

(19)日本国特許庁(JP)

(12)特許公報(B2)

(11)特許番号
特許第7520122号
(P7520122)

(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

F I

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

G 0 5 B 19/418 (2006.01)

G 0 5 B 19/418

Z

請求項の数 20 (全45頁)

(21)出願番号	特願2022-538571(P2022-538571)	(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2022-545296(P2022-545296 A)	(74)代理人	東京都千代田区丸の内二丁目7番3号 110001195 弁理士法人深見特許事務所
(43)公表日	令和4年10月26日(2022.10.26)	(72)発明者	ラフトチーブ, エミル
(86)国際出願番号	PCT/JP2020/045360		アメリカ合衆国、0 2 1 3 9 - 1 9 5 5
(87)国際公開番号	WO2021/112255		マサチューセッツ州、ケンブリッジ、ブ
(87)国際公開日	令和3年6月10日(2021.6.10)		ロードウェイ 2 0 1、エイス・フロア
審査請求日	令和4年2月21日(2022.2.21)		、ケアオブ・ミツビシ・エレクトリック
(31)優先権主張番号	16/705,621		・リサーチ・ラボラトリーズ・インコー
(32)優先日	令和1年12月6日(2019.12.6)		ポレイテッド
(33)優先権主張国・地域又は機関	米国(US)	(72)発明者	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－ロボットチームによって実行されるタスクを用いた個別製造プロセスにおける高度な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】

個々のアイテムを生産する個別製造プロセス（DMP）内の少なくとも1つのタスクを人間－ロボットチームにより実行する前記プロセスにおいて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、

ロボット動作信号を含むDMPセンサからのDMP信号と、ヒューマンワーカ（HW）センサからのHW信号とを含むテスト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、

前記メモリおよび入力インターフェイスと通信する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、

予測されたイベントのシーケンスを前記DMP信号から抽出して、前記DMP信号における前記予測されたイベントのシーケンスが、DMPモデルに記載された前記DMPの動作の挙動と不一致であるか否かを判断し、前記DMP信号からの前記予測されたイベントのシーケンスが前記挙動と不一致である場合、アラームが伝えられるように構成され、

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、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HPモデル、前記HRIモデルまた

はそれら両方からの出力は、人間－ロボットチームにより実行する前記プロセスの異常の分類または異常無しを決定するために前記DMPモデルに入力され、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、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DMP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、プロセス制御システム。

【請求項2】

前記HWのための前記HPモデルは、HW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】

前記挙動の訓練データからイベントの対同士の間に見出された位置関係を指定するためにイベント遷移テーブルが使用され、前記テスト信号からの前記予測されたイベントのシーケンスが前記挙動と不一致である場合、前記アラームが伝えられる、請求項1に記載のプロセス制御システム。

【請求項4】

イベント遷移テーブルは、訓練フェーズ中に前記訓練データを含む訓練信号から構築され、前記訓練信号は、前記DMPの動作中に前記DMPのモニタリングシステムから得られ、前記ハードウェアプロセッサは、前記少なくとも1つのタスクおよび複数のタスクについてロボットタスクのタスク期間の最小期間および最大期間を求めることを含む、請求項3に記載のプロセス制御システム。

【請求項5】

前記イベント遷移テーブルおよび前記人間－ロボットチームのタスクの予測完了時刻を考慮してイベントのシーケンスが実現可能であるか否かを判断することをさらに備える、請求項3に記載のプロセス制御システム。

【請求項6】

前記入力インターフェイスは、オフライン訓練期間内における前記DMPの訓練動作中に、前記テスト信号を得る前に、および前記訓練データを受信すると、前記DMPセンサから訓練データを得て、前記ハードウェアプロセッサは、

前記DMPの前記訓練動作中に、前記イベント遷移テーブルを構築するためのシーケンスとして、イベントを前記訓練信号から抽出するように構成され、

前記イベントのシーケンスを前記メモリに格納するように構成される、請求項4に記載のプロセス制御システム。

【請求項7】

DMPデータは、DMP構成要素訓練データ、DMP組立ライン訓練データ、DMP動作訓練データ、DMP管理訓練データを含み、前記DMP信号は、DMP構成要素データ、DMP組立ラインデータ、DMP動作データ、DMP管理データを含み、HWセンサからの前記HW信号は、前記HWによって完了されるタスクの測定値の時系列を含む、請求項1に記載のプロセス制御システム。

【請求項8】

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

10

20

30

40

50

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。

【請求項 9】

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、前記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み、前記 H W 訓練信号および前記 H W 信号は、訓練動作または前記人間-ロボットチームによる前記 D M P 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 1 に記載のプロセス制御システム。

10

【請求項 10】

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、

20

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 1 に記載のプロセス制御システム。

【請求項 11】

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 が前記少なくとも 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 10 に記載のプロセス制御システム。

30

【請求項 12】

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のタスクラベル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 10 に記載のプロセス制御システム。

【請求項 13】

前記異常無しが判断される場合、前記 H W の前記状態は、前記 H P モデルの H W 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 H W 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 H W ピークパフォーマンス閾値よりも大きい場合、前記 H P モデルは、前記 H W によってモデルピークパフォーマンスに更新され、H W 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 H W 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 H W の前記状態を予測するために使用される、請求項 1 に記載のプロセス制御システム。

40

【請求項 14】

前記 H W 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 H W による動きのパターン、元気レベル、H W 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。

50

テム。

【請求項 15】

【数 1】

前記イベント遷移テーブルは、前記イベント遷移テーブルへの各入力によって構築され、 $\succ$ 記号ラベルで初期化され、前記メモリは、シーケンシャルにスキャンされ、1つのイベントが別のイベントのすぐ後に続くイベントの任意の対について、前記イベント遷移テーブルの対応する入力は、 $>$ 記号ラベルに変更され、前記スキャンの完了時に、任意の2つのイベントは、前記 $>$ 記号ラベルまたは前記 $\succ$ 記号ラベルの関係のいずれかの関係になり、一組のルール、すなわち $A > B$ および $B \succ A$ であれば $A \rightarrow B$ ； $A \succ B$ および $B > A$ であれば $A \leftarrow B$ ； $A > B$ および $B > A$ であれば $A \parallel B$ ；ならびに $A \succ B$ および $B \succ A$ であれば $A \# B$ 、を使用して、前記メモリからの前記 $>$ 記号ラベルおよび前記 $\succ$ 記号ラベルの関係に基づいて、導出関係 $\rightarrow$ 、 $\leftarrow$ 、 $\parallel$ および $\#$ が計算され、

10

前記イベント遷移テーブルおよび時間間隔で測定されたタスク期間にわたる確率分布は、前記DMPの前記動作の前記挙動の訓練データからイベントの対同士の間に見出された位置関係を指定し、Aはイベントであり、Bはイベントであり、 $A > B$ は、前記イベントAが前記イベントBのすぐ後に続く場合である、請求項3に記載のプロセス制御システム。

20

【請求項 16】

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（平均的なエネルギーレベル）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。

30

【請求項 17】

個々のアイテムを生産する個別製造プロセス（DMP）内の少なくとも1つのタスクを人間-ロボットチームにより実行する前記プロセスにおいて異常を検出するためのプロセス制御システムのための方法であって、

40

ロボット動作信号を含むDMPセンサからのDMP信号と、ヒューマンワーカ（HW）によって完了されたタスクの測定値の時系列を含むHWセンサからのHW信号とを含むテスト信号を受信するステップと、

前記DMP信号および予測した人間-ロボットチームのタスクの完了時刻からイベントのシーケンスを予測して、前記予測されたイベントのシーケンスが、DMPモデルに記載された前記DMPの動作の挙動と不一致であるか否かを判断し、前記DMP信号からの前記予測されたイベントのシーケンスが前記挙動と不一致である場合、アラームが伝えられるステップと、

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

50

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、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HPモデル、前記HRIモデルまたはそれら両方の出力は、人間－ロボットチームにより実行する前記プロセスの異常の分類または異常無しを決定するために前記DMP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DMP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、方法。

【請求項18】

イベント遷移テーブルは、前記挙動の訓練データからイベントの対同士の間に見出された位置関係を指定し、前記テスト信号からの前記予測されたイベントのシーケンスが前記挙動と不一致である場合、前記アラームが伝えられ、以前の製造プロセス（MP）データ、以前のヒューマンデータおよび以前の人間－ロボットデータは、前記テスト信号を受信する前に取得されて、前記メモリに格納される、請求項17に記載の方法。

【請求項19】

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17に記載の方法。

【請求項20】

個々のアイテムを生産する個別製造プロセス（DMP）内の少なくとも1つのタスクを人間－ロボットチームにより実行する前記プロセスにおいて異常を検出するためのプロセス制御システムのための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、前記方法は、

ロボット動作信号を含むDMPセンサからのDMP信号と、ヒューマンワーカー（HW）センサからのHW信号とを含むテスト信号を受信するステップと、

前記DMP信号および予測した人間－ロボットチームのタスクの完了時刻からイベントのシーケンスを予測して、前記予測されたイベントのシーケンスが、DMPモデルに記載された前記DMPの動作の挙動と不一致であるか否かを判断し、前記DMP信号からの前記予測されたイベントのシーケンスが前記挙動と不一致である場合、アラームが伝えられるステップと、

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、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HPモデル、前記HRIモデルまたはそれら両方の出力は、人間－ロボットチームにより実行する前記プロセスの異常の分類または異常無しを決定するために前記DMP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

10

20

30

40

50

ラームの前記タイプを前記DMP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、非一時的なコンピュータ読取可能記憶媒体。

【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、より具体的にはプロセスの中のいくつかのステップが人間-ロボット協働オペレーションチームによって実行される個別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。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を支配する非常に複雑な物理法則（剛体動力学（RBD）と呼ばれる）およびこれらの物理法則の概要のみが通常は知られていることに由来する。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、ポテンシオメータ、近接センサ...）、速度および加速度は測定されない。

【0003】

いくつかの従来の機械学習アプローチは、コンピュータビジョンのサブ分野からのものである傾向があり、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、CN105389859A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か分からない。

【0004】

さらに、高速かつ強力な機械が非常に速い速度で複雑な動作シーケンスを実行することができる製造では、安全性および品質をモニタリングして制御することが非常に重要である。意図された動作のシーケンスまたはタイミングからの逸脱は、品質を低下させ、原材料を無駄にし、ダウンタイムおよび機器の故障を生じさせ、出力を減少させる可能性がある。ワーカーにとっての危険が主な懸案事項である。このため、不測のイベントを最小化するように製造プロセスを注意深く設計するために細心の注意を払わなければならない。さまざまなセンサおよび非常スイッチを使用して生産ラインに安全装置を設計する必要がある。製造のタイプとして、プロセス製造および個別製造がある。プロセス製造では、製品（たとえば、石油、天然ガスおよび塩）は概して区別されない。個別製造は、個々のアイテム（たとえば、自動車、家具、玩具および飛行機）を生産する。安全性を向上させて材料および出力の損失を最小化するための従来のアプローチは、生産ラインがいつ異常に動作しているかを検出して、このような場合に必要であればラインを停止するというものである。これを実現するために、従来のアプローチでは、許容動作領域を定義してその領域外の動作点を検出する測定可能な変数（たとえば、温度、圧力など）の範囲に関する生産ラインの通常動作の説明を使用する。この従来の方法は、通常は物理変数の許容範囲に関して十分な理解があるプロセス製造業界（たとえば、石油精製）では一般的であり、製品品質の品質メトリクスは、これらの変数の観点から直接定義されることが多い。しかし、個

10

20

30

40

50

別製造における作業プロセスの性質は、プロセス製造におけるものとは異なっており、通常の作業プロセスからの逸脱は、非常に異なった特徴を有している可能性がある。個別製造は、作業単位で行われる動作のシーケンス（機械加工、はんだ付け、組立など）を含む。異常は、1つまたは複数のタスクの誤った実行、またはタスクの誤った順序を含み得る。異常な状況であっても、物理変数（温度または圧力など）は範囲外にならないことが多く、そのため、このような変数の直接的なモニタリングは、このような異常を確実に検出することができない。

【0005】

したがって、個別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、サブステップが人間－ロボット協働チームによって実行され得る個別製造プロセスを対象にした学習システムを開発する必要がある。ここでは、学習システムは、2つのレベルで動作することができ、第1のレベルは、ヒューマン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ための方法を学習するというものである。第2のレベルは、いくつかのステップがロボットおよび人間によって実行されることを考慮して、システムレベルで、個別製造プロセス全体において異常を検出することを学習するというものである。

【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、より具体的にはステップが人間－ロボット協働チームによって実行される個別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。また、本開示に示されているシステムおよび方法は、ヒューマンワーカー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。

【0008】

製造プロセス全体は、いくつかのステップが人間－ロボット協働チームによって実行される個別製造プロセス（DMP）である。ここでは、DMP（組立ラインなど）における異常も本開示に従って検出することができる。訓練中、データは、DMPの通常動作中に得られることができる。通常動作は、通常動作の説明の範囲外の異常な動作を検出することなくある期間にわたる許容動作領域を定義する測定可能な変数（たとえば、温度、圧力など）の範囲に関する生産ラインの通常動作の説明として理解することができる。重要なことに、プロセスの中のいくつかのタスクが人間－ロボット協働チームによって実行される場合、通常動作は、ワーカーのさまざまな想定される身体的状態（たとえば、健康である、疲れている、病気である、眠いなど）の間にワーカーによって行われる作業を含む。したがって、DMの通常動作中に、ワーカーの通常の動作範囲も見られる。このような訓練データ収集は、生産ラインのテスト期間中に学習され得て、数ある測定技術の中で特に、物理変数の許容範囲および製品品質の品質メトリクスを決定して、通常動作を決定することを可能にする。生産ラインの通常動作を決定すると、センサから取得されたデータが取得されて、個別のイベントのストリームを形成するように処理される。これらのイベントから通常動作についてのイベント関係テーブルが構築される。次いで、オンラインタイム処理中に、このテーブルを使用して、リアルタイムで得られたデータを使用してDMPの動作における異常を検出する。テーブルの作成にはいくつかの利点がある。非限定的な例として、テーブルは、DMPの正確なワークフローまたは通常動作を表すことができる。第二に、有限オートマタなどの従来のモデル化形式主義とは対照的に、テーブルは、並行して

10

20

30

40

50

実行される複数のサブプロセスをコンパクトかつ正確に表す。このようなサブプロセスは、独立している場合もあれば、関係している場合もある。第三に、テーブルは、複数のサブプロセス間の関係を表す。

【0009】

人間－ロボットインタラクションについてのいくつかの実施形態は、ヒューマンワーカ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カが行う典型的な動きおよびワーカが体験する集中力または疲労のレベルを判断することを含み得る。ヒューマンワーカの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。第1の認識は、タスク実行およびヒューマンワーカ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とのインタラクションの最適化に由来する。非限定的な例として、閾値アプローチに基づいてヒューマンワーカのパフォーマンスレベルまたはワーク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）パーツをヒューマンワーカに近付けること、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。これは、ワーカの状態を条件としてロボットがヒューマンワーカ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と理解され得る。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将来の異常を検出することもできる。たとえば、DMPのオンラインタイム処理中に、テーブルを使用して、DMPがリアルタイムで動作している間に将来の／来たるべき異常を検出することができる。テーブルの使用は、製造プロセス全体の速度、正確なワークフローの問題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。

【0010】

人間－ロボット混在組立プロセスにおいて予想されるいくつかの局面は、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る。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。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。ヒューマンワーカの作業の方法を学習するために、ワーカは、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。

【0011】

本開示のいくつかの実施形態は、ヒューマン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。

【0012】

本開示のいくつかの実施形態は、異常検出メカニズムを作成してタスク完了時刻を予測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、イベント関係テーブルを使用して、人間-ロボット製造プロセスにおいて想定されるステップのシーケンスを生成することができる。この情報は、人間-ロボット製造プロセスを特徴付ける。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正確な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の完了時刻を有している場合、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る。ここでは、DMPの通常完了を表すためにいくつかの想定されるイベントシーケンスを生成することができる。ここで、予測タスク完了時刻およびイベント遷移テーブルまたは生成されたDMPの完全なシーケンスを使用して、ワーカの現在の状態およびヒューマンワーカコラボレーションに基づいてプロセスにおける異常を予想することが可能である。言い換えれば、現在の予測完了時刻を考慮して、発生するであろうイベントのシーケンスは、イベント遷移テーブルにおいてDMPを完了させることはなく、DMPの想定される通常の動作シーケンスの一部でもない。

【0013】

たとえば、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と、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である。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。人間-ロボットチームがタスクの通常完了時刻を予測しているとする。この場合、イベント遷移テーブルを使用してプロセスの完了までにこの瞬間から生成されたイベントシーケンスは、完全であろう。しかし、ここで、タスクの予測完了時刻が長すぎるとする。この場合、イベント遷移テーブルを使用して生成されたイベントシーケンスは、不完全であろう。これは、長いイベント期間がイベント遷移テーブルにおいて1つのイベントから次のイベントへの無効な遷移を生じさせたために、プロセスが完了しなかったことを意味する。このようにして、完全な製造イベントシーケンスを生成できないことにより、DMではもうすぐ異常が発生し、それが人間-ロボット協働タスクに由来するものであることが分かる。

【0014】

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、および現在のヒューマンワーカ信号から抽出される次のワーカタスクを決定することができる。分類アルゴリズム（すなわち、ヒューマンパフォーマンスモデルの一部である）は、ヒューマンワーカの状態を決定する。次いで、ヒューマンワーカの状態とともに分類アルゴリズムによってヒューマンワーカ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に基づいて、異常分類または異常無しを取得する。人間-ロボットインタラクション（HRI）モデルは、現在のロボット動作信号、現在のヒューマンワーカ信号および分類された異常で更新される。ヒューマンワーカ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は、更新されたHRIモデルおよび分類された異常を使用して決定することができる。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

10

20

30

40

50

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て、これはたとえばリアルタイムでなされ得る。重要なことに、この異常アラームは、異常が発生する前に事前に起動されることもできる。なぜなら、ヒューマンパフォーマンスモデルによって生じる予測は、将来のタスク実行シーケンスを生成することができるからである。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。

【0015】

別の任意のアプローチは、分類アルゴリズムを使用して、予測されたタスクおよびアクションと、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されたタスクおよびアクションとを比較することを含み得て、ヒューマンワークの状態に関して決定を下すことができる。

【0016】

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み得る。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。たとえば、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】

本開示の一実施形態に従って、個別製造プロセス（DMP）内の少なくとも1つのタスクを実行する人間-ロボットチームにより上記プロセスにおいて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、ロボット動作信号を含むDMPセンサからのDMP信号と、ヒューマンワーク（HW）センサからのHW信号とを含む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、上記メモリおよび入力インターフェイスと通信する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、予測されたイベントのシーケンスを上記DMP信号から抽出して、上記DMP信号における上記予測されたイベントのシーケンスが、DMPモデルに記載された上記DMPの動作の挙動と不一致であるか否かを判断し、上記DMP信号からの上記予測されたイベントのシーケンスが上記挙動と不一致である場合、アラームが伝えられるように構成され、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、上記人間の状態は、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HWモデル、上記HRIモデルまたはそれら両方からの出力は、異常または異常無しの分類を決定するために上記DMPモデルに入力され、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、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

10

20

30

40

50

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DMP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。

【0018】

本開示の一実施形態に従って、個別製造プロセス（DMP）内の少なくとも1つのタスクを実行する人間-ロボットチームにより上記プロセスにおいて異常を検出するためのプロセス制御システムのための方法である。上記方法は、ロボット動作信号を含むDMPセンサからのDMP信号と、ヒューマンワーカー（HW）によって完了されたタスクの測定値の時系列を含むHWセンサからのHW信号とを有するテスト信号を受信するステップと、上記DMP信号および予想人間-ロボットチーム完了時刻からイベントのシーケンスを予測して、上記DMP信号におけるこの予測されたイベントのシーケンスが、DMPモデルに記載された上記DMPの動作の挙動と不一致であるか否かを判断し、上記DMP信号からの上記予測されたイベントのシーケンスが上記挙動と不一致である場合、アラームが伝えられるステップと、上記HW信号から、タスク完了時刻と、タスク名と、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、以前のヒューマンデータから取得された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の上記状態は、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HWモデル、上記HRIモデルまたはそれら両方からの出力は、異常または異常無しの分類を決定するために上記DMPモデルに入力され、上記方法はさらに、以前の人間-ロボットデータから取得された上記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DMP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。

【0019】

本開示の一実施形態に従って、個別製造プロセス（DMP）内の少なくとも1つのタスクを実行する人間-ロボットチームにより上記プロセスにおいて異常を検出するためのプロセス制御システムのための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。上記方法は、ロボット動作信号を含むDMPセンサからのDMP信号と、ヒューマンワーカー（HW）によって完了されたタスクの測定値の時系列を含むHWセンサからのHW信号とを含むテスト信号を受信するステップと、上記DMP信号および予想人間-ロボットチーム完了時刻からイベントのシーケンスを予測し、上記DMP信号におけるこの予測されたイベントのシーケンスが、DMPモデルに記載された上記DMPの動作の挙動と不一致であるか否かを判断し、上記DMP信号からの上記予測されたイベントのシーケンスが上記挙動と不一致である場合、アラームが伝えられるステップと、上記HW信号から、タスク完了時刻と、上記HWの状態および予測された次の順番のタスクに関連する測定値と、以前の人間データから取得された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有し、次いで、上記HWの上記状態は、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HWモデル、上記HRIモデルまたはそれら両方からの出力は、異常または異常無しの分類を決定するために上記DMPモデルに入力され、上記方法はさらに、以前の人間-ロボットデータから取得された上記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DMPの管理システムに出力するステップとを有し、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。

【0020】

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説明する。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、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】

【0021】

【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、個別製造プロセスの組立ラインにおいてタスクを実行するロボットシステムおよびヒューマンワーク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、個別製造プロセス(DMP)において異常を検出するための方法の図を示す概略図である。

【図2B】本開示のいくつかの実施形態に係る、ログベースの順序関係テーブルの図を示すテーブルである。

【図2C】本開示のいくつかの実施形態に係る、シーケンスとモデルとの間の整合性を判断することによってイベントシーケンスから異常を検出するための方法の図を示す概略図である。

【図3A】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クデータを取得するための、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。

【図3B】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3C】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4A】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4B】本開示のいくつかの実施形態に係る、図4A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4A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5A】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5B】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を起動するロボットモデル学習プログラム、すなわち図5A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6A】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6B】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て協働モデルにすることを示すブロック図である。

【図6C】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

10

20

30

40

50

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協働モデルにすることを示すブロック図である。

【図 6 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を向上させるために使用される協働モデルを学習し、最終的にこのロボットポリシは動作中に使用できることを示すブロック図である。

【図 7 A】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 B】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】

【0022】

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

【0023】

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。

【0024】

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、個別製造プロセス（DMP）内の少なくとも 1 つのタスクを実行する人間—ロボットチームによりプロセスにおいて異常を検出するためのプロセス制御システムを含む。このプロセス制御方法は、いくつかのタスクが人間—ロボット協働チームによって実行される個別製造プロセス（DMP）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ことができる。ステップのうちのいくつかは、

【0025】

ロボット動作信号および他の DMP 構成要素信号を含む DMP センサからの DMP 信号と、ヒューマンワーカ（HW）によって完了されたタスクの測定値の時系列を含む HW センサからの HW 信号とを含むテスト信号を受信する図 1 A のステップ 15 A を含む。

【0026】

図 1 A のステップ 20 A は、DMP 信号および予想人間—ロボットチーム完了時刻からイベントのシーケンスを予測し、DMP 信号におけるこの予測されたイベントのシーケンスが、DMP モデルに記載された DMP の動作の挙動と不一致であるか否かを判断し、DMP 信号からの予測されたイベントのシーケンスが挙動と不一致である場合、アラームが伝えられるステップを含む。

【0027】

図 1 A のステップ 25 A は、HW 信号から、タスクデータと、HW の状態に関連する測定値と、以前のヒューマンデータから取得された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示し、次いで、HW の状態は、人間—ロボットインタラクション（HRI）モデルに入力され、HW モデル、HRI モデルまたはそれら両方からの出力は、異常または異常無しの分類を決定するために DMP モデルに入力される。

【0028】

図 1 A のステップ 30 A は、以前の人間—ロボットデータから取得された 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。

【0029】

10

20

30

40

50

制御アクションは、（a）ヒューマンワーカの状態に従ってロボット速度の量を調整すること、（b）X軸方向、Y軸方向もしくは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、または（c）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こと、のうちの1つまたはそれらの組み合わせを含み得る。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。さらに、いくつかの異常検出の分類は、ロボットの速度レベル、ロボットの動き、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などのロボットアクションに関連付けられ得る。他の異常検出の分類は、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、構成要素の故障の異常、品質異常および組立ライン異常の検出などの異常のタイプを含み得る。

10

【0030】

図1Aのステップ35A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DMP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。イベントのシーケンスが動作の挙動と不一致であるという判断を受信すると、伝えられたアラームを人間-ロボット混在プロセスの管理システムに出力することも考えられる。

【0031】

20

異常アラームのいくつかのタイプは、即座のアクションを対象とした異常アラームであり得るが、より重要なことに、この異常アラームは、より大きなまたは好ましくない異常が発生する前に事前に起動されることもできる。なぜなら、ヒューマンパフォーマンスモデル、人間-ロボットインタラクションモデルおよびDMPモデルによって見出され得る予測は、将来のタスク実行シーケンスを生成することができるからである。即座のまたは将来の異常アラームのいくつかの例としては、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、HW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挙げることができる。

【0032】

30

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、ワーカの状態を条件としてロボットがヒューマンワーカ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。また、本開示に示されている実施形態は、以前はヒューマンワーカの詳細なモデルを学習すること無くして不可能であった製造プロセス全体における将来を見据えた異常検出を提供する。

【0033】

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、組み合わせられたロボット-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。

40

【0034】

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され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を含み得る。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データ59、ならびに他の想定されるデータ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

50

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に格納され得る。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。

【００３５】

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。

【００３６】

図１Ｃは、本開示の実施形態に係る、個別のタスクを実行する、個別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ク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クが少なくとも１つのタスクを完了することを支援すると考えられる。

【００３７】

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ク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、ロボットまたはヒューマンワーク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。

【００３８】

依然として図１Ｃを参照して、ヒューマンワーク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。

個別製造プロセス（ＤＭＰ）における異常検出

【００３９】

図２Ａは、本開示の実施形態に係る、個別製造プロセス（ＤＭＰ）２００において異常を検出するための方法を示す図である。なお、このＤＭＰは、プロセス内にいかなるヒュー

10

20

30

40

50

ーマンワーカも持たない。本開示の実施形態は、組立ラインなどの個別製造プロセス（DMP）において異常を検出するための方法を提供する。訓練中、データは、DMPの通常動作中に得られる。このデータは、個別のイベントのストリームを形成するように処理される。これらのイベントから通常動作についてのイベント関係テーブルが構築される。次いで、オンラインタイム処理中に、このテーブルを使用して、リアルタイムで得られたデータを使用してDMPの動作における異常を検出する。

【0040】

このテーブルにはいくつかの利点がある。第一に、テーブルは、DMPの正確なワークフローまたは通常動作を表すことができる。第二に、有限オートマタなどの従来のモデル化形式主義とは対照的に、テーブルは、並行して実行される複数のサブプロセスをコンパクトかつ正確に表す。このようなサブプロセスは、独立している場合もあれば、連係している場合もある。第三に、テーブルは、複数のサブプロセス間の連係を表す。

10

【0041】

いくつかの実施形態は、オフライン訓練と、リアルタイム処理とを含む。訓練は、一回限りの前処理タスクであり得る。代替的に、訓練は、たとえば変わりゆく処理条件に適合するように必要に応じて行われる。上記方法は、当該技術分野において公知であるように、バスによってメモリおよび入力／出力インターフェイスに接続された処理デバイスにおいて実行可能である。

【0042】

DMPは、容器201～202と、製造ロボット203～204と、コンベヤ205～206と、アセンブラ207とを含む。動作中、ロボットは、容器からパーツをつまみ取って、これらのパーツをコンベヤの上に載せて、組み立てる。

20

【0043】

訓練：訓練中、DMPによって使用されるさまざまなセンサ、スイッチなどから信号209が得られる。センサは、DMPのさまざまな動作構成要素（たとえば、容器、ロボット、コンベヤおよびアセンブラ）に接続され得る。

【0044】

これらの信号からイベントのシーケンス221が抽出される（210）。これらのイベントは、訓練データベース251に格納される。これらのイベントを使用して関係テーブル270を構築し、この関係テーブル270は、テーブル270に基づく、DMPの通常動作の観察されたイベントの全ての対同士の間のログベースの順序関係のテーブルである。

30

【0045】

検出：このテーブルを使用して、異常スコア231を求めることによって、リアルタイムで得られた信号209における異常を検出する（230）。スコアが予め定められた閾値を超える場合、アラームが伝えられ得る（240）。

【0046】

機械学習：本開示は、機械学習を使用して、データ測定値からイベントシーケンスの関係テーブルを構築する。これらの測定値は、工場デバイス、ロボットおよびワーカから取得される。

【0047】

イベントシーケンス：上記方法の第1のステップは、DMPにおける全てのデバイス、ワーカおよびロボットからこのような信号を得るというものである。

40

【0048】

【数1】

50

関係テーブル：実際には、関係テーブルは、単純かつ効率的な二段階手順によって構築することができる。最初に、関係テーブルへの全ての入力は、 ∇ 記号で初期化される。第1のステップ中に、データベースはシーケンシャルにスキャンされ、1つのイベントが別のイベントのすぐ後に続くイベントの任意の対について、関係テーブルの対応する入力は、 $>$ 記号に変更される。第1のステップの後、任意の2つのイベントは、 $>$ 関係または ∇ 関係のいずれかの関係になり得る。第2のステップ中に、以下のルールを使用して、第1のステップ中に見出された関係 $>$ および ∇ に基づいて、導出関係 $\rightarrow$, $\leftarrow$, $\parallel$ および $\#$ が計算される。

$A > B$ および $B \nabla A$ であれば $A \rightarrow B$;

$A \nabla B$ および $B > A$ であれば $A \leftarrow B$;

$A > B$ および $B > A$ であれば $A \parallel B$; ならびに

$A \nabla B$ および $B \nabla A$ であれば $A \# B$

【0049】

図2Bは、本開示のいくつかの実施形態に係る、例示的なログベースの順序関係テーブルの図を示すテーブルである。なお、異常検出は、先行技術に見られるような複雑な完全な求められたモデルではなく、関係テーブルに基づく。関係テーブルは、モデルではない。その代わりに、関係テーブルは、ログベースの順序関係テーブルによって表される、DMPの通常動作中のイベントの対同士の間の発見された位置関係についてのデータログの要約統計量を表す。

【0050】

タスク期間：タスク期間は、現在のタスクの時刻と、イベントトレースにおける現在のタスクに先行する全てのタスクに対応するイベントの中の最も遅い時刻との間の差である。たとえば、イベント (t_1, Op_2) , (t_2, Op_1) , (t_3, Op_3) ($t_1 < t_2 < t_3$) を含むイベントトレースでは、タスク Op_3 の期間は、 $d(Op_3) = t_3 - t_2$ である。なぜなら、 Op_1 および Op_2 は両方ともSWNにおける Op_3 の先行タスクであり、 Op_1 の方がより遅く、すなわち時刻 t_2 において発生するため、その時刻においてタスク Op_3 を可能にし、対応するイベントは、 $t_3 - t_2$ 時間後に発せられる。なお、所与のタスクに対応するイベントは、最初に、最後に、中間に、またはそのタスク中のランダムな時刻に発せられることができる。イベントが常に各タスクの最後に発せられる場合には、収集されたタスク期間 d は、それぞれのタスクの実行時間を実際に表す。他の場合にはいずれも、タスク期間は、対応するイベントが発せられるまでの時間しか含まないが、1つまたは複数の先行タスクがそれらのイベントを発した時刻と、1つまたは複数の先行タスクが実際に完了された時刻との間の時間も含んでもよい。どの場合がDMPに存在するかにかかわらず、タスク期間は、プロセスの重要な特性であり、異常検出の目的でそのモデルに含めることができる。

【0051】

任意に、ロボットタスクのタスク期間は、いくつかの方法でモデルに含めることができる。1つの方法は、それらのタスクについての最小期間 $d_{min}(T)$ と最大期間 $d_{max}(T)$ とを求めて、タスク記述子によりそれらの期間を記録するというものである。別の方法は、タスク T の想定される期間 d にわたる確率分布 $f_T(d)$ (ガウス分布、ベータ分布またはワイブル分布など) のための特定のパラメトリック形式を想定して、その分

布についての対応するパラメータ（たとえば、ガウス分布についての平均偏差および標準偏差）を求めるというものである。単純な動作では、タスク期間は、ガウス分布の平均値として近似され得る。

【0052】

リアルタイム異常検出：図2Cは、本開示のいくつかの実施形態に係る、シーケンスとモデルとの間の整合性を判断することによってイベントシーケンスから異常を検出するための方法の図を示す概略図である。リアルタイム処理は、2つの段階、すなわちイベントのシーケンス221が、モデルによって表される通常動作と一致するか否かを判断すること（210）と、タスク期間がテーブルと一致するか否かを判断すること（220）とを有する。ここでは、これは、ロボットによって実行されるタスクのみを対象としていること

10

【0053】

【数2】

タスクのシーケンスの正確さを確認するための別の方法は、イベントストリームに見られるタスクの相対的順序と、訓練フェーズ中に構築されたログベースの順序付け関係テーブル270の入力とを比較するというものである。たとえば、イベントのシーケンスABが見られるが、関係 $A \rightarrow B$ が関係テーブルに存在している場合、異常が伝えられ得る。 $A \rightarrow B$ が、訓練データベースにおいてAのあとにBが続くことを意味している、という

20

うことを想起されたい。このような挙動が現在見られていれば、それは明らかに訓練データと不一致である。

個別異常検出方法と組み合わせる

【0054】

上記の方法は、発生するイベントのシーケンスを記載するイベント関係テーブルに依拠する。極めて重要なことに、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、製造プロセスにおける想定されるシーケンスの範囲を記載するタイミング情報を取り込む。この情報は、製造プロセスを記載する特徴付け情報である。

30

【0055】

一定の実行時間中、これらのテーブルは、我々が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る。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して、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である。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。一例として、人間ロボットチームがタスクの通常完了時刻を予測しているとする。この場合、イベント遷移テーブルを使用してプロセスの完了までにこの瞬間から生成されたイベントシーケンスは、完全であろう。しかし、ここで、タスクの予測完了時刻が長すぎるとする。この場合、イベント遷移テーブルを使用して生成されたイベントシーケンスは、不完全であろう。これは、長いイベント期間がイベント遷移テーブルにおいて1つのイベントから次のイベントへの無効な遷移を生じさせたために、プロセスが完了しなかったことを意味する。このようにして、完全な製造イベントシーケンスを生成できないことにより、DMではもうすぐ異常が発生し、それが人間-ロボット協働タスクに由来するものであることが分かる。

40

【0056】

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。一例として、手順が図2Cに示されている。ここでは、分類アルゴリズムは、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決定する。このようなアル

50

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。予測されたタスクおよびアクションと、制御システムからの予想されたタスクおよびアクションとを比較して、ワーカの状態に関して決定を下す。一例として、イベント遷移テーブルからであろうと意図的であろうと、実行対象の現在のタスクが溶接であることを制御システムが知っているとする。そして、分類アルゴリズムが各時間ステップにおいて一貫して、ワーカが溶接を行っていると判断しており、予測アルゴリズムが通常完了時刻を予測しているとする、ワーカは健康であるにちがいない。一方、分類システムが溶接と切断との間で判断が揺れ動いており、完了時刻の予測が非常に長いとすると、ワーカは疲れているにちがいない。ワーカについてより多くのデータが収集されるにつれて、これらの状態は、改良されることができるとともに、統計モデルパフォーマンスの低下に関連付けられ得る。たとえば、最初は、モデルは、ワーカが疲れていると常に判断するが、モデルは、過去の判断および現在の状態を考慮に入れるように訓練されることができる。そして、より多くのデータが収集されると、モデルは、ワーカがたとえば疲れてきているか作業疲れに達しているかを判断することができる。

10

【0057】

ワーカによる問題の検出を全体的なプロセス異常として扱う、またはワーカパフォーマンスを向上させるために変更される、ロボットヘルパに提供されるアクションとして扱うことができることに注目することは重要である。実際、DMPで異常を宣言する前に、ロボットコントローラは、ヒューマンワーカを支援するための対策を講じるべきであった。この目的のために、人間予測／分類モデルを、ロボットモデルとヒューマンモデルとを組み合わせるコントローラにおいて使用するか、またはロボット学習状態空間における追加の次元として使用することができる。後者は、ロボットによって提供される手助けのタイプの自動学習を容易にするので、重要な認識である。すなわち、ロボットは、製造プロセスの最終製品品質および速度を向上させるために人間の健康状態の各々において取るべき具体的なアクションを学習し得る。上記のように、図2Cは、ヒューマンパフォーマンスのモデルを学習し、次いで、ヒューマンパフォーマンスのモデルを利用するプロセスを示している。学習の第1のステップにおいて、図2Bに示されるアプローチを使用して収集されたデータの履歴データベースにアクセスすることができる。ここでは、履歴データベースを使用して、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ことができる。

20

30

ヒューマンワーカのモデルを学習する

【0058】

図3Aは、本開示の実施形態に係る、訓練データベース303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301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。たとえば、ヒューマンワーカ313は、ワーカ313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304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。

【0059】

他のセンサ（モーションモニタ302、オンボディモーションセンサ306A、306B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）などのバイオメト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308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307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。

40

【0060】

図3Bは、本開示の実施形態に係る、ワーカパフォーマンスタスクをモニタリングするセンサ311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、ワーカの典型

50

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317、バイオメトリックデータ315、環境センサ307、タイムスタンプ308およびオンボディモーションセンサ306A、306Bを含み得る。また、ワークパフォーマンスタスクデータ320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322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。

10

【0061】

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、ワークなど）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。

20

【0062】

図3Cは、本開示の実施形態に係る、ヒューマンワークパフォーマンスのモデル380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の利用を示すブロック図である。ヒューマンワークパフォーマンスのモデル380は、ワーク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。

30

【0063】

【数3】

40

50

図3Cのステップ1は、図3B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303にアクセスすることによってヒューマンワークパフォーマンスのモデル380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303は、ヒューマンワークパフォーマンスのモデル380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。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303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）およびワークスキルレベル（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303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。

【0064】

依然として図3Cのステップ1を参照して、訓練データベース303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。

【0065】

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303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。

【0066】

依然として図3C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。

【0067】

訓練データベース303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／集中力のレベルを含み得る。たとえば、上記の例を使用して、ワーカの集中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ものに対して、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、ワーカの集中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。

【0068】

依然として図3C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380が学習されると、パフォーマンスモデル380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380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。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は、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 0.1 A でタスクを実行し、病気のワーカが速度 0.5 A 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を選択するかを選択することができる。なお、ロボットは、タスク当たり現在のヒューマンパフォーマンスデータに適合するように任意の方向、速度などで移動することができる。

【0069】

図3Cのステップ2は、このワーカ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319、ウェアラブルセンサ304および既知のタスク情報320から継続的に収集される。このデータに加えて、このワーカから収集された事前データのデータベース303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303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。

【0070】

図3C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384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384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384およびプロセス較正386は、プロセスのステップ4の一部である。

【0071】

図3C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303および現在収集されているデータ304、319、320を使用して学習されたモデル380を活用する。この実験セットアップを使用して多くの異常検出メカニズムを構築することができる。一例は、完了時刻予測モデルを直接使用して、ワーカ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386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、パーツをワーカに近づ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、現在のワーカによって観察された負荷の一部を他のワーカ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、ワーカをモニタリングする統計モデルが、ワーカ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使用できることを意味する。

【0072】

図4A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、ヒューマンワーカパフォーマンス

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、このワーカから収集された事前データのデータベース400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、ワーカが上手く作業している場合のワーカ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400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401および402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（404）。

10

【0073】

図4Bは、イベント遷移テーブルにおいて図4A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4Bにおいて、履歴データベース400を使用して、分類モデルを訓練し（401）、予測モデルを訓練する（402）。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。

20

【0074】

図5A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590、591、595および作業台511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。

30

【0075】

引き続き図5A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500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550を介してロボットコントローラ591に送信する。ロボットコントローラ591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595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593によって検出されたロボットシステム590のロボット状態信号592、物体状態検出器によって検出された物体595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531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532および物体状態履歴533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594）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590、591、595、594、593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い

40

50

てもよい。

【0076】

依然として図5A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得る初期ロボットポリシ537が、インターフェイス550を使用してロボットシステム590に送信される。初期ロボットポリシは、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550がデータ前処理プログラム531に送信する、それぞれ594および593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531では、データは、前処理にかけられて、ロボット状態履歴532および物体状態履歴533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。

10

【0077】

ロボットモデル学習プログラム534は、たとえば、入力としてロボット状態履歴532、物体状態履歴533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534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。534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595上で計算しなければならないタスクのタスク仕様536とともに使用して、535において更新済みロボットポリシを計算する。535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。535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550およびコントローラ591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590は、物体595上でタスクを実行する。534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535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534およびポリシ計算535は、ここに示されているものに限定されない。モデル534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535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534および535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。

20

30

【0078】

図5B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5A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。

【0079】

図5Bおよび図5Aを参照して、図5B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。図5B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5Aの590）に図5Aのインターフェイス550を介して送信し、この制御信号を図5Aのコントローラ591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5Aのロボットシステム590を移動させる。図5Bのステップ3は、図5Aのロボットシステム590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5Aの物体595を操作する。図5Bのステップ4は、図5Aのロボット状態信号592および図5Aの物体状態検出器594からの物体状態信号を収集して、これらの信号を図5Aのインターフェイス550を介して図5Aのロボット学習制御

40

50

装置 500 に送信する。図 5 B のステップ 5 は、初期化されたロボットポリシーとともにこれらの信号を図 5 A のデータ前処理プログラム 531 に送受信し、そこで、データは前処理されて、図 5 A のロボット状態履歴 532 および図 5 A の物体状態履歴 533 としてメモリに格納される。図 5 B のステップ 6 は、図 5 A の導関数フリー S P G P 学習モデル 534 を前のステップ（ステップ 5）の受信データで更新する。図 5 B のステップ 7 は、ロボットシステムが図 5 A の操作対象物体 595 上で計算すべきである図 5 A のタスク 536 を定義する。図 5 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 5 A の i L Q G 535 を使用してロボットポリシーを更新する。次いで、図 5 B のステップ 9 は、更新されたロボットポリシーを、図 5 A のコントローラ 591 に接続された図 5 A のインターフェイス 550 を使用して図 5 A のロボットシステム 590 に送信する。図 5 B のステップ 10 は、図 5 A の導関数フリー S P G P 学習モデル 534 を使用して取得された図 5 A の更新済みポリシー 535 に従って図 5 A の物体 594 のタスク操作を実行する図 5 A のロボットシステム 590 を介して、更新済みロボットポリシーを実行する。

【0080】

図 5 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 590 を制御するのに使用することができ、初期および更新済みポリシープログラムをインターフェイス 550 を介してロボットシステム 590 に送信するように構成され得る。ロボットシステム 590 のロボット状態信号 592 および物体状態信号は、作業台 511 上でロボットシステム 590 によって操作される物体 595 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 594 によって検出され、図 1 B のメモリ 140 は、コンピュータによって実行可能なプログラムを図 1 B のストレージ 130 に格納することができ、ストレージ 130 は、データ前処理プログラム 131 と、物体状態履歴データ 133 と、ロボット状態履歴データ 132 と、統計モデル学習プログラム 134 と、更新ポリシープログラム 135 と、初期ポリシープログラム 137 とを含み、図 1 B のメモリ 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。図 1 B のプロセッサ 120 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 の初期ポリシープログラム 137 をネットワーク 57 を介して図 1 B のロボットシステム 195 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 531 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 534 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 534 に従って更新ポリシープログラム 535 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

【0081】

図 6 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。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または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。学習済みモデルは、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り得る。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。

【0082】

依然として図6A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ようにする制御法則またはポリシーを初期化する。これは、運動感覚教示によって、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。

【0083】

結果として生じるロボット／人間の協働モデルは、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6A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。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6A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。

【0084】

図6B、図6Cおよび図6Dは、人間－ロボット協働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－ロボットモデル（すなわち、図6Bの601B、図6Cの608Cおよび図6Dの609D）を提供することができる。

【0085】

図6Bは、ヒューマンモデル604Bとロボットモデル607Bとを組み合わせることで協働モデル605Bにすることに注目した第1のアプローチ601B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602Bおよび訓練フェーズ603Bおよびロボットデータ606Bおよび訓練フェーズ611

Bを使用する。結果として生じるモデル605Bは、事前に学習されたモデル604Bおよび607B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。ロボットのポリシーは、ロボットモデル607B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617B（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612B、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-ロボット協働モデル605Bが計算されると、これを使用してロボットポリシー612Bを向上させることができ、ロボットポリシー612Bは、新たなロボットポリシー612Bを有するために、ロボットモデル607Bおよびタスク617Bを考慮に入れるだけでなく、ヒューマンモデル604Bの情報も有するように更新され得る。

10

【0086】

図6C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協働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608Cは、ヒューマンワークから収集されたデータ602Cを使用してヒューマンモデル604Cを訓練する（603C）によって開始する。次いで、ヒューマンモデル604Cは、協働モデル605Cの訓練611C中にロボットデータ606Cとともに使用される。人間-ロボット協働モデル605C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612C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。

20

【0087】

図6D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協働モデルを学習し、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609Dは、第1のアプローチ601Bと同様に開始する。ここでは、ヒューマンモデル604Dとロボットモデル607Dとを組み合わせる協働モデル605D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602Dおよび訓練フェーズ603Dおよびロボットデータ606Dおよび訓練フェーズ611Dを使用する。結果として生じるモデル605Dは、事前に学習されたモデル604Dおよび607Dの両方のモデルの出力に依拠する。このモデルを使用して第1のロボットポリシー612Dを学習する。601Bにおける第1のアプローチとの違いとしては、ロボットモデル607Dおよびロボットポリシー612Dがオンラインで更新されることである。人間が、ロボットポリシー612Dの下で制御されるロボットと一緒に作業している間に、619D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607Dおよびロボットポリシー612D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ーは、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607Dとともに使用される初期ロボットモデル607Dおよび初期ロボットポリシー612Dに対する修正であると考えることができる。

30

40

【0088】

いずれの場合にも、次いで、学習済み協働モデルを使用して、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、

50

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7A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701を含み得て、行動的識別子701は、物理的な動き703と、関与パターン705（行動的特徴および行動パターン）と、物理的な動き707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702を含み得て、身体的識別子702は、写真および映像704と、生理学的認識706と、音声708と、身体属性710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720と、皮膚伝導722と、皮膚温度とを含み得る。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720、皮膚温度724および／または皮膚伝導722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るべきである。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720は、リモートフォトプレチスモグラフィ（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。

【0090】

依然として図7Aおよび図7Bを参照して、図7Aは、皮膚伝導722が、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ことを示している。皮膚温度724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IR画像を出力するIRカメラを含み得る。IR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。図7B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

【0091】

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（GP

R) 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 1 B の統計モデル学習 1 3 4、図 1 B の制御プログラム 1 3 5、図 5 A のモデル学習 5 3 4、図 5 A の更新ポリシ 5 3 5 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。

【0092】

【数 4】

マルコフ決定過程 (MDP) は、RL のための環境を正式に定義する。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 $\tilde{\mathbf{x}}$ 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。

10

【0093】

【数 5】

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。

20

【0094】

【数 6】

30

40

50

ガウス過程回帰： $\hat{\mathbf{f}}(\tilde{\mathbf{x}}_k, \mathbf{u}_k)$ 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
 ャットである $\{X, \mathbf{y}^i\}$ 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 $\tilde{x}_{k+1}^i$ として、または
 $y_k^i = \tilde{x}_{k+1}^i - \tilde{x}_k^i$ 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。

【0095】

【数7】

10

20

30

40

50

物理現象からヒントを得たカーネル：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、G P R 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 (P I) 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 P I 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。

【0096】

【数8】

後で便利のように、 $\boldsymbol{\varphi}(\cdot)$ 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。

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

【0097】

$p = 1$ 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。

【0098】

【数9】

10

20

30

40

50

ノンパラメトリックカーネル：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。

【 0 0 9 9 】

【数 1 0】

セミパラメトリックカーネル：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。

【 0 1 0 0 】

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。

【 0 1 0 1 】

【数 1 1】

i L Q Gを使用した軌道最適化：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

10

て表される「smooth-abs」関数が一般的に使用され、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

【0102】

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。

【0103】

第1に、数値微分：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

【0104】

【数12】

第2に、条件付き独立性の想定：（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。

40

【0105】

第3に、動力学における遅延および非線形性：最後に、物理システムは、いくつかの時刻

50

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

【0106】

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、導関数フリーの態様でシステム状態を定義する。

【数13】

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

10

式中、 $k_p \in \mathbb{R}$ は、正の整数である。

【0107】

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。

【0108】

【数14】

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）

20

30

。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

40

【0109】

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（PIDF）カーネルを取得するための手順が提案される。

50

【 0 1 1 0 】

【数 1 5】

$\mathbf{q}_{k-}^i = [q_k^i, \dots, q_{k-p}^i]$ 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、D F S P G P モデル学習プログラムの重要な構成要素である P I D F 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

【 0 1 1 1 】

【数 1 6】

P I D F カーネルガイドライン : $\boldsymbol{\varphi}(\cdot)$ 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。

【 0 1 1 2 】

【数 1 7】

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。

20

【 0 1 1 3 】

【数 1 8】

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 $\sin(q^i) \rightarrow k_{poly}^1(\sin(\mathbf{q}_{k-}^i), \sin(\mathbf{q}_{j-}^i \cdot))$ になる。

30

【 0 1 1 4 】

【数 1 9】

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 $k_{PDF}(\cdot, \cdot)$ が生成される。

40

【 0 1 1 5 】

【数 2 0】

50

セミパラメトリック導関数フリー（S P D F）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 N P 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、D F－S P G P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、D F－S P G Pカーネル学習プログラム（D F－S P G Pカーネル学習プログラムは、D F－S P G P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D F－S P G P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

【0116】

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。

【0117】

一局面は、HWのためのH P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、D M Pモデルは、異常または異常無し検出の分類を発行することを支援するために使用される製造プロセスの異なる動作を学習済みであるように事前に構成され、H R I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。

【0118】

別の局面は、挙動の訓練データからイベントの対同士の間の見出された位置関係を指定するためにイベント遷移テーブルが使用され、テスト信号からのイベントのシーケンスが挙動と不一致である場合、アラームが伝えられる、というものであり得る。一局面は、イベント遷移テーブルが、訓練フェーズ中に訓練信号から構築され得て、訓練信号は、D M Pの動作中にD M Pのモニタリングシステムから得られ、ハードウェアプロセッサは、少なくとも1つのタスクおよび複数のタスクについて最小期間および最大期間を求めることを含む、というものであり得る。さらに、一局面は、イベント遷移テーブルおよび人間ロボットチームの予測完了時刻を考慮してイベントのシーケンスが実現可能であるか否かを判断することであり得る。

【0119】

別の局面は、入力インターフェイスが、オフライン訓練期間内におけるD M Pの訓練動作中に、テストデータを得る前に、および訓練データを受信すると、D M Pセンサから訓練データを得て、ハードウェアプロセッサは、D M Pの訓練動作中に、観察されたイベントの対同士の間の許容位置関係の順序関係のイベント遷移テーブルを構築するためのシーケンスとして、イベントを訓練信号から抽出するように構成され、イベントのシーケンスをメモリに格納するように構成され得る、というものであり得る。さらに、一局面は、D M Pデータが、D M P構成要素訓練データ、D M P組立ライン訓練データ、D M P動作訓練データ、D M P管理訓練データなどの他のデータを含み、D M P信号が、D M P構成要素データ、D M P組立ラインデータ、D M P動作データ、D M P管理データなどの他のデータを含み、HWセンサからのHW信号は、HWによって完了されるタスクの測定値の時系列を含む、というものであり得る。

【0120】

別の局面は、異常検出の分類のうちのいくつかは、HWの状態に関連付けられたロボットアクションを含み得て、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、というものであり得る。さらに、別の局面は、HPモデルが、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、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、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み、HW訓練信号およびHW信号は、訓練動作または人間-ロボットチームによるDMPの動作中に、HWに関連付けられたセンサから得られる、というものであり得る。

10

【0121】

別の局面は、HPモデルが、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、HTEモデルが、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、というものであり得る。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、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。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のタスクラベル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。

20

30

【0122】

一局面は、異常無し検出がもたらされる場合、HWの状態は、HWモデルの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モデルは、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は、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、このデータは、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、というものである。または、一局面は、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ラベル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、というものであり得る。

40

【0123】

【数21】

50

別の局面は、イベント遷移テーブルまたはログベースの順序関係テーブルが、イベント遷移テーブルへの各入力によって構築され得て、 ∇ 記号ラベルで初期化され、メモリが、シーケンシャルにスキャンされ、1つのイベントが別のイベントのすぐ後に続くイベントの任意の対について、イベント遷移テーブルの対応する入力が、 $>$ 記号ラベルに変更され、スキャンの完了時に、任意の2つのイベントが、 $>$ 記号ラベルまたは ∇ 記号ラベルの関係のいずれかの関係になり、一組のルール、すなわち $A > B$ および $B \nabla A$ であれば $A \rightarrow B$; $A \nabla B$ および $B > A$ であれば $A \leftarrow B$; $A > B$ および $B > A$ であれば $A \parallel B$; ならびに $A \nabla B$ および $B \nabla A$ であれば $A \# B$ 、を使用して、メモリからの $>$ 記号ラベルおよび ∇ 記号ラベルの関係に基づいて、導出関係 $\rightarrow$, $\leftarrow$, $\parallel$ および $\#$ が計算され、イベント遷移テーブルおよび時間間隔で測定されたタスク期間にわたる確率分布は、DMPの動作の挙動の訓練データからイベントの対同士の間に見出された位置関係を指定し、Aはイベントであり、Bはイベントであり、 $A > B$ は、イベントAがイベントBのすぐ後に続く場合である、というものである。

10

20

【0124】

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が、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（平均的な元気レベルなど）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。

30

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

10

20

30

40

50

【図 3 C】




FIG.3C

【図 4 A】




FIG.4A

【図 4 B】




FIG.4B

【図 5 A】




FIG.5A

【図 5 B】




FIG.5B

【図 6 A】




FIG.6A

【図 6 B】




FIG.6B

【図 6 C】





FIG.6C


【図 6 D】

FIG.6D




【図 7 A】

FIG.7A



【図 7 B】

FIG.7B



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2015-197917 (JP, A)
特開2018-205818 (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