(19) Bundesrepublik Deutschland
Deutsches Patent- und Markenamt

(10) **DE 10 2009 025 855 A1** 2009.12.03

(12) **Offenlegungsschrift**

(21) Aktenzeichen: **10 2009 025 855.8**
(22) Anmeldetag: **20.05.2009**
(43) Offenlegungstag: **03.12.2009**

(51) Int Cl.[8]: ***G07C 3/00*** (2006.01)
G07C 3/08 (2006.01)
G05B 19/048 (2006.01)

(30) Unionspriorität:
12/129,632 29.05.2008 US

(71) Anmelder:
General Electric Company, Schenectady, N.Y., US

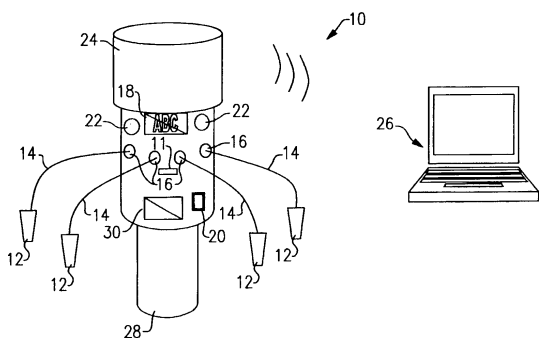
(74) Vertreter:
Rüger und Kollegen, 73728 Esslingen

(72) Erfinder:
Bonissone, Piero Patrone, Schenectady, N.Y., US; Hershey, John Erik, Ballston Lake, N.Y., US; Mitchell, Robert James jun., Waterford, N.Y., US; Subbu, Rajesh Venkat, Clifton Park, N.Y., US; Taware, Avinash Vinayak, Rexford, N.Y., US; Hu, Xiao, Schenectady, N.Y., US

Die folgenden Angaben sind den vom Anmelder eingereichten Unterlagen entnommen

(54) Bezeichnung: **Systeme und Verfahren zur modernen Zustandsüberwachung eines Anlagegutsystems**

(57) Zusammenfassung: Ein Verfahren zur modernen Zustandsüberwachung eines Anlagegutsystems beinhaltet die Verwendung von mehreren auto-assoziativen neuronalen Netzen, um Schätzwerte von Istwerten zu bestimmen, die von wenigstens einem Sensor in wenigstens einem von den mehreren Betriebsbereichen gemessen werden; die Ermittlung eines Restfehlers zwischen den geschätzten Messwerten und den Istwerten, die von dem wenigstens einen Sensor aus jedem der mehreren auto-assoziativen neuronalen Netzwerke gemessen werden; und eine Kombination der Restfehler durch Verwendung eines Fuzzy-Überwachungsmodellmischers; eine Durchführung einer Fehlerdiagnose an den kombinierten Restfehlern; und eine Ermittlung einer Betriebsänderung des Anlagegutsystems durch Analyse der kombinierten Restfehler. Ein Alarm wird, falls erforderlich, erzeugt. Ein intelligentes Sensorsystem (10) enthält eine integrierte Verarbeitungseinheit (11) zum Durchführen des Verfahrens gemäß der Erfindung.



Beschreibung

HINTERGRUND ZU DER ERFINDUNG

[0001] Die Erfindung betrifft im Wesentlichen zustandsbasierende Wartung (CBM – Condition Based Maintenance) und insbesondere moderne zustandsbasierende Überwachung von Anlagegütern unter Verwendung intelligenter Sensoren, um Agilität und Ansprechempfindlichkeit für die Wartung des Anlagegutes zu verbessern, betriebliche Verfügbarkeit des Anlagegutes zu steigern und Gesamtkosten über die Lebenszeit des Anlagegutes zu verringern.

[0002] Es sind Milliarden von Dollars in Festanlagen-Geräte investiert worden, welche vitale und zeitkritische Funktionen zur Unterstützung von industriellen und infrastrukturellen Aktivitäten ausführen. Es ist wichtig, dass eine Verschlechterung dieser Geräte sofort erkannt wird, um die maroden Geräte zu isolieren oder zu reparieren, bevor sie ausfallen und erheblich den Wirkungsgrad des Systems beeinträchtigen, von dem sie ein Teil sind, oder sogar noch schlimmer, einen physischen Schaden bewirken, der weit über das ausgefallene Gerät hinausgeht.

[0003] Die Wartung hat sich über die Jahre hinweg von einer reinen Reaktion auf Geräteausfälle (Instandsetzung oder fehlerbehebende Wwartung) über die Durchführung einer zeitbasierenden Präventionswartung zur derzeitigen Betonung der Notwendigkeit, eine Wartung auf der Basis des Zustands des Systems/des Anlagegutes (zustandsbasierende Wartung) entwickelt. Die Erkennung einer Anomalie ist eine kritische Aufgabe bei der Geräteüberwachung, Fehlerdiagnose und Systemprognose. Sie beinhaltet die Überwachung von Änderungen an dem Systemzustand, um ein fehlerhaftes Verhalten zu erkennen. Eine frühzeitige Erkennung anomaler Zustände erlaubt die Ausführung rechtzeitiger Wartungsaktionen, bevor ein möglicher Fehler zunimmt, der einen sekundären Schaden und eine Geräteausfallzeit bewirkt. Frühere Lösungsansätze für die Erkennung einer Anomalie verwenden normalerweise eindimensionale bzw. univariate Techniken, um Änderungen in den Messwerten einzelner Sensoren zu erkennen. Jedoch ist typischerweise der Zustand eines Systems durch die Wechselwirkungen und Zwischenbeziehungen zwischen den zusammen betrachteten verschiedenen Messungen gekennzeichnet.

[0004] Es gibt einen steigenden Bedarf für zustandsbasierende Wartung (CBM), um die Agilität und Ansprechempfindlichkeit für die Wartung zu verbessern, die Betriebsverfügbarkeit zu steigern und die Gesamtkosten über die Lebenszeit zu verringern.

KURZBESCHREIBUNG ZU DER ERFINDUNG

[0005] Kurz zusammengefasst, weist ein Verfahren zur modernen Zustandsüberwachung eines Anlagegutsystems die Schritte auf:
Aufteilen eines Betriebsraums eines Anlagegutsystems in mehrere Betriebsbereiche;
Verwenden mehrerer auto-assoziativer neuronaler Netze (AANNs), um Schätzwerte von Istwerten zu ermitteln, die von dem wenigstens einen Sensor in wenigstens einem von den mehreren Betriebsbereichen gemessen werden;
Ermitteln eines Restfehlers zwischen den geschätzten Messwerten und den von dem wenigstens einem Sensor aus jedem von den mehreren auto-assoziativen neuronalen Netzen gemessenen Istwerten; und
Kombinieren der Restfehler durch Verwenden eines Fuzzy-Überwachungsmodellmischers;
Durchführen einer Fehlerdiagnose an den kombinierten Restfehlern;
Ermitteln einer Veränderung des Betriebs des Anlagegutsystems durch Analyse der kombinierten Restfehler; und
Erzeugen eines Alarms, wenn eine Veränderung des Betriebs des Anlagegutsystems ermittelt worden ist.

[0006] In noch einem weiteren Aspekt der Erfindung weist ein intelligentes Sensorsystem einen intelligenten Sensor zum Überwachen eines Betriebszustands eines Anlagegutsystems, wobei der intelligente Sensor mit einem Eingangsanschluss über ein Kabel verbunden ist; und eine eingebaute Verarbeitungseinheit zur modernen Zustandsüberwachung des Anlagegutsystems unter Verwendung des in dem vorstehenden Absatz angegebenen Verfahrens auf.

KURZE BESCHREIBUNG DER ZEICHNUNGEN

[0007] Diese und weitere Merkmale, Aspekte und Vorteile der vorliegenden Erfindung werden besser verständlich, wenn die nachstehende detaillierte Beschreibung unter Bezugnahme auf die beigefügten Zeichnun-

gen gelesen wird, in welchen gleiche Bezugszeichen gleiche Teile durchgängig in allen Zeichnungen repräsentieren, wobei:

[0008] Fig. 1 eine schematische Darstellung einer Ausrüstung zur modernen Zustandsüberwachung gemäß einer Ausführungsform der Erfindung zeigt;

[0009] Fig. 2 ein Flussdiagramm einer Steuerungseinstellsequenz eines Bedieners ist;

[0010] Fig. 3A eine graphische Darstellung von normierten Zeitreihen von Sensordaten aus einem Turboblässertriebwerk ist, das am Ende der Reihe überholt wurde;

[0011] Fig. 3B das Berechnungsergebnis einer Hotelling T^2 Statistik zur Änderungserkennung, angewendet auf die normierte Zeitreihe von Fig. 3A, darstellt;

[0012] Fig. 4 die Verwendung der Kurtosis bzw. Wölbung darstellt, um die Abweichung von Normalzustand zu erkennen;

[0013] Fig. 5 simulierte Daten für sechs Systemüberwachungseinrichtungen darstellt;

[0014] Fig. 6 individuelle Variablenbeiträge zu Hotelling T^2 unter Verwendung einer farbcodierten Karte darstellt;

[0015] Fig. 7 eine Ausreißeridentifizierung unter Verwendung von Entropie- und Minderheits-Entscheidungsmaßen darstellt;

[0016] Fig. 8 graphische Darstellungen einer Datenerzeugung für einen Sensorfehler sind, in welchen normale Sensormessungen in den linken graphische Darstellungen dargestellt sind und dann individuelle Sensorfehler (Messwertverschiebung) dort eingespeist werden, wo es rote Pfeile in den rechten graphischen Darstellungen anzeigen;

[0017] Fig. 9(A) eine Anzeige einer Variablenbeitrags-Matrix ist, in welcher aufgehellte Punkte Sensoren anzeigen, die für den hohen T^2 Wert verantwortlich sind;

[0018] Fig. 9(B) eine graphische Darstellung einer Hotelling T^2 Statistik ist, in welchem die Spitzen der T^2 Werte Anomalien in den Sensormesswerten anzeigen;

[0019] Fig. 10 eine Datenerzeugung für einen Systemfehler zeigt, in welcher die Datenpunkte nach der gestrichelten Linie während eines Systemfehlers erzeugt werden;

[0020] Fig. 11 eine Anzeige einer Variablenbeitrags-Matrix ist, in welcher aufgehellte Punkte Sensoren anzeigen, die für den hohen T^2 Wert verantwortlich sind;

[0021] Fig. 12 eine graphische Darstellung einer Hotelling T^2 Statistik ist, in welcher die hohen T^2 Werte Anomalien in der Sensormessung anzeigen;

[0022] Fig. 13 eine Darstellung der Architektur eines 7-5-3-5-7 auto-assoziativen neuronalen Netzwerks (AANN) zeigt;

[0023] Fig. 14 eine Darstellung eines Anomalieerkennungsparadigmas unter Verwendung eines AANNs zeigt;

[0024] Fig. 15(A) Darstellungen von Abtastwerten von typischen Sensorrohmessungen X1(t), ..., X9(t) sind;

[0025] Fig. 15(B) graphische Darstellungen von Restwerten R1(t), ..., R9(t) sind, die den Sensorrohmesswerten X1(t), ..., X9 (t) von Fig. 15(A) entsprechen;

[0026] Fig. 16 Restwerte nach der Einspeisung einer großen Schrittfunktion in die die fünfte Variable messenden Sensordatenmesswerte darstellt;

[0027] Fig. 17 eine Darstellung eines anderen Betriebsbereichs unter Verwendung von Flughüllkurven ist;

[0028] Fig. 18(A)–(C) Restfehler von unterschiedlichen AANN-Modellen bezüglich Testsätzen aus unterschiedlichen Betriebsbereichen darstellen;

[0029] Fig. 19(A)–(C) Restfehler eines globalen AANN-Modells bezüglich Testsätzen aus unterschiedlichen Betriebsbereichen darstellen;

[0030] Fig. 20(A) und Fig. 20(B) Darstellungen eines Übergangs von Systembetriebsbereichen sind;

[0031] Fig. 21(A) und Fig. 21(B) Darstellungen von Flugbereichsübergängen und Fuzzy-Zugehörigkeitsfunktionen für jeweils Flugbetriebsbereiche definierende Variable sind;

[0032] Fig. 22 eine schematische Darstellung eines Schemas einer AANN-Interpolation durch ein Fuzzy-Überwachungsmodell ist;

[0033] Fig. 23(A) und Fig. 23(B) graphische Darstellungen von Restfehlern von AANN_1 und AANN_2 sind, wenn der Flugbereich entlang der in Fig. 20(A) und Fig. 20(B) definierten Kurve wechselt, und Fig. 23(C) graphische Darstellungen von Restfehlern aus einem Fuzzy-Überwachungsmodell sind;

[0034] Fig. 24 eine graphische Darstellung eines allgemeinen Lösungsansatzes für ein Zeitreihen-Fehlererkennung ist, der ”aktuelle” Punkte mit ”älteren” auf dem oberen Achsensatz vergleicht, wobei ein kleiner Puffer, nicht benutzt wird, um Unterschiede auf den unteren Achsen ausgeprägter zu machen;

[0035] Fig. 25(A)–(C) Darstellungen eines Permutationstests von Ausgangsdaten, einer Realisierung einer Zufalls-Umdeklaration und der Verteilung der Teststatistik für 100000 Permutationen (durchgezogene Linie) bzw. für die ursprüngliche Anordnung (gestrichelte Linie) sind;

[0036] Fig. 26 graphische Darstellungen sind, die ein Beispiel univariater Änderungserkennung einer Zeitreihe mit an der roten Linie aufgetretener Verschiebungsänderung darstellen, wobei, wenn die gestrichelten Linien Alarmierungsschwellenwerte für jede Technik sind, die eingekreisten Punkte sich dort befinden, wo die Änderung erkannt wird.

DETAILLIERTE BESCHREIBUNG DER ERFINDUNG

[0037] In den Zeichnungen, auf die Bezug genommen wird und in welchen identische Bezugszeichen dieselben Elemente durchgängig durch die verschiedenen Ansichten bezeichnen, stellt Fig. 1 ein intelligentes Sensorsystem **10** mit einem oder mehreren intelligenten Sensor(en) **12** für moderne bzw. fortschrittliche Zustandsüberwachung von einem oder mehreren (nicht dargestellten) Geräten, wie z. B. einer Turbine, einem Motor und dergleichen, gemäß einer Ausführungsform der Erfindung dar. Wie hierin definiert, bildet das eine oder die mehreren Geräteteile ein (nicht dargestelltes) Anlagegutsystem. In der dargestellten Ausführungsform überwachen vier Sensoren **12** einen Betriebszustand eines interessierenden physikalischen Parameters von dem einen oder mehreren Geräteteilen des von dem intelligenten Sensorsystem **10** zu überwachenden Anlagegutsystems. Der durch das intelligente Sensorsystem **10** überwachte Betriebszustand umfasst, ist jedoch nicht darauf beschränkt, Druck, Temperatur, Schwingung und dergleichen. Man wird erkennen, dass die Erfindung nicht auf die Anzahl der Sensoren **12** beschränkt ist und dass die Erfindung mit jeder gewünschten Anzahl von Sensoren zur Überwachung des Anlagegutsystems ausgeführt werden kann. Man wird auch erkennen, dass die Erfindung nicht auf die einen Betriebszustand des physikalischen Parameters von Interesse überwachenden Sensoren beschränkt ist und dass die Erfindung mit Sensoren ausgeführt werden kann, die eine beliebige Vorrichtung, Einrichtung oder ein beliebiges System mit jedem beliebigen Zustand überwachen, der durch den bzw. die Sensoren **12** gemessen werden kann.

[0038] Das Anlagegutsystem kann Geräte mit einem (nicht dargestellten) Geräteetikett enthalten, das die durch das System **10** überwachten Geräte identifiziert. Signale werden von den Sensoren **12** erzeugt und über ein Kabel **14** an Eingangsanschlüsse **16** des intelligenten Sensorsystems **10** übertragen. Es kann nur ein einziger Eingangsanschluss **14** für mehrere Sensoren **12** vorhanden sein, oder alternativ kann ein einzelner Eingangsanschluss **16** für jeden Sensor **12** vorhanden sein. Das intelligente Sensorsystem **10** kann eine Anzeige- und Alarmeinheit **18** enthalten, auf welcher Berechnungsergebnisse zusätzlich zu den Analysatoreinstellungen oder dem ausgelösten Alarm angezeigt werden können. Die Berechnungsergebnisse sind auch über einen Ausgangsanschluss **20** verfügbar. Das intelligente Sensorsystem **10** ist auch über eine oder mehrere lokale Steuereinrichtungen **22** steuerbar, die durch den Bediener von Hand eingestellt werden können. Das Sensorsystem **10** kann auch durch über den Eingangsanschluss **30** eingegebene Instruktionen gesteuert und auch

programmiert werden. Das Sensorsystem **10** enthält auch eine drahtlose Kommunikationseinheit **24** mit einer (nicht dargestellten) eingebauten Antenne zur drahtlosen Übertragung der Signale aus dem intelligenten Sensor **10** an eine periphere Verarbeitungsvorrichtung **26**, wie z. B. einen Personal Computer und dergleichen. Dieses Merkmal ermöglicht einen ferngesteuerten Betrieb über das Internet oder andere drahtgebundene oder drahtlose Netzwerke. Das System **10** enthält auch eine Energiequelle **28**, wie z. B. eine Batterie, eine Energiegewinnungseinrichtung und dergleichen. Mehrere derartiger intelligenter Sensorsysteme **10**, welche von der Ferne aus mit einer peripheren Verarbeitungsvorrichtung **26** kommunizieren, können in einer verteilten Weise eingesetzt werden, um eine moderne Zustandsüberwachung über ein breit verteiltes System (z. B. eine Energieerzeugungsanlage, Infrastrukturanlagegüter) zu erhalten.

[0039] Das intelligente Sensorsystem **10** enthält eine an Bord befindliche (eingebaute) Verarbeitungseinheit **10**, die Berechnungshardware, einen Speicher und eine Sensorschnittstellenschaltung, wie z. B. Analog/Digital-Wandler, aufweist. In einer Ausführungsform führt die integrierte Verarbeitungseinheit des intelligenten Sensorsystems **10** einen Hotelling T^2 Test an den aus den Sensoreingängen **16** erhaltenen Daten durch. Wie allgemein auf dem Gebiet der Signalanalyse bekannt, ist der Hotelling T^2 Test ein wirksamer Test für die Überprüfung von Prozessverschiebungen, wie z. B. Verschiebungen in den Schwerpunkten von Gruppierungen von Datenwerten. Damit der Hotelling T^2 Test Prozessverschiebungen identifiziert, ist es erforderlich, dass wenigstens einer von zwei Konfigurationen für eine anfängliche Überwachungsaktivität befolgt werden. Die erste Konfiguration ist der Fall, in welchem mehrere Sensoren vorhanden sind und die Überwachung mit dem Versuch beginnt, eine Prozessverschiebung auf der Basis der Mahalanobi-Abstände zwischen den mehreren Datengruppierungen zu erkennen. Die zweite Konfiguration ist der Fall, in welchem nur ein einzelner Sensor vorhanden ist. Für diesen Fall ist es erforderlich, die Daten aus dem einzelnen Sensor mit einer verzögerten Version dieser selbst zu verarbeiten.

[0040] Das intelligente Sensorsystem **10** kann von zwei bestimmten Parteien für eine moderne Zustandsüberwachung eines Anlagegutsystems programmiert werden. Die erste Partei ist der Gerätetechniker. Der Gerätetechniker stellt Steuerungen ein, wie beispielsweise, aber nicht im Sinne einer Einschränkung, die Abtastrate, die Anzahl von Abtastwerden, die Größe des Analysefensters, Auswahl und Abstimmung von Nachfilterungsoperationen, Datenausgabeformatierung und Transportart und Anzeigeformatierung der Ergebnisse. Die zweite Partei ist der Gerätebetreiber. Der Betreiber stellt ebenfalls Steuerungen ein, wie beispielsweise, aber nicht im Sinne einer Einschränkung, die Anzahl und Art der zu verwendenden Sensoren, die Datenverzögerungen für gemessene Daten und die Art der Datenerfassung und durchzuführenden Verarbeitung. Ein typisches Flussdiagramm der Betreibersteuereinstellungssequenz ist in **Fig. 2** dargestellt. Im Schritt S2.1 wird die Gerätekennung in das moderne Zustandsüberwachungssystem **10** eingegeben. Die Gerätekennung befindet sich auf dem Geräteidentifizierungsetikett. Die Gerätekennung kann Zahlen, Buchstaben und andere informationshaltige Zeichen, wie z. B., jedoch nicht als Einschränkung, einen Barcode aufweisen. Die Gerätekennung kann auch elektronisch und nicht sichtbar vorhanden sein, wie z. B. und nicht als Einschränkung, als RFID-Element. Der Eintrag der Gerätekennung in das moderne Zustandsüberwachungssystem **10** kann über einen von mehreren Wegen erfolgen, wie z. B. und nicht im Sinne einer Einschränkung, durch Lesen und Eingeben der sichtbaren Kennungsetiketten durch den Betreiber, ein Barcode-Lesegerät und ein RFID-Lesegerät. Die Betreibersteuerungseinstellsequenz geht dann zu dem Schritt S2.2 über, in welchem der Betreiber die Anzahl der in der anschließenden Überwachungsaktivität zu verwendenden Sensoren festlegt. Die Betreibersteuerungseinstellsequenz geht dann zu dem Schritt S2.3 über, in welchem der Betreiber Datenverzögerungen bezüglich der Sensoreingangssignale einstellt. Eine Ausführungsform, die wenigstens eine Nicht-Null-Datenverzögerung nutzt, umfasst die Überwachungsaktivität, in welcher nur ein einziger Sensor vorhanden ist. Wenn die Anzahl der Sensoren, wie in dem Schritt S2.2 1 ist und eine Nicht-Null-Datenverzögerung im Schritt S2.3 eingegeben wird, konfiguriert das moderne Zustandsüberwachungssystem **10** seine Verarbeitung so, dass die Daten des einzigen Sensors gemeinsam mit dessen verzögerten Version verarbeitet werden. Die Betreibersteuerungseinstellsequenz geht dann zu dem Schritt S2.4 über, in welchem der Betreiber gefragt wird, ob die anschließende Überwachungsaktivität ein Vergleichsvorgang sein soll. Wenn der Betreiber ”Nein” eingibt, wird das moderne Zustandsüberwachungssystem **10** sich selbst so konfigurieren, dass es die Hotelling T^2 Statistik ausgeführt, ohne Daten oder Ergebnisse von vorherigen Überwachungsaktivitäten für dieselbe Gerätekennung zu verwenden oder sich darauf zu beziehen, und die Betreibersteuerungseinstellsequenz geht zu dem Schritt S2.8 über, in welchem das moderne Zustandsüberwachungssystem **10** für die Aufnahme der Überwachungsdaten bereit ist. Wenn der Betreiber ”Ja” eingibt, geht dann die Betreibersteuerungseinstellsequenz zu dem Schritt S2.5 über, in welchem der Betreiber gefragt wird, ob der Betreiber die Verwendung von gespeicherten Mittelwertvektoren aus der letzten Überwachungsaktivität wünscht. Wenn der Betreiber ”Ja” eingibt, geht die Betreibersteuerungseinstellsequenz zu dem Schritt S2.7 über, in welchem das moderne Zustandsüberwachungssystem die Mittelwertvektoren der letzten Überwachungsaktivität für dieselbe Gerätekennung lädt oder anderweitig darauf zugreift. Die Betreibersteuerungseinstellsequenz geht dann zu dem Schritt S2.8

über, in welchem das moderne Zustandsüberwachungssystem **10** für die Aufnahme der Überwachungsdaten bereit ist. Wenn der Betreiber ”Nein” eingibt, geht dann die Steuerüberwachungssequenz des Betreibers zu dem Schritt S.6 über, in welchem angenommen wird, dass der Betreiber das Laden aktueller Betriebsdaten aus der letzten Überwachungsaktivität für dieselbe Gerätekennung wünscht. Die Steuerung geht dann zu dem Schritt S2.8 über, in welchem das moderne Zustandsüberwachungssystem **10** für die Aufnahme der Überwachungsdaten bereit ist.

[0041] Die Hotelling T^2 Technik wurde unter Verwendung realer Überwachungsdaten aus dem Flugzeugtriebwerk GE90 getestet. **Fig.** 3(A) stellt einige exemplarische Sensordaten dar, die von einem Turbobläsertriebwerk über eine Periode, einschließlich einer Zeit gemessen wurden, als es bei dem Zyklus 2N aufgrund von Verschlechterung überholt wurde. Dargestellt sind drei Verläufe über einer mit Zyklus(#) bezeichneten Abszisse. Der obere Verlauf ist die Abgastemperatur (EGT), der mittlere Verlauf ist der Brennstoffdurchsatz (WFM). Der untere Verlauf ist die Kerndrehzahl (N2). Man wird erkennen, dass kein offensichtlicher Trend zu einer Verschiebung der Sensormesswerte vorliegt, wenn die Triebwerksverschlechterung fortschreitet. **Fig. 3B** stellt das Berechnungsergebnis des Hotelling T^2 Tests mit den Daten von **Fig. 3A** dar. Es sei angemerkt, dass die Hotelling T^2 Statistik von ihrem Bereich relativ niedriger Werte zu wesentlich höheren Werten ansteigt, die einen Datentrend anzeigen, der in diesem Fall für eine Verschlechterung indikativ ist. Die ansteigende T^2 Statistik deckt auf, dass der Systemzustand den normalen Zustand verlässt.

[0042] Sobald eine Änderung in dem Betrieb des komplexen Systems durch die Hotelling T^2 Statistik erkannt wurde, geht das Verfahren dazu über, die dem System zugeordneten Variablen, welche das Verlassen des Normalbetriebs verursachen, zu isolieren. Insgesamt ist die Hotelling T^2 Statistik eine einfache, aber sehr effektive Technik mit geringem rechnerischem Aufwand. Diese Eigenschaften machen sie für einen Einsatz sowohl in einer Online-Überwachung als auch in Handgeräten geeignet. Wenn die Änderung in dem komplexen System durch einen Sensor verursacht wird, kann dann ein Sensorfehler korrigiert werden. Andererseits kann, wenn die Änderung in dem komplexen System systembezogen ist, der Systemfehler dann gemeldet werden.

[0043] Es ist möglich, und es kann von großem Nutzen sein, eine selektive Nachverarbeitung an einer erstellten Hotelling T^2 Statistik auszuführen. Diese Nachverarbeitung kann so ausgelegt sein, dass sie solche Daten, wie die Rate des statistischen Anstiegs, den Zeitpunkt der Schwellenwertdurchschreitung und die Dauer des Datentrends aufdeckt. Nachverarbeitungs-Verfahren und -Techniken beinhalten beispielsweise, aber nicht im Sinne einer Einschränkung, Kurvenanpassung auf der Basis von L1, L2 oder andere Normminimierungstechniken, Wavelets, Modellanpassung, Medianfilterung und andere Störungsbeseitigungstechniken.

MULTIVARIATE ÄNDERUNGSERKENNUNG

[0044] In einem komplexen System ist es nicht möglich, alle von den vielen Variablen aus einem Satz von Sensoren vollständig zu instrumentieren und zu kalibrieren. Dies ist so, weil ein komplexes System eine große Anzahl von Zuständen durchläuft und ferner in einer sehr großen Anzahl von Modi arbeitet, wovon jeder Modus eine eindeutige normale Betriebshüllkurve in einem Zustandsraum zeigt.

[0045] Es ist daher extrem schwierig und vielleicht unmöglich, einen allgemeinen Test zu ersinnen, der die Betriebsabweichung des komplexen Systems von dem Normalzustand aufdeckt, aber aufgrund der Kosten in Verbindung mit der Implementation und Entwicklung eines großen komplexen Systems ist es wichtig, dass innovative Anstrengungen ausgeweitet werden, um sich besser einem wirkungsvollen Gesamttest für eine Normalitätsabweichung, der zeitlichen Lokalisierung einer derartigen Abweichung und Identifizierung der System-zugeordneten Variablen anzunähern, die die Abweichung vom Normalbetrieb bewirken. Es ist ferner erwünscht, dass ein Weg entwickelt wird, der eine signifikante und leicht erkennbare Änderung in der Betriebsabweichung des komplexen Systems vom Normalzustand reflektiert, der keine anfängliche Analyse von mehr als einer nominellen Anzahl von Testergebnissen erfordert, d. h., es wäre ideal, wenn irgendeine signifikante Änderung in dem Systembetriebszustand deutlich in einem einzigen Testergebnis reflektiert werden würde.

[0046] Ein Aspekt des Verfahrens der Erfindung besteht darin, dass eine Signalverarbeitung von beobachteten Daten eines komplexen Systems genutzt wird, um zu ermitteln, wann ein komplexes System von seinem Normalbetrieb abweicht. Das Verfahren identifiziert auch die System-zugeordneten Überwachungsvariablen, deren Daten eine Abweichung vom Normalbetrieb anzeigen.

[0047] Die Hotelling T^2 Statistik, oder alternativ T^2, ist auf dem Gebiet der Signalverarbeitung allgemein bekannt. Zuerst von Harold Hotelling vorgeschlagen, ist sie das Quadrat des Mahalanobis-Abstands, einer weiteren allgemein bekannten Technik auf dem Gebiet der Statistik, und ist eine Verallgemeinerung der Student t

Statistik, die bei multivariaten Hypothesentests eingesetzt wird. Sie ist in Bezug auf einen Satz von p Variablen $x = (x_1, x_2, ..., x_p,)$ mit Mittelwerten $\mu = (\mu_1, \mu_2, ... \mu_p)$ und eine p × p Kovarianzmatrix W definiert, wobei W von n Schnappschüssen gebildet wird,

$$W = \sum_{i=1}^{n} (x_i - \mu_i)(x_i - \mu_i) / (n - 1)$$

aus den System-zugeordneten Variablen entnommen ist.

[0048] In der Hotelling T^2 Statistik ist t^2 als $t^2 = (x - \mu)'W^{-1}(x - \mu)$ definiert. Bei dem erwarteten Verhalten der Hotelling T^2 Statistik basiert t^2 auf der Annahme, dass $x = (x_1, x_2 ..., x_p)$ eine gemeinsame p-variate Gauss'sche Verteilung bildet. In der Praxis sieht man niemals eine derartige Verteilung. Jedoch können die Hotelling T^2 Statistik und viele weitere auf derselben Annahme vorhergesagte Statistiken einen immensen Wert zu einer Systemanalyse beitragen.

[0049] Wenn die Hotelling T^2 Statistik genutzt wird, ist es im Allgemeinen ratsam, eine Trainings- bzw. Lernperiode mit Daten bereitzustellen, die von Sensoren genommen werden, die die System-zugeordneten Variablen beobachten, wenn man vernünftigerweise glaubt, dass sich das System in einem stabilen Betriebsintervall befindet. Während eines derartigen Intervalls wird die Existenz von Mittelwerten $\mu = (\mu_1, \mu_2, ... \mu_p)$ angenommen, und diese können durch Mittelwertbildung abgeleitet werden.

[0050] Es ist eine Änderung in der p-dimensionalen Kovarianzmatrix W oder in den Mittelwerten u, die bewirkt, dass die eindimensionale Hotelling T^2 Statistik eine erkennbare Veränderung zeigt. Um den Vorteil der Dimensionalitätsreduktion von mehreren gemessenen System-zugeordneten Variablen in die nur eine Hotelling T^2 Statistik zu nutzen, und um effizient die Veränderung in der Hotelling T^2 Statistik über zwei Sätzen von Schnappschüssen, Δt^2, zu erzeugen, kann die Berechnung ausgeführt werden, indem berechnet wird

$$\Delta t^2 = (x^* - m^*)'W_2^{-1}(x^* - m^*) - (x - m)'W_1^{-1}(x - m)$$

wobei W_1 und W_2, x und x* und μ und μ* jeweils über den ersten bzw. zweiten Satz der Schnappschüsse hinweg berechnet werden.

[0051] Schnappschuss-Sensordaten wurden von einem Turbobläsertriebwerk über eine Periode gesammelt, die eine Zeit beinhaltete, als dieses aufgrund einer Verschlechterung überholt wurde. **Fig. 3A** stellt die normierten Sensormesswerte von drei der elf Variablen dar: Abgastemperatur-EGT, Brennstoffdurchsatz-WFM und Kerndrehzahl-N2. Aus **Fig. 3A** können wir ersehen, dass es keinen offensichtlichen Trend oder eine Verschiebung in den Sensormesswerten gibt, wenn sich das Triebwerk verschlechtert. Zuerst wurden Daten aus den ersten 1000 Flugzyklen (Punkten) verwendet, um den Abtastmittelwert und eine Abtastkovarianz abzuschätzen. Anschließend wurde die T^2 Statistik direkt für alle Daten, einschließlich EGT, WMF, N2 und einiger anderer Schlüsselparameter, berechnet. In **Fig. 3B** können wir den Aufwärtstrend der T^2-Bewertung sehen, welche höhere Werte zeigt, wenn wir uns dem Triebwerksverschlechterungswert annähern, der dessen Überholung verursachte.

[0052] Die in die Berechnung der Hotelling T^2 Statistik enthaltene Hauptaufgabe ist die Berechnung der Kovarianzmatrix. Diese Matrix kann auf viele Arten abgeschätzt werden. Diese Arten umfassen, ohne implizierte Einschränkung, einen direkten Ansatz einer ersten Erfassung von sequentiellen Sätzen individueller Variablenwerte, eine Berechnung der Mittelwerte der Variablen über den erfassten Werten, eine Subtraktion der Mittelwerte von den entsprechenden Sätzen von Variablen, und dann eine Durchführung einer geeigneten paarweisen Multiplikation und Abtastgrößenteilung. Der Schätzwert der Kovarianzmatrix kann auch durch Erzeugen von Minimalvolumen-Ellipsoiden über den verschiedenen Variablenpaaren erzeugt werden. Dieses Verfahren ist bekanntermaßen sehr robust bei Vorliegen verfälschter Daten, und bei korrekter Behandlung von Ausreißern und anderen vermutlich verfälschten Daten ergibt das Verfahren einen guten Schätzwert der Mittelwerte der Variablen und der Einträge der Kovarianzmatrix. Noch ein weiterer Weg zur Abschätzung der Kovarianzmatrix erfolgt durch Aufbau einer Abschätzfunktion sukzessiver Differenzen über n Schnappschüssen. Diese Schätzfunktion wird aus $x = (x_1, x_2, ... x_n)$ als $V_i = x_i + 1 - x_i$ für i = 1, 2, ..., n–1 aufgebaut und zur Erzeugung von

$$W = \frac{1}{2(n - 1)} \sum_{i=1}^{n} V_i V_I' \text{ verwendet.}$$

[0053] In einigen wichtigen Fällen einer Systemverschlechterung können die Mittelwerte der System-zugeordneten überwachten Variablen langsame lineare Driftwerte haben. Die Hotelling T^2 Statistik deckt wahrscheinlicher diese Driftwerte auf, wenn die aufeinander folgenden Differenzen, die zum Aufbau des Schätzwertes der Kovarianzmatrix verwendet werden, weiter als 1 entfernt sind. Es ist daher lohnend, eine Verarbeitungsoption mit einzubeziehen, welche aufeinander folgende Differenzen über eine Abtastwertzahldifferenz von δ, $V_i = x_{i+\delta} - x_i$, erzeugt, wobei $\delta > 1$ ist.

[0054] Es gibt zahlreiche mögliche Techniken zum Hervorheben einer signifikanten Änderung in der Hotelling T^2 Statistik oder der paarweisen Änderungen in der Hotelling T^2 Statistik über eine Reihe von Schnappschüssen. Diese Techniken umfassen beispielsweise und ohne Einschränkung Energietests und Tests der Momente höherer Ordnung, insbesondere die Verwendung der Exzess-Kurtosis, die durch Division der vierten Kumulante durch das Quadrat der Varianz und eine anschließende Subtraktion von drei (3) erhalten wird. **Fig. 4** stellt eine Aufzeichnung der Kurtosis (Wölbung) dar, die über ein gleitendes Fenster mit einer Weite von 20 Abtastwerten über T^2 Abtastdaten berechnet wurde. Man beachte die Kurtosisspitzen, wenn der erste anormale Punkt in das Fenster bei der Abtastwertnummer **55** eintritt. Weitere Techniken beinhalten die Einstellung eines Schwellenwertes. Ein geeigneter Schwellenwert kann in einer Vielzahl von Arten erdacht werden. Beispielsweise und nicht im Sinne einer Einschränkung kann der Schwellenwert durch Analyse von Verlaufsdaten gewählt werden, welche während eines normalen Systembetriebs erfasst wurden, und indem ein erster Teil von diesen Verlaufsdaten verwendet wird, um den Mittelwert der System-zugeordneten Überwachungsvariablen und die Kovarianzmatrix der System-zugeordneten Überwachungsvariablen abzuschätzen. Ein zweiter Teil der Verlaufsdaten, der sich nicht mit dem ersten Teil überlappt, kann zum Unterscheiden der Wahrscheinlichkeitsdichtefunktion verwendet werden, die das Verhalten der T^2 Statistik beschreibt. Ein Schwellenwert kann dann auf eine Anzahl unterschiedlicher Möglichkeiten eingestellt werden. Eine derartige Möglichkeit besteht beispielsweise und nicht im Sinne einer Einschränkung in der Berechnung der Wahrscheinlichkeit eines Fehlalarms unter Normalbetrieb und der erwarteten Kosten eines Fehlalarms und der Einstellung des Schwellenwertes in einer derartigen Weise, dass die Kosten pro Abtastwert unter Normalbetrieb kleiner oder gleich vorgegebenen Kosten sind.

SYSTEMÄNDERUNG UND VARIABLENIMPLIKATION

[0055] Sobald eine Änderung in dem Betrieb des komplexen Systems durch die Hotelling T^2 Statistik erkannt wurde, geht das Verfahren dazu über, die System-zugeordneten Variablen, die die Abweichung von dem Normalbetrieb bewirkten, zu isolieren. Eine Möglichkeit, diesen Schritt auszuführen, besteht darin, zuerst die Hotelling T^2 Statistik anhand ihrer Hauptkomponenten auszudrücken. Dieses erfolgt, indem zuerst T^2 dargestellt wird als:

$$T^2 = \sum_{a=1}^{n} \frac{t_a^2}{\lambda_a} = \sum_{a=1}^{n} \frac{t_a^2}{s_a^2}$$

wobei λ_a, a = 1, 2, ... n die Eigenwerte der Kovarianzmatrix W sind und t_a die Werte der Hauptkomponententransformation sind. S^2_a ist die Varianz von t_a (die Varianz der Hauptkomponenten sind die Eigenwerte von W). Jeder Wert t_a kann ausgedrückt werden als

$$t_a = p'_a(x - \mu) = \sum_{j=1}^{n} p_{a,j}(x_j - \mu_j)$$

wobei p_a der Eigenvektor von W ist, der λ_a entspricht, und $p_{a,j}$, x_j, μ_j Elemente des entsprechenden Vektors, zugeordnet der j-ten Variablen sind. Durch diese Darstellung des Beitrags jeder Variablen x_j zu dem Wert der Hauptkomponente findet man a als $p_{a,j}(x_j - \mu_j)$. Diese Information kann dazu genutzt werden, die Variable(n) zu erkennen, die den stärksten Einfluss auf die durch das Hotelling T^2 Maß gemessene Anomalie hat/haben.

[0056] Der nächste Schritt besteht in der Berechnung des Beitrags $cont_{a,j}$ einer Variablen, die in dem normalisierten Wert $(t_a/s_a)^2$ auftritt. Wir haben $cont_{a,j} = (t_a/s^2_a)p_{a,j}(x_j - \mu_j)$. Wir berechnen dann den Gesamtbeitrag der Variablen x_j durch Summation

$$CONT_j = \sum_{a=1}^{n} (cont_{a,j}).$$

Die Hotelling T^2 Statistik kann nun als eine Summe der Beiträge aller Variablen über all den Werten geschrie-

ben werden als:

$$t^2 = \sum_{a=1}^{n} \frac{t_a}{s_a^2} \sum_{j=1}^{n} p_{a,j}(x_j - \mu_j) = \sum_{j=1}^{n} \{ \sum_{a=1}^{n} \frac{t_a}{\lambda_a} [p_{a,j}(x_j - \mu_j)] \}$$

[0057] Als ein Beispiel und nicht im Sinne einer Einschränkung der Technik zum Ermitteln, wann das komplexe System von dem normalen Betrieb abweicht, und zum Bewerten der Beiträge der verschiedenen Variablen, wird der Fall betrachtet, dass es sechs Variablen x_1, x_2, ..., x_6 gibt, die sequentielle Werte gemäß der graphischen Darstellung in Fig. 5 zeigen. Die für die sechs Variablen x_1, x_2, ..., x_6 verwendeten Daten wurden aus einer unabhängigen Abtastung eines Gauss'schen Zufallsvariablengenerators abgeleitet und dann modifiziert gemäß:

$x_1(55) = +4$

$x_2(60) = -4$

$x_3(65) = +3$

$x_4(65) = -3$

$x_5(81:85) \leftarrow x_5(81:85) + 3$

$x_6(81:85) \leftarrow x_6(81:85) + 3$

[0058] Die Hotelling T^2 Statistik, T^2, wird auf der Basis der Daten von Fig. 5 berechnet, wobei die Kovarianzmatrix unter Verwendung der ersten 50 Abtastwerte von jeder der sechs Variablen geschätzt wird. Der nächste Schritt besteht in der Veranschaulichung der unterschiedlichen Beiträge von den sechs Variablen zu der Hotelling'schen T^2-Statistik an den Punkten, an denen die Statistik über einem Schwellenwert liegt. Dieses kann auf verschiedene Arten erfolgen. Beispielsweise und nicht im Sinne einer Einschränkung ist die Größe $M_{i,j}$ des Beitrags der j-ten Variable zu dem Wert der Hauptkomponente an dem Datenpunkt i $M_{i,j} = |p_{i,j}(x_j - \mu_j)|$, und die über alle Variablenbeiträge der Größen normierte relative Größe wird als $M'_{i,j}$ bezeichnet und als

$$M'_{i,j} = \frac{M_{i,j}}{\sum_{j=1}^{n} M_{i,j}}$$

berechnet. Die Verteilungsgrößen und die relativen Größen können unter Benutzung einer Farbcodierung zur Unterstützung des Betreibers bei der Interpretation der Ergebnisse angezeigt werden. Fig. 6 stellt die unterschiedlichen Beiträge von den sechs Variablen für die Hotelling T^2 Statistik an allen 100 Punkten unter Verwendung einer Farbcodierung dar. Das farbcodierte Blockgitter stellt die relativen Beiträge an der Ordinate von den an der Abszisse aufgelisteten sechs Variablen x_1, x_2, ..., x_6 dar.

[0059] In einer weiteren Ausführungsform können Ausreißer, wie z. B. die in Fig. 7 dargestellten, auch durch ein Entropiemaß E_i, wobei

$$E_i = -(1 / \ln(n)) \sum_{j=1}^{n} M'_{i,j} \ln(M'_{i,j}),$$

und durch ein Minderheitsentscheidungsmaß m_i, wobei $m_i = 1 - \max_j(M'_{i,j})$, unterschieden werden. Fig. 7 trägt E_i und m_i für diejenigen T^2 Punkte auf, die einen Schwellenwert überschreiten. Zum Zwecke der Veranschaulichung werden zwei unterschiedliche Schwellenwerte betrachtet. Der erste Schwellenwert, Fig. 7 links, ist der Schwellenwert, der dazu führt, dass fünf der Schwellenwerte die T^2-Berechnungen überschreiten. Der zweite Schwellenwert, Fig. 7 rechts, ist ein niedrigerer Schwellenwert, der zu zehn den Schwellenwert überschreitenden T^2 Berechnungen führt.

[0060] Als ein weiteres Beispiel der Technik zum Ermitteln, wann das komplexe System vom Normalbetrieb abweicht, und zum Bewerten der Beiträge der verschiedenen Variablen, werde in Betracht gezogen, dass es neun kritische Sensoren x_1, x_2, ..., x_9 in dem "Cycle-Deck"-Modell des GE 90 gibt, die sequentielle Werte, wie

in Fig. 8 graphisch dargestellt, anzeigen. Die für die neun Variablen x_1, x_2, x_9 verwendeten Daten wurden erzeugt, während ”Cycle-Deck” unter normalen Flugbedingungen ohne Verlust an Wirkungsgrad und Durchsatz simuliert wurde. Wir können diese Daten als „fehlerfreie” Daten Zustands betrachten. Um einen Sensorfehler zu simulieren, modifizierten wir absichtlich einige von den Sensormesswerten zu unterschiedlichen Zeitpunkten:

ZPCN25(130) = 100

PS3(150) = 170

T3(170) = 1310

CT49(181:185) = 1170

[0061] Der nächste Schritt besteht in der Darstellung der unterschiedlichen Beiträge von den neun Variablen zu der Hotelling T^2 Statistik. Dieses kann auf mehrere Arten erfolgen. Die Beitragsgrößen und die relativen Größen können zur Unterstützung des Betreibers bei der Interpretation der Ergebnisse angezeigt werden. Die Anzeige kann farbcodiert werden. Fig. 9(A) zeigt, wie angezeigt eine Abbildung der relativen Beitragsgrößen. Das Gitter zeigt auf der Ordinate die relativen Beiträge von den auf der Abszisse aufgelisteten neun Variablen x_1, x_2, ..., x_9 an.

[0062] Die T^2 Statistik wird auf der Basis der Zeitreihendaten aus den in Fig. 9(B) dargestellten neun Sensoren berechnet. Die Lage der Spitzen in den T^2 Statistikwerten entspricht den Stellen, an denen die Sensorfehler eingespeist wurden. Die Sensorvariablen mit hohem Beitrag sind für die Änderung in der T^2 Bewertung impliziert. Vielversprechenderweise sind die durch die Analyse des Variablenbeitrags identifizierten Sensoren genau die Sensoren mit dem eingespeisten Fehler.

[0063] Um einen Systemfehler zu simulieren, konfigurierten wir die Parameter Durchfluss und Wirkungsgrad des ”Cycle Deck”-Modells im Betrieb vom Normalzustand (”fehlerfrei”) aus auf einen Systemfehler. Wie in Fig. 10 dargestellt, entsprechen die Punkte nach den Strichlinien einem Systemfehler. In Fig. 12 nimmt die T^2 Statistik rasch von 200 an zu, wo der Systemfehler beginnt. Ferner erkennt die Beitragsanalyse die Sensoren mit einer Abweichung von der Normalität genau, wie in Fig. 11 veranschaulicht. In einem gewissen Umfang ist dies eine Möglichkeit, Sensor- und Systemfehler voneinander zu unterscheiden, da es sehr unwahrscheinlich ist, dass mehrere Sensoren zum gleichen Zeitpunkt einen Fehler haben.

[0064] Sobald ein anormales Verhalten erkannt worden ist, kann ein die Ergebnisse der Analyse meldender Alarm an die Systemüberwachungsstellen auf eine beliebige Vielzahl von Möglichkeiten, einschließlich, jedoch nicht notwendigerweise darauf beschränkt, über elektrische Verkabelung, Informationsübertragung über Energieversorgungsleitungen, ein Intranet, das Internet oder drahtlos übertragen werden.

SENSORVALIDIERUNG

[0065] Für eine zuverlässige Zustandüberwachung ist es erforderlich, über genaue Sensorinformation zu verfügen. Sensoren können jedoch manchmal fehlerhaft sein, oder sie können aufgrund eines Ausfalls oder von Wartungsaktivitäten nicht zur Verfügung stehen. Eine Sensorvalidierung ist daher ein kritischer Teil der Zustandsüberwachung. Herkömmliche Lösungsansätze zur Sensorvalidierung beinhalten eine periodische Instrumentenkalibrierung. Die Kalibrierungen sind sowohl hinsichtlich der Arbeit als auch hinsichtlich der Prozessausfallzeit aufwendig.

[0066] Zur Behandlung der Probleme in Verbindung mit der Sensorvalidierung nutzt die Erfindung ein auf einem auto-assoziativen neuronalen Netzwerk (AANN) basierendes Sensorvalidierungsmodells, das eine Online-Kalibrierungsüberwachung von auf Plattformen eingesetzten Sensoren durchführen kann. Die Eigenschaft des Modells ermöglicht die Erkennung von Sensordrift oder -fehler durch Vergleichen der Sensorrohmesswerte, welche die Modelleingangsgröße sind, mit einem entsprechenden Modellbasierenden Schätzwert der Sensorwerte. Zusätzlich kann eine Überwachungsanalyse der Restgrößen zwischen den Roh- oder Ist-Sensormesswerten und dem Sensorschätzwert helfen, zwischen einem Sensorfehler und einem Systemfehler zu unterscheiden. Per Definition ist eine Restgröße bzw. ein Restfehler der Unterschied zwischen einem tatsächlichen gemessenen oder erfassten Wert und dem zugehörigen geschätzten Wert. Ein Restgrößen- bzw. Restfehlervektor ist der Unterschied zwischen einem Satz von Istwerten und dem entsprechenden Satz von geschätzten Werten. Eine signifikante Abweichung in den Restgrößen für einen kleinen Teilsatz von Sensormess-

werten würde (einen) Sensorfehler anzeigen, während eine signifikante Abweichung von Restgrößen für einen großen Teilsatz von Sensormesswerten einen Systemfehler anzeigen würde. Eine Abweichung der Restgrößen von einem einzelnen Sensor ist typischerweise ein Hinweis auf einen Sensorfehler, während mehrere Abweichungen der Restgrößen aus mehreren Sensoren typischerweise ein Hinweis auf einen Systemfehler darstellen.

[0067] Die Eingaben in das AANN durchlaufen eine Dimensionalitäts-Reduktion, da ihre Information in Zwischenschichten kombiniert und komprimiert wird. Beispielsweise werden in Fig. 13 die sieben Knoten in der Eingabeschicht auf fünf und dann auf drei Knoten in der zweiten Schicht (Codierung) bzw. in der dritten Schicht (Flaschenhals) reduziert. Dann werden die Knoten in der dritten Schicht verwendet, um die ursprünglichen Eingangsgrößen wieder zu erzeugen, indem sie eine Dimensionalitätserweiterung (vierte Schicht, Decodierung und fünfte Schicht, Ausgaben) durchlaufen. In dem idealen Falle sollten die AANN-Ausgangsgrößen mit den Eingangsgrößen identisch sein. Deren Unterschied (Restwerte Fig. 14) werden in der Fehlerdiagnose-Entscheidungsfällung **260** verwendet.

[0068] Dieses Netzwerk berechnet im Wesentlichen die größten nicht linearen Hauptkomponenten (NLPCA – Non-Linear Principal Components) – die Knoten in der Zwischenschicht – um Korrelationen zwischen den Variablen zu erkennen und zu beseitigen. Neben der Erzeugung von Restfehlern wie in dieser Anwendung kann diese Art von Netzwerk auch bei der Dimensionalitätsreduktion, Visualisierung und exploratorischen Datenanalyse verwendet werden. Es ist anzumerken, dass PCA nur lineare Korrelationen zwischen Variablen identifiziert, während NLPCA sowohl lineare als auch nicht-lineare Korrelationen ohne Einschränkung bezüglich der Eigenschaften der in den Daten vorhandenen Nichtlinearitäten offenlegt. NLPCA arbeitet durch Trainieren eines neuronalen Netzwerkes mit Vorwärtskopplung, um die Identitätszuordnung auszuführen, in welcher die Netzwerkeingangsgrößen an der Ausgangsschicht reproduziert werden. Das Netzwerk enthält eine interne ”Flaschenhals”-Schicht (die weniger Knoten als die Eingangs- oder Ausgangsschicht enthält), welche das Netzwerk dazu zwingt, eine kompakte Darstellung der Eingangsdaten und zwei zusätzliche verborgene Schichten zu erzeugen. Die in den verborgenen Knoten enthaltenen nicht-linearen Funktionen sind typischerweise von dem ”tansig”-Typ, während die zentrale Flaschenhalsschicht eingebettete lineare Transformationsfunktionen hat.

[0069] Physikalische Modelle können dazu genutzt werden, den nominellen Wert der Sensormessergebnisse unter verschiedenen Betriebszustände zu erzeugen, sodass die Restfehler (Fig. 16) zwischen einer Sensorrohmessung und dem nominellen Messwert dazu verwendet werden können, Trendänderungen über der Zeit zu erkennen. Jedoch müssen, wenn kein physikalisches Modell zur Verfügung steht, nominelle Sensormesswerte direkt aus den Rohmessungen abgeleitet werden. Früher wurden auto-assoziative neuronale Netze (AANN) zur Sensorvalidierung verwendet, wenn Informationen in den Messwerten in dem Sinne analytisch redundant sind, dass, wenn ein Messwert verloren geht, dieser durch einen Schätzwert aus den restlichen gültigen Sensoren ersetzt werden kann. Andererseits verwendet die Erfindung ein AANN, um Sensormesswerte unter normalen Bedingungen abzuschätzen, so dass dann der Restfehler zwischen dem Rohmesswert und dem normalen Messwert dazu genutzt werden kann, um auf anormale Zustände in dem Sensor/System zu schließen.

[0070] Wir verwendeten einen neun-wertigen Zustandsvektor, der von dem ”Cycledeck”-Modell des GE90 erzeugte Flugzeugtriebwerksdaten repräsentiert. Unter Verwendung dieses Datensatzes bauten wir ein 9-5-3-5-9 AANN gemäß der in Fig. 13 dargestellten Architektur auf. Ein neuronales Netzwerk zum Abschätzen der Sensorwerte ist in Fig. 14 dargestellt, wobei das neuronale Netz dieser Ausführungsform lediglich für Beispielzwecke und nicht im Sinne einer Einschränkung sieben Eingänge, fünf Codierungsschichtknoten, drei Flaschenhalsschichtknoten, fünf Decodierungsschichtknoten und sieben Ausgänge besitzt. Wir bezeichnen eine derartige neuronale Netzarchitektur als 7×5×3×5×7. Die Struktur **200** zeigt die Sensor-Istwerte, wie sie zur Vereinfachung der graphischen Darstellung in dem Kasten **210** gruppiert und in die Eingabeschicht **215** eines fünfstufigen neuronalen Netzes **270** eingegeben werden. Die Sensor-Istwerte werden auch an einen Kombinator **250** gesendet. Wie allgemein auf dem Gebiet neuronaler Netze bekannt, werden die Ausgangssignale der Eingangsschicht **215** in die Codierungsschicht **220** eingegeben. Die Ausgangssignale der Codierungsschicht **220** werden in die Flaschenhalsschicht **225** eingegeben. Die Ausgangssignale der Flaschenhalsschicht **225** werden in die Decodierungsschicht **230** eingegeben. Die Ausgangssignale der Decodierungsschicht **230** werden in die Ausgangsschicht **235** eingegeben. Die Ausgangssignale der Decodierungsschicht **235** bilden die Schätzwerte der Sensorwerte, die zur Vereinfachung der graphischen Darstellung in dem Kasten **240** gruppiert sind. Die Sensorwertschätzwerte werden an den Kombinator **250** gesendet, wo die Restfehler **255** durch Subtrahieren der Sensor-Istwerte von den geschätzten Sensorwerten erzeugt werden. Die Restfehler werden in das Modul **260** eingegeben, welches Entscheidungen bezüglich der Restfehler zur Unterscheidung und Mel-

dungerzeugung irgendwelcher abgeleiteter Fehlerdiagnosen trifft. Es gibt zwei optionale Eingangssignale in das Entscheidungsfällungsmodul **260**. Das erste von diesen Eingangssignalen **212** stammt aus dem internen Informationsmodul **221** und weist verarbeitete interne Informationen auf. Die verarbeiteten internen Informationen beinhalten beispielsweise, und nicht als Einschränkung, Physik-basierende Modelle und Beziehungen, die bekanntermaßen unter und zwischen den Sensor-Istwerten **210** existieren. Diese Werte werden in das interne Informationsmodul von den Sensor-Istwerten **210** eingegeben. Das zweite von diesen Eingangssignalen **214** stammt aus dem externen Informationsmodul **213** und weist gesammelte und verarbeitete externe Informationen auf, die beispielsweise, jedoch nicht im Sinne einer Einschränkung, automatisch oder manuell eingegebene Anlageinformationen, Betreiberanmerkungen, Anlagenenergieversorgungsparameter, wie z. B. Energiequalität, temporäre Änderung an Gerätearbeitspunkten und Umgebungsfaktoren beinhalten. Die Fehlerdiagnose kann beispielsweise, jedoch nicht im Sinne einer Einschränkung, solche allgemein bekannte statistische Techniken, wie z. B. den sequentiellen Wahrscheinlichkeitsverhältnistest (SPRT – Sequential Probability Ratio Test) beinhalten.

[0071] Fig. 15(A) und (B) stellen eine Probe von typischen Sensorrohmessungen in Fig. 15(A) und deren zugehörige Restfehler in Fig. 15(B) dar, wenn kein Fehler in dem System und in den Sensoren vorliegt. Unter diesen Umständen sind die Restfehler typischerweise um zwei Größenordnungen kleiner als die Rohdaten. Wir speisten dann eine große Schrittfunktion in die Sensormessung der fünften Variablen (ZT49) ein und erkannten, das die zugehörige Restgröße die größte Auswirkung zeigte, während die anderen Restgröße wesentlich kleinere Änderungen zeigten. Dieses ist in Fig. 16 veranschaulicht.

[0072] Um den Erkennungsvorgang zu automatisieren, schlagen wir eine Normierung der Restfehler R_i unter Verwendung des Mittelwertes der Rohdatenmessungen, d. h.:

$$E_i = \frac{R_i}{\overline{X}_i},$$

[0073] Wir können dann einen Gütefaktor, wie z. B.

$$FOM = \sqrt{\frac{1}{nm}\sum_{i=1}^{n}\sum_{j=1}^{m}\left(\frac{R_{ij}}{\overline{X}_i}\right)^2},$$

berechnen, um die Gesamtgröße der Restfehler zu bewerten. Falls der FOM kleiner als ein spezifizierter Schwellenwert ist, können wir sagen, dass keine Anomalien vorliegen. Ansonsten ist eine Anomalie erkannt. Wenn ein (prozentual) großer Restfehlerwert vorliegt, erkannten wir die Anomalie als einen Sensorfehler. Wenn alle Restfehler größer als die Bezugsgröße sind, aber in etwa gleichmäßig zu dem FOM beitragen, gibt es dann zwei Möglichkeiten:

(1) es liegt ein Systemfehler vor; oder

(2) das AANN ist für die Erzeugung der Restfehler nicht geeignet (d. h., das AANN wurde in einem anderen Bereich des Zustandsraums als demjenigen trainiert, aus welchem die momentanen Rohdaten extrahiert worden sind).

SENSORVALIDIERUNG FÜR UNTERSCHIEDLICHE BETRIEBSZUSTÄNDE

[0074] Wenn sich der Betriebszustand oder Modus, in welchem das System arbeitet, ändert, können sich die Eigenschaften des Systems dementsprechend ändern. Beispielsweise haben Gasturbinen Betriebsmodi, wie z. B. Grundlast, Teillast und Volllast. In jedem Modus verhält sich das System, wie durch das Systemausgangssignal (Leistung usw.) und seine Sensormesswerte (Temperatur, Druck, Schwingung usw.) erfasst, anders. In dem vorherigen Kapitel nutzten wird das AANN-Modell zur Durchführung einer Sensorvalidierung innerhalb eines bekannten Betriebsbereichs. Im Wesentlichen wurde ein AANN-Modell verwendet, um die Systemeigenschaften kenn zu lernen. Wenn sich der Betriebsbereich verändert, muss das zugrunde liegende AANN-Modell ebenfalls geändert (oder neu trainiert) werden.

[0075] Als ein Beispiel, und keineswegs im Sinne einer Einschränkung, werde angenommen, dass die überwachte Maschine ein Strahltriebwerk, wie z. B. ein Flugzeugtriebwerk GE90 ist, das bezüglich der Höhe (ALT), Umgebungstemperatur (Tamb) und Machzahl (Mach) überwacht wird. Ws wird beachtet, dass das Triebwerk in drei unterschiedlichen Betriebsbereichen arbeitet und dass es bekannt ist, wann Übergänge zwischen Betriebsbereichen erfolgen. Fig. 17 stellt das Beispiel dar, in welchem drei Betriebszustände als zweidimensionale Projektionen von Volumina in einem dreidimensionalen Raum mit den Achsen Höhe, Machzahl und Umgebungstemperatur dargestellt sind. Die Projektion der Volumina auf den zweidimensionalen Höhen-Umge-

bungstemperatur-Raum ist in Fig. 17 dargestellt. Die dargestellten zugehörigen Graphen repräsentieren die Projektionen der Volumina auf die drei Achsen von Höhe, Machzahl und Umgebungstemperatur. Die Kurve des Strahltriebwerksbetriebs in den, durch die und zwischen den Betriebskurven ist als Flughüllkurve oder FE bekannt. 1000 normale Betriebspunkte wurden zufällig aus jedem Betriebsbereich erzeugt. Für jeden erzeugten Betriebspunkt gibt es einen diesem zugehörigen neunwertigen Zustandsvektor.

[0076] Unter Verwendung dieses Datensatzes bauten wir drei 9-5-3-5-9 AANNs gemäß der in Fig. 13 dargestellten Architektur für die jeweiligen drei Betriebsbereiche auf. Während der Trainingsphase jedes AANN-Modells wurden 900 Datenpunkte verwendet. Die restlichen 100 Datenpunkte wurden für den Test reserviert. Fig. 18(A)–(C) stellen die Restfehler der AANN-Modelle bezüglich des Testsatzes aus unterschiedlichen Betriebsbereichen dar. Da das AANN1 in dem Betriebsbereich 1 trainiert wurde, aus dem Testsatz 1 entnommen wurde, sind die Restfehler in Fig. 18(A) klein. Dasselbe gilt für das AANN3 bezüglich des Testsatzes 3, wie in Fig. 18(B) dargestellt. Wenn jedoch das AANN1 an dem Testsatz 2 in Fig. 18(C) getestet wurde, welcher aus einem anderen Betriebsbereich stammt, waren die Restfehler typischerweise um eine oder zwei Größenordnungen höher als in dem vorherigen Fall.

[0077] Eine weitere Möglichkeit, mit unterschiedlichen Betriebsbereichen zurechtzukommen, besteht in dem Aufbau eines globalen Modells über alle Betriebsbereiche. Somit kann, wenn sich ein Betriebsbereich ändert, das globale Modell dazu genutzt werden, um das Verhalten des Systems zu erfassen. Jedoch ist aufgrund des Umstandes, dass das Modell über den gesamten Betriebsbereich aufgebaut wird, dieses bei der Erfassung der Eigenschaften des Systems in lokalen Bereichen weniger genau. Fig. 19(A)–(C) stellen die Restfehler eines globalen AANN-Modells bezüglich des Testsatzes von unterschiedlichen Betriebsbereichen dar. Da das globale AANN-Modell auf allen drei (3) lokalen Betriebsbereichen trainiert wurde, sind die Restfehler bezüglich des Testsatzes 2 (Fig. 19(C)) wesentlich kleiner als der eine in Fig. 18(C). Die Restfehler in den Fig. 19(A) und (B) sind jedoch größer als die in den Fig. 18(A) und (B).

[0078] Ein Aufbau lokaler Modelle ist einem Aufbau eines globalen Modells in Hinblick auf eine bessere Erfassung lokaler Systemeigenschaften besser, wenn die lokalen Betriebsbereiche identifiziert werden können.

FUZZY-ÜBERWACHUNGSMODELLE FÜR BETRIEBSZUSTANDSÜBERGÄNGE

[0079] Typischerweise wird ein Industrie-Anlagegut oder -System unter unterschiedlichen Bedingungen/Modi betrieben. Das System verhält sich entsprechend den unterschiedlichen Betriebszuständen unterschiedlich. Um Sensoreigenschaften unter unterschiedlichen Betriebszuständen besser zu repräsentieren, sind Mehrfachsensor-Validierungsmodelle erwünscht, um die Beziehung zwischen den Sensoren zu erfassen. Wie automatisch die Änderung von Betriebszuständen zu erkennen sind und das geeignete lokale Sensorvalidierungsmodell zu wählen ist, wird zu einen Problem.

[0080] Lokale Modelle können die Systemdynamik innerhalb ihrer spezifizierten Betriebsbereiche erfassen. Jedoch kann in einem Übergangsbereich keines der speziell angepassten lokalen Modelle die Dynamik des Systems genau erfassen. Somit überschreiten die während der Übergangsphase erzeugten Restfehler den Alarmierungsschwellenwert und verursachen positive Fehlalarme. Eine derzeit eingesetzte übliche Lösung dieses Problems besteht in dem Ignorieren der erzeugten Alarme, wenn bekannt ist, dass das System einen Übergang zwischen Betriebsbereichen ausführt. Der Nachteil dieses Lösungsansatzes ist die Unterbrechung der Systemüberwachung unter Verwendung lokaler Modelle und das Risiko, einige echte Fehleralarme zu übersehen, die während der Übergangsphase erzeugt werden.

[0081] Im Allgemeinen behandelt die Erfindung diese Probleme unter Verwendung eines Fuzzy-Überwachungsmodellmischers, um den Übergang zwischen Sensorvalidierungsmodellen auf der Basis von Betriebszustandsänderungen zu handhaben. Insbesondere verwenden wir Fuzzy-Logik (FL), um Regeln für ein Überwachungsmodell zur Kontrolle des Übergangs lokaler Modelle zu schreiben, wenn sich ein Betriebsbereich verändert. Es gibt eine Menge Literatur bezüglich Fuzzy-Logik und deren Anwendung in Regelbasierender Annäherungsschlußfolgerung. Sprachliche ”FALLS-DANN”-Regeln mit geeigneten mathematischen Konstrukten werden in das Überwachungsmodell eingebaut, um über die Eignung lokaler Modelle für vorliegende Betriebszustände zu entscheiden. Der Eignungsgrad unterschiedlicher lokaler Modelle wird berücksichtigt, wenn der Beitrag von Restfehlern aus lokalen Modellen zu dem vereinten Ausgangssignal gewichtet wird. Ein GE90 ”Cycledeck”-Simulator wurde verwendet, um Daten für die Demonstration zu erzeugen. Experimentelle Ergebnisse haben gezeigt, dass mit dem den Übergang von lokalen Sensorvalidierungsmodellen kontrollierenden Überwachungsmodell Sensorschätzwerte genauer und robuster gegenüber Betriebszustandsänderungen sind.

[0082] Die Fuzzy-Logik gibt uns eine Sprache mit Syntax und lokaler Semantik, mittels welcher wir eine qualitative Kenntnis bezüglich des zu lösenden Problems übertragen können. Insbesondere erlaubt uns FL, linguistische Variablen zur Modellierung dynamischer Systeme zu verwenden. Diese Variablen nehmen Fuzzy-Werte an, die durch ein "Label" oder eine Kennzeichnung (einen aus der Syntax erzeugten Satz) und eine Bedeutung (eine Zugehörigkeitsfunktion, die durch eine lokale semantische Prozedur bestimmt ist) gekennzeichnet sind. Die Bedeutung einer linguistischen Variablen kann als eine elastische Einschränkung für ihren Wert interpretiert werden. Diese Einschränkungen werden durch Fuzzy-Inferenzoperationen auf der Basis des verallgemeinerten Modus-Ponens weitergegeben. Dieser Schlussfolgerungsmechanismus mit seinen Interpolationseigenschaften gibt FL eine Robustheit in Bezug auf Veränderungen der Systemparameter, Störungen, usw., was eine von den Haupteigenschaften von FL ist.

[0083] Die häufigste Definition einer Fuzzy-Regelbasis R ist die disjunktive Interpretation und ist in den meisten Fuzzy-Regler-Anwendungen zu finden als:

$$R = \bigcup_{i=1}^{m} r_i = \bigcup_{i=1}^{m} (\overline{X}_i \rightarrow Y_i)$$

wobei R aus einer Disjunktion von m Regeln zusammengesetzt ist. Jede Regel definiert eine Zuordnung zwischen einem Fuzzy-Zustandsvektor und einer zugehörigen Fuzzy-Aktion. Der kartesische Produktoperator repräsentiert jede Regel.

[0084] Die Inferenzmaschine eines FC kann als ein Parallel-Vorwärts-Verkettungsbilder definiert sein, der mit Fuzzy-Produktionsregeln arbeitet. Ein Eingangsvektor $\overline{I}$ wird mit jedem n-dimensionalen Zustandsvektor $\overline{X}_i$ abgestimmt (d. h., linke Seite (LHS) der Regel ($\overline{X}_i \rightarrow Y_i$). Der Übereinstimmungsgrad λ_i zeigt den Grad an, bis zu welchem die Regelausgabe auf die Gesamt-FC-Ausgabe angewendet werden kann. Die hauptsächlichen Inferenzprobleme für den FC sind: die Definition der Fuzzy-Prädikat-Evaluation, welche üblicherweise ein Möglichkeitsmaß ist; die LHS-Evaluierung, welche typischerweise eine Dreiecks-Norm ist; die Schlussfolgerungsabtrennung, welche normalerweise eine Dreiecks-Norm oder ein Materialimplikationsoperator ist; und die Regelausgabeaggregation, welche üblicherweise eine Dreiecks-Conorm für die disjunktive Interpretation der Regelbasis oder eine Dreiecksnorm für den konjunktiven Fall ist. Unter üblicherweise verwendeten Annahmen können wir die Ausgabe aus dem Fuzzy-System beschreiben als

$$\mu_Y(y) = \mathrm{Max}_{i=1}^{m} \{\mathrm{Min}[\lambda_i, \mu_{Y_i}(y)]\}$$

wobei λ_i der Anwendbarkeitsgrad der Regel r_i ist

$\lambda_i = \mathrm{Min}_{j=1}^{n} \Pi(X_{i,j}, I_j)$

und $\Pi(X_{i,j}, I_j)$ das Möglichkeitsmaß ist, das die Übereinstimmung zwischen der Bezugszustandsvariablen repräsentiert. Diese drei Gleichungen beschreiben den generalisierten Modus-Ponens, welcher die Basis für die Interpretation eines Fuzzy-Regelsatzes ist.

[0085] Wir verwendeten dieselben drei lokalen AANN-Modelle, die bezüglich der vorstehend beschriebenen drei lokalen Betriebsbereiche aufgebaut waren. Der Betriebsbereich des simulierten Modells wurde allmählich von der Flughüllkurve FE 1 zu FE 3 entlang der in **Fig. 20(A)** dargestellten Kurve verschoben. **Fig. 20(A)** und (B) zeugen die unterschiedlichen Darstellungen des Übergangs von Betriebsbereichen.

[0086] Eine Fuzzy-Zugehörigkeitsfunktion wird entwickelt, welche die Achsen verwendet, die die Volumina der Betriebszustände definieren. Dies ist in den **Fig. 21(A)** und (B) dargestellt, welche die Werte der Flughüllkurvenvariablen darstellen, wenn das simulierte System in unterschiedliche Betriebsbereiche übergeht. Auf der linken Seite der Figur können wir die Definitionen der Zugehörigkeitsfunktionen für "Niedrig", "Mittel" und "Hoch" der Flughüllkurvenvariablen sehen.

[0087] Dann können wir einen Fuzzy-Regelsatz von drei Fuzzy-Regeln spezifizieren, wie bspw. den in der Tabelle 1 beschriebenen, welche die Anwendbarkeit lokaler Modelle in unterschiedlichen in Fuzzy-Termen definierten Betriebsbereichen beschreiben.

ZUSTANDS-VARIABLE		HÖHE	UMGEB.-TEMP.	MACH #	MODELL #
REGELN	R1	HOCH	HOCH	HOCH	AANN-1
	R2	HOCH	MITTEL	MITTEL	AANN-2
	R3	MITTEL	NIEDRIG	NIEDRIG	AANN-3

Tabelle 1: Fuzzy-Regelsatz, der die Modellanwendbarkeit in unterschiedlichen Betriebsbereichen beschreibt.

[0088] In Fig. 22 zeigen wir das Schema zur Verwendung eines Fuzzy-Überwachungsmodells zum Steuern des Umschaltens lokaler Modelle und zur Sicherstellung der Glätte bzw. Homogenität von Restfehlern durch Interpolation bei Flugbereichsübergängen. Auf der linken Seite der Figur sehen wir Sensorrohmesswerte, die den drei lokalen AANN-Modellen präsentiert werden, um jeweils die Restfehler zu erzeugen. Die Zustandsvariablen, die Betriebsbereiche definieren, werden durch den Fuzzy-Regelsatz geführt, um die Anwendbarkeit jedes lokalen AANN-Modells zu ermitteln. Die normalierte Anwendbarkeit jedes Modells wird dann dazu genutzt, einen gewichteten Mittelwert der Restfehler aus jedem individuellen Modell zu bilden, um einen integrierten Gesamtrestwert zu erzeugen.

[0089] In den Fig. 23(A) und (B) stellen wir Beispiele von Restfehlern zwischen aktuellen Sensormesswerten und Schätzwerten aus dem lokalen Modell AANN_1 bzw. AANN_2 dar, wenn der Flugbereich entlang der in Fig. 20(B) definierten Kurve übergeht. Natürlich kann ein lokales Modell nur die Restfehler innerhalb des Flugbereichs minimieren, für welchen es aufgebaut und trainiert wurde. Das Fuzzy-Überwachungsmodell kann jedoch die Überlegenheit einzelner lokaler Modelle in den Flugbereichen, für welche sie aufgebaut wurden, ausnutzen und lokale Modelle miteinander vermischen, um die Homogenität der Restfehler während eines Übergangs zwischen Betriebsbereichen, wie es in Fig. 23(C) zu sehen ist, sicherzustellen.

UNIVARIATE ÄNDERUNGSERKENNUNG

[0090] Bis zu diesem Punkt basierten alle vorstehend beschriebenen Techniken auf der Annahme, dass mehrere als eine einzige gemessene Variable pro Anlagegut vorliegen. Es gibt jedoch eine große Vielzahl von im Feld eingesetzten Anlagegütern, wie z. B. Fabrikergänzungs-Anlagegüter, welche typischerweise nur eine einzige Variable pro Anlagegegenstand zum Überwachen ihres Verhaltens haben. Für diese Anlagegüter gelten multivariate Änderungserkennungs- und Zustandsüberwachungs-Verfahren nicht. Um insbesondere diesen Fall mit nur einem einzigen Sensor pro Anlage zu behandeln, haben wir eine Familie von Techniken entwickelt, welche die Hotelling T^2 Statistik, den Wahrscheinlichkeitsverhältnistest, die Berechnung von Exzess-Kurtosis und Rang-Permutationstransformationsverfahren für univariate Änderungserkennung enthalten. Jedoch können gekoppelte Familien dieser Anlagegüter als eine Gruppe unter Verwendung multivariater Techniken überwacht werden.

RANG-PERMUTATIONSTRANSFORMATION (RPT)

[0091] Die Rang-Permutationstransformation (RPT) ist auf Zeitreihen zugeschnitten. Dieser allgemeine Ansatz zur Fehlerdetektion in einer Zeitreihe, der hierin verwendet wird, besteht in dem Vergleich einer Teststatistik für die ”Ist”-Daten (einige wenige neuere Datenpunkte) mit den ”älteren” Daten (einer typischerweise größeren Anzahl von Punkten vor den ”Ist”-Daten), eventuell mit einem Puffer nicht verwendeter Punkte dazwischen, um Unterschiede deutlicher zu machen, wie es in Fig. 24 dargestellt ist.

[0092] Die Verwendung von Rängen statt von Absolutwerten löst eine Anzahl von Problemen. Erstens wird die problematische Auswirkung von Ausreißern erheblich vermindert. Die Rangtransformation wird mit großem Vorteil in der nicht-parametrischen Statistik eingesetzt. Die Rangverteilung für eine vorgegebene Anzahl von Daten kann im Voraus berechnet werden, was die Implementation zum Ablaufzeitpunkt sehr schnell macht (eine wichtiger Gesichtspunkt für in Echtzeit ablaufenden eingebettete Anwendungen, die nur wenig einzusparende Rechenleistung haben).

[0093] Das Prinzip der Verwendung zufälliger Permutationen der Daten, um eine genaue oder nahezu genaue Wahrscheinlichkeit des Auftretens zu entwickeln, ist in den Fig. 25(A)–(C) dargestellt. Fig. 25(A) stellt die Originaldaten dar. Die Nullhypothese besteht darin, dass die letzten fünf Sternchenpunkte aus demselben Beitrag wie die vorhergehenden runden Punkte entnommen sind. Wenn die Nullhypothese zutrifft, sollte dann

eine Statistik (sagen wir der Mittelwert), die aus den Sternpunkten berechnet wird, etwa dieselbe sein wie die Statistik für beliebige fünf Punkte, die zufällig aus all den Daten ausgewählt werden. Wenn wir dieselben Daten beibehalten und zufällig die Markierungen (Stern oder runder Punkt) permutieren, und die "Mittelwert von fünf Sternpunkten"-Statistik mehrere Male berechnen, erhalten wir die in **Fig. 25(C)** dargestellte Verteilung. Diese Prozedur legt nahe, dass beliebige fünf Punkte, die zufällig aus allen Punkten ausgewählt werden, einen Mittelwert so groß wie den der ursprünglichen fünf Punkte nur während 7,2 Prozent der Zeit haben. In ähnlicher Weise kann jeder Abtastwert von Daten mit einem anderen Abtastwert (z. B. unter Verwendung des vorstehend dargestellten Neu-gegen -Alt-Lösungsansatzes) verglichen werden, und eine (bis zu einer willkürlichen Anzahl von signifikanten Stellen) genaue Wahrscheinlichkeit dafür, dass sich die Abtastwerte von einer beliebigen Teststatistik unterscheiden, berechnet werden.

[0094] Durch Umsetzen beider Ideen (die Verwendung des Rangs statt der Rohdaten und von Permutationsverteilungen) kann die "Rangpermutationstransformation" (RPT) verwendet werden, um eine grobe, sich schlecht verhaltende Zeitreihe in Merkmale (Entscheidungen) zu transformieren, welche über Musteränderungen in Daten informieren. Um die RPT zu berechnen, muss man zuerst eine kleine Anzahl von Punkten als den "Ist"-Satz und eine (typischerweise größere) Anzahl von Punkten als den "alten" Satz definieren. Die zwei Datensätze werden zuerst verknüpft, und die Ränge der kombinierten Daten werden berechnet. Die Summe der Ränge für die ursprüngliche Anordnung (die Teststatistik) für die "Ist"-Daten wird berechnet. Insbesondere werden die Datenmarkierungen ("Ist/alt") zufällig permutiert und die Teststatistik berechnet; dieser Schritt wird viele Male (z. B. 5000 mal) wiederholt. Der Wert der Teststatistik für die ursprüngliche Anordnung der Daten wird mit den mittels der Permutationen erzeugten Werten verglichen, und die Wahrscheinlichkeit des zufälligen Auftretens der ursprünglichen Ordnung berechnet. Der Wert der $\log_{10}$-Wahrscheinlichkeit (die Ausgabe der RPT) wird dazu genutzt, um seltene Ereignisse zu betonen. Beispielsweise bedeutet der Wert von $10(\log_{10}10^{10})$, dass die Seltenheit des Ereignisses 1 unter 10 Milliarden beträgt. Der Algorithmus für die Berechnung der RPT ist auf dem Fachgebiet allgemein bekannt.

[0095] Die Rangpermutationstransformation wurde auf die Falldaten angewendet, um eine Teststatistik zu erzeugen. Wenn die Teststatistik einen vorbestimmten Schwellenwert überschritt, wurde eine Veränderung gemeldet.

WAHRSCHEINLICHKEITSVERHÄLTNISTEST (LRT)

[0096] Der Wahrscheinlichkeitsverhältnistest untersucht die Änderung von Verteilungen in sequentiellen Daten. Deshalb ist er gut für eine Änderungserkennung in einer Zeitreihe gut geeignet und wurde bereits allgemein ausgeführt. Die allgemeine Struktur des Problems für LRT wird wie folgt angegeben.

[0097] Es werde eine skalare Zeitreihe, x(t), betrachtet, wobei t der aktuelle Zeitindex ist. Der aktuelle Zeitindex t unterteilt die Zeitreihe in zwei Untersätze

$$x_1(t) = \{x(i)\}_{i=t-n_1, \ldots, t-1}$$

(unmittelbare Vergangenheit) und

$$x_2(t) = \{x(i)\}_{i=t, \ldots, t+n_2-1}$$

(unmittelbare Zukunft). Jeder Teilsatz erfüllt eine gewisse Wahrscheinlichkeitsdichtefunktion (pdf), $p_1(\theta_1)$ bzw. $p_2(\theta_2)$. Es sei t ein bestimmter Zeitpunkt, dann ist der LRT ein Neyman-Pearson-Test zur Unterscheidung zwischen zwei Hypothesen:

$$\begin{cases} H_0 : p_2 = p_1 & \text{(keine Änderung tritt auf)} \\ H_1 : p_2 \neq p_1 & \text{(Änderung tritt auf)} \end{cases}$$

[0098] Der Parameter der pdf vor der Änderung oder nach der Änderung ist nicht bekannt. Außerdem ist der Änderungszeitpunkt, die Zeit T, nicht bekannt. Trotzdem kann das log-Wahrscheinlichkeitsverhältnis zwischen den postulierten Hypothesen H_1, dass eine Änderung zu einem Zeitpunkt T auftritt, und den Null-Hypothesen H_0, dass keine Änderung in n-Abtastwerten auftritt, gebildet werden:

$$LR = \ln\left(\frac{p_1(x_{T-n_1}^{T-1}; \theta_1') \cdot p_2(x_T^{T+n_2-1}; \theta_2)}{p_1(x_{T-n_1}^{T+n_2-1}; \theta_1)}\right)$$

wobei $n = n_1 + n_2$. Man beachte, dass der Unterschied zwischen θ_1' und θ_1 bedeutet, dass sie über unterschiedliche Zeiten hinweg geschätzt sind. Da die tatsächlichen Parametersätze θ_1, θ_1' und θ_2 unbekannt sind, kann der Maximalwahrscheinlichkeits-(ML)-Ansatz verwendet werden, um mit deren Schätzwerten $\hat{\theta}_1$, $\hat{\theta}_1$ und $\hat{\theta}_2$ zu beginnen, welche direkt aus den dortigen entsprechenden Bereichen erhalten werden: $\{t - n_1, ..., t + n_2 - 1\}$, $\{t - n_1, ..., t - 1\}$ und $\{t, ..., t + n_2 - 1\}$. Wenn die sich ergebende Wahrscheinlichkeit

$$LR\ |\hat{\theta}_1,\hat{\theta}_1',\hat{\theta}_2$$

einen bestimmten vordefinierten Schwellenwert überschreitet, wird eine Änderung angezeigt.

HOTELLINGSCHE T^2-STATISTIK

[0099] Die Hotelling T^2 Statistik ist eine Verallgemeinerung der Student t Statistik, die in einem multivariaten Hypothesetest verwendet wird. Eine Möglichkeit, sie für das univariate Änderungserkennungproblem einzusetzen, besteht in der Einführung von Zeitverzögerungen an der univariaten Sensormessung. D. h., das univariate Rohsignal x(t) wird um m Abtastpunkte verzögert, um x(t – m) zu erzeugen. In ähnlicher Weise kann x(t – m) um weitere m-Datenpunkte verzögert werden, um x(t – 2m) zu erzeugen. Auf diese Weise kann man eine pseudo-multivariate Zeitreihe erzeugen, wie z. B. [x(t), x(t – m), x(t – 2m)]', um die Hotelling T^2 Berechnung wie vorstehend auszuführen.

[0100] In Fig. 26 zeigen wir univariate Zeitreihendaten, bei denen eine Verschiebungsänderung an der roten Linie auftritt. PRT, LRT und eine Anzahl von Varianten von Hotelling T^2 Techniken werden individuell verwendet um zu erkennen, wo die Änderung auftrat. Alle diese Techniken können die Änderungen mit vernünftigen Verzögerungen erkennen, obwohl die Alarmschwellen, bei welchen jede Technik ausgelöst wird, unterschiedlich sind. Im Vergleich zu RPT und LRT kann die Hotelling T^2 Statistik eine Änderung nicht so schnell erkennen wie diese, aber ihr Verhalten ist sehr konsistent, wenn verschiedene Arten von Änderungen getestet werden. Diese Eigenschaft der Hotelling T^2 Statistik macht sie zu einem potentiell guten Kandidaten für die Verwendung in dem realen Überwachungssystem.

[0101] Wie vorstehend beschrieben, nutzt die Erfindung die Hotelling T^2 Statistik-Technik, um die Normalität von multivariaten Daten abzuschätzen. Die Hotelling'sche T^2 Statistik verwendet den statistischen Abstand, der die multivariate Varianz-Kovarianz-Matrix verkörpert. Daher erkennt sie sowohl eine mittlere Verschiebung als auch Gegenbeziehungen zwischen den erfassten Variablen.

[0102] Diese Beschreibung verwendet Beispiele, um die Erfindung, einschließlich der besten Ausführungsart, zu offenbaren und um auch jedem Fachmann auf diesem Gebiet zu ermöglichen, die Erfindung auszuführen und zu nutzen. Der patentierbare Schutzumfang der Erfindung ist durch die Ansprüche definiert und kann weitere Beispiele umfassen, die für den Fachmann auf diesem Gebiet ersichtlich sind. Derartige weitere Beispiele sollen in dem Schutzumfang der Erfindung enthalten sein, sofern sie strukturelle Elemente besitzen, die sich nicht von dem Wortsinn der Ansprüche unterscheiden, oder wenn sie äquivalente strukturelle Elemente mit unwesentlichen Änderungen gegenüber dem Wortsinn der Ansprüche enthalten.

[0103] Ein Verfahren zur modernen Zustandsüberwachung eines Anlagegutsystems beinhaltet die Verwendung von mehreren autoassoziativen neuronalen Netzen, um Schätzwerte von Istwerten zu bestimmen, die von wenigstens einem Sensor in wenigstens einem von den mehreren Betriebsbereichen gemessen werden; die Ermittlung eines Restfehlers zwischen den geschätzten Messwerten und den Istwerten, die von dem wenigstens einem Sensor aus jedem der mehreren auto-assoziativen neuronalen Netzwerke gemessen werden; und eine Kombination der Restfehler durch Verwendung eines Fuzzy-Überwachungsmodellmischers; eine Durchführung einer Fehlerdiagnose an den kombinierten Restfehlern; und eine Ermittlung einer Betriebsänderung des Anlagegutsystems durch Analyse der kombinierten Restfehler. Ein Alarm wird, falls erforderlich, erzeugt. Ein intelligentes Sensorsystem **10** enthält eine integrierte Verarbeitungseinheit **11** zum Durchführen des Verfahrens gemäß der Erfindung.

TEILELISTE

Bezugszeichenliste

10 Intelligentes Sensorsystem
11 integrierte Verarbeitungseinheit
12 Intelligenter Sensor
14 Kabel

16 Eingangsanschluss
18 Anzeige- und Alarmeinheit
20 Ausgangsanschluss
22 lokale Steuerung
24 drahtlose Kommunikationseinheit
26 periphere Verarbeitungsvorrichtung
28 Energiequelle
30 Eingangsanschluss

Patentansprüche

1. Verfahren zur modernen Zustandsüberwachung eines Anlagegutsystems, wobei das Verfahren die Schritte aufweist:
Aufteilen eines Betriebsraums eines Anlagegutsystems in mehrere Betriebsbereiche;
Verwenden mehrerer auto-assoziativer neuronaler Netzwerke (AANNs) zum Ermitteln von Schätzwerten von Istwerten, die von dem wenigstens einen Sensor in wenigstens einem der mehreren Betriebsbereiche gemessen werden;
Ermitteln eines Restfehlers zwischen den geschätzten Messwerten und den von dem wenigstens einen Sensor aus jedem von den mehreren auto-assoziativen neuronalen Netzwerken gemessenen Istwerten;
Kombinieren der Restfehler unter Verwendung eines Fuzzy-Überwachungsmodellmischers;
Durchführen einer Fehlerdiagnose an den kombinierten Restfehlern;
Ermitteln einer Änderung des Betriebs des Anlagegutsystems durch Analyse der kombinierten Restfehler; und
Erzeugen eines Alarms, wenn eine Betriebsänderung des Anlagegutsystems ermittelt worden ist.

2. Verfahren nach Anspruch 1, wobei das AANN verborgene Knoten des tan-Sigmoid-(tansig)-Typs aufweist.

3. Verfahren nach Anspruch 1, wobei das AANN eine zentrale Flaschenhalsschicht mit eingebetteten Lineartransformationsfunktionen aufweist.

4. Verfahren nach Anspruch 1, wobei der Alarmierungsschritt die Verteilung einer Meldung über ein Informationstransportmedium aufweist, das aus der Gruppe ausgewählt ist, zu der ein elektrisches Kabel, eine Energieversorgungsleitung, ein Intranet, das Internet und eine drahtlose Übertragung gehören.

5. Verfahren nach Anspruch 1, wobei der Ermittlungsschritt ausgeführt wird, wenn das Anlagegutsystem einen Übergang zwischen zwei von den mehreren Betriebsbereichen ausführt.

6. Verfahren nach Anspruch 1, wobei der Alarmierungsschritt ausgeführt wird, wenn das Anlagegutsystem einen Übergang zwischen zwei von den mehreren Betriebsbereichen ausführt.

7. Verfahren nach Anspruch 1, wobei der Ermittlungsschritt ausgeführt wird, wenn das Anlagegutsystem in einem von den mehreren Betriebsbereichen arbeitet.

8. Verfahren nach Anspruch 1, wobei der Alarmierungsschritt ausgeführt wird, wenn das Anlagegutsystem in einem von den mehreren Betriebsbereichen arbeitet.

9. Verfahren nach Anspruch 1, wobei der Fuzzy-Überwachungsmodellmischer ein globales Modell über die mehreren Betriebsbereiche des Anlagegutsystems hinweg implementiert.

10. Verfahren nach Anspruch 1, wobei der wenigstens eine Sensor einen intelligenten Sensor aufweist.

11. Verfahren nach Anspruch 10, wobei der intelligente Sensor mit einem intelligenten Sensorsystem verbunden ist.

12. Verfahren nach Anspruch 11, wobei das intelligente Sensorsystem eine integrierte Verarbeitungseinheit zur modernen Zustandsüberwachung des Anlagegutsystems aufweist.

13. Intelligentes Sensorsystem (**10**), aufweisend:
einen intelligenten Sensor (**12**) zur Überwachung eines Betriebszustandes eines Anlagegutsystems, wobei der intelligente Sensor mit einem Eingangsanschluss (**16**) über ein Kabel (**14**) verbunden ist; und

eine integrierte Verarbeitungseinheit (**11**) zur modernen Zustandsüberwachung des Anlagegutsystems unter Anwendung des Verfahrens nach Anspruch 1.

14. System nach Anspruch 13, welches ferner eine drahtlose Kommunikationseinheit (**24**) aufweist, um drahtlos Signale aus dem intelligenten Sensorsystem (**10**) zu einer peripheren Verarbeitungsvorrichtung zu übertragen.

15. System nach Anspruch 13, welches ferner eine Anzeige- und Alarmeinheit (**18**) zum Anzeigen von Berechnungsergebnissen von der Verarbeitungseinheit (**11**) aufweist.

Es folgen 34 Blatt Zeichnungen

Anhängende Zeichnungen

GE P 2587

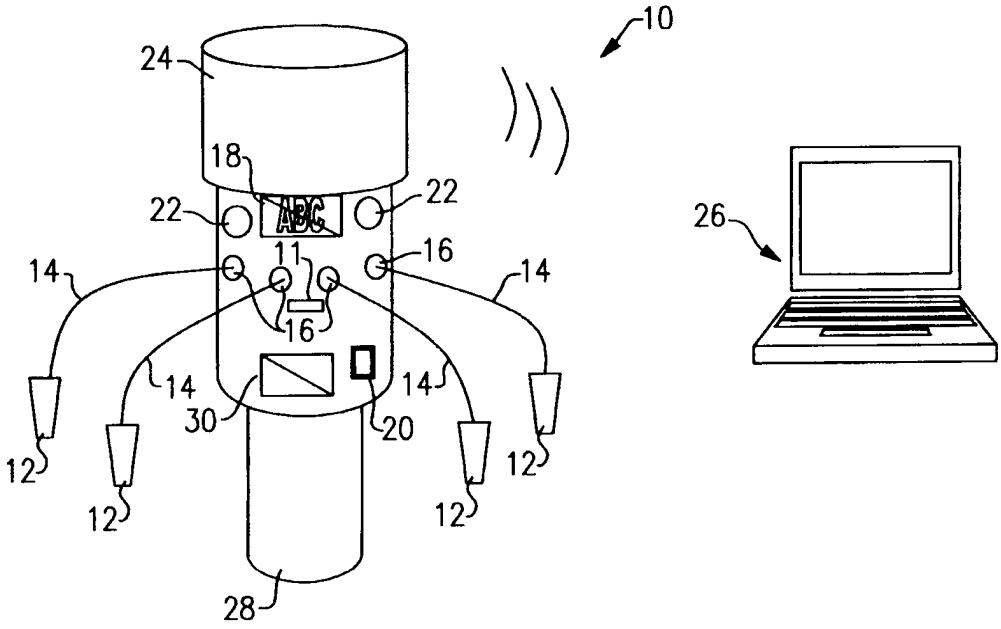


FIG.1

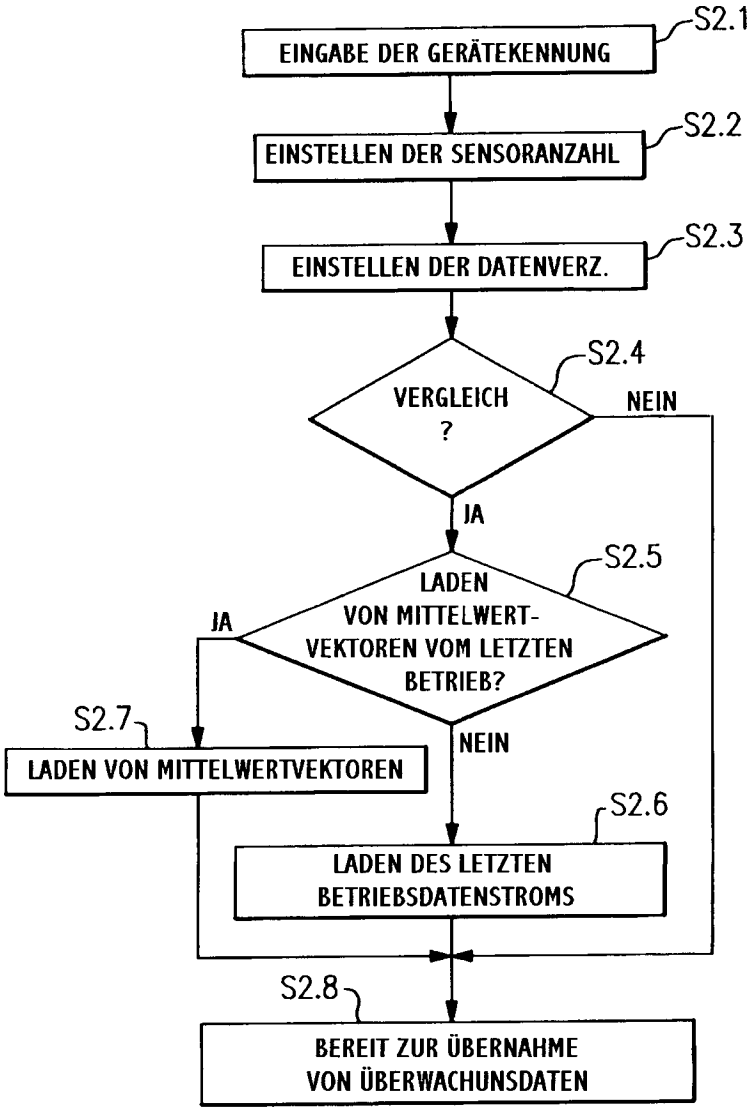

S2.1
EINGABE DER GERÄTEKENNUNG
S2.2
EINSTELLEN DER SENSORANZAHL
S2.3
EINSTELLEN DER DATENVERZ.
S2.4
VERGLEICH ?
NEIN
JA
S2.5
LADEN VON MITTELWERT-VEKTOREN VOM LETZTEN BETRIEB?
JA
NEIN
S2.7
LADEN VON MITTELWERTVEKTOREN
S2.6
LADEN DES LETZTEN BETRIEBSDATENSTROMS
S2.8
BEREIT ZUR ÜBERNAHME VON ÜBERWACHUNSDATEN

FIG.2

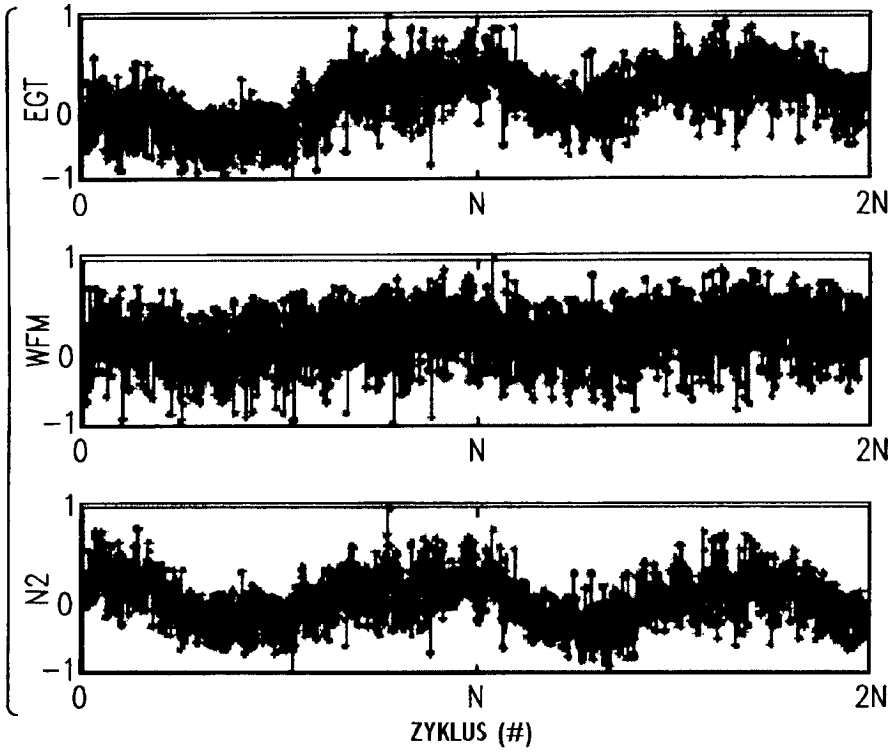

EGT
WFM
N2
1
0
−1
0
N
2N
ZYKLUS (#)

FIG.3A

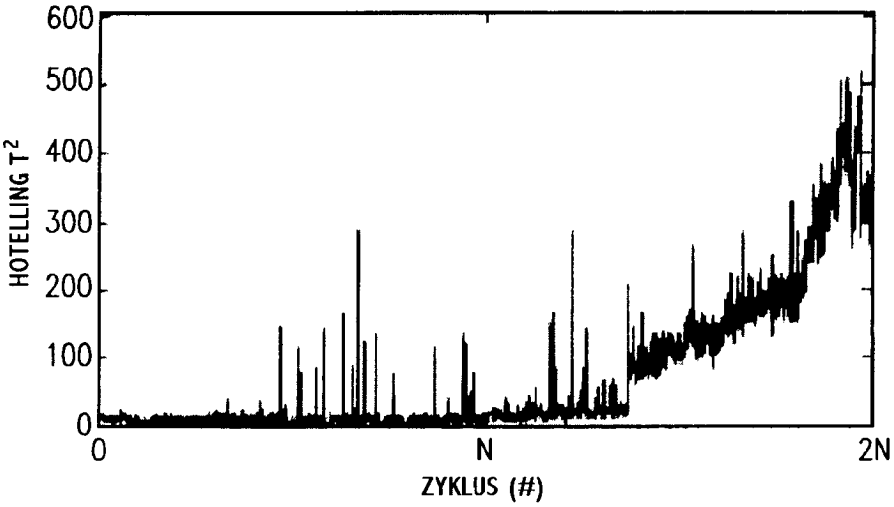

HOTELLING T²
600
500
400
300
200
100
0
0
N
2N
ZYKLUS (#)

FIG.3B

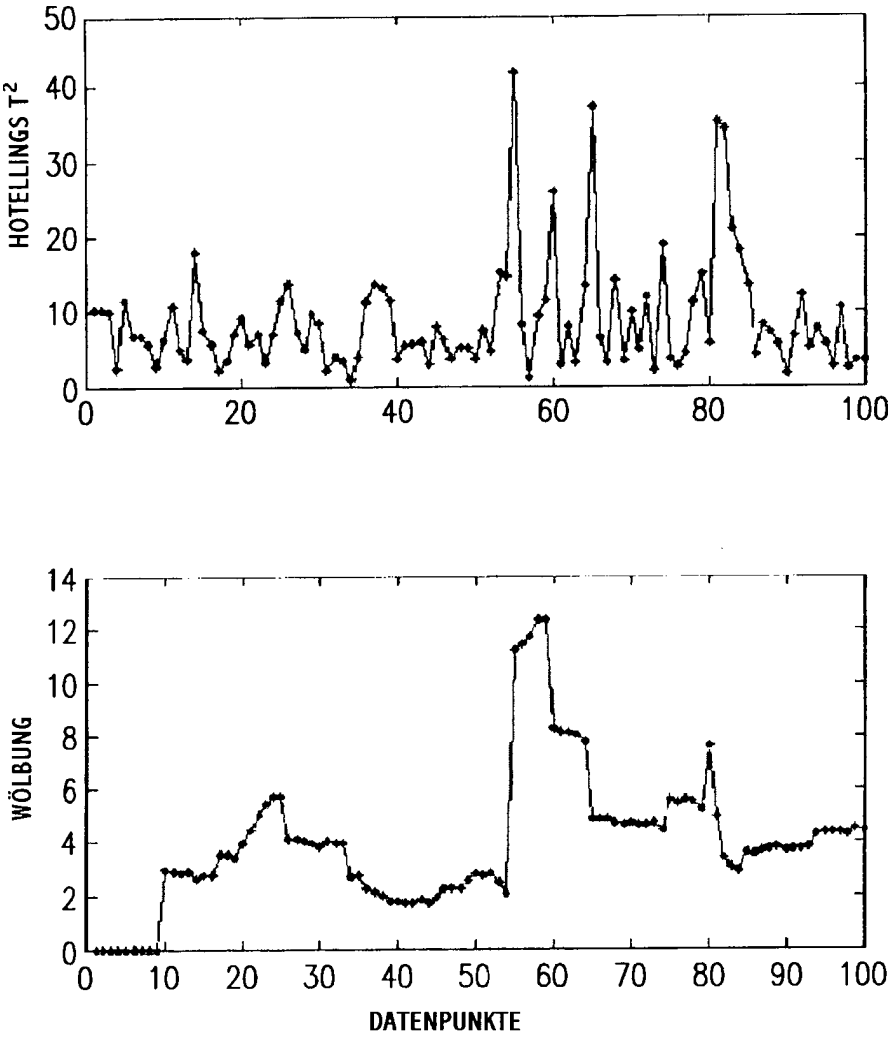

HOTELLINGS T²
0
10
20
30
40
50
0
20
40
60
80
100
WÖLBUNG
0
2
4
6
8
10
12
14
0
10
20
30
40
50
60
70
80
90
100
DATENPUNKTE

FIG.4

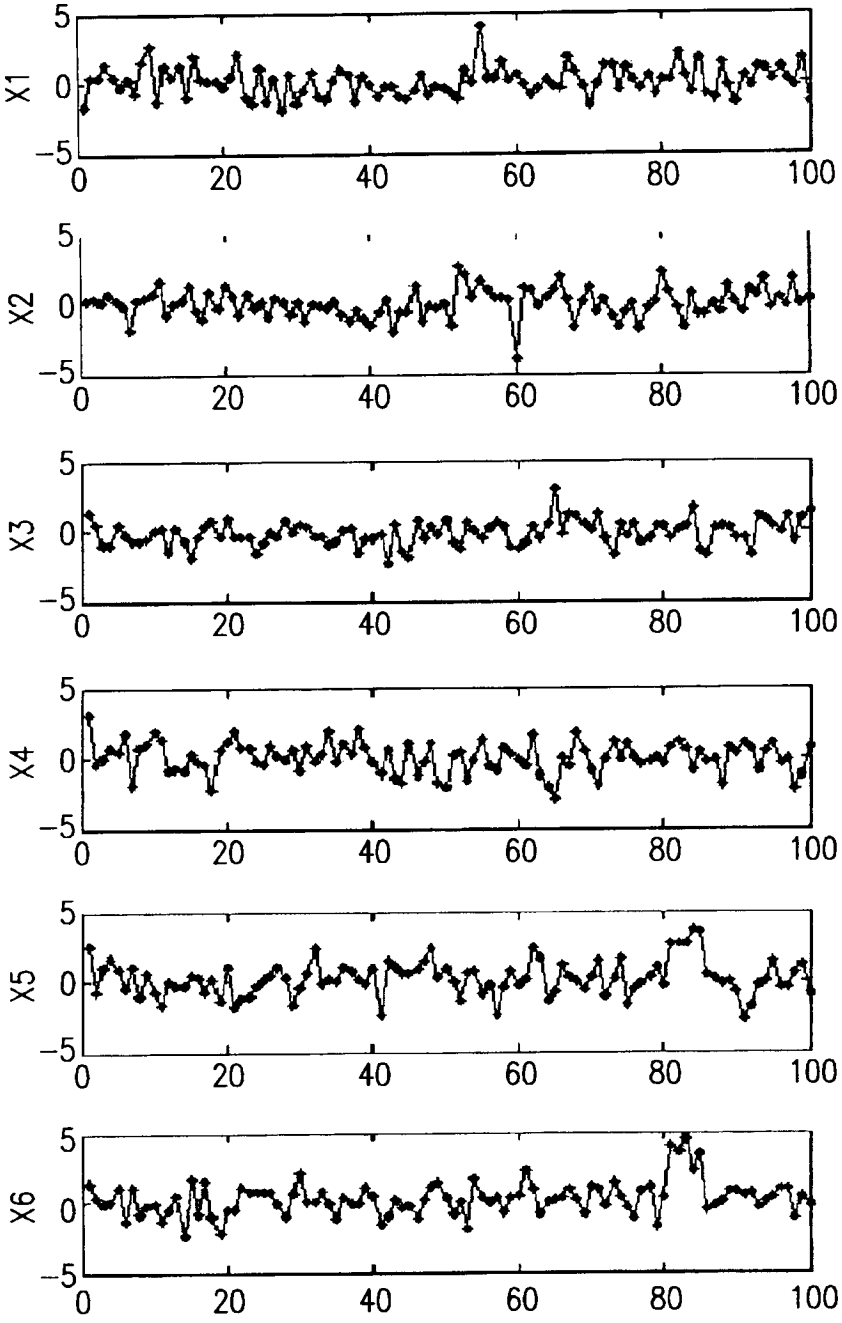


FIG.5

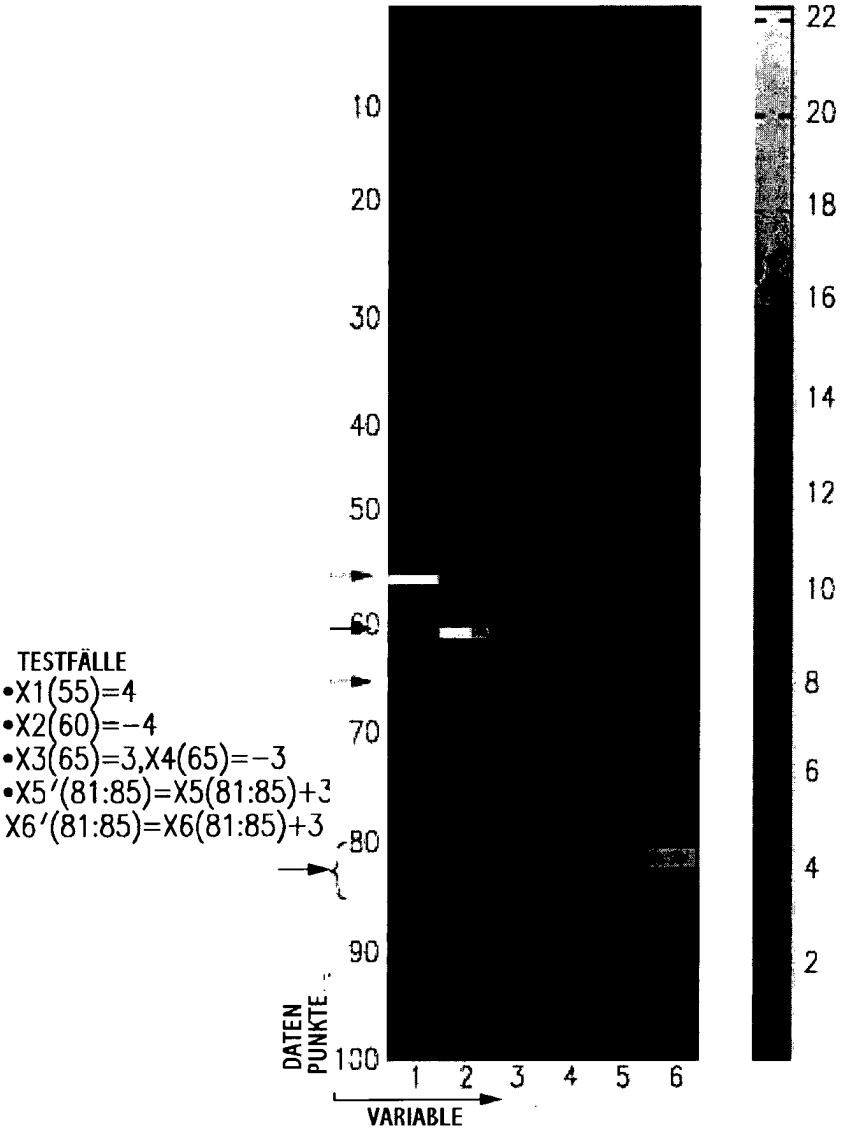

TESTFÄLLE
•X1(55)=4
•X2(60)=−4
•X3(65)=3,X4(65)=−3
•X5′(81:85)=X5(81:85)+3
X6′(81:85)=X6(81:85)+3
10
20
30
40
50
60
70
80
90
100
DATEN PUNKTE
1
2
3
4
5
6
VARIABLE
22
20
18
16
14
12
10
8
6
4
2

FIG.6

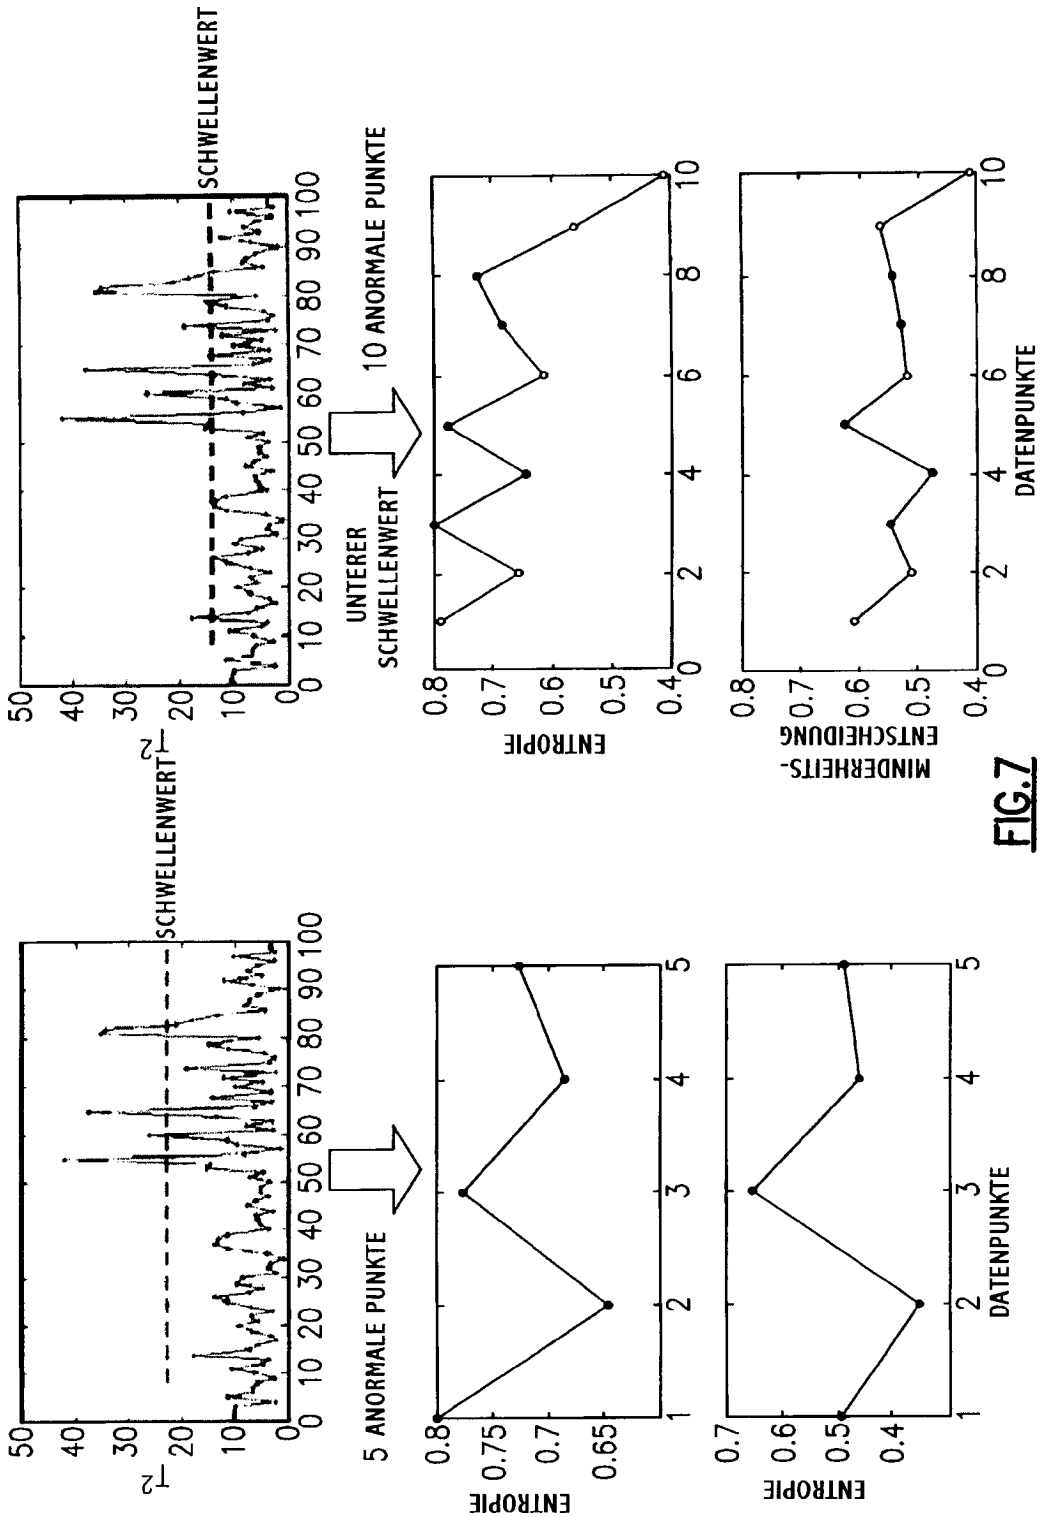
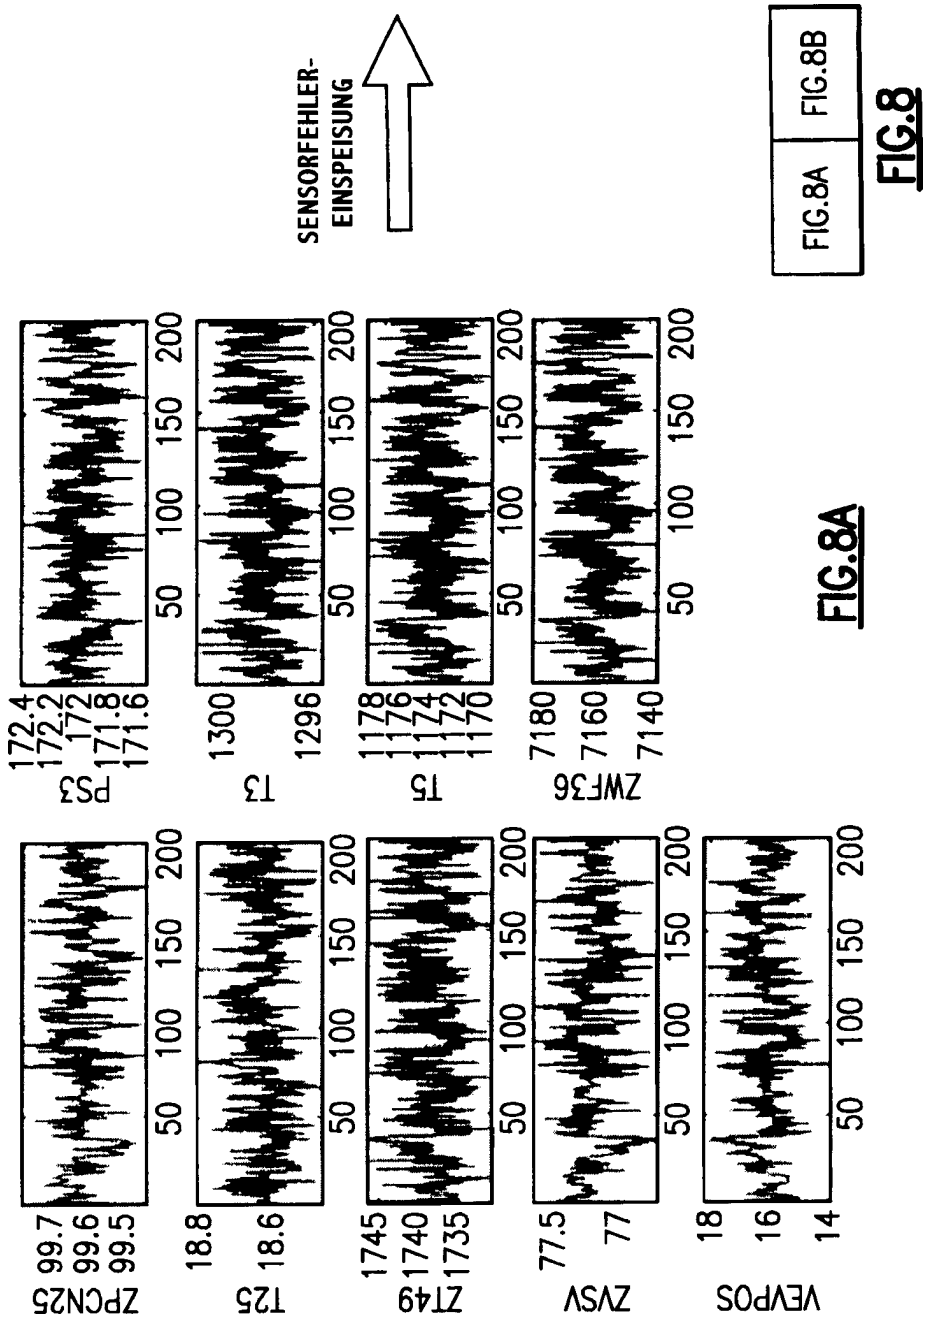

SCHWELLENWERT
T^2
0 10 20 30 40 50 60 70 80 90 100
10 ANORMALE PUNKTE
UNTERER SCHWELLENWERT
ENTROPIE
MINDERHEITS-ENTSCHEIDUNG
DATENPUNKTE
5 ANORMALE PUNKTE

FIG.7


SENSORFEHLER-
EINSPEISUNG
FIG.8A
FIG.8B
FIG.8
VEVPOS
ZVSV
ZT49
T25
ZPCN25
ZWF36
T5
T3
PS3

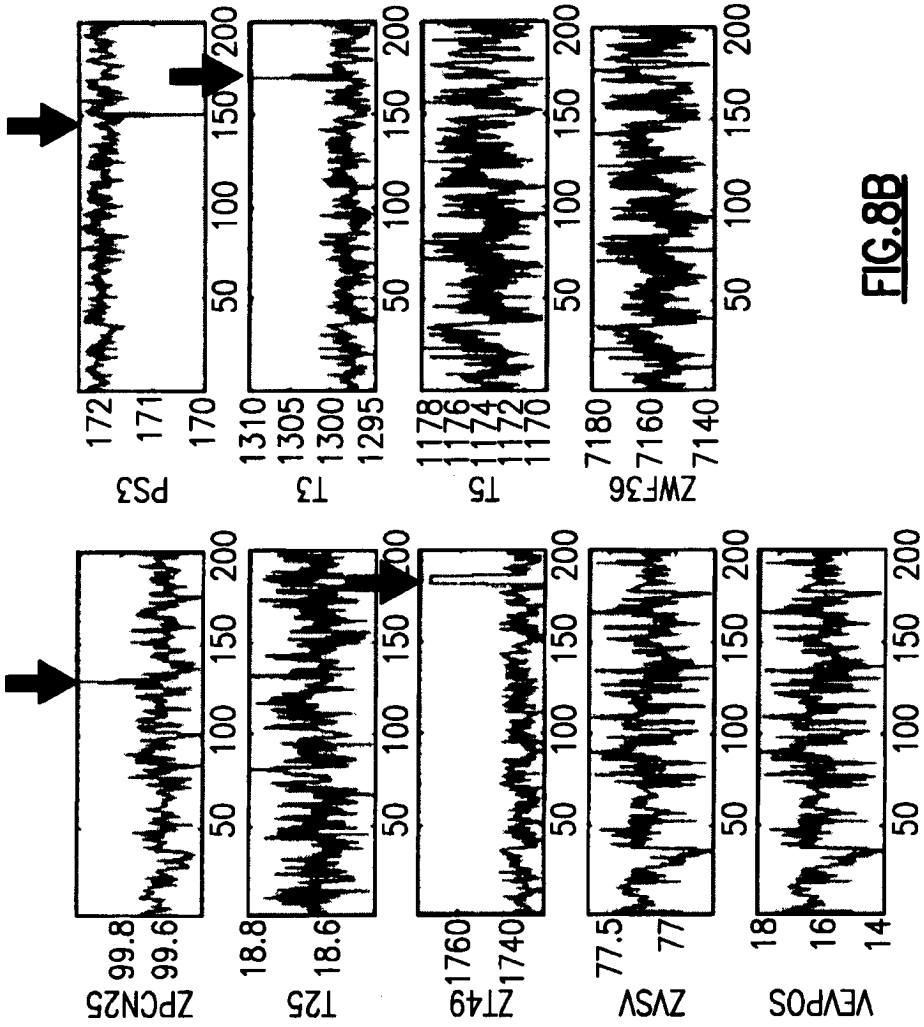


FIG.8B

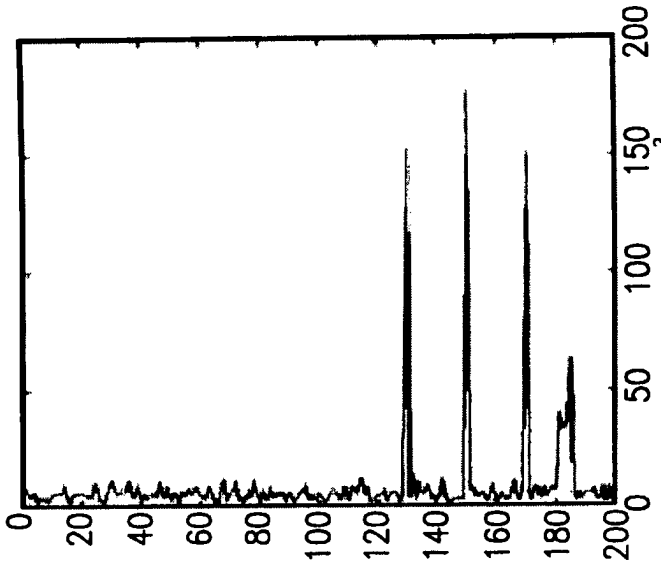

0
20
40
60
80
100
120
140
160
180
200
0
50
100
150
200
HOTELLINGS T²

FIG.9(B)

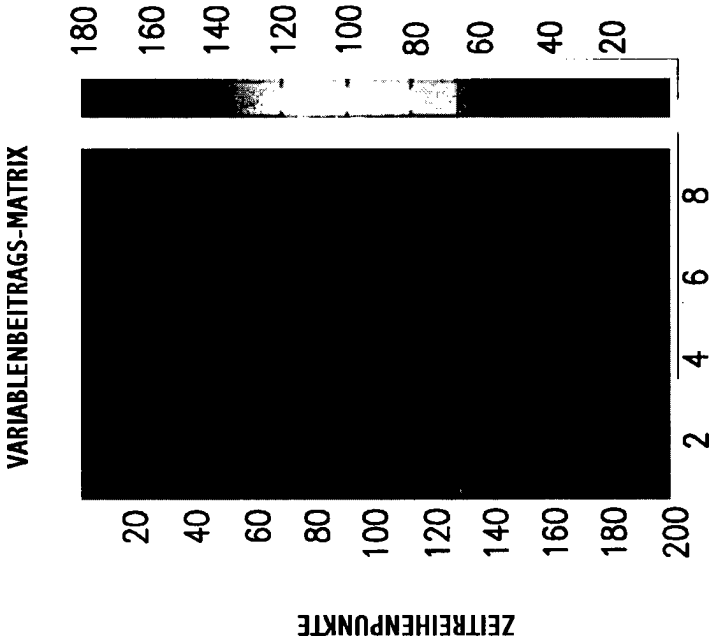

VARIABLENBEITRAGS-MATRIX
180
160
140
120
100
80
60
40
20
2
4
6
8
VARIABLE
20
40
60
80
100
120
140
160
180
200
ZEITREIHENPUNKTE

FIG.9(A)

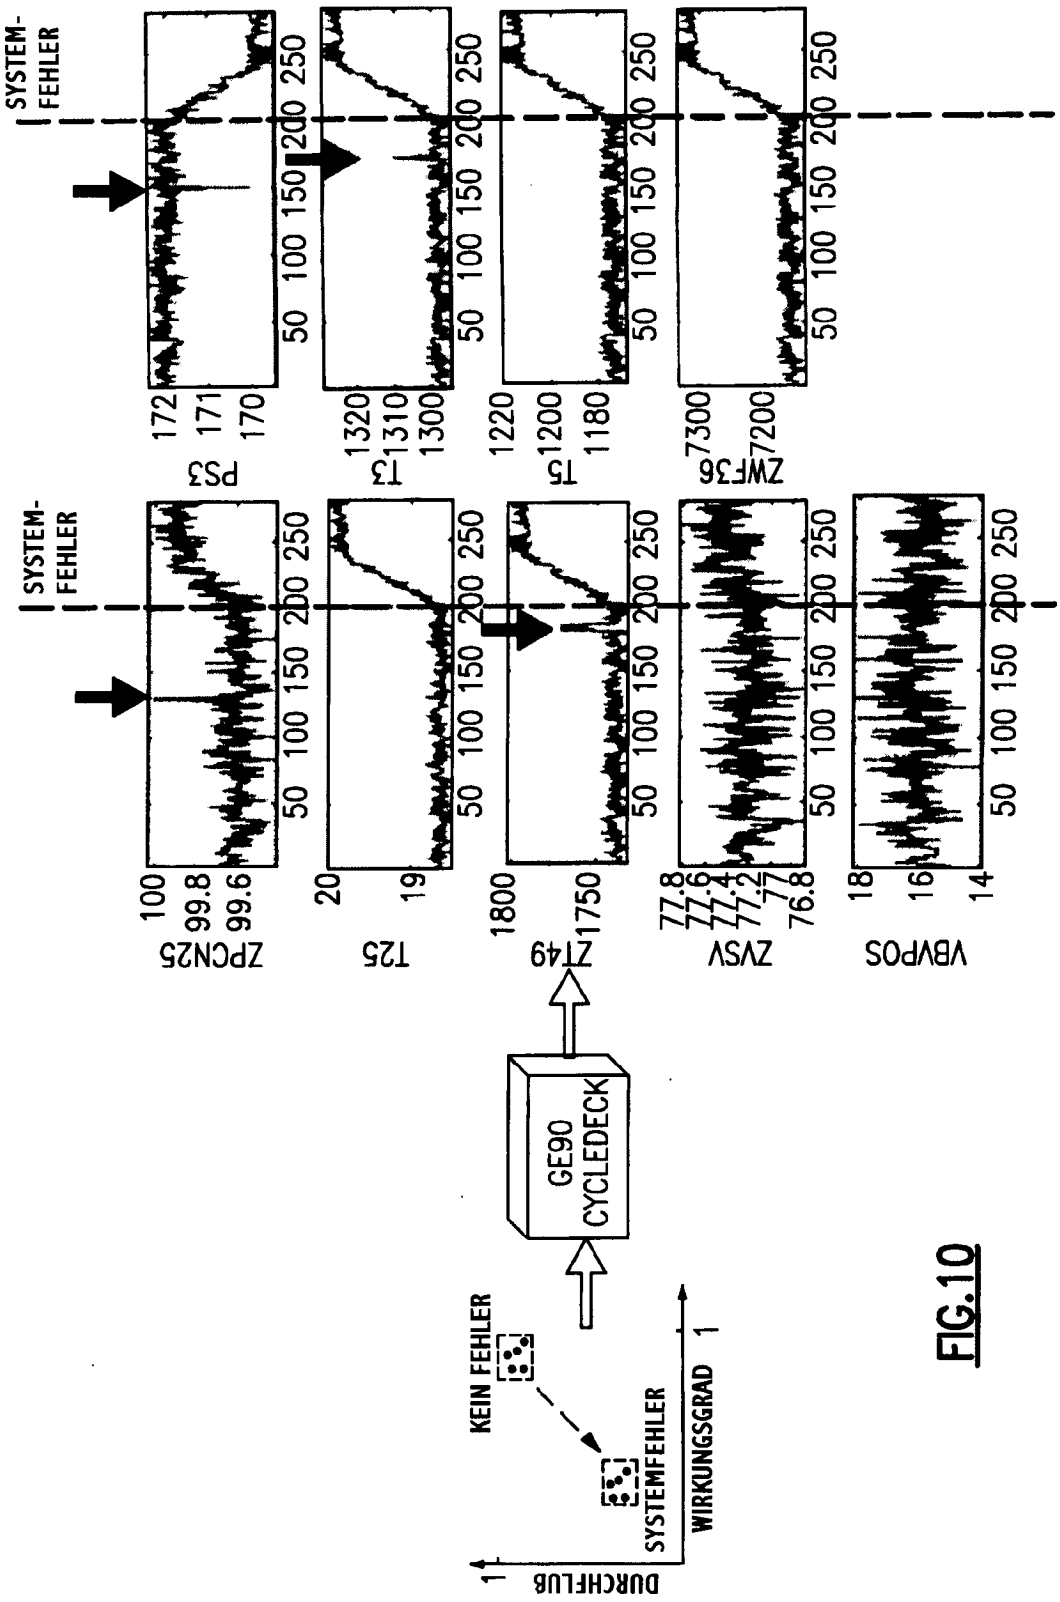

SYSTEM-FEHLER
PS3
T3
T5
ZWF36
ZPCN25
T25
ZT49
ZVSV
VBVPOS
GE90 CYCLEDECK
KEIN FEHLER
SYSTEMFEHLER
DURCHFLUß
WIRKUNGSGRAD

FIG.10

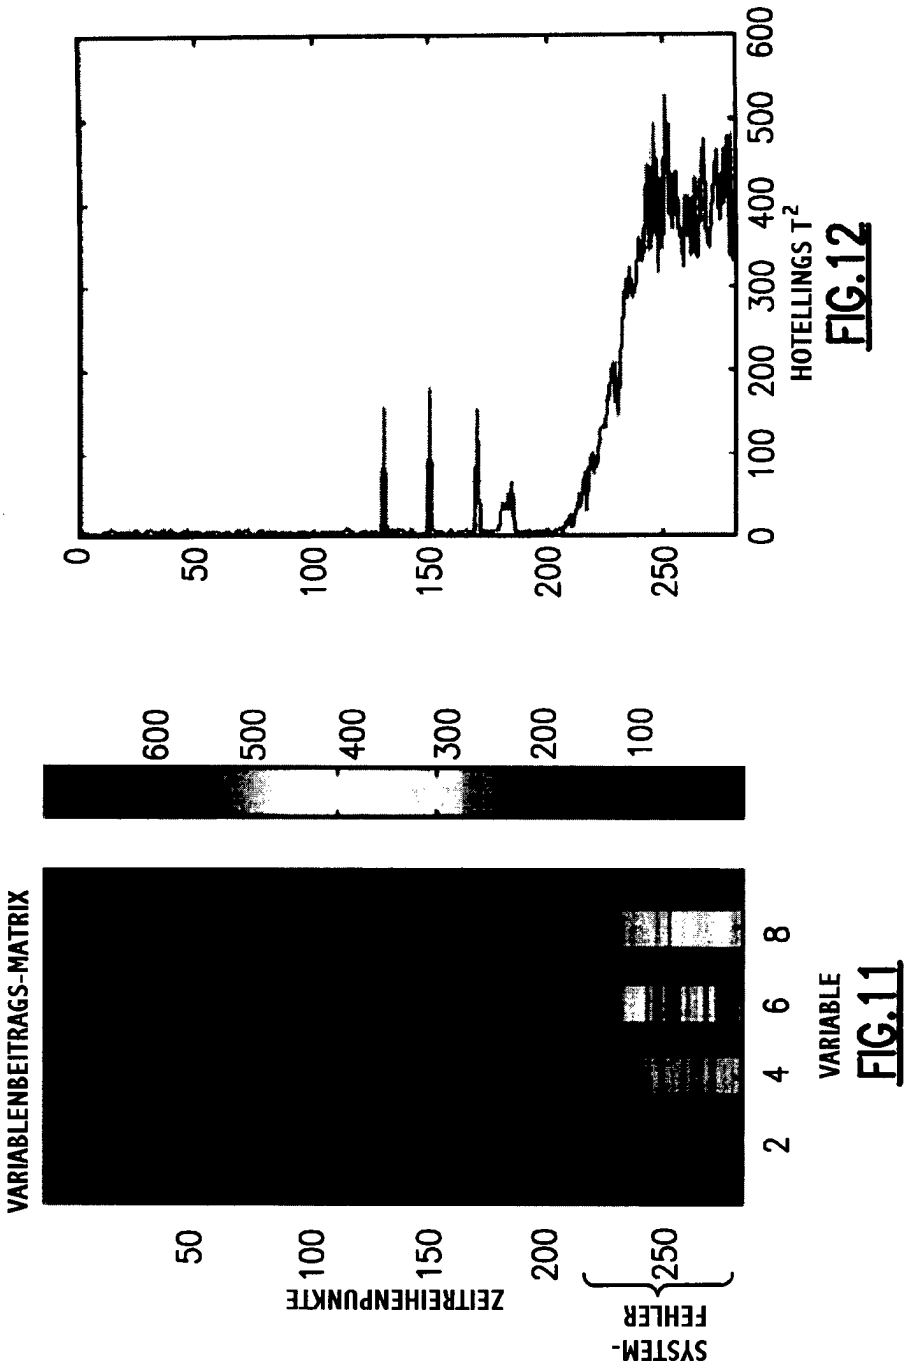

VARIABLENBEITRAGS-MATRIX
ZEITREIHENPUNKTE
SYSTEM-FEHLER
VARIABLE
HOTELLINGS T²

FIG.11

FIG.12

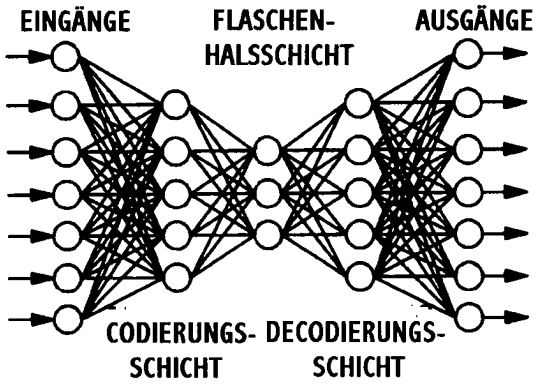

EINGÄNGE
FLASCHEN-
HALSSCHICHT
AUSGÄNGE
CODIERUNGS-
SCHICHT
DECODIERUNGS-
SCHICHT

FIG.13

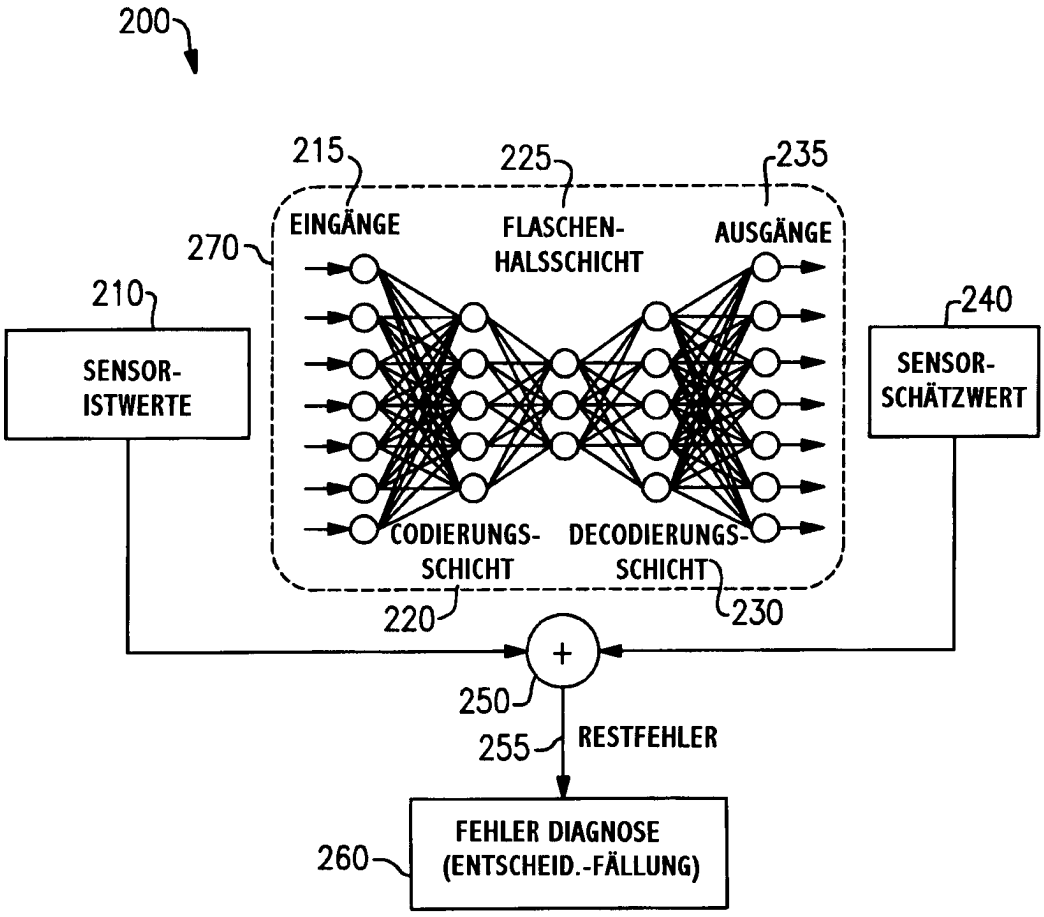

200
215
225
235
EINGÄNGE
FLASCHEN-
HALSSCHICHT
AUSGÄNGE
270
210
240
SENSOR-
ISTWERTE
SENSOR-
SCHÄTZWERT
CODIERUNGS-
SCHICHT
DECODIERUNGS-
SCHICHT
220
230
+
250
255
RESTFEHLER
FEHLER DIAGNOSE
(ENTSCHEID.-FÄLLUNG)
260

FIG.14

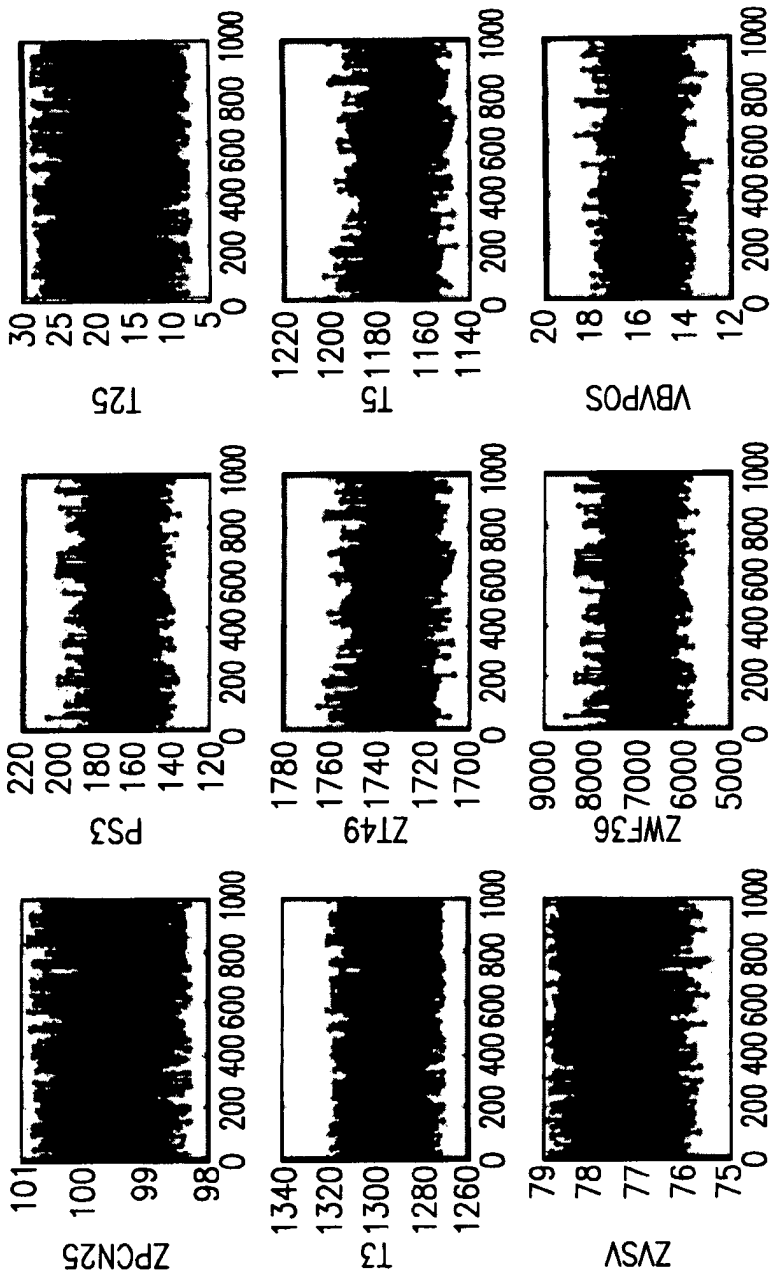

ZPCN25
T3
ZVSV
PS3
ZT49
ZWF36
T25
T5
VBVP0S
0 200 400 600 800 1000

FIG.15(A)

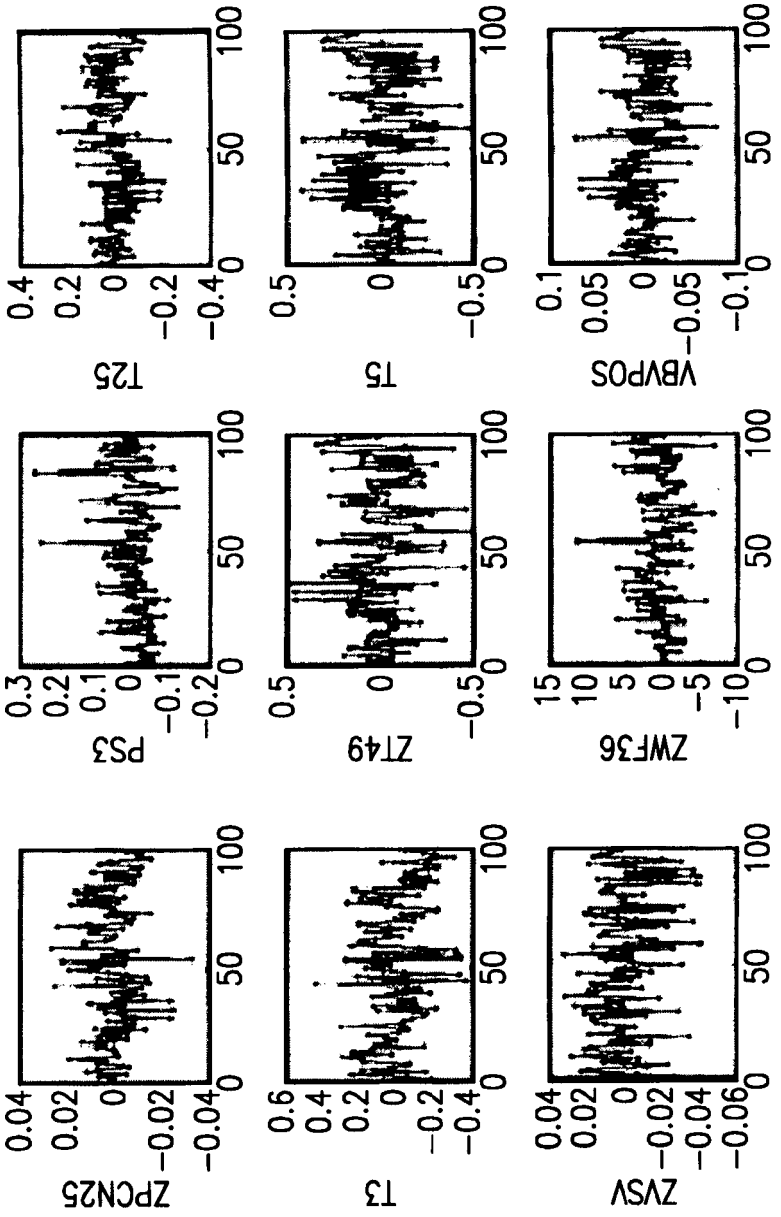


FIG.15(B)

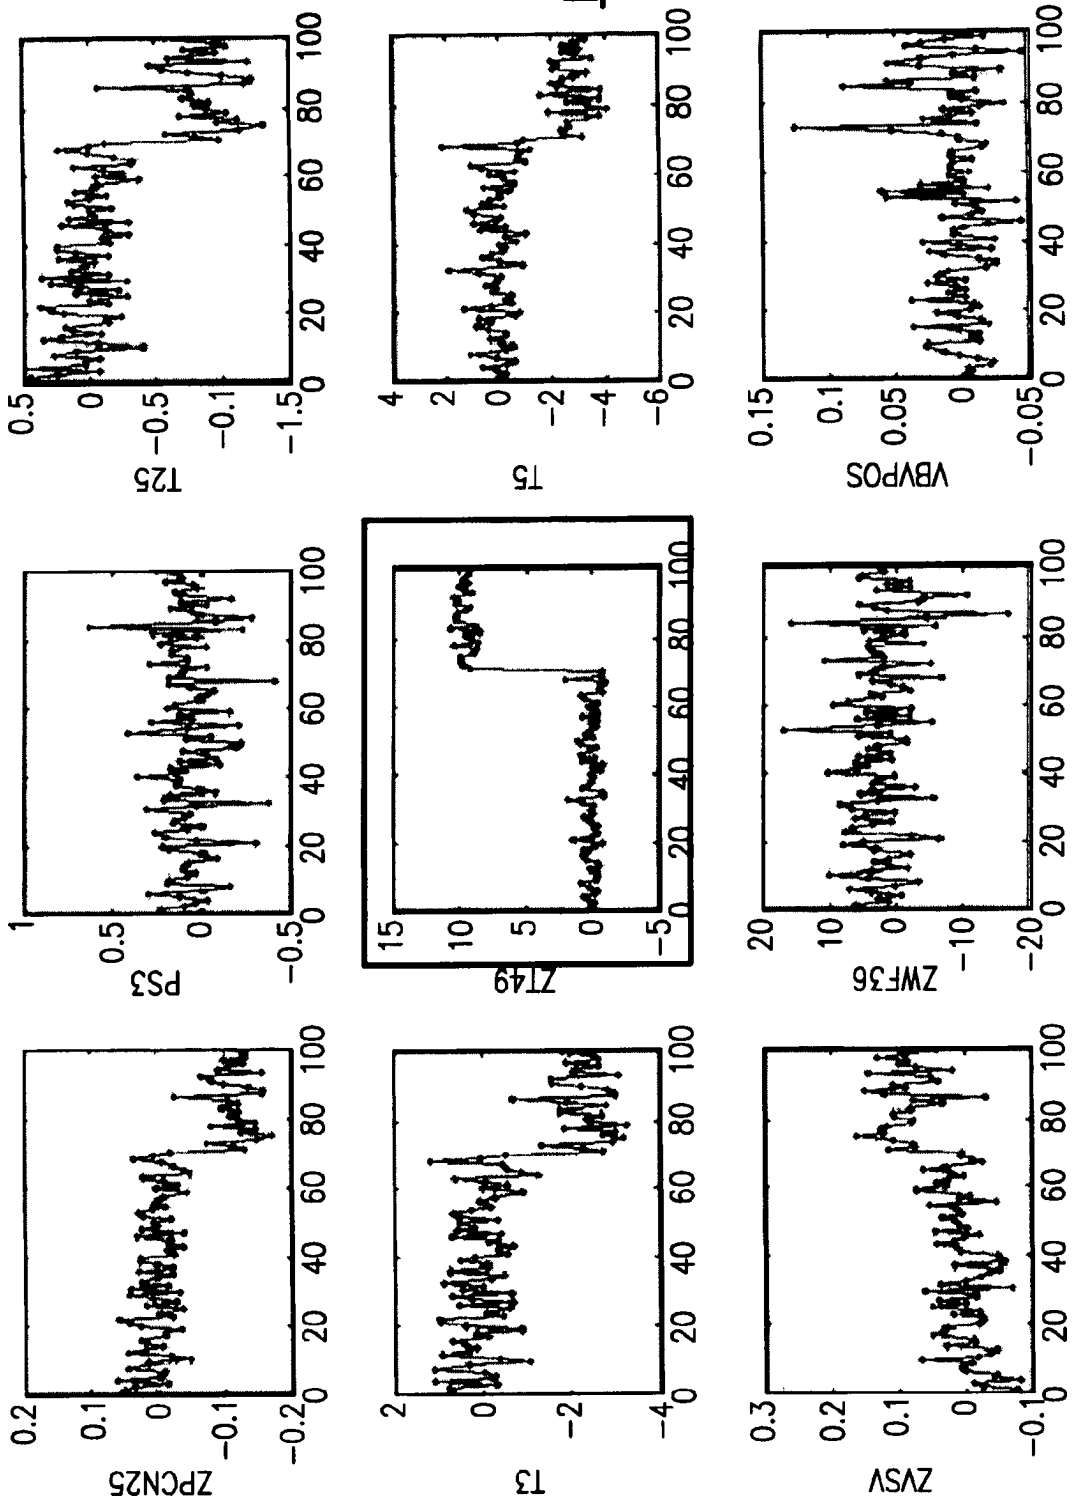


FIG.16

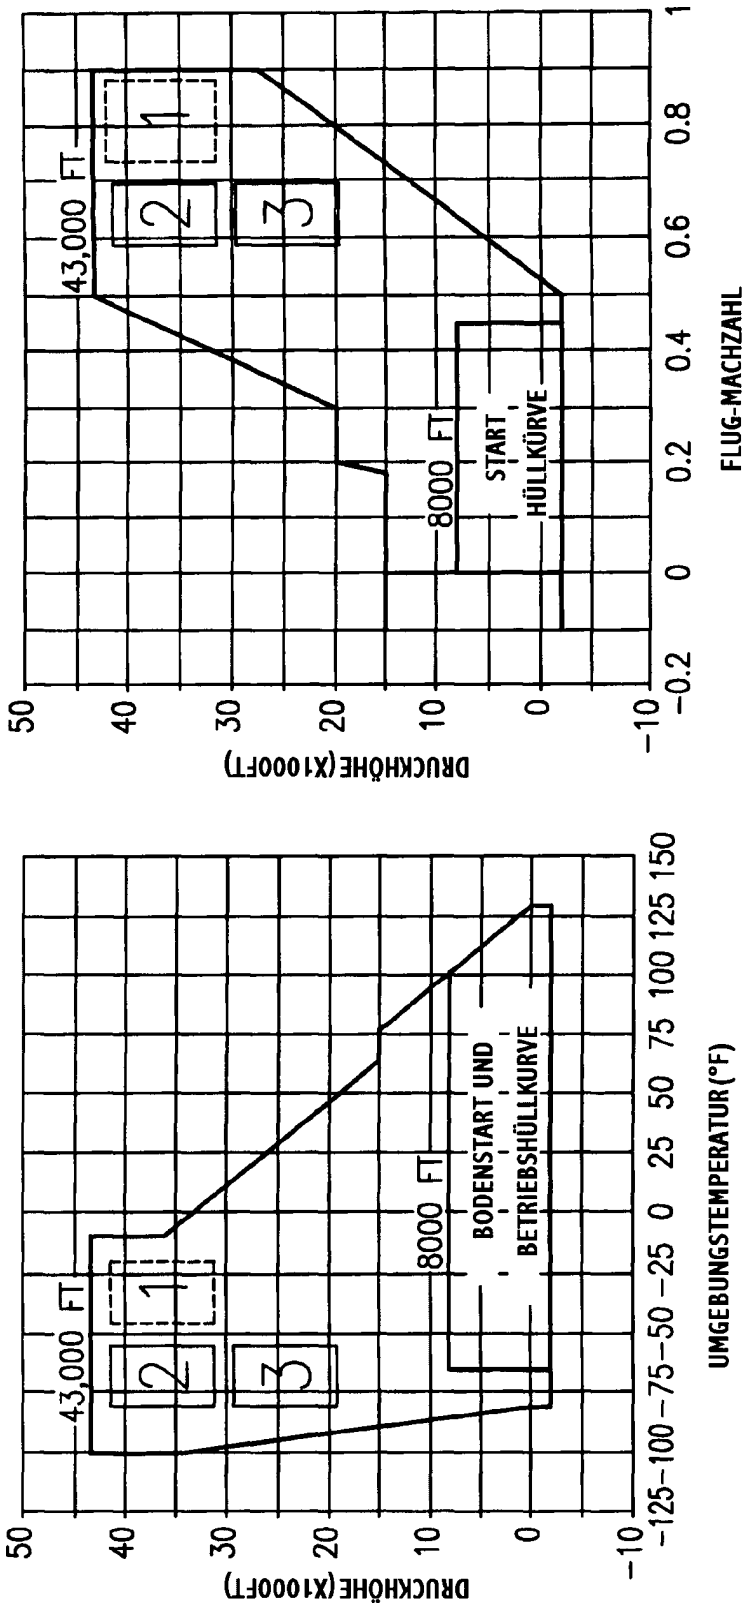

DRUCKHÖHE (X1000FT)
50
40
30
20
10
0
−10
43,000 FT
1
2
3
8000 FT
START-
HÜLLKÜRVE
−0.2
0
0.2
0.4
0.6
0.8
1
FLUG-MACHZAHL
DRUCKHÖHE (X1000FT)
50
40
30
20
10
0
−10
43,000 FT
1
2
3
8000 FT
BODENSTART UND
BETRIEBSHÜLLKURVE
−125 −100 −75 −50 −25 0 25 50 75 100 125 150
UMGEBUNGSTEMPERATUR (°F)

FIG.17

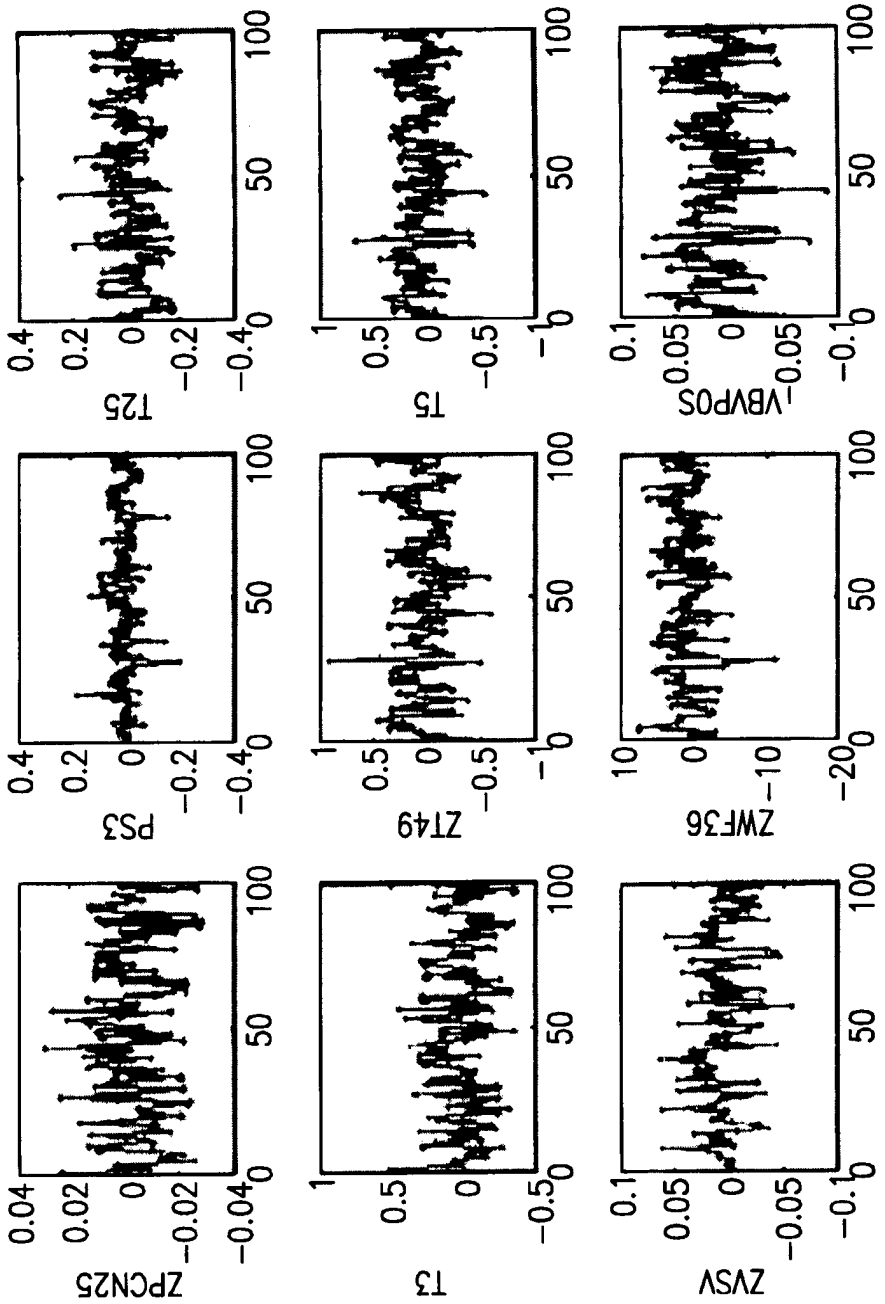


FIG.18(A)

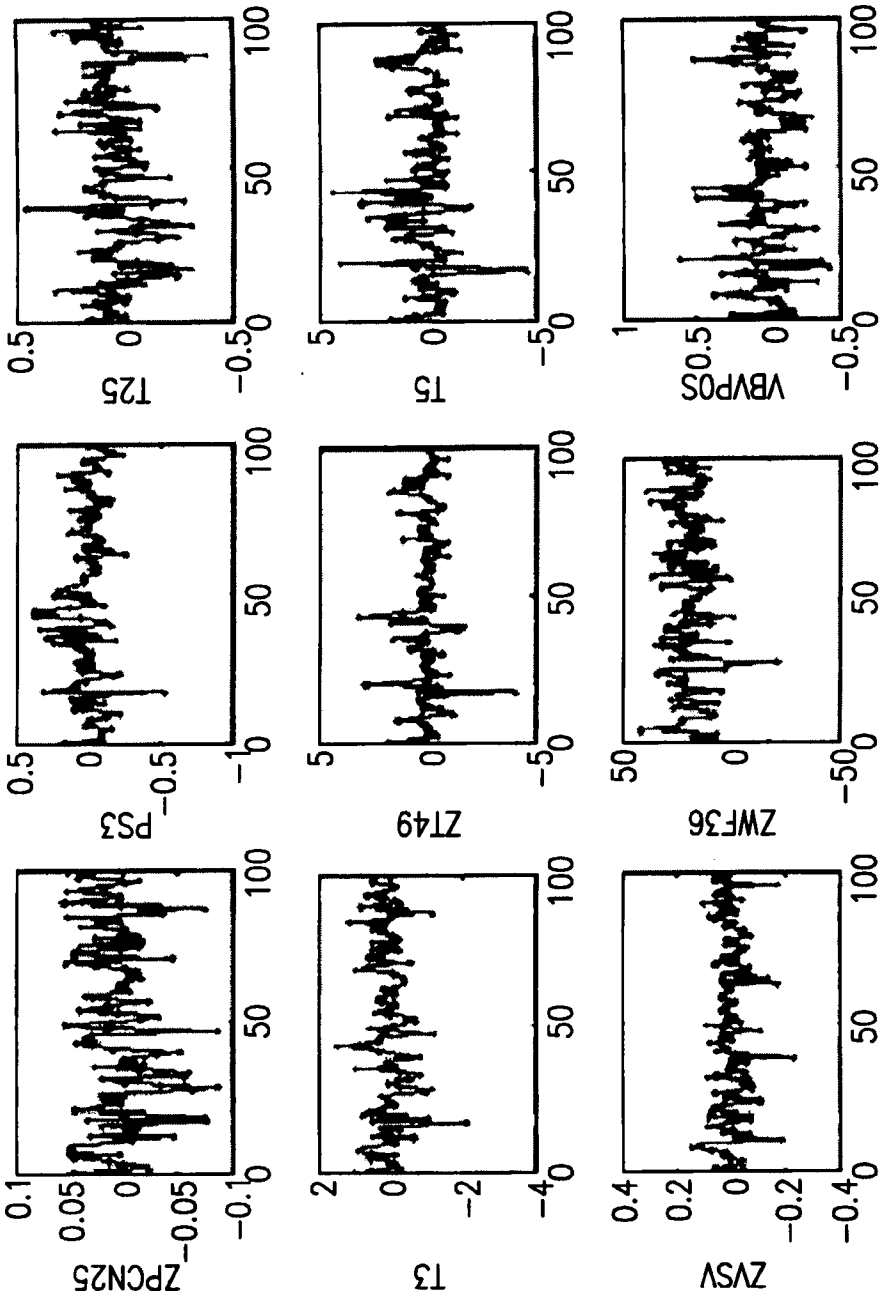


FIG.18(B)

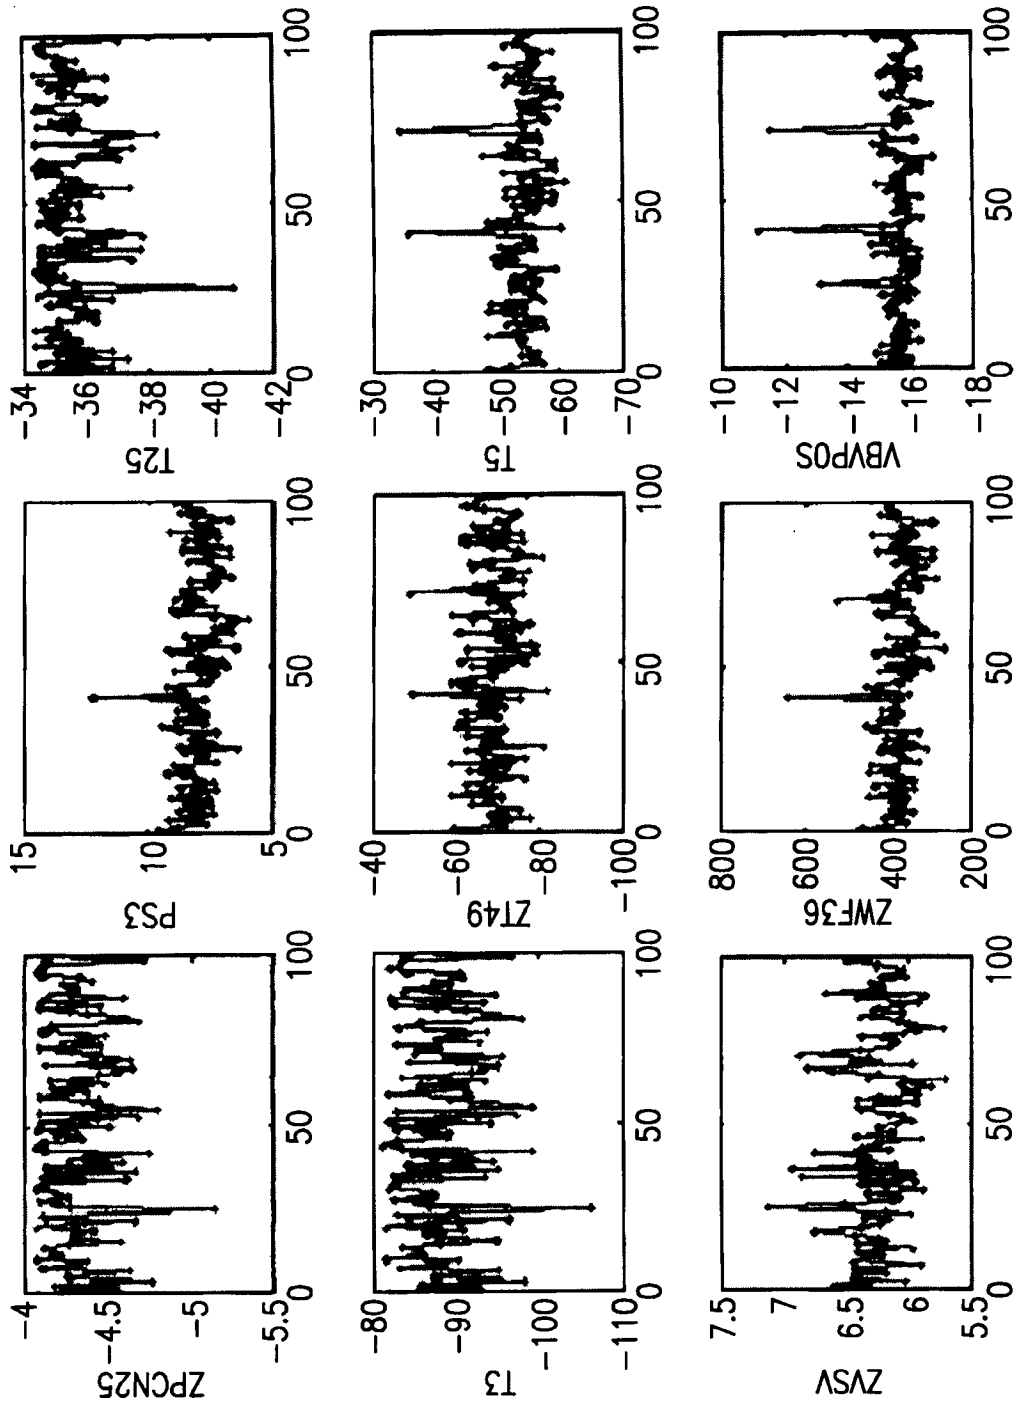


FIG.18(C)

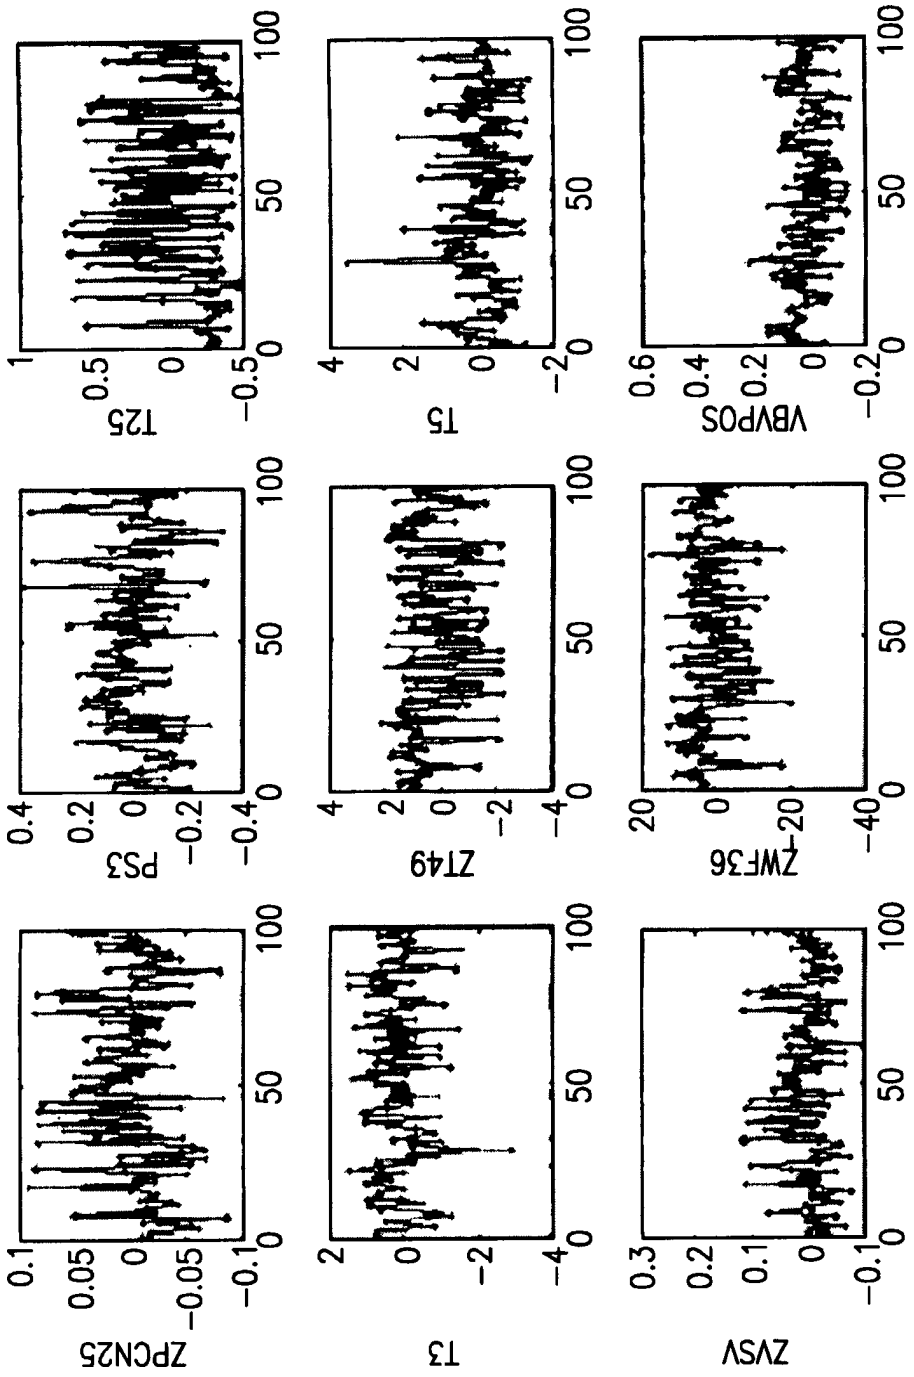


FIG.19(A)

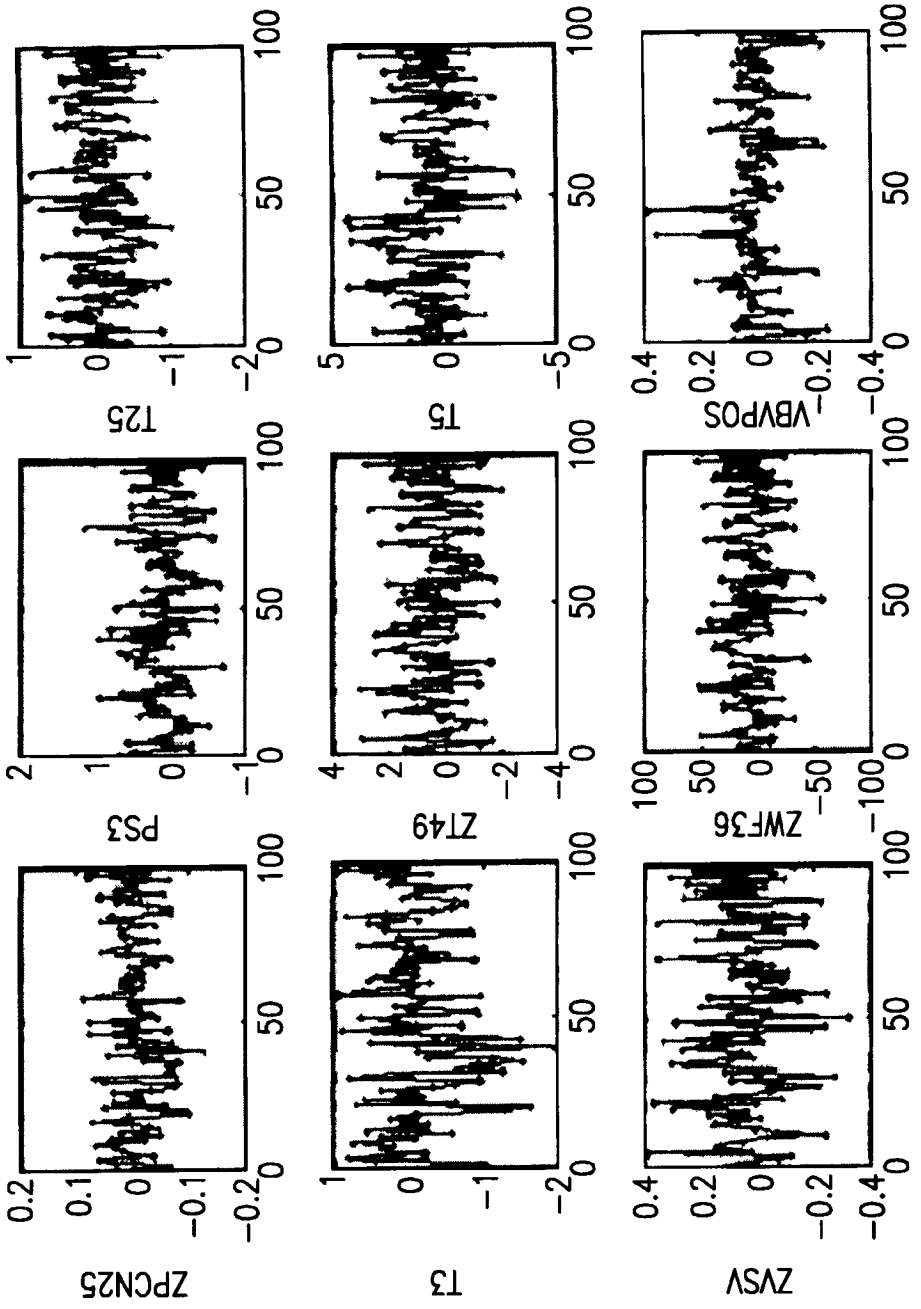


FIG.19(B)

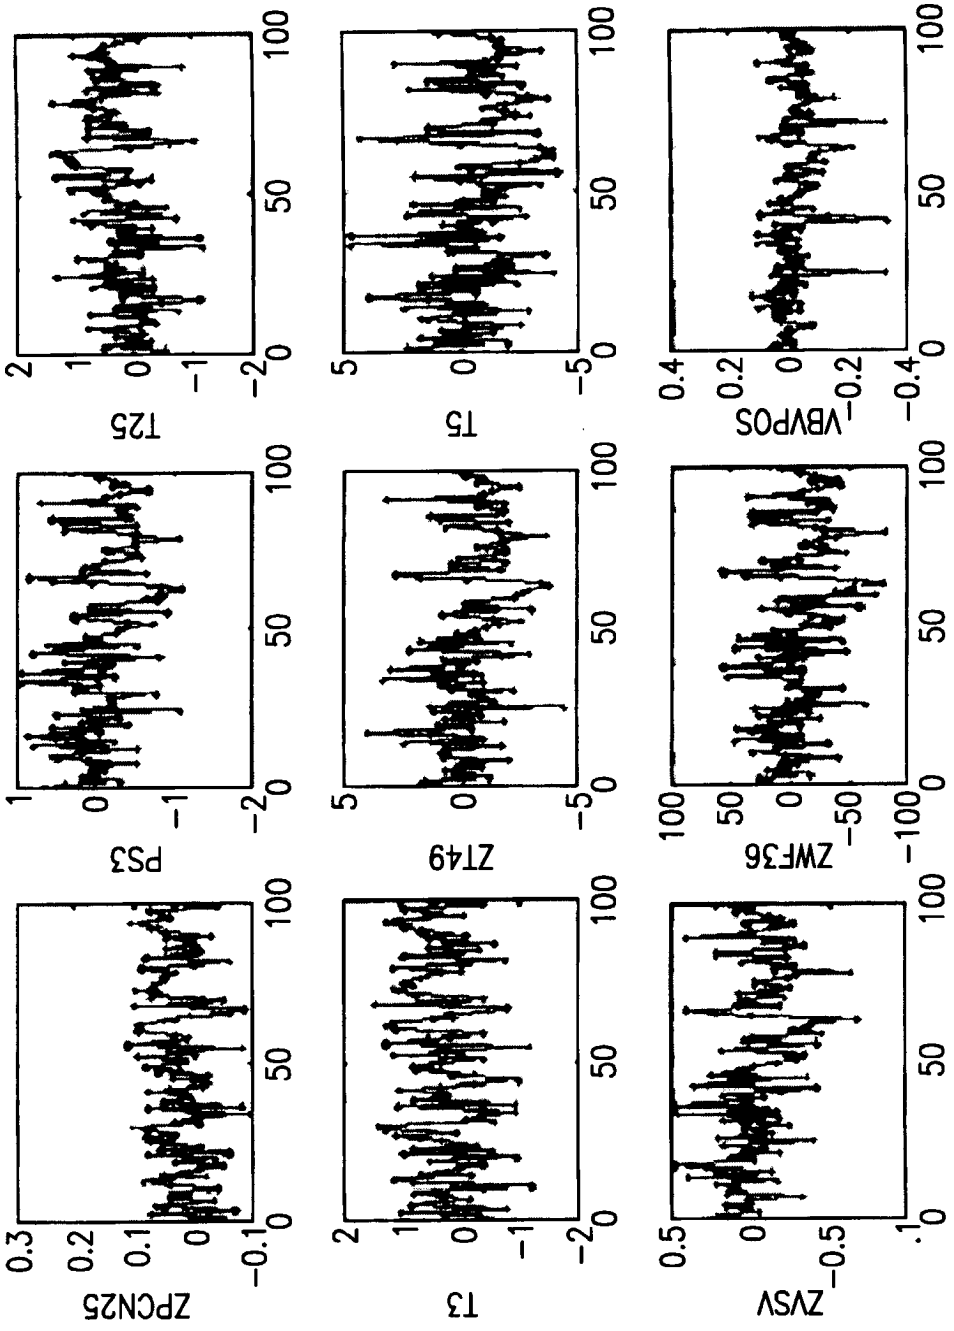


FIG.19(C)

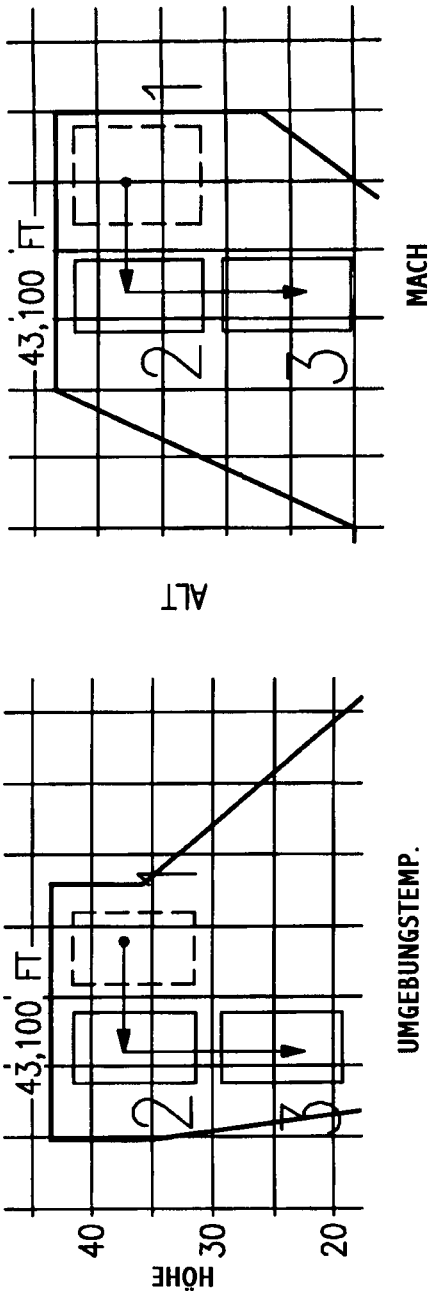


FIG.20(A)

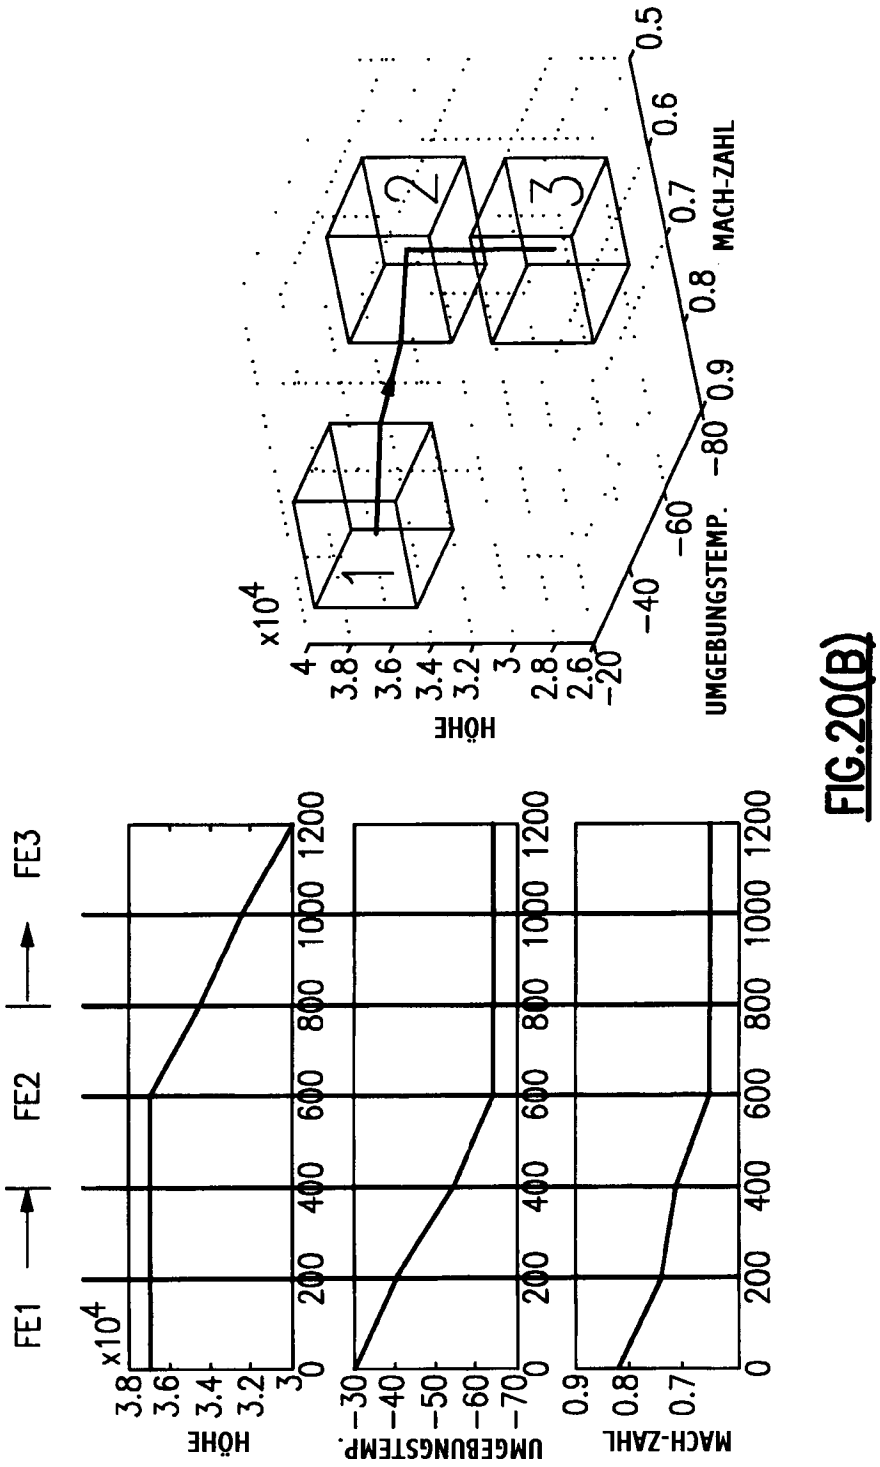


FIG.20(B)

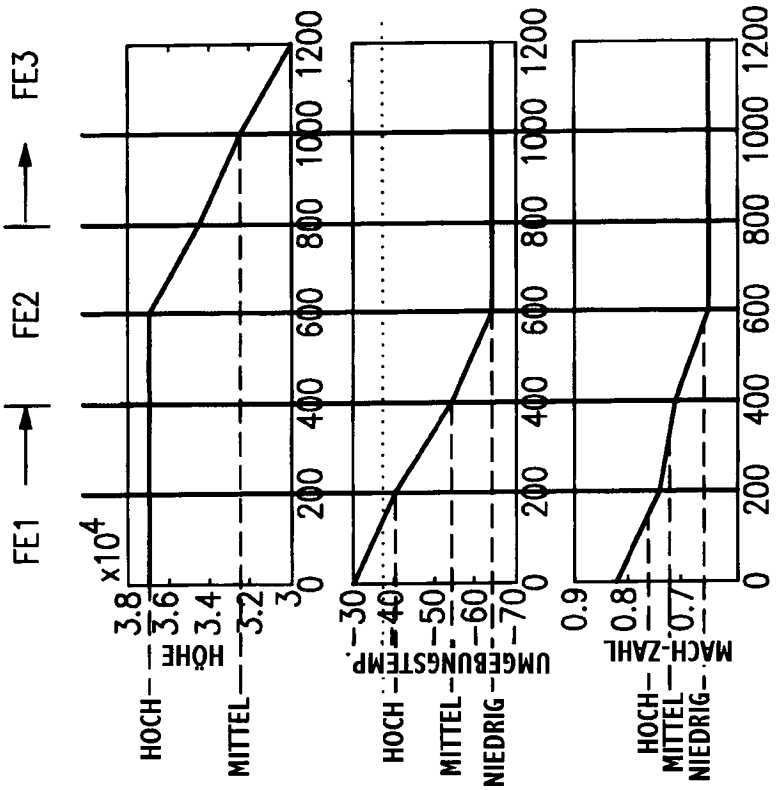

FE1
FE2
FE3
x10^4
3.8
3.6
3.4
3.2
3
HÖHE
HOCH
MITTEL
0
200
400
600
800
1000
1200
-30
-40
-50
-60
-70
UMGEBUNGSTEMP.
HOCH
MITTEL
NIEDRIG
0.9
0.8
0.7
MACH-ZAHL
HOCH
MITTEL
NIEDRIG

FIG.21(A)

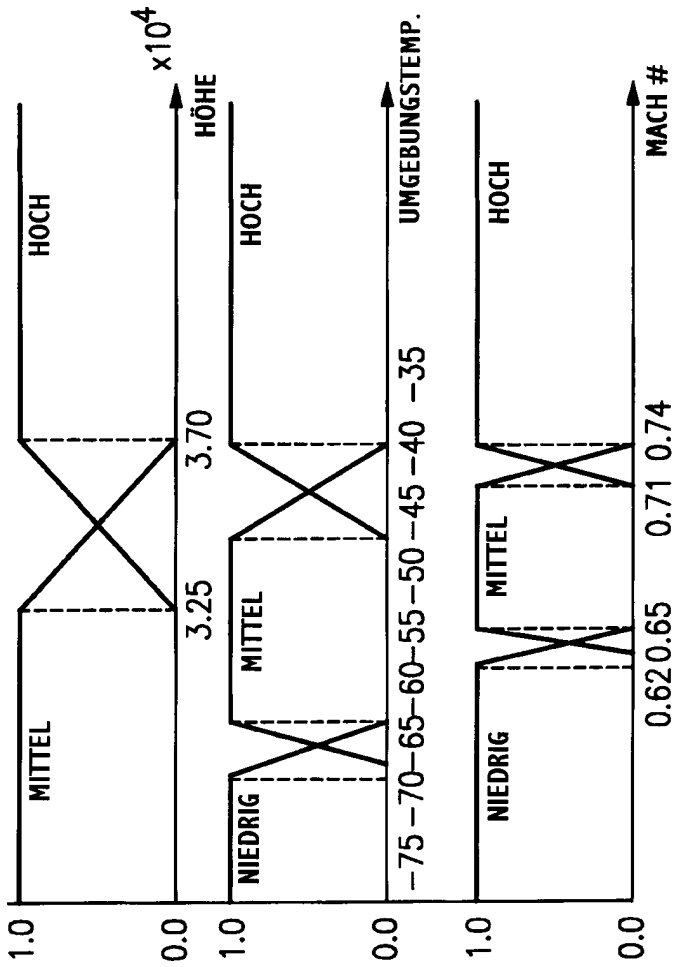

x10^4
HÖHE
UMGEBUNGSTEMP.
MACH #
HOCH
MITTEL
NIEDRIG
3.70
3.25
-35 -40 -45 -50 -55 -60 -65 -70 -75
0.74 0.71 0.65 0.62
1.0
0.0

FIG.21(B)

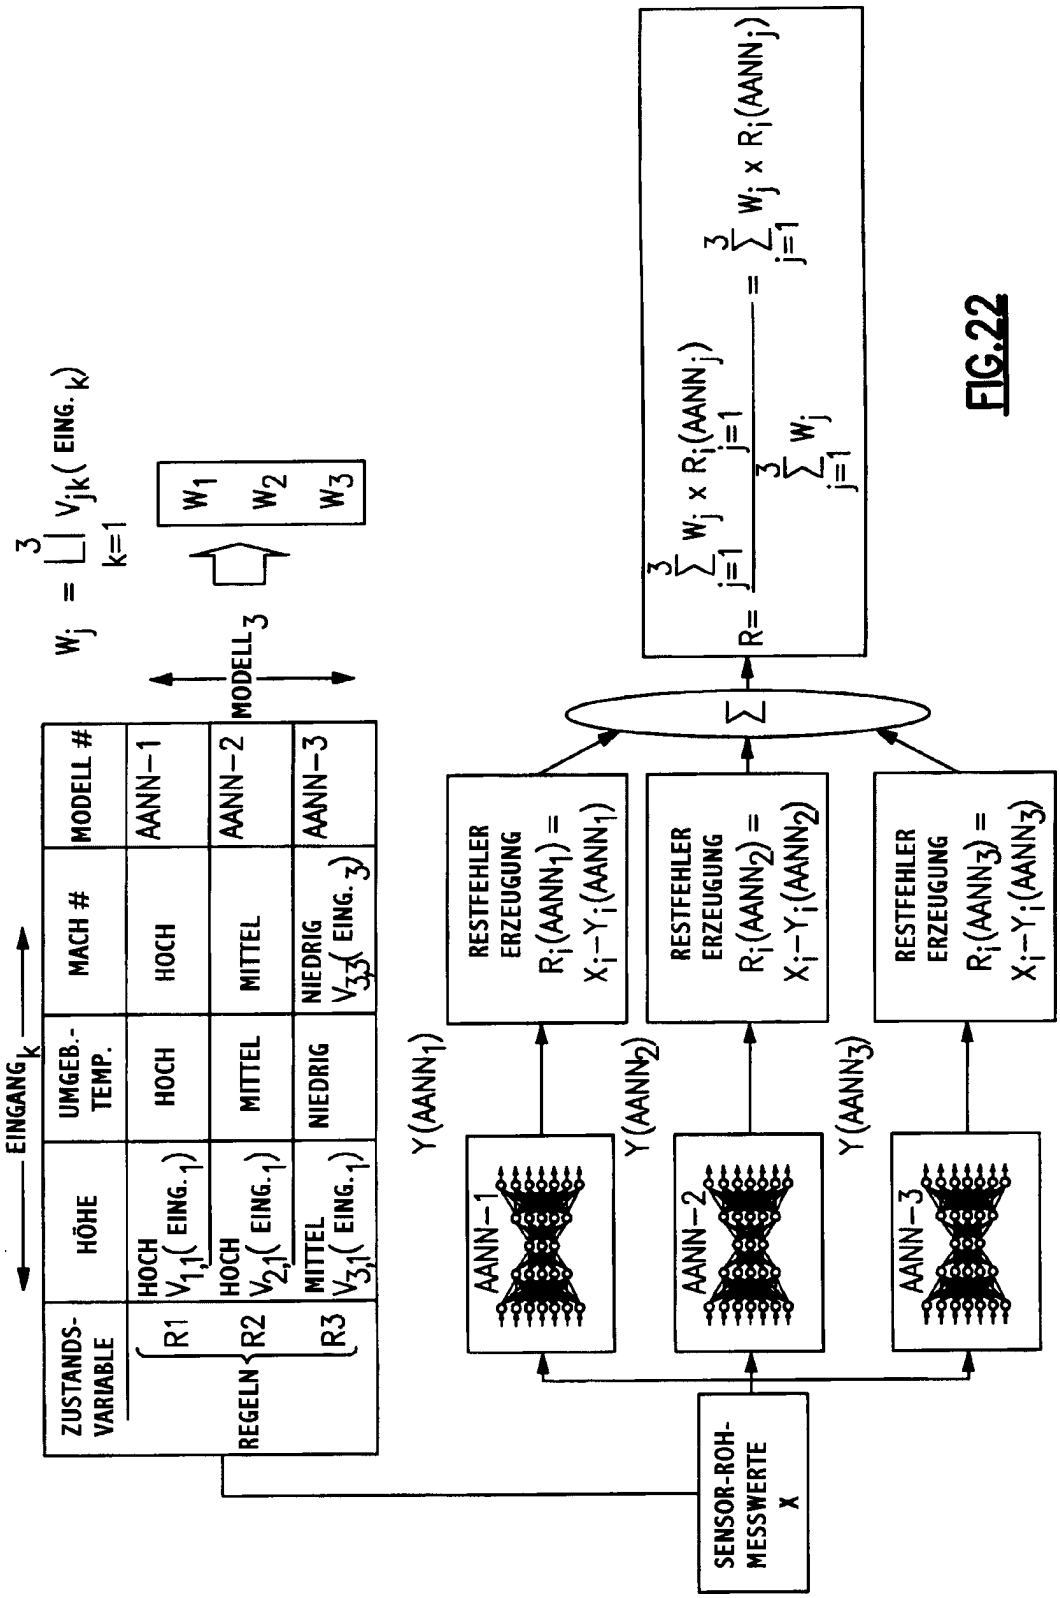

EINGANG$_k$
ZUSTANDS-VARIABLE
HÖHE
UMGEB.-TEMP.
MACH #
MODELL #
REGELN
R1
R2
R3
HOCH $V_{1,1}$(EING.$_1$)
HOCH $V_{2,1}$(EING.$_1$)
MITTEL $V_{3,1}$(EING.$_1$)
HOCH
MITTEL
NIEDRIG
NIEDRIG $V_{3,3}$(EING.$_3$)
AANN-1
AANN-2
AANN-3
MODELL$_3$
$W_j = \sum_{k=1}^{3} V_{jk}$(EING.$_k$)
W_1 W_2 W_3
SENSOR-ROH-MESSWERTE X
AANN-1
AANN-2
AANN-3
Y(AANN$_1$)
Y(AANN$_2$)
Y(AANN$_3$)
RESTFEHLER ERZEUGUNG R_i(AANN$_1$) = $X_i - Y_i$(AANN$_1$)
RESTFEHLER ERZEUGUNG R_i(AANN$_2$) = $X_i - Y_i$(AANN$_2$)
RESTFEHLER ERZEUGUNG R_i(AANN$_3$) = $X_i - Y_i$(AANN$_3$)
$\sum$
$R = \frac{\sum_{j=1}^{3} W_j \times R_i(\text{AANN}_j)}{\sum_{j=1}^{3} W_j} = \sum_{j=1}^{3} W_j \times R_i(\text{AANN}_j)$

FIG.22

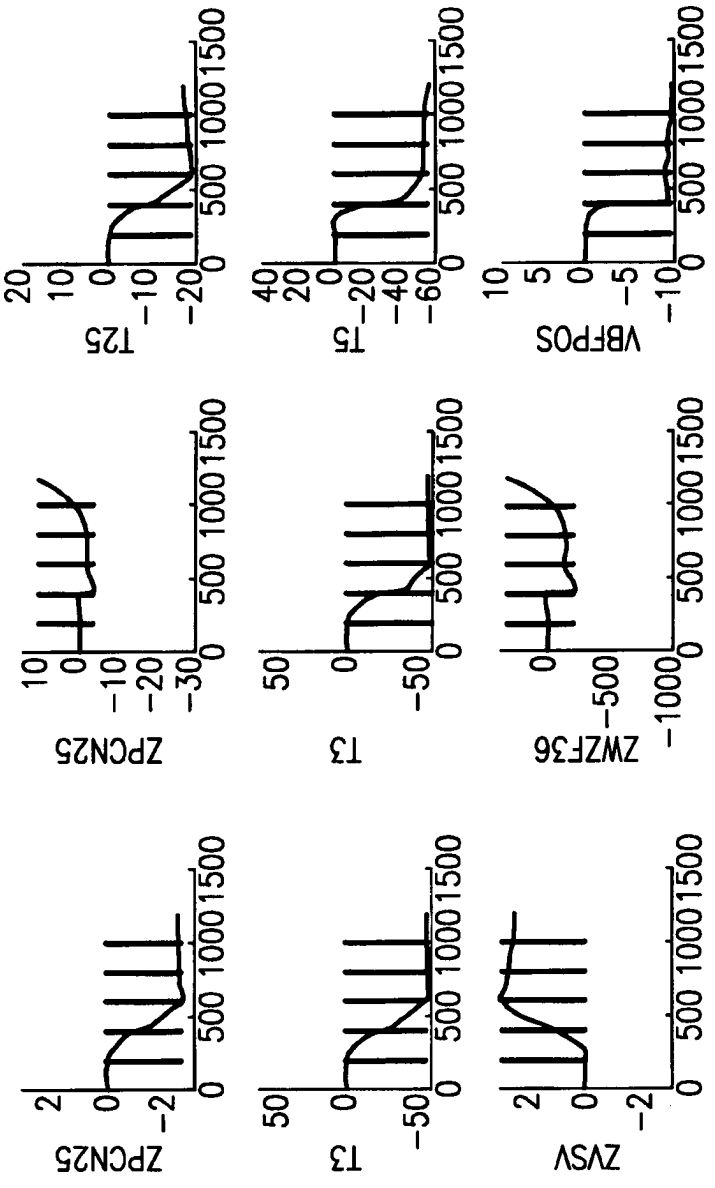


FIG.23(A)

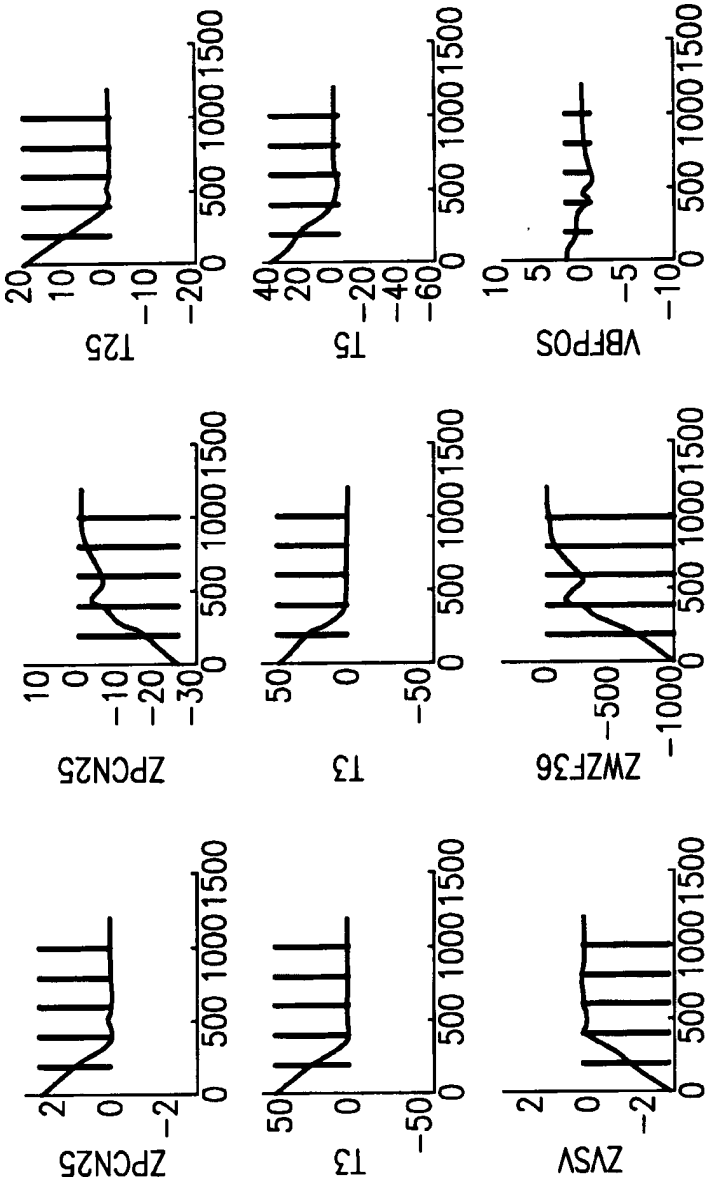


FIG.23(B)

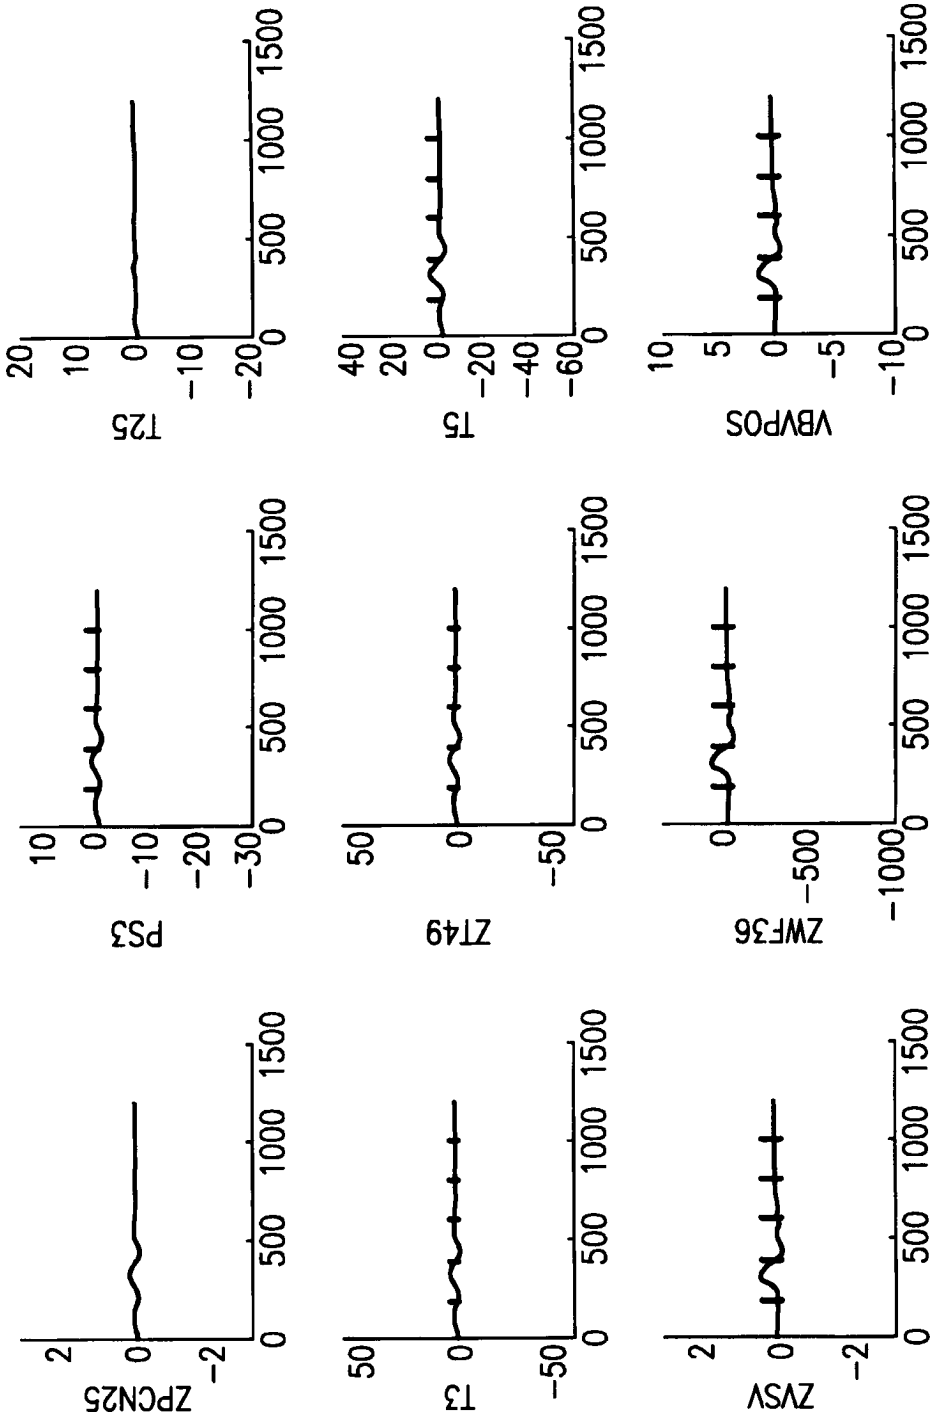


FIG.23(C)

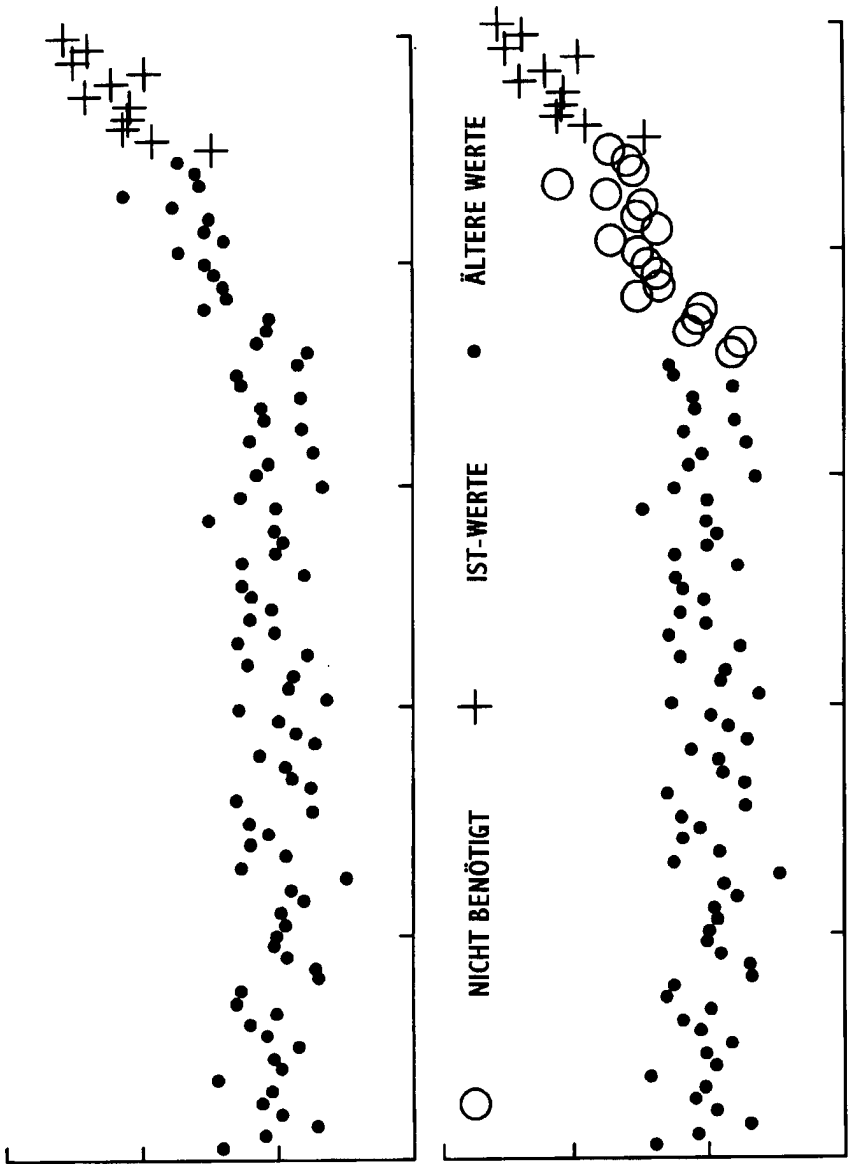


FIG.24

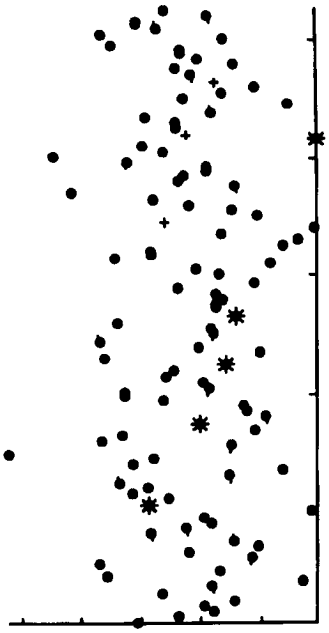


FIG.25(B)

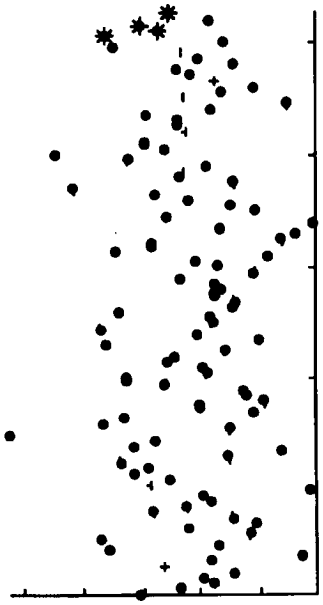


FIG.25(A)

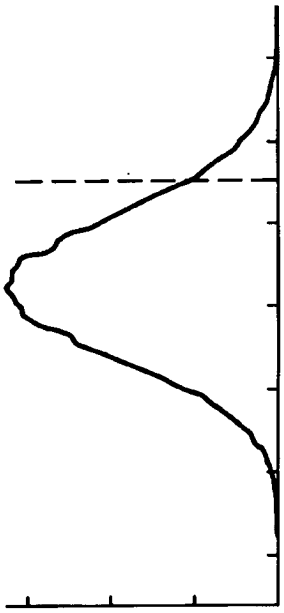


FIG.25(C)

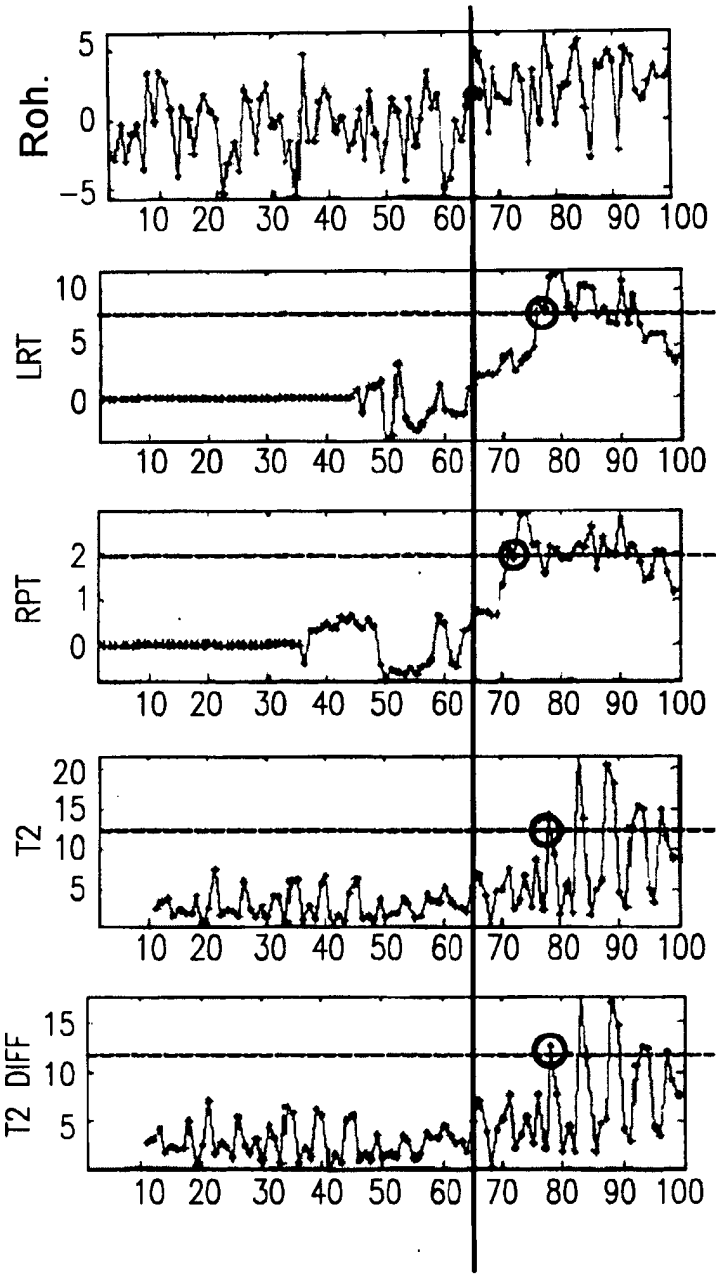

Roh.
5
0
−5
10 20 30 40 50 60 70 80 90 100
LRT
10
5
0
10 20 30 40 50 60 70 80 90 100
RPT
2
1
0
10 20 30 40 50 60 70 80 90 100
T2
20
15
10
5
10 20 30 40 50 60 70 80 90 100
T2 DIFF
15
10
5
10 20 30 40 50 60 70 80 90 100

FIG.26