

(19) 日本国特許庁(JP)

(12) 特 許 公 報(B2)

(11) 特許番号

特許第5345551号
(P5345551)

(45) 発行日 平成25年11月20日(2013.11.20)

(24) 登録日 平成25年8月23日(2013.8.23)

(51) Int.Cl.		F I	
GO6N	3/04	(2006.01)	GO6N 3/04 E
GO6N	3/00	(2006.01)	GO6N 3/00 550E
GO6N	3/08	(2006.01)	GO6N 3/08 Z
GO5B	13/04	(2006.01)	GO5B 13/04

請求項の数 11 (全 8 頁)

(21) 出願番号	特願2009-544386 (P2009-544386)	(73) 特許権者	390039413
(86) (22) 出願日	平成19年12月19日 (2007.12.19)		シーメンス アクチエンゲゼルシャフト
(65) 公表番号	特表2010-515181 (P2010-515181A)		Siemens Aktiengesellschaft
(43) 公表日	平成22年5月6日 (2010.5.6)		ドイツ連邦共和国 D-80333 ミュンヘン ヴィッテルスバッハープラッツ 2
(86) 国際出願番号	PCT/EP2007/064264		Wittelsbacherplatz 2, D-80333 Muenchen, Germany
(87) 国際公開番号	W02008/080863	(74) 代理人	100061815
(87) 国際公開日	平成20年7月10日 (2008.7.10)		弁理士 矢野 敏雄
審査請求日	平成21年8月31日 (2009.8.31)	(74) 代理人	100099483
(31) 優先権主張番号	102007001026.7		弁理士 久野 琢也
(32) 優先日	平成19年1月2日 (2007.1.2)		
(33) 優先権主張国	ドイツ (DE)		

最終頁に続く

(54) 【発明の名称】 計算機支援による技術システムの開ループ制御および/または閉ループ制御のための方法

(57) 【特許請求の範囲】

【請求項 1】

技術システムの計算機支援による開ループ制御および/または閉ループ制御のための方法において、

a) 複数の時点 (t) について、前記技術システムを、第 1 の次元を有する第 1 の状態空間内の複数の状態変数をもつ状態 (x_t) によって表し、

b) 前記第 1 の状態空間の状態 (x_t) を、入力層 (I)、隠れリカレント層 (H)、および出力層 (O) を有するリカレントニューラルネットワークにより、既知の状態を訓練データとして用いてモデル化し、その際、

i) 前記複数の時点 (t) について、前記入力層 (I) と前記出力層 (O) をそれぞれ前記第 1 の状態空間内の状態 (x_t) により形成し、

ii) 前記隠れリカレント層 (H) を、第 2 の次元を有する第 2 の状態空間内の複数の隠れ状態変数をもつ隠れ状態 (s_t) により形成し、ただし、第 2 の次元は第 1 の次元よりも低く、

c) 前記第 2 の状態空間内の隠れ状態 (s_t) に対して、前記技術システム上で行動を実施することにより前記技術システムの開ループ制御および/または閉ループ制御のための学習法および/または最適化法を実行する、ことを特徴とする技術システムの計算機支援による開ループ制御および/または閉ループ制御のための方法。

【請求項 2】

前記技術システムは非線形動特性を有している、請求項 1 記載の方法。

10

20

【請求項 3】

前記ステップ b) において、前記リカレントニューラルネットワークは非線形活動化関数を使用する、請求項 1 または 2 記載の方法。

【請求項 4】

前記学習法および / または最適化法は強化学習法である、請求項 1 から 3 のいずれか 1 項記載の方法。

【請求項 5】

前記ステップ b) において、前記リカレントニューラルネットワークにより求められた状態 (x_t) と前記訓練データの既知の状態 (x_t^d) の間の偏差が所定の閾値よりも小さい限り、前記第 2 の状態空間の第 2 の次元を漸次縮小する、請求項 1 から 4 のいずれか 1 項記載の方法。

10

【請求項 6】

各時点 (t) における前記入力層 (I) 内の前記技術システムの各状態 (x_t) は、前記各時点 (t) における前記隠れ層 (H) の隠れ状態 (s_t) を介して前記各時点 (t) より後の時点 ($t+1$) における前記出力層 (O) 内の前記技術システムの状態 (x_t) と結合されている、請求項 1 から 5 のいずれか 1 項記載の方法。

【請求項 7】

前記リカレントニューラルネットワークは将来の状態 (x_t) を考慮した動的的に整合的な時間的展開をもつネットワークである、請求項 1 から 6 のいずれか 1 項記載の方法。

【請求項 8】

前記リカレントニューラルネットワークによって前記第 1 の状態空間の状態 (x_t) をモデル化するために、逆伝搬法を用いる、請求項 1 から 7 のいずれか 1 項記載の方法。

20

【請求項 9】

前記リカレントニューラルネットワークは以下の式で表される、

【数 1】

$$s_t = \tanh(As_{t-1} + Bx_t + \theta)$$

$$x_{t+1} = Cs_t$$

30

$$\sum_t \sum_\tau (x_\tau - x_\tau^d)^2 \rightarrow \min_{A, B, C, \theta}$$

ただし、 θ の値域には、時点 t より前の予め決められた個数 m の時間ステップと、時点 t より後の予め決められた個数 n の時間ステップとが含まれており、

$t \in \{m, \dots, T-n\}$ 、ここで T は訓練データが存続する時点の個数であり、

x_t は、時点 t において前記リカレントニューラルネットワークによって決定される前記技術システムの状態を表し、

x_t^d は、前記訓練データによる時点 t における既知の状態を表し、

s_t は、前記リカレントニューラルネットワークの隠れ層の時点 t における隠れ状態を表してあり、

40

A, B, C は求めようとする行列、 θ は求めようとするバイアスである、請求項 1 から 8 のいずれか 1 項記載の方法。

【請求項 10】

前記技術システムはタービン、とりわけガスタービンである、請求項 1 から 9 のいずれか 1 項記載の方法。

【請求項 11】

計算機上で実行したときに請求項 1 から 10 のいずれか 1 項記載の方法を実行する、機械可読媒体上に記憶されたプログラムコードを有するコンピュータプログラム。

【発明の詳細な説明】

50

【技術分野】

【0001】

本発明は、技術システムをコンピュータ支援により開ループ制御および/または閉ループ制御する方法と、相応するコンピュータプログラム製品に関する。

今日では、技術システムは高度な複雑さを有していることが多い。つまり、技術システムは多数の状態変数をもつ状態により記述される。ここで、状態変数とは特に、例えば圧力、温度、電力といった物理量のような測定可能な状態量のことである。複雑な技術システムを制御する場合、所定の基準を考慮しつつ技術システムの時間的な動特性を最適化する計算機支援による方法が使用されることが多い。このような方法の例が、先行技術から十分に知られている強化学習(Reinforcement Learning 文献[2]を参照されたい)などの学習法である。これらの方法は技術システム上で実行されるべき適切な行動を決定することにより技術システムの動特性を最適化する。なお、これらの行動は、例えばバルブ位置の変化、圧力の上昇などのような技術システム上の所定の操作量の変化を含む。各行動は、例えば費用関数を含めた報酬とペナルティとによって適切に評価され、これにより技術システムの最適な動特性を達成することができる。

10

【0002】

技術システムの動特性を制御ないし最適化する上記の標準的な方法の問題点は、この種の方法は多数の状態変数をもつ(すなわち、高次元の状態空間内の)状態に対して限られた範囲内でしか使用できないということにある。

20

【0003】

先行技術からは、状態空間を縮退させることのできるいわゆる「特徴選択」法が公知である。しかしながら、通常は、関連する状態変数を選択するだけで、すべての変数に基づいて状態空間の次元を低減させることは行われない。さらに、これらの方法は統計的であり、技術システムの動特性の明示的な考察や識別は行われない。

30

文献「Xianfeng Zhung et al.: "A novel approach for modeling cracking furnace severity", Intelligent Control and Automation, 2004, WCICA 2004, Fifth World Congress on Hang-zhou, China, 15-19 June 2004, Piscataway, NJ, USA, IEEE, US, vol. 1, 15. Juni 2004 (2004-06-15), pp.250-253, XP010729576, ISBN: 0-7803-8273-0」および文献「Min Han et al.: "Application of Neural Networks on Multivariate Time Series Modeling and Prediction", American Control Conference, 2006, Minneapolis, MN, USA, June 14-16, 2006, Piscataway, NJ, USA, IEEE, 14. Juni 2006 (2006-06-14), pp.3698-3703, XP010929375, ISBN: 1-4244-0209-3」には、時間的に順次連続する状態をモデル化するために、PCA分析(PCA=主成分分析)をリカレントニューラルネットワークと組み合わせることが記載されている。

文献「zhou et al.: "Fault detection and classification in chemical processes based on neural networks with feature extraction", ISA Transactions, Instrument Society of America, Pittsburgh, US, vol. 42, No. 4, October 2003 (2003-10), pp.651-664, XP005835325, ISSN: 0019-0578」には、多項式フィッティングをニューラルネットワークに基づいた状態のモデル化と組み合わせることが記載されている。

40

【0004】

それゆえ、本発明の課題は、状態空間を適切に縮退させた後にそれ自体公知の学習法および最適化法を使用することができるようにした、技術システムの計算機支援による開ループ制御および/または閉ループ制御のための方法を提供することである。

【0005】

この課題は独立請求項により解決される。本発明の展開形態は従属請求項に記載されている。

【0006】

本発明による方法は、複数の時点について、第1の状態空間内に複数の状態変数をもつそれぞれの状態により技術システムを特徴付けることに基づいている。第1の状態空間内の状態は、入力層、隠れリカレント層、および出力層を有するリカレントニューラルネッ

50

トワークにより、既知の状態を訓練データとしてモデル化される。その際、

i) 前記複数の時点について、入力層と出力層がそれぞれ第1の状態空間内の状態により形成される。

ii) 隠れリカレント層は、第2の次元を有する第2の状態空間内の複数の隠れ状態変数をもつ隠れ状態により形成される。ただし、第2の次元は第1の次元よりも低い。

最後に、技術システム上で行動が実施される際に、技術システムの開ループ制御および/または閉ループ制御のための学習法および/または最適化法が実行される。この後、この学習法ないし最適化法は第2の状態空間内の隠れ状態を使用する。

【0007】

第2の状態空間の次元は低くなっているため、元の第1の状態空間が高次元であるせいで使用できなかった学習法および/または最適化法が使用可能となる。それゆえ、本発明は、高度に複雑な技術システムに対してもそれ自体公知の学習法および/または最適化法を非常に柔軟に使用できるような方法を成している。また、本発明による方法は状態空間の次元縮小の効率的な方式である。この方法では、技術システムの同定の高品質を利用して、リカレントニューラルネットワークにより状態空間の次元が最小となるシステムの展開が模倣ないしモデル化される。類似した目標設定をもつ既存の方法と比べると、動特性の明確な同定およびモデル化が行われる。特に、リカレントニューラルネットワークの使用は非線形動特性のモデル化も可能にする。この方法はすでに発明者によりガスタービンの制御方法に投入され、成功を収めている。

【0008】

本発明による方法は、特に、非線形の動特性を有する技術システムも開ループ制御ないし閉ループ制御することができるという利点を有している。さらに、本発明による方法では、非線形の活動化関数を有するリカレントニューラルネットワークを使用することもできる。

【0009】

すでに上で述べたように、本発明によれば、リカレントニューラルネットワークを介して求められた縮退した状態空間内で公知の学習法および/または最適化法が使用される。これらの学習法および/または最適化法は、例えば、従来技術から十分に公知のすでに上で述べた強化学習法であってよい。

【0010】

十分な予測品質を保ちつつ、状態空間の次元をできる限り低くするために、本発明の1つの実施形態では、リカレントニューラルネットワークにより求められた状態と訓練データの既知の状態の間の偏差が所定の閾値よりも小さい限り、第2の状態空間の第2の次元が縮小される。このようにして、公知の学習法のデータ効率的な適用を可能にする最小の状態空間が得られる。

【0011】

本発明によるリカレントニューラルネットワークは、有利には、各時点における入力層内の技術システムの各状態が前記各時点における隠れ層の隠れ状態を介して前記各時点より後の時点における出力層内の技術システムの状態と結合されているように形成されている。ここで、リカレントネットワークは、有利には、将来の状態を考慮した動的に整合的な時間的展開をもつネットワークである(英語では"Network with Dynamically Consistent Overshooting"と呼ばれる)。この種のネットワークでは、ネットワーク自身の予測が将来の未知の入力としてネットワーク内で使用される。

第1の状態空間の状態をリカレントニューラルネットワークによってモデル化するには、とりわけ逆伝播法を、特に文献[1]に記載された方法を使用することができる。

【0012】

有利な実施形態では、状態空間の最小化に用いられるリカレントニューラルネットワークは以下の式によって表される。

10

20

30

40

【数 1】

$$s_t = \tanh(As_{t-1} + Bx_t + \theta)$$

$$x_{t+1} = Cs_t$$

$$\sum_t \sum_\tau (x_\tau - x_\tau^e)^2 \rightarrow \min_{A,B,C,\theta}$$

ここで の値域には、時点 t より前の予め決められた個数 m の時間ステップと、時点 t より後の予め決められた個数 n の時間ステップとが含まれており、

$t \in \{m, \dots, T-n\}$ 、ここで T は訓練データが存続する時点の個数であり、

x_t は、時点 t においてリカレントニューラルネットワークによって決定される技術システムの状態を表し、

x_t^e は訓練データによる時点 t における既知の状態を表し、

s_t は、リカレントニューラルネットワークの隠れ層の時点 t における隠れ状態を表して

おり、
 A, B, C は求めようとする行列、また θ は求めようとするバイアスである。

すでに上で述べたように、本発明は相応の状態により記述される任意の技術システムに対して使用することができる。1つの適用事例は、例えばタービン、とりわけガスタービンである。

【0013】

本発明はさらに、上記方法の他に、コンピュータ上で走らせたときに本発明による方法を実行するプログラムコードをコンピュータ可読媒体に記憶させたコンピュータプログラム製品にも関している。

【0014】

以下では、本発明の実施例を添付図面に基づき詳細に説明する。

【図面の簡単な説明】

【0015】

【図 1】本発明の実施形態において状態空間の次元縮小のために使用されるリカレントニューラルネットワークの概略図である。

【0016】

本発明の以下に示す実施形態では、第 1 の状態空間の次元の低減がニューラルネットワークにより達成される。第 1 の状態空間は各時点 t における技術システムの状態 x_t の状態変数の数により決まる次元によって特徴付けられる。したがって、状態 x_t は技術システムの状態変数を成分とする状態ベクトルである。状態変数の値は測定してもよい。技術システムが例えばガスタービンならば、状態変数はとりわけガス圧、ガス温度、燃焼室加速度等の量を含む。第 1 の状態空間の次元はたいてい高次元であり、公知の学習法にとっては大きすぎる場合が多い。それゆえ、本発明の課題は公知の学習法を使用できるように状態空間の次元を最小化することである。この課題は図 1 のリカレントニューラルネットワークを用いた以下に示す実施形態において解決される。

【0017】

図 1 のネットワークは入力層 I を含んでいる。入力層 I は、観察時点 t において、相応する高次元の状態 x_t と過去の状態 $x_{t-1}, x_{t-2}, x_{t-3}$ 等から形成されている。入力層の状態は行列 B を介して隠れ層 H の隠れ状態およびバイアス θ と結合されている。ただし、時点 t における状態 x_t は隠れ層 H の同じ時点における相応する隠れ状態 s_t に対応している。第 1 の状態空間の縮小を達成するために、隠れ状態 s_t の状態空間の次元は第 1 の状態空間の次元よりも低い。なお、隠れ状態 s_t の状態空間は請求項では第 2 の状態空間と呼ばれている。隠れ層 H は、時点 t における隠れ状態 s_t を行列 A とバイアス θ を介して後続の時点における状態 s_{t+1} と結合するリカレント層である。層 H の個々の隠れ状態 s_t は再び - 入力層 I と同様に - 技術システムの状態 x_t によって表される出力層 O と結合されている。各時点 t における隠れ状態 s_t は行列 C を介して次の時点 $t+1$ における状態

10

20

30

40

50

x_{t+1} と結合されている。

【 0 0 1 8 】

図 1 に示されているリカレントニューラルネットワークは、技術システムの既知の状態を含む訓練データを用いて訓練される。したがって、相応する技術システムの時間的な動特性がこのネットワークによりモデル化される。図 1 によるリカレントネットワークは、将来の状態を考慮した動的に整合的な時間的展開をもつネットワークであり、英語では "Network with Dynamically Consistent Overshooting" と呼ばれる。これは、ネットワーク内で時点 t に過去の状態 x_t, x_{t-1}, \dots 等だけでなく、将来の状態 x_{t+1}, x_{t+2}, \dots 等も考慮されることを意味する。出力層におけるネットワークの固有の予測、すなわち、図 1 の状態 x_{t+1}, x_{t+2} および x_{t+3} は再びネットワークへの入力として使用される。図 1 では、これが出力層 O の状態を隠れ層 H の相応する状態と結合する破線によって示されている。それゆえ、図 1 によるリカレントニューラルネットワークでは、システム自体の状態 x が予測される。このようにして、基礎となる技術システムの動特性をモデル化することができる。数学的には、図 1 のネットワークは以下の式により表される。

【 数 2 】

$$s_\tau = \tanh(As_{\tau-1} + Bx_\tau + \theta)$$

$$x_{\tau+1} = Cs_\tau$$

$$\sum_t \sum_\tau (x_\tau - x_\tau^e)^2 \rightarrow \min_{A,B,C,\theta}$$

これらの式は時点 t におけるリカレントニューラルネットワークに関係している。時点 t には、時点 t の値域が考慮される。 t の値域は時点 t より前の所定数 m の時間ステップと時点 t より後の所定数 n の時点（いわゆるオーバーシュート部分）とを含んでいる。

ここで、 $t \in \{m, \dots, T-n\}$ が成り立つ。

ただし、 T は訓練データが存続する時点の個数、すなわち、技術システムの既知の状態が存続する時点の個数を表している。

【 0 0 1 9 】

上記の式によれば、ニューラルネットワークのパラメータとして、行列 A, B, C およびバイアス θ が求められる。なお、これらのパラメータは、ネットワークによって求められた状態 x と相応する既知の状態 x^d との間の平方誤差が訓練データに従って最小となるように選択されている。

技術システムをリカレントニューラルネットワークによってモデル化した後、技術システム上で行動を実施する際に技術システムを開ループ制御および/または閉ループ制御するために、このモデル化から得られた隠れ層の状態 s_t に対して相応の学習法および/または最適化法が適用される。隠れ層 H 内の状態の次元は第 1 の状態空間の次元よりも低いので、元の第 1 の状態空間の次元が大きいために適用できなかった学習法が適用可能になる。それゆえ、本発明の方法によれば、公知の複数の学習法または最適化法を技術システムの動特性のモデル化に使用できるように、状態空間を効率的に縮退させることができる。有利な実施形態では、第 1 の状態空間の状態をリカレントニューラルネットワークを用いてモデル化する際、リカレントニューラルネットワークにより求められた状態と訓練データの既知の状態の間の偏差が所定の閾値よりも小さい限り、隠れ状態の次元が漸次縮小される。こうして、状態空間の次元を可能な限り縮小することができる。

【 0 0 2 0 】

学習法ないし最適化法としては、例えば従来技術から公知の強化学習法（いわゆる Reinforcement Learning）を使用することができる。これらの学習法によれば、報酬ないしペナルティを考慮して技術システム上で実行されるべき行動を学習することができ、それにより技術システムの動特性の最適化が可能になる。

【 0 0 2 1 】

文献一覧

10

20


30

40

50

- [1] D.E. Rumelhart, G.E. Hinton, and R.J. Williams, "Learning internal representations by error propagation", in Parallel Distributed Processing: Explorations In The Microstructure of Cognition, D.E. Rumelhart and J.L.M. et al., Eds. Cambridge: MIT Press, 1986, vol. 1, pp. 318-362
- [2] Leslie Pack Kaelbling; Michael L. Littman; Andrew W. Moore, Reinforcement Learning: A Survey, Journal of Artificial Intelligence Research 4 (1996) pp. 237-285

【 図 1 】



フロントページの続き

- (74)代理人 100112793
弁理士 高橋 佳大
- (74)代理人 100128679
弁理士 星 公弘
- (74)代理人 100135633
弁理士 二宮 浩康
- (74)代理人 100114890
弁理士 アインゼル・フェリックス=ラインハルト
- (72)発明者 アントン マキシミアン シェーファー
ドイツ連邦共和国 ミュンヘン ホーエンツォレルンシュトラッセ 10 エルゲーバー
- (72)発明者 シュテフェン ウォルドルフ
ドイツ連邦共和国 アイヒェナウ ハービヒトシュトラッセ 2

審査官 大塚 俊範

- (56)参考文献 特開平08-235145(JP,A)
特表2002-509303(JP,A)
特表2002-522832(JP,A)
特開平5-108601(JP,A)
LONG-JI LIN, Reinforcement Learning for Robots Using Neural Networks, 1993年 1月
6日, pp.1,14-15,28,109-114, URL, <http://oai.dtic.mil/oai/oai?verb=getRecord&meta-dataPrefix=html&identifier=ADA261434>
深谷 亮 他2名, リカレントニューラルネットによる時系列顔表情からの特徴抽出, 電子情報通信学会技術研究報告, 日本, 社団法人電子情報通信学会, 2001年 7月20日, 第101巻, 第238号, p.71-78.
道木 加絵 外, 自律移動ロボットの実時間行動探索に適した記憶構造の提案, 電気学会論文誌C, 2002年12月 1日, Vol. 122-C No. 12, 第2091-2099頁
ニューラルネットワークの設計と応用 知能工学シリーズ, 日本, 株式会社昭晃堂, 1999年
6月30日, 第4巻 初版, 第42-45頁

(58)調査した分野(Int.Cl., DB名)

G06N 3/00 - 3/08
G05B 13/04