コントローラに送信されたコマンドを介した環境条件の調整を含み、前記異常の分類のタイプのうちのいくつかは、将来の異常、メンテナンス関連異常、安全性関連異常、損失生産異常、構成要素の潜在的故障の異常、品質異常および組立ライン異常の検出も含む、請求項1に記載のプロセス制御システム。

20

【請求項12】

前記異常無しが判断される場合、前記HWの前記状態は、HWパフォーマンス閾値の予め定められたレベルと比較され、前記HWが前記タスクを完了するためのピークパフォーマンスを示すHWピークパフォーマンス閾値よりも大きい場合、前記HPモデルは、前記HWによってモデルピークパフォーマンスに更新され、HWパフォーマンスの前記レベルは、学習済み統計モデルを用いて、前記受信したHW信号から抽出したデータによって求められ、前記データは、学習済み統計モデルに適合し、または取得した前記HWの前記状態を予測するために使用される、請求項2に記載のプロセス制御システム。

30

【請求項13】

前記HPモデルによって前記ヒューマンデータから学習されたさまざまなタイプの異常および異常無しの前記事前に学習された前記HWの前記状態の境界のうちのいくつかは、HWがもう作業を行っていないこと、HWが注意散漫であること、前記事前に学習された前記HWの前記状態の境界に従ってHWが疲れているもしくはパフォーマンスが低下していることを示すエネルギーレベルをHWが体験していること、前記事前に学習された前記HWの前記状態の境界に従ってHWが元気であるもしくは高いエネルギーレベルで動作していることを示すエネルギーレベルをHWが体験していること、または、前記事前に学習された前記HWの前記状態の境界に従ってHWが疲れていないもしくは元気である（平均的な元気レベル）もしくは平均的なHWパフォーマンスに関連付けられたエネルギーレベルで動作していることを示すエネルギーレベルをHWが体験していることを含む、請求項1に記載のプロセス制御システム。

40

【請求項14】

人間-ロボット混在プロセスにおいてタスクのシーケンスの中のタスクの実行時に異常を検出するためのプロセス制御方法であって、

ヒューマンワーカ(HW)のデータを収集するためのセンサから取得されたHW信号およびロボットの動作を収集するためのセンサから取得されたロボット動作信号を得るステップと、

50

前記HW信号から、ヒューマンパフォーマンス（HP）モデルへ入力するヒューマンデータを抽出して、事前に学習された前記HWの状態の境界に基づいて前記HWの状態を取得するステップとを備え、次いで、前記HWの前記状態は、異常の分類または異常無しを決定するために人間－ロボットインタラクション（HRI）モデルに入力され、前記方法はさらに、

前記HRIモデルを前記ロボット動作信号、前記HW信号および分類された異常で更新し、次いで、更新されたHRIモデルおよび前記分類された異常を使用して、前記HWと相互作用するロボットの制御アクションまたは異常アラームのタイプを決定するステップと、

前記更新されたHRIモデルおよび前記分類された異常に基づいて、ロボットアクションを変更するために前記ロボットの前記制御アクションを出力するか、または前記異常アラームの前記タイプを前記人間－ロボット混在プロセスの管理システムに出力するステップとを備え、前記ステップは、メモリに接続されたハードウェアプロセッサによって実行され、

前記HRIモデルは、前記HWの前記さまざまな状態と最適なロボットアクションとの間のマッピングを学習済みであるように事前に構成される、プロセス制御方法。

【請求項15】

前記異常アラームのタイプは、疑わしい組立ライン機械的故障、疑わしい組立ラインへの材料供給問題、前記HWに起因する生産不足問題、オペレータ関連タスク、もしくは疑わしい電子的故障のうちの1つまたはそれらの組み合わせを含む、請求項14に記載の方法。

【請求項16】

前記HPモデルは、ヒューマンタスク実行（HTE）モデルおよび前記HWの前記状態のモデルによって構築され、前記HTEモデルは、訓練タスクのシーケンスを完了しながら訓練フェーズ中に取得されたHW訓練信号を使用して訓練された少なくとも1つの予測モデルを使用して構築され、前記HWの前記状態の前記モデルは、前記HW訓練信号を使用して訓練された少なくとも1つの分類モデルを使用して構築され、各々の完了した訓練タスクは、前記HWの複数の状態に関連付けられて、前記メモリに格納され、

前記予測モデルは、タスクの予測完了時刻またはヒューマンワークの動きのパターンを推論するためのモデルで、前記分類モデルは、ヒューマンワークの状態およびヒューマンワークが現在取り組んでいるタスクを推論するためのモデルである、請求項14に記載の方法。

【請求項17】

前記少なくとも1つの予測モデルは、各々の完了したタスクについて予測完了時刻を学習して、センサから取得されたセンサデータに見られる前記HWの動きのパターンを識別するまたは取り込むように構成され、少なくとも1つの統計モデル学習アプローチは、1つまたは複数の予測モデル、1つまたは複数の分類モデル、またはそれら両方を含み、前記HWが少なくとも1つのタスクを完了するにあたり前記ロボットとインタラクティブに作業している間に、前記ヒューマンデータを考慮して進行中のタスクの完了時刻の推定値を生成することができる、請求項16に記載の方法。

【請求項18】

前記少なくとも1つの分類モデルは、完了したタスクおよび次の順番のタスクを最初に判断することによって前記HW信号から前記HWの状態を学習するように構成され、次いでタスクの完了中にワークの視線の位置の分布を学習する視線検出アルゴリズムを使用して前記HWの前記状態を判断する、請求項16または請求項17に記載の方法。

【請求項19】

プロセス制御方法を実行するためのコンピュータによって実行可能なプログラムが組み込まれた非一時的なコンピュータ読取可能記憶媒体であって、前記プロセス制御方法は、人間－ロボット混在プロセスにおいてタスクのシーケンスの中のタスクの実行時に異常を検出するためのものであって、前記プロセス制御方法は、

10

20

30

40

50

ヒューマンワーカ（HW）のデータを収集するためのセンサから取得されたHW信号およびロボットの動作を収集するためのセンサから取得されたロボット動作信号を得るステップと、

前記HW信号から、ヒューマンパフォーマンス（HP）モデルへ入力するヒューマンデータを抽出して、事前に学習された前記HWの状態の境界に基づいてHWパフォーマンスの状態を取得するステップとを備え、次いで、前記HWパフォーマンスの前記状態は、異常の分類または異常無しを決定するために人間－ロボットインタラクション（HRI）モデルに入力され、前記方法はさらに、

前記HRIモデルを前記ロボット動作信号、前記HW信号および分類された異常で更新し、次いで、更新されたHRIモデルおよび前記分類された異常を使用して、前記HWと相互作用するロボットの制御アクションまたは異常アラームのタイプを決定するステップと、

前記更新されたHRIモデルおよび前記分類された異常に基づいて、ロボットアクションを変更するために前記ロボットの前記制御アクションを出力するか、または前記異常アラームの前記タイプを前記人間－ロボット混在プロセスの管理システムに出力するステップとを備え、前記プロセス制御方法の前記ステップは、メモリに接続されたハードウェアプロセッサを使用して実行され、

前記HRIモデルは、前記HWの前記さまざまな状態と最適なロボットアクションとの間のマッピングを学習済みであるように事前に構成される、非一時的なコンピュータ読取可能記憶媒体。

【請求項20】

前記HPモデルは、ヒューマンタスク実行（HTE）モデルおよび前記HWの前記状態のモデルによって構築され、前記HTEモデルは、訓練タスクのシーケンスを完了しながら訓練フェーズ中に取得されたHW訓練信号を使用して訓練された少なくとも1つの予測モデルを使用して構築され、

前記HWの前記状態の前記モデルは、前記HW訓練信号を使用して訓練された少なくとも1つの分類モデルを使用して構築され、各々の完了した訓練タスクは、前記HWの複数の状態に関連付けられて、前記メモリに格納され、

前記予測モデルは、タスクの予測完了時刻またはヒューマンワーカの動きのパターンを推論するためのモデルで、

前記分類モデルは、ワーカの状態およびワーカが現在取り組んでいるタスクを推論するためのモデルであり、

前記少なくとも1つの予測モデルは、各々の完了したタスクについて予測完了時刻を学習して、センサから取得されたセンサデータに見られる前記HWの動きのパターンを識別するまたは取り込むように構成され、少なくとも1つの統計モデル学習アプローチは、1つまたは複数の予測モデル、1つまたは複数の分類モデル、またはそれら両方を含み、前記HWが少なくとも1つのタスクを完了するにあたり前記ロボットとインタラクティブに作業している間に、前記ヒューマンデータを考慮して進行中のタスクの完了時刻の推定値を生成することができ、

前記少なくとも1つの分類モデルは、完了したタスクおよび次の順番のタスクを最初に判断することによって前記HW信号から前記HWの状態を学習するように構成され、次いでタスクの完了中にワーカの視線の位置の分布を学習する視線検出アルゴリズムを使用して前記HWの前記状態を判断する、請求項1に記載のプロセス制御システム。

【発明の詳細な説明】

【技術分野】

【0001】

技術分野

本開示は、一般にモデル学習技術のシステムおよび方法に関し、より具体的には人間－ロボット協働製造プロセスのためのモデル学習技術のシステムおよび設計に関する。

【背景技術】

【0002】

背景技術

従来の機械学習技術は、ロボットおよびパーソナルアシスタントなどのインテリジェントシステムが、例または命令から学習によって知識を得て困難な問題を解決することを可能にすることができる。

【0003】

しかし、これらの従来の学習モデルでは、ロボットシステムを制御するにあたって多くの難題がある。これは、ロボットシステムの動きが、剛体動力学（RBD）と呼ばれる非常に複雑な物理法則によって支配され、通常はこれらの物理法則の概要しか知られていないことに由来する。さらに、入手できないことが多いロボットの各構成要素の位置、速度および加速度などの物理量の測定は、これらの法則を計算する必要がある。ロボットシステムに搭載されたセンサは、一般に、位置成分のみを測定し（たとえば、エンコーダ、ポテンショメータ、近接センサ...）、速度および加速度は測定されない。さらに、タスクが特定の物体の操作を含む場合、物体がセンサレスであり、空間上でその位置を測定するために外部センサ（たとえば、カメラまたはエンコーダ）しか追加することができない場合が多い。

10

【0004】

ロボットシステムを制御する際のこれらの従来の学習モデルの他の問題点は、ウェアラブル技術および機械学習の発展が説明されず、さらに言えば含まれないことである。これらの従来の機械学習アプローチが使用される場合、コンピュータビジョンのサブ分野からになりやすく、ソリューションの適用範囲の点で相当な制約をもたらす。たとえば、CN 105389859 A 特許は、作業状態における清掃作業員をモニタリングするためのモニタリングシステムに関する。この方法は、RFIDおよびスマート街灯柱を使用して作業員の出席をモニタリングするインテリジェント街灯柱アプリケーションに基づく。しかし、この方法では、作業員が何をしているか、および、作業員の健康状態がどうであるかが分からない。

20

【0005】

したがって、人間-ロボット協働製造プロセスを特徴付けることを学習する学習システムのための高度な技術を開発する必要がある。特に、ヒューマンワークの状態を条件としてロボットがヒューマンワークに提供できる手助けを調整するプロセスを人間-ロボットコラボレーションレベルで最適化するように設計された学習システムを提供する必要がある。また、製造プロセス全体において異常を検出することができるシステム。

30

【発明の概要】

【課題を解決するための手段】

【0006】

発明の概要

本開示は、一般にモデル学習技術のシステムおよび方法に関し、より具体的には人間-ロボット協働製造プロセスのためのモデル学習技術のシステムおよび設計に関する。

【0007】

特に、本開示のいくつかのシステムおよび方法は、製造プロセス全体に沿って速度を最適化し、人間とロボットとの間のインタラクションを最適化して製品の速度および品質を最適化することによって、従来の人間-ロボットコラボレーションプロセス問題を克服する。これは、ヒューマンワークの状態の起こり得る変化を考慮に入れながら製造プロセス全体において異常を検出することができるとともに、ワークの状態を条件としてロボットがヒューマンワークに提供している手助けを調整することによってプロセスを人間-ロボットコラボレーションレベルで最適化することによって、実現することができる。

40

【0008】

たとえば、いくつかの実施形態は、最初にヒューマンワークパフォーマンスの典型的なまたは通常の動作を学習すること、すなわちヒューマンワークが行う典型的な動きおよびワークが体験する注意力または疲労のレベルを判断することを含む。ヒューマンワークの

50

状態に左右または影響される個人化されたタスク実行モデルを学習することが、多くの利点を有することが分かった。実験から見いだされた第1の認識は、タスク実行およびヒューマンワーカーの状態における変化および異常を認識することにより、従来の方法と比較して、人間-ロボット製造プロセスにおいてはるかに早く異常を検出できるということである。すなわち、タスク実行およびワーカーのヒューマンヘルスは、迫り来る製造プロセス異常の早期警告を提供することができる。第2の認識は、ヒューマンワーカーの典型的なパフォーマンスおよび状態を理解することが、この情報自体をロボットと人間との間のコラボレーションに使用することができて、組み合わせられた人間/ロボットパフォーマンスを向上させることができることを意味するという認識を含んでいた。これらの進歩は、ロボットとヒューマンワーカーとのインタラクションの最適化に由来する。一例として、閾値アプローチに基づいてヒューマンワーカーのパフォーマンスレベルまたはワーカーの健康状態のいずれかにおいて異常が検出され得る場合、人間がタスクを完了することをロボットが支援する組立ライン環境では、ヒューマンワーカーの異常を早期に検出することにより、このヒューマンワーカーの異常を吸収するためにロボットアクションを変更するようにロボットに警告することができる。たとえば、ロボットは、疲れているヒューマンワーカーのアクションと一致するようにそのアクションを減速させることができる。ロボットアクションの代替例は、さらなるタスクを実行すること、手助けを求めて監督者を呼ぶこと、（さらなる時間を費やして）ヒューマンワーカーに近いパーツをつかむこと、照明、冷暖房などを追加することによって隣接エリアの快適さを向上させることなどを含み得る。この中の全ては、ワーカーの状態を条件としてロボットがヒューマンワーカーに提供している手助けを調整することによってプロセスを人間-ロボットコラボレーションレベルで最適化するようにプロセス制御システムを設計できることを意味する。また、プロセス制御システムは、人間/ロボットシステムの全体論的内容を知っており、製造プロセス全体において異常を検出することもでき、これは、製造プロセス全体の速度および製造された製品の品質の最適化をもたらすことができる。

【0009】

しかし、このような認識を得ることは、人間がロボットのそばで作業して、ロボットができないタスクを人間が行わなければならない従来の現代的協働製造プロセスのうちのいくつかを最初によりよく理解する必要があった。たとえば、速度および品質は、従来の現代的製造プロセスにとって不可欠である。しかし、従来の製造プロセスは、複数の並行プロセスで構成されており、その各々が個別のステップのシーケンスであるので、最適な速度および品質を実現するためのモニタリングは困難である。この問題は、ヒューマンワーカーがロボットヘルパのそばでタスクを実行する場合にはさらに複雑になる。なぜなら、ヒューマンワーカーは、精神的および身体的状態に左右される可変のパフォーマンスを有するからである。

【0010】

人間-ロボット混在製造プロセスにおいて個別のイベントシーケンスを使用して従来の製造プロセスを特徴付けることの当初の問題は、精神的および身体的状態に左右されるヒューマンワーカーの可変のパフォーマンスをどのように特徴付けるかであった。第1の実験アプローチは、人間-ロボット製造プロセスがヒューマンワーカーを考慮に入れることなくもっぱらロボットによって実行されるという想定を含んでいた。これは、組立ライン上の動作のシーケンスのみを観察することによりプロセスの全内容を学習できることを意味していた。しかし、ヒューマンワーカーがプロセスに追加されると、プロセスを特徴付けることの問題は、はるかに難しくなった。これは、ヒューマンワーカーのスキル、生理的状态および心理的状态がさまざまであると考えられるからである。さらに、ヒューマンパフォーマンスは、これらの要因の相互作用によって、日ごとに予測不可能に変化し得る。

【0011】

ロボットを用いて操作タスクを学習することの当初の問題は、人間から独立して実行されるロボットタスクであった。この状況において、ロボットによって起こされるアクションのシーケンスは固定されており、製品品質および製造速度を最大化するように調整可能

10

20

30

40

50

である。しかし、この状況は限定される。なぜなら、ロボットの器用さは、依然として人間の器用さをはるかに下回っており、そのため、ロボットが対処できるタスクの範囲が限定されるからである。これにより、多くの人間－ロボット製造プロセスにおいて人間との協働作業が必要になる。ロボットが人間のそばで作業する場合、上記の人間の制約は、新たなレベルの不確実性をこの問題に追加することになる。具体的には、ロボットによって起こされるアクションを機械的に最適化することはもはや不可能である。なぜなら、その環境における少なくとも1つの変数が、動的に（時には製品ごとに）異なるからである。したがって、人間とロボットとの協働チームは、人間の相当な変動性に悩まされることになる、これは、製品品質および組立プロセス全体の速度に影響を及ぼす。

【0012】

さらなる実験は、製造プロセスをセットアップすることを含み、プロセスは協働的であるように取り決められ、人間がロボットのそばで作業して、ロボットができないタスクを行う必要があった。発見されたいくつかの局面は、これにより、製造プロセス全体に沿って速度を最適化すること、および、人間とロボットとの間のインタラクションを最適化して製品の速度および品質を最適化することという2つの要素からなる問題が発生するというものであった。人間－ロボット混在組立プロセスを用いて実験することから学習されたいくつかの局面は、プロセスの個別の異常モデル、人間の行動のモデル、およびロボット操作のモデルを別々に学習することが不十分であるというものであった。ここでの認識は、これらの要素を利用してプロセスの速度および製品の品質を協働して最適化するようにシステムを設計しなければならないというものである。

【0013】

したがって、人間の行動を学習して、人間によって行われる作業の正確な方法を学習することは、プロセス制御システムを設計する際の重要な要素である。ヒューマンワーカーの作業の方法を学習するために、ワーカーは、進行中の作業プロセスについての情報を収集するセンサ（以下に記載）を装備しなければならない。また、ヒューマンワーカーから収集された情報（たとえば、腕の動き）は、タスクラベル（組立、検査、塗装、縫製など）、予想タスク期間（典型的な期間、指定された期間など）およびヒューマンワーカースキルレベル（雇用年数で表すことができる）などのタスク情報を収集することによって、プロセス制御システム内の情報によって強化することができる。これらの特徴は、一緒に訓練データベースに記録されて、ヒューマンパフォーマンスのモデルの学習に使用することができる。

【0014】

本開示のいくつかの実施形態は、ヒューマンワーカーパフォーマンスの説明を統計モデルに取り込む機械学習方法を介してヒューマンパフォーマンスを学習することができる。ここでは、2つのタイプのモデル、すなわち予測モデルおよび分類モデルを利用してもよい。予測モデルは、予想完了時刻を学習するのに使用することができ、ヒューマンワーカーがどのようにタスクを実行しているかを示す、センサデータに見られるパターンを効果的に取り込む。分類モデルは、ヒューマンワーカーの状態（たとえば、元気である、疲れている、緩慢であるなど）または実行されるタスク（組立、検査、塗装、縫製など）を学習するのに使用することができる。

【0015】

本開示のいくつかの実施形態は、異常検出テーブルおよび予測タスク完了時刻を作成することによって予測モデルおよび分類モデルから得られる知識を要約している。たとえば、複数の並行プロセスが実行されているとき、これらのテーブルは、人間－ロボット製造プロセスにおける想定されるシーケンスの範囲を説明するタイミング情報を取り込む。この情報は、人間－ロボット製造プロセスを説明する特徴付け情報である。一定の実行時間中、これらのテーブルは、我々が人間－ロボット製造プロセスにおいて通常イベントのシーケンスを生成することを可能にする。重要なことに、イベントのシーケンスは、決定論的であり、各イベントは、単一の先行するイベントのあとに続く。しかし、1つまたは複数のイベントが可変である場合、複数のイベントが任意の単一のイベントのあとに続き得

10

20

30

40

50

る。したがって、これらの異常検出テーブルおよび予測タスク完了時刻を使用することにより、プロセスで発生するであろう異常を予想することが可能になる。これは、将来のイベントのシーケンスが異常検出テーブルにおける有効なシーケンスと一致しない場合に起こる。

【0016】

ヒューマンワーカによる当座の問題の検出は、分類アルゴリズムを使用して完了することができる。分類アルゴリズムは、ヒューマンワーカによって実行されている現在のタスクおよび次のワーカタスクを決定することができる。予測されたタスクおよびアクションは、予め訓練されてメモリに格納された制御システムからの予想タスクおよびアクションと比較され得て、ヒューマンワーカの状態について決定が下され得る。ここでは、ヒューマンワーカパフォーマンスを向上させるために、異常アラームが与えられるか、またはロボットヘルパのアクションが変更され得る。次いで、ロボットは、ヒューマンパフォーマンスのレベルを考慮して正しい挙動の例を提供されることによってその挙動を変更することを学習し得る。後述するように、これらの例は、学習手順中に明確に提供または発見され得る。

【0017】

本開示のシステムおよび方法を開発する別の局面は、ロボット学習をヒューマンパフォーマンスモニタリングと組み合わせることを含んでいた。実験は、人間-ロボット製造プロセス中のロボットと人間との間のインタラクションをよりよく理解することを含んでいた。少なくとも1つの認識は、ロボットと人間オペレータとの間の進行中のインタラクションを推論して対応することができる統計モデル（機械学習）を使用してこのインタラクションを学習するというものであった。これらのモデルを学習するために、ロボットの内蔵センサから、およびカメラのような外部センサから、データが収集された。外部センサは、非限定的な例として、ヒューマンコラボレータの特徴付けを学習するために以前に使用されたセンサと同一のセンサであり得る。次いで、学習済みモデルを使用して、固有の身体的状態（元気である、疲れている、緩慢であるなど）にあるヒューマンコラボレータと相互作用することができるロボットの制御方法を決定することができる。重要なことに、このコラボレーションは、人間-ロボット製造タスクを完了して製品品質を最大化する目的で学習される。

【0018】

本開示の一実施形態に従って、人間-ロボット混在プロセスにおいてタスクのシーケンスの中のタスクの実行時に異常を検出するためのプロセス制御システムである。上記プロセス制御システムは、ロボットデータ、製造プロセス（MP）データ、ヒューマンデータおよび実行可能なモデルを含むデータを格納するように構成されたメモリと、センサから取得されたヒューマンワーカ（HW）信号およびロボット動作信号を受信するように構成された入力インターフェイスと、ハードウェアプロセッサとを含み、上記ハードウェアプロセッサは、上記HW信号から、タスク完了時刻と、上記HWの状態および予測された次の順番のタスクに関連する測定値と、ヒューマンパフォーマンス（HP）モデルへの入力とを抽出するように構成され、上記HPモデルは、上記HWの上記状態の事前に学習された境界に基づいて上記HWの上記状態を判断し、上記HWの上記状態は、異常または異常無しの分類を決定するために人間-ロボットインタラクション（HRI）モデルに入力され、上記ハードウェアプロセッサはさらに、上記HRIモデルを上記ロボット動作信号、上記HW信号および上記分類された異常で更新するように構成され、上記更新されたHRIモデルおよび上記分類された異常を使用して、上記HWと相互作用するロボットの制御アクションまたは異常アラームのタイプを決定するように構成され、上記プロセス制御システムはさらに、上記更新されたHRIモデルおよび上記分類された異常に基づいて、ロボットアクションを変更するために上記ロボットの上記制御アクションを出力するか、または上記異常アラームの上記タイプを上記人間-ロボット混在プロセスの管理システムに出力するための出力インターフェイスを含む。

【0019】

本開示の一実施形態に従って、人間－ロボット混在プロセスにおいてタスクのシーケンスの中のタスクの実行時に異常を検出するためのプロセス制御方法である。上記プロセス制御方法は、センサからヒューマンワーカ（HW）信号およびロボット動作信号を得るステップと、上記HW信号から、タスク完了時刻と、上記HWの状態および次の順番のタスクに関連する測定値と、ヒューマンパフォーマンス（HP）モデルへの入力とを抽出して、上記HWの上記状態の事前に学習された境界に基づいて上記HWの状態を取得するステップとを含み得て、次いで、上記HWの上記状態は、異常または異常無しの分類を決定するために人間－ロボットインタラクション（HRI）モデルに入力され、上記方法はさらに、上記HRIモデルを上記ロボット動作信号、上記HW信号および上記分類された異常で更新し、次いで、上記更新されたHRIモデルおよび上記分類された異常を使用して、上記HWと相互作用するロボットの制御アクションまたは異常アラームのタイプを決定するステップと、上記更新されたHRIモデルおよび上記分類された異常に基づいて、ロボットアクションを変更するために上記ロボットの上記制御アクションを出力するか、または上記異常アラームの上記タイプを上記人間－ロボット混在プロセスの管理システムに出力するステップとを含み得て、上記ステップは、メモリに接続されたハードウェアプロセッサによって実行される。

10

【0020】

本開示の一実施形態に従って、プロセス制御方法を実行するためのコンピュータによって実行可能なプログラムが組み込まれた非一時的なコンピュータ読取可能記憶媒体である。上記プロセス制御方法は、人間－ロボット混在プロセスにおいてタスクのシーケンスの中のタスクの実行時に異常を検出するためのものである。上記プロセス制御方法は、センサからヒューマンワーカ（HW）信号およびロボット動作信号を得るステップと、上記HW信号から、タスク完了時刻と、上記HWの状態および次の順番のタスクに関連する測定値と、ヒューマンパフォーマンス（HP）モデルへの入力とを抽出して、上記HWの上記状態の事前に学習された境界に基づいて上記HWパフォーマンスの状態を取得するステップとを含み得て、次いで、上記HWパフォーマンスの上記状態は、異常または異常無しの分類を決定するために人間－ロボットインタラクション（HRI）モデルに入力され、上記方法はさらに、上記HRIモデルを上記ロボット動作信号、上記HW信号および上記分類された異常で更新し、次いで、上記更新されたHRIモデルおよび上記分類された異常を使用して、上記HWと相互作用するロボットの制御アクションまたは異常アラームのタイプを決定するステップと、上記更新されたHRIモデルおよび上記分類された異常に基づいて、ロボットアクションを変更するために上記ロボットの上記制御アクションを出力するか、または上記異常アラームの上記タイプを上記人間－ロボット混在プロセスの管理システムに出力するステップとを含み得て、上記プロセス制御方法の上記ステップは、メモリに接続されたハードウェアプロセッサを使用して実行される。

20

30

【0021】

ここに開示されている実施形態について、添付の図面を参照してさらに説明する。示されている図面は、必ずしも一定の縮尺に応じておらず、その代わりに、全体として、ここに開示されている実施形態の原理を例示することに強調が置かれている。

【図面の簡単な説明】

40

【0022】

【図1A】本開示の一実施形態に係る方法を示すブロック図である。

【図1B】本開示のいくつかの実施形態に係る、図1Aの方法を実行するために使用されるいくつかの構成要素を示す概略図である。

【図1C】本開示のいくつかの実施形態に係る、少なくとも1つのタスクと一緒に完了する、人間－ロボット製造プロセスの組立ラインにおけるロボットシステムおよびヒューマンワーカを示す概略図である。

【図2A】本開示のいくつかの実施形態に係る、訓練データベースに格納される訓練データを取得して、訓練データの収集後に現在のヒューマンワーカデータを取得するための、ヒューマンワーカに関連付けられたセンサからのデータ収集を示す概略図である。

50

【図 2 B】本開示のいくつかの実施形態に係る、ヒューマンワークパフォーマンスタスクをモニタリングするセンサからのデータ収集を示す概略図である。

【図 2 C】本開示のいくつかの実施形態に係る、ヒューマンワークパフォーマンスのモデルのいくつかの学習プロセスステップ、およびそれに続く、ヒューマンワークパフォーマンスのモデルに対するプロセス較正を示すブロック図である。

【図 3 A】本開示のいくつかの実施形態に係る、ヒューマンワークパフォーマンスのモデルのいくつかのプロセスステップ、およびそれに続く、ヒューマンワークパフォーマンスのモデルの利用を示すブロック図である。

【図 3 B】本開示のいくつかの実施形態に係る、図 3 A のヒューマンワークパフォーマンスのモデルのいくつかの学習プロセスステップ、およびそれに続く、図 3 A のヒューマンワークパフォーマンスのモデルを利用するためのいくつかのプロセスステップを示すブロック図である。

【図 4 A】本開示のいくつかの実施形態に係る、ロボットシステムに接続されたロボットモデル学習プログラム（たとえば、導関数フリーセミパラメトリックガウス過程（Semi-parametric Gaussian Process：SPGP））学習モデルを含むロボット学習制御装置を示す概略図である。

【図 4 B】本開示のいくつかの実施形態に係る、予め定められた期間中にロボットシステムの学習プロセスを開始するためにロボットポリシーを起動するロボットモデル学習プログラム、すなわち図 4 A の導関数フリーセミパラメトリックガウス過程（SPGP）学習モデルを説明するフローチャートを示すブロック図である。

【図 5 A】本開示のいくつかの実施形態に係る、人間－ロボット製造プロセス中のロボットと人間との間のインタラクションを示す概略図である。

【図 5 B】本開示のいくつかの実施形態に係る、ヒューマンモデルとロボットモデルとを組み合わせる人間－ロボット協働インタラクションモデルにすることを示すブロック図である。

【図 5 C】本開示のいくつかの実施形態に係る、ヒューマンワークから収集されたデータを使用してヒューマンモデルを訓練することを含む、ヒューマンモデルとロボットモデルとを組み合わせる人間－ロボット協働インタラクションモデルにすることを示すブロック図である。

【図 5 D】人間およびロボットの両方について個々のモデルを学習し、次いでロボットポリシーを向上させるために使用される人間－ロボット協働インタラクションモデルを学習し、最終的にこのロボットポリシーは動作中に使用できることを示すブロック図である。

【図 6】本開示のいくつかの実施形態に係る、収集可能であって、プロセス制御システムが異常を検出することを支援するのに使用可能な、バイオメトリックデータおよび他のデータを含むセンシングデータを示すブロック図である。

【図 7】本開示のいくつかの実施形態に係るリストデバイスを示す概略図である。

【発明を実施するための形態】

【0023】

上記の図面は、ここに開示されている実施形態を説明するが、本明細書に記載されているように他の実施形態も考えられる。本開示は、限定としてではなく代表として例示的な実施形態を示している。多数の他の変形例および実施形態を当業者が考案することができ、これらの変形例および実施形態は、ここに開示されている実施形態の原理の範囲および精神の範囲内である。

実施形態の説明

【0024】

本開示は、一般にモデル学習技術のシステムおよび方法に関し、より具体的には人間－ロボット協働製造プロセスのためのモデル学習技術のシステムおよび設計に関する。

【0025】

図 1 A は、本開示の一実施形態に係る方法のブロック図であり、この方法は、人間－ロボット混在プロセスにおいてタスクのシーケンスの中のタスクの実行時に異常を検出する

10

20

30

40

50

ためのプロセス制御方法を含む。ステップのうちのいくつかは、

【0026】

センサからヒューマンワーカ（HW）信号およびロボット動作信号を得る図1Aのステップ15Aを含む。

【0027】

図1Aのステップ20Aは、HW信号から、タスク完了時刻と、HWの状態および次の順番のタスクに関連する測定値と、ヒューマンパフォーマンス（HP）モデルへの入力とを抽出して、HWの状態の事前に学習された境界に基づいてHWの状態を取得するステップを含み、次いで、HWの状態は、異常または異常無しの分類を決定するために人間-ロボットインタラクション（HRI）モデルに入力される。

【0028】

HWのためのHPモデルは、ヒューマンデータにおける一組の境界に対応するHWパフォーマンスのさまざまな状態を学習済みであるように事前に構成され得ると考えられる。HRIモデルは、HWのさまざまな状態と最適なロボットアクションとの間のマッピングを学習済みであるように事前に構成される。さらに、HPモデルは、HW信号を受信する前に、訓練フェーズ中に、完了した訓練タスクのHW訓練信号から構築され得て、訓練信号は、完了した訓練タスクの各々の完了した訓練タスクについてデータを含み、このデータは、訓練タスク名、各々の完了した訓練タスクについてのHWの複数の訓練状態、および次の順番の訓練タスクを含む。HW訓練信号は、HW信号を得る前に、訓練動作中に、HWに関連付けられたセンサから得られ得て、HW信号は、人間-ロボット混在プロセスの動作中に、HWに関連付けられたセンサから得られる。

【0029】

依然として図1Aのステップ20Aを参照して、HPモデルは、ヒューマンタスク実行（HTE）モデルおよびHWの状態のモデルによって構築され得て、HTEモデルは、訓練タスクのシーケンスを完了しながら訓練フェーズ中に取得されたHW訓練信号を使用して訓練された少なくとも1つの予測モデルを使用して構築され、HWの状態のモデルは、HW訓練信号を使用して訓練された少なくとも1つの分類モデルを使用して構築され、各々の完了した訓練タスクは、HWの複数の状態に関連付けられて、メモリに格納される。また、HTEモデルは、各々の完了したタスクについて予想完了時刻を学習して、センサから取得されたセンサデータに見られるHWの動きのパターンを識別するまたは取り込むように構成され得て、少なくとも1つの統計モデル学習アプローチは、1つまたは複数の予測モデル、1つまたは複数の分類モデル、またはそれら両方を含み、HWが少なくとも1つのタスクを完了するにあたりロボットとインタラクティブに作業している間に、HWのセンサ測定値を考慮して進行中のタスクの完了時刻の推定値を生成することができる。

【0030】

さらに、少なくとも1つの分類モデルは、完了したタスクおよび次の順番のタスクを最初に判断することによってHW信号からHWの状態を学習するように構成され、次いで視線検出アルゴリズムを使用してHWの状態を判断し、HWの状態は、焦点レベルの量およびタスクを完了するときのHWのエネルギーレベルの量などである。

【0031】

依然として図1Aのステップ20Aを参照して、HTEモデルのHW訓練信号は、各々の完了した訓練タスクについて訓練タスクを識別するなどのタスクに関連付けられた訓練データを含み、各々の完了した訓練タスクについて、（1）HWの状態に対応する予想タスク完了期間のスケールを含み、予想タスク完了期間のスケールは、スケールの最低部における最高HWパフォーマンス予想タスク完了期間からスケールの最高部における最低HWパフォーマンス予想タスク完了期間までであり、（2）予想タスク完了期間のスケールを期間閾値のタイプに関連付けることを含み、（3）各々の完了した訓練タスクについてのHWデータを含み、HWデータは、完了した訓練タスクの時点でのHWのデータを含み、HWのデータは、年齢、技術教育のレベル、高等教育のレベル、タスクを完了するスキルのレベル、雇用年数、身長、体重、精神的キャパシティのレベル、身体障害を含む身体

10

20

30

40

50

的キャパシティのレベルなどであると考えられる。さらに別の局面は、HW訓練信号が、慣性測定センサ、生物学的センサ、人体搭載モーションセンサ、HWがタスクを完了している環境における外部モニタ、訓練タスクの各訓練タスクを完了することに関連付けられた時刻情報、および視線検出器などの外部モーションセンサなどのセンサから取得された訓練データを含む、というものであってもよい。

【0032】

図1Aのステップ25Aは、HRIモデルをロボット動作信号、HW信号および分類された異常で更新し、次いで、更新されたHRIモデルおよび分類された異常を使用して、HWと相互作用するロボットの制御アクションまたは異常アラームのタイプを決定するステップを含む。

10

【0033】

図1Aのステップ30Aは、更新されたHRIモデルおよび分類された異常に基づいて、ロボットアクションを変更するためにロボットの制御アクションを出力するか、または異常アラームのタイプを人間-ロボット混在プロセスの管理システムに出力するステップを含み、これらのステップは、メモリに接続されたハードウェアプロセッサによって実行される。

【0034】

制御アクションは、ヒューマンワーカーの状態に従ってロボット速度の量を調整すること、または、X軸方向、Y軸方向およびZ軸方向のうちの1つもしくはそれらの組み合わせを含むロボットの方向を調整することを含み得ると考えられる。また、制御アクションに従ったロボット動作の変化を示すなどの可聴音声コマンドを起動する。他の制御アクションは、ロボットのメンテナンス関連アクション、人間およびロボットの両方に対する安全性関連アクション、ならびにロボットの診断関連アクションを含み得ると考えられる。

20

【0035】

異常アラームのタイプは、重要度、優先度、安全性、メンテナンスなどのレベルに基づく複数の異常アラームのスケーリングのタイプであり得て、これらのレベルは、製造プロセスに関連するユーザ、オペレータまたは管理者によって予め定められ、すなわちユーザによって指定された特定のアプリケーションに基づいて詳細を予め定めることができる。たとえば、これらのレベルは、アクションを必要としないゼロなどの最小レベルから、即座のアクションを必要とする最大レベルまでであり得る。最小レベルから最大レベルまでのスケールを有する異常アラームのタイプのいくつかの例としては、非限定的な例として、(a) ヒューマンワーカー、すなわちワーカーの健康、動作または環境問題に関連付けられた安全性異常アラーム、(b) ロボット、すなわちメンテナンス、動作不良、電子的またはソフトウェア問題、動作問題に関連付けられた安全性異常アラームなどを挙げることができる。最小レベルから最大レベルまでのスケールを有する他のタイプの異常アラームは、疑わしい組立ライン機械的故障、疑わしい組立ラインへの材料供給問題、ヒューマンワーカーに起因する生産不足問題、疑わしいロボット関連問題、オペレータ関連タスクまたは疑わしい電子的故障を含み得る。また、メンテナンス部門、オペレータ、管理タイプグループなどのために予め取り決められたグループ関連異常アラームも考えられる。

30

【0036】

本開示のいくつかの実施形態によれば、本開示のシステムおよび方法のいくつかの利点は、製造プロセス全体に沿って速度を最適化し、人間とロボットとの間のインタラクションを最適化して速度および製品の品質を最適化することによって、従来の人間-ロボットコラボレーションプロセスの問題を克服する。これは、製造プロセス全体において異常を検出することができるとともに、ワーカーの状態を条件としてロボットがヒューマンワーカーに提供している手助けを調整することによって人間-ロボットコラボレーションレベルでプロセスを最適化することによって実現することができる。

40

【0037】

図1Bは、本開示のいくつかの実施形態に係る、図1Aの方法を実行するために使用されるいくつかの構成要素を示す概略図である。たとえば、図1Bは、組み合わせられた口

50

ボットー人間モデルの実施形態を実現するために使用することができる。

【0038】

図1Bは、バス55を介してロボットシステム58を制御するのに使用することができるプロセス制御システム100を含み、プロセス制御システム100は、バス56を介してネットワーク57に接続するように適合されたネットワークインターフェイスコントローラ(NIC)51を含み得て、ロボットシステム58、すなわち複数のロボットシステム、ヒューマンワーカーをモニタリングするのに使用される入力測定値などの入力測定値を含むヒューマンセンサモニタシステムデータ59、ならびに他の想定されるデータおよび他の入力データ61との間でデータをやりとりすることができる。メモリ140は、コンピュータによって実行可能なプログラムをストレージ130に格納するのに使用することができ、ストレージ130は、データ前処理プログラム131と、ヒューマンモデルおよびロボットモデルのための統計モデル学習プログラム134と、統計モデルに基づく制御プログラム135と、統計モデルの学習を初期化するための初期化プログラム137とを含み、メモリ140と接続したプロセッサ120(または、2つ以上のプロセッサ)がある。物体状態履歴データ(図示せず)およびロボット状態履歴データ(図示せず)もストレージ130に格納されている。入力/出力インターフェイス80、バス83を介してデバイス84に接続された制御インターフェイス82を含む構成要素が存在し得る。

【0039】

プロセス制御システムのいくつかの任意の構成要素としては、バス61を介してキーボード62に接続され、バス63を介してポインティングデバイス/メディア64に接続されたヒューマンマシンインターフェイス(HMI)60を挙げることができる。他の任意の構成要素としては、バス73を介してディスプレイデバイス67に接続されたディスプレイインターフェイス66と、バス74を介してイメージングデバイス69に接続されたイメージングインターフェイス68と、バス75を介して印刷デバイス72に接続されたプリンタインターフェイス71とを挙げることができる。

【0040】

図1Cは、本開示の実施形態に係る、少なくとも1つのタスクと一緒に完了する、人間ーロボット製造プロセスの組立ラインにおけるロボットシステムおよびヒューマンワーカーを示す概略図である。ヒューマンパフォーマンスのモデル、ロボット学習プロセスおよび他のプロセスについては、後述の図面において詳細に説明する。組立ラインは、複数のステーションを含み、各ステーションにおいて、少なくとも1つのロボットによって完了される少なくとも1つのタスクを含み、少なくとも1つのロボットは、少なくとも1人のヒューマンワーカーが少なくとも1つのタスクを完了することを支援すると考えられる。

【0041】

ロボットシステム90は、コントローラ91と、ロボット状態検出器(たとえば、位置エンコーダ93)とを含み、位置エンコーダ93は、ロボット状態信号92を生成することができる。ロボットシステム90は、物体状態検出器(たとえば、カメラ94)も含み得て、カメラ94は、作業空間または作業台11のコンベヤ12においてロボットシステム90によって操作される物体95の物体状態信号を生成することができる。ロボットシステム90は、少なくとも1人のヒューマンワーカー13が作業台11上で少なくとも1つのタスクを完了することを支援し、そのため、作業空間またはコンベヤは、ロボットおよびヒューマンワーカーのいずれかがタスクを完了することを支援するために順方向および逆方向に移動することができる。なお、これらの構成要素11~12および90~94は、ここでは一例として示されているが、本開示の実施形態はさまざまな適用例に対してロバストであるため、適用例によって異なってもよい。また、ロボット動作データは、任意に、ユーザに特有の関心によっては、ロボット学習プロセス101にワイヤレスで送受信され得る。

【0042】

依然として図1Cを参照して、ヒューマンワーカー13は、データを収集するためのセンサを有し得て、これらのセンサは、リストデバイス104、モーションモニタ102、オ

10

20

30

40

50

ンボディモーションセンサ 106A, 106B、時刻デバイス 108 および環境センサ 109 を含む。これらのデバイスからのデータは、ヒューマンワークに特有のモデルのための学習プロセスを容易にする。これらのセンサは、まとめて人間状態検出器の一例である。ロボットの制御ポリシーを学習するために、人間の状態は、操作対象の物体 95 の状態およびロボットシステム 90 の状態とともに考慮に入れられる。

【0043】

図 2A は、本開示の実施形態に係る、訓練データベース 203 に格納される訓練データを取得して、訓練データの収集後に現在のヒューマンワークデータ 201 を取得するための、ヒューマンワークに関連付けられたセンサからのデータ収集を示す概略図である。たとえば、ヒューマンワーク 213 は、ワーク 213 に取り付けられるかまたは埋め込まれたセンサ（リストデバイス 204 または他の人体センサなど）を有し得て、体温、血圧、心拍数／脈拍、呼吸率、O₂ 飽和度、皮膚伝導および皮膚温度などのデータを収集することができる。

【0044】

他のセンサ（モーションモニタ 202、オンボディモーションセンサ 206A, 206B など）は、行動的識別子（物理的な動き、関与パターン、物理的な動きなど）および身体的識別子（写真および映像、生理学的認識、音声、および身体属性など）などのバイOMETリックデータを収集することができる。また、他のセンサは、時刻デバイス 208 を介してタイムスタンプデータを収集することができ、環境センサ 207 から環境データを収集することができ、このようなデータは、気温、気流速度、湿度、大気質および放射温度を含み得る。

【0045】

図 2B は、本開示の実施形態に係る、ワークパフォーマンスタスクをモニタリングするセンサ 211 からのデータ収集を示す概略図である。収集されたデータは、ワークの典型的な状態とともにヒューマンワークの通常のまたは典型的な動作方法を学習するのに使用することができる。収集されたデータの一部は、ワークパフォーマンスタスクをモニタリングするセンサからのものであり、これらのセンサは、視線検出器を使用するなどしてモーションをモニタリングするのに使用することができる外部センサ 217、バイOMETリックデータ 215、環境センサ 207、タイムスタンプ 208 およびオンボディモーションセンサ 206A, 206B を含み得る。また、ワークパフォーマンスタスクデータ 220 は、履歴タスクプロセス情報（図 1B のメモリ 140 に事前に格納されたタスク情報 222 など）を含む。プロセス制御システムのために収集されるデータは、非限定的な例として、タスクラベリング（組立、検査、塗装、縫製など）、予想タスク期間（典型的な期間、指定された期間など）およびワークスキルレベル（雇用年数で表すことができる）であり得る。

【0046】

環境データセンシングは、I/O モジュール（ワイヤレス通信コンポーネントもしくはオンデバイスユーザインターフェイスを含み得る）、データプロセッサもしくは制御モジュール、電源（リムーバブルもしくは充電式バッテリーであり得る）、またはワイヤレス電力変換装置を含み得る。環境データセンシングは、環境のさまざまな特徴（気温、気流速度、湿度、大気質 328 および／または放射温度など）を測定する 1 つまたは複数のセンサを含み得る。さらに、乱気流および CO₂ センサなどであるがこれらに限定されないセンサが環境データセンシングに含まれる。1 つまたは複数のセンサは、ワークの近傍に位置している。別個のアイテムとして示されているが、環境データセンシングの単一のセンサが 2 つ以上の変数を測定してもよいということが考えられる。たとえば、気流速度および乱気流強さの測定に全方向性風速計を使用してもよい。別の例では、放射温度は、IR カメラからのデータに基づいて、または球温度計などの別個のセンサを使用して、求められてもよい。いくつかの実施形態において、環境データは、環境のモデルと、環境のモデルの変数の分布とを含み得る。環境のモデルは、窓の場所、ならびに、ドアおよび壁の場所を含み、環境のモデルの変数は、これらの窓およびドアが開いているか閉まっているか

を示す。さらに、環境のモデルは、環境内の熱源（コンピュータ、オーブン、ワーカなど）の場所およびタイプを含み、環境のモデルの変数は、熱源の状態を示す。

【0047】

HTEモデルのヒューマンワーカ訓練信号のいくつかの局面は、タスクラベリング（各々の完了した訓練タスクについて訓練タスク名またはラベルを識別することなど）に関連付けられた訓練データを含み得て、各々の完了した訓練タスク名またはラベルについて、情報を含み得て、この情報は、（１）ヒューマンワーカの状態に対応する予想タスク完了期間のスケールを含み、予想タスク完了期間のスケールは、スケールの最低部における最高ヒューマンワーカパフォーマンス予想タスク完了期間からスケールの最高部における最低ヒューマンワーカパフォーマンス予想タスク完了期間までであり、（２）予想タスク完了期間のスケールを期間閾値のタイプに関連付けることを含み、（３）各々の完了した訓練タスクラベルについてのヒューマンワーカデータを含み、ヒューマンワーカデータは、完了した訓練タスクの時点でのヒューマンワーカのデータを含み、ヒューマンワーカのデータは、年齢、技術教育のレベル、高等教育のレベル、タスクを完了するスキルのレベル、雇用年数、身長、体重、精神的キャパシティのレベル、身体障害を含む身体的キャパシティのレベルなどである。

10

【0048】

図2Cは、本開示の実施形態に係る、ヒューマンワーカパフォーマンスのモデル280のいくつかの学習プロセスステップ、およびそれに続く、ヒューマンワーカパフォーマンスのモデルの利用を示すブロック図である。ヒューマンワーカパフォーマンスのモデル280は、ワーカパフォーマンスの説明を統計モデルに取り込む機械学習方法を介して学習される。2つのタイプのモデル、すなわち（１）予測モデルおよび（２）分類モデルを使用することができる。

20

【0049】

図2Cのステップ1は、図2Bに示されるアプローチを使用して収集された訓練データベース203にアクセスすることによってヒューマンワーカパフォーマンスのモデル280を学習するための学習プロセスステップであり得る。訓練データベース203は、ヒューマンワーカパフォーマンスのモデル280の予測モデルおよび分類モデルの両方のモデルを学習するのに使用することができる。

30

【0050】

【数1】

40

50

予測モデルは、一連のタスクの中のさまざまなサブタスクの予想完了時刻を学習するために人間によって実行される動作方法を、訓練データベース 203 の中の訓練データを介して効果的に学習し、ワーカがどのように一連のタスクの中のタスクを実行するかを示す、センサデータに見られるパターンを効果的に取り込むのに使用することができる。予測モデルは、履歴（過去の）ワーカデータ（すなわち、現在のワーカデータを収集する前に収集される）を使用して訓練され得る。しかし、評価対象のワーカと同様の特徴を有する他のワーカについてこのような訓練データが収集されてもよいということが考えられる。他のワーカの同様の特徴のいくつかの局面は、ワーカについて取得された全てのデータを含み得て、このデータは、非限定的な例として、経験年数、年齢、教育、身体的特徴、健康状態評価などを含む。収集されるタスク情報は、タスクラベル（組立、検査、塗装、縫製など）、予想タスク期間（典型的な期間、指定された期間など）およびワカスキルレベル（雇用年数で表すことができる）を含み得る。これらの特徴は、一緒に訓練データベース 203 に記録されて、ヒューマンパフォーマンスのモデルを学習することを支援するのに使用される。予測アルゴリズムには多くのタイプがある。分かりやすくするために、線形回帰予測モデルについて説明する。線形回帰モデルは、出力と入力との間の線形の従属関係を想定しており、リグレッサとも呼ばれる入力は、一組のパラメータを乗算され、次いで合計されて、出力を推定する。一例として、1つの多次元リグレッサ点 $X = [x_1, x_2, x_3, \dots, x_N]$ を収集したとする。式中、各 x_i ($\{i = 1, \dots, N\}$) は、上記の変数（ワーカの心拍数、 x 、 y または z 方向のワーカの動き、室温など）のうちの1つを表す。次いで、機械学習またはシステム識別技術を介して一組のパラメータ $A = [a_1, a_2, \dots, a_N]$ を推定して、現在のタスクの完了時刻 t_c を予測したとする。この場合、完了時刻は、 $f(X)$ として予測することができ、 $f(X)$ は、 $\hat{t}_c = \hat{f}(X) = a_1x_1 + a_2x_2 + \dots + a_Nx_N$ として求められる。

【0051】

依然として図 2 C のステップ 1 を参照して、訓練データベース 203 に格納された訓練済み予測モデルは、異常検出を支援するのに使用され得るパフォーマンスのレベルに関連する閾値を作成するために、一連のタスクの中のさまざまなタスクについての予想完了時刻のレベルと、ワーカがどのように一連のタスクの中のタスクを実行するかのパターンとを含み得る。

【0052】

分類モデルは、人間によって行われる作業のスタイルを学習するのに使用することができる。分類モデル、すなわちアルゴリズムは、ワーカによって実行されている現在のタスクおよび次のワーカタスクを、訓練データベース 203 に格納された訓練データから決定することができる。このようなアルゴリズムの例としては、ユーザが進行中のタスクに集中しているか否かを判断することができるワーカ視線検出アルゴリズムが挙げられる。例示的な視線検出アルゴリズムは、タスクの完了中にワーカの視線の位置の分布（ x 、 y 座標）を学習する。この分布は、各々の特定のタスクについて固有であると想定される。次いで、既知のタスクについて、ワーカの視線がこの分布に入力されて、特定のタスクに帰属している確率が割り当てられ得る。確率が低い場合、ワーカは、疲れている、注意散漫である、または単に休憩しているであろう。

【0053】

依然として図 2 C のステップ 1 を参照して、ワーカパフォーマンスを追跡する他の方法は、慣性測定センサ、生物学的センサ、環境における外部モニタ、時刻情報、外部モーションセンサ（視線検出器など）からの測定値を使用して構築することができ、これらは、ワーカの状態（たとえば、元気である、疲れている、緩慢であるなど）または実行されるタスク（組立、検査、塗装、縫製など）などの情報を取得するのに使用され得る。分類モデルの一例として、ガウス分布を使用する。この分布は、平均値および分散を使用してパラメータ化される。具体的には、我々は、ワーカの視線のガウス分布を学習したい。ここ

では、ワーカの視線は平面内で追跡されるので、学習される分布は二次元であり、平均値 μ およびサイズ 2×2 の共分散行列 Σ を有する。モデル学習は、格納された視線データからこれらの平均値および共分散行列を推定することからなる。次いで、各点 x, y において、分布の値 $f(x, y, \mu, \Sigma)$ を求めることができる。ワーカがタスクに注意を払っているか否かを分類するために、各々の新たな視線位置 x_n, y_n が分布 $f(x_n, y_n | \mu, \Sigma)$ に入力される。高確率点 p は、ワーカが割り当てられたタスクに取り組んでいることを意味する。低確率は、ワーカが注意散漫である、疲れている、休憩している、または異なるタスクに取り組んでいることを意味する。このように使用される分類モデルは、タスク完了が正常であるか否かを判断する。しかし、このアプローチは、タスク同士を区別するのに使用することができる。各タスクについて分布を学習したとする。この場合、最高確率をもたらす分布は、タスク帰属、すなわち進行中のタスクの分類を決定する。

【0054】

訓練データベース203に格納された訓練済み分類モデルは、異常検出を支援するのに使用され得るワーカの健康レベルに関連する閾値を作成するために、ヒューマンワーカの健康／注意力のレベルを含み得る。たとえば、上記の例を使用して、ワーカの注意力レベルについてさまざまな分布を学習することができる。ここでは、健康な注意怠りないワーカのガウス分布は狭いのに対して、疲れているワーカのガウス分布は広いであろう。既知のタスクでは、これらの異なる分布を比較することにより、ワーカの注意力レベルが明らかになる。分布が1つである場合には、共分散行列 Σ の変化を追跡してワーカの変化を求めることが可能であろう。一般に、ワーカの健康は、健康レベルを使用して明示的に追跡されるか、または既知のモデルの予測／分類の変化を調べることによって暗黙的に追跡されるかのいずれかであり得る。

【0055】

依然として図2Cのステップ1を参照して、ヒューマンワーカパフォーマンスのモデルまたはパフォーマンスモデル280が学習されると、パフォーマンスモデル280は、優れたヒューマンワーカパフォーマンスを学習するために継続的に更新される。たとえば、ピークパフォーマンスがワーカによって観察されると、パフォーマンスモデルは更新される。ここでは、ピークパフォーマンスは、所望の適用例の文脈において、たとえばワーカとロボットとが協働して組立ライン上で作業している図1Cに示される状況において解釈される。ここでは、ピークパフォーマンスは、1時間当たりの所望の製品、1時間当たりの所望の不良率、またはそれらの組み合わせであってもよい。これらの条件が満たされる場合に、収集されたデータは、実質的に、所望のピークパフォーマンスを生じさせる方法、アクションおよびワーカの状態を説明する。なお、ワーカは、目標パフォーマンスレートを達成することができると想定される。このアプローチは、パフォーマンスモデル280に、優れたパフォーマンスの正確なモデルを作成させ、それによりパフォーマンス低下の正確な検出を行わせるであろう。ワーカの典型的なパフォーマンスおよび状態を理解することの少なくとも1つの局面は、ロボットと人間との間のコラボレーション自体がロボットアクションまたはヒューマンワーカアクションの変化を識別する際のものであってもよく、これは、パフォーマンス、すなわちロボット、ヒューマンワーカのパフォーマンス、タスク完了時刻をさらに向上させ、組立ラインまたは生産される製品の全体的速度および品質を向上させる、というものであり得る。「典型的な（通常の）パフォーマンス」は、上記の例に従った所望の製品出力または不良率閾値を満たすものとして定義される。これは、ロボットパフォーマンスを人間の状態に調整し、それによってヒューマンパフォーマンスのモデルをロボットタスク学習に結び付けることの一例であり得て、人間の状態に従ってロボット速度を調整することである。ここでは、ロボットは、人間の状態を速度にマッピングする一組のルールを学習済みである。たとえば、元気なワーカが速度Aでタスクを実行し、疲れているワーカが速度0.1Aでタスクを実行し、病気のワーカが速度0.5Aでタスクを実行することをロボットが学習したとする。この場合、リアルタイムで予測アルゴリズムを使用して、ロボットは、求められたワーカの状態を考慮してどの速度

10

20

30

40

50

を選択するかを選択することができる。

【0056】

図2Cのステップ2は、このワーカーのピークパフォーマンスの学習を説明している。ここでは、データは、モニタリングセンサ219、ウェアラブルセンサ204および既知のタスク情報220から継続的に収集される。このデータに加えて、このワーカーから収集された事前データのデータベース203が利用可能である。特定の適用例において所望である観察されたワーカーパフォーマンスが目標パフォーマンスに達すると、データは訓練データベースに保存される。ワーカーの他の状態（疲れている、病気である、悲しいなど）について同様のデータベースを作成することができる。次いで、この（これらの）データベース203からのデータを使用して、上記の分類モデルおよび予測モデルを見つける。このデータの収集は、非常に重要である。なぜなら、それは、次のステップで説明する異常検出およびプロセスモニタリングに必要な状況を提供するからである。

【0057】

図2Cのステップ3は、上記のステップ1で学習した統計モデルの利用であると考えることができる。ここでは、分類モデルは、ワーカーのパフォーマンスが通常から逸脱しているか否かをすぐに検出することができる即時異常検出284に使用することができる。また、説明したように、分類モデルの変化は、実際の異常が検出される前にワーカーに低下が起ることを観察するのに使用することができる。予測モデルは、ワーカーがいつ現在のタスクを完了するかを判断するのに使用することができる。異常検出284機能を提供することに加えて、これは、プロセス全体における異常検出も容易にする。なぜかと言うと、この情報は、イベント遷移テーブルを使用して、この時点以降に起こるであろうイベントのシーケンスを生成するのに使用できるからである。そして、異常検出284およびプロセス較正286は、プロセスのステップ4の一部である。

【0058】

図2Cのステップ4は、モデル利用ステップであると考えることができる。ここでは、格納されたデータ203および現在収集されているデータ204, 219, 220を使用して学習されたモデル280を活用する。この実験セットアップを使用して構築することができる異常検出メカニズムは多数ある。一例は、完了時刻予測モデルを直接使用して、ワーカーが上手く作業しているのかそうでないのかを判断するというものである。より複雑な例は、イベント遷移テーブルにおいて完了時刻を使用して、予測タスク完了時刻を考慮して想定される製造アクションのシーケンスを生成するというものである。いずれの場合にも、モデルは、即座の異常についてアラームを直接送信することができる。しかし、微妙な認識は、異常モデルがプロセス較正286にも使用できるというものである。たとえば、上記の視線検出のガウス方法が視線平面において共分散の増加を示している場合、速度および品質を向上させるように製造プロセスを変更することが可能であろう。たとえば、ロボットは、ワーカーアクションに一致するようにそのアクションを減速させることによってエラーを減らすように訓練され得る。代替的に、ロボットは、パーツをワーカーに近付けて焦点を向上させるように訓練され得る。全体的にみて、現在のワーカーによって観察された負荷の一部を他のワーカーが肩代わりするように、一連の製造イベントはリルートされてもよい。これは、ワーカーをモニタリングする統計モデルが、ワーカーの状態に適合するように人間-ロボット製造プロセスを向上させるのにも使用できることを意味する。

【0059】

図3Aは、本開示のいくつかの実施形態に係る、ヒューマンワーカーパフォーマンスのモデル311のいくつかのプロセスステップ、およびそれに続く、ヒューマンワーカーパフォーマンスのモデルの利用を示すブロック図である。この図は、このワーカーのピークパフォーマンスの学習を具体的に説明している。ここでは、このワーカーから収集された事前データの履歴データベース300が利用可能である。具体的には、格納されたデータは、その収集方法のために、ワーカーが上手く作業している場合のワーカーのパフォーマンスを取り込む。それとは別に、データは、ワーカーの他の状態（疲れている、病気である、悲しいなど）について注釈を付けられることもできる。次いで、このデータベース300からのデー

タを使用して、分類モデルおよび予測モデルを見つける。これらのモデルは、ステップ 301 および 302 において求められ、上記の予測モデルおよび分類モデルであると考えることができる。次いで、これらのモデルは、（上記のように）対応するワーカ状態が検出されると更新され得て、新たなデータが収集される（304）。

【0060】

図3Bは、イベント遷移テーブルにおいて図3Aのヒューマンワーカパフォーマンスの学習済みモデルを使用するいくつかのステップを示すブロック図である。これらのテーブルは、人間-ロボット製造プロセス全体におけるイベントの通常のシーケンスを記載しており、計算効率のよい異常検出方法である。図3Bにおいて、履歴データベース300を使用して、分類モデルを訓練し（301）、予測モデルを訓練する（302）。次いで、分類モデルは、現在起こっているイベントを予測するので、イベント遷移テーブルを学習する（331）のに使用することができる。本質的に、モデルは、1つのタスクから次のタスクへのワーカの遷移を検出することに役立つ。予測モデルは、タスク完了時刻の分布を学習することによってイベント遷移テーブルを強化する（332）のに使用することができる。イベント遷移テーブルは、適用例に特有の状態に基づくモデルと同様に更新され得る。たとえば、ワーカが所望の不良率で所望の製品出力を達成した場合、典型的な製造シーケンスが作成されて、イベント遷移テーブルが更新され得る。また、さまざまなワーカの状態について遷移テーブルを作成することもできる。

【0061】

図4Aは、本開示のいくつかの実施形態に係る、ロボットシステムに接続されたロボットモデル学習プログラム（たとえば、導関数フリーセミパラメトリックガウス過程（SPGP）学習モデル）を含むロボット学習制御装置を示す概略図である。ロボットのための学習システムによって可能にされるロボット学習も本開示の不可欠な部分である。本開示のいくつかの実施形態に従って、他のシステム（非限定的な例として、他のモデルベースの強化学習技術を使用したさまざまなタイプの技術水準の機械学習アプローチからのさまざまなタイプのコントローラ、または、たとえばガウス過程またはニューラルネットワークを使用してデータからモデルが学習され、制御法則がたとえばモデル予測制御によって提供され得る従来の技術水準の制御アプローチからのさまざまなタイプのコントローラなど）を使用することができると考えられる。構成要素490、491、495および作業台411は、本開示の実施形態の一部を適用することができる適用例の一例を定義する。

【0062】

引き続き図4Aのロボット学習システムを参照して、ロボット学習制御装置400は、ロボットシステムを制御するのに使用され、初期化および更新済みのロボットポリシーをインターフェイス450を介してロボットコントローラ491に送信する。ロボットコントローラ491は、初期化および更新済みのロボットポリシーを実行して、物体495上でタスクを実行する。さらに、少なくとも1つのロボット状態検出器、すなわち位置エンコーダ493によって検出されたロボットシステム490のロボット状態信号492、物体状態検出器によって検出された物体495の物体状態信号、および初期化されたロボットポリシーは、データ前処理プログラム431に送信され、そこで、これらの信号は前処理されて、ロボット状態履歴432および物体状態履歴433としてメモリに格納される。少なくとも1つの物体検出器（たとえば、カメラ494）によって物体状態信号を検出することができると考えられる。これらの構成要素490、491、495、494、493は、ここでは一例として示されているが、本開示のいくつかの実施形態に従って、特定のユーザアプリケーションまたはさまざまなタスク関連アプリケーションによって異なってもよい。

【0063】

依然として図4Aを参照して、学習（訓練）プロセスの最初に、予め定められた期間にわたって探索的な態様でロボットを動かして得る初期ロボットポリシー437が、インターフェイス450を使用してロボットシステム490に送信される。初期ロボットポリシーは、任意の信号であり、たとえば正弦波信号、正弦波または不規則信号の合計であり得る。予

め定められた期間中、収集されたデータは、入力／出力インターフェイス450がデータ前処理プログラム431に送信する、それぞれ494および493によって検出された物体状態およびロボットシステム状態である。データ前処理プログラム431では、データは、前処理にかけられて、ロボット状態履歴432および物体状態履歴433としてメモリに格納され、各時間ステップにおけるこれらの量は、それぞれロボットおよび物体の過去の位置の有限履歴を含む。

【0064】

ロボットモデル学習プログラム434は、たとえば、入力としてロボット状態履歴432、物体状態履歴433および初期ロボットポリシをとる導関数フリーSPGP（DF-SPGP）であり得る。DF-SPGPモデル学習プログラム434を実行する際に、導関数フリーSPGP（DF-SPGP）カーネル学習プログラム（図示せず）および導関数フリーSPGPモデル学習プログラムが訓練される。434において取得された導関数フリーSPGPモデルを、ロボットが物体495上で計算しなければならないタスクのタスク仕様436とともに使用して、435において更新済みロボットポリシを計算する。435において、ロボットポリシは、たとえば反復線形二次ガウス（ILQG）であり得るが、任意のモデルベースの軌道最適化技術と置き換えることができる。435において更新済みロボットポリシが学習されると、これは、入力／出力インターフェイス450およびコントローラ491を介してロボットシステムに送信され得る。ここで、ロボットシステム490は、物体495上でタスクを実行する。434における導関数フリーSPGP（DF-SPGP）モデル学習プログラムおよび435におけるポリシアルゴリズム反復線形二次ガウス（ILQG）は、ロボット操作で上手くいくことが示された一例に過ぎない。本開示のいくつかの実施形態によれば、モデル学習プログラム434およびポリシ計算435は、ここに示されているものに限定されない。モデル434は、たとえば標準的なガウス過程、ディープニューラルネットワーク、または順動力学のためのその他の関数近似器であり得る。また、ポリシ435は、モデル予測制御などのその他のモデルベースのコントローラであり得る。構成要素434および435は、モデルフリーポリシアルゴリズム（PIDコントローラなど）またはモデルフリー強化学習アルゴリズムを使用して特定のモデルを持たないポリシを求めるように、組み合わせることもできる。

【0065】

図4Bは、本開示の実施形態に係る、予め定められた期間中にロボットシステムの学習プロセスを開始するためにロボットポリシを起動するロボットモデル学習プログラム、すなわち図4Aの導関数フリーセミパラメトリックガウス過程（SPGP）学習モデルのいくつかのステップを説明するフローチャートを示すブロック図である。

【0066】

図4Bおよび図4Aを参照して、図4Bのステップ1は、ロボットシステムの学習プロセスを起動するためのロボットポリシを計算して初期化する。

【0067】

図4Bのステップ2は、初期化されたロボットポリシを制御信号によってロボットシステム（図4Aの490）に図4Aのインターフェイス450を介して送信し、この制御信号を図4Aのコントローラ491に送信することにより、次のステップ（ステップ3）において、初期化されたロボットポリシに従って図4Aのロボットシステム490を移動させる。

【0068】

図4Bのステップ3は、図4Aのロボットシステム490によって使用される制御信号を受信して、予め定められた期間にわたって図4Aの物体495を操作する。

【0069】

図4Bのステップ4は、図4Aのロボット状態信号492および図4Aの物体状態検出器494からの物体状態信号を収集して、これらの信号を図4Aのインターフェイス450を介して図4Aのロボット学習制御装置400に送信する。

【0070】

図 4 B のステップ 5 は、初期化されたロボットポリシとともにこれらの信号を図 4 A のデータ前処理プログラム 4 3 1 に送受信し、そこで、データは前処理されて、図 4 A のロボット状態履歴 4 3 2 および図 4 A の物体状態履歴 4 3 3 としてメモリに格納される。

【0071】

図 4 B のステップ 6 は、図 4 A の導関数フリー S P G P 学習モデル 4 3 4 を前のステップ（ステップ 5）の受信データで更新する。

【0072】

図 4 B のステップ 7 は、ロボットシステムが図 4 A の操作対象物体 4 9 5 上で計算すべきである図 4 A のタスク 4 3 6 を定義する。

【0073】

図 4 B のステップ 8 は、定義されたタスクを導関数フリー S P G P 学習モデルとともに使用して、図 4 A の i L Q G 4 3 5 を使用してロボットポリシを更新する。

【0074】

次いで、図 4 B のステップ 9 は、更新されたロボットポリシを、図 4 A のコントローラ 4 9 1 に接続された図 4 A のインターフェイス 4 5 0 を使用して図 4 A のロボットシステム 4 9 0 に送信する。

【0075】

図 4 B のステップ 10 は、図 4 A の導関数フリー S P G P 学習モデル 4 3 4 を使用して取得された図 4 A の更新済みポリシ 4 3 5 に従って図 4 A の物体 4 9 5 のタスク操作を実行する図 4 A のロボットシステム 4 9 0 を介して、更新済みロボットポリシを実行する。

【0076】

図 4 A を参照して、本開示の局面によれば、モデル学習システム（たとえば、上記の導関数フリーモデル学習プログラム）は、ロボット学習制御装置内に配置されることができ、このロボット学習制御装置は、本開示の実施形態に従って、図 1 B のプロセス制御システム 100 内に配置されるか、または少なくとも図 1 B のプロセス制御システムの構成要素を含み得る別個のユニットとして配置されることができる。ロボット学習制御装置は、ロボットシステム 4 9 0 を制御するのに使用することができ、初期ポリシプログラムおよび更新済みポリシプログラムをインターフェイス 4 5 0 を介してロボットシステム 4 9 0 に送信するように構成され得る。ロボットシステム 4 9 0 のロボット状態信号 4 9 2 および物体状態信号は、作業台 4 1 1 上でロボットシステム 4 9 0 によって操作される物体 4 9 5 に関して受信される。物体状態信号は、少なくとも 1 つの物体検出器 4 9 4 によって検出され、図 1 B のメモリ 1 4 0 は、コンピュータによって実行可能なプログラムを図 1 B のストレージ 1 3 0 に格納することができ、ストレージ 1 3 0 は、データ前処理プログラム 1 3 1 と、物体状態履歴データ 1 3 3 と、ロボット状態履歴データ 1 3 2 と、統計モデル学習プログラム 1 3 4 と、更新ポリシプログラム 1 3 5 と、初期ポリシプログラム 1 3 7 とを含み、図 1 B のメモリ 1 4 0 に関連してプロセッサ 1 2 0（または、2 つ以上のプロセッサ）がある。図 1 B のプロセッサ 1 2 0 は、予め設定された期間中に物体を操作するロボットシステムを動作させる学習プロセスを起動するための図 1 B の初期ポリシプログラム 1 3 7 をネットワーク 5 7 を介して図 1 B のロボットシステム 1 9 5 に送信するように構成される。この場合、プロセッサは、上記の予め設定された期間内に受信したロボット状態信号および物体状態信号の組からデータ前処理プログラム 4 3 1 を使用して変換された物体状態履歴データおよびロボット状態履歴データに従ってモデル学習プログラム 4 3 4 を更新することができ、プロセッサは、更新されたモデル学習プログラム 4 3 4 に従って更新ポリシプログラム 4 3 5 を更新する。

ロボット学習とヒューマンパフォーマンスモニタリングとを組み合わせる

【0077】

図 5 A は、本開示のいくつかの実施形態に係る、人間-ロボット製造プロセス中のロボットと人間との間のインタラクションを示す概略図である。

【0078】

このインタラクションを学習するために、統計モデルが使用され、統計モデルは、ロボ

10

20

30

40

50

ットと人間オペレータとの間の進行中のインタラクションを推論して対応することができる機械学習に基づく。これらのモデルを学習するために、ロボットの内蔵センサ、カメラのような外部センサからデータを収集する。外部センサは、たとえばヒューマンコラボレータの特徴付けを学習するために事前に使用されたセンサと同一のセンサ、またはロボットシステムに近接して位置している他の外部センサであり得る。

【0079】

学習済みインタラクション統計モデルは、ロボットとヒューマンコラボレータとの組み合わせ表現である。概念レベルでは、この学習済みモデルは、学習プロセス中にヒューマンコラボレータおよびロボットを表す特徴を追加するか、または個々の表現を別々に学習して、その後、これらを組み合わせてグローバルモデルにすることであり得る。

【0080】

依然として図5Aを参照して、具体的には、例示的な例として、ロボットモデルがロボットの状態およびアクション空間上と人間の状態およびアクション空間上とで合同で学習される場合を考える。ロボットモデルは、訓練フェーズ中に学習される。訓練フェーズは、外部センサ（たとえば、1つまたは複数のカメラ）および他のセンサによって観察され得るヒューマンデータ（ワーカまたはワーカの集団など）を収集する第1のフェーズで構成され得る。このヒューマンデータを用いて、予測完了時刻または予測ワーカ動作のような量を推論するための予測モデルと、ワーカの状態およびワーカが現在取り組んでいるタスクを推論するための分類モデルとを学習することができる。次いで、第二に、ロボットがワーカを手助けするために遂行しなければならない動作においてロボットがまあまあ上手く機能することを可能にする制御法則またはポリシーを初期化する。これは、運動感覚指示によって、または機械学習技術（強化学習など）を介したシミュレーションを通じて熟練技師が行うことができる。訓練の最終段階は、ロボットおよび人間の状態空間を含む状態空間上で定義されるグローバルモデルを訓練することで構成され得る。ここで、ワーカとロボットとが一緒に作業してタスクを遂行するので、ロボットのポリシーをこの学習モデルに適合するように向上させる。これらの適合オンライン機械学習技術は、学習インタラクション統計モデルおよびロボットポリシーを更新するのに使用することができる。なぜなら、データは、ロボットの内蔵センサおよびヒューマンワーカから収集されるからである。このように、ロボットは、ロボット自体のポリシーを完全なものにするだけでなく、ワーカの状態が変化するさまざまな状況に適合することもできる。ロボットは、協働ロボットであるべきであり、および／または、ワーカの安全性を保証するためにコンプライアンスモードで制御されるべきである。

【0081】

結果として生じる学習済みインタラクション統計モデルまたはロボット／人間の人間－ロボット協働インタラクションモデルは、人間のさまざまな状態により非常に異なっていることが考えられる。これは、図5Aに示されており、必要に迫られてこの図は二次元であるが、論理的には任意の次元数に拡張することができる。ここでは、ロボットは、加速または減速という1つの可能なアクションしか有していない。人間は、疲れているまたは元気であるという2つの可能な状態しか有していない。ロボットは、人間が元気である場合にはロボットが速度を速くすることができ、人間が疲れている場合にはロボットが速度を遅くすることができる、ということを学習しなければならない。インタラクション統計モデルが学習されると、ロボットは、ワーカが疲れている場合には高速アクションのためのコストが高くなり、低速のためのコストが最適になることを学習するであろう。同様のことが、ワーカが元気である場合には逆に当てはまる。図5Aは、ヒューマンパフォーマンスモデルの必要性も示している。人間の測定値をロボットに直接送り込むことによってこの同一の原理に到達できるということは確かに事実である。しかし、これにより、ロボットの状態空間がはるかに大きくなって、ノイズおよび計算の複雑さが問題に上乗せされることになるであろう。したがって、最初に人間の状態の進展のモデルを学習して、組み合わせ人間／ロボットモデルにこれを含めることが有利である。

【0082】

図 5 B、図 5 C および図 5 D は、インタラクション統計モデルまたは人間－ロボット協働インタラクションモデルを開発する複数の方法を示しており、3つの想定される訓練アプローチが、概念を上記した組み合わせ人間－ロボット協働インタラクションモデル（すなわち、図 5 B の 5 0 1 B、図 5 C の 5 0 8 C および図 5 D の 5 0 9 D）を提供することができる。

【 0 0 8 3 】

図 5 B は、ヒューマンモデル 5 0 4 B とロボットモデル 5 0 7 B とを組み合わせることで人間－ロボット協働インタラクションモデル 5 0 5 B にすることに注目した第 1 のアプローチ 5 0 1 B を示す。このモデルは、その対応するデータ、すなわち所与のデータセットに固有であるヒューマンデータ 5 0 2 B および訓練フェーズ 5 0 3 B およびロボットデータ 5 0 6 B および訓練フェーズ 5 1 1 B を使用する。結果として生じるモデル 5 0 5 B は、事前に学習されたモデル 5 0 4 B および 5 0 7 B の両方のモデルの出力に依拠する。このアプローチは、これらのモデルを組み合わせる直接的な方法であり得る。

【 0 0 8 4 】

ロボットのポリシーは、ロボットモデル 5 0 7 B に基づいて、およびロボットが達成しなければならないタスク 5 1 7 B（たとえば、組立ラインにおけるヒューマンワークを手助けしなければならないタスク）に基づいて、計算される。このポリシーは、任意のポリシー最適化アルゴリズム 5 1 2 B、上記のモデルベースの強化学習または最適制御で実現することができる。人間－ロボット協働インタラクションモデル 5 0 5 B が計算されると、これを使用してロボットポリシー 5 1 2 B を向上させることができ、ロボットポリシー 5 1 2 B は、新たなロボットポリシー 5 1 2 B を有するために、ロボットモデル 5 0 7 B およびタスク 5 1 7 B を考慮に入れるだけでなく、ヒューマンモデル 5 0 4 B の情報も有するように更新され得る。

【 0 0 8 5 】

図 5 C は、本開示のいくつかの実施形態に係る、ヒューマンワークから収集されたデータを使用してヒューマンモデルを訓練することを含む、ヒューマンモデルとロボットモデルとを組み合わせることで人間－ロボット協働インタラクションモデルにすることを示すブロック図である。これらのモデルを組み合わせるこの第 2 のアプローチ 5 0 8 C は、ヒューマンワークから収集されたデータ 5 0 2 C を使用してヒューマンモデル 5 0 4 C を訓練する（5 0 3 C）によって開始する。次いで、ヒューマンモデル 5 0 4 C は、人間－ロボット協働インタラクションモデル 5 0 5 C の訓練 5 1 1 C 中にロボットデータ 5 0 6 C とともに使用される。人間－ロボット協働インタラクションモデル 5 0 5 C が計算されると、これを使用して新たなロボットポリシー 5 1 2 C を学習することができる。この第 2 のアプローチの少なくとも 1 つの利点は、統合モデルを学習しており、その入力特徴が、ヒューマンワークについて学習されたモデルを含む、というものである。

【 0 0 8 6 】

図 5 D は、本開示のいくつかの実施形態に係る、人間およびロボットの両方について個々のモデルを学習し、次いでロボットポリシーを向上させるために使用される人間－ロボット協働インタラクションモデルを学習し、最終的にこのロボットポリシーは動作中に使用でき、そのためロボットおよび人間が動作している間にデータを収集することができ、この収集されたデータを使用してロボットモデルおよびロボットポリシーが継続的に更新されることを示すブロック図である。第 3 のアプローチ 5 0 9 D は、第 1 のアプローチ 5 0 1 B と同様に開始する。ここでは、ヒューマンモデル 5 0 4 D とロボットモデル 5 0 7 D とを組み合わせることで人間－ロボット協働インタラクションモデル 5 0 5 D にする。各モデルは、その対応するデータ、すなわち所与のデータセットに固有であるヒューマンデータ 5 0 2 D および訓練フェーズ 5 0 3 D およびロボットデータ 5 0 6 D および訓練フェーズ 5 1 1 D を使用する。結果として生じるモデル 5 0 5 D は、事前に学習されたモデル 5 0 4 D および 5 0 7 D の両方のモデルの出力に依拠する。

【 0 0 8 7 】

このモデルを使用して第 1 のロボットポリシー 5 1 2 D を学習する。5 0 1 B における第

10

20

30

40

50

1のアプローチとの違いとしては、ロボットモデル507Dおよびロボットポリシ512Dがオンラインで更新されることである。人間が、ロボットポリシ512Dの下で制御されるロボットと一緒に作業している間に、519Dにおいて、人間およびロボットの両方からのデータが収集される。このデータは、上記の本開示のいくつかの実施形態で説明したものと同一である。次いで、これらのデータをオンラインで使用して、ロボットモデル507Dおよびロボットポリシ512Dを向上させる。更新されたロボットモデルおよびロボットポリシは、適切なロボット動作を確実にするために元のロボットモデル507Dとともに使用される初期ロボットモデル507Dおよび初期ロボットポリシ512Dに対する修正であると考えることができる。

【0088】

いずれの場合にも、次いで、学習済み人間-ロボット協働インタラクションモデルを使用して、測定値によって表される固有の身体的状態（元気である、疲れている、緩慢であるなど）にある間にコラボレータと相互作用することができるロボットの制御方法を決定する。重要なことに、このコラボレーションは、人間-ロボット製造タスクを完了して製品品質を最大化する目的で学習される。なぜなら、この状況においてデータを収集することは時間がかかる可能性があり、このシステムにおけるロボットはエンジニアードデバイスであるからである。ここでは、学習済みモデルは、物理的知識（たとえば、ロボットの動きの方程式）、人間オペレータの特徴、およびおそらくタスクに依存する特徴を事前情報として機械学習アルゴリズムに組み込むこともできる。

【0089】

図6は、本開示のいくつかの実施形態に係る、収集可能であって、プロセス制御システムが異常を検出することを支援するのに使用可能である、バイオメトリックデータおよび他のデータを含むセンシングデータを示すブロック図である。たとえば、バイオメトリックデータは、行動的識別子601を含み得て、行動的識別子601は、物理的な動き603と、関与パターン605（行動的特徴および行動パターン）と、物理的な動き607とを含み得る。他のバイオメトリックデータは、身体的識別子602を含み得て、身体的識別子602は、写真および映像604と、生理学的認識606と、音声608と、身体属性610とを含み得る。収集可能な他のデータは、ワーカのバイタルサイン620と、皮膚伝導622と、皮膚温度とを含み得る。

【0090】

バイオメトリックデータセンシングは、I/Oモジュール（ワイヤレス通信コンポーネントまたはオンデバイスユーザインターフェイスを含み得る）、制御モジュール、電源（リムーバブルまたは充電式バッテリーであり得る）を含み得る。バイオメトリックデータセンシングは、心拍数、ワーカのバイタルサイン620、皮膚温度624および/または皮膚伝導622を測定する1つまたは複数のセンサを含み得る。これらの1つまたは複数のセンサは、ワーカの近傍に位置している。心拍数モニタまたは心拍数センサは、ワーカの心拍数を測定し得る。心拍数センサは、LF帯域とHF帯域とを区別するのに十分な精度を有すべきである。さらに、心拍数測定値に基づいて、プロセッサモジュールを使用して、高スペクトル周波数（HF）心拍数変動に対する低スペクトル周波数（LF）心拍数変動の比率を求めることができる。HFに対するLFの比率が高いことは、ワーカの不快レベルが高いことに対応する。ワーカのバイタルサイン620は、リモートフォトリプレキシモグラフィ（RPPG）センサを利用することによって取得され得る。いくつかの実施形態では、ワーカのバイタルサインを測定するのにウェアラブルデバイスが使用されてもよく、プロセス制御システムの動作中、このウェアラブルデバイスは、プロセス制御システムの入力インターフェイスとリモート通信することができる。

【0091】

依然として図6を参照して、皮膚伝導622は、ワーカの皮膚からの蒸発伝達に関連付けられたワーカの皮膚の電気的特性の変化を反映するガルバニック皮膚反応として測定され得る。皮膚温度624は、ワーカと環境との間の熱伝達を定量化するのに使用され得る。皮膚伝導測定値および皮膚温度測定値の各々は、特定のワーカの好みを示すそれぞれの

10

20

30

40

50

予め定義された範囲と比較され得る。バイオメトリックデータセンシングは、ワーカの I R 画像を出力する I R カメラを含み得る。I R 画像の分析は、衣服の最外層の温度とワーカの皮膚温度とを比較することによって衣服レベルの推定値を提供し得る。バイオメトリックデータを取得するために、1つまたは複数のセンサがワーカの皮膚と直接接触していてもよい。たとえば、センシングは、ウェアラブルデバイス（時計、ブレスレット、ネックレス、靴の中敷きまたはアームバンドなど）であってもよい。

【0092】

図7は、本開示のいくつかの実施形態に係るウェアラブルリストデバイスの一例を示す概略図である。ウェアラブルデバイス746は、ワーカの手首748に配置されてもよい。ウェアラブルデバイス746は、リスト750を表示するとともに、リスト750内の各項目についてデータを取得するように構成され得る。たとえば、このような表示およびリスト750における取得されたデータは、体温751、血圧752、脈拍数753、呼吸率754、O₂飽和度756、皮膚伝導757および皮膚温度758を含み得る。

ガウス過程回帰を使用したモデルベースの強化学習

【0093】

ここでは、モデルベースの強化学習MBRLにおいて採用されるガウス過程回帰（GPR）および軌道最適化アルゴリズムを使用した標準的なモデル学習フレームワークについて説明する。これは、図1Bの統計モデル学習134、図1Bの制御プログラム135、図4Aのモデル学習434、図4Aの更新ポリシ435をどのように計算することができるかを技術的に説明する。

【0094】

【数2】

RLのための環境は、マルコフ決定過程（MDP）によって正式に定義される。マルコフ性を条件として離散時間システム $\tilde{\mathbf{x}}_{k+1} = \mathbf{f}(\tilde{\mathbf{x}}_k, \mathbf{u}_k)$ を考えてみる。式中、 $\tilde{\mathbf{x}}_k \in \mathbb{R}^{n_s}$ および $\mathbf{u}_k \in \mathbb{R}^{n_u}$ は、時刻 k における状態ベクトルおよび入力ベクトルである。一般化座標 $\mathbf{q}_k = [q_k^1, \dots, q_k^n] \in \mathbb{R}^n$ を有する機械システムを考えたとき、剛体動力学を通じて取得される動力学方程式が示唆していることは、マルコフ性を満たすために、状態ベクトル $\tilde{\mathbf{x}}_k$ が、タスク定義次第で、一般化座標の位置、速度および加速度で構成されるべきである、すなわち $\tilde{\mathbf{x}}_k = [\mathbf{q}_k, \dot{\mathbf{q}}_k, \ddot{\mathbf{q}}_k] \in \mathbb{R}^{3n}$ であるべきであるか、またはおそらくこれらの変数のサブセットで構成されるべきであるということである。

【0095】

【数3】

モデルベースのRLアルゴリズムは、システムの進展の推定値である $\hat{\mathbf{f}}(\tilde{\mathbf{x}}_k, \mathbf{u}_k)$ から始まるポリシ $\pi(\tilde{\mathbf{x}}_k)$ を導き出す。

ガウス過程回帰

【0096】

【数4】

10

20

30

40

50

$\hat{\mathbf{f}}(\tilde{\mathbf{x}}_k, \mathbf{u}_k)$ を学習するためにGPRを使用することができる。一般的に言って、 $\tilde{\mathbf{x}}_{k+1}$ を構成する変数は、 $\tilde{\mathbf{x}}_{k+1}$ および $\mathbf{u}_k$ を考慮して条件付きで独立していると想定され、各状態次元は、別個のGPRによってモデル化される。 $\hat{f}^i(\tilde{\mathbf{x}}_k, \mathbf{u}_k)$ ($i=1 \dots n_s$) によって表される $\hat{\mathbf{f}}(\tilde{\mathbf{x}}_k, \mathbf{u}_k)$ の成分は、ノイズの混ざった入力-出力観察値のデータセットである $\{X, \mathbf{y}^i\}$ に基づいて推論および更新される。Nは、利用可能なサンプルの数であり、GPR入力の組を $X = [\bar{\mathbf{x}}_1, \dots, \bar{\mathbf{x}}_N]$ として定義し、式中、 $\bar{\mathbf{x}}_k = [\tilde{\mathbf{x}}_k, \mathbf{u}_k] \in \mathbf{R}^m$ ($m = n_s + n_u$) である。出力 $\mathbf{y}^i = [y_1^i, \dots, y_N^i]$ に関して、文献では2つの定義が提案されている。特に、 y_k^i は、次の時刻における状態のi番目の成分である $\tilde{\mathbf{x}}_{k+1}^i$ として、または $y_k^i = \tilde{\mathbf{x}}_{k+1}^i - \tilde{\mathbf{x}}_k^i$ として定義されることができ、 $\hat{\tilde{\mathbf{x}}}_{k+1} = \tilde{\mathbf{x}}_k + \hat{\mathbf{f}}(\tilde{\mathbf{x}}_k, \mathbf{u}_k)$ ということになる。いずれの場合にも、GPRは、これらの観察値を以下のようにモデル化する。

$$\mathbf{y}^i = \begin{bmatrix} f^i(\bar{\mathbf{x}}_1) \\ \vdots \\ f^i(\bar{\mathbf{x}}_N) \end{bmatrix} + \begin{bmatrix} e_1 \\ \vdots \\ e_N \end{bmatrix} = \mathbf{f}^i(X) + \mathbf{e}, \quad (1)$$

式中、 $\mathbf{e}$ は、ゼロ平均値および共分散 σ_n^2 を有するガウスi. i. d. ノイズであり、 $\mathbf{f}^i(X) : \mathbf{N}(\mathbf{m}_{f^i}(X), K_{f^i}(X, X))$ である。行列 $K_{f^i}(X, X) \in \mathbf{R}^{N \times N}$ は、カーネル行列と呼ばれ、カーネル学習プログラムであるカーネル関数 $k_{f^i}(\cdot, \cdot)$ を通じて定義される。これらの想定の下で、 $\mathbf{f}^i(\cdot)$ の事後分布は、ガウス分布であり、閉形式で入手可能である。モデル学習プログラムであるGPRにおいて、極めて重要な局面は、通常は0であると考えられる $m_{f^i}(\cdot)$ によって定義される $f^i(\cdot)$ および $k_{f^i}(\cdot, \cdot)$ のための事前関数の選択である。以下では、 $\mathbf{f}(\cdot)$ 成分および関連性のあるカーネル関数のうちの1つとしてそれぞれ $f(\cdot)$ および $k(\cdot, \cdot)$ を参照する。文献では、GPRが物理システムのモデル化に適用されると、多くの場合、以下の事例のうちの1つにおいてカーネル関数またはカーネル学習プログラムが定義される。

物理現象からヒントを得たカーネル

【0097】

【数5】

10

20

30

40

50

システムの物理モデルが第一原理によって導き出される場合、モデル情報は、システムの進展が線形である特徴空間を識別するのに使用され得る。より正確には、モデルは、 $y_k = \boldsymbol{\varphi}(\bar{\mathbf{x}}_k)^T \mathbf{w}$ という形式で書くことができ、式中、 $\boldsymbol{\varphi}(\bar{\mathbf{x}}_k): \mathbf{R}^m \rightarrow \mathbf{R}^q$ は、GPR入力ベクトル $\bar{\mathbf{x}}_k$ を物理現象からヒントを得た特徴空間上にマッピングする、第一原理によって取得される既知の非線形関数であり、 $\mathbf{w}$ は、ゼロ平均ガウス確率変数としてモデル化された未知のパラメータのベクトルであり、すなわち $\mathbf{w}: N(0, \Sigma_{PI})$ であり、 $\Sigma_{PI} \in \mathbf{R}^{q \times q}$ は、しばしば対角線であるように選択される。物理現象からヒントを得たカーネル (PI) の式は、以下の通りである。

$$k(\bar{\mathbf{x}}_k, \bar{\mathbf{x}}_j) = \boldsymbol{\varphi}(\bar{\mathbf{x}}_k)^T \Sigma_{PI} \boldsymbol{\varphi}(\bar{\mathbf{x}}_j), \quad (2)$$

すなわち、特徴 $\boldsymbol{\varphi}(\cdot)$ における線形カーネルである。推定パフォーマンスの観点からの PI カーネルの効率は、モデルと実際のシステムの挙動との間の適合に密接に関連している。モデルが正確である場合、これらのカーネルは、精度および一般化の点で優れたパフォーマンスを示す。

【0098】

【数6】

後で便利なように、 $\boldsymbol{\varphi}(\cdot)$ における同次多項式カーネルも定義し、これは (2) のより一般的な事例である。

$$k_{poly}^p(\bar{\mathbf{x}}_k, \bar{\mathbf{x}}_j) = \left(\boldsymbol{\varphi}(\bar{\mathbf{x}}_k)^T \Sigma_{PI} \boldsymbol{\varphi}(\bar{\mathbf{x}}_j) \right)^p. \quad (3)$$

【0099】

$p = 1$ である場合に線形カーネルが取得されることに注目されたい。推定対象のハイパーパラメータは、行列 Σ_{PI} の対角線要素のままである。

ノンパラメトリックカーネル

【0100】

【数7】

10

20

30

40

50

モデル化対象のプロセスの既知の構造がない場合、カーネルは、モデル化対象のプロセスの理解に従ってユーザによって選択されなければならない。一般的なオプションは、以下のような放射基底関数カーネル（R B F）である。

$$k_{RBF}(\bar{\mathbf{x}}_k, \bar{\mathbf{x}}_j) = \lambda e^{-\frac{(\bar{\mathbf{x}}_k - \bar{\mathbf{x}}_j)^T \Sigma_{RBF}^{-1} (\bar{\mathbf{x}}_k - \bar{\mathbf{x}}_j)}{2}}, \quad (4)$$

式中、 λ は、スケーリング係数と呼ばれる正定数であり、 Σ_{RBF} は、 $\bar{\mathbf{x}}_k$ と $\bar{\mathbf{x}}_j$ との間の距離が計算されるノルムを定義する正定値行列である。スケーリング係数および Σ_{RBF} の要素は、ハイパーパラメータと呼ばれる未知のパラメータであり、このような理由から、それは、ノンパラメトリック（N P）カーネルと呼ばれる。 Σ_{RBF} をパラメータ化するいくつかのオプション、たとえばコレスキー分解によって定義される対角行列または全行列、すなわち $\Sigma_{RBF} = LL^T$ が提案されている。この場合、 Σ_{RBF} のハイパーパラメータは、下三角行列Lの要素であり、対角線に沿ったこれらの要素は、強制的に正であるようにされる。この選択により、全ての正定値行列がパラメータ化されることに注目されたい。

セミパラメトリックカーネル

【0101】

【数8】

このアプローチは、物理現象からヒントを得たカーネルとノンパラメトリックカーネルとを組み合わせる。ここでは、カーネル関数は、以下のように共分散の合計として定義される。

$$k(\bar{\mathbf{x}}_k, \bar{\mathbf{x}}_j) = \phi(\bar{\mathbf{x}}_k)^T \Sigma_{PI} \phi(\bar{\mathbf{x}}_j) + k_{NP}(\bar{\mathbf{x}}_k, \bar{\mathbf{x}}_j). \quad (5)$$

式中、 $k_{NP}(\cdot, \cdot)$ は、たとえばR B Fカーネル（4）であり得る。

【0102】

セミパラメトリック（S P）カーネルは、パラメトリックカーネル k_{PI} のグローバル特性およびノンパラメトリックカーネル k_{NP} の柔軟性を活用する。S Pカーネルの使用は、ノンパラメトリックカーネルを用いて取得されたモデル学習プログラムの典型的な挙動を、データによって上手く検討されない状態空間のエリアにも上手く一般化するモデル学習プログラムを有し、同時に、モデル化されていない動力学に悩まされるパラメトリックカーネルを用いて取得されたモデル学習プログラムよりも高い精度パフォーマンスを有することが分かった。

i L Q Gを使用した軌道最適化

【0103】

【数9】

10

20

30

40

50

本開示のいくつかの実施形態は、i L Q G アルゴリズムを軌道最適化に使用できるという認識に基づく。(1)などの離散時間動力学およびコスト関数を考慮して、アルゴリズムは、軌道に沿ったシステムのための局所線形モデルおよび二次コスト関数を計算する。次いで、これらの線形モデルを使用して、関連付けられたL Q G問題を繰り返し解くことによって最適な制御入力および局所ゲイン行列を計算する。コントローラ設計のためのコスト関数は、ターゲット状態 $\mathbf{x}_*$ からの状態逸脱である $\mathbf{e}$ および入力飽和の関数である。

状態コストに関して、 $\ell_{\mathbf{x}_*}(\mathbf{e}) = \sqrt{(\|\mathbf{e}\|_2^2 + \beta^2)} - \beta$ によって表される「smooth-abs」関数が

10

一般的に使用され、式中、 $\|\mathbf{e}\|_2^2$ は、 $\mathbf{e}$ のユークリッドノルムの二乗であり、 β は、ゼロ付近の関数の滑らかさを制御するパラメータである。入力飽和に対する最終的な制約を説明するために、コサイン-双曲線関数 $\ell_{u^i}(\mathbf{u}) = \gamma^2 \cosh((u^i/\gamma) - 1)$ を使用することができ、これにより、コストが指数関数的に所望の制御ボリュームの範囲外の無限大に増加して、パラメータ γ がこのボリュームを支配することが確実になる。このコスト関数は、G P モデルを線形化して、i L Q G アルゴリズムを使用して逆方向および順方向検索を実行することによって最適化される。

20

強化学習アルゴリズムのための導関数フリーフレームワーク

【0104】

このセクションでは、物理システムの進展をモデル化するための新規の学習フレームワークが提案される。上記の標準的なモデル化アプローチではいくつかの問題に対処する必要がある。ここでは、本開示のいくつかの実施形態によって解決される主な問題を列挙する。

第1に、数値微分

【0105】

物理第一原理から計算される任意の物理システムの剛体動力学は、関節の位置、速度および加速度の関数である。しかし、一般的な問題は、関節の速度および加速度は測定できないことが多く、関節の位置の（おそらくノイズの混ざった）測定値から開始して数値微分によってそれらを計算することは、最終的な解に深刻な影響を及ぼす可能性がある、というものである。これは、非常によく知られた、しばしば論じられる問題であり、通常は一部がアドホックフィルタ設計によって対処される。しかし、これは、フィルタのパラメータを調整する際に相当なユーザの知識および経験を必要とし、依然としてさまざまなエラーおよび遅延を生じさせる傾向がある。

30

第2に、条件付き独立性の想定

【0106】

【数10】

(1)において $\bar{\mathbf{x}}_k$ を考慮して $f^i(\bar{\mathbf{x}}_k)$ ($i = 1 \dots d$) の中の条件付き独立性を想定する

40

ことは、特に検討される出力が、本来相互に関連付けられる同一変数の位置、速度または加速度である場合には、実際のシステムの挙動の非常に不正確な近似であろう。この事実は、推定パフォーマンスでは問題であり、本来相互に関連付けられる変数をモデル化するために各出力について1つの別個のG Pを推定する必要があるので問題であり、これにより、モデル化設計およびテスト作業が冗長になり、計算リソースおよび時間が無駄になる。この最後の局面は、相当数の自由度を有するシステムを考える場合に特に関連するであろう。

50

第3に、動力学における遅延および非線形性

【0107】

最後に、物理システムは、いくつかの時刻にわたってシステムに影響を及ぼす固有の遅延および非線形効果の影響を受けることが多く、これは一次マルコフ仮定と矛盾し、このような挙動の例については後述する。

導関数フリー状態定義

【0108】

上記の制約を克服するために、位置測定値の履歴を状態要素と見なして、導関数フリーの状態でシステム状態を定義する。

【数11】

$$\mathbf{x}_k := [\mathbf{q}_k, \dots, \mathbf{q}_{k-k_p}] \in \mathbb{R}^{n(k_p+1)}. \quad (6)$$

式中、 $k_p \in \mathbb{R}$ は、正の整数である。

【0109】

状態の定義は、以下のように説明される。場合によっては、物体状態データは、予め定められた期間における物体の位置の一組のシーケンシャルな測定データを表し得て、ロボット状態データは、予め定められた期間におけるロボットの位置の一組のシーケンシャルな測定データを表し得る。

【0110】

【数12】

速度および加速度測定値が入手できず、 k_p が十分に大きいように選択される場合に、位置の履歴は、時刻 k において入手可能な全てのシステム情報を含むが、状態遷移関数を推定する可能性をモデル学習アルゴリズムに残す、というように上記の定義を理解することができる。実際、因果関係のある数値微分を介して計算される速度および加速度は、過去の位置生データの統計値を表す、有限のインパルス応答（または、非線形フィルタでは有限の過去の瞬間の知識）を有するデジタルフィルタの出力である。これらの統計値は、一般に正確ではなく、たとえばノイズを拒否するためにローパスフィルタが使用される場合に発生する遅延によって、または、いくつかのフィルタが適用される場合には複合エラー伝搬によって深刻に損なわれる可能性があり、これは、学習アルゴリズムのための情報の喪失につながる。代わりに、この情報の喪失は、本開示のいくつかの実施形態である提案された導関数フリーフレームワークでも維持される。状態遷移関数は、状態の全ての $[\mathbf{q}_{k-1}, \dots, \mathbf{q}_{k-k_p}]$ 成分について決定論的になり、既知になる（すなわち、恒等関数になる）

。その結果、システムの進展を学習することの問題は、関数 $\mathbf{q}_{k+1} = \mathbf{f}(\mathbf{x}_k, \mathbf{u}_k)$ のみを学習することに限定され、これは、学習すべきモデルの数を減少させて、誤った条件付き独立性の想定を回避する。最後に、MDP は、固有の遅延にロバストであって一次マルコフ性に従うのに十分にリッチな状態情報を有する。

PIDFカーネルを用いた状態遷移学習

【0111】

提案された状態定義は、MDPの状態遷移関数のためのモデル化技術の必要性を伴う。導関数フリーGPRは、ノンパラメトリック導関数フリーGPRについてのみ既に紹介された。しかし、上記で指摘したように、データ駆動型モデルの一般化パフォーマンスは、ロバストな学習パフォーマンスを保証するには十分でない可能性があり、物理モデルからの最終的な事前情報を活用することが極めて重要である。一方、物理モデルは、位置、速度および加速度に依存しており、導関数フリーフレームワークでのそれらの使用は、標準

的な公式化では不可能であり、本開示の実施形態は、この問題を解決する。以下では、いわゆる物理現象からヒントを得た導関数フリー（P I D F）カーネルを取得するための手順が提案される。

【0112】

【数13】

$\mathbf{q}_{k-}^i = [q_k^i, \dots, q_{k-p}^i]$ を定義して、そのタイプの物理モデル $y_k = \boldsymbol{\varphi}(\mathbf{q}_k, \dot{\mathbf{q}}_k, \ddot{\mathbf{q}}_k, \mathbf{u}_k) \mathbf{w}$ が既知であると想定されたい。この場合、DFSPGPモデル学習プログラムの重要な構成要素であるPIDFカーネルを導き出すために、 $\boldsymbol{\varphi}(\mathbf{q}_k, \dot{\mathbf{q}}_k, \ddot{\mathbf{q}}_k, \mathbf{u}_k)$ に基づいて一組のガイドラインを提案する。

10

PIDFカーネルガイドライン

【0113】

【数14】

$\boldsymbol{\varphi}(\cdot)$ における各々の位置、速度または加速度項を、次数 p の別個の多項式カーネル

$k_{poly}^p(\cdot, \cdot)$ と置換し、 p は、元の項の次数であり、たとえば $\ddot{q}^{i^2} \rightarrow k_{poly}^2(\cdot, \cdot)$ になる。

20

【0114】

【数15】

1) におけるカーネル $k_{poly}^p(\cdot, \cdot)$ の各々の入力は、 $\mathbf{q}_{k-}^i$ の関数であり、位置 q^i の履歴は、置換された項の独立変数に対応し、たとえば $\ddot{q}^{i^2} \rightarrow k_{poly}^2(q_{k-}^i, \cdot)$ になる。

【0115】

【数16】

状態変数が、関数 $g(\cdot)$ によって変換された $\boldsymbol{\varphi}(\cdot)$ の中に現れる場合、 $k_{poly}^p(\cdot, \cdot)$ への入力は、同一の関数 $g(\cdot)$ によって変換された、時点 2) において定義された入力になり、たとえば $\sin(q^i) \rightarrow k_{poly}^1(\sin(q_{k-}^i), \sin(q_{j-}^i \cdot))$ になる。

30

【0116】

【数17】

このガイドラインを適用することにより、速度および加速度を知ることなく、物理学によって提供される情報を組み込んだカーネル関数 $k_{PIDF}(\cdot, \cdot)$ が生成される。

40

【0117】

【数18】

50

セミパラメトリック導関数フリー（SPDF）カーネルへの拡張は、「セミパラメトリックカーネル」のセクションで説明したように、提案された $k_{PDF}(\mathbf{x}_k, \cdot)$ と導関数フリー状態を有するNPカーネル $k_{NPDF}(\mathbf{x}_k, \cdot)$ とを組み合わせる場合には問題にならなくなる。

$$k_{SPDF}(\mathbf{x}_k, \mathbf{x}_j) = k_{PDF}(\mathbf{x}_k, \mathbf{x}_j) + k_{NPDF}(\mathbf{x}_k, \mathbf{x}_j). \quad (7)$$

これは、DF-SPGPカーネル学習プログラムである。これらのガイドラインは、物理モデルを使用するが速度および加速度を測定することなく実際のシステムをモデル化するという重要な問題に対する解決策を具体化する。言い換えれば、DF-SPGPカーネル学習プログラム（DF-SPGPカーネル学習プログラムは、DF-SPGPモデル学習プログラムを定義し得る）に基づいて定義されるDF-SPGPモデル学習プログラムは、ロボットおよび／またはロボットによって操作される物体の挙動を予測することができる。

特徴

【0118】

1つまたは複数の異なる実施形態を作成するために局面のうちの1つまたは組み合わせを独立請求項1に含めることができると考えられる。たとえば、これらの局面のうちの1つまたは組み合わせの中には、以下を含むものもある。

【0119】

一局面は、HWのためのHPモデルが、ヒューマンデータにおける一組の境界に対応するHWパフォーマンスのさまざまな状態を学習済みであるように事前に構成され、HRIモデルが、HWのさまざまな状態と最適なロボットアクションとの間のマッピングを学習済みであるように事前に構成される、ということを含み得る。

【0120】

別の局面は、HWデータが、各々の完了した訓練タスクについてデータを含み、このデータが、HWによる動きのパターン、HWのエネルギーレベル、一組のHWスキルレベルに関連付けられたスキルレベル、および各々の完了した訓練タスクに関連付けられたパフォーマンスマトリックスに対応するHWの状態の履歴レベルのうちの1つまたはそれらの組み合わせなどである、というものである。一局面は、異常検出の分類のうちのいくつか、HWの状態に関連付けられたロボットアクションを含み、このロボットアクションが、ロボットのさまざまなレベルの速度、X軸、Y軸およびZ軸の動き、音声告知、電話をかけること、1つまたは複数の期間にわたるロボット位置の維持、コントローラに送信されたコマンドを介した環境条件の調整を含み、異常の分類のタイプのうちのいくつか、将来の異常、メンテナンス関連異常、安全性関連異常、損失生産異常、構成要素の潜在的故障の異常、品質異常および組立ライン異常の検出も含む、というものであり得る。

【0121】

また、一局面は、異常無しが判断される場合、HWの状態が、HWパフォーマンス閾値の予め定められたレベルと比較され、HWがタスクを完了するためのピークパフォーマンスを示すHWピークパフォーマンス閾値よりも大きい場合、HPモデルが、HWによってモデルピークパフォーマンスに更新され、HWパフォーマンスのレベルが、受信したHW信号からデータを抽出することによって求められ、このデータが、学習済み統計モデルへのHW測定値の適合、モデルパフォーマンスの劣化、またはHWの取得した状態を予測するために使用される特定の学習モデルなどである、というものであり得る。

【0122】

さらに、一局面は、HPモデルによってヒューマンデータから学習されたさまざまなタイプの異常および異常無しの事前に学習された境界のうちのいくつか、HWがもう作業を行っていないこと、HWが注意散漫であること、事前に学習された境界に従ってHWが

疲れているもしくはパフォーマンスが低下していることを示すエネルギーレベルをHWが体験していること、事前に学習された境界に従ってHWが元気であるもしくは高いエネルギーレベルで動作していることを示すエネルギーレベルをHWが体験していること、または、事前に学習された境界に従ってHWが疲れていないもしくは元気である（平均的なエネルギーレベルなど）もしくは平均的なHWパフォーマンスに関連付けられたエネルギーレベルで動作していることを示すエネルギーレベルをHWが体験していることを含む、というものであり得る。

定義

【0123】

バイオメトリック：バイオメトリクスとは、身体の測定および計算のための技術用語である。それは、人間の特征に関連するメトリクスを指す。バイオメトリック識別子は、個人をラベル付けして説明するために使用される特徴的な測定可能な特徴である。バイオメトリック識別子は、しばしば、生理学的特徴対行動的特徴として分類される。生理学的特徴は、体型に関連している。例としては、指紋、手のひら静脈、顔認識、DNA、掌紋、掌形認証、虹彩認識、網膜および臭い／香りが挙げられるが、これらに限定されるものではない。行動的特徴は、人の行動のパターンに関連しており、タイピングリズム、歩きぶりおよび声が挙げられるが、これらに限定されるものではない。身体的識別子：身体的識別子は、大部分が不変であり、デバイスから独立している。写真および映像：デバイスがカメラを備えている場合、それを認証に使用しやすい。顔認識および網膜スキャンが2つの一般的なアプローチである。生理学的認識：音声：音声ベースのデジタルアシスタントおよび電話ベースのサービスポータルは、ユーザを識別して顧客を認証するために音声認識を既に使用している。身体属性：三次元人体の表面を構築するために身体の端縁（すなわち、身体の輪郭、形状または物体を定義するまたは境界付ける端縁または線）を適合させる三次元人体モデルから、すなわち長手方向補間、スケーリングなどの変形を介して取得される。三次元身体は、輪郭から直接四角形メッシュとして表され、サイジングパラメータに対応する特徴線をモデルにおいて定義することができる。身体は、これらのサイジングパラメータで表され、エネルギーベースの変形を適用するために、制約を有するモデル変形、すなわちその固有の定義として表される輪郭に変換される。たとえば、横になっているかまたは椅子に座っている人間から圧点を収集する。

【0124】

行動的識別子：以下の局面を含み得る。タイピングパターン：誰しも異なるタイピングスタイルを有している。タイプする速度、1つの文字から別の文字に進むのにかかる時間の長さ、キーボードに対する衝撃の程度である。物理的な動き：環境面に関連した場所、位置または姿勢の変化であり、さまざまな身体系（骨格系、心血管系、筋神経系および身体のエネルギー系など）が協働する場合にのみ動きが生じる。すなわち、ある人の歩行は、個人に固有である。この動きは、固定軸または支点を中心に行われ、方向を有する。解剖学的な動きも、なんら違いはない。それらは、通常、骨または身体の一部が主要な解剖学的軸（矢状軸、冠状軸、前額軸など）またはそれらに平行な平面に対して固定関節を中心として動くことを含む。ナビゲーションパターン：トラックパッドまたはタッチセンサ式スクリーン上でのマウスの動きおよび指の動きは、個人に固有であり、ソフトウェアで検出することが比較的容易であり、追加のハードウェアは不要である。関与パターン：我々は皆、さまざまな方法で技術と相互作用する。どのようにアプリを開いて使用するか、どれくらい安くバッテリーを入手できるか、デバイスを使用する可能性が最も高い場所および時刻、ウェブサイトナビゲートする仕方、電話を手につくときにどれくらい電話を傾けるか、またはソーシャルメディアアカウントをどれくらい頻繁にチェックするかは全て、固有の行動的特徴であるかもしれない。これらの行動パターン（すなわち、所与の物体の方へのまたは所与の状況における個人またはグループによる反復的な行動の仕方）は、ボットが人間を真似るのが上手くなるまでは、人とボットとを区別するのに使用することができる。そして、それらは、他の認証方法と組み合わせて使用することもでき、または技術が十分に向上するとスタンドアロンのセキュリティ対策として使用することもできる。

10

20

30

40

50

【0125】

バイオメトリックセンサ：バイオメトリックセンサは、人のバイオメトリックトリート (biometric treat) を電気信号に変化させるトランスデューサである。バイオメトリックトリートは、主に、バイオメトリック指紋リーダ、虹彩、顔、音声などを含む。一般に、センサは、光、温度、速度、電気容量および他のタイプのエネルギーを読み取ったり測定したりする。センサおよびデジタルカメラの高度な組み合わせ、すなわちネットワークを使用してこの変換を行うためにさまざまな技術を適用することができる。どのバイオメトリックデバイスも1つのタイプのセンサを必要とする。バイオメトリックスの適用例は、主に、顔認識のための高精細度カメラでの使用または音声取り込みのためのマイクでの使用を含む。バイオメトリックスの中には、皮膚の下の静脈パターンをスキャンするように特別に設計されているものもある。バイオメトリックセンサまたはアクセス制御システムは、生理学的バイオメトリックスおよび行動的バイオメトリックスなどの2つのタイプに分類される。生理学的バイオメトリックスは、主に、顔認証、指紋、掌形認証、虹彩認識およびDNAを含む。一方、行動的バイオメトリックスは、キーストローク、署名および音声認識を含む。

10

【0126】

バイタルサイン (バイタルとしても知られている) は、身体の生命維持に必要な (生命を維持させる) 機能の状態を示す4つ~6つの最も重要なサインのグループである。これらの測定値は、人の全身健康状態を評価することを手助けし、病気の可能性についての手がかりを提供し、回復に向けた経過を示すために取得される。人のバイタルサインの正常範囲は、年齢、体重、性別および健康全般によってさまざまである。主要なバイタルサインは、体温、血圧、脈拍 (心拍数) および呼吸率 (呼吸数) の4つであり、しばしばBT、BP、HRおよびRRと表記される。しかし、臨床状況によっては、バイタルサインは、「第5のバイタルサイン」と呼ばれる他の測定値、すなわち周辺酸素飽和度 (SpO_2) の読み取りによって人の酸素飽和度 (SO_2) をモニタリングするパルスオキシメトリを介した酸素飽和度を含み得る。

20

【0127】

慣性測定ユニット (IMU) は、加速度計、ジャイロスコープ、および時には磁力計の組み合わせを使用して、身体の比力、角速度、および時には身体の向きを測定して報告する電子デバイスである。IMUは、加速度計 (ACC) などの微小電気機械式慣性センサを使用して測定することができ、自発運動量のモニタリングにはジャイロスコープが広く採用される。ACCセンサは、速度および変位の変化を測定するのに対して、ジャイロスコープは、回転変位などの向き、速度および加速度の変化を測定する。

30


【0128】

IMUは、角速度、力、および時には磁場を測定する特定のタイプのセンサである。IMUは、3軸加速度計および3軸ジャイロスコープで構成され、これは、6軸IMU (X軸、Y軸、Z軸、ヨー、ピッチおよびロール) であると考えられるであろう。それらは、追加の3軸磁力計も含み得て、これは、9軸IMUであると考えられるであろう。技術的には、「IMU」という語は、単にセンサを指すが、IMUは、複数のセンサからのデータを組み合わせて向きおよび方位の測定を行うセンサフュージョンソフトウェアと対になっていることが多い。一般的な用法では、「IMU」という語は、センサとセンサフュージョンソフトウェアとの組み合わせを指すために使用され得て、この組み合わせは、AHRF (姿勢方位基準装置) とも称される。IMUのいくつかの適用例は、GPSシステムにおいて方向を決定すること、携帯電話およびビデオゲームリモコンなどの家庭用電子機器において動きを追跡すること、またはAR (拡張現実) およびVR (仮想現実) システムにおいてユーザの頭の動きを追従することを含むIMUの適用例であり得る。

40

【表 1】

【表 1】



10

実施形態

【0129】

上記の説明は、例示的な実施形態を提供しているに過ぎず、本開示の範囲、利用可能性または構成を限定することを意図したものではない。むしろ、例示的な実施形態の以下の説明は、1つまたは複数の例示的な実施形態を実現するための実施可能な程度の説明を当業者に提供するであろう。添付の特許請求の範囲に記載されている開示されている主題の精神および範囲から逸脱することなく要素の機能および配置の点でさまざまな変更がなされ得ると考えられる。

【0130】

20

実施形態を十分に理解してもらうために、以下の説明では具体的詳細が提供されている。しかし、当業者によって理解されるなら、これらの具体的詳細なしに実施形態を実施してもよい。たとえば、開示されている主題におけるシステム、プロセスおよび他の要素は、実施形態を不必要に詳細に曖昧にすることのないように、ブロック図の形式の構成要素として示されてもよい。他の例では、周知のプロセス、構造および技術は、実施形態を曖昧にすることを回避するために、不必要な詳細なしに示されてもよい。

【0131】

また、個々の実施形態は、フローチャート、フロー図、データフロー図、構造図またはブロック図として描かれるプロセスとされてもよい。フローチャートは、動作をシーケンシャルなプロセスとして記載し得るが、多くの動作は、並行してまたは同時に実行することができる。また、動作の順序は、並べ替えられてもよい。プロセスは、その動作が完了すると終了され得るが、図面に記載されていないまたは図面に含まれていない追加のステップを有してもよい。さらに、いずれかの特定の記載されているプロセスにおける全ての動作が全ての実施形態で行われるとは限らない。プロセスは、方法、関数、手順、サブルーチン、サブプログラムなどに対応し得る。プロセスが関数に対応する場合、関数の終了は、呼び出し関数またはメイン関数への関数の戻りに対応し得る。

30

【0132】

特定の好ましい実施形態を参照して本開示を説明してきたが、本開示の精神および範囲内でさまざまな他の適合および変形がなされ得ることが理解されるべきである。したがって、全てのこのような変更および変形を本開示の真の精神および範囲内に包含することは、添付の特許請求の範囲の局面である。

40

50

【図面】

【図 1 A】




FIG. 1A

【図 1 C】




FIG. 1C

【図 1 B】




FIG. 1B

【図 2 A】




FIG. 2A

【図 2 B】




FIG.2B

【図 2 C】




FIG.2C

【図 3 A】




FIG.3A

【図 3 B】






FIG.3B


【図 4 A】




【図 5 A】




【図 4 B】




【図 5 B】




【図 5 C】




【図 5 D】



【図 6】



【図 7】



10

20

30

40

50

フロントページの続き

ロードウェイ 201、エイス・フロア、ケアオブ・ミツビシ・エレクトリック・リサーチ・ラボ
ラトリーズ・インコーポレイテッド

審査官 神山 貴行

(56)参考文献 特開2016-159407 (JP, A)
特開2018-205818 (JP, A)
特開2015-197917 (JP, A)
特開2011-227773 (JP, A)
米国特許出願公開第2019/0105779 (US, A1)
米国特許出願公開第2019/0139441 (US, A1)
米国特許出願公開第2015/0206090 (US, A1)

(58)調査した分野 (Int.Cl., DB名)
B25J 19/06
G06N 20/00
G05B 19/418