

(19) 日本国特許庁(JP)

(12) 公開特許公報(A)

(11) 特許出願公開番号

特開2016-100009

(P2016-100009A)

(43) 公開日 平成28年5月30日(2016.5.30)

(51) Int.Cl.
G05B 13/04 (2006.01)

F I
G05B 13/04

テーマコード (参考)
5H004

審査請求 未請求 請求項の数 20 O L 外国語出願 (全 73 頁)

(21) 出願番号	特願2015-218271 (P2015-218271)	(71) 出願人	000006013 三菱電機株式会社 東京都千代田区丸の内二丁目7番3号
(22) 出願日	平成27年11月6日(2015.11.6)	(74) 代理人	100110423 弁理士 曾我 道治
(31) 優先権主張番号	14/552, 788	(74) 代理人	100111648 弁理士 梶並 順
(32) 優先日	平成26年11月25日(2014.11.25)	(74) 代理人	100122437 弁理士 大宅 一宏
(33) 優先権主張国	米国 (US)	(74) 代理人	100147566 弁理士 上田 俊一
		(74) 代理人	100161171 弁理士 吉田 潤一郎
		(74) 代理人	100161115 弁理士 飯野 智史

最終頁に続く

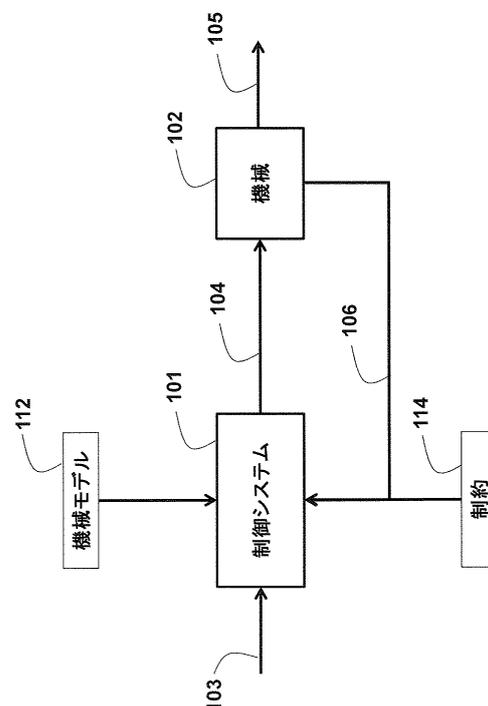
(54) 【発明の名称】 機械の動作を制御する方法、および機械の動作を反復的に制御する制御システム

(57) 【要約】 (修正有)

【課題】 方法が、制御入力に対する制約を条件としたコスト関数の最適化に基づいて機械のモデルを用いて求められた制御入力を用いて、機械の動作を反復的に制御する。

【解決手段】 本方法の現在の反復は、機械102の以前のモデルを用いて以前のコスト関数を最適化することによって以前の反復について求められた以前の制御入力を用いた制御の後に、機械の現在の状態を求めることと、機械の現在のモデル112を求めて、現在の状態と、機械の以前のモデルを用いて推定された状態との間の相違を縮小することを含む。コスト関数は、以前のモデルと現在のモデルとの間の相違に基づいて現在の反復中に更新され、現在のコスト関数が生成される。現在の反復における制御の現在の制御入力は、現在のモデルおよび現在のコスト関数を用いて求められる。

【選択図】 図1A



【特許請求の範囲】**【請求項 1】**

機械のモデルに従って機械の動作を制御する方法であって、
制御入力に対する制約を条件としたコスト関数の最適化に基づいて前記モデルを用いて
求められた前記制御入力を用いて、前記機械の前記動作を反復的に制御すること、
を含み、少なくとも1つの現在の反復は、

前記機械の以前のモデルを用いて以前のコスト関数を最適化することによって以前の反
復について求められた以前の制御入力を用いた前記制御の後に、前記機械の現在の状態を
求めることと、

前記機械の現在のモデルを求めて、前記現在の状態と、前記機械の前記以前のモデルを
用いて推定された状態との間の相違を縮小することと、

前記以前のモデルと前記現在のモデルとの間の相違に基づいて前記コスト関数を更新し
て、現在のコスト関数を生成することと、

前記現在のモデルおよび前記現在のコスト関数を用いて前記現在の反復における前記制
御の現在の制御入力を求めることと、

を含み、該方法は、前記機械の前記動作を制御するコントローラのプロセッサによって実
行される、機械のモデルに従って機械の動作を制御する方法。

【請求項 2】

前記コスト関数は、前記動作の目的に従って制御入力の第1の値を求める第1の項を含
むとともに、前記機械の将来の状態と前記機械の前記現在のモデルを用いて推定された将
来の状態との間の前記相違を縮小する前記制御入力の第2の値を求める第2の項を含み、
前記最適化は、前記第1の項および前記第2の項の組み合わせを最適化するようになって
おり、前記コスト関数を前記更新することは、前記組み合わせにおける前記第2の項の重
みを変化させることを含む、請求項1に記載の方法。

【請求項 3】

前記コスト関数の前記第2の項は、前記機械の前記現在の状態と、以前の機械状態およ
び以前の機械制御入力から前記現在の機械モデルを用いて推定された前記機械の状態と
の間の前記相違の関数を含み、前記更新することは、

前記以前のモデルと前記現在のモデルとの間の前記相違を求めることと、

前記求められた相違を用いて前記コスト関数の前記第2の項を更新することと、
を含む、請求項2に記載の方法。

【請求項 4】

前記コスト関数の前記第1の項は、前記機械の性能に関係し、前記第2の項は、前記機
械の前記モデルのパラメータの推定を改善することに関係し、前記第2の項は、前記以
前の機械状態、前記以前の機械制御入力、および前記現在の機械状態から求められた前記
機械の前記現在のモデルの予測誤差の非負の非減少関数として測定された前記機械の前記
現在のモデルの信頼性によって重み付けられる、請求項2に記載の方法。

【請求項 5】

前記機械の前記モデルは、前記モデルのパラメータ間の関係を規定する公称モデルと
、前記モデルの少なくとも1つのパラメータの値の範囲を規定する不確実性モデルとを
含み、前記現在のモデルは、該現在のモデルの前記パラメータの現在の値が前記値の範
囲内になるように求められる、請求項1に記載の方法。

【請求項 6】

前記不確実性モデルは、前記公称モデルおよび前記不確実性モデルの組み合わせが、加
法性外乱の凸結合を有する線形モデルの凸結合に含まれるように拡張される、請求項5に
記載の方法。

【請求項 7】

前記機械の前記現在のモデルは、前記現在のモデルの前記パラメータが前記線形モデ
ルの凸結合および前記加法性外乱の凸結合内になるように再帰的に求められる、請求項6
に記載の方法。

10

20

30

40

50

【請求項 8】

前記現在のモデルを前記求めることは、
 前記線形モデルの組み合わせベクトルおよび前記加法性外乱の組み合わせベクトルを求めることと、
 前記線形モデルの前記組み合わせベクトルを前記線形モデルの前記凸結合に投影することと、
 前記加法性外乱の前記組み合わせベクトルを前記加法性外乱の前記凸結合に投影することと、
 を含む、請求項 6 に記載の方法。

【請求項 9】

前記制御入力に対する前記制約は、前記制御入力に対する制御不変制約であって、該制御不変制約を満たす制御入力の任意の値が、前記機械の前記動作に対する制約を満たす状態の制御不変部分集合内に前記機械の状態を維持するように選択された前記制御入力に対する制御不変制約を含み、前記制御不変部分集合内の前記機械の任意の状態について、前記制御不変制約を満たすとともに、前記不確実性モデルによって規定された前記範囲内の前記モデルの前記パラメータの全ての値について前記機械の前記状態を前記制御不変部分集合内に維持する、許容可能な制御入力が存在する、請求項 5 に記載の方法。

【請求項 10】

前記制御入力に対する前記制約は、前記機械の前記動作に対する制約を満たす状態の制御不変部分集合内の任意の状態について、制御不変制約が、前記公称モデルおよび前記不確実性モデルによって規定された前記機械の前記モデルの前記パラメータの全ての値について前記動作中満たされるような制御入力が存在することを保証する後方到達可能反復によって前記線形モデルの前記凸結合および前記加法性外乱の前記凸結合から求められた前記制御不変制約を含む、請求項 6 に記載の方法。

【請求項 11】

前記制御入力に対する前記制約は、前記公称モデルおよび前記不確実性モデルによって規定された前記機械の前記モデルの前記パラメータの全ての値について、前記機械の前記状態を目標値に収束させる安定性制約を含む、請求項 5 に記載の方法。

【請求項 12】

前記安定性制約は、前記機械の制御リアプノフ関数を含む、請求項 11 に記載の方法。

【請求項 13】

前記制御リアプノフ関数は、前記制御不変制約を満たす前記機械の全ての状態について実現可能値低減テストを満たす無限ノルム制御リアプノフ関数であり、前記実現可能値低減テストは、

前記無限ノルム制御リアプノフ関数を記述する行列の行を選択することと、

前記制御不変制約を満たす前記機械の少なくとも 1 つの入力について前記無限ノルム制御リアプノフ関数を記述する前記行列の前記行に対する実現可能値低減を、正の条件および負の条件について満たす前記機械の前記状態の凸成分を求めることと、

前記凸成分の和集合を求めることと、

前記機械の前記状態の前記制御不変部分集合内の前記機械の全ての前記状態が前記凸成分の前記和集合に含まれることを検証することと、
 からなる、請求項 12 に記載の方法。

【請求項 14】

前記最適化は、数値最適化アルゴリズムによって解かれる、請求項 1 に記載の方法。

【請求項 15】

機械のモデルのパラメータ間の関係を規定する公称モデルと、前記モデルの少なくとも 1 つのパラメータの値の範囲を規定する不確実性モデルとを含む前記モデルに従って前記機械の動作を制御する方法であって、

コスト関数の最適化に基づいて前記機械の前記モデルを用いて求められた制御入力を用いて、前記機械の前記動作を反復的に制御すること、

10

20

30

40

50

を含み、前記最適化は、前記制御入力に対する制御不変制約であって、該制御不変制約を満たす前記制御入力の任意の値が、前記機械の前記動作に対する制約を満たす状態の制御不変部分集合内に前記機械の状態を維持するように選択された前記制御入力に対する制御不変制約を条件とし、前記制御不変部分集合内の前記機械の任意の状態について、前記制御不変制約を満たすとともに、前記不確実性モデルによって規定された前記範囲内の前記モデルの前記パラメータの全ての値について前記機械の前記状態を前記制御不変部分集合内に維持する、許容可能な制御入力が存在し、少なくとも1つの現在の反復は、

前記機械の以前のモデルを用いて以前のコスト関数を最適化することによって以前の反復について求められた以前の制御入力を用いた前記制御の結果から得られる前記機械の現在の状態を求めることと、

前記機械の現在のモデルの前記パラメータの現在の値が前記値の範囲内にあるように前記現在のモデルを求めて、前記測定された現在の状態と、前記機械の前記以前のモデルを用いて推定された状態との間の相違を縮小することと、

前記以前のモデルと前記現在のモデルとの間の相違に基づいて前記コスト関数を更新することであって、前記コスト関数は、前記動作の目的に従って前記制御入力の第1の値を求める第1の項を含むとともに、前記機械の前記現在の状態と前記機械のモデルを用いて推定された状態との間の前記相違を縮小する前記制御入力の第2の値を求める第2の項を含み、前記最適化は、前記第1の項および前記第2の項の組み合わせを最適化するようになっており、前記コスト関数を前記更新することは、前記組み合わせにおける前記第2の項の重みを変化させることを含むことと、

前記現在のモデルおよび前記現在のコスト関数を用いて前記現在の反復における前記制御の現在の制御入力を求めることと、

を含み、該方法は、前記機械の前記動作を制御するコントローラのプロセッサによって実行される、機械のモデルのパラメータ間の関係を規定する公称モデルと、前記モデルの少なくとも1つのパラメータの値の範囲を規定する不確実性モデルとを含む前記モデルに従って前記機械の動作を制御する方法。

【請求項16】

前記コスト関数の前記第2の項は、前記機械の前記現在の状態と、以前の機械状態および以前の機械制御入力から前記現在の機械モデルを用いて推定された前記機械の状態との前記相違の関数を含み、前記更新することは、

前記以前のモデルと前記現在のモデルとの間の前記相違を求めることと、

前記求められた相違を用いて前記コスト関数の前記第2の項を更新することと、を含む、請求項15に記載の方法。

【請求項17】

機械のモデルに従って該機械の動作を反復的に制御する制御システムであって、

前記モデルのパラメータ間の関係を規定する公称モデルと、前記モデルの少なくとも1つのパラメータの値の範囲を規定する不確実性モデルとを含む前記機械の前記モデル、および前記機械に対する前記制約を記憶するメモリと、

少なくとも1つのプロセッサであって、

前記機械の現在のモデルを用いて現在の制御入力に対する制約を条件として現在のコスト関数を最適化することによって現在の反復中の前記制御の前記現在の制御入力を求める制御入力モジュールと、

前記現在のモデルの前記パラメータの現在の値が、前記値の範囲を有するとともに、前記機械の以前のモデルを用いて以前のコスト関数を最適化することによって以前の反復について求められた以前の制御入力を用いた前記制御の結果から得られた前記機械の現在の状態と、前記機械の前記以前のモデルを用いて推定された推定状態との間の相違を縮小するように、前記機械の前記現在のモデルを求めるモデル学習モジュールと、

前記機械の前記現在の状態と、以前の機械状態および以前の機械制御入力から前記現在の機械モデルを用いて推定された前記機械の状態との間の相違を用いて、前記以前のコスト関数を更新するコスト関数モジュールと、

10

20

30

40

50

を含む前記コントローラのモジュールを実行する、少なくとも1つのプロセッサと、
を備える、機械のモデルに従って該機械の動作を反復的に制御する制御システム。

【請求項18】

前記現在のコスト関数は、前記動作の目的に従って前記現在の制御入力第1の値を求め第1の項を含むとともに、前記現在の状態と前記機械の前記現在のモデルに従って推定された前記状態との間の前記相違を縮小する前記現在の制御入力第2の値を求める第2の項を含み、前記最適化は、前記第1の項および前記第2の項の組み合わせを最適化するようになっており、前記コスト関数を前記更新することは、前記組み合わせにおける前記第2の項の重みを変化させることを含む、請求項17に記載の制御システム。

【請求項19】

前記コスト関数の前記第2の項は、前記機械の前記現在の状態と、以前の機械状態および以前の機械制御入力から前記現在の機械モデルを用いて推定された前記機械の前記状態との間の前記相違の関数を用いて更新される、請求項18に記載の制御システム。

【請求項20】

前記制御入力に対する前記制約は、前記制御入力に対する制御不変制約であって、該制御不変制約を満たす制御入力の任意の値が、前記機械の前記動作に対する制約を満たす状態の制御不変部分集合内に前記機械の状態を維持するように選択された前記制御入力に対する制御不変制約を含み、前記制御不変部分集合内の前記機械の任意の状態について、前記制御不変制約を満たすとともに、前記不確実性モデルによって規定された前記範囲内の前記モデルの前記パラメータの全ての値について前記機械の前記状態を前記制御不変部分集合内に維持する、許容可能な制御入力が存在する、請求項17に記載の制御システム。

【発明の詳細な説明】

【技術分野】

【0001】

本発明は、包括的には、機械の動作を制御することに関し、より詳細には、後退ホライズンにわたってモデル予測制御(MPC)を用いて動作を制御することに関する。

【背景技術】

【0002】

機械制御では、ソフトウェアまたはハードウェアの一方または組み合わせを用いて実施することができるコントローラが、例えば、センサーおよび/または推定器、機械の出力から取得された測定値に基づいて、この機械への入力のコマンド値を生成する。コントローラは、機械が所望のとおり動作するように、例えば、動作が所望の基準プロファイルに従うか、または出力をある特定の値に調整するように、入力を選択する。いくつかの場合には、コントローラは、例えば、対応する変数がいくつかの所定の範囲内にあることを確保して物理的仕様から安全な機械動作を確保する制約を機械の入力および出力に対して課す。そのような制約を課すために、コントローラは、多くの場合、機械のモデルを用いて、コマンド、すなわち、制御入力が印加されたときに機械がどのような挙動を引き起こすのかを予測する。制約を機械の入力および出力に対して課している間に機械の制御を達成することが可能なコントローラにおけるプロセスの1つの例は、モデル予測制御(MPC)である。

【0003】

MPCは、機械のモデルの反復的な有限ホライズン最適化に基づいており、適切な制御動作を取るために将来のイベントを予想する能力を有する。これは、制約を条件として、将来の有限時間ホライズンにわたって機械の動作を最適化し、あとは、現在のタイムスロットにわたって制御を実施するだけで達成される。例えば、制約は、機械の物理的境界、機械の動作に対する安全性境界、および軌道上の性能境界を表すことができる。機械の制御戦略は、そのような制御戦略について、機械によって引き起こされた運動が全ての制約を満たすときに許容することができる。例えば、時間 t において、機械の現在の状態がサンプリングされ、許容可能なコスト最小化制御戦略が、将来に

10

20

30

40

50

おける比較的短い時間ホライズンについて求められる。具体的には、オンライン計算またはリアルタイム計算が、時間 $t + T$ までのコスト最小化制御ストラテジーを求める。制御のステップが実施された後、状態が再びサンプリングされ、計算がその時の現在の状態から開始して繰り返され、新たな制御および新たな予測された状態パスが得られる。予測ホライズンは、前方にシフトし、この理由から、MPCは、後退ホライズン制御とも呼ばれる。

【0004】

MPCは、システムの様々な物理的制約および仕様制約を条件として、有限の将来の時間にわたって最適制御問題を解くことによって、システムのモデルおよび所望の基準軌道に基づいて、機械の運動の実際の軌道を生成するのに用いることができる。MPCは、機械の基準運動と実際の運動との間の誤差、機械のエネルギー消費、および誘発されるシステム振動等の機械の運動の性能指数を最小化することを目標とする。

10

【0005】

MPCは、モデルベースのフレームワークであるので、MPCの性能は、必然的に、最適制御計算において用いられる予測モデルの品質に依存する。しかしながら、ほとんどの場合、いくつかのパラメータは、正確に測定されないので、機械動特性のモデルは、事前には未知である。このため、コントローラは、機械がすでに動作中に、機械のモデルの未知のパラメータを推定することが必要な場合があり、このため、パラメータが推定されている間、制約を課す場合もある。そのような問題を取り扱う従来の手法は、適応型MPCまたは学習ベースのMPCを含み、これらのMPCでは、未知の機械パラメータを学習するために、MPC制御問題が、閉ループ同定方式を用いて強化される。未知のパラメータを学習することによって、コントローラによって達成される機械の動作が改善される。

20

【0006】

しかしながら、適応型MPCおよび学習ベースのMPCの現在の手法は、複数の理由のために限界がある。第1に、未知のパラメータを推定している間、制約が違反される可能性があるか、または制約を控えめに課すために、制御性能が過度に低減される場合がある。実際に、特許文献1に記載されている方法等のいくつかの既存の方法は、制約を単に無視し、このため、制約を条件として機械の許容可能な制御ストラテジーを生成することが可能でない。

30

【0007】

第2に、閉ループ同定方法をMPCコントローラに単に含めることによって生成される、所望の値への推定される未知のパラメータの収束は、遅くなる可能性がある。これは、パラメータを推定するために機械の強い励振が同定に必要とされている間、コントローラは、機械の励振を制限するので、適応型制御における一般的な問題を反映している。また、未知のパラメータを用いて制約を課す控えめな方法は、多くの場合、制約の違反を防止するために大きな励振を回避し、このため、推定値のさらに遅い収束が得られる。最後に、適応型MPCのいくつかの方法は、かなりの計算量を必要とし、高価なプロセッサにおいても低速でしか実行することができず、低い応答帯域幅を有する機械を制御することしか可能でない。

40

【先行技術文献】

【特許文献】

【0008】

【特許文献1】米国特許出願公開第2011/0022193号

【発明の概要】

【発明が解決しようとする課題】

【0009】

したがって、不確実性を含むMPCを用いて制約を受ける機械の動作を制御する方法が必要とされている。

【課題を解決するための手段】

50

【0010】

本発明のいくつかの実施の形態は、機械の動作に対する制約がモデルのパラメータの任意の許容可能な値について違反されないことを保証しつつ、機械の各状態に印加することができる制御入力の値に対する制約を用いることによって、機械の動作に対して制約を課すことと、機械のモデルのパラメータの値への高速な収束とを有するモデル予測制御(MPC)方法を提供することが可能であるという認識に基づいている。いくつかの実施の形態では、MPCの制御戦略は、制御の性能と、パラメータの推定率とを合わせて最適化する。

【0011】

いくつかの実施の形態は、機械パラメータの不確実な値の許容可能な範囲に基づいて規定されたモデルのファミリーに対して制約を課することが可能であるという認識に基づいている。このモデルのファミリーは、実現可能な状態の集合を提供する。例えば、これらの実現可能な状態の特別な部分集合は、この部分集合内の全ての状態について、それらの既知の範囲内の未知の機械パラメータの全ての値について、状態をその部分集合内に維持する実現可能な制御入力が存在するように、設計することができる。

10

【0012】

最適化された入力が状態を上記特別な部分集合内に維持するように、MPCを用いてシステムを制御することが可能であるということがさらに認識されている。これによって、MPCによって制御されるシステムは、パラメータが不確実である場合を含む全ての制約を常に満たすことが保証される。

20

【0013】

状態を上記特別な部分集合内に維持する入力の中で、制御と同定性能との間のトレードオフを最適化する入力を選ぶことができるということがさらに認識されている。構築することによって、この入力も、未知のパラメータの真の値にかかわらず、制約の充足を保証する。

【0014】

MPC予測モデルおよび制御と同定との間のトレードオフは、未知のパラメータの同定に基づいてオンラインで更新することができるということ、並びに制御と同定性能との間のトレードオフは、残っている不確実性に基づいて調整することができるということも認識されている。

30

【0015】

したがって、本発明の1つの実施の形態は、機械のモデルに従って機械の動作を制御する方法を開示する。本方法は、制御入力に対する制約を条件としたコスト関数の最適化に基づいて前記モデルを用いて求められた前記制御入力を用いて、前記機械の前記動作を反復的に制御すること、を含み、少なくとも1つの現在の反復は、前記機械の以前のモデルを用いて以前のコスト関数を最適化することによって以前の反復について求められた以前の制御入力を用いた前記制御の後に、前記機械の現在の状態を求めることと、前記機械の現在のモデルを求めて、前記現在の状態と、前記機械の前記以前のモデルを用いて推定された状態との間の相違を縮小することと、前記以前のモデルと前記現在のモデルとの間の相違に基づいて前記コスト関数を更新して、現在のコスト関数を生成することと、前記現在のモデルおよび前記現在のコスト関数を用いて前記現在の反復における前記制御の現在の制御入力を求めることと、を含み、該方法のステップは、前記機械の前記動作を制御するコントローラのプロセッサによって実行される。

40

【0016】

別の実施の形態は、機械のモデルのパラメータ間の関係を規定する公称モデルと、前記モデルの少なくとも1つのパラメータの値の範囲を規定する不確実性モデルとを含む前記モデルに従って前記機械の動作を制御する方法を開示する。本方法は、コスト関数の最適化に基づいて前記機械の前記モデルを用いて求められた制御入力を用いて、前記機械の前記動作を反復的に制御すること、を含み、前記最適化は、前記制御入力に対する制約不変制約であって、該制約不変制約を満たす前記制御入力の任意の値が、前記機械の前記

50

動作に対する制約を満たす状態の制御不変部分集合内に前記機械の状態を維持するように選択された前記制御入力に対する制御不変制約を条件とし、前記制御不変部分集合内の前記機械の任意の状態について、前記制御不変制約を満たすとともに、前記不確実性モデルによって規定された前記範囲内の前記モデルの前記パラメータの全ての値について前記機械の前記状態を前記制御不変部分集合内に維持する、許容可能な制御入力が存在し、少なくとも1つの現在の反復は、前記機械の以前のモデルを用いて以前のコスト関数を最適化することによって以前の反復について求められた以前の制御入力を用いた前記制御の結果から得られる前記機械の現在の状態を求めることと、前記機械の現在のモデルの前記パラメータの現在の値が前記値の範囲内にあるように前記現在のモデルを求めて、前記測定された現在の状態と、前記機械の前記以前のモデルを用いて推定された状態との間の相違を縮小することと、前記以前のモデルと前記現在のモデルとの間の相違に基づいて前記コスト関数を更新することであって、前記コスト関数は、前記動作の目的に従って前記制御入力の第1の値を求める第1の項を含むとともに、前記機械の前記現在の状態と前記機械のモデルを用いて推定された状態との間の前記相違を縮小する前記制御入力の第2の値を求める第2の項を含み、前記最適化は、前記第1の項および前記第2の項の組み合わせを最適化するようになっており、前記コスト関数を前記更新することは、前記組み合わせにおける前記第2の項の重みを変化させることを含むことと、前記現在のモデルおよび前記現在のコスト関数を用いて前記現在の反復における前記制御の現在の制御入力を求めることと、を含み、該方法のステップは、前記機械の前記動作を制御するコントローラのプロセッサによって実行される。

10

20

【0017】

さらに別の実施の形態は、機械のモデルに従って機械の動作を反復的に制御する制御システムを開示する。本システムは、前記モデルのパラメータ間の関係を規定する公称モデルと、前記モデルの少なくとも1つのパラメータの値の範囲を規定する不確実性モデルとを含む前記機械の前記モデル、および前記機械に対する前記制約を記憶するメモリと、少なくとも1つのプロセッサであって、前記機械の現在のモデルを用いて現在の制御入力に対する制約を条件として現在のコスト関数を最適化することによって現在の反復中の前記制御の前記現在の制御入力を求める制御入力モジュールと、前記現在のモデルの前記パラメータの現在の値が、前記値の範囲を有するとともに、前記機械の以前のモデルを用いて以前のコスト関数を最適化することによって以前の反復について求められた以前の制御入力を用いた前記制御の結果から得られた前記機械の現在の状態と、前記機械の前記以前のモデルを用いて推定された推定状態との間の相違を縮小するように、前記機械の前記現在のモデルを求めるモデル学習モジュールと、前記機械の前記現在の状態と、以前の機械状態および以前の機械制御入力から前記現在の機械モデルを用いて推定された前記機械の状態との間の相違を用いて、前記以前のコスト関数を更新するコスト関数モジュールと、を含む前記コントローラのモジュールを実行する、少なくとも1つのプロセッサと、を備える。

30

【図面の簡単な説明】**【0018】**

【図1A】本発明の1つの実施の形態による機械の動作を制御するコントローラのブロック図である。

40

【図1B】本発明の1つの実施の形態による図1Aのコントローラの一般的な構造のブロック図である。

【図2A】本発明の1つの実施の形態によるコントローラの様々なモジュールのブロック図である。

【図2B】本発明の1つの実施の形態によるコントローラのモジュールによって実行される方法のブロック図である。

【図3A】本発明のいくつかの実施の形態の原理を視覚化した座標系に配置された一例示のポリトープの概略図である。

【図3B】機械の状態に対するモデルのパラメータの不確実性の影響の概略図である。

50

【図 4 A】本発明のいくつかの実施の形態による機械の動作に対する様々な制約によって規定された状態の制御不変部分集合の 2 次元投影の一例の概略図である。

【図 4 B】本発明のいくつかの実施の形態に従って求められた、機械の状態の実現可能領域と制御不変部分集合との間の関係を示す概略図である。

【図 5】本発明の 1 つの実施の形態による制御不変部分集合を求める後方可到達領域計算のブロック図である。

【図 6】本発明の 1 つの実施の形態による状態の以前の集合を求める一例示の実施の態様のブロック図である。

【図 7】本発明の 1 つの実施の形態による状態 - 入力の組を求める方法のブロック図である。

【図 8】本発明の 1 つの実施の形態による制御不変リアプノフを求める方法のブロック図である。

【図 9】本発明の 1 つの実施の形態による候補のリアプノフ関数の状態の部分集合を求める方法のブロック図である。

【図 10 A】有効な制御不変リアプノフ関数および無効な制御不変リアプノフ関数を判断するテストの概略図である。

【図 10 B】有効な制御不変リアプノフ関数および無効な制御不変リアプノフ関数を判断するテストの概略図である。

【図 11】本発明の 1 つの実施の形態による機械のモデルを更新する方法のブロック図である。

【発明を実施するための形態】

【0019】

図 1 A は、機械 102 の動作を制御する制御システム 101 のブロック図を示している。機械 102 は、その動作が、コマンドに応答して、位置、速度、電流、温度、数値等の量を変化させる装置である。機械の動作は、本明細書において用いられるように、そのような量を変化させる機械の運動を決定する。制御システムは、上記量のうちのいくつかの所望の軌道または目標点等の機械の所望の運動 103 を受け取り、制御入力 104 を介して機械を制御する。これらの制御入力は、機械の動作のパラメータを変化させるコマンドを含むこともできるし、機械の運動に影響を与え、その結果、機械の量 105 を生成する電圧、圧力、トルク、力等のパラメータの実際の値を含むこともできる。

【0020】

制御システム 101 は、機械に直接またはリモートに接続されたセンサー、ハードウェア、またはソフトウェアから、機械の運動についての情報 106 を受信する。情報 106 は、機械の状態を含む。機械は、この状態を制御入力 104 の選択に用いる。情報 106 は、運動の量 105 のうちのいくつかまたは全てを含むことができ、機械についての追加の情報も含むことができる。量 105、制御入力 104、またはそれらの組み合わせには、機械の動作に対する制約 114 によるいくつかのあらかじめ規定された範囲内に留まるように要求することができる。

【0021】

図 1 B は、本発明の 1 つの実施の形態による制御システム 101 の一般的な構造を示している。制御システム 101 は、コントローラのモジュールを実行する少なくとも 1 つのプロセッサ 130 を備える。プロセッサ 130 は、モデル 112 および制約 114 を記憶するメモリ 120 に作動接続されている。本発明のいくつかの実施の形態の目的は、制約 114 を条件として機械 112 のモデルを用いて制御入力 104 を求めることである。いくつかの実施の形態の別の目的は、制約 114 が更新中満たされるように、機械のモデルを動作中に更新する (116) ことである。

【0022】

図 2 A は、本発明の 1 つの実施の形態による制御システム 101 の様々なモジュールのブロック図を示している。本発明のいくつかの実施の形態では、機械の MPC またはモデルは、不確実性の少なくとも 1 つのパラメータを含む。例えば、ロボットのアームのモ

10

20

30

40

50

デルは、物体をケアするアームの質量についての不確実性を含むことがある。列車の移動のモデルは、現在の天候条件における車輪とレールとの摩擦についての不確実性を含むことがある。いくつかの実施の形態では、制御システム 101 は、制御の不確実性を求めるのに用いられる。

【0023】

いくつかの実施の形態では、機械のモデルは、モデル 112 のパラメーター間の関係を規定する公称モデル 202 と、モデル 112 および / または公称モデル 202 の少なくとも 1 つのパラメーターの値の範囲を規定する不確実性モデル 203 とを含む。例えば、公称モデルのパラメーターは、当該パラメーターのデフォルト値を用いることができる。例えば、公称モデル 202 は、理想的な条件における機械の運動を記述することができる。しかしながら、機械は、摩耗、外部動作、時間および天候に起因した変動、製造プロセスにおける不完全性に起因した正確に知られていない物理量、または測定誤差等の外部の影響を受け、したがって、機械の実際の運動は、公称モデルのものと正確に同じではない。例えば、1 つの実施の形態は、公称モデルから開始して、機械状態値のシーケンスの観点から、現在のモデルが観察された機械の運動と一致するまで、現在のモデルを反復的に更新する。

10

【0024】

機械量のうちのいくつかは、機械の動作に対する制約 205 によって規定される所望の範囲内に留まる必要がある。本発明のいくつかの実施の形態は、制御入力に対する制約 206 を、不確実性モデル 203 を考慮に入れて、機械の動作に対する制約 205 から求めることができるという付加的な認識に基づいている。例えば、制御入力に対する制約 206 は、制約 206 を満たす制御入力 104 によって制御される機械 102 が、不確実性モデル 203 によって規定された許容可能な範囲内にあるモデルのパラメーターの値の全ての変動について制約 206 を満たすことを保証するように求められる。

20

【0025】

いくつかの実施の形態では、制約 206 は、オフラインで求められ、制約 205 は、機械の制御に用いられない。いくつかの実施の形態では、制約 206 は、機械を制御する少なくともいくつかの制約 205 と組み合わせて用いられる。

【0026】

いくつかの実施の形態では、制御入力 104 は、当該制御入力に対する制約 206 を条件としたコスト関数 209 の最適化に基づいて求められる。制約 206 は、制御の実現可能性を保証するので、いくつかの実施の形態は、機械の動作の目的を達成する制御と、機械のモデルのパラメーターの不確実性を低減する割合を増加させる制御との間のトレードオフのための種々の項をコスト関数に含む。

30

【0027】

例えば、コスト関数は、動作の目的に従って制御入力の第 1 の値を求める第 1 の項を含むことができ、機械の現在の状態と、機械のモデルを用いて推定された状態との間の相違を縮小する制御入力の第 2 の値を求める第 2 の項を含み、そのため、最適化は、これらの第 1 の項および第 2 の項の組み合わせを最適化し、コスト関数を更新することは、この組み合わせにおける第 2 の項の重みを変化させることを含む。

40

【0028】

したがって、いくつかの実施の形態では、制御システム 101 の様々なモジュールは、異なる制御目的について異なる項を含むコスト関数の最適化を用いて、機械の公称モデルおよび不確実性モデルによって規定された値の範囲内で機械のモデルのパラメーターを更新しながら、機械の動作の目的を満たす機械の制御を達成する。

【0029】

制御システムは、機械のモデルを記憶するメモリ 120 と、コントローラのモジュールを実行するプロセッサ 130 とを備える。モジュールは、現在のコスト関数 209 を最適化することによって現在の反復中に制御する現在の制御入力 104 を求める制御入力モジュール 208 を含む。この制御入力モジュールは、現在の制御入力に対する制約 206 を

50

条件として、機械の現在のモデル 2 0 1 を用いて現在のコスト関数を最適化する。

【 0 0 3 0 】

制御システムは、機械の現在のモデル 2 0 1 を求めるモデル学習モジュール 2 0 4 も備える。このモデル学習モジュールは、現在のモデルのパラメータの現在の値が、公称モデル 2 0 2 および不確実性モデル 2 0 3 によって規定された値の範囲を有するとともに、機械の以前のモデルを用いて以前のコスト関数を最適化することによって以前の反復の間に求められた以前の制御入力を用いて制御した結果得られた機械の現在の状態 1 0 6 と、機械の以前のモデルを用いて推定された推定状態 2 1 6 との間の相違を縮小するようになっている。

【 0 0 3 1 】

コントローラは、現在のコスト関数 2 0 9 を求めるコスト関数モジュール 2 0 7 も備える。例えば、コスト関数モジュールは、以前のモデルと現在のモデルとの間の相違を用いて以前のコスト関数を更新し、現在のコスト関数を生成する。制御のステップは、反復的に実行されるので、現在のモデルおよび現在のコスト関数は、後続の反復については以前のモデルおよび以前のコスト関数になる。例えば、以前のモデル、以前のコスト関数、および以前の制御入力は、以前の反復においては、現在のモデル、現在のコスト関数、および現在の制御入力として求められる。

【 0 0 3 2 】

図 2 B は、制御システム 1 0 1 のモジュールによって実行される方法のブロック図を示している。本方法は、コスト関数の最適化に基づいて機械のモデルを用いて求められた制御入力を用いて、機械の動作を反復的に制御する (2 7 0)。本方法は、機械の以前のモデルを用いて以前のコスト関数を最適化することによって以前の反復について求められた以前の制御入力を用いた制御の結果から得られる機械の現在の状態を求める (2 1 0)。

【 0 0 3 3 】

本方法は、測定された現在の状態と、機械の以前のモデルを用いて推定された状態との間の相違を縮小する機械の現在のモデルを、この現在のモデルのパラメータの現在の値が上記値の範囲を有するように調整し (2 2 0)、以前のモデルと現在のモデルとの間の相違に基づいてコスト関数を更新する (2 3 0)。この更新 2 3 0 は、機械の動作の目的を達成する制御と、機械のモデルのパラメータの不確実性を低減する割合を増加させる制御との間のトレードオフを提供する。

【 0 0 3 4 】

いくつかの実施の形態では、コスト関数は、動作の目的に従って制御入力の第 1 の値を求める第 1 の項を含むとともに、機械の現在の状態と機械のモデルを用いて推定された状態との間の相違を縮小する制御入力の第 2 の値を求める第 2 の項を含み、最適化は、第 1 の項および第 2 の項の組み合わせを最適化する。それらの実施の形態では、コスト関数は、その組み合わせにおける第 2 の項の重みを変化させることによって更新される。例えば、以前のモデルと現在のモデルとの間の相違が小さいほど、組み合わせにおける第 2 の項の重みは、低減される。

【 0 0 3 5 】

次に、本方法は、現在のモデルおよび現在のコスト関数を用いて、現在の反復における制御のための現在の制御入力を求める (2 8 0)。例えば、本方法は、更新された現在のコスト関数および現在の機械モデルを用いて、現在の時刻から、少なくとも新たな機械状態の測定値を取得するのに十分な長さの将来の固定時間量の中の将来の入力のシーケンスを、予測された将来の機械状態および入力が制御入力に対する制約を満たすように求める (2 4 0)。機械の状態の新たな測定値を取得するのに必要とされる時間量に等しい継続期間の間に入力シーケンスの第 1 の部分は、現在の制御入力として機械に印加される (2 5 0)。機械の現在の状態、機械の現在のモデル、および機械への現在の制御入力に基づいて、機械の次の状態が求められ (2 6 0)、コントローラは、新たな状態測定値が受信されるまで待機する (2 7 0)。

【 0 0 3 6 】

10

20

30

40

50

不確実性モデリング

本発明のいくつかの実施の形態は、モデルのパラメータの真の値が不確実であっても、モデルのパラメータの不確実性が既知の範囲内にあるという認識に基づいている。例えば、列車の質量は、空の列車および一杯に荷を積んだ列車の値の範囲内とすることができる。同様に、モデルのパラメータの値に対する外乱には、限界が存在するとすることができる。不確実性モデル 203 は、公称モデルおよび不確実性モデルの組み合わせを用いて MPC の機械の現在のモデルを求めることができるように、モデルの少なくとも 1 つのパラメータの可能な値の範囲を表す。

【0037】

図 3 A は、上記認識の原理を視覚化した座標系 320 に配置された一例示のポリトープ 310 を示している。座標系 320 は、通常、不確実性を有するモデルのパラメータの低次元系である。例えば、モデルが、不確実性を有する 4 つのパラメータを含む場合、座標系 320 は、4 次元であり、パラメータの組み合わせの新たな値、例えば、値 333、335、337 がポリトープ 310 内で選択されるように、パラメータのそれぞれにつき、1 つの次元 322、324、326、および 328 を有する。

【0038】

例えば、所与の機械状態、入力、および不確実性の組み合わせった影響を表す外乱 d の連立差分方程式によって、等時間間隔のサンプリング時点における機械の運動を記述する関数は、以下の式となる。

【数 1】

$$\begin{aligned} x(k+1) &= f(x(k), u(k), d(k)) \\ y(k) &= Cx(k) \end{aligned} \quad (1)$$

ここで、 k はサンプリング時点のインデックスであり、 f は汎用関数であり、 C は行列であり、 x は機械状態 106 であり、 u は機械入力 104 であり、 y は機械出力 105 である。外乱の状況の数は、範囲 D 内に制限され、状態は範囲

【数 2】

\mathcal{X}
内に制限され、制御入力は、範囲 U 内に制限されることが了解されている。

【数 3】

$$x \in \mathcal{X}, u \in U, d \in D \quad (2)$$

【0039】

例えば、値の範囲 D は、機械質量の最小値および最大値、外力の最小値および最大値によって求めることができる。同様に、入力および状態の範囲は、速度、位置、電圧、またはトルクの最小値および最大値によって求めることができる。

【0040】

いくつかの実施の形態は、 f および D に基づいて、それぞれ

【数 4】

$$\{(A_i, B_i)\}_{i=1}^{\ell}, B_w, W \quad (3)$$

である行列の集合、加法線形外乱行列、および加法性外乱の多面体集合を構築し、この結果、任意の所与の x および u について、

【数 5】

$$\text{co}\{A_i x + B_i u\}_{i=1}^{\ell} \oplus \text{co}\{B_w w_i\}_{i=1}^{\eta} \supseteq f(x, u, d), \forall d \in D \quad (5)$$

となるような多元差分包含

【数 6】

$$\text{co}\{A_i x + B_i u\}_{i=1}^{\ell} \oplus \text{co}\{B_w w_i\}_{i=1}^{\eta} \quad (4)$$

が得られる。ここで、

【数 7】

$$W = \text{co}\{w_i\}_{i=1}^{\eta}$$

であり、 w_i は W の頂点であり、「co」はこの集合の凸包を示すようになっている。

【0041】

式(4)における線形モデルは、例えば、 D によって許容されるベクトル d を形成するパラメータおよび/またはそれらの組み合わせの最大値および最小値を選ぶことによって求めることができる。

【0042】

図3Bは、機械の状態を推定する際の、式(4)によって求められたモデルのパラメータの不確実性の影響の概略図を示している。機械の現在の状態 x_{301} および制御入力を与えられると、機械の次の状態は、機械のモデルのパラメータの d の種々の可能な値について、集合 302 内で変動する可能性がある。例えば、ベクトル d の特定の値に応じて、状態 301 は、制御入力の同じ値について集合 302 内で異なる状態 310 に遷移する可能性がある。

【0043】

本発明のいくつかの実施の形態では、不確実性モデルは、公称モデルおよび不確実性モデルの組み合わせが、加法性外乱の凸結合を有する線形モデルの凸結合 303 に含まれるように拡張される。例えば、 $W = 0$ のとき、式(4)のモデルは、有界多面体、すなわちポリトープである集合 303 によって集合 302 を過剰近似する。ここで、頂点 304 は、以下の式から求められる。

【数 8】

$$v_i = A_i x + B_i u, i = 1 \dots \ell \quad (6)$$

ここで、 1 、 (A_i, B_i) 、 $i = 1 \dots \ell$ は、それぞれ、式(3)において規定された数および行列である。 $W = 0$ である実施の形態では、集合 303 は、集合

【数 9】

$$\text{co}\{B_w w_i\}_{i=1}^{\eta}$$

の凸包から取得された和集合である。

【0044】

式(4)に基づいて、全てが

【数 10】

$$A_i x + B_i u + B_w w_j \in \mathcal{X}, i = 1 \dots \ell, j = 1 \dots \eta \quad (7)$$

を満たす範囲

【数 11】

\mathcal{U}

内の入力 u によって、集合 303 は、完全に、許容可能な状態の範囲 320 内となり、したがって、(1)による機械の可能な次の状態 302 も 320 内になる。このため、式(4)に対して制約を課すことによって、式(1)に対して制約を課することが保証される。式(4)によって求められたモデルを用いる実施の形態は、計算上有利である。なぜならば、式(4)によって求められたモデルは、式(1)に記述された不確実な非線形モデルではなく、線形モデルの集合を含むからである。

【0045】

機械への制御入力に対する制約

本発明のいくつかの実施の形態は、機械の運動に対する制約が、所定の範囲内のモデルのパラメータの値の全ての変動について、機械の動作中満たされることを保証するために、状態の実現可能領域

10

20

30

40

50

【数 1 2】

X の部分集合を、機械の状態がそのような部分集合内にあるときは、常に、その状態がパラメータの全ての可能な値および外乱について、その部分集合内に留まるような少なくとも1つの許容可能な制御入力が存在するように求めることができるという認識に基づいている。部分集合内に留まることによって、その部分集合は、実現可能領域

【数 1 3】

X に含まれるので、全ての機械の運動制約が満たされる。

【0 0 4 6】

本発明のいくつかの実施の形態は、本明細書において制御入力に対する制御不変制約と呼ばれる制御入力に対するそのような制約を求めて用い、本明細書において状態の制御不変部分集合と呼ばれる状態の実現可能領域

【数 1 4】

X のそのような部分集合内に機械の状態を維持する制御入力を求める。この構成によって、制御不変制約を満たす制御入力は、不確実性モデルによって規定された範囲内のモデルのパラメータの全ての値について、機械の状態を、機械の動作に対する制約を満たす状態の制御不変部分集合内に維持する。

【0 0 4 7】

図 4 A は、本発明の実施の形態による、機械の動作に対する様々な制約によって規定された状態の制御不変部分集合の 2 次元投影 4 1 0 の一例を示している。通常、この実現可能領域は、動作に対する制約に対応する複数の次元に沿って、1 次不等式によって表される超平面によって決定された多次元ポリトープである。

【0 0 4 8】

後退ホライズン制御の性質に起因して、ある特定のホライズンの解が存在することは、それだけで、後続のホライズンの解が存在することを保証するものではない。例えば、機械の状態および基準軌道の状態 4 2 0 は、1 つの反復にとって最適かつ実現可能である可能性があるが、コントローラが次の反復中に取りることが可能な全ての制御動作 4 2 1 ~ 4 2 4 は、機械の状態を実現可能領域 4 1 0 の外部に持っていく可能性がある。

【0 0 4 9】

本発明のいくつかの実施の形態は、実現可能領域の制御不変部分集合 4 1 5 を、その制御不変部分集合内の機械の任意の状態から、基準軌道の既知の将来の状態または基準軌道の全ての許容可能な将来の状態について、その部分集合内に機械の状態を維持する制御入力が存在するように選択することが可能であるというさらに別の認識に基づいている。例えば、部分集合 4 1 5 内およびコントローラが実行することができる全ての可能な制御入力 4 3 1 ~ 4 3 4 内の状態 4 3 0 等の任意の状態について、機械および基準の状態を部分集合 4 1 5 内に維持する少なくとも1つの制御入力 4 3 4 が存在する。この場合、部分集合 4 1 5 は、制御不変部分集合である。

【0 0 5 0】

いくつかの実施の形態は、制御不変部分集合内の状態ごとに、式 (5) による全ての可能な状態値について、機械の状態を制御不変部分集合内に維持する少なくとも1つの制御動作が存在するように、式 (4) のモデルの状態の制御不変部分集合を求める。

【0 0 5 1】

図 4 B は、機械の状態の実現可能領域 4 0 1 と、

【数 1 5】

X 内における式 (1) による不確実性を有するモデルの状態の最も大きいロバスト制御不変部分集合 4 0 2 との関係を示している。いくつかの実施の形態では、制御不変部分集合 4 0 2 は、この部分集合 4 0 2 よりも小さいが、線形方程式によって形成されるより単

10

20

30

40

50

純な形状を有する制御不変 4 0 3 を形成するように縮小される。部分集合 4 0 2 は、非線形方程式によって求められるので、部分集合 4 0 2 の形状は、非凸である可能性がある。このように、4 0 3 の計算は、より単純で、より効率的であり、制御目的に有利である。

【 0 0 5 2 】

図 5 は、本発明の 1 つの実施の形態による実現可能領域

【 数 1 6 】

\mathcal{X}

4 0 1 から開始してロバスト制御不変部分集合 4 0 3 を求める後方可到達領域計算のブロック図を示している。後方可到達領域計算は、ロバスト制御不変部分集合 C_x を求めるとともに、制御不変集合 $C_u(x)$ も求める。この計算は、 C_x 内の任意の x について、印

10

【 数 1 7 】

\mathcal{U}

内の入力 u の集合を、(4) による全ての可能な次の状態が C_x の内部となるように求める。

【 0 0 5 3 】

後方可到達領域計算は、現在の集合

【 数 1 8 】

\mathcal{X}_c

を実現可能集合

20

【 数 1 9 】

\mathcal{X}

に初期化し (5 0 1)、 P 内のパラメータ p の全ての可能な値について、更新された状態が現在の集合

【 数 2 0 】

\mathcal{X}_c

内となるような

【 数 2 1 】

\mathcal{U}

内の入力 u が、

【 数 2 2 】

\mathcal{X}_p

内の全ての状態 x について存在するように、状態の以前の集合

【 数 2 3 】

\mathcal{X}_p

を、現在の集合

40

【 数 2 4 】

\mathcal{X}_c

の部分集合として求める (5 0 2)。

【 0 0 5 4 】

5 0 3 において、以前の集合

【 数 2 5 】

\mathcal{X}_p

が空である場合 (5 0 4)、コントローラの正しい動作を保証することができない。これは、パラメータの可能な値の集合 P のサイズが、場合によっては機械の動作の設計または目的を変更することによって、縮小されるべきであることを意味する。5 0 5 において

50

、現在の集合と以前の集合とが等しい場合には、以前の集合が現在の集合となるように割り当てられ (5 0 7)、計算が再び反復され (5 0 8)、等しくない場合には、5 0 6 において、集合 C_x も計算される。集合 C_x が見つかった場合、状態 - 入力対の最後に計算された集合が、 C_x 内の全ての x についてのロバスト許容可能入力集合 $C_u(x)$ である。

【 0 0 5 5 】

図 6 は、1つの実施の形態による状態の以前の集合を求める (5 0 2) 一例示の実施の態様のブロック図を示している。この実施の形態は、パラメーターの全ての値について現在の集合内にある更新された状態を生成する状態 - 入力対を特定し (6 0 1)、これらの状態入力対を状態値に投影する (6 0 2)。すなわち、この実施の形態は、そのような状態 - 入力対のうち少なくとも 1 つに属する状態を特定する。

10

【 0 0 5 6 】

図 7 は、1次不等式が集合

【 数 2 6 】

\mathcal{X}
および

【 数 2 7 】

\mathcal{U}

を記述しているときの状態 - 入力の対の計算 (6 0 1) の方法のブロック図を示している。本方法は、現在の集合を以下の式とみなし、

20

【 数 2 8 】

$$H^{(c)}x \leq K^{(c)} \tag{8}$$

現在の集合に対する加法性外乱 w の最悪の場合の影響

【 数 2 9 】

$$i. \quad [S]_i = \max_{w \in \mathcal{W}} [H^{(c)}B_w w]_i, \quad i = 1, \dots, n_q^{(c)} \tag{9}$$

を求める (7 0 1)。ここで、 $H^{(c)}$ は、(8) において規定された現在の集合を記述する行列であり、

30

【 数 3 0 】

$n_q^{(c)}$

は、現在の集合の行列 $H^{(c)}$ の行の数である。

【 0 0 5 7 】

次に、本方法は、これらの最悪の場合の外乱の影響分だけ現在の集合を縮小して (7 0 2)、

【 数 3 1 】

$$H^{(c)}x \leq K^{(c)} - S_i \tag{10}$$

40

によって記述される縮小された現在の集合

【 数 3 2 】

\mathcal{X}_s

を生成し、次いで、更新された状態が (1 8) における全ての頂点系について現在の集合の内部になるような、すなわち、

【 数 3 3 】

$$A_i x + B_i u \in \mathcal{X}_s, \forall i = 1, \dots, \ell$$

となるような対 (x, u) を求める (7 0 3)。

【 0 0 5 8 】

安定性制約

50

本発明のいくつかの実施の形態では、制御入力に対する制約は、公称モデルおよび不確定性モデルによって規定された機械のモデルのパラメータの全ての値について、機械の状態を目標値に収束させる安定性制約を含む。1つの実施の形態では、これらの安定性制約は、機械の制御リアプノフ関数を含む。例えば、式(4)のモデルの制御リアプノフ関数(CLF)は、以下の実現可能値低減を満たす関数である。

【数34】

$$V(f(x, u)) \leq \rho V(x) \tag{11}$$

ここで、fは、式(4)のモデルであり、は、所望の目標においては0であり、それ以外のあらゆる箇所においては正である関数であり、は、0~1の値である。

10

【0059】

いくつかの実施の形態では、制御リアプノフ関数は、制御不変である。本明細書において規定されているように、有効な不変制御リアプノフ関数は、例えば、式(4)のモデルについて求められた制御不変部分集合C_xの内部の全てのxについて、C_u(x)の内部に制御入力uが存在するような制御リアプノフ関数、すなわち、式(11)が満たされるように制御不変制約を満たす制御リアプノフ関数である。

【0060】

図8は、本発明の1つの実施の形態による制御システムの不変制御リアプノフ関数を求める方法を示している。本方法は、候補のCLFを生成し(801)、この候補のCLFの状態の部分集合を、式(11)が有効であるように

20

【数35】

U

の内部にuが存在するようなC_xの部分集合として求める(802)。次に、本方法は、部分集合802が部分集合C_xに等しいか否かを検証する(803)。これに該当する場合(804)、候補のCLFは、制御不変リアプノフ関数であり、そうでない場合(805)、異なる候補のCLFが生成される。

【0061】

図9は、(x) = ||Px|| である1つの実施の形態による、候補のリアプノフ関数の状態の部分集合を求める(802)方法のブロック図を示している。ここで、Pは、n_p個の行を有する無限ノルム制御リアプノフ関数を記述した行列である。この実施の形態は、行列Pのこれまでに選択されていない行911を選択し(901)、正の条件 = +1について、不等式

30

【数36】

$$\begin{aligned} \varepsilon &\geq [P(A_i x + B_i u)]_j, \forall j = 1, \dots, n_p, \forall i = 1, \dots, \ell \\ \varepsilon &\geq -[P(A_i x + B_i u)]_j, \forall j = 1, \dots, n_p, \forall i = 1, \dots, \ell \\ \varepsilon &\leq \rho [Px]_r \\ \sigma [Px]_r &\geq [Px]_h, \forall h = 1, \dots, n_p, \\ \sigma [Px]_r &\geq -[Px]_h, \forall h = 1, \dots, n_p, \end{aligned} \tag{12}$$

40

が = +1の場合に当てはまるようなuおよびが存在するようにxの集合を計算することによって、行911に関係した部分集合の凸成分を求める(902)。ここで、n_pは、行列Pの行の数である。

【0062】

次に、この実施の形態は、負の条件 = -1について、行911に関係した部分集合の凸成分を求め(903)、-1は、(12)がこの時は = -1で満たされるようなuおよびが存在するようにxの集合として計算される。全ての行が選択されると、全ての凸成分の和集合は、部分集合802を形成する。

【0063】

50

図10Aおよび図10Bは、有効な制御不変リアブノフ関数および無効な制御不変リアブノフ関数を判断するテストの説明図を示している。制御不変部分集合1001内の部分集合1002は、部分集合1003が候補のCLFの複数の凸成分1003の和集合である場合に有効である。図10Aでは、部分集合1002および1001が異なるので、CLFは、制御不変ではない。図10Bでは、部分集合1004が部分集合1001のエリア全体を包含することから、有効な部分集合1004を有する候補のCLFが部分集合1001について有効であるので、CLFは、制御不変である。

【0064】

例えば、本発明の1つの実施の形態では、制御リアブノフ関数は、制御不変制約を満たす機械の全ての状態について実現可能値低減テストを満たす無限ノルム制御リアブノフ関数である。このテストは、無限ノルム制御リアブノフ関数を記述する行列の行を選択することと、制御不変制約を満たす機械の少なくとも1つの入力について無限ノルム制御リアブノフ関数を記述する行列の行に対する実現可能値低減を、正の条件および負の条件について満たす機械の状態の凸成分を求めることを含むことができる。次に、この実施の形態は、これらの凸成分の和集合を求め、機械の状態の制御不変部分集合内の機械の全ての状態が凸成分の和集合に含まれることを検証する。

10

【0065】

モデル学習

1つの実施の形態では、機械の現在のモデル201は、公称モデル202に基づいて初期化される。この初期化では、一对の推定されたシステム行列

20

【数37】

$$(\hat{A}, \hat{B})$$

が、式(3)における行列の集合の凸包から選択され、

【数38】

$$(\hat{A}, \hat{B}) \in \text{co}\{(A_i, B_i)\}_{i=1}^{\ell} \quad (13)$$

加法性外乱推定値

【数39】

$$\hat{w}$$

が、式(3)における加法性外乱の多面体集合から選択される。

30

【数40】

$$\hat{w} \in \mathcal{W} \quad (14)$$

【0066】

式(13)~(14)における現在のモデルは、現在のモデルが、機械状態値のシーケンスの観点から、観察された機械の運動と一致するまで、入力104および状態106を用いて各時間ステップにおいて、そのそれぞれの集合内で更新される。

【0067】

1つの実施の形態では、このモデル更新の実施の態様は、(13)および(14)におけるモデルを、式(6)の頂点とWの頂点との線形結合であるとみなす。

40

【数41】

$$\hat{A}x + \hat{B}u + B_w \hat{w} = \sum_{i=1}^{\ell} [\theta]_i (A_i x + B_i u) + \sum_{i=1}^p [\eta]_i B_w w_i \quad (15)$$

ここで、 $[\theta]$ は、線形モデルの組み合わせベクトルであり、 $[\eta]$ は、加法性外乱の組み合わせベクトルである。

【数 4 2】

$$\theta \in \mathbb{R}^\ell, 0 \leq [\theta]_i \leq 1, \sum_i [\theta]_i^\ell = 1$$

$$\eta \in \mathbb{R}^p, 0 \leq [\eta]_i \leq 1, \sum_i [\eta]_i^p = 1$$

(15b)

そのため、結合パラメータベクトル

【数 4 3】

$$\lambda = [\theta \quad \eta]^\top$$

(16)

について、線形回帰モデルを形成することができる。

【0068】

この線形回帰モデルは、以下の形を取る。

【数 4 4】

$$y = \sum_{i=1}^{\ell} [\theta]_i (A_i x + B_i u) + \sum_{i=1}^p [\eta]_i B_w w_i + \epsilon,$$

$$= \Gamma(x, u)\theta + \Upsilon\eta + \epsilon,$$

$$= M^\top(x, u)\lambda + \epsilon,$$

(17)

ここで、 ϵ は、測定雑音を表し、

【数 4 5】

$$\Gamma(x, u) = [A_1 x + B_1 u, \dots, A_\ell x + B_\ell u]$$

$$\Upsilon = [B_w w_1, \dots, B_w w_p]$$

$$\text{and } M^\top(x, u) = [\Gamma(x, u) \quad \Upsilon]$$

(18)

である。

【0069】

線形回帰 (17) は、この場合、いくつかの方法によって解くことができる。例えば、1つの実施の形態は、回帰の出力 $y = [\dots]^\top$ が、(15b) によるその許容された範囲内にあることを確実にするように修正された再帰的最小二乗 (RLS) 方法を用いる。

【0070】

例えば、RLS方法は、以下の式の解を含むことができる。

【数 4 6】

$$\Psi(t+1) = (I - \mathcal{K}_{\text{RLS}}(t+1)M^\top(x(t), u(t))) \Psi(t)$$

$$\mathcal{K}_{\text{RLS}}(t+1) = \Psi(t+1)M(x(t), u(t)),$$

$$\hat{\lambda}(t+1) = \hat{\lambda}(t) + \mathcal{K}_{\text{RLS}}(t+1) \left(y(t+1) - M^\top(x(t), u(t))\hat{\lambda}(t) \right),$$

$$\hat{\lambda}(t+1) = \text{proj}_\lambda(\hat{\lambda}(t+1))$$

(18b)

ここで、 \mathcal{K}_{RLS} は、推定訂正利得であり、 Ψ は、推定共分散行列であり、 proj_λ は、その引数を λ のドメイン内に投影する演算子である。

10

20

30

40

50

【 0 0 7 1 】

図 1 1 は、本発明の 1 つの実施の形態に従って、修正された R L S を用いて機械のモデルを更新し、機械の現在のモデルを生成するブロック図を示している。各ステップにおける修正された R L S は、以前の入力および以前の状態を用いてリグレッサー行列 M を形成する (1 1 0 1) とともに、現在の時間ステップの状態を測定値 y として用いる。修正された R L S は、予測誤差共分散行列 を更新し (1 1 0 2)、推定利得 を更新する (1 1 0 3)。

【 0 0 7 2 】

次に、修正された R L S は、パラメーターの第 1 の推定値

【 数 4 7 】

10

$$\hat{\lambda}(t+1)$$

を求め (1 1 0 4)、パラメーターの第 1 の推定値を、(1 5 b) によって求められた $= [\quad]^T$ の許容可能な範囲上に投影することによってパラメーターの第 2 の推定値

【 数 4 8 】

$$\hat{\lambda}(t+1)$$

を求める (1 1 0 5)。次に、修正された R L S は、次の測定まで待機する (1 1 0 6)

。

【 0 0 7 3 】

20

第 2 のパラメーター推定値は、複数の方法で求めることができる (1 1 0 5)。例えば、1 つの実施の形態は、まず、パラメーターの第 1 の推定値

【 数 4 9 】

$$\hat{\lambda} = [\hat{\theta} \quad \hat{\eta}]^T$$

の各成分を 0 と 1 との間にサチュレートさせ、次いで、パラメーターの第 1 の推定値における

【 数 5 0 】

$$\hat{\theta}$$

30

および

【 数 5 1 】

$$\hat{\eta}$$

の各成分を、当該パラメーターの第 1 の推定値における

【 数 5 2 】

$$\hat{\theta}$$

および

【 数 5 3 】

$$\hat{\eta}$$

40

のサチュレートされた成分の合計により除算することによって、それらの各成分を正規化することで、第 2 のパラメーターを求める。この結果、現在の時間ステップにおけるパラメーターベクトル (1 6) の推定値が得られ、それによって、(1 3) および (1 4) における現在のモデルの更新された推定値が与えられる。他の実施の形態では、他の回帰モデルおよび / または推定アルゴリズムが、(1 3) および (1 4) に基づいて機械の現在のモデル 2 0 1 を更新するのに用いられる。

【 0 0 7 4 】

コスト関数

50

本発明のいくつかの実施の形態では、コスト関数モジュール 207 は、公称コスト関数に基づいて現在のコスト関数 209 を初期化する。1つの実施の形態では、この公称コスト関数は、多面的であり、相反する目的を有する。例えば、コスト関数は、動作の目的に従って制御入力第 1 の値を求める第 1 の項を含むことができるとともに、機械の現在の状態と、機械のモデルを用いて推定された状態との間の相違を縮小する制御入力第 2 の値を求める第 2 の項を含み、そのため、最適化は、これらの第 1 の項および第 2 の項の組み合わせを最適化し、コスト関数を更新することは、この組み合わせにおける第 2 の項の重みを変化させることを含む。

【0075】

1つの実施の形態では、コスト関数は、以下の式の形を取る。

【数54】

$$F_t(x_N) + \sum_{k=1}^N L_t(x_k, u_k, P_k) \quad (19)$$

ここで、 F_t および L_t は、機械の状態にバイアスをつけるそれらの引数と、多面的な目的を反映した値への入力との関数であり、 P_k は、RLS アルゴリズムからの予測されたパラメータ誤差共分散行列である。1つの実施の形態では、 L_t は、機械の状態およびモデルのパラメータを学習する目的の二元的な客観的取引規則を含む。例えば、コスト関数の第 1 の項は、機械の性能に関係し、第 2 の項は、モデルのパラメータの推定を改善することに関係し、第 2 の項は、現在のモデルの予測誤差の非負の非減少関数として測定された機械の現在のモデルの信頼性によって重み付けされる。

【0076】

1つの実施の形態では、関数 L_t は、以下の式となる。

【数55】

$$L_t(x_k, u_k, P_k) = x_k^T Q x_k + u_k^T R u_k + \gamma \left(y(t) - M^T(x(t-1), u(t-1)) \hat{\lambda}(t-1) \right) \psi(P_k)$$

ここで、 ψ は、現在のモデル 201 によって予測された状態と、測定された実際の状態 106 との間の残余誤差の関数であり、 $\psi(P_k)$ は、予測されたパラメータ誤差共分散行列の情報汎関数である。

【0077】

この情報汎関数は、未知のパラメータベクトル (16) と関連付けられた情報の尺度である。この例には、トレース、行列式、および最大固有値が含まれる。情報汎関数が、コスト関数において優先権を与えられた場合、すなわち、 $\psi(P_k)$ が大きい場合、機械の状態および入力には、モデル学習を改善する値に向けてバイアスがかけられ、そうでない場合、状態および入力には、機械の状態の調整に向けてバイアスがかけられる。

【0078】

現在のコスト関数 (19) は、残余誤差が大きいときは、コスト関数がモデル学習の改善のみを試みるように、各時間ステップにおいて、現在のモデルによって予測された状態および測定された実際の状態を用いて更新される。例えば、コスト関数の第 2 の項は、以前のモデルと現在のモデルとの間の相違の関数を含み、更新することは、以前のモデルと現在のモデルとの間の相違を求め、求められた相違を用いてコスト関数の第 2 の項を更新する。

【0079】

別の実施の形態では、コスト関数は、入力計算 208 に用いられる 2 つのコスト関数に分離される。ここで、第 1 のコスト関数は、モデル学習にのみ関係があり、すなわち、 $F_t = 0$ および $L_t = \psi(P_k)$ であり、第 2 のコスト関数は、機械の状態および第 1 のコスト関数の適用によって生成された入力シーケンスからの逸脱にペナルティを科すことの二元的な客観的取引規則を形成する。

10

20

30

40

50

【 0 0 8 0 】

入力計算

いくつかの実施の形態では、入力計算 2 0 8 は、以下の式の有限ホライズン数値最適化問題の形を取る。

【数 5 6】

$$\min_U F_t(x_N) + \sum_{k=1}^N L_t(x_k, u_k, P_k),$$

$$\text{s.t. } x_{k+1} = M^T(x_k, u_k)\hat{\lambda}(t),$$

$$x_0 = x(t),$$

$$P_0 = P(t),$$

$$u_k \in C_u^\infty(x_k),$$

(20)

10

この式は、現在のコスト関数 (F_t および L_t) 2 0 7 と、ホライズンにわたって状態の展開を予測する現在のパラメーター推定値

【数 5 7】

 $\hat{\lambda}$

を有する機械モデル 2 0 1 と、ロバスト制約

【数 5 8】

$$C_u^\infty(x_k)$$

2 0 6 と、現在の時間ステップにおける状態 $x(t)$ とから形成されている。問題 (2 0) は、問題制約を条件として現在のコスト関数を最小化する入力シーケンス $U = [u_1, \dots, u_N]^T$ を見つけ出す数値ソルバーを用いて解かれる。この入力シーケンスにおける第 1 の入力 u_1 は、入力計算 2 0 8 の出力とみなされ、機械 1 0 2 に印加される。次の時間ステップ $t + 1$ において、モデルおよびコスト関数が更新され、状態が更新され、数値最適化問題が再び解かれる。

20

30

【 0 0 8 1 】

代替の実施の形態では、問題 (2 0) は、以下の 2 つのフェーズに分解される。

i) モデル学習フェーズ、例えば、 $L_t = (P_k)$ 。このフェーズは、予測されたパラメーター誤差共分散行列の情報汎関数を最小化する入力シーケンスを生成することのみに関係する。

ii) 制御フェーズ。このフェーズは、機械を起点に調整する入力シーケンスを生成することのみに関係し、例えば、以下の式である。

【数 5 9】

$$L_t = x_k^T Q x_k + u_k^T R u_k$$

【 0 0 8 2 】

モデル学習フェーズから制御フェーズへの切り替えは、現在のモデル 2 0 1 によって予測された状態と測定された実際の状態 1 0 6 との間の残余誤差に基づく。すなわち、この誤差が、設定された閾値未満であるとき、モデル学習は、もはや必要ではなく、制御フェーズへの切り替えが実施される。モデル学習フェーズへの戻し切り替えは、上記誤差が、設定された閾値を上回った場合に実施される。

40

【 0 0 8 3 】

本発明の上記で説明した実施の形態は、数多くの方法のうちの任意のもので実施するこ

50

とができる。例えば、これらの実施の形態は、ハードウェア、ソフトウェア、またはそれらの組み合わせを用いて実施することができる。ソフトウェアで実施されるとき、ソフトウェアコードは、単一のコンピューターに設けられるかまたは複数のコンピューター間に分散されるかを問わず、任意の適したプロセッサまたはプロセッサの集合体上で実行することができる。そのようなプロセッサは、集積回路コンポーネントに1つまたは複数のプロセッサを有する集積回路として実施することができる。ただし、プロセッサは、任意の適した形式の回路部を用いて実施することができる。

【0084】

さらに、コンピューターは、ラックマウントコンピューター、デスクトップコンピューター、ラップトップコンピューター、ミニコンピューター、またはタブレットコンピューター等の複数の形態のうちの任意のもので具現化することができることが理解されるべきである。そのようなコンピューターは、エンタープライズネットワークまたはインターネット等のローカルエリアネットワークまたはワイドエリアネットワークを含む1つまたは複数のネットワークによって任意の適した形態に相互接続することができる。そのようなネットワークは、任意の適した技術に基づくことができ、任意の適したプロトコルに従って動作することができ、無線ネットワーク、有線ネットワーク、または光ファイバーネットワークを含むことができる。

10

【0085】

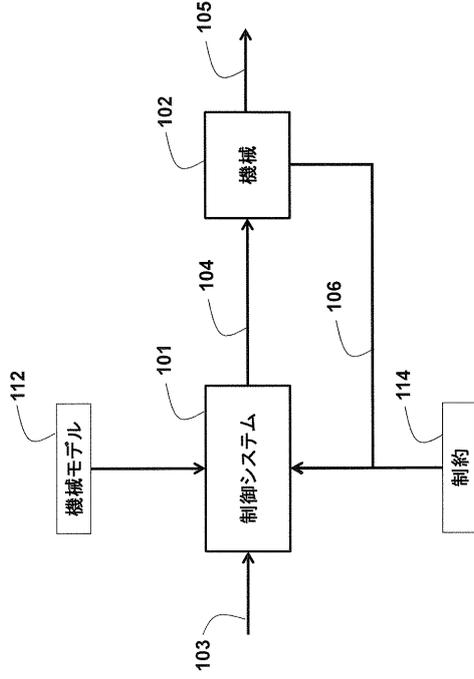
また、本明細書において略述した様々な方法またはプロセスは、様々なオペレーティングシステムまたはプラットフォームのうちの任意の1つを用いる1つまたは複数のプロセッサ上で実行可能なソフトウェアとしてコード化することもできる。加えて、そのようなソフトウェアは、複数の適したプログラミング言語および/またはプログラミングツールもしくはスクリプティングツールのうちの任意のものを用いて記述することができる。

20

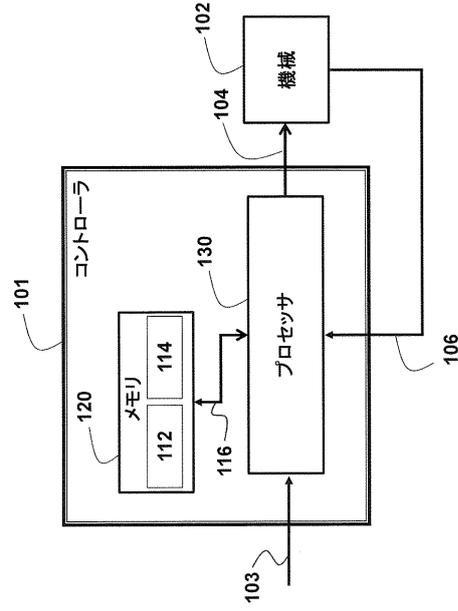
【0086】

また、本発明の実施の形態は、方法として具現化することもできる。この方法の一例が提供されている。この方法の一部として実行されるステップは、任意の適した方法で順序付けることができる。したがって、例示されたものと異なる順序で動作が実行される実施の形態を構築することができ、これらの実施の形態は、いくつかの動作を、例示の実施の形態では順次的な作用として示されていても、同時に実行することを含むことができる。

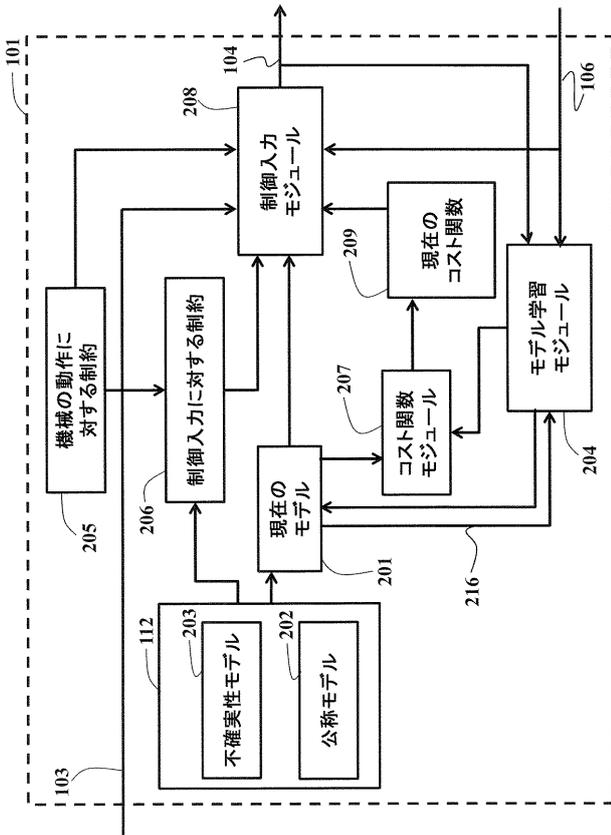
【図 1 A】



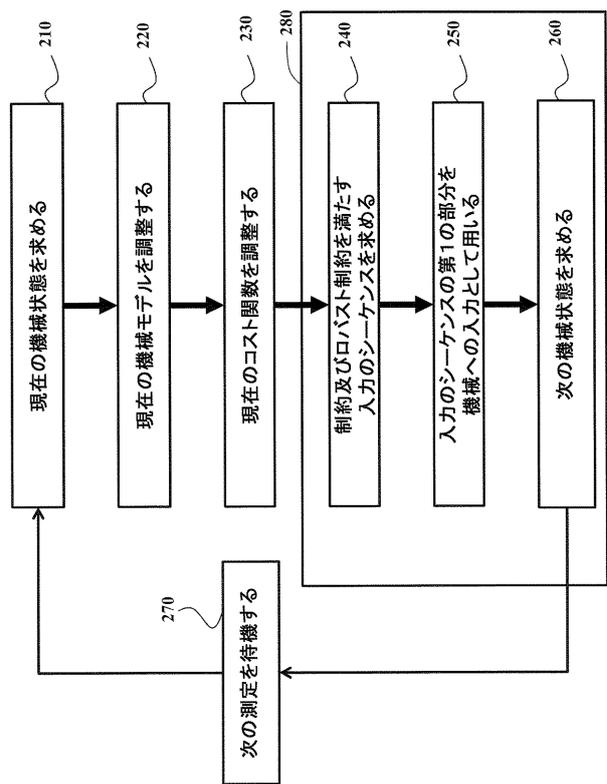
【図 1 B】



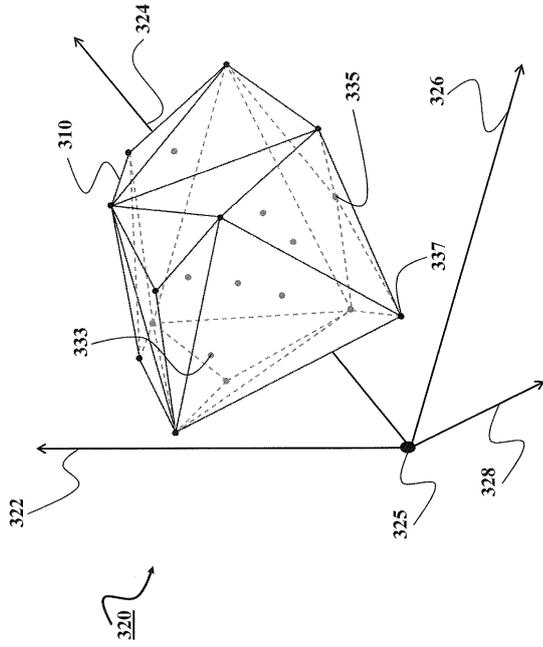
【図 2 A】



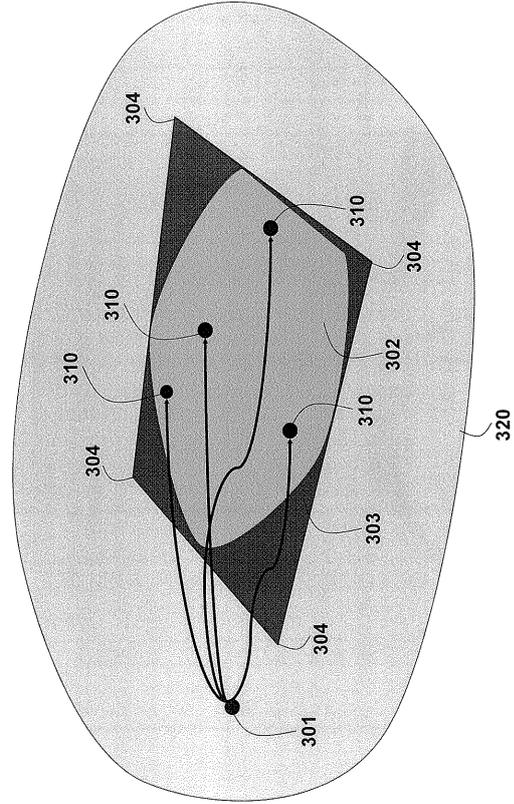
【図 2 B】



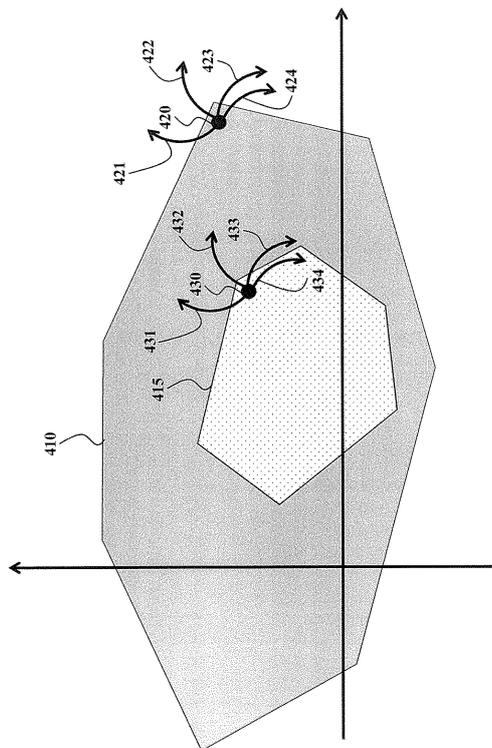
【 図 3 A 】



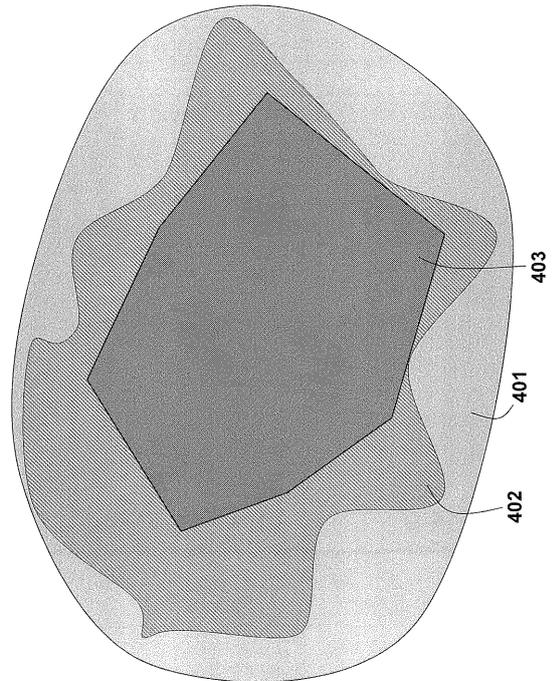
【 図 3 B 】



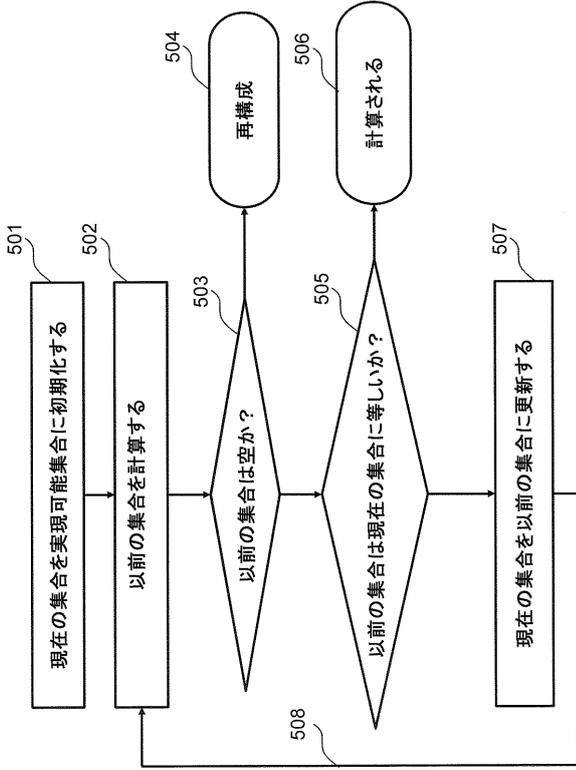
【 図 4 A 】



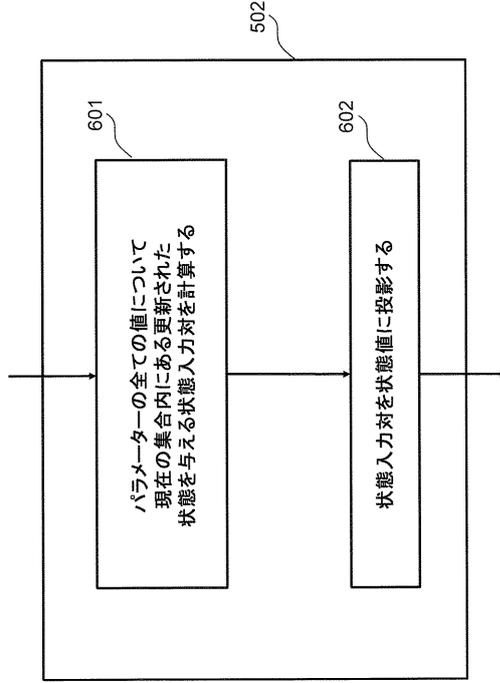
【 図 4 B 】



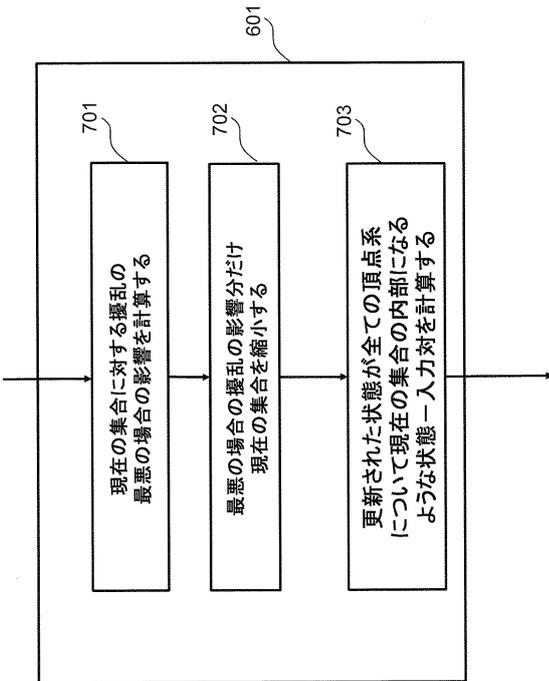
【 図 5 】



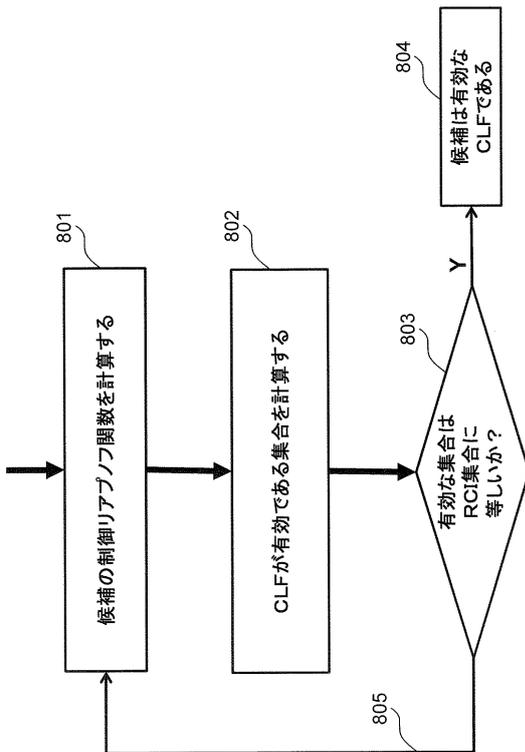
【 図 6 】



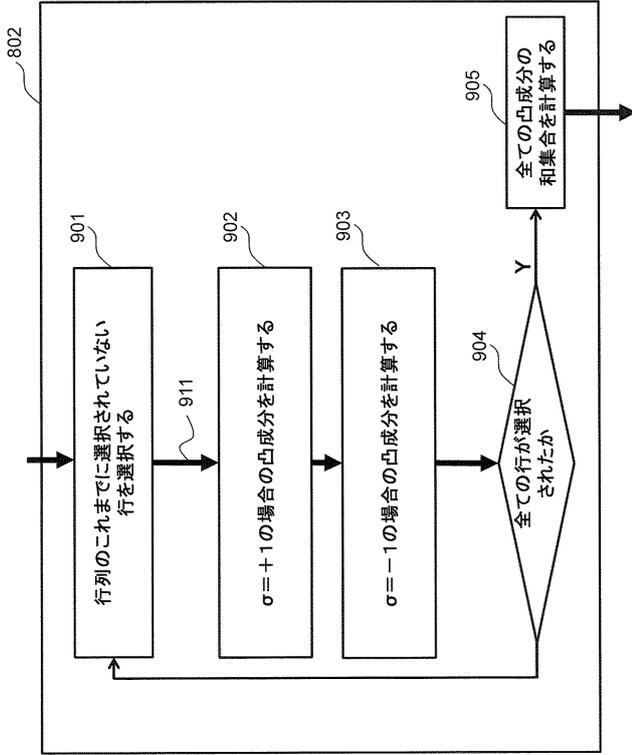
【 図 7 】



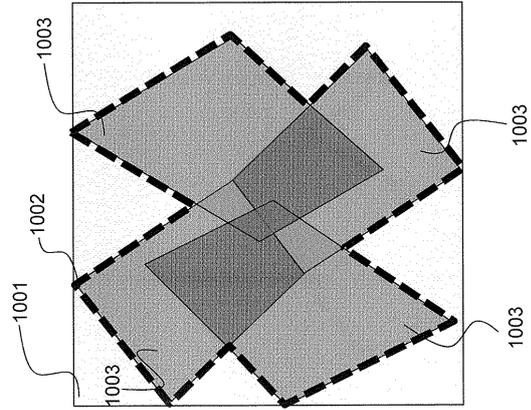
【 図 8 】



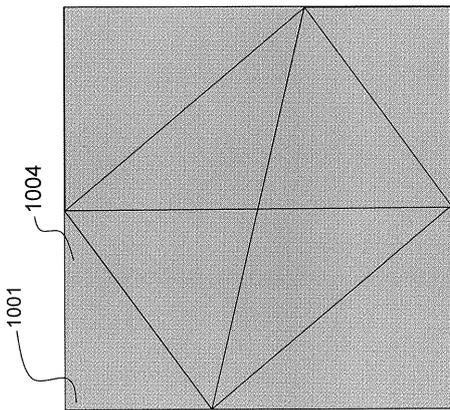
【図9】



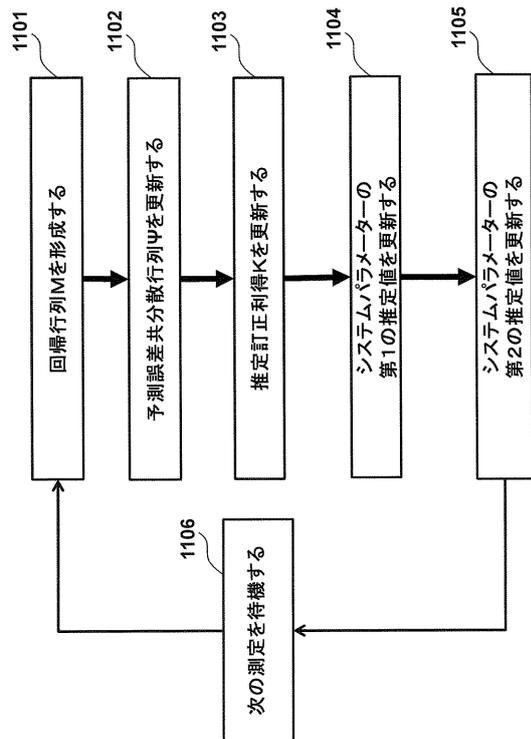
【図10A】



【図10B】



【図11】



フロントページの続き

(72)発明者 ステファノ・ディ・カイラノ
アメリカ合衆国、マサチューセッツ州、ケンブリッジ、ブロードウェイ 201、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

(72)発明者 アビシャイ・ワイス
アメリカ合衆国、マサチューセッツ州、ケンブリッジ、ブロードウェイ 201、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

Fターム(参考) 5H004 GA15 GB11 GB16 HA01 HA07 HA08 HA14 HB01 HB07 HB08
HB14 KC06 KC17 LA12

【外国語明細書】

Method for Controlling Operation of Machine and Control System for Controlling Iteratively Operation of Machine

Field of the Invention

This invention relates generally to controlling an operation of a machine, and more particularly to controlling the operation using a model predictive control (MPC) over a receding horizon.

Background of the Invention

In machine control, a controller, which can be implemented using one or combination of software or hardware, generates commands values for input to a machine based on measurements obtained, e.g., from sensors and/or estimators, or from outputs of the machine. The controller selects the input so that the machine operates as desired, for instance, the operation follows a desired reference profile, or regulates the outputs to a specific value. In several cases, the controller enforces constraints on the inputs and outputs of the machine, for instance, ensuring the corresponding variables are in some predetermined ranges to ensure safe machine operation from a physical, specification. In order to enforce such constraints, the controller often uses a model of the machine to predict what behavior the machine produce when a command, i.e., a control input, is applied. One example of a process in a controller that is capable of achieving control of a machine while enforcing constraints on the machine inputs and outputs is model predictive control (MPC).

The MPC is based on an iterative, finite horizon optimization of a model of a machine and has the ability to anticipate future events to take appropriate control actions. This is achieved by optimizing the operation of the machine over a future finite time-horizon subject to constraints, and only implementing the control over the current timeslot. For example, the constraints can represent physical limitation of the machine, safety limitations on the operation of the machine, and performance limitations on a trajectory. A control strategy for the machine is admissible when the motion generated by the machine for such a control strategy satisfies all the constraints. For example, at time t , the current state of the machine is sampled and an admissible cost minimizing control strategy is determined for a relatively short time horizon in the future. Specifically, an online or real-time calculation determines a cost-minimizing control strategy until time $t+T$. After the step of the control is implemented, the state is sampled again and the calculations are repeated starting from the now current state, yielding a new control and new predicted state path. The prediction horizon shifts forward, and for this reason MPC is also called receding horizon control.

The MPC can be used to generate the actual trajectory of the motion of the machine based on a model of the system and the desired reference trajectory by solving an optimal control problem over a finite future time subject to various physical and specification constraints of the system. The MPC aims for minimizing performance indices of the motion of the machine, such as an error between a reference and an actual motion of the machine, the machine energy consumption, and induced system vibration.

Because the MPC is a model-based framework, the performance of the MPC inevitably depends on the quality of the prediction model used in the optimal

control computation. However, in most cases, the model for the machine dynamics is unknown *a priori*, as some parameters are not measured precisely. Thus, the controller may need to estimate unknown parameters of the model of the machine, during already operation of the machine, and thus, also enforce constraints while the parameters are estimated. The conventional approaches to handle such problems include adaptive or learning-based MPC, where an MPC control problem is augmented with a closed-loop identification scheme in order to learn the unknown machine parameters. By learning the unknown parameters, the operation of the machine achieved by the controller is improved.

However, current approaches of adaptive and learning based MPC are limited for multiple reasons. First, while estimating the unknown parameters, constraints can be violated or the control performance may be excessively reduced in order to conservatively enforce the constraints. In fact, several existing methods, such as a method described in U.S. 2011/0022193, simply ignore the constraints and thus are incapable of producing admissible control strategies for machines subject to constraints.

Second, simply including a closed-loop identification method in the MPC controller can generate a slow convergence of the estimated unknown parameters to the desired values. This reflects the general problem in adaptive control, as the controller limits the excitation of the machine while the identification requires strong excitation of the machine to estimate the parameters. Also, conservative methods that enforce constraints with unknown parameters often avoid large excitation to prevent violating the constraints, thus obtaining an even slower convergence of the estimate. Finally, several methods for adaptive MPC require a significant amount of computation and can be executed only in expensive

processors at a slow rate, enabling only machines with low response bandwidth to be controlled.

Accordingly, there is a need for a method for controlling an operation of a machine using the MPC that includes uncertainty, wherein the operation of the machine is subject to the constraints.

Summary of the Invention

Some embodiments of the invention are based on the realization that it is possible to provide a model predictive control (MPC) method with enforcement of the constraints on the operation of a machine and fast convergence to a value of a parameter of a model of the machine by using constraints on values of control inputs that can be applied to each state of the machine while guaranteeing that the constraints on the operation of the machine are not violated for any admissible value of the parameters of the model. In some embodiments, the control strategy of the MPC is to jointly optimize a performance of the control and a rate of the estimation of the parameters.

Some embodiments are based on the realization that it is possible to enforce constraints on a family of models defined based on an admissible range for the uncertain values of the machine parameters. The family of models provides a set of feasible states. For example, a special subset of these feasible states can be designed such that, for all states in this subset, there is a feasible control input that maintains the states in that subset for all values of the unknown machine parameters within their known ranges.

It is further realized that it is possible to control the system using MPC such that the optimized input maintains the state in the special subset. This guarantees that the system controlled by the MPC always satisfies all the constraints including the case when the parameters are uncertain.

It is an additional realization that among the inputs that maintain the state in the special subset, an input that optimizes the trade-off between control and identification performance could be chosen. By construction, this input also guarantees constraint satisfaction regardless of the true values of the unknown parameters.

It is also realized that the MPC prediction model and the trade-off between control and identification can be updated online based on the identification of the unknown parameters and that the tradeoff between the control and identification performance can be adjusted based on the residual uncertainty.

Accordingly, one embodiment of the invention discloses a method for controlling an operation of a machine according to a model of the machine. The method includes controlling iteratively the operation of the machine with control inputs determined using the model based on an optimization of a cost function subject to constraints on the control inputs, wherein at least one current iteration comprises: determining a current state of the machine after the controlling with a previous control input determined for a previous iteration by optimizing a previous cost function using a previous model of the machine; determining a current model of the machine to reduce a difference between the current state and a state estimated using the previous model of the machine; updating the cost function based on a difference between the previous model and the current model to

produce a current cost function; and determining a current control input for the controlling at the current iteration using the current model and the current cost function, wherein steps of the methods are performed by a processor of a controller controlling the operation of the machine.

Another embodiment discloses a method for controlling an operation of a machine according to a model of the machine including a nominal model defining relationships among parameters of the model and an uncertainty model defining a range of values for at least one parameter of the model. The method includes controlling iteratively the operation of the machine with control inputs determined using the model of the machine based on an optimization of a cost function, wherein the optimization is subject to control-invariant constraints on the control inputs selected such that any value of the control input satisfying the control-invariant constraints maintains a state of the machine in a control-invariant subset of states satisfying constraints on the operation of the machine, wherein for any state of the machine within the control-invariant subset there is an admissible control input satisfying the control-invariant constraints and maintaining the state of the machine within the control-invariant subset for all values of the parameters of the model within the range defined by the uncertainty model, wherein at least one current iteration comprises: determining a current state of the machine resulted from the controlling with a previous control input determined for a previous iteration by optimizing a previous cost function using a previous model of the machine; determining a current model of the machine to reduce a difference between the measured current state and a state estimated using the previous model of the machine, such that a current value of the parameter of the current model is within the range of values; updating the cost function based on a difference between the previous and the current models, wherein the cost function includes a

first term for determining a first value for the control input according to an objective of the operation and includes a second term for determining a second value for the control input for reducing the difference between the current state of the machine and a state estimated with a model of the machine, such that the optimization optimizes a combination of the first term and the second term, wherein the updating the cost function includes changing a weight of the second term in the combination; and determining a current control input for the controlling at the current iteration using the current model and the current cost function, wherein steps of the methods are performed by a processor of a controller controlling the operation of the machine.

Yet another embodiment discloses a control system for controlling iteratively an operation of a machine according to a model of the machine. The system includes a memory storing the model of the machine including a nominal model defining relationships among parameters of the model and an uncertainty model defining a range of values for at least one parameter of the model, and the constraints on the machine; and at least one processor for executing modules of the controller comprising: a control input module for determining a current control input for the controlling during a current iteration by optimizing a current cost function subject to constraints on the current control input using a current model of the machine; a model learning module for determining the current model of the machine, such that a current value of the parameter of the current model is with the range of values and reduces a difference between a current state of the machine resulted from the controlling with a previous control input determined for a previous iteration by optimizing a previous cost function using a previous model of the machine and an estimated state estimated using the previous model of the machine; and a cost function module updating the previous cost function using a

difference between the current state of the machine and the state of the machine estimated using the current machine model from a previous machine state and a previous machine control input.

Brief Description of the Drawings

Figure 1A is a block diagram of a controller for controlling an operation of a machine according to one embodiment of the invention;

Figure 1B is a block diagram of a general structure of the controller of Figure 1A according to one embodiment of the invention;

Figure 2A is a block diagram of various modules of the controller according to one embodiment of the invention;

Figure 2B is a block diagram of a method executed by the modules of the controller according to one embodiment of the invention;

Figure 3A is a schematic of an exemplar polytope arranged in the coordinate system visualizing the principles of some embodiments of the invention;

Figure 3B is a schematic of effect of the uncertainties of the parameters of the model on a state of the machine;

Figure 4A is a schematic of an example of a two-dimensional projection of the control-invariant subset of states defined by various constraints on the operation of the machine according to some embodiments of the invention;

Figure 4B is a schematic showing the relation between the feasible region of the states of the machine and control invariant subsets determined according to some embodiments of the invention;

Figure 5 is a block diagram of a backward-reachable region computation for determining the control invariant subset according to one embodiment of the invention;

Figure 6 is a block diagram of an exemplar implementation of determining the previous set of states according to one embodiment of the invention;

Figure 7 is a block diagram of a method for determining the couples of states-inputs according to one embodiment of the invention;

Figure 8 is a block diagram of a method for determining a control invariant Lyapunov according to one embodiment of the invention;

Figure 9 is a block diagram of a method for determining the subset of states for a candidate Lyapunov function according to one embodiment of the invention;

Figures 10A and 10B are schematics of the test for determining valid and non-valid control invariant Lyapunov function; and

Figure 11 is a block diagram of a method for updating the model of the machine according to one embodiment of the invention.

Detailed Description of the preferred embodiment

Figure 1A shows a block diagram of a control system 101 for controlling an operation of a machine 102. The machine 102 is a device whose operation changes quantities such as positions, velocities, currents, temperatures, numerical values, in response to commands. As used herein, the operation of the machine determines a motion of the machine that changes such quantities. The control system receives a desired motion 103 for the machine, such as a desired trajectory or target point for some of the quantities, and controls the machine via control inputs 104. The control inputs can include commands to change parameters of the operation of the machine or can include actual values of the parameters such as voltages, pressures, torques, forces that affect the machine motion resulting in the generation of quantities 105 for the machine.

The control system 101 receives information 106 about the machine motion, from sensors, hardware, or software connected directly or remotely to the machine. The information 106 includes a state of the machine. The machine uses the state for the selection of the control inputs 104. The information 106 can include some or all of the motion quantities 105 and can also include additional information about the machine. The quantities 105, the control inputs 104 or a combination thereof, can be requested to remain in some pre-defined ranges according to constraints 114 on the operation of the machine.

Figure 1B shows a general structure of the control system 101 according to one embodiment of the invention. The control system 101 includes at least one processor 130 for executing modules of the controller. The processor 130 is operatively connected to a memory 120 for storing the model 112 and the

constraints 114. It is an objective of some embodiments of the invention to determine the control inputs 104 using a model of the machine 112 subject to the constraints 114. It is another objective of some embodiments to update 116 the model of the machine during the operation such that the constraints 114 are satisfied during the update.

Figure 2A shows a block diagram of various modules of the control system 101 according to one embodiment of the invention. In some embodiments of the invention, MPC or the model of the machine includes at least one parameter of uncertainty. For example, a model of an arm of a robot can include an uncertainty about a mass of the arm caring an object. A model for the movement of a train can include an uncertainty about a friction of the wheels with the rails in current weather conditions. In some embodiments, the control system 101 is used to determine the uncertainties of the control.

In some embodiments, the model of the machine includes a nominal model 202 defining relationships among parameters of the model 112 and an uncertainty model 203 defining a range of values for at least one parameter of the model 112 and/or the nominal model 202. For example, the parameters of the nominal model can use default values of the parameters. For example, the nominal model 202 can describes the motion of the machine in ideal conditions. However, the machine is subject to external effects, such as wear, external actions, variations due to time and weather, inexactly known physical quantities due to imperfections in the manufacturing process or measurement errors and hence the actual motion of the machine is not exactly the same as the one of the nominal model. For example, one embodiment, starting from a nominal model, update the current model iteratively

until the current model is in line with the observed machine motion, in terms of the sequence of the machine state values.

Some of the machine quantities need to remain in desired ranges defined by constraints 205 on the operation of the machine. Some embodiments of the invention are based on the additional realization that constraints 206 on the control inputs can be determined from constraints 205 on the operation of the machine considering the uncertainty model 203. For example, the constraints 206 on the control inputs are determined such that the machine 102 controlled by the control inputs 104 satisfying the constraints 206 are guaranteed to satisfy the constraints 206 for all variations of the values of the parameters of the model within the admissible range defined by the uncertainty model 203.

In some embodiments, the constraints 206 are determined offline and the constraint 205 are not used for the controlling of the machine. In some embodiments, the constraints 206 are used in combination with at least some constraints 205 for controlling the machine.

In some embodiments, the control inputs 104 are determined based on an optimization of a cost function 209 subject to constraints 206 on the control inputs. Because the constraints 206 guaranties the feasibility of the control, some embodiments include different terms in the cost function for a trade-off between the control to achieve the objective of the operation of the machine and the control to increase a rate of reducing the uncertainties of the parameters of the model of the machine.

For example, the cost function can include a first term for determining a first value for the control input according to an objective of the operation and includes a second term for determining a second value for the control input for reducing the difference between the current state of the machine and a state estimated with the model of the machine, such that the optimization optimizes a combination of the first term and the second term, wherein the updating the cost function includes changing a weight of the second term in the combination.

Accordingly, in some embodiments, various modules of the control system 101 achieve the control of the machine satisfying the objectives of the operation of the machine while updating the parameters of the model of the machine within the range of values defined by the nominal model and the uncertainty model of the machine using the optimization of the cost function including different terms for different objectives of the control.

The control system includes a memory 120 for storing the model of the machine and the processor 130 for executing modules of the controller. The modules include a control input module 208 for determining a current control input 104 for the controlling during a current iteration by optimizing a current cost function 209. The control input module optimizes the current cost function using a current model 201 of the machine subject to constraints 206 on the current control input.

The control system also includes a model learning module 204 for determining the current model 201 of the machine, such that a current value of the parameter of the current model is with the range of values defined by the nominal model 202 and the uncertainty model 203 and reduces a difference between a

current state 106 of the machine resulted from the controlling with a previous control input determined for a previous iteration by optimizing a previous cost function using a previous model of the machine and an estimated state 216 estimated using the previous model of the machine.

The controller also includes a cost function module 207 for determining the current cost function 209. For example, the cost function module updates the previous cost function using a difference between the previous model and the current model to produce the current cost function. Because the steps of the control are performed iteratively, the current model and the current cost function become previous model and previous cost function for subsequent iteration. For example, the previous model, the previous cost function and the previous control input are determined at a previous iteration as the current model, the current cost function and the current control input.

Figure 2B shows a block diagram of a method executed by the modules of the control system 101. The method controls iteratively 270 the operation of the machine with control inputs determined using the model of the machine based on an optimization of a cost function. The method determines 210 a current state of the machine resulted from the controlling with a previous control input determined for a previous iteration by optimizing a previous cost function using a previous model of the machine.

The method adjusts 220 a current model of the machine to reduce a difference between the measured current state and a state estimated using the previous model of the machine, such that a current value of the parameter of the current model is with the range of values, and updates 230 the cost function based

on a difference between the previous and the current models. The update 230 provides a trade-off between the control to achieve the objective of the operation of the machine and the control to increase a rate of reducing the uncertainties of the parameters of the model of the machine.

In some embodiments, the cost function includes a first term for determining a first value for the control input according to an objective of the operation and includes a second term for determining a second value for the control input for reducing the difference between the current state of the machine and a state estimated with the model of the machine, such that the optimization optimizes a combination of the first term and the second term. In those embodiments, the cost function is updated by changing a weight of the second term in the combination. For example, a smaller difference between the previous and the current models reduces the weight of the second term in the combination.

Next, the method determines 280 a current control input for the controlling at the current iteration using the current model and the current cost function. For example, the method uses the updated current cost function and current machine model to determine 240 a sequence of future inputs, from current time instant for a fixed amount of time in the future, at least as long as to obtain a new machine state measurement, such that the predicted future machine states and inputs satisfies the constraints on the control inputs. The first part of the input sequence, for duration equal to the amount of time needed to obtain a new measurement of the state of the machine, is applied 250 as current control input to the machine. Based on the current state of the machine, current model of the machine, and current control input to the machine, the next state of the machine is determined 260, and the controller waits 270 until a new state measurement is received.

Uncertainty Modeling

Some embodiments of the invention are based on the realization that even if the true values of the parameters of the models are uncertain, the uncertainties of the parameters of the model are within the known range. For example, the mass of the train can be within a range of values for an empty train and fully loaded train. Similarly, the disturbances on the values of the parameters of the model can be bounded. The uncertainty model 203 represents the ranges for the possible values of at least one parameter of the model, such that a combination of the nominal model and the uncertainty model can be used to determine a current model of the machine for the MPC.

Figure 3A shows an exemplar polytope 310 arranged in a coordinate system 320 visualizing the principles of the above realization. The coordinate system 320 is usually a low-dimensional system of parameters of the model having the uncertainties. For example, if the model includes four parameters with uncertainties, the coordinate system 320 is four dimensional and have one dimension 322, 324, 326, and 328 for each of the parameters such that new values of the combination of parameters, e.g., values 333, 335, 337 are selected within the polytope 310.

For example, a function that describes the motion of the machine at equally time-spaced sampling instants by a system of difference equations for a given machine state, input, and disturbance d , which represents the combined effects of uncertainties is

$$\begin{aligned} x(k+1) &= f(x(k), u(k), d(k)) \\ y(k) &= Cx(k) \end{aligned}, \quad (1)$$

where k is the index of the sampling instant, f is a generic function, C is a matrix, x is the machine state 106, u is the machine input 104 and y is the machine output 105. It is realized that the number of situations in the disturbances are bounded within the range D , the states are bounded within the range \mathcal{X} , and the control inputs are bounded within the range U

$$x \in \mathcal{X}, u \in \mathcal{U}, d \in D. \quad (2)$$

For instance the range of values D can be determined by the minimum and maximum value of the machine mass, the minimum and maximum value of the external forces. Similarly, the ranges of the inputs and states can be determined by minimum and maximum values of velocities, positions, voltages, or torques.

Some embodiments, based on f and D , construct a set of matrices, an additive linear disturbance matrix and a polyhedral set for additive disturbance

$$\{(A_i, B_i)\}_{i=1}^{\ell}, B_w, \mathcal{W} \quad (3)$$

respectively, that results in the polytopic difference inclusion

$$\text{co}\{A_i x + B_i u\}_{i=1}^{\ell} \oplus \text{co}\{B_w w_i\}_{i=1}^{\eta} \quad (4)$$

such that for any given x and u ,

$$\text{co}\{A_i x + B_i u\}_{i=1}^{\ell} \oplus \text{co}\{B_w w_i\}_{i=1}^{\eta} \supseteq f(x, u, d), \quad \forall d \in D. \quad (5)$$

where $\mathcal{W} = \text{co}\{w_i\}_{i=1}^{\eta}$, so that w_i are the vertices of \mathcal{W} and "co" indicates the convex hull of the set.

The linear models in Equation (4) can be determined, for instance, by taking the maximum and minimum of the parameters that form vector d allowed by D , and/or of their combinations.

Figure 3B shows a schematic of effect of the uncertainties of the parameters of the model determined by Equation (4) in estimating the state of the machine. Given the current state x 301 of the machine and a control input, the next state of the machine can vary within a set 302 for different possible values of d of the parameters of the model of the machine. For instance, depending on specific values of the vector d , the state 301 can transition to different states 310 within the set 302 for the same value of the control input.

In some embodiments of the invention, the uncertainty model is extended such that a combination of the nominal model and the uncertainty model is included into a convex combination 303 of linear models with a convex combination of additive disturbances. For example, when $W = 0$, the model of Equation (4) over-approximates the set 302 by set 303 which is a bounded polyhedron, or polytope, where the vertices 304 are determined from

$$v_i = A_i x + B_i u, i = 1 \dots \ell, \quad (6)$$

wherein ℓ , (A_i, B_i) , $i = 1, \dots, \ell$ are the number and the matrices, respectively, defined in Equation (3). In embodiments with $W \neq 0$, the set 303 is the sum of the set obtained from the convex hull of the set $\text{co}\{B_w w_i\}_{i=1}^{\eta}$.

Based on Equation (4) an input u in the range \mathcal{U} that satisfies all

$$A_i x + B_i u + B_w w_j \in \mathcal{X}, i = 1 \dots \ell, j = 1 \dots \eta \quad (7)$$

makes the set 303 entirely in the range of admissible states , 320, and hence also the possible next state of the machine 302 according to (1) is within 320. Thus, enforcing constraints on Equation (4) guarantees enforcement of the constraints on Equation (1). The embodiments that use the model determined by Equation (4) are computationally advantageous, because the model determined by Equation (4) includes a set of linear models, rather than uncertain nonlinear models described in Equation (1).

Constraints on Control Inputs to the Machine

Some embodiments of the invention are based on realization that in order to guarantee that the constraints on the machine motion are satisfied during the operation of the machine for all variation of the values of the parameters of the model within the predetermined range, a subset of the feasible region \mathcal{X} of the states can be determined, such that whenever the state of the machine is in such a subset, there exists at least one admissible control input such that the state remains in the subset for all possible values of the parameters and the disturbances. By remaining in the subset, all the machine motion constraints are satisfied since the subset is included in the feasible region \mathcal{X} .

Some embodiments of the invention determines and use such constraints on the control inputs, referred to herein as control-invariant constraints on the control inputs, to determine a control input that maintains the state of the machine in such a subset of the feasible region \mathcal{X} of the states, referred to herein as a control-invariant subset of states. By the construction, a control input satisfying the control-invariant constraints maintains a state of the machine in a control-invariant

subset of states satisfying constraints on the operation of the machine for all values of the parameter of the model within the range defined by the uncertainty model.

Figure 4A shows an example of a two-dimensional projection of the control-invariant subset of states 410 defined by various constraints on the operation of the machine according to embodiments of the invention. Typically, the feasible region is a multi-dimensional polytope determined by hyperplanes, which are represented by linear inequalities, along multiple dimensions corresponding to the constraints on the operation.

Due to the nature of receding horizon control, the existence of a solution for a certain horizon does not by itself guarantee the existence of the solution for a subsequent horizon. For example, the state of the machine and a state of the reference trajectory 420 can be optimal and feasible for one iteration, but all control actions 421-424 that controller is allowed to take during the next iteration can bring a state of the machine outside of the feasible region 410.

Some embodiments of the invention are based on yet another realization that it is possible to select a control-invariant subset 415 of the feasible region, such that from any state of the machine within that control-invariant subset, there is a control input maintaining the state of the machine within the subset for the known future states of the reference trajectory or for all admissible future states of the reference trajectory. For example, for any state such as a state 430 within the subset 415 and within all possible control inputs 431-434 that the controller can execute, there is at least one control input 434 that maintains the state of the machine and reference within the subset 415. In this case, the subset 415 is a control invariant subset.

Some embodiments determine the control invariant subset of state for the model of Equation (4), such that for each state within the control invariant subset there is at least one control action maintaining the state of the machine within the control invariant subset for all possible states values according to Equation (5).

Figure 4B shows the relation between the feasible region 401 of the states of the machine, and the largest robust control invariant subset 402 of the state for the model with uncertainties according to Equation (1) within \mathcal{X} . In some embodiments the control invariant subset 402 is reduced to form control invariant 403, which is less than the subset 402, but has a simpler shape formed by linear equations. Because the subset 402 is determined by nonlinear equations, the shape of the subset 402 can be non-convex. Thus, computation of 403 is simpler, more efficient and advantageous for control purposes.

Figure 5 shows a block diagram of a backward-reachable region computation for determining the robust control invariant subset 403 starting from the feasible region \mathcal{X} , 401 according to one embodiment of the invention. The backward-reachable region computation determines the robust control invariant subset \mathcal{C}_x and also the control invariant set $\mathcal{C}_u(x)$, which determines for any x within \mathcal{C}_x the set of inputs u in \mathcal{U} that can be applied so that all possible next states according to (4) are inside \mathcal{C}_x .

The backward-reachable region computation initializes 501 a current set \mathcal{X}_c to the feasible set \mathcal{X} and determines 502 a previous set of states \mathcal{X}_p as a subset of the current set \mathcal{X}_c such that for all states x in \mathcal{X}_p there exists an input u in \mathcal{U} such

that for all the possible values of the parameters p in P , the updated state is in the current set \mathcal{X}_c .

If at 503 the previous set \mathcal{X}_p is empty 504, correct operation of the controller cannot be guaranteed, which means that the set P of possible values of the parameters should be reduced in size, possibly by changing the design or objective of the operation of the machine. If at 505 the current set and the previous set are equal, that is also at 506 the set \mathcal{C}_x is computed otherwise, the previous set is assigned 507 to be the current set and the computation iterates 508 again. When the set \mathcal{C}_x is found the last computed set of state-input couples is the robust admissible input set $\mathcal{C}_u(x)$ for all x within \mathcal{C}_x .

Figure 6 shows a block diagram of an exemplar implementation of determining 502 the previous set of states according to one embodiment. The embodiment identifies 601 the state-input couple that generates an updated state that is in the current set for all the values of the parameters, and projects 602 the state input couples into state values, i.e., the embodiment identifies the states that belongs to at least one of such state-input couples.

Figure 7 shows a block diagram of a method for computation of the couples of states-inputs 601 when linear inequalities describe the sets \mathcal{X} and \mathcal{U} . The method considers the current set as

$$H^{(c)}x \leq K^{(c)} \quad (8)$$

and determines 701 the worst case effects of the additive disturbance w on the current set,

$$i. \quad [S]_i = \max_{w \in \mathcal{W}} [H(c)B_w w]_i, \quad i = 1, \dots, n_q^{(c)} \quad (9)$$

wherein $H^{(c)}$ is a matrix describing the current set defined in (8), $n_q^{(c)}$ is the number of rows of the matrix $H^{(c)}$ of the current set.

Next, the method reduces 702 the current set by the worst case disturbance effects to produce a reduced current set \mathcal{X}_s described by

$$H^{(c)}x \leq K^{(c)} - S_i, \quad (10)$$

and then determines 703 the couples (x, u) such that the updated state is inside the current set for all the vertex systems in (18), i.e., $A_i x + B_i u \in \mathcal{X}_s, \forall i = 1, \dots, \ell$.

Stability Constraints

In some embodiments of the invention, the constraints on the control inputs include stability constraints for converging the state of the machine to a target value for all values of the parameters of the model of the machine defined by the nominal and the uncertainty models. In one embodiment, the stability constraints include a control Lyapunov function of the machine. For example, the control Lyapunov function (CLF) for the model of Equation (4) is a function \mathcal{V} that satisfies the feasible value reduction

$$\mathcal{V}(f(x, u)) \leq \rho \mathcal{V}(x), \quad (11)$$

where f is the model of Equation (4), \mathcal{V} is a function that is 0 at the desired target and positive everywhere else, ρ is a value between 0 and 1.

In some embodiments the control Lyapunov function \mathcal{V} is a control invariant. As defined herein, the valid invariant control Lyapunov function is such a control Lyapunov function that for all x inside the control invariant subset \mathcal{C}_x , e.g., determined for the model of Equation (4), there exists the control input u

inside $\mathcal{C}_u(x)$, i.e., satisfying the control invariant constraints, such that Equation (11) is satisfied.

Figure 8 shows a method for determining the invariant control Lyapunov function for the control system according to one embodiment of the invention. The method generates 801 a candidate CLF, and determines the subset of states 802 of the candidate CLF as the subset of \mathcal{C}_x such that there exists a u inside \mathcal{U} such that Equation (11) hold. Next, the method verifies 803 whether the subset 802 is equal to the subset \mathcal{C}_x . If this is the case 804, the candidate CLF \mathcal{V} is the control invariant Lyapunov function, otherwise 805 a different candidate CLF is generated.

Figure 9 shows a block diagram of a method for determining the subset of states 802 for the candidate Lyapunov function according to one embodiment wherein $\mathcal{V}(x) = \|Px\|_\infty$ where P is a matrix describing an infinity-norm control Lyapunov function with n_p rows. The embodiment selects 901 a previously not selected row 911 of the matrix P , and determines 902, the convex component of the subset related to the row 911 for positive condition $\sigma = +1$ by computing the set of x such that there exists u and ε such that the inequalities

$$\begin{aligned}
 \varepsilon &\geq [P(A_i x + B_i u)]_j, \quad \forall j = 1, \dots, n_p, \forall i = 1, \dots, \ell \\
 \varepsilon &\geq -[P(A_i x + B_i u)]_j, \quad \forall j = 1, \dots, n_p, \forall i = 1, \dots, \ell \\
 \varepsilon &\leq \rho[Px]_r \\
 \sigma[Px]_r &\geq [Px]_h, \quad \forall h = 1, \dots, n_p, \\
 \sigma[Px]_r &\geq -[Px]_h, \quad \forall h = 1, \dots, n_p,
 \end{aligned} \tag{12}$$

holds true for $\sigma = +1$, where n_p is the number of rows of the matrix P .

Next, the embodiment determines 903, for negative condition $\sigma = -1$, the convex component of the subset related to the row 911 and -1 is computed as the set of x such that there exists u and \mathcal{E} such that (12) is satisfied with now $\sigma = -1$. When all the rows have been selected, the union of all the convex components form the subset 802.

Figures 10A and 10B show an illustration of the test for determining valid and non-valid control invariant Lyapunov function. The subset 1002 within the control invariant subset 1001 is valid where subset 1003 is a union of multiple convex components 1003 of the candidate CLF. In the Figure 10A, the CLF is not control invariant because subsets 1002 and 1001 are different. In Figure 10B, the CLF is control invariant, because a candidate CLF that has valid subset 1004, is valid for the subset 1001 since the subset 1004 covers the entire area of the subset 1001.

For example, in one embodiment of the invention, the control Lyapunov function is an infinity-norm control Lyapunov function that satisfies a feasible value reduction test for all states of the machine satisfying the control-invariant constraints. The test can include selecting rows of a matrix describing the infinity-norm control Lyapunov function and determining convex components of the states of the machine that satisfy, for positive and negative conditions, a feasible value reduction on the rows of the matrix describing the infinity-norm control Lyapunov function for at least one input of the machine satisfying the control-invariant constraints. Next, the embodiment determines a union of the convex components and verify that all the states of the machine in the the control-invariant subset of the states of the machine are contained in the union of the convex components.

Model Learning

In one embodiment, the current model of the machine 201 is initialized based on the nominal model 202 where a pair of estimated system matrices (\hat{A}, \hat{B}) is selected from the convex hull of the set of matrices in Equation (3),

$$(\hat{A}, \hat{B}) \in \text{co}\{(A_i, B_i)\}_{i=1}^{\ell} \quad (13)$$

and an additive disturbance estimate \hat{w} is selected from the polyhedral set for additive disturbance in Equation (3),

$$\hat{w} \in \mathcal{W}. \quad (14)$$

The current model in Equations (13) - (14) is updated within its respective set at each time step, using the input 104, and the state 106, until the current model is in line with the observed machine motion, in terms of the sequence of the machine state values.

In one embodiment, the implementation of the model update considers the model in (13) and (14) to be linear combinations of the vertices of Equation (6) and of the vertices of \mathcal{W}

$$\hat{A}x + \hat{B}u + B_w \hat{w} = \sum_{i=1}^{\ell} [\theta]_i (A_i x + B_i u) + \sum_{i=1}^p [\eta]_i B_w w_i, \quad (15)$$

where θ is the combination vector of the linear models, and η is the combination vector of the additive disturbances

$$\begin{aligned} \theta &\in \mathbb{R}^{\ell}, \quad 0 \leq [\theta]_i \leq 1, \quad \sum_i [\theta]_i^{\ell} = 1 \\ \eta &\in \mathbb{R}^p, \quad 0 \leq [\eta]_i \leq 1, \quad \sum_i [\eta]_i^p = 1, \end{aligned} \quad (15b)$$

so that a linear regression model can be formed for the joint parameter vector

$$\lambda = [\theta \quad \eta]^T. \quad (16)$$

The linear regression model takes the form

$$\begin{aligned} y &= \sum_{i=1}^{\ell} [\theta]_i (A_i x + B_i u) + \sum_{i=1}^p [\eta]_i B_w w_i + \epsilon, \\ &= \Gamma(x, u)\theta + \Upsilon\eta + \epsilon, \\ &= M^T(x, u)\lambda + \epsilon, \end{aligned} \quad (17)$$

where ϵ represents measurement noise,

$$\begin{aligned} \Gamma(x, u) &= [A_1 x + B_1 u, \dots, A_\ell x + B_\ell u] \\ \Upsilon &= [B_w w_1, \dots, B_w w_p] \\ \text{and } M^T(x, u) &= [\Gamma(x, u) \quad \Upsilon]. \end{aligned} \quad (18)$$

The linear regression (17) can then be solved by several methods. For example, one embodiment uses a recursive least squares (RLS) method, modified to ensure that the output of the regression $\lambda = [\theta \quad \eta]^T$ is in its allowed range according to (15b).

For example, the RLS method can include the solution of

$$\begin{aligned} \Psi(t+1) &= (I - \mathcal{K}_{\text{RLS}}(t+1)M^T(x(t), u(t))) \Psi(t) \\ \mathcal{K}_{\text{RLS}}(t+1) &= \Psi(t+1)M(x(t), u(t)), \\ \hat{\lambda}(t+1) &= \hat{\lambda}(t) + \mathcal{K}_{\text{RLS}}(t+1) \left(y(t+1) - M^T(x(t), u(t))\hat{\lambda}(t) \right), \\ \hat{\lambda}(t+1) &= \text{proj}_\lambda(\hat{\lambda}(t+1)) \end{aligned} \quad (18b)$$

wherein \mathcal{K}_{RLS} is an estimate correction gain, Ψ is an estimate covariance matrix and proj_λ is the operator that projects its argument into the domain of λ .

Figure 11 shows a block diagram of updating the model of the machine using modified RLS according to one embodiment of the invention to produce the current model of the machine. The modified RLS at each step uses the previous input and the previous state to form 1101 the regressor matrix M , as well as the current time-step's state as the measurement \mathcal{Y} . The modified RLS updates 1102 the prediction error covariance matrix \mathcal{P} , and updates 1103 the estimation gain σ .

Next, the modified RLS determines 1104 a first estimate of the parameters $\hat{\lambda}(t+1)$, and determines 1105 a second estimate of the parameters $\hat{\lambda}(t+1)$ by projecting the first estimate of the parameters onto the admissible range of $\lambda = [\theta \quad \eta]^T$ as determined by (15b). Then, the modified RLS waits 1106 until the next measurement.

The second parameter estimates can be determined 1105 in a number of ways. For example, one embodiment determine the second parameter by first saturating each component of the first estimate of the parameters $\hat{\lambda} = [\hat{\theta} \quad \hat{\eta}]^T$ between 0 and 1, and then normalizing each component of $\hat{\theta}$ and $\hat{\eta}$ in the first estimate of the parameters, by dividing them by the sum of the saturated components of $\hat{\theta}$ and $\hat{\eta}$ in the first estimate of the parameters. This results in the estimate of parameter vector (16) at the current time step, thereby giving an updated estimate of the current model in (13) and (14). In other embodiments, other regression models and/or estimation algorithms are used for updating the current model of the machine 201 based on (13) and (14).

Cost Function

In some embodiments of the invention, the cost function module 207 initialize the current cost function 209 based on a nominal cost function. In one embodiment, the nominal cost function is multifaceted and includes conflicting objectives. For example, the cost function can include a first term for determining a first value for a control input according to an objective of the operation and includes a second term for determining a second value for the control input for reducing the difference between the current state of the machine and the state estimated with the model of the machine, such that the optimization optimizes a combination of the first term and the second term, wherein the updating the cost function includes changing a weight of the second term in the combination.

In one embodiment, the cost function takes the form

$$F_t(x_N) + \sum_{k=1}^N L_t(x_k, u_k, P_k) \quad , \quad (19)$$

where F_t and L_t are functions of their arguments that bias the machine's states and inputs to values that reflect the multifaceted objective, and P_k is the predicted parameter error covariance matrix from the RLS algorithm. In one embodiment, the L_t includes a dual objective trading regulation of the states of the machine and objectives of the learning the parameters of the model. For example, the first term of the cost function is related to a performance of the machine, and the second term is related to improving estimation of the parameters of the model, wherein the second term is weighted by reliability of the current model of the machine measured as a nonnegative, nondecreasing function of a prediction error of the current model.

In one embodiment the function L_t is

$$L_t(x_k, u_k, P_k) = x_k^T Q x_k + u_k^T R u_k + \gamma \left(y(t) - M^T(x(t-1), u(t-1)) \hat{\lambda}(t-1) \right) \psi(P_k)$$

where γ is a function of the residual error between the state predicted by the current model 201 and the actual measured state 106, and $\psi(P_k)$ is an information functional of the predicted parameter error covariance matrix.

The information functional is a measure of the information associated with the unknown parameter vector (16), examples of which include trace, determinant, and maximum eigenvalue. If the information functional is given priority in the cost function, i.e. γ is large, then the machine's states and inputs are biased towards values that improve model learning; otherwise, the states and inputs are biased towards the regulation of the machine's states.

The current cost function (19) is updated at each time step with the state predicted by the current model and the actual measured state, so that the cost function only attempts to improve the model learning when the residual error is large. For example, the second term of the cost function includes a function of the difference between the previous and the current models and the updating determines the difference between the previous and the current models and updates the second term of the cost function with the determined difference.

In another embodiment, the cost function is separated into two cost functions that are used for input computation 208, where the first cost functions is only concerned with model learning, i.e. $F_t = 0$ and $L_t = \psi(P_k)$, and the second

cost function forms a dual objective, trading regulation of the machine's states and penalizing deviations from the input sequence generated by application of the first cost function.

Input Computation

In some embodiments, the input computation 208 takes the form of a finite horizon numerical optimization problem,

$$\begin{aligned}
 \min_U \quad & F_t(x_N) + \sum_{k=1}^N L_t(x_k, u_k, P_k), \\
 \text{s.t.} \quad & x_{k+1} = M^T(x_k, u_k) \hat{\lambda}(t), \\
 & x_0 = x(t), \\
 & P_0 = P(t), \\
 & u_k \in C_u^\infty(x_k),
 \end{aligned} \tag{20}$$

which is formed from the current cost function (F_t and L_t) 207, the machine model with current parameter estimate $\hat{\lambda}$ 201 that predicts the evolution of the state over the horizon, the robust constraints $C_u^\infty(x_k)$ 206, and the state at the current time step $x(t)$. The problem (20) is solved using a numerical solver, which finds the input sequence $U = [u_1 \dots u_N]^T$ that minimizes the current cost function subject to the problem constraints. The first input u_1 in the input sequence is considered as the output of the input computation 208 and is applied to the machine 102. At the next time step, $t + 1$ the model and cost function are

updated, the state is updated, and the numerical optimization problem is solved again.

In alternative embodiment, the problem (20) is separated into two phases:

- i) a model learning phase, e.g., $L_t = \psi(P_k)$, which is only concerned with generating an input sequence that minimizes the information functional of the predicted parameter error covariance matrix, and
- ii) a control phase, which is only concerned with generating an input sequence that regulates the machine to the origin, e.g.,

$$L_t = x_k^T Q x_k + u_k^T R u_k.$$

The switch from the model learning phase to the control phase is based on the residual error between the state predicted by the current model 201 and the actual measured state 106, that is, when the error is below a set threshold, model learning is no longer necessary and a switch to the control phase is enacted. A switch back to the model-learning phase is enacted if the error grows beyond a set threshold.

The above-described embodiments of the present invention can be implemented in any of numerous ways. For example, the embodiments may be implemented using hardware, software or a combination thereof. When implemented in software, the software code can be executed on any suitable processor or collection of processors, whether provided in a single computer or distributed among multiple computers. Such processors may be implemented as integrated circuits, with one or more processors in an integrated circuit component. Though, a processor may be implemented using circuitry in any suitable format.

Further, it should be appreciated that a computer may be embodied in any of a number of forms, such as a rack-mounted computer, a desktop computer, a laptop computer, minicomputer, or a tablet computer. Such computers may be interconnected by one or more networks in any suitable form, including a local area network or a wide area network, such as an enterprise network or the Internet. Such networks may be based on any suitable technology and may operate according to any suitable protocol and may include wireless networks, wired networks or fiber optic networks.

Also, the various methods or processes outlined herein may be coded as software that is executable on one or more processors that employ any one of a variety of operating systems or platforms. Additionally, such software may be written using any of a number of suitable programming languages and/or programming or scripting tools.

Also, the embodiments of the invention may be embodied as a method, of which an example has been provided. The steps performed as part of the method may be ordered in any suitable way. Accordingly, embodiments may be constructed in which acts are performed in an order different than illustrated, which may include performing some acts simultaneously, even though shown as sequential acts in illustrative embodiments.

1. A method for controlling an operation of a machine according to a model of the machine, comprising:

controlling iteratively the operation of the machine with control inputs determined using the model based on an optimization of a cost function subject to constraints on the control inputs, wherein at least one current iteration comprises:

determining a current state of the machine after the controlling with a previous control input determined for a previous iteration by optimizing a previous cost function using a previous model of the machine;

determining a current model of the machine to reduce a difference between the current state and a state estimated using the previous model of the machine;

updating the cost function based on a difference between the previous model and the current model to produce a current cost function; and

determining a current control input for the controlling at the current iteration using the current model and the current cost function, wherein steps of the methods are performed by a processor of a controller controlling the operation of the machine.

2. The method of claim 1, wherein the cost function includes a first term for determining a first value for a control input according to an objective of the operation and includes a second term for determining a second value for the control input for reducing the difference between a future state of the machine and a future state estimated with the current model of the machine, such that the optimization optimizes a combination of the first term and the second term, wherein the updating the cost function includes changing a weight of the second term in the combination.

3. The method of claim 2, wherein the second term of the cost function includes a function of the difference between the current state of the machine and a state of the machine estimated using the current machine model from a previous machine state and a previous machine control input, wherein the updating comprises:

determining the difference between the previous and the current models; and
updating the second term of the cost function with the determined difference.

4. The method of claim 2, wherein the first term of the cost function is related to a performance of the machine, and the second term is related to improving estimation of the parameters of the model of the machine, wherein the second term is weighted by reliability of the current model of the machine measured as a nonnegative, nondecreasing function of a prediction error of the current model of the machine determined from the previous machine state, the previous machine control input and the current machine state.

5. The method of claim 1, wherein the model of the machine includes a nominal model defining relationships among parameters of the model and an uncertainty model defining a range of values for at least one parameter of the model, and wherein the current model is determined such that a current value of the parameter of the current model is within the range of values.

6. The method of claim 5, wherein the uncertainty model is extended such that a combination of the nominal model and the uncertainty model is included into a convex combination of linear models with a convex combinations of additive disturbances.

7. The method of claim 6, wherein the current model of the machine is determined recursively such that the parameters of the current model are within the convex combination of linear models and the convex combinations of additive disturbances.

8. The method of claim 6, wherein the determining the current model comprises:

determining a combination vector of the linear models and a combination vector of the additive disturbances;

projecting the combination vector of the linear models in the convex combination of the linear models; and

projecting the combination vector of the additive disturbances in the convex combination of the additive disturbances.

9. The method of claim 5, wherein the constraints on the control inputs include control-invariant constraints on the control inputs selected such that any value of a control input satisfying the control-invariant constraints maintains a state of the machine in a control-invariant subset of states satisfying constraints on the operation of the machine, wherein for any state of the machine within the control-invariant subset there is an admissible control input satisfying the control-invariant constraints and maintaining the state of the machine within the control-invariant subset for all values of the parameter of the model within the range defined by the uncertainty model.

10. The method of claim 6, wherein the constraints on the control inputs include control-invariant constraints determined from the convex combination of the linear models and the convex combination of the additive disturbances by backward

reachability iterations that guarantee that for any state into a control-invariant subset of states satisfying constraints on the operation of the machine, there exists a control input such that the control-invariant constraints are satisfied during the operation for all values of the parameters of the model of the machine defined by the nominal and the uncertainty models.

11. The method of claim 5, wherein the constraints on the control inputs include stability constraints converging the state of the machine to a target value for all values of the parameters of the model of the machine defined by the nominal and the uncertainty models.

12. The method of claim 11, wherein the stability constraints include a control Lyapunov function of the machine.

13. The method of claim 12, wherein the control Lyapunov function is an infinity-norm control Lyapunov function that satisfies a feasible value reduction test for all states of the machine satisfying the control-invariant constraints comprising of:

- selecting rows of a matrix describing the infinity-norm control Lyapunov function;

- determining convex components of the states of the machine that satisfy, for positive and negative conditions, a feasible value reduction on the rows of the matrix describing the infinity-norm control Lyapunov function for at least one input of the machine satisfying the control-invariant constraints;

- determining a union of the convex components;

- verifying that all the states of the machine in the control-invariant subset of the states of the machine are contained in the union of the convex components.

14. The method of claim 1, wherein the optimization is solved by numerical optimization algorithms.

15. A method for controlling an operation of a machine according to a model of the machine including a nominal model defining relationships among parameters of the model and an uncertainty model defining a range of values for at least one parameter of the model, comprising:

controlling iteratively the operation of the machine with control inputs determined using the model of the machine based on an optimization of a cost function, wherein the optimization is subject to control-invariant constraints on the control inputs selected such that any value of the control input satisfying the control-invariant constraints maintains a state of the machine in a control-invariant subset of states satisfying constraints on the operation of the machine, wherein for any state of the machine within the control-invariant subset there is an admissible control input satisfying the control-invariant constraints and maintaining the state of the machine within the control-invariant subset for all values of the parameters of the model within the range defined by the uncertainty model, wherein at least one current iteration comprises:

determining a current state of the machine resulted from the controlling with a previous control input determined for a previous iteration by optimizing a previous cost function using a previous model of the machine;

determining a current model of the machine to reduce a difference between the measured current state and a state estimated using the previous model of the machine, such that a current value of the parameter of the current model is within the range of values;

updating the cost function based on a difference between the previous and the current models, wherein the cost function includes a first term for determining

a first value for the control input according to an objective of the operation and includes a second term for determining a second value for the control input for reducing the difference between the current state of the machine and a state estimated with a model of the machine, such that the optimization optimizes a combination of the first term and the second term, wherein the updating the cost function includes changing a weight of the second term in the combination; and

determining a current control input for the controlling at the current iteration using the current model and the current cost function, wherein steps of the methods are performed by a processor of a controller controlling the operation of the machine.

16. The method of claim 15, wherein the second term of the cost function includes a function of the difference of the current state of the machine and the state of the machine estimated using the current machine model from a previous machine state and a previous machine control input, wherein the updating comprises:

determining the difference between the previous and the current models; and

updating the second term of the cost function with the determined difference.

17. A control system for controlling iteratively an operation of a machine according to a model of the machine, comprising:

a memory storing the model of the machine including a nominal model defining relationships among parameters of the model and an uncertainty model defining a range of values for at least one parameter of the model, and the constraints on the machine; and

at least one processor for executing modules of the controller comprising:

a control input module for determining a current control input for the controlling during a current iteration by optimizing a current cost function subject to constraints on the current control input using a current model of the machine;

a model learning module for determining the current model of the machine, such that a current value of the parameter of the current model is within the range of values and reduces a difference between a current state of the machine resulted from the controlling with a previous control input determined for a previous iteration by optimizing a previous cost function using a previous model of the machine and an estimated state estimated using the previous model of the machine; and

a cost function module updating the previous cost function using a difference between the current state of the machine and the state of the machine estimated using the current machine model from a previous machine state and a previous machine control input.

18. The control system of claim 17, wherein the current cost function includes a first term for determining a first value for the current control input according to an objective of the operation and includes a second term for determining a second value for the current control input for reducing the difference between the current state and the state estimated according to the current model of the machine, such that the optimization optimizes a combination of the first term and the second term, wherein the updating the cost function includes changing a weight of the second term in the combination.

19. The control system of claim 18, wherein the second term of the cost function is updated using a function of the difference between the current state of the machine

and the state of the machine estimated using the current machine model from a previous machine state and a previous machine control input.

20. The control system of claim 17, wherein the constraints on the control inputs include control-invariant constraints on the control inputs selected such that any value of a control input satisfying the control-invariant constraints maintains a state of the machine in a control-invariant subset of states satisfying constraints on the operation of the machine, wherein for any state of the machine within the control-invariant subset there is an admissible control input satisfying the control-invariant constraints and maintaining the state of the machine within the control-invariant subset for all values of the parameter of the model within the range defined by the uncertainty model.

Abstract

A method controls iteratively the operation of the machine with control inputs determined using the model of the machine based on an optimization of a cost function subject to constraints on the control inputs. A current iteration of the method includes determining a current state of the machine after the controlling with a previous control input determined for a previous iteration by optimizing a previous cost function using a previous model of the machine and determining a current model of the machine to reduce a difference between the current state and a state estimated using the previous model of the machine. The cost function is updated during the current iteration based on a difference between the previous model and the current model to produce a current cost function. A current control input for the controlling at the current iteration is determined using the current model and the current cost function.

Representative Drawing

Fig. 1A

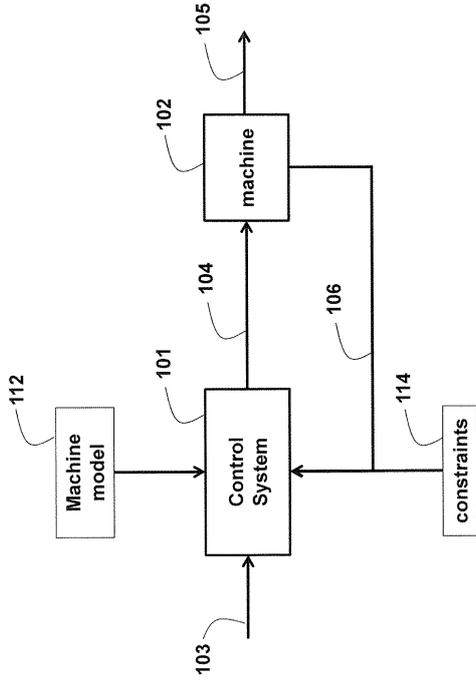


FIG. 1A

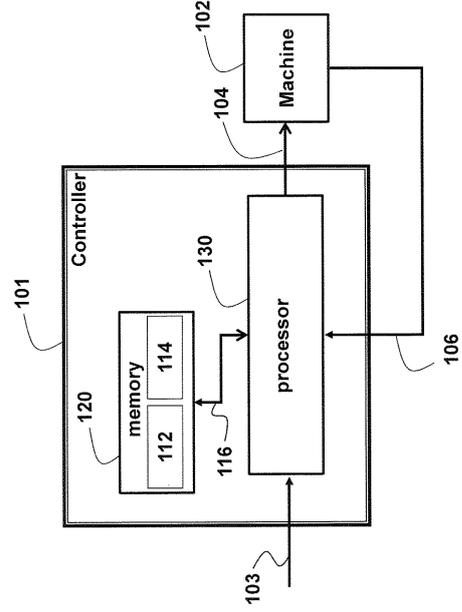


FIG. 1B

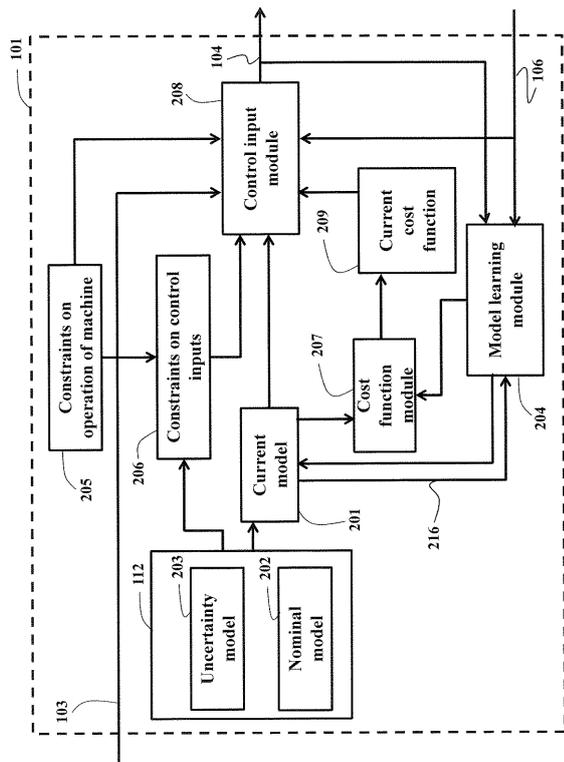


FIG. 2A

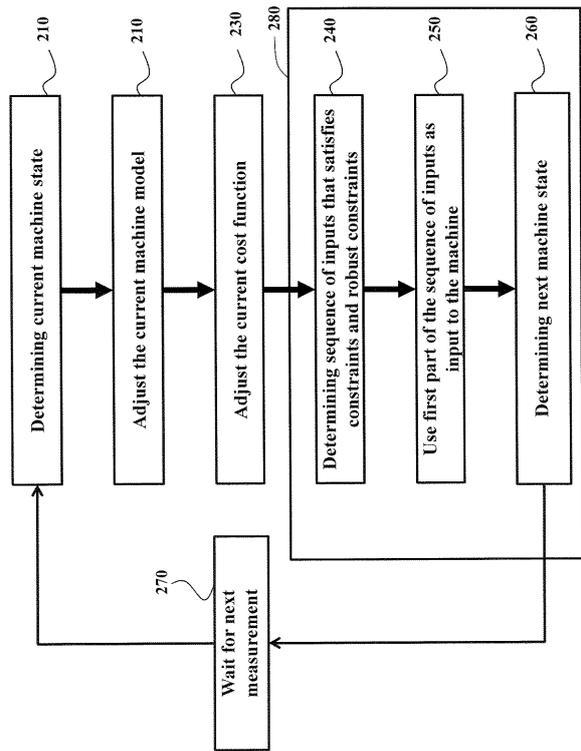


FIG. 2B

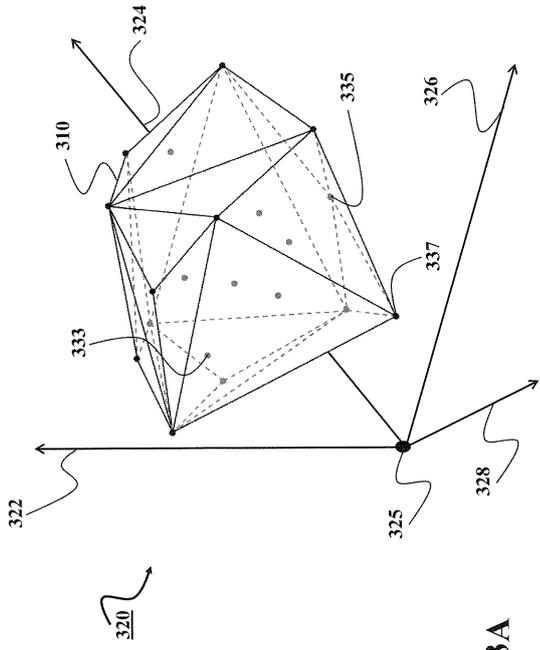


FIG. 3A

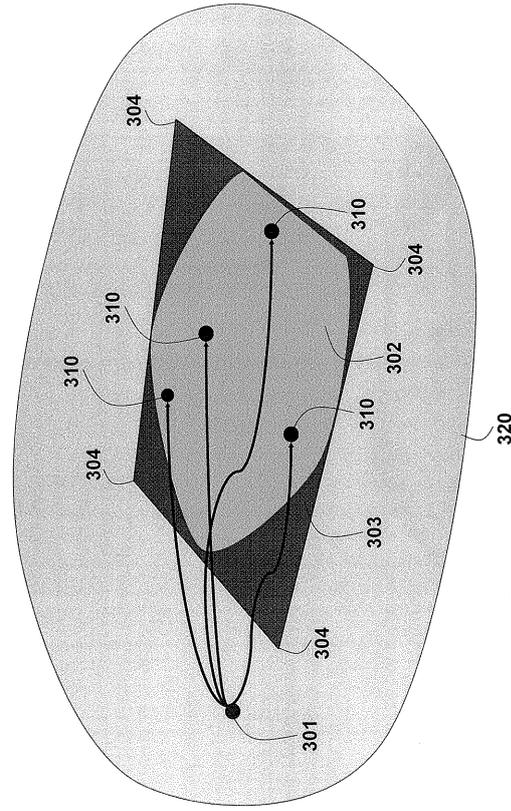


FIG. 3B

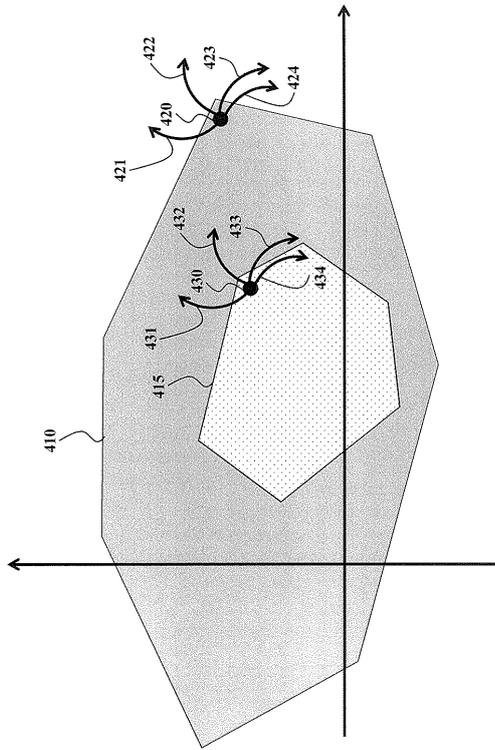


Fig. 4A

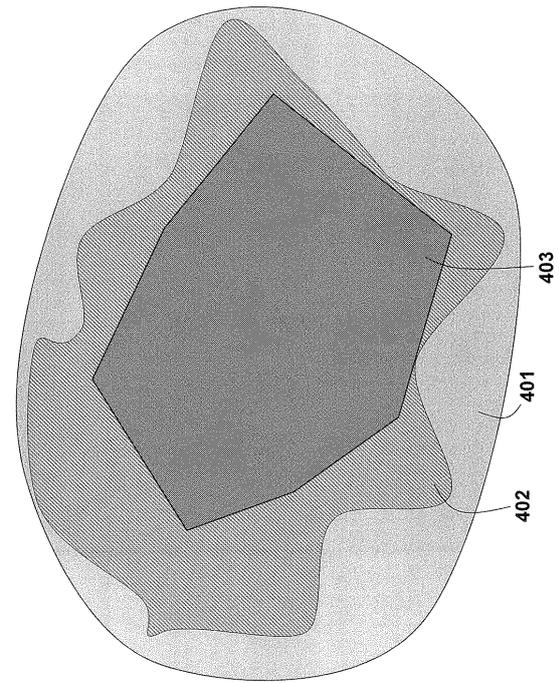


Fig. 4B

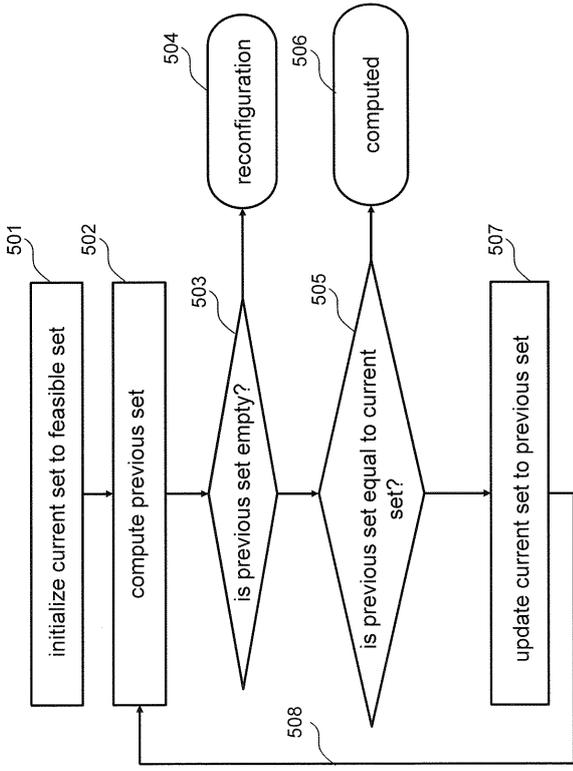


Fig. 5

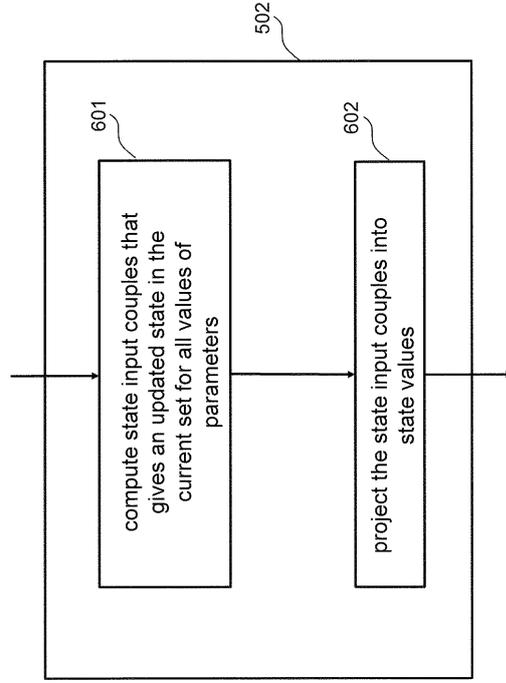


Fig. 6

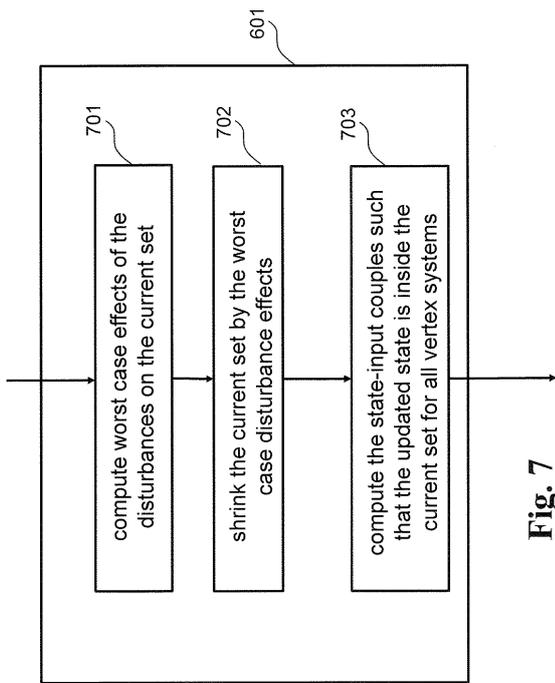


Fig. 7

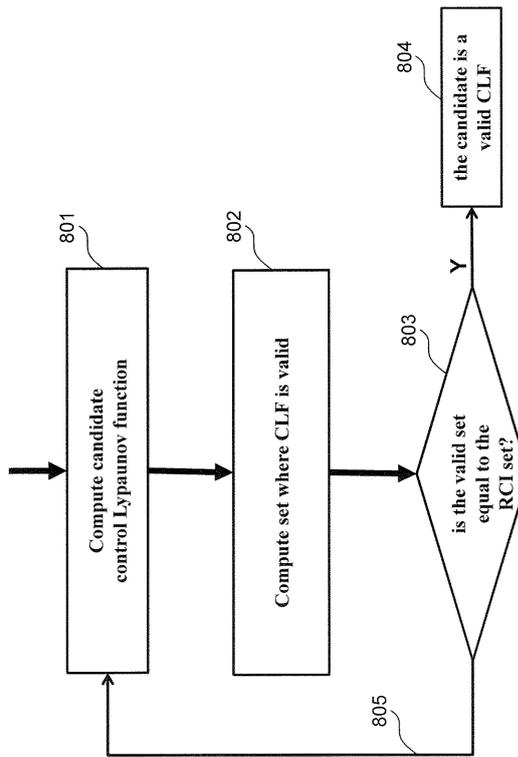


Fig. 8

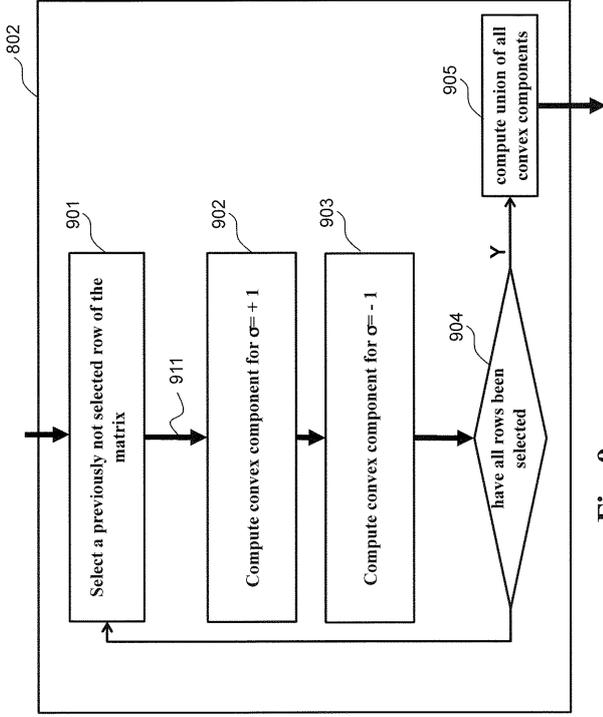


Fig. 9

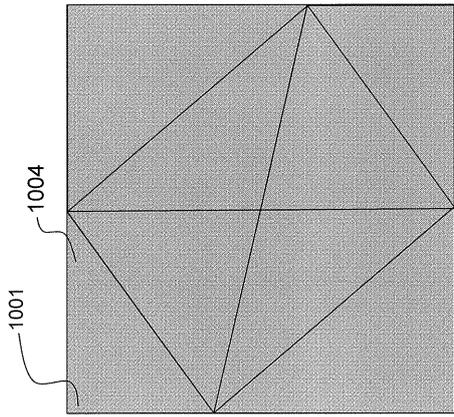


Fig. 10B

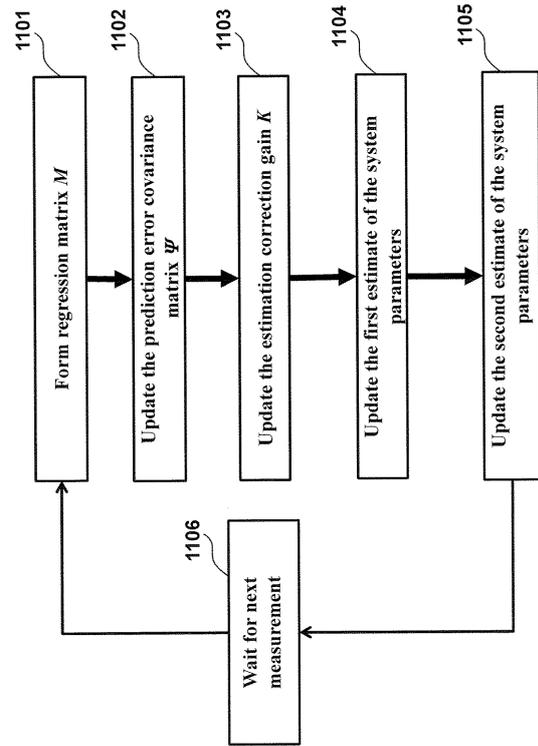


Fig. 11

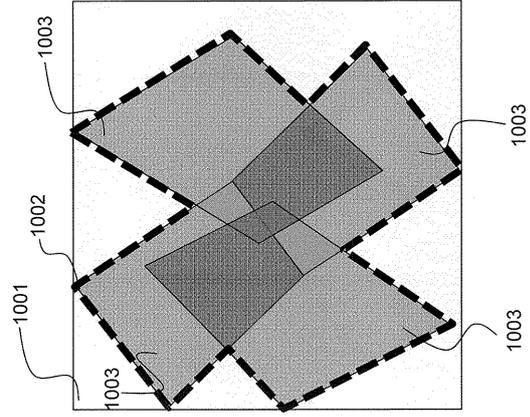


Fig. 10A