

(12) **Patentschrift**

(21) Anmeldenummer:	A 804/2011	(51) Int. Cl.:	G05B 13/04	(2006.01)
(22) Anmeldetag:	31.05.2011		G05B 23/02	(2006.01)
(45) Veröffentlicht am:	15.05.2015		G01M 15/00	(2006.01)
			F02D 45/00	(2006.01)

(56) Entgegenhaltungen:
 SOUNDERS T. M. ET AL: "Cutting the high cost of testing", IEEE SPECTRUM, IEEE INC. NEW YORK, US, vol. 28, no.3, 1 März 1991 (1991-03-01), Seiten 48-51, XP011419566, ISSN: 0018-9235, DOI: 10.1109/6.67285
 DOBOS L. ET AL: "Optimal experiment design techniques integrated with time-series segmentation", APPLIED MACHINE INTELLIGENCE AND INFORMATICS (SAMI), 2010 IEEE 8TH INTERNATIONAL SYMPOSIUM ON, IEEE, PISCATAWAY, NJ, USA, 28. Jänner 2010 (2010-01-28), Seiten 207-210, XP031644176, ISBN: 978-1-4244-6422-7

(73) Patentinhaber:
 AVL LIST GMBH
 8020 GRAZ (AT)

(72) Erfinder:
 Stadlbauer Markus Dipl.Ing.
 1030 Wien (AT)
 Hametner Christoph Dipl.Ing. Dr.techn.
 1020 Wien (AT)
 Jakubek Stefan Dr.
 1230 Wien (AT)
 Winsel Thomas Dr.Ing.
 87730 Bad Grönenbach (DE)
 Keuth Nikolaus Dipl.Ing. Dr.
 8010 Graz (AT)


(74) Vertreter:
 Patentanwälte Pinter & Weiss OG
 Wien

(54) **MASCHINELL UMGESETZTES VERFAHREN ZUM ERHALTEN VON DATEN AUS EINEM NICHT LINEAREN DYNAMISCHEN ECHTSYSTEM WÄHREND EINES TESTLAUFS**

(57) In einem maschinell umgesetzten Verfahren zum Erhalten von Daten aus einem nicht linearen dynamischen Echtssystem während eines Testlaufs, beispielsweise aus einer Brennkraftmaschine, einem Antriebsaggregat oder Teilen davon, wird eine Folge von dynamischen Anregungssignalen für mindestens einen Messkanal gemäß einer zuvor generierten Versuchsplanung für den Testlauf generiert, und der Systemausgang mindestens eines Ausgangskanals wird gemessen.

Um die schnelle und präzise Generierung der Versuchspläne für die globale Messung, Modellierung und Optimierung eines nicht linearen dynamischen Echtsystems zu ermöglichen, wird vorgeschlagen, dass die Folge der dynamischen Anregungssignale durch das Verfahren des Generierens einer Versuchsplanung mit einer Folge von Anregungssignalen generiert wird, wobei Ausgangsdaten durch das Einspeisen der Folge von Anregungssignalen in ein Modell für das Echtssystem erhalten werden, wobei das Modell nicht lineare dynamische Modelle umfasst, und wobei ein Kriterium für den Informationsgehalt von Anregungssignalen der gesamten Versuchsplanungsfolge bestimmt wird,

und in einem folgenden Schritt die Gesamtheit der Folge von Anregungssignalen verändert wird, wodurch neue Ausgangsdaten durch das Einspeisen der veränderten Folge von Anregungssignalen in das Modell für das Echtssystem erhalten werden, das Kriterium für den Informationsgehalt von Anregungssignalen erneut bestimmt wird, und diese Schritte wiederholt werden, bis das Kriterium seinen Optimalwert erreicht hat, wobei die letzte generierte Folge von Anregungssignalen als Versuchsplanung für den Testlauf des Echtsystems verwendet wird.



Beschreibung

MASCHINELL UMGESETZTES VERFAHREN ZUM ERHALTEN VON DATEN AUS EINEM NICHT LINEAREN DYNAMISCHEN ECHTSYSTEM WÄHREND EINES TESTLAUFS

[0001] Maschinell umgesetztes Verfahren zum Erhalten von Daten aus einem nicht linearen dynamischen Echtssystem während eines Testlaufs, beispielsweise aus einer Brennkraftmaschine, einem Antriebsaggregat oder Teilen davon, gemäß dem Oberbegriff von Anspruch 1.

[0002] Im Kraftfahrzeugbereich gibt es einen stets steigenden Bedarf an effizienten und präzisen Modellen, da die Kalibrierung des Motor Steuersystems immer komplexer und aufgrund laufend strenger werdender Regulierungen auch fortwährend teurer wird. Die grundlegenden Anforderungen an gute Modelle sind gute Messdaten und ein entsprechend ausgewählter Messplan. Dadurch erhöht sich die Anzahl der Messungen und folglich wird auch der Messzeitraum länger. Da Zeit am Teststand jedoch sehr teuer ist, besteht Bedarf an effektiven Versuchsplänen, welche die Anzahl der Messpunkte minimieren und den Testzeitraum möglichst effektiv abdecken, während gleichzeitig die Qualität der Modelle, die für die Verwendung dieser Daten trainiert werden, nicht verringert wird. Diese Modelle werden dann dafür verwendet, die Strukturen der Motor Steuergeräte (ECU) zu optimieren und zu kalibrieren oder auch Entscheidungen in Bezug auf Komponenten zu treffen.

[0003] Die optimale Versuchsplanung (OED) optimiert den Informationsgehalt von Anregungssignalen, anhand dessen die Parameter eines Modells mit möglichst geringem Aufwand korrekt festgelegt werden sollen, wie dies in L. Pronzato „Optimal experimental design and some related control problems“ Automatica 44(2):303-325, 2008, erklärt wird. Dynamische Anregungssignale sind durch ihre räumliche Verteilung und ihre Haltezeiten gekennzeichnet. Zur Identifikation linearer dynamischer Systeme werden für gewöhnlich Pseudo Binär Rausch Signale (PRBS) verwendet, siehe G. C. Goodwin und R. L. Payne „Dynamic System Identification: Experiment Design and Data Analysis“ Academic Press Inc., New York, 1977. Bei nicht linearen dynamischen Systemen sind amplitudenmodulierte Pseudo Binär Rausch Signale (APRBS) als Anregungssignale etabliert, um die nicht linearen Prozesskennzeichen zu verfolgen; siehe beispielsweise O. Nelles „Nonlinear System Identification: From Classical Approaches to Neural Networks and Fuzzy Models“ Springer, Berlin, 2001. Im Gegensatz zu diesen sehr allgemeinen Methodologien für Versuchspläne ist die modellbasierte Versuchsplanung (DoE) spezifischer für den zu identifizierenden Prozess geeignet, indem ein Modell eines vorhergehenden Prozesses oder zumindest eine Modellstruktur verwendet wird, um die aus Versuchen gewonnenen Informationen zu maximieren.

[0004] Echte Prozesse unterliegen Beschränkungen, die grundsätzlich Systemeingänge und -ausgänge betreffen. Beispielsweise dürfen die geänderten Variablen und die Kontrollvariablen nicht außerhalb des fahrbaren Bereichs liegen, um vorgegebene Betriebsbedingungen bereitzustellen oder Schäden von der Anlage zu verhindern. Für die Berücksichtigung der Ausgangsbeschränkungen des Systems wird in der Versuchsplanung ein Modell benötigt, das die Ausgangsdynamik vorhersagt. Die modellbasierte Versuchsplanung kann auch für die Online Versuchsplanung eingesetzt werden, wobei das Modell kontinuierlich an eingehende Daten angepasst wird und die Versuchsplanung sequenziell für eine bestimmte Anzahl von zukünftigen Systemeingängen generiert wird. Ein derartiges Vorgehen ist für gewöhnlich als online oder adaptive Versuchsplanung bekannt und in Fig. 1 abgebildet. Erklärungen finden sich in Online Dynamic Black Box Modelling and Adaptive Experiment Design in Combustion Engine Calibration, München, Deutschland, 2010, und in László Gemcsér, Hakan Hjalmarsson und Jonas Martensson „Identification of arx Systems with nonstationary inputs - asymptotic analysis with application to adaptive input design“ Automatica 45:623-633, März 2009.

[0005] Der Zweck des hier vorgestellten Verfahrens besteht darin, Versuchspläne zu schaffen, die auf typische Anwendungen bei der Entwicklung von Motoren oder Antriebsaggregaten und auf die Kalibrierung der ECUs oder TCUs abgestimmt sind. Das Verfahren ist dafür konzipiert,

die schnelle und präzise Generation von Versuchsplänen für globale Messungen, Modellierung und Optimierung eines nicht linearen dynamischen Echtsystems zu ermöglichen, z. B. einer Brennkraftmaschine, eines Antriebsaggregats oder Subsystemen davon, sowie die globale Optimierung davon, während Versuchslimits und zusätzliche Kriterien berücksichtigt werden.

[0006] Um diesen Zweck zu erfüllen, ist das eingangs beschriebene Verfahren durch den kennzeichnenden Teil von Anspruch 1 gekennzeichnet. Bevorzugte Ausführungsformen dieses grundsätzlichen Konzepts sind in den abhängigen Ansprüchen angegeben.

[0007] Die Hauptvorteile der modellbasierten Versuchsplanung im Gegensatz zu herkömmlichen Versuchsplanungsverfahren bestehen darin, dass das Modell zum Optimieren der Versuchsplanung genutzt wird, sodass die Versuche möglichst effektiv sind und die Einbindung verschiedener Beschränkungen, einschließlich Beschränkungen des Systemausgangs, sowie die Anwendung in einer online Versuchsplanung möglich sind.

[0008] Die Erfindung ist in der folgenden Spezifikation auf der Grundlage bevorzugter Beispiele und unter Bezugnahme auf die Figuren der beiliegenden Zeichnung ausführlicher beschrieben.

[0009] Fig. 1 zeigt einen offline und einen online Versuchsplanungsvorgang, Fig. 2 zeigt ein zweischicht Perceptron mit drei Eingängen, zwei Neuronen in der verdeckten Schicht und einem Ausgang, Fig. 3 stellt eine Struktur eines künstlichen neuronalen Netzes in Ausgangsfehler Konfiguration (NNOE) mit einem einzelnen Eingang u und Todzeit d dar, Fig. 4 zeigt eine nicht lineare beschränkte Optimierung mit Ungleichungsbeschränkung für ein zweidimensionales Eingangssignal u , Fig. 5 stellt das Anregungssignal u und den Modellausgang \hat{y} mit der Ausgangslimitüberschreitung $\hat{y}(k) > y_{\max}$ dar, Fig. 6 zeigt die Struktur des Wiener-Modells, Fig. 7 ist eine Darstellung des Anregungssignals u , des Modellausgangs \hat{y} und der Eingangsrates u_{rate} mit den zugehörigen Beschränkungen (dargestellt als gestrichelte Linien) für den Initialen Versuchsplan (I), den Ersten Gültigen Versuchsplan (II) (alle Beschränkungen werden das erste Mal eingehalten) und den Endgültigen Versuchsplan (III), wobei der Initiale Versuchsplan den fahrbaren Bereich (dargestellt als gestrichelte Linie) des Modellausgangs übersteigt, und Fig. 8 zeigt die iterative Vergrößerung von $\log(\det(I))$ einschließlich der drei Stufen aus Fig. 7: Initialer Versuchsplan (I), Erster Gültiger Versuchsplan (II) und Endgültiger Versuchsplan (III).

[0010] In der folgenden Spezifikation wird erklärt, wie ein mit den Eingangs- und Ausgangsbeschränkungen konformes optimales Versuchsplanungs-Batchverfahren ausgearbeitet werden kann, wobei ein dynamisches mehrlagiges Perceptron (MLP) für die Darstellung des nicht linearen Echtsystems unter Beobachtung verwendet wird, d. h. die Brennkraftmaschine, das Antriebsaggregat oder dergleichen, das in einem Testlauf, beispielsweise auf einem Teststand, analysiert werden soll. Das Verfahren zielt darauf ab, die Fisher-Informationsmatrix eines MLP zu optimieren und kann folglich auf eine große Klasse dynamischer Systeme angewandt werden. In der Literatur werden mehrere Verfahren für die optimale Versuchsplanung auf der Grundlage künstlicher neuronaler Netze vorgeschlagen, die Kandidaten-Sets für die Optimierung von Anregungssignalen einsetzen. In D. A. Cohn „Neural network exploration using optimal experiment design“ Neural Networks 9(6): 1071-1083, 1996, wird die optimale Versuchsplanung auf Lernprobleme angewandt, indem es dem Lerner bei jedem Zeitschritt gestattet wird, einen neuen Systemeingang aus einem Kandidaten-Set auszuwählen. Bei der Auswahl des neuen Eingangs werden entweder statische oder dynamische Eingangsbeschränkungen berücksichtigt, indem der Erwartungswert des mittleren quadrierten Fehlers des Lerners minimiert wird. Es ist des Weiteren bekannt, dass das Kriterium der D-Optimalität für die Verringerung von Trainingsdaten für globale dynamische Modelle auf der Grundlage von dynamischen künstlichen neuronalen Netzen angewandt wird. Auch eine lokale sequenzielle D-optimale Versuchsplanung wurde vorgeschlagen und mittels Optimierung über ein Set zulässiger Systemeingänge, die auf der zeitlichen Entwicklung eines vorgegebenen APRBS basieren, als ein Problem der Model Predictive Control formuliert. Die Verwendung von MLP-Netzen für die modellbasierte Versuchsplanung wird durch die oben genannten Publikationen inspiriert und mit einem Gradientenverfahren zur Verbesserung der Anregungssignale kombiniert. Im Gegensatz zu den meisten Zugängen am Stand der Technik wird in dieser Schrift die Optimierung des

Auslegungskriteriums analytisch durchgeführt, sodass kein Kandidaten-Set erforderlich ist. Die gleichzeitige Optimierung der zeitlichen und räumlichen Entwicklung des Anregungssignals und die Einhaltung der Eingangs- und Ausgangsbeschränkungen werden vorgeschlagen. In diesem Kontext muss die dynamische modellbasierte Versuchsplanung den inhärenten Effekt jedes Anregungssignals auf alle zukünftigen Systemausgänge berücksichtigen, sodass sein Einfluss auf die Fisher-Informationsmatrix sowie das Einhalten der Ausgangsbeschränkungen sehr anspruchsvoll werden kann.

[0011] Als nicht lineare Modellstruktur werden MLP-Netze als nicht lineare Modellstruktur ausgewählt, da sie zur Klasse der universellen Approximatoren gehören. Weitere nicht lineare Modellstrukturen, die gemäß der vorliegenden Erfindung verwendet werden können, sind lokale Modellnetzwerke (LMN) oder Takagi Sugeno Fuzzy Modelle.

[0012] Insbesondere werden MLP-Netze mit mehreren Eingängen und einem Ausgang (MISO) verwendet, wie in Fig. 2 gezeigt ist. Die freien Modellparameter werden durch die Eingangsgewichte W und die Ausgangsgewichte ω vorgegeben, die zum Parametervektor θ kombiniert werden können.

$$W = \begin{bmatrix} W_{10} & \dots & W_{1n_\varphi} \\ \vdots & \ddots & \vdots \\ W_{n_h 0} & \dots & W_{n_h n_\varphi} \end{bmatrix} \quad (1)$$

$$\omega = [\omega_{10} \quad \dots \quad \omega_{1n_h}]^T \quad (2)$$

$$\theta = [\omega_{10} \dots \omega_{1n_h} \quad W_{10} \dots W_{1n_\varphi} \dots W_{n_h 0} \dots W_{n_h n_\varphi}]^T \quad (3)$$

[0013] Der Modellausgang \hat{y} wird als eine gewichtete Summe nicht linearer Sigma-Aktivierungsfunktionen f_i in der verdeckten Schicht berechnet. Es gibt n_φ Modelleingänge φ_i , die den Regressionsvektor φ bilden.

$$f_i(h_i) = \frac{1}{1 + e^{-h_i}} \quad \varphi = [\varphi_1 \quad \dots \quad \varphi_{n_\varphi}] \quad (4)$$

[0014] Die Approximationsfähigkeit des MLP-Netzes wird durch die Anzahl der Neuronen in der verdeckten Schicht n_h bestimmt. In der Nomenklatur der Vektormatrizen werden der Eingang in die verdeckte Schicht h und der Ausgang der verdeckten Schicht o wie folgt angegeben:

$$h = W \begin{bmatrix} 1 \\ \varphi^T \end{bmatrix} \quad o(h) = \begin{bmatrix} f_1(h_1) \\ \vdots \\ f_{n_h}(h_{n_h}) \end{bmatrix} \quad (5)$$

[0015] Der Ausgang des MLP-Netzes ist eine nicht lineare Funktion $g(\varphi, \theta)$, die vom Regressionsvektor φ und vom Parametervektor θ abhängig ist.

$$\hat{y} = g(\varphi, \theta) = \omega^T \begin{bmatrix} 1 \\ o(h) \end{bmatrix} = \sum_{j=1}^{n_h} \omega_{1j} f_j \left(\sum_{l=1}^{n_v} W_{jl} \varphi_l + W_{j0} \right) + \omega_{10} \quad (6)$$

[0016] Sowohl die Eingänge in die Neuronen in der verdeckten Schicht als auch die Ausgänge der verdeckten Schicht enthalten die versetzten Terme W_{j0} und ω_{10} . Es wird angenommen, dass der Systemausgang des tatsächlichen Prozesses $y(k)$ durch das Modell $\hat{y}(k, \theta)$ und einen Gaußschen Fehler $e(k)$ mit einem Mittelwert von Null und Varianz σ^2 angegeben wird:

$$y(k) = g(\varphi(k), \theta) + e(k) = \hat{y}(k, \theta) + e(k) \quad (7)$$

[0017] Bislang wurde nicht spezifiziert, ob das MLP-Netz für statische oder dynamische Systeme verwendet wird. Im Folgenden werden dynamische MLP-Netze in Ausgangsfehler Konfiguration (NNOE) beobachtet. Dann besteht der Regressionsvektor $\varphi(k, \theta)$ bei der k -th-Beobachtung aus vergangenen Netzausgängen $\hat{y}(k - i)$ mit $i = 1 \dots n$ und vergangenen Systemeingängen $u(k - d + j)$ mit $j = 1 \dots m$ und Todzeit d (siehe Fig. 3).

$$\varphi(k, \theta) = [\hat{y}(k-1, \theta) \dots \hat{y}(k-n, \theta) \quad u_1(k-d) \dots \dots u_1(k-d-m) \dots u_{n_u}(k-d) \dots u_{n_u}(k-d-m)] \quad (8)$$

[0018] Es wird angenommen, dass das Anregungssignal U aus N Beobachtungen und n_u unterschiedlichen Eingängen besteht. Der gemessene Systemausgang y wird wie folgt angegeben:

$$U = [u_1 \dots u_{n_u}] = \begin{bmatrix} u_1(1) & \dots & u_{n_u}(1) \\ \vdots & \ddots & \vdots \\ u_1(N) & \dots & u_{n_u}(N) \end{bmatrix} \quad (9)$$

[0019] Der gemessene Systemausgang y wird wie folgt angegeben:

$$y = \begin{bmatrix} y(1) \\ \vdots \\ y(N) \end{bmatrix} \quad (10)$$

[0020] Die Netzwerkparameter θ müssen an die Eingangs- und Ausgangsdaten des Versuchs angepasst werden. Das Training der Netzwerkgewichte wird für gewöhnlich mit einem standardmäßigen Levenberg-Marquardt-Algorithmus durchgeführt, der darauf abzielt, eine quadratische Kostenfunktion $V_N(\theta)$ auf der Grundlage des Prädiktionsfehlers $s(k)$ zu minimieren:

$$V_N(\theta) = \frac{1}{2N} \sum_{k=1}^N (y(k) - \hat{y}(k, \theta))^2 = \frac{1}{2N} \sum_{k=1}^N \epsilon^2(k, \theta) \quad (11)$$

[0021] Die optimale modellbasierte Versuchsplanung zielt darauf ab, den Informationsgehalt

der Versuche zu maximieren. Zu diesem Zweck wird ein Optimalitätskriterium optimiert, das für gewöhnlich aus der Fisher-Informationsmatrix abgeleitet wird. In diesem Kontext ist das Prozessmodell in der Form eines MLP-Netzes für die Berechnung der Fisher-Informationsmatrix nötig. Aus statistischem Blickwinkel trifft die Fisher-Informationsmatrix I eine Aussage über den Informationsgehalt der Daten in Form einer Kovarianzmatrix der geschätzten Parameter. Gängige Auslegungskriterien für die modellbasierte Versuchsplanung sind die Spur von I^{-1} (A-Optimalität), die Determinante von I (D-Optimalität) und der kleinste Eigenwert von I (E-Optimalität).

[0022] Die modellbasierte Versuchsplanung kann angewandt werden, wenn bereits ein Modell eines Systems existiert und nur einige Teile des Systems verändert wurden, sodass ein ähnliches Verhalten erwartet werden kann, wenn das System unter geänderten Umgebungsbedingungen betrieben wird und ein Modell eines ähnlichen Systems zur Verfügung steht.

[0023] Die Fisher-Matrix ist ein statistisches Maß der Informationsmenge der zu Grunde liegenden Daten und ihre Umkehrung ergibt die Kovarianzmatrix der geschätzten Modellparameter θ . Diese Matrix ist die Ableitung des Modellausgangs in Bezug zu den Modellparametern:

$$I = \frac{1}{\sigma^2} \sum_{k=1}^N \frac{\partial \hat{y}(k)}{\partial \theta} \frac{\partial \hat{y}(k)}{\partial \theta}^T$$

[0024] Gängige Auslegungskriterien für die modellbasierte Versuchsplanung verwenden einen Skalarwert der Fisher-Matrix oder ihrer Umkehrung als Zielfunktion. Dadurch wird ein Maß für den Informationsgehalt benötigt, um die Anregungssignale optimieren zu können. Da die Fisher-Informationsmatrix statistische Angaben über den Informationsgehalt der zu Grunde liegenden Daten bzw. die Kovarianzmatrix der geschätzten Parameter enthält, ist sie eine Basis für gängige Auslegungskriterien wie A-, D- und E-Optimalität.

[0025] Die Fisher-Informationsmatrix ist vom Vektor der Parametersensitivität $\psi(k)$ abhängig, der die funktionale Abhängigkeit des Modellausgangs von den Modellparametern beschreibt:

$$\psi(k) = \frac{\partial \hat{y}(\varphi(k, \theta), \theta)}{\partial \theta} \quad (12)$$

[0026] Die Fisher-Informationsmatrix umfasst die Vektoren der Parametersensitivität aller Beobachtungen $k = 1 \dots N$ gemäß

$$I(\Psi) = \frac{1}{\sigma^2} \Psi^T \Psi, \quad (13)$$

wobei die Matrix der Parametersensitivität Ψ die Parametersensitivität aller Beobachtungen kombiniert:

$$\Psi = \begin{bmatrix} \psi^T(1) \\ \vdots \\ \psi^T(N) \end{bmatrix} \quad (14)$$

[0027] Die Parametersensitivität wird für die MLP-Ausgangsgewichte $\psi_w(k)$ und -Eingangsgewichte $\Psi_W(k)$ separat ermittelt:

$$\psi_{\omega}(k) = \frac{\partial \hat{y}(\varphi(k, \theta), \theta)}{\partial \omega} = \begin{bmatrix} 1 \\ o(h(k)) \end{bmatrix} \quad (15)$$

$$\psi_{\omega}(k) \in \mathbb{R}^{(1+n_a) \times 1} \quad (16)$$

$$\Psi_W(k) = \frac{\partial \hat{y}(\varphi(k, \theta), \theta)}{\partial W} = \text{diag}(o'(h(k))) \tilde{\omega} [1 \ \varphi(k, \theta)] \quad (17)$$

$$\Psi_W(k) \in \mathbb{R}^{n_a \times (1+n_a)} \quad (18)$$

[0028] Der Vektor des Ausgangsgewichts ohne Bias-Term wird durch $\tilde{\omega}$ ausgedrückt:

$$\tilde{\omega} = [\omega_{11} \ \dots \ \omega_{1n_a}]^T \quad (19)$$

$$o'(h(k)) = \left[\frac{\partial c_i(h_i(k))}{\partial h_i(k)} \right] \quad i = 1 \dots n_a \quad (20)$$

$$o'(h(k)) = 1 - o(h(k)) \circ o(h(k)), \quad (21)$$

[0029] Hier zeigt $o'(h(k))$ einen Spaltenvektor an, dessen i -th-Element durch die Ableitung des i -th-Ausgangs der verdeckten Schicht in Bezug auf den i -th-Eingang in die verdeckte Schicht bei der k -th-Beobachtung vorgegeben wird. In (17) zeigt $\text{diag}(o'(h(k)))$ eine diagonale Matrix an, deren Eingaben die Elemente des Vektors $o'(h(k))$ sind, und wobei \circ das Hadamard-Produkt bezeichnet.

[0030] Häufig verwendete Optimalitätskriterien auf der Grundlage der Fisher-Informationsmatrix sind die A-, D- und E-Optimalität. Die A-Optimalität zielt darauf ab, die Summe der Parameter-Varianzen zu minimieren. Daher basiert das zugehörige Auslegungskriterium auf der Spur von I^{-1} :

$$J_A(\Psi) = \text{Tr}(I^{-1}(\Psi)) \quad (22)$$

[0031] Die D-Optimalität nutzt die Determinante von I , die im Gegensatz zur A-Optimalität empfindlicher auf einzelne Parameter-Kovarianzen reagiert, da die Determinante dem Produkt der Eigenwerte gleicht. Außerdem ist die D-Optimalität unter jeder nicht-singulären erneuten Parametrisierung invariant, was nicht vom Versuch abhängig ist.

$$J_D(\Psi) = \det(I(\Psi)) \quad (23)$$

[0032] Bei der E-Optimalität wird der kleinste Eigenwert λ_{\min} der Fisher-Informationsmatrix maximiert.

$$J_E(\Psi) = \lambda_{\min}(I(\Psi)) \quad (24)$$

[0033] Das Auslegungskriterium J kann nur durch Ändern der Systemeingänge $u_i(k)$ beeinflusst werden. Für die Optimierung des Auslegungskriteriums wird für gewöhnlich ein Kandidaten-Set von zulässigen Eingängen generiert, aus dem bestimmte Eingänge zum Optimieren des Ausle-

gungskriteriums ausgewählt werden.

[0034] Das vorgeschlagene Verfahren für die modellbasierte Versuchsplanung setzt die Minimierung von (22) und die Maximierung von (23) und (24) durch eine analytische Berechnung der optimierten Anregungssignale unter Berücksichtigung der Eingangs- und Ausgangsbeschränkungen um.

[0035] Allgemein zielt die Verbesserung der Anregungssignale darauf ab, das Auslegungskriterium zu optimieren, während gleichzeitig die Beschränkungen eingehalten werden. Mathematisch wird das Optimierungsproblem unter Berücksichtigung von Eingangs-, Eingangsrate- und Ausgangsbeschränkungen wie folgt ausgedrückt:

$$\text{A-optimality: } J_A \rightarrow \min_{u_i(k)} \quad (25)$$

$$\text{D- and E-optimality: } J_D, J_E \rightarrow \max_{u_i(k)} \quad (26)$$

$$\text{Input constraint: } u_{\min} \leq u_i(k) \leq u_{\max} \quad (27)$$

$$\text{Rate constraint: } \Delta u_{\min} \leq u_i(k+1) - u_i(k) \leq \Delta u_{\max} \quad (28)$$

$$\text{Output constraint: } y_{\min} \leq \hat{y}(k) \leq y_{\max} \quad (29)$$

[0036] Die Verbesserung des Auslegungskriteriums J stellt eine nicht lineare Optimierungsaufgabe dar, für die unterschiedliche Optimierungsverfahren verfügbar sind. Für die Verbesserung des Auslegungskriteriums linearer dynamischer Systeme ist ein Gradientenverfahren bekannt. Zur Verwendung in der vorliegenden Erfindung gibt es ein iteratives Gradientenverfahren zum Optimieren der Anregungssignale nicht linearer dynamischer Systeme. Das vorgeschlagene Verfahren für die analytische Berechnung der optimierten Anregungssignale wird in zwei Schritten ausgeführt. Zuerst wird der Gradient des Auslegungskriteriums in Bezug zu den dynamischen Systemeingängen bestimmt, und als Zweites werden die Systemeingänge rekursiv aktualisiert und die Eingangs- und Ausgangsbeschränkungen beachtet.

[0037] Die Optimierung basiert auf der Berechnung des Gradienten der Zielfunktion, der durch das Auslegungskriterium in Bezug zu den dynamischen Systemeingängen dargestellt wird. Bei jeder Iteration wird das Anregungssignal aktualisiert, sodass das Auslegungskriterium verbessert wird, während die Beschränkungen eingehalten werden.

[0038] Die Ableitung des Auslegungskriteriums J in Bezug zum i-th-Systemeingang $u_i(k)$ wird durch die Verwendung der Kettenregel in drei Schritten berechnet:

$$\frac{dJ(\Psi)}{du_i(k)} = \sum_{l=1}^N \underbrace{\frac{dJ(\Psi)}{d\psi^T(l)}}_{(i)} \underbrace{\frac{d\psi(l)}{d\varphi(l, \theta)}}_{(ii)} \underbrace{\frac{d\varphi^T(l, \theta)}{du_i(k)}}_{(iii)} \quad (30)$$

[0039] Ad(i): Zuerst wird die Ableitung des Auslegungskriteriums in Bezug zum Vektor der

Parametersensitivität für die l -th-Beobachtung $\psi(l)$ benötigt. Für die A-Optimalität und die D-Optimalität wird das Ergebnis wie folgt ausgedrückt:

$$\frac{dJ_A(\Psi)}{d\psi^T(l)} = -2s(l)\Psi[\Psi^T\Psi]^{-2} \quad (31)$$

$$\frac{dJ_D(\Psi)}{d\psi^T(l)} = 2s(l)J_D(\Psi)\Psi[\Psi^T\Psi]^{-1} \quad (32)$$

$$s(l) = [0 \dots 1 \dots 0]^T \in \mathbb{R}^{1 \times N} \quad (33)$$

wobei $s(l)$ den einzelnen Eingabevektor darstellt, der an der l -th-Position gleich 1 und überall sonst gleich 0 ist. Die E-Optimalität erfordert die Berechnung der Ableitung des kleinsten Eigenwerts der Fisher-Matrix λ_{\min} in Bezug zum Vektor der Parametersensitivität $\psi(l)$, was zu folgendem Ergebnis führt:

$$\frac{dJ_E(\Psi)}{d\psi(l)^T} = 2s(l)\Psi x_{\min} x_{\min}^T \quad (34)$$

[0040] Hier zeigt x_{\min} den Eigenvektor des kleinsten Eigenwerts λ_{\min} an:

$$\mathbf{L}x_{\min} = \lambda_{\min}x_{\min} \quad (35)$$

[0041] In (31) und (32) zeigt sich die Umkehrung der Fisher-Matrix. Folglich muss die Fisher-Matrix regelmäßig sein, um umkehrbar zu sein. Es wurde bereits gezeigt, dass eine singuläre Fisher- Informationsmatrix, die auf einem MLP-Netz basiert, regelmäßig gemacht werden kann, indem redundante Neuronen entfernt werden.

[0042] Ad(ii): Die Ableitung des Vektors der Parametersensitivität für die Ausgangsgewichte $\psi_{\omega}(l)$ in Bezug zum Regressionsvektor $\phi(l, \theta)$ wird wie folgt angegeben:

$$\frac{d\psi_{\omega}(l)}{d\phi(l, \theta)} = \begin{bmatrix} 0 \\ \text{diag}(\sigma'(h(l)))\tilde{W} \end{bmatrix} \in \mathbb{R}^{(1+n_h) \times n_{\phi}} \quad (36)$$

[0043] Hier werden die Eingangsgewichte ohne Bias-Terms durch \tilde{W} angezeigt:

$$\tilde{W} = \begin{bmatrix} W_{11} & \dots & W_{1n_{\phi}} \\ \vdots & \ddots & \vdots \\ W_{n_h 1} & \dots & W_{n_h n_{\phi}} \end{bmatrix} \quad (37)$$

[0044] Und die Ableitung der Matrix der Parametersensitivität für die Eingangsgewichte $\Psi W(l)$ in Bezug zur i -th-Komponente des Regressionsvektors $\phi(l, \theta)$ wird wie folgt bestimmt:

$$\frac{d\Psi_W(l)}{d\varphi_i(l, \theta)} = \text{diag}(o'(h(l)))\tilde{\omega}[0 \ e_i] + \\ + ((\text{diag}(o''(h(l)))\tilde{\omega}) \circ (W s(i)^T)) [1 \ \varphi(l, \theta)] \quad (38)$$

$$\frac{d\Psi_W(l)}{d\varphi_i(l, \theta)} \in \mathbb{R}^{n_h \times (1+n_\varphi)} \quad (39)$$

wobei $o''(h(l))$ einen Spaltenvektor anzeigt, dessen i -th-Eingabe durch die zweite Ableitung des Ausgangs der verdeckten Schicht in Bezug zum i -th-Eingang in die verdeckte Schicht bei der k -th- Beobachtung vorgegeben wird:

$$o''(h(l)) = \left[\frac{\partial^2 o_i(h_i(k))}{\partial h_i^2(k)} \right] \quad i = 1 \dots n_h \quad (40)$$

$$o''(h(l)) = -2o(h(l)) \circ o'(h(l)) \quad (41)$$

[0045] Hier zeigt e_i den Richtungsvektor in die i -th-Komponente von $\varphi(l, \theta)$ an, und $s(i)$ ist erneut der einzelne Eingabevektor.

$$e_i = [0 \ \dots \ 1 \ \dots \ 0] \in \mathbb{R}^{1 \times n_\varphi} \quad (42)$$

$$s(i) = [0 \ \dots \ 1 \ \dots \ 0] \in \mathbb{R}^{1 \times n_\varphi} \quad (43)$$

[0046] Ad(iii): Für dynamische autoregressive Systeme ist der Regressionsvektor nicht nur von vergangenen Systemeingängen sondern auch von Modellausgängen abhängig. Folglich erfordert die Ableitung von $\varphi(l+1, \theta)$ in Bezug zu $u_i(l-j)$ die Berechnung der Ableitung vergangener Modellausgänge $\hat{y}(l, \theta)$ in Bezug zu $u_i(l-j)$. Dynamische Systemeingänge $u_i(k)$ haben einerseits eine direkte Auswirkung auf den Modellausgang und andererseits einen indirekten Einfluss über die vergangenen n Modellausgänge. Unter Berücksichtigung dieser Tatsache und unter Verwendung der Kettenregel wird die Ableitung von $\hat{y}(l, \theta)$ in Bezug zu $u_i(l-j)$ wie folgt angegeben:

$$\frac{d\hat{y}(l, \theta)}{du_i(l-j)} = \frac{\partial g(\varphi(l, \theta), \theta)}{\partial \hat{y}(l-1, \theta)} \underbrace{\frac{d\hat{y}(l-1, \theta)}{du_i(l-j)}}_{\text{recursive calculation}} + \dots + \\ + \frac{\partial g(\varphi(l, \theta), \theta)}{\partial \hat{y}(l-n, \theta)} \frac{d\hat{y}(l-n, \theta)}{du_i(l-j)} + \frac{\partial g(\varphi(l, \theta), \theta)}{\partial u_i(l-j)} \quad (44)$$

$$j \geq 1 \quad k = l - j \quad (45)$$

[0047] Im nächsten Zeitschritt wird das Ergebnis von (44) für die Berechnung der Ableitung von $\hat{y}(l+1, \theta)$ in Bezug zu $u_i(l-j)$ verwendet. In einem rekursiven Vorgang werden alle Modellausgänge, die für den Regressionsvektor bei der 1-th-Beobachtung benötigt werden, differenziert. Die Ableitung von $g(\varphi(l, \theta), \theta)$ in Bezug zu den Elementen des Regressionsvektors wird in der Nomenklatur der Vektormatrizen wie folgt angegeben: in (46)

$$\frac{\partial g(\varphi(l, \theta))}{\partial \varphi(l, \theta)} = \tilde{\omega}^T \text{diag}(o'(h(l))) \tilde{W} \in \mathbb{R}^{1 \times n_\varphi} \quad (46)$$

[0048] Die Ableitung aller Systemeingänge $u_j(s)$, die im Regressionsvektor $\varphi(l, \theta)$ in Bezug zu $u_i(k)$ verwendet werden, wird wie folgt berechnet:

$$\frac{du_j(s)}{du_i(k)} = \delta_{ij} \delta_{ks} \quad 1 \leq i, j \leq n_u \quad l-d-m \leq s \leq l-d \quad (47)$$

$$\delta_{ij} = \begin{cases} 1, & \text{for } i = j \\ 0, & \text{for } i \neq j \end{cases} \quad (48)$$

[0049] Hier steht δ_{ij} für das Kronecker-Delta, das 1 für $i = j$ und 0 für $i \neq j$ beträgt, und wobei i, j den Eingangsindex von 1 bis n_u bezeichnen.

[0050] Die beschränkte rekursive Optimierung des Anregungssignal basiert auf der Berechnung des Gradienten (30) in Bezug zu allen unterschiedlichen Eingängen $u_i(k)$ mit $i = 1 \dots n_u$ für alle Beobachtungen $k = 1 \dots N$. Die Einhaltung der Eingangs-, Eingangsraten- und Ausgangsbeschränkungen während des Optimierungsvorgangs wird durch ein beschränktes Gradientenverfahren gewährleistet. Das Prinzip des Verfahrens wird in Fig. 4 für ein zweidimensionales Beispiel erklärt. Bei jeder Iteration (angezeigt durch den Index v) wird die (quadratische) Differenz zwischen dem Gradienten $\delta^{(v)} \nabla J^{(v)}$ und dem Anregungssignal-Inkrement Δu_i minimiert, während gleichzeitig eine Annäherung an den zulässigen Bereich, der durch den Beschränkungsvektor $g \leq 0$ definiert ist, vollzogen wird. Der Beschränkungsvektor $g = [g_1 \dots g_o] \in \mathbb{R}^{k_o}$ umfasst alle möglichen Beschränkungen. Eine Beschränkung ist aktiv, wenn $g_k = 0$, und inaktiv, wenn $g_k < 0$. Hier bezeichnet $\delta^{(v)}$ die variable Schrittweite des Gradientenverfahrens. Mathematisch wird das Problem wie folgt ausgedrückt:

$$(\Delta u_i - \delta^{(v)} \nabla_i J_D^{(v)})^T (\Delta u_i - \delta^{(v)} \nabla_i J_D^{(v)}) \rightarrow \min_{\Delta u_i} \quad (49)$$

[0051] Die Linearisierung der aktiven Beschränkungen $g^{(v)}_{act}$ wird durch $g^{(v)}_{lin}$ vorgegeben, das gleich Null sein muss:

$$g^{(v)}_{lin} = (g^{(v)}_{act})^T + \left(\frac{dg^{(v)}_{act}}{du_i} \right)^T \Delta u_i = 0 \quad (50)$$

[0052] Für die Optimierung mit aktiven Beschränkungen ist eine skalare Lagrangefunktion L mit dem entsprechenden aktiven Multiplikator-Zeilenvektor $\lambda^{(v)}_{act}$ definiert.

$$\mathcal{L}^{(\nu)} = \frac{1}{2} (\Delta u_i - \delta^{(\nu)} \nabla_i J_D^{(\nu)})^T (\Delta u_i - \delta^{(\nu)} \nabla_i J_D^{(\nu)}) + \lambda_{act}^{(\nu)} g_{lim}^{(\nu)T} \quad (51)$$

[0053] Der Extremwert der Lagrangefunktion wird erhalten, wenn die Ableitung von L in Bezug zu Δu_i gleich Null ist:

$$\frac{d\mathcal{L}^{(\nu)}}{d\Delta u_i} = \Delta u_i - \delta^{(\nu)} \nabla_i J_D^{(\nu)} + \frac{dg_{act}^{(\nu)}}{du_i} \lambda_{act}^{(\nu)T} = 0 \quad (52)$$

[0054] Dann wird die Änderung Δu_i des Anregungssignals als eine Funktion von λ_{act} ausgedrückt:

$$\Delta u_i = \delta^{(\nu)} \nabla_i J_D^{(\nu)} - \frac{dg_{act}^{(\nu)}}{du_i} \lambda_{act}^{(\nu)T} \quad (53)$$

[0055] Das Einsetzen dieses Ergebnisses in die Beschränkungsbedingung (50) ergibt für λ_{act} :

$$\lambda_{act}^{(\nu)T} = \left\{ \left(\frac{dg_{act}^{(\nu)}}{du_i} \right)^T \left(\frac{dg_{act}^{(\nu)}}{du_i} \right) \right\}^{-1} \cdot \left\{ (g_{act}^{(\nu)})^T + \left(\frac{dg_{act}^{(\nu)}}{du_i} \right)^T \delta^{(\nu)} \nabla_i J_D^{(\nu)} \right\} \quad (54)$$

[0056] Das Verwenden des Ergebnisses für $\lambda^{(\nu)}_{act}$ und das Einsetzen in (53) ergibt das Endergebnis für die iterative Änderung Δu_i des Anregungssignals.

[0057] In der Folge werden die aktiven Beschränkungen in (50) ausführlich hinsichtlich Eingangs-, Eingangsraten- und Ausgangslimitüberschreitungen behandelt. Eingangsbeschränkungen: Wenn als Beispiel angenommen wird, dass der Eingang bei der k-th-Beobachtung den zulässigen Bereich, der durch $[u_{min}, u_{max}]$ definiert ist, überschreitet, dann sind die folgenden Beschränkungen aktiv:

$$u_i(k) > u_{max}: \quad \Delta u_i(k) - u_{max} + u_i^{(\nu)}(k) = 0 \quad (55)$$

$$u_i(k) < u_{min}: \quad -\Delta u_i(k) + u_{min} - u_i^{(\nu)}(k) = 0 \quad (56)$$

[0058] Ratenbeschränkungen: Die Einhaltung der Eingangsrates $\Delta u_{rate}(k) = u_i(k+1) - u_i(k)$ auf $[\Delta u_{min}, \Delta u_{max}]$ ist durch die folgenden Bedingungen ausgedrückt:

[0059] Für $\Delta u_{rate}(k) > \Delta u_{max}$:

$$[u_i^{(v)}(k+1) + \Delta u_i(k+1)] - [u_i^{(v)}(k) + \Delta u_i(k)] - \Delta u_{max} = 0 \quad (57)$$

For $\Delta u_{i,max}(k) < \Delta u_{min}$:

$$-[u_i^{(v)}(k+1) + \Delta u_i(k+1)] + [u_i^{(v)}(k) + \Delta u_i(k)] + \Delta u_{min} = 0 \quad (58)$$

[0060] Ausgangsbeschränkungen: Für die Einbindung von Ausgangsbeschränkungen muss die Tatsache berücksichtigt werden, dass in autoregressiven Systemen der Eingang $u_i(k)$ alle zukünftigen Modellausgänge $\hat{y}(k+l)$, $l > 1$ beeinflusst. Wenn es bei der k -th-Beobachtung zu einer Ausgangslimitüberschreitung kommt, bei der $\hat{y}(k) > y_{max}$, dann müssen die Systemeingänge $u_i(l)$ mit $l \geq k$ geändert werden, sodass $\hat{y}(k)$ im zulässigen Bereich liegt, siehe Fig. 5. Dies führt zu den folgenden Beschränkungen:

$$\hat{y}(k) > y_{max}: \quad \hat{y}^{(v)}(k) + \frac{d\hat{y}^{(v)}(k)}{du_i^{(v)}} \Delta u_i - y_{max} = 0 \quad (59)$$

$$\hat{y}(k) < y_{min}: \quad -\hat{y}^{(v)}(k) - \frac{d\hat{y}^{(v)}(k)}{du_i^{(v)}} \Delta u_i + y_{min} = 0 \quad (60)$$

[0061] Äquivalent zu einem Problem der Model Predictive Control muss die Berechnung zukünftiger Systemeingänge unter Berücksichtigung der Entwicklung zukünftiger Systemausgänge vorgenommen werden. Dies erfordert die Berechnung der Ableitung des Modellausgangs in Bezug zum dynamischen Anregungssignal; siehe Gleichung (44).

[0062] Das folgende Beispiel zeigt die Effektivität des vorgeschlagenen Verfahrens für die modellbasierte Versuchsplanung mit MLP-Netzen mittels eines nicht linearen dynamischen Prozesses. Es wird gezeigt, wie die Determinante der Fisher-Matrix iterativ unter Einhaltung von Eingangs-, Eingangsraten- und Ausgangsbeschränkungen verbessert wird. Als initiale Versuchsplanung wird ein APRB-Signal erzeugt, das in der Folge durch die Anwendung des vorgestellten Verfahrens verbessert wird. Der vorgestellte Optimierungsvorgang wird auf ein (SISO-) Wiener-Modell angewandt. Das Wiener-Modell wird durch eine serielle Anordnung einer linearen zeitinvarianten Transferfunktion $G(z^{-1})$ und eine statische Nicht-Linearität NL am Systemausgang beschrieben.

$$NL: y = \arctan(v) \quad (61)$$

[0063] Hier beschreibt die Transferfunktion ein schwingendes System zweiter Ordnung:

$$G(z^{-1}) = \frac{0.01867z^{-1} + 0.01746z^{-2}}{1 - 1.7826z^{-1} + 0.8187z^{-2}} = \frac{V(z^{-1})}{U(z^{-1})} \quad (62)$$

[0064] Die Generierung von Ausgangsdaten geschieht anhand des dargestellten Wiener-Modells, wie in Fig. 6 gezeigt. Dann wird unter Verwendung eines Standard-Tools, z. B. der NNSYSID Toolbox für Matlab, ein Referenzmodell des zu Grunde liegenden Prozesses trainiert. In diesem Fall kann ein MLP-Netz mit fünf Neuronen bereits relativ gut an das verwendete Wiener-Modell herankommen. Als initiale Versuchsplanung für den Optimierungsvorgang wird ein APRB-Signal vom Stand der Technik mit 100 Samples verwendet. In Fig. 7 sind das Anregungssignal u , die Eingangsrate Δu_{rate} und der Modellausgang \hat{y} zusammen mit den zugehörigen Beschränkungen, die durch gestrichelte Linien dargestellt sind, für den initialen, den ersten gültigen und den endgültigen Versuchsplan abgebildet. Ein initialer Versuchsplan, der gegen die Ausgangsbeschränkungen verstößt, wurde ausgewählt, um die Funktionalität des vorgestellten beschränkten Optimierungsvorgangs zu zeigen. Der erste gültige Versuchsplan ist erreicht, wenn alle Beschränkungen erstmals eingehalten werden. Hier wird der Optimierungsalgorithmus nach 40 Iterationen angehalten und der endgültige Versuchsplan erreicht. In Fig. 8 ist die zugehörige iterative Vergrößerung des Logarithmus der Determinante der Fisher-Matrix abgebildet. Die Determinante der Fisher-Matrix verringert sich bei der ersten Iteration, da die Ausgangslimitüberschreitung der initialen Versuchsplanung kompensiert werden muss, und bei der vierten Iteration wird der erste gültige Versuchsplan erreicht. Die Vergrößerung der Determinante der Fisher-Matrix verursacht eine erhöhte Anregung der Systemausgangsdynamik, wie in Fig. 7 gezeigt ist. Dies ist ein sinnvolles Ergebnis, da mehr Informationen gesammelt werden, wenn das System im gesamten Ausgangsbereich angeregt wird. Die Vergrößerung des Informationsgehalts des Anregungssignals ist äquivalent zu einer Verringerung der Unsicherheit der geschätzten Modellparameter.

[0065] Durch die vorliegende Erfindung wird ein neues Verfahren für die Versuchsplanung auf der Basis eines mehrlagigen Perzeptrons für nicht lineare dynamische Systeme vorgeschlagen. Die Motivation für diese Arbeit ist die Schaffung eines analytischen Batchverfahrens für die Optimierung dynamischer Anregungssignale unter Einhaltung von Eingangs-, Eingangsraten- und Ausgangsbeschränkungen, das für eine online Versuchsplanung benötigt wird. Die Effektivität des vorgeschlagenen Konzepts für die modellbasierte Versuchsplanung wird an einem nicht linearen dynamischen System gezeigt, indem die iterative Vergrößerung der Determinante der Fisher-Matrix dargestellt wird, was zu einer Verringerung der Unsicherheit der geschätzten Modellparameter führt. Das Simulationsbeispiel zeigt, dass die Optimierung des Informationsgehalts des Anregungssignals zu einer vergrößerten Systemausgangsdynamik führt. Das vorgestellte Verfahren für die Optimierung von Anregungssignalen hält auch Eingangs-, Eingangsraten- und Ausgangsbeschränkungen ein, was eine Voraussetzung für einen online Versuchsplanungsvorgang ist.

Patentansprüche

1. Maschinell umgesetztes Verfahren zum Erhalten von Daten aus einem nicht linearen dynamischen Echtssystem während eines Testlaufs, beispielsweise aus einer Brennkraftmaschine, einem Antriebsaggregat oder Teilen davon, aufweisend die Generierung einer Folge von dynamischen Anregungssignalen für mindestens einen Messkanal gemäß einer zuvor generierten Versuchsplanung für den Testlauf und das Messen des Systemausgangs mindestens eines Ausgangskanals, **dadurch gekennzeichnet**, dass die Folge der dynamischen Anregungssignale durch das Verfahren des Generierens einer Versuchsplanung mit einer Folge von Anregungssignalen generiert wurde, wobei Ausgangsdaten durch das Einspeisen der Folge von Anregungssignalen in ein Modell für das Echtssystem erhalten werden, wobei das Modell nicht lineare dynamische Modelle umfasst, und wobei ein Kriterium für den Informationsgehalt von Anregungssignalen der gesamten Versuchsplanungsfolge bestimmt wird, und in einem folgenden Schritt die Gesamtheit der Folge von Anregungssignalen verändert wird, wodurch neue Ausgangsdaten durch das Einspeisen der veränderten Folge von Anregungssignalen in das Modell für das Echtssystem erhalten werden, das Kriterium für den Informationsgehalt von Anregungssignalen erneut bestimmt wird, und diese Schritte wiederholt werden, bis das Kriterium seinen Optimalwert erreicht hat, wobei die letzte generierte Folge von Anregungssignalen als Versuchsplanung für den Testlauf des Echtsystems verwendet wird.
2. Verfahren nach Anspruch 1, **dadurch gekennzeichnet**, dass während jedes Schritts die Einhaltung der Beschränkungen der Anregungssignale und/oder des Modellausgangs überprüft wird, wodurch die Folge der Anregungssignale im Fall einer Nichteinhaltung derart verändert wird, dass die Einhaltung wiederhergestellt wird und sich das Kriterium gleichzeitig seinem Optimalwert nähert.
3. Verfahren nach Anspruch 1 oder 2, **dadurch gekennzeichnet**, dass nach jeder Iteration die Ableitung des Kriteriums in Bezug zum dynamischen Anregungssignal bestimmt wird, und die Iterationen angehalten werden, sobald die Ableitung unter einen vorbestimmten Wert fällt oder eine vorbestimmte Anzahl von Iterationen erreicht ist.
4. Verfahren nach einem der Ansprüche 1 bis 3, **dadurch gekennzeichnet**, dass bei jeder Iteration die gleichzeitige Optimierung der räumlichen Verteilung der Versuchspunkte oder Messpunkte und der zeitlichen Entwicklung des Anregungssignals gestattet wird.
5. Verfahren nach einem der Ansprüche 1 bis 4, **dadurch gekennzeichnet**, dass das Kriterium von der Fisher-Informationsmatrix bestimmt wird, insbesondere durch das Berechnen der Spur der Umkehrung der Matrix, durch das Berechnen der Determinante oder des kleinsten Eigenwerts.
6. Verfahren nach einem der Ansprüche 1 bis 5, **dadurch gekennzeichnet**, dass die Ausgangsdaten mit einem Modell bestimmt werden, das mehrlagige Perzeptrons-Netze (MLP) als die nicht lineare dynamische Modellarchitektur verwendet.
7. Verfahren nach einem der Ansprüche 1 bis 5, **dadurch gekennzeichnet**, dass die Ausgangsdaten mit einem Modell bestimmt werden, das ein lokales Modellnetzwerk (LMN) oder ein Takagi Sugeno Fuzzy Modell als die nicht lineare dynamische Modellarchitektur verwendet.

Hierzu 3 Blatt Zeichnungen

1

Fig. 1




Fig. 2




Fig. 3




Fig. 4




Fig. 5




Fig. 6



Fig. 8




Fig. 7

