



(19) 대한민국특허청(KR)
(12) 등록특허공보(B1)

(45) 공고일자 2013년10월08일
(11) 등록번호 10-1316486
(24) 등록일자 2013년10월01일

(51) 국제특허분류(Int. Cl.)
G05B 23/02 (2006.01)
(21) 출원번호 10-2011-7002716
(22) 출원일자(국제) 2009년05월29일
심사청구일자 2011년02월01일
(85) 번역문제출일자 2011년02월01일
(65) 공개번호 10-2011-0026515
(43) 공개일자 2011년03월15일
(86) 국제출원번호 PCT/JP2009/002391
(87) 국제공개번호 WO 2010/041355
국제공개일자 2010년04월15일
(30) 우선권주장
JP-P-2008-263030 2008년10월09일 일본(JP)
(56) 선행기술조사문헌
JP2006252259 A
JP2006107179 A
전체 청구항 수 : 총 14 항

(73) 특허권자
가부시킴이가이샤 히타치제이사쿠쇼
일본국 도쿄도 치요다쿠 마루노우치 1초메 6반 6고
(72) 발명자
마에다, 슌지
일본 244-0817 가나가와켄 요코하마시 도즈카꾸
요시다쵸 292 가부시킴이가이샤 히타치제이사쿠쇼
생산기술연구소 내
시부야, 히사에
일본 244-0817 가나가와켄 요코하마시 도즈카꾸
요시다쵸 292 가부시킴이가이샤 히타치제이사쿠쇼
생산기술연구소 내
(74) 대리인
이중희, 장수길, 박충범

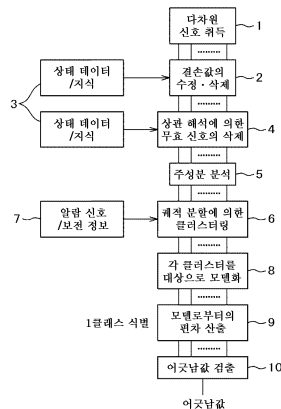
심사관 : 정성운

(54) 발명의 명칭 이상 검지 방법 및 시스템

(57) 요약

학습 데이터의 완전성, 이상의 혼입을 허용할 수 있고, 플랜트 등의 설비에서 이상의 조기·고정밀도의 발견을 가능하게 하는 방법 및 그 시스템을 제공하는 것이다. 상기 목적을 달성하기 위해, 본 발명은, (1) 시간적인 데이터의 움직임에 주목하여, 시간을 따라서 궤적을 클러스터로 분할한다. (2) 분할한 클러스터군에 대하여, 부분 공간에서 모델하고, 어긋남값을 이상 후보로서 산출한다. (3) 학습 데이터를 레퍼런스로서 활용(비교·참조 등)하고, 경시 변화, 환경 변동, 보수(부품 교환), 가동 상태에 의한 상태 천이를 파악한다. (4) 모델화는, 데이터의 N개 제거(N=0, 1, 2, ...)의 회귀 분석법이나 투영 거리법 등의 부분 공간법(예를 들면 N=1의 경우는, 이상 데이터가 1개 혼입하고 있다고 생각하고, 이것을 제거하여 모델화함), 혹은 국소 부분 공간법에 의한 것으로 한다. 또한, 회귀 분석법에서의 직선의 적용은, 가장 저차원인 회귀 분석에 상당한다.

대표도 - 도1



특허청구의 범위

청구항 1

플랜트 또는 설비의 이상을 조기에 검지하는 이상 검지 방법으로서,
 데이터 취득부에 의해, 복수의 센서로부터 데이터를 취득하고, 궤적 분할부에 의해, 상기 데이터의 시간적인 변화에 기초하여, 데이터 공간의 궤적을 복수의 클러스터군으로 분할하고,
 모델화부에 의해, 상기 분할한 상기 클러스터군에 대하여, 부분 공간법으로 모델화하고,
 이상 검출부에 의해, 상기 분할한 상기 클러스터군에 대한 어긋남값을 이상 후보로서 산출하는 것을 특징으로 하는 이상 검지 방법.

청구항 2

제1항에 있어서,
 상기 모델화는, 상기 복수의 센서로부터 과거에 얻어진 데이터로 이루어지는 학습 데이터를 대상으로 모델화한 레퍼런스 모델을 병용하여, 상기 어긋남값을 이상 후보로서 산출하는 것을 특징으로 하는 이상 검지 방법.

청구항 3

제1항에 있어서,
 상기 모델화는, 데이터의 N 개 제거($N=0, 1, 2, \dots$)의 회귀 분석법, 또는, 부분 공간법을 이용하여 행하는 것을 특징으로 하는 이상 검지 방법.

청구항 4

제3항에 있어서,
 상기 부분 공간법은, 투영 거리법, CLAFIC법, 또는, 관측 데이터의 근방을 대상으로 하는 국소 부분 공간법인 것을 특징으로 하는 이상 검지 방법.

청구항 5

제4항에 있어서,
 상기 어긋남값의 검출은, 상기 회귀 분석법, 상기 투영 거리법, 상기 CLAFIC법, 또는, 관측 데이터의 근방을 대상으로 하는 상기 국소 부분 공간법의 출력을 통합하여 행하는 것인 것을 특징으로 하는 이상 검지 방법.

청구항 6

플랜트 또는 설비의 이상을 조기에 검지하는 방법으로서,
 데이터 취득부에 의해, 복수의 센서로부터 데이터를 취득하고,
 궤적 분할부에 의해, 시간적인 데이터의 시간적 변화에 기초하여, 데이터 공간의 궤적을 복수의 클러스터로 분할하고,
 데이터 표시부에 의해, 분할한 클러스터를 알 수 있도록, 데이터를 표시함으로써, 상태를 가시화하는 것을 특징으로 하는 이상 검지 방법.

청구항 7

제1항에 있어서,
 상기 어긋남값을 이상 후보로서 산출하는 것은, 타 클러스터를 대상으로 하여 행하는 이상 검지로서, 상기 복수의 센서로부터의 과거의 데이터에 기초하는 클러스터군에 대한 이상 검지에 의해 제1보(報)를 출력하고, 자기(自) 클러스터를 대상으로 하여 행하는 이상 검지로서, 상기 복수의 센서의 현재의 데이터에 기초하는 클러스터

군에 대한 이상 검지에 의해 제2보를 출력하는 것을 포함하는 것을 특징으로 하는 이상 검지 방법.

청구항 8

플랜트 또는 설비의 이상을 조기에 검지하는 이상 검지 시스템으로서,
 복수의 센서로부터 데이터를 취득하는 데이터 취득부와,
 상기 데이터의 시간적인 변화에 기초하여, 데이터 공간의 궤적을 복수의 클러스터군으로 분할하는 궤적 분할부와,
 분할한 상기 클러스터군에 대하여, 부분 공간에서 모델화하는 모델화부와,
 상기 모델화부에서 모델화한 상기 클러스터군에 대한 어긋남값을 이상 후보로서 산출하는 이상 검출부를 갖고,
 상기 궤적 분할부에서는 상기 분할한 클러스터군에 대하여, 부분 공간에서 모델화하고, 상기 어긋남값을 이상 후보로서 산출하는 것을 특징으로 하는 이상 검지 시스템.

청구항 9

제8항에 있어서,
 상기 데이터 취득부에서 취득한 상기 복수의 센서로부터의 과거의 데이터를 축적하고, 또한, 모델화하여 레퍼런스 모델을 작성하는 학습 데이터베이스부를 갖고, 상기 학습 데이터베이스부에서의 상기 레퍼런스 모델을 병용하여, 상기 어긋남값을 이상 후보로서 산출하는 것을 특징으로 하는 이상 검지 시스템.

청구항 10

제8항에 있어서,
 상기 모델화는, 데이터의 N개 제거($N=0, 1, 2, \dots$)의 회귀 분석법, 또는, 부분 공간법을 이용하여 행하는 것을 특징으로 하는 이상 검지 시스템.

청구항 11

제10항에 있어서,
 상기 부분 공간법은, 투영 거리법, CLAFIS법, 또는, 관측 데이터의 근방을 대상으로 하는 국소 부분 공간법인 것을 특징으로 하는 이상 검지 시스템.

청구항 12

제11항에 있어서,
 상기 어긋남값의 검출은, 상기 회귀 분석법, 상기 투영 거리법, 상기 CLAFIS법, 또는, 관측 데이터의 근방을 대상으로 하는 상기 국소 부분 공간법의 출력을 통합하여 행하는 것인 것을 특징으로 하는 이상 검지 시스템.

청구항 13

플랜트 또는 설비의 이상을 조기에 검지하는 이상 검지 시스템으로서,
 복수의 센서로부터 데이터를 취득하는 데이터 취득부와,
 상기 데이터의 시간적인 변화에 기초하여, 데이터 공간의 궤적을 복수의 클러스터군으로 분할하는 궤적 분할부와,
 상기 분할한 클러스터군에 대하여, 부분 공간에서 모델화하는 모델화부와,
 상기 모델화부에서 모델화한 상기 클러스터군에 대한 어긋남값을 이상 후보로서 산출하는 이상 검출부와,
 데이터 표시부를 갖고,
 상기 분할한 복수의 클러스터군을 알 수 있도록, 데이터를 표시함으로써, 상태를 가시화하는 것을 특징으로 하는 이상 검지 시스템.

청구항 14

제13항에 있어서,

타 클러스터를 대상으로 하여 행하는 이상 검지로서, 상기 복수의 센서로부터의 과거의 데이터에 기초하는 클러스터군에 대한 이상 검지에 의해 제1보를 출력하고, 자기 클러스터를 대상으로 하여 행하는 이상 검지로서, 상기 복수의 센서의 현재의 데이터에 기초하는 클러스터군에 대한 이상 검지에 의해 제2보를 출력하는 것을 특징으로 하는 이상 검지 시스템.

명세서

기술분야

[0001] 본 발명은, 플랜트나 설비 등의 이상을 조기에 검지하는 방법에 관한 것이다.

배경기술

[0002] 전력 회사에서는, 가스 터빈의 폐열 등을 이용하여 지역 난방용 온수를 공급하거나, 공장용 고압 증기나 저압 증기를 공급하거나 하고 있다. 석유 화학 회사에서는, 가스 터빈 등을 전원 설비로서 운전하고 있다. 이와 같이 가스 터빈 등을 이용한 각종 플랜트나 설비에서, 그 이상을 조기에 발견하는 것은, 사회에의 피해를 최소한으로 억제할 수 있어, 매우 중요하다.

[0003] 가스 터빈이나 증기 터빈뿐만 아니라, 수력 발전소에서의 수차, 원자력 발전소의 원자로, 풍력 발전소의 풍차, 항공기나 중장비의 엔진, 철도 차량, 에스컬레이터, 엘리베이터, 기기·부품 레벨에서도, 탑재 전지의 열화·수명 등, 조기에 이상을 발견해야만 하는 설비는 일일이 들려면 한이 없다. 최근에는, 건강 관리를 위해, 뇌파 측정·진단에서 보여지는 바와 같이, 인체에 대한 이상(각종 증상) 검지도 중요하게 되고 있다.

[0004] 이를 위해, 예를 들면 미국의 SmartSignal사에서는, US6,952,662나 US6,975,962의 기재와 같이, 주로 엔진을 대상으로, 이상 검지의 업무를 서비스하고 있다. 거기서는, 과거의 데이터를 데이터베이스(DB)로 해 두고, 관측 데이터와 과거의 학습 데이터와의 유사도를 독자의 방법으로 계산하고, 유사도가 높은 데이터의 선형 결합에 의해 추정값을 산출하여, 추정값과 관측 데이터의 어긋남 정도를 출력한다. General Electric사와 같이, US6,216,066 출원 내용을 보면, 이상 검지를 k-means 클러스터링에 의해 검출하고 있는 예도 있다.

선행기술문헌

특허문헌

- [0005] (특허문헌 0001) 특허 문헌 1 : US6,952,662
- (특허문헌 0002) 특허 문헌 2 : US6,975,962
- (특허문헌 0003) 특허 문헌3 : US6,216,066

비특허문헌

[0006] (비특허문헌 0001) 비특허 문헌 1 : Stephan W. Wegerich;Nonparametric modeling of vibration signal features for equipment health monitoring, Aerospace Conference, 2003. Proceedings. 2003 IEEE, Volume 7, Issue, 2003 Page(s):3113-3121

발명의 내용

해결하려는 과제

[0007] SmartSignal사가 이용하고 있는 수법에서는, 데이터베이스에 격납하는 과거의 학습 데이터는 다양한 상태를 망라적으로 포함할 필요가 있다. 가령, 학습 데이터에 없는 관측 데이터가 관찰되면, 이들은 모두 학습 데이터에는 포함되지 않는 것으로서 취급되어, 어긋남값으로 판단되고, 정상 신호에서도 이상으로 판정되게 되어, 검사

의 신뢰성이 현저히 저하하게 된다. 이 때문에, 유저는, 과거의 각종 상태의 데이터 전부를 DB로서 저장하는 것이 필수적으로 된다.

[0008] 한편, 학습 데이터에 이상이 혼입되어 있는 경우, 이상을 나타내고 있는 관측 데이터와의 괴리도가 낮아져, 이를 놓치게 된다. 이 때문에, 학습 데이터에 이상이 포함되지 않도록, 충분한 체크가 필요하다.

[0009] 이와 같이, SmartSignal사가 제안하는 학습 데이터에 기초하는 방법에서는, 유저는, 망라적인 데이터 수집과 이상의 배제라고 하는 부하를 부담하게 된다. 특히, 경시 변화나, 주위의 환경 변동, 부품 교환 등의 보수 작업의 유무 등에, 치밀하게 대응할 필요가 있다. 이와 같은 대응을 행하는 것은, 실질적으로 어려워, 불가능한 경우가 많다.

[0010] General Electric사의 방법에서는, k-means 클러스터링 때문에, 신호의 거동을 보지 못해, 그 점에서 본질적인 이상 검지로는 되지 않는다.

[0011] 따라서, 본 발명의 목적은, 상기 과제를 해결하여, 학습 데이터의 불완전성이나 이상의 혼입을 허용하고, 유저 부하를 경감하는 것을 도모하고, 또한 조기에 이상을 고감도로 검지하는 것이 가능한 이상 검지 방법 및 시스템을 제공하는 것에 있다.

과제의 해결 수단

[0012] 상기 목적을 달성하기 위해, 본 발명은, (1) 시간적인 데이터의 움직임에 주목하고, 시간을 따라서 궤적을 클러스터로 분할하고, (2) 분할한 클러스터군에 대하여, 부분 공간에서 모델하고, 어긋남값을 이상 후보로서 산출한다. (3) 학습 데이터를 레퍼런스로서 활용(비교·참조 등)하고, 경시 변화, 환경 변동, 보수(부품 교환), 가동 상태에 의한 상태 천이를 파악한다. (4) 모델화는, 데이터의 N개 제거(N=0, 1, 2, ...)의 회귀 분석법이나 투영 거리법 등의 부분 공간법(예를 들면 N=1의 경우는, 이상 데이터가 1개 혼입되어 있다고 생각하고, 이것을 제거하여 모델화함), 혹은 국소 부분 공간법에 의한 것으로 한다.

[0013] 또한, (5) 부분 공간법 등, 복수의 식별기의 출력을 종합하여, 이상 판단을 행한다. 또한, 회귀 분석법에서의 직선의 적용은, 가장 저차원의 회귀 분석에 상당한다.

발명의 효과

[0014] 본 발명에 따르면, 학습 데이터가 완전하지 않아도, 이상의 혼입을 허용할 수 있고, 플랜트 등의 설비에서 이상의 조기·고정밀도의 발견을 가능하게 한다. 즉, SmartSignal사와 같이 정상부의 학습, 복수의 상태에 따른 망라적 데이터 수집의 필요성이 없다.

도면의 간단한 설명

[0015] 도 1은 본 발명의 제1 실시예를 나타내는 차트.

도 2는 다차원 시계열 신호의 예.

도 3은 상관 행렬의 예.

도 4는 궤적 분할 클러스터링의 적용예.

도 5는 궤적 분할 클러스터링의 적용예.

도 6은 궤적 분할 클러스터링의 적용예.

도 7은 궤적 분할 클러스터링 실시 시의 모델과의 편차의 예.

도 8은 궤적 분할 클러스터링 미실시 시의 모델과의 편차의 예.

도 9는 특정 공간에서 데이터 표시를 한 일례.

도 10은 특정 공간에서 데이터 표시를 한 다른 예.

도 11은 특정 공간에서 데이터 표시를 한 또 다른 예.

도 12는 특정 공간에서 데이터 표시를 한 또 다른 예.

도 13은 본 발명의 제2 실시예를 나타내는 차트.

- 도 14는 본 발명의 제3 실시예를 나타내는 차트.
- 도 15는 알람 신호의 히스토그램의 예.
- 도 16은 본 발명의 제4 실시예를 나타내는 차트.
- 도 17은 Wavelet(변환) 해석의 예.
- 도 18은 본 발명의 제5 실시예를 나타내는 차트.
- 도 19는 산포도 해석 및 상호 상관 해석의 예.
- 도 20은 본 발명의 제6 실시예를 나타내는 차트.
- 도 21은 시간·주파수 해석의 예.
- 도 22는 본 발명의 제7 실시예를 나타내는 차트.
- 도 23은 본 발명의 제7 실시예의 상세를 지원하는 차트.
- 도 24는 부분 공간법의 일례.
- 도 25는 Wavelet 변환의 설명도.
- 도 26은 이상 진단과의 관계를 설명하는 도면.
- 도 27은 하드웨어 구성도.
- 도 28은 국소 부분 공간법의 적용예.
- 도 29는 투영 거리법, 국소 부분 공간법의 적용예.
- 도 30은 복수 식별기의 통합에 의한 식별예.
- 도 31은 복수 식별기의 통합에 의한 이상 검지예.

발명을 실시하기 위한 구체적인 내용

- [0016] 이하 실시예에 따라서, 본 발명의 내용을 상세하게 설명한다.
- [0017] <실시예 1>
- [0018] 설명을 간략화하기 위해, 본원에서는, 동일한 구성 요소에는 동일한 부호를 부가하고 있다. 본 발명의 일 실시 형태를 도 1에, 대상으로 하는 신호의 예를 도 2에 도시한다. 대상 신호는, 도 2에 도시한 바와 같은 복수의 시계열 신호이다. 여기서는, 계열 1, 2, 3, 4라고 하는 4종류의 신호를 나타내고 있다. 실제로는, 신호는 4종류에 한정되는 것이 아니라, 수백 내지 수천의 수로 되는 경우도 있다.
- [0019] 각 신호가, 대상 플랜트나 설비에 설치된 복수의 센서로부터의 출력에 상당한다. 예를 들면, 실린더, 오일, 냉각수 등의 온도, 오일이나 냉각수의 압력, 축의 회전 속도, 실온, 운전 시간 등이, 다양한 센서로부터, 1일에 수회 내지 리얼타임 등, 정한 간격으로 관측된다. 출력이나 상태를 나타낼 뿐만 아니라, 무엇인가를 제어하기 위한 제어 신호(입력)의 경우도 있다. ON/OFF 제어의 것도 있는가 하면, 일정값으로 되도록 제어하는 경우도 있다. 이들의 데이터는, 서로 상관이 높은 것이나 낮은 것이 있다. 이들 모든 신호가, 대상으로 될 수 있다. 이들의 데이터를 보고, 이상의 유무를 판단한다. 여기서는, 다차원 시계열 신호로서 취급한다.
- [0020] 도 1에 도시한 이상 검지 방법에 대해서 설명한다. 우선, 다차원 시계열 신호를 다차원 신호 취득부(1)에서 취득한다. 다음으로, 취득한 다차원 시계열 신호가, 결손되어 있는 경우가 있기 때문에, 결손값의 수정·삭제를 결손값의 수정·삭제부(2)에서 행한다. 결손의 수정은, 예를 들면, 전후의 데이터의 치환이나 이동 평균의 치환이 일반적이다. 삭제는, 많은 데이터가 동시에 0으로 리셋되었을 때 등, 데이터로서의 이상을 배제하는 것이다. 결손값의 수정·삭제는, 설비의 상태나 엔지니어의 지식을 상태 데이터/지식(3)이라고 하는 DB에 저장해 두고, 이를 기초로 행하는 경우도 있다. 다음으로, 수정·삭제된 다차원 시계열 신호에 관하여, 상관 해석에 의한 무효 신호의 삭제를, 상관 해석에 의한 무효 신호의 삭제부(4)에서 행한다. 이것은, 도 3에서 상관 행렬의 예를 나타낸 바와 같이, 다차원 시계열 신호에 대하여 상관 해석을 행하고, 상관값이 1에 가까운 복수의 신호가 있는 경우 등, 매우 유사성이 높은 경우에, 이들은 용장인 것으로 하여, 이 복수의 신호로부터 중복되는 신호를 삭제하고, 중복되지 않는 것을 남기는 것이다. 이 경우도, 상태 데이터/지식(3)에 격납한 정보에 기초

하여, 삭제한다.

- [0021] 다음으로, 데이터의 차원 삭감을 주성분 분석부(5)에서 행한다. 여기서는, 주성분 분석에 의해, M차원의 다차원 시계열 신호를, 차원수 r의 r차원 다차원 시계열 신호로 선형 변환한다. 주성분 분석은, 변동 최대가 되는 축을 생성하는 것이다. KL 변환으로도 상관없다. 차원수 r은, 주성분 분석에 의해 구한 고유값을 내림차순으로 배열하고, 큰 쪽으로부터 가산한 고유값을 전체 고유값의 합으로 나눈 누적 기여율인 값에 기초하여 구한다.
- [0022] 다음으로, r차원의 다차원 시계열 신호에 대하여, 궤적 분할에 의한 클러스터링을 궤적 분할에 의한 클러스터링부(6)에서 행한다. 도 4에 그 모양을 나타낸다. 도 4의 좌측 위의 3차원 표시(특징 공간이라고 부름)는, 주성분 분석 후의 r차원의 다차원 시계열 신호를 기여율이 높은 3차원으로 표시한 것이다. 이 상태에서는, 아직 대상 설비의 상태가 복잡한 것으로서 관측되어 있는 것을 알 수 있다. 도 4의 남은 여덟개의 3차원 표시는, 궤적을 시간에 따라서 추적하고, 클러스터링을 실시한 것이며, 각 클러스터를 나타내고 있다. 클러스터링은, 시간에 따라서 데이터간의 거리가 정한 임계값을 초과하면, 다른 클러스터로 하고 임계값을 초과하지 않으면, 동일한 클러스터로서 취급하는 것이다. 이에 의해, 클러스터 1, 3, 9, 10, 17은, 운전 ON의 상태의 클러스터이며, 클러스터 6, 14, 20은, 운전 OFF의 상태의 클러스터로 나뉘어져 있는 것을 알 수 있다. 클러스터 2 등, 도시하고 있지 않은 클러스터는, 과도기의 것이다. 이들의 클러스터를 분석하면, 운전 ON의 상태에서는, 선형상으로 궤적 이동하고 있는 것을 엿볼 수 있고, 운전 OFF의 상태에서는, 불안정한 궤적 이동하고 있는 것을 엿볼 수 있다. 이와 같이, 궤적 분할에 의한 클러스터링은, 몇 개의 메리트가 있는 것을 알 수 있다.
- [0023] 운전 ON의 상태, 운전 OFF의 상태 등, 복수의 상태로 분류할 수 있다.
- [0024] 운전 ON의 상태에서 보여지는 바와 같이, 이들의 클러스터는, 예를 들면 선형 등, 저차원의 모델로 표현할 수 있다.
- [0025] 이들의 클러스터링은, 설비의 알람 신호나 보전 정보를 가미하여, 이들의 조건 부여로서, 실시하여도 된다. 구체적으로는, 각 클러스터에, 알람 신호 등의 정보가 속성으로서 부가된다.
- [0026] 도 5에, 특징 공간에서, 클러스터링에 의해 라벨을 붙인 상태 외의 예를 나타낸다. 도 6은, 하나의 시계열 신호 상에, 클러스터링의 결과를 표시한 것이다. 이 경우, 클러스터는 16개 생성할 수 있고, 시계열 신호가, 16개의 클러스터로 분할되어 있는 모습을 알 수 있다. 운전 시간(누적 시간)도 겹쳐서 표시하였다. 수평하게 되어 있는 부분은, 운전 OFF이다. 운전 ON과 운전 OFF가, 정밀도 좋게 분리될 수 있는 것을 알 수 있다.
- [0027] 다음으로, 클러스터링된 각 클러스터를 대상으로, 저차원 부분 공간에서의 모델화를, 각 클러스터를 대상으로 모델화부(8)에서 행한다. 정상부 한정일 필요는 없으며, 이상이 혼입하는 것은 문제 없다. 여기서는, 예를 들면, 회귀 분석에 의해 모델화를 행한다. 회귀 분석의 일반식은, 하기와 같다. 「y」가, 클러스터마다의 r차원의 다차원 시계열 신호에 상당한다. 「X」가, y를 설명하는 변수이다. 「y~」가 모델로 된다. 「e」는 편차이다.
- [0028] y : 목적 변수(r열)
- [0029] b : 회귀 계수(1+p열)
- [0030] X : 설명 변수 행렬(r행, 1+p열)
- [0031] $||y-Xb|| \Rightarrow \min$
- [0032] $b=(X'X)^{-1}X'y$ ('는 전치를 나타냄)
- [0033] $y \sim =Xb=X(X'X)^{-1}X'y$ (설명 변수의 영향을 나타내는 부분)
- [0034] $e=y-y \sim$ ($y \sim$ 에서 근사할 수 없는 부분. 설명 변수의 영향을 제거한 부분)
- [0035] 단, rank $X=p+1$
- [0036] 여기서는, 각 클러스터의 r차원의 다차원 시계열 신호에 대해, 데이터의 N개 제거(N=0, 1, 2, ...)의 회귀 분석을 한다. 예를 들면 N=1의 경우는, 이상 신호가 1종 혼입되어 있다고 생각하고, 이를 제거한 신호를 「X」로서 모델화한다. N=0의 경우는, 전체 r차원 다차원 시계열 신호를 취급하게 된다.
- [0037] 회귀 분석 이외에, CLAFIC법이나 투영 거리법 등의 부분 공간법을 적용하여도 된다. 그리고, 모델로부터의 편차를 모델로부터의 편차 산출부(9)에서 구한다. 도 24에 일반적인 CLAFIC법을 도해하여 나타낸다. 2클래스, 2차원 패턴의 경우를 나타낸다. 각 클래스의 부분 공간, 즉, 여기서는 1차원의 직선으로서 나타내는 부분 공간

을 구한다.

- [0038] 일반적으로, 각 클래스의 데이터의 자기 상관 행렬을 고유값 분해하여, 고유 벡터를 기저로서 구한다. 값이 큰, 상위 몇 개의 고유값에 대응하는 고유 벡터를 이용한다. 미지 패턴 q (최신 관측 패턴)가 입력되면, 부분 공간에의 정상경의 길이, 혹은 부분 공간에의 투영 거리를 구한다. 그리고, 정상경의 길이가 최대, 혹은 투영 거리가 짧은 클래스에, 미지 패턴(최신 관측 패턴) q 를 분류한다.
- [0039] 도 24에서는 미지 패턴 q (최신 관측 패턴)는, 클래스 A로 분류된다. 도 2에 도시한 다차원 시계열 신호에서는, 기본적으로 정상부를 대상으로 하기 때문에, 1클래스 식별의 문제로 되므로(도 1에서 도시), 클래스 A를 정상부로 하고, 미지 패턴 q (최신 관측 패턴)에서 클래스 A까지의 거리를 구하여, 이를 편차로 한다. 그리고, 편차가 크면, 어긋남값으로 판단한다. 이와 같은 부분 공간법에서는, 이상값이 약간 섞여 있어도, 차원 삭감하고, 부분 공간으로 한 시점에서, 그 영향이 완화된다. 부분 공간법 적용의 메리트이다.
- [0040] 또한, 투영 거리법에서는, 각 클래스의 무게 중심을 원점으로 한다. 각 클래스의 공분산 행렬로 KL 전개를 적용하여 얻어진 고유 벡터를 기저로서 이용한다. 다양한 부분 공간법이 입안되어 있지만, 거리 척도를 갖는 것이면, 어긋남 정도가 산출 가능하다. 또한, 밀도의 경우도, 그 대소에 의해, 어긋남 정도를 판단 가능하다. CLAFIC법은, 정상경의 길이를 구하는 것이므로, 유사도 척도이다.
- [0041] 이와 같이, 부분 공간에서 거리나 유사도를 계산하고, 어긋남 정도를 평가하게 된다. 투영 거리법 등의 부분 공간법은, 거리에 기초하는 식별기이므로, 이상 데이터를 이용할 수 있는 경우의 학습법으로서, 사전 패턴을 갱신하는 벡터 양자화나 거리 함수를 학습하는 매트릭 학습을 사용할 수 있다.
- [0042] 또한, 국소 부분 공간법이라고 부르는, 미지 패턴 q (최신 관측 패턴)에 가까운 k 개의 다차원 시계열 신호를 구하고, 각 클래스의 최근방 패턴이 원점으로 되는 선형 다양체를 생성하고, 그 선형 다양체에의 투영 거리가 최소로 되는 클래스에 미지 패턴을 분류하는 방법도 적용할 수 있다(도 31의 국소 부분 공간법의 틀 내 참조). 국소 부분 공간법도 부분 공간법의 일종이다.
- [0043] 이미 설명한 클러스터링 후의 각 클러스터에 대하여, 국소 부분 공간법을 적용하게 된다. k 는, 파라미터이다. 이상 검지에서는, 전술과 마찬가지로, 1클래스 식별의 문제로 되므로, 대다수의 데이터가 속하는 클래스 A를 정상부로 하고, 미지 패턴 q (최신 관측 패턴)에서 클래스 A까지의 거리를 구하여, 이를 편차로 한다.
- [0044] 이 수법에서는, 예를 들면, k 개의 다차원 시계열 신호를 이용하여 형성되는 부분 공간에의, 미지 패턴 q (최신 관측 패턴)로부터의 정상경한 점을 추정값으로서 산출할 수도 있다(도 31의 국소 부분 공간법의 틀 내에서 설명한 추정값인 데이터). 또한, k 개의 다차원 시계열 신호를, 미지 패턴 q (최신 관측 패턴)에 가까운 순으로 재배열, 그 거리에 반비례한 가중치 부여를 행하여, 각 신호의 추정값을 산출할 수도 있다. 투영 거리법 등에서도, 마찬가지로 추정값을 산출할 수 있다.
- [0045] 파라미터 k 는 통상은 1종류로 정하지만, 파라미터 k 를 몇 개 바꿔서 실행하면, 유사도에 따라서 대상 데이터를 선택하게 되고, 그들의 결과로부터 종합적으로 판단할 수 있기 때문에, 한층 효과적이다. 국소 부분 공간법에서는, 클러스터 내의 선택된 데이터를 대상으로 하기 때문에, 이상값이 약간 섞여 있어도, 국소 부분 공간에 한 시점에서, 그 영향이 크게 완화된다.
- [0046] 국소 부분 공간법의 「국소」라고 하는 개념은, 회귀 분석에도 적용 가능하다. 즉, 「 y 」로서, 관측 미지 패턴 q 에 가까운 k 개의 다차원 시계열 신호를 구하고, 이 y 의 모델로서, 「 $y\sim$ 」를 구하고, 편차 「 e 」를 산출한다.
- [0047] 또한, 단순히, 1클래스 식별의 문제로 생각하면, 1클래스 서포트 벡터 머신 등의 식별기도 적용 가능하다. 이 경우, 고차 공간에 사상하는, radial basis function 등의 커널화를 사용할 수 있게 된다. 1클래스 서포트 벡터 머신에서는, 원점에 가까운 축이, 어긋남값, 즉 이상으로 된다. 단, 서포트 벡터 머신은, 특징량의 차원은 크게 해도 대응할 수 있지만, 학습 데이터수가 증가하면 계산량이 방대하게 된다고 하는 결점도 있다.
- [0048] 이 때문에, MIRU2007(화상의 인식·이해 심포지움, Meeting on Image Recognition and Understanding 2007)에서 발표된, 「IS-2-10 가토 조와 카즈, 노구치 진신, 와다 토시카즈(와카야마대), 사카이 카오루, 마에다 순지(히타치); 패턴의 근접성에 기초하는 1클래스 식별기」 등의 수법도 적용 가능하며, 이 경우, 학습 데이터수가 증가하여도, 계산량은 방대한 것으로 되지 않는다고 하는 메리트가 있다.
- [0049] 다음으로, 회귀 분석을 예로 들어, 실험예를 설명한다. 도 7에, $N=0$ 으로 하고, 선형 회귀 분석에 의해, r 차원 다차원 시계열 신호를 모델화하고, 그 모델과 실측값의 편차를 도시한 예를 나타낸다. 도 8은, 참고로, 궤적 분할에 의한 클러스터링을 실시하지 않는 경우이다. 도 7의 경우, 편차가 큰 것은, 운전 OFF의 구간, 및, 운전

ON의 구간에서 시계열 신호가 진동적인 움직임을 하고 있는 경우이다. 마지막으로, 어긋남값 검출부(10)에서 어긋남값을 구한다. 여기서는, 임계값과의 대소를 체크한다. 검출된 이상 신호는, 주성분 분석 후이므로, 이를 역변환하고, 원래의 신호가 어떠한 비율로 합성되어, 이상으로 판단되었는지를 확인할 수도 있다.

- [0050] 이와 같이, 궤적 분할에 의한 클러스터링을 중심으로, 저차원 모델로 다차원 시계열 신호를 표현함으로써, 복잡한 상태를 분해할 수 있어, 간단한 모델로 표현할 수 있으므로, 현상을 이해하기 쉽다고 하는 이점이 있다. 또한, 모델을 설정하기 위해, SmartSignal사의 방법과 같이 완전히, 데이터를 완비할 필요는 없다. 데이터의 결락이 있어도 된다고 하는 메리트가 있다.
- [0051] 다음으로, 국소 부분 공간법의 적용예를 도 28에 도시한다. 신호를 전반과 후반으로 나누고(교차 확인이라고 부르는 검증 방법에 따른), 각각을 학습 데이터로 하여, 남은 데이터까지의 거리를 구한 예이다. 파라미터 k는 10으로 하였다. k를 몇 개 바꿔서, 그들의 다수결을 취하면, 안정된 결과가 얻어진다(후술하는 버깅(bagging)이라고 하는 수법과 마찬가지로의 생각에 기초함). 이 국소 부분 공간법에서는, 데이터의 N개 제거가, 자동으로 행해진다고 하는 메리트가 있다. 도 28 적용예에서는, 운전 OFF 중의 불규칙한 거동이 검지되어 있다.
- [0052] 상기 예에서는, 클러스터링의 필요성도 완화되지만, 관측 데이터가 속해 있는 클러스터 이의를 학습 데이터로 하고, 이 데이터와 관측 데이터에 국소 부분 공간법을 적용하여도 된다. 이 방법에 따르면, 다른 클러스터로부터의 괴리도를 평가할 수 있다. 투영 거리법도 마찬가지이다. 도 29에 그들의 예를 나타낸다. 관측 데이터가 속해 있는 클러스터 이의를 학습 데이터로 하였다. 이 생각은, 시계열 데이터와 같이 유사 데이터가 연속하는 경우에, 가장 유사한 데이터를 「국소」 영역으로부터 배제할 수 있기 때문에, 효과적이다. 또한, 데이터의 N개 제거는, 특징량(센서 신호)으로서 설명하였지만, 시간축 방향의 데이터이어도 된다.
- [0053] 다음으로, 데이터의 표현 형태를, 몇 개 도면을 이용하여 설명한다. 도 9에 몇 개의 예를 도시한다. 도 9의 좌측의 도면은, 주성분 분석 후의 r차원 시계열 신호를 2차원 표시한 것이다. 데이터의 움직임을 가시화한 예로 된다. 도 9의 우측의 도면은, 궤적 분할에 의한 클러스터링을 실시하고, 클러스터를 도시한 것이다. 클러스터마다, 간단한 저차의 모델(여기서는 직선)로 표현한 예이다. 도 10의 좌측의 도면은, 데이터가 움직이는 속도를 알 수 있도록 도시한 예이다. 후술하는 Wavelet 해석을 적용하면, 속도, 즉 주파수도 분석 가능, 그리고 다변량으로서 취급하는 것이 가능하게 된다. 도 10의 우측의 도면은, 도 9의 우측의 도면에서 도시한 모델로부터의 편차를 알 수 있도록 표시한 예이다.
- [0054] 도 11의 좌측의 도면은, 다른 예이다. 거리 기준 등에 기초하여 유사하다고 판정한 클러스터를 머지하여(도 11에서는, 인접한 클러스터의 머지를 나타냄), 머지 후의 모델을 나타내고, 또한 모델로부터의 편차를 도시한 예이다. 도 11의 우측의 도면은, 상태를 표현한 것이다. 상태 A, B, C라고 하는 3종류의 상태를 나누어 표시하였다. 상태를 나누어 생각하면, 도 12의 좌측의 도면에 도시한 바와 같이, 상태 A의 변화 등을 도시 가능하게 된다.
- [0055] 도 6의 예로 생각하면, 동일한 운전 ON의 상태라도, 운전 OFF의 전후에서, 다른 거동을 나타내고 있고, 이들을 특징 공간 중에서 표현할 수 있는 것으로 된다. 도 12의 우측의 도면은, 과거의 학습 데이터로부터 얻어진 모델(저차의 부분 공간)로부터의 변화를 나타낸 것이며, 상태 변화를 관찰할 수 있다. 이와 같이, 데이터를 가공하고, 가공한 데이터를 유저에 나타내고, 현재의 상황을 가시화함으로써, 보다 좋은 이해를 추구할 수 있다.
- [0056] 다음으로, 다른 실시예를 설명한다. 이미 설명한 블록은 생략한다. 도 13에 이상 검지 방법을 나타낸다. 여기서는, 각 클러스터에 대해, r차원 다차원 시계열 신호를 랜덤으로 정한 개수분 선택한다. 랜덤 선택에 의해, 모든 신호를 사용하는 경우에 보이지 않았던 특성이 나타나고, 유효하지 않은 신호를 제거하는 모든 조합으로부터, 단시간에 계산할 수 있다고 하는 이점이 있다.
- [0057] 또한, 시간축 방향으로 r차원 다차원 시계열 신호를 랜덤으로 정한 개수분 선택한다고 하는 선택도 생각된다. 여기서는, 클러스터를 단위로 하는 경우도 있지만, 클러스터 내를 구분하고, 이들을 정한 개수만큼, 랜덤으로 선택한다.
- [0058] 도 14에 다른 실시예를 나타낸다. 알람 신호를 처리하는 부분(12)을 부가하였다. 도 15의 (a)에 도시한 바와 같이 알람 신호의 발생 이력을 취득한다. 그리고, 그 히스토그램을 표시한다. 빈도가 높은 구간은, 이상의 정도가 높은 것은 용이하게 상상을 할 수 있다. 따라서, 도 15의 (b)에 도시한 바와 같이, 히스토그램의 빈도도 고려하여, 도 1에 도시한 이상 특정부(13)에서, 알람 신호와 어긋남값을 조합하여 이상의 정도나 신뢰도를 부가하거나, 이상 판정을 행한다.
- [0059] 도 16에 다른 실시예를 나타낸다. Wavelet(변환) 해석을 부가한 예이다. Wavelet 해석 신호 부여부(14)에서,

M차원의 다차원 시계열 신호를 대상으로, 도 17에 도시한 Wavelet 해석을 행하고, 이들의 신호를 M차원의 다차원 시계열 신호에 가한다. M차원의 다차원 시계열 신호로 치환하는 것도 가능하다. 이와 같은 신규에 가해지거나, 치환되거나 한 다차원 시계열 신호를 대상으로, 국소 부분 공간법 등의 식별기에 의해, 이상을 검지한다. 또한, 도 17의 (a)는 후에 설명하는 도 25에서의 스케일 1의 신호에 해당하고, 도 17의 (b)는 후에 설명하는 도 25에서의 스케일 8의 변동에 해당하고, 도 17의 (c)는 도 25에서의 스케일 4의 변동에 해당하고, 도 17의 (d)는 도 25에서의 스케일 2의 변동에 해당한다.

- [0060] Wavelet 해석은, 다중 해상도 표현을 제공하는 것이다. 도 25에 Wavelet 해석을 도해하여 도시한다. 스케일 1의 신호가 원래의 신호이다. 이를 순차적으로 오프 가산하여 스케일 2의 신호를 만들고, 원래의 신호와의 차를 산출하여, 스케일 2의 변동 신호를 생성한다. 순차적으로, 이를 반복하면, 마지막에, 스케일 8의 일정값의 신호와 그 변동 신호가 얻어지고, 결국, 원래의 신호는, 스케일 2, 4, 8의 각 변동 신호와 스케일 8의 직류 신호로 분해할 수 있다. 따라서, 이와 같은 스케일 2, 4, 8의 각 변동 신호를, 새로운 특징적 신호라고 간주하여, 다차원 시계열 신호에 추가하여 취급한다.
- [0061] 펄스나 임펄스 등의 비정상 신호에서는, 푸리에 변환을 행하여 얻어지는 주파수 스펙트럼은 전역으로 넓어져, 개개의 신호에 대해서 특징을 추출하는 것이 곤란하다. 시간에 국재(局在)한 스펙트럼을 얻을 수 있는 Wavelet 변환은, 화학 프로세스와 같은, 펄스나 임펄스 등을 포함하는, 비정상인 신호를 많이 포함하는 데이터를 대상으로 한 경우에 적합하다.
- [0062] 또한, 1차 지연을 갖는 계(시스템)에서는, 시계열의 상태만으로는, 그 패턴을 관측 곤란하지만, 시간·주파수 영역상에서는, 식별 가능한 특징이 나타나는 경우가 있어, Wavelet 변환이 유효한 경우가 많다.
- [0063] 또한, Wavelet 해석의 응용은, 전기 학회 편집에서, 신 세이치저의 「웨이브릿 해석의 산업 응용」 2005년, 아사쿠라 출판에 상세하게 기재되어 있다. 화학 플랜트의 제어계 진단, 공조 플랜트 제어에서의 이상 검지, 세멘트의 소성 프로세스의 이상 감시, 글래스 용해로 제어 등, 많은 대상에 적용되어 있다.
- [0064] 본 실시예에서의, 종래 기술과의 상위점은, Wavelet 해석을 다중 해상도 표현으로서 취급하고, 원래의 다차원 시계열 신호의 정보를, Wavelet 변환에 의해 현재화한 점에 있다. 게다가, 이들을 다변량으로서 취급함으로써, 이상이 미약한 단계로부터 조기에 검지할 수 있다. 즉, 예조로서 조기에 검지 가능하게 된다.
- [0065] Wavelet 해석을 분류에 적용한 것 외의 예를 설명한다. 이상 데이터가 적지 않게 있어, 교시할 수 있는 경우의 예이다. 사용하는 기호를 이하에 표시한다.

수학식 1

N : 1계열의 데이터 길이(샘플수)

m : AR 모델의 차수

K : 클래스의 수

N_p : 트레이닝 데이터의 계열수

y_t : 시계열 신호 ($t = 1 \sim N$)

$$z_{t-1} = [y_{t-1}, y_{t-2}, \dots, y_{t-m}]^T$$

$$Z_N = \{y_1, y_2, \dots, y_N\}$$

Z_N^j : j 번째의 관측값 계열

C_i : 클래스 i ($i = 1 \sim K$)

f_j : AR 계수 ($j = 1 \sim m$)

$$\Phi = [f_1, f_2, \dots, f_m]^T$$

$$q = [\Phi^T, r]^T$$

$P_r(C_i)$: 클래스 i 의 사전 확률

$P(C_i | Z_N)$: 클래스 i 의 사후 확률

$p(Z_N | C_i)$: 클래스 C_i 에 관한 시계열 데이터 Z_N 의 조건부 확률 밀도 함수

$p(Z_N | q)$: 파라미터 q 에 관한 시계열 데이터 Z_N 의 조건부 확률 밀도 함수

[0066]

[0067] 또한, 이하의 모델을 가정한다.

수학식 2

$$y_t = \sum_{j=1}^m \phi_j y_{t-1} + v_t = \Phi^T z_{t-1} + v_t, \quad m+1 \leq t \leq N$$

[0068]

[0069] 단, v_t 는 평균값 0, 분산 ρ 의 가우스성 백색 계열이다.

[0070] 여기서, $p(Z_N|\theta)$ 를 생각할 수 있다.

$$p(Z_N|\theta) = p(y_N, y_{N-1}, \Lambda, y_1|\theta) \\ = p(y_1, y_2, \Lambda, y_m, \theta) p(\theta) \times \prod_{t=m+1}^N p(y_t|y_{t-1}, y_{t-2}, \Lambda, y_1, \theta)$$

[0071]

[0072] y_1, y_2, Λ, y_m 은, 관측값으로서 이용하고,

[0073] $p(y_1, y_2, \Lambda, y_m, \theta) = p(y_1, y_2, \Lambda, y_m) p(\theta)$ 로 가정하면,

$$p(Z_N|\theta) = p(y_1, y_2, \Lambda, y_m) \prod_{t=m+1}^N p(y_t|y_{t-1}, y_{t-2}, \Lambda, y_1, \theta)$$

[0074]

[0075] 여기서, y_t 는 가우스 분포라고 가정하고 있으므로, $p(y_t|y_{t-1}, \Lambda, y_1, \theta)$ 도 가우스 분포로 되고,

$$p(y_t|y_{t-1}, \Lambda, y_1, \theta) = \frac{1}{\sqrt{2\pi\rho}} \exp\left(-\frac{1}{2\rho} (y_t - \Phi^T z_{t-1})^2\right)$$

[0076]

[0077] 따라서, $p(Z_N|\theta)$ 는 다음 식으로 표현된다.

$$p(Z_N|\theta) = p(y_1, y_2, \Lambda, y_m) \left(\frac{1}{2\pi\rho}\right)^{(N-m)/2} \exp\left(-\frac{1}{2\rho} \sum_{t=m+1}^N (y_t - \Phi^T z_{t-1})^2\right)$$

[0078]

[0079] 파라미터의 최대 우도(最尤) 추정값은, 대수 우도 $p(Z_N|\theta)$ 를, Φ, ρ 에 의해 편미분하여 0으로 하여, 다음과 같이 구할 수 있다.

$$\hat{\Phi} = \left(\sum_{t=m+1}^N z_{t-1} z_{t-1}^T\right)^{-1} \left(\sum_{t=m+1}^N z_{t-1} y_t\right) \\ \hat{\rho} = \frac{1}{N-m} \sum_{t=m+1}^N (y_t - \hat{\Phi}^T z_{t-1})^2$$

[0080]

[0081] 다음으로, 관별식으로서 다음의 식을 생각할 수 있다.

수학식 3

$$I^* = \text{Arg Max}_i \ln p(C_i|Z_N)$$

[0082]

[0083] 상기 식은 관측값 계열 Z_N 이 얻어졌을 때의 클래스 C_i 의 사후 확률이 최대로 되는 클래스를 관별 클래스로서 채용한다.

$$I^* = \text{Arg Max}_i \ln p(Z_N|C_i) P_i(C_i)$$

[0084]

[0085] 여기서, 시스템을 결정하는 파라미터 θ 는 각 클래스에서 일정하며,

[0086] $p(\theta|C_i) = \delta(\theta - \theta_i)$ 로 가정하면, $p(Z_N|C_i)$ 는, 다음과 같다.

$$p(Z_N|C_i) = \int p(Z_N, \theta | C_i) d\theta = \int p(Z_N | \theta, C_i) p(\theta | C_i) d\theta$$

$$= \int p(Z_N | \theta, C_i) \delta(\theta - \theta_i) d\theta = p(Z_N | \theta_i, C_i) = p(Z_N | \theta_i)$$

[0087]

[0088] 따라서, 판별식은 다음과 같게 된다.

$$I^* = \text{Arg Max}_i \ln p(Z_N | \theta_i) P_i(C_i)$$

[0089]

[0090] 또한, 파라미터 추정에 관해서는, 다음 식에서 정의되는 우도를 최대로 하는 최대 우도 추정법을 이용하는 것으로 한다.

수학식 4

$$L = \sum_{j=1}^{N_p} \ln p(Z_N^j | \theta_i)$$

[0091]

[0092] 단, Z_N^j 는 j번째의 관측값 계열이며, N_p 는 트레이닝 데이터의 개수이다.

[0093] 이상의 결과로부터, 판별식, 파라미터 추정식은, 다음과 같게 된다.

[0094] [판별식]

수학식 5

$$I^* = \text{Arg Max}_i \left(-\frac{N-m}{2} \ln \hat{\rho}_i + \ln pr(C_i) - \frac{1}{2\hat{\rho}_i} \sum_{t=m+1}^N (y_t - \hat{\Phi}_i^T z_{t-1})^2 \right)$$

[파라미터 추정식]

$$\hat{\Phi}_i = \left(\sum_{j=1}^{N_p} \sum_{t=m+1}^N z_{t-1}^j z_{t-1}^{jT} \right)^{-1} \left(\sum_{j=1}^{N_p} \sum_{t=m+1}^N z_{t-1}^j y_t^j \right)$$

$$\hat{\rho}_i = \frac{1}{N_p(N-m)} \sum_{j=1}^{N_p} \sum_{t=m+1}^N (y_t^j - \hat{\Phi}_i^T z_{t-1}^j)^2$$

[0095]

[0096] 상기 식에 기초하여, 분류가 가능하게 된다. 특히, 상기는 멀티 클래스에의 분류의 예이지만, 클래스수 K를 2로 하면, 2분류 문제, 즉 이상 검지의 문제로 된다. 그리고, 상기 관측값에 Wavelet 해석의 결과를 적용하면, 시간에 국재한 이상도 대상으로 하는 이상 검지를 행할 수 있다. 이와 같이, 이상 데이터가 적지 않게 있어, 교시할 수 있는 경우에는, 통계적인 의미에서, 보다 정밀도가 높은 이상 검지를 행할 수 있다.

[0097] 도 18에 다른 실시예를 나타낸다. 산포도·상관 해석부(15)를 부가한 예이다. r차원의 다차원 시계열 신호를 대상으로, 산포도·상관 해석을 행한 예도 도 19에 도시한다. 도 19의 상호 상관 해석에서는, 지연의 래그(lag)를 고려하고 있다. 통상, 상호 상관 함수의 최대값의 위치를 래그라고 부른다. 이 정의에 따르면, 2개의 현상에 관한 시간의 어긋남은, 상호 상관 함수의 래그와 동등하다.

- [0098] 래그의 정부는, 2개의 현상의 어느 쪽이 빨리 일어나는가에 의해 결정된다. 이와 같은 산포도 해석이나 상호 상관 해석의 결과는, 시계열 신호간의 상관을 나타내는 것이지만, 각 클러스터의 특징 부여에도 활용할 수 있어, 클러스터간의 유사성의 판단 지표로 될 수 있는 것이다. 예를 들면, 래그의 양의 일치도에 의해, 클러스터간의 유사성을 판단한다. 이에 의해, 도 11에 도시한 유사한 클러스터의 머지 등이 가능하게 된다. 머지 후의 데이터를 이용하여 모델화한다. 또한, 머지의 방법은, 다른 수법이어도 된다.
- [0099] 도 20에 다른 실시예를 나타낸다. 시간·주파수 해석부(16)를 부가한 예이다. r차원의 다차원 시계열 신호를 대상으로, 시간·주파수 해석을 행한 예를 도 21에 도시한다. 시간·주파수 해석, 혹은 산포도·상관 해석을 행하고, 이들의 신호를 M차원의 다차원 시계열 신호에 가하거나, 또는 M차원의 다차원 시계열 신호로 치환하는 것도 가능하다.
- [0100] 도 22에 다른 실시예를 나타낸다. 학습 데이터의 DB(17)와 모델화(1)(18)를 부가한 예이다. 도 23에, 그 상세를 도시한다. 모델화(1)에 의해, 학습 데이터를 대상으로 그것을 복수의 모델로서 모델화하고, 관측 데이터와의 유사성을 판단하여 그 모델을 적용시켜, 관측 데이터와의 편차를 산출한다. 모델화(2)는, 도 1과 마찬가지로의 부분이며, 여기서부터, 관측 데이터로부터 얻어지는 모델과의 편차를 산출한다.
- [0101] 그리고, 모델화(1) (2)의 각각의 편차로부터, 상태 변화를 산출하고, 종합 편차를 산출한다. 여기서, 모델화(1) (2)를 균등하게 취급하는 것도 가능하지만, 가중치 부여를 하여도 된다. 즉, 학습 데이터를 기본으로 생각하면, 모델(1)의 가중치를 크게 하고, 관측 데이터를 기본으로 생각하면, 모델(2)의 가중치를 크게 한다.
- [0102] 도 12에 도시한 표현을 따르면, 모델(1)로 구성된 부분 공간 모델을 클러스터간에서 비교하면, 그리고 그들이 원래 동일 상태의 클러스터이면, 그 상태 변화를 알 수 있다. 그리고, 관측 데이터의 부분 공간 모델이 거기서부터 이동하고 있으면, 상태 변화를 판독할 수 있다. 상태 변화가, 부품 교환 등으로 의도하는 것이면, 즉, 설계측이 알고 있고, 그에 의한 변화를 허용해야 하면, 모델(1)의 가중치를 작게 하고, 모델(2)의 가중치를 크게 한다. 상태 변화가, 의도하지 않는 것이면, 모델(1)의 가중치를 크게 한다. 예를 들면, 파라미터 α 를, 모델(1)의 가중치로서 사용하면,
- [0103] $\alpha \times \text{모델}(1) + (1 - \alpha) \times \text{모델}(2)$
- [0104] 로서 정식화할 수 있다.
- [0105] 모델(1)의 가중치를, 오래된 것일수록 작게 한다고 하는 망각형(忘却形)의 것이어도 된다. 이 경우, 최근 데이터에 기초하는 모델이 증시되게 된다.
- [0106] 도 23에서, 물리 모델(22)은, 시뮬레이션에 의해 대상 엔진 등을 모의한 모델이다. 대상 지식이 충분한 경우는, 대상 엔진 등을 이산 시간 (비)선형 상태 공간 모델(상태 방정식 등으로 표현)로 표현할 수 있으므로, 그 중간값이나 출력 등을 추정 가능하게 된다. 따라서, 이 물리 모델에 따르면, 이 모델로부터의 편차에 기초하여, 이상 검지를 행하는 것도 가능하게 된다.
- [0107] 물론, 물리 모델에 따라서, 학습 데이터의 모델(1)을 수정하는 것도 가능하다. 혹은, 반대로, 학습 데이터의 모델(1)에 따라서, 물리 모델을 수정하는 것도 가능하다. 물리 모델의 변형으로서, 과거의 실적으로서의 지견을, 물리 모델로서 구성하는 것도 가능하다. 알람의 발생이나 부품 교환에 수반하는 데이터의 친이름, 물리 모델에 짜넣는 것도 가능하다. 혹은, 학습 데이터(개개의 데이터나 무게 중심 위치 등)를, 알람의 발생이나 부품 교환에 수반하여, 이동시켜도 된다.
- [0108] 또한, 도 23에 대하여, 도 1에서 도 22까지 도시한 바와 같이, 물리 모델에 대하여, 통계 모델을 주로 사용하는 것은, 데이터를 만들어 내는 프로세스에 대한 이해가 적은 경우에, 통계 모델이 유효한 것에 의한다. 거리나 유사성은, 데이터의 생성 과정이 불명료하여도 정의할 수 있다. 화상이 대상인 경우도, 화상 생성 과정이 불명료일 때, 통계 모델은 유효하다. 대상에 관한 지식이, 조금이라도 이용할 수 있는 경우에는, 물리 모델(22)을 활용할 수 있게 된다.
- [0109] 도 26에, 이상 검지, 및 이상 검지 후의 진단을 도시한다. 도 26에서, 설비로부터의 시계열 신호로부터, 지금까지의 설명한 방법에 의해, 이상을 검지한다. 동시에, 보수의 이벤트(알람이나 작업 실적 등) 등의 부대 정보를 취득하고, 이상을 고감도로 검지한다. 도 26에 도시한 바와 같이, 조기에 예조로서 발견할 수 있으면, 고장이 나 가동 정지로 되기 전에, 어떠한 대책을 쓰게 된다. 따라서, 이 예조에 기초하여, 이상 진단을 행한다.
- [0110] 이상 진단은, 예조를 내포하고 있는 센서를 특정하는 현상 진단과, 고장을 야기할 가능성이 있는 파츠(parts)를 특정하는 원인 진단으로 나누면 생각하기 쉽다. 이상 검지부에서는, 이상 진단부에 대하여, 이상의 유무라고

하는 신호 외에, 특징량에 관한 정보를 출력한다. 이상 진단부는, 이들의 정보에 기초하여 진단을 행한다.

- [0111] 도 27에, 하드웨어 구성을 도시한다. 이상 검지를 실행하는 프로세서에, 대상으로 하는 엔진 등의 센서 데이터를 입력하고, 결손값의 수복 등을 행하여, 데이터베이스 DB에 격납한다. 프로세서는, 관측 데이터, DB 데이터를 이용하여, 이상 검지를 행하고, 이상 검지 신호를 출력한다. 표시부에서는, 실시예에서 설명한 바와 같은 각종 표시를 행한다. 트렌드를 표시하는 것도 가능하게 한다.
- [0112] 데이터베이스 DB는, 숙련 엔지니어가 DB를 조작할 수 있다. 특히, 이상 사례나 대책 사례를 교시할 수 있어, 격납할 수 있다. (1) 학습 데이터(정상), (2) 이상 데이터, (3) 대책 내용이 격납된다. 데이터베이스 DB를, 숙련 엔지니어가 있는 구조로 함으로써, 세련된, 유용한 데이터베이스가 완성되게 된다. 데이터 조작은, 학습 데이터(개개의 데이터나 무게 중심 위치 등)를, 알람의 발생이나 부품 교환에 수반하여, 이동시킴으로써 행한다. 또한, 취득 데이터를 추가하는 것도 가능하다. 이상 데이터가 있으면, 데이터의 이동에, 일반화 벡터 양자화 등의 수법도 적용할 수 있다.
- [0113] 상기 실시예에서는, 엔진 등의 설비를 대상으로 설명하였지만, 시계열 신호와 같은 종류의 것이면, 대상에 구애 받지 않는다. 인체의 측정 데이터에도 적용 가능하다. 본 실시예를 따르면, 상태의 수, 천이의 횟수가 많아도, 대응 가능하다.
- [0114] 또한, 실시예에서 설명한 각 기능, 예를 들면 클러스터링, 주성분 분석이나, Wavelet 해석 등은, 반드시 실시한다고 하는 것이 아니라, 대상의 신호의 성질에 따라서, 적절하게 실시하면 된다.
- [0115] 클러스터링도, 시간 궤적뿐만 아니라, 혼합 분포에 대한 EM(Expectation-Maximization) 알고리즘이나 k-means 클러스터링 등을 포함하고, 데이터 마이닝 분야에서의 수법을 쓸 수 있는 것은 물론이다. 얻어진 클러스터는, 이를 대상으로 식별기를 적용하여도 되지만, 클러스터를 그루핑하여, 이를 대상으로 식별기를 적용하여도 된다. 가장 간단한 예는, 날마다의 관측 데이터가 속하는 클러스터와, 그것이 속하는 클러스터 이외로 나누는 것이다(도 10의 우측의 특징 공간에서 도시한 주목 데이터인 현 데이터와, 그것보다 시간적으로 전의 과거 데이터에 해당). 또한, 센서 신호(특징량)의 선택은, 래퍼법(예를 들면, backward stepwise selection에 의해, 모든 특징량이 있는 상태로부터, 가장 불필요한 특징을 하나씩 제거함) 등, 기존의 방법이 적용 가능하다.
- [0116] 또한, 식별기는, 몇 개의 식별기를 준비하고, 그들의 다수결을 취하는 것도 가능하다. 즉, 다른 식별기군을 이용한 앙상블(집단) 학습을 적용할 수 있다. 도 30에 그 구성예를 나타낸다. 예를 들면, 식별기(1)는 투영 거리법, 식별기(2)는 국소 부분 공간법, 식별기(3)는 선형 회귀법이라는 식인 것이다. 사례 데이터에 기초하는 것이면, 임의의 식별기가 적용 가능하다.
- [0117] 복수의 식별기를 사용하는 이유는, 식별기는 각각 다른 기준, 다른 대상 데이터 범위(세그먼트 분류나 그 통합에 의존)에서, 어긋남 상황을 구하기 위해, 그 결과에 미묘한 차이가 생기기 때문이다. 이 때문에, 다수결을 취해 안정화하거나, OR(어긋남값 그 자체, 즉 다치의 경우는 최대값 검출) 논리로, 어느 것인가의 식별기에서 이상이 검지되면 이상이 발생한 것으로서 출력하고, 이상을 남김없이 검지하려고 하거나, AND(다치의 경우에는 최소값 검출) 논리로, 어느 식별기에서도 동시에 이상이 검지되면 이상이 발생한 것으로서 출력하고, 오검지를 최소한으로 하는 식의, 상위 기준에 의해 식별기를 구성한다. 물론, 알람 신호, 부품 교환 등의 보전 정보 등의 정보를 가미하여, 상기 통합을 행하는 것도 가능한 것은 물론이다.
- [0118] 식별기 h1, h2, ...을 모두 동일한 식별기로 하고, 대상 데이터 범위(세그먼트 분류나 그 통합에 의존)를 바꿔서 학습하는 것도 가능하다. 예를 들면, 패턴 인식의 대표적 수법인 버깅이나 부스팅 등의 수법도 적용할 수 있다. 이 수법의 적용에 의해, 이상 검지에 관하여, 보다 높은 정해율을 확보할 수 있다. 여기서, 버깅은, N개의 데이터로부터 중복을 허용하여 데이터를 K개 취해(복원 추출), 이 K개를 바탕으로 1개째의 식별기 h1을 만들고, 또한 N개의 데이터로부터 중복을 허용하여 데이터를 K개 취해, 이 K개(1개째의 식별기와 내용물이 틀림)를 바탕으로 2개째의 학습기 h2를 만드는 것을 계속하고, 다른 데이터로부터 몇 개의 식별기를 만들고, 실제로 판별기로서 사용할 때에는 다수결을 취하는 방법이다.
- [0119] 부스팅(Adaboost라고 부르는 수법)은, N개의 데이터에 균등한 가중치 1/N을 우선은 할당, 1개째의 식별기 h1은 N개 모든 데이터를 이용하여 학습하고, 학습한 후, 데이터 N개에 관하여 정해율을 조사하고, 그것을 바탕으로 신뢰도 $\beta_1 (> 0)$ 을 구한다. 1개째의 식별기가 정해한 데이터의 가중치를 $\exp(-\beta_1)$ 배로 하여 가중치를 줄이고, 정해할 수 없었던 데이터의 가중치를 $\exp(\beta_1)$ 배로 하여 가중치를 늘린다.
- [0120] 2개째의 식별기 h2는 N개 모든 데이터를 이용하여 가중치 부여의 학습을 행하고, 신뢰도 $\beta_2 (> 0)$ 를 구하고, 데이터의 가중치를 갱신한다. 2개 모두 정해한 데이터의 가중치는 가법고, 2개 모두 잘못된 데이터의 가중치는

무거워진다. 이후, 이를 반복하여 M개의 식별기를 만들고, 실제로 판별기로서 사용할 때에는 신뢰도를 가진 다수결을 취하는 것이다. 이들의 방법을, 클러스터군을 대상으로 적용함으로써, 성능 향상을 기대할 수 있다.

[0121] 도 31에, 도 30에 도시한 식별기를 포함한, 이상 검지 전체의 구성예의 일례를 나타낸다. 궤적 클러스터링, 특징 선택 등을 거쳐, 앙상블 학습을 행하고, 높은 식별율을 달성하는 것이다. 식별기 출력의 통합의 방법은 상술한 바와 같지만, 어떤 클러스터에, 어떤 식별기를 적용할지라고 하는 조합은, 몇 개 존재한다. 예를 들면, 관측 데이터와는 다른 클러스터에 대하여 국소 부분 공간법을 적용하여, 다른 클러스터로부터의 어긋남 상황을 파악하고(추정값도 산출함), 관측 데이터와 동일한 클러스터에 대해서는 회귀 분석법을 적용하여, 자기 클러스터로부터의 어긋남 상황을 파악한다.

[0122] 그리고, 이들의 식별기 출력을 통합하여, 이상 판정을 행할 수 있다. 다른 클러스터로부터의 어긋남 상황을, 투영 거리법이나 회귀 분석법에 의해 행하는 것도 가능하다. 자기 클러스터로부터의 어긋남 상황을 투영 거리법에 의해 행할 수도 있다. 클러스터는, 알람 신호를 활용할 수 있는 경우에는, 알람 신호의 중증도 레벨에 따라서, 중증 알람 신호가 부가되어 있지 않은 클러스터를 대상으로 할 수도 있다.

[0123] 클러스터간의 유사성을 판단하고, 유사 클러스터를 통합하여, 이를 대상으로 할 수도 있다. 식별기 출력의 통합은, 어긋남값의 가산, 최대·최소, OR/AND 등의 스칼라 변환 처리이어도 되고, 식별기의 출력을 벡터적으로, 다차원으로서 취급할 수도 있다. 물론, 식별기 출력의 스케일은, 극력 일치시키는 것으로 한다.

[0124] 상술한 클러스터와의 관련을 갖게 하는 방법에 관하여, 또한, 타 클러스터를 대상으로 하여 제1보의 이상 검지를 행하고, 자기 클러스터의 데이터가 수집된 시점에서 자기 클러스터를 대상으로 하여 제2보의 이상 검지를 행하여도 된다. 이와 같이 하여, 고객에의 주의 환기를 촉구하는 것이 가능하게 된다. 이와 같이, 본 실시예는, 대상 클러스터군과의 관계에서, 신호의 움직임, behavior에, 보다 주목한 실시예라고 말할 수 있다.

[0125] 상술한 몇 개의 실시예에 관한 종합적 효과를 더 보충한다. 예를 들면, 발전 설비를 소유하고 있는 회사에서는, 기기의 보수 비용 삭감을 희망하고 있고, 보증 기간 중에 기기를 점검, 부품 교환을 실시하고 있다. 이것은 시간 베이스의 설비 보전이라고 불리어지고 있다. 그러나, 최근 기기의 상태를 보고, 부품 교환을 실시하는 상태 베이스의 보전으로 이행하고 있다. 상태 보전을 실시하기 위해서는, 기기의 정상·이상 데이터를 수집할 필요가 있고, 이 데이터의 양, 질이 상태 보전의 품질을 결정하게 된다. 그러나, 이상 데이터의 수집은, 드문 케이스도 많고, 대형의 설비로 될수록, 이상 데이터를 수집하는 것은 곤란하다. 따라서, 정상 데이터로부터, 어긋남값을 검출하는 것이 중요하게 된다. 상술한 몇 개의 실시예에 따르면,

[0126] 정상 데이터로부터, 이상을 검지할 수 있고, 데이터 수집이 불완전하여도 정밀도가 높은 이상 검지가 가능하게 되고, 이상 데이터가 포함되어 있어도, 이 영향을 허용할 수 있는 등의 직접적 효과 외에, 유저에게 있어서는, 현상을 이해하기 쉽고, 엔지니어의 지식을 활용할 수 있고, 물리 모델도 병용할 수 있다고 하는 부차적인 효과가 있다.

산업상 이용가능성

[0127] 플랜트, 설비의 이상 검지로서 이용할 수 있다.

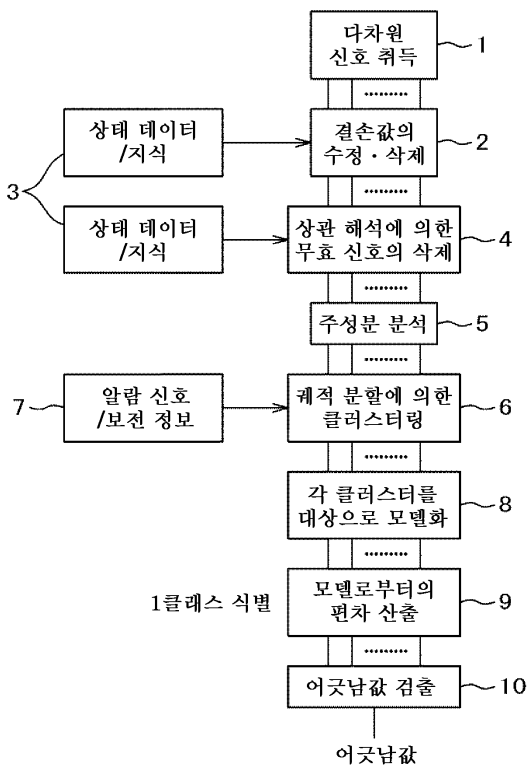
부호의 설명

- [0128] 1 : 다차원 신호 취득부
- 2 : 결손값의 수정·삭제부
- 3 : 상태 데이터·지식 데이터베이스
- 4 : 상관 해석에 의한 무효 신호의 삭제부
- 6 : 궤적 분할에 의한 클러스터링
- 7 : 알람 신호/보전 정보
- 8 : 각 클러스터를 대상으로 모델화부
- 9 : 모델로부터의 편차 산출부
- 10 : 어긋남값 검출부


- 11 : 각 클러스터를 특징 선택에서 모델화부
- 12 : 알람 신호 등의 일정 구간 누적 히스토그램
- 13 : 이상 특정부
- 14 : Wavelet(변환) 해석부
- 15 : 각 클러스터 궤적 산포도·상관 해석부
- 16 : 각 클러스터 매시간·주파수 해석부
- 17 : 학습 데이터
- 18 : 모델화(1)부
- 19 : 프로세서
- 20 : 표시기
- 21 : 데이터베이스
- 22 : 물리 모델

도면

도면1



도면2

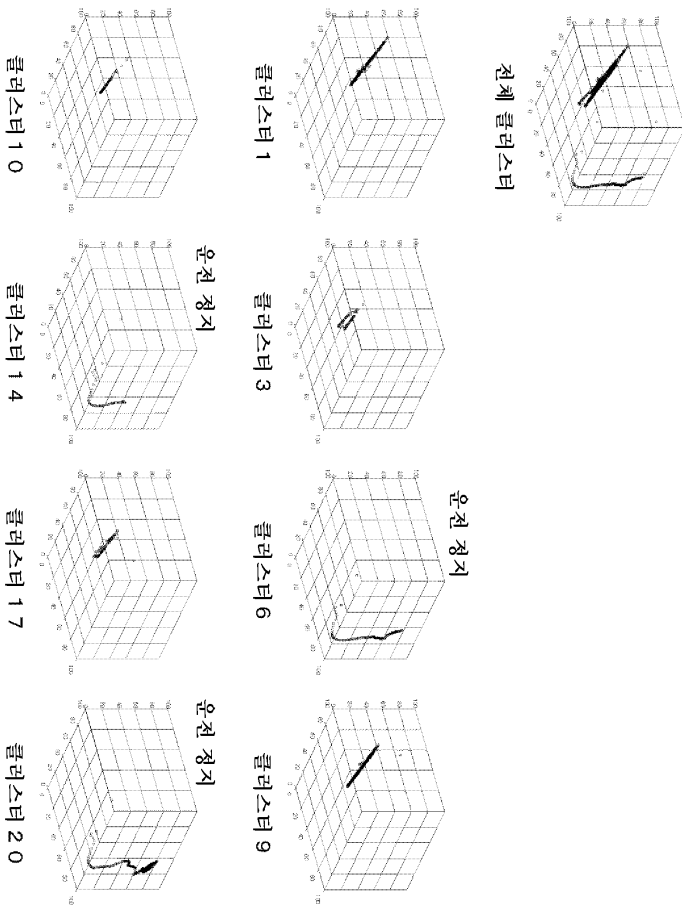


도면3


상관 행렬

	신호 1	신호 2	신호 3	신호 4
신호 1	1.000	-0.991	0.781	0.990
신호 2	-0.991	1.000	-0.814	-0.992
신호 3	0.781	-0.814	1.000	0.816
신호 4	0.990	-0.992	0.816	1.000


도면4




도면5




도면6



도면7




도면8




도면9

데이터의 움직임(궤적)을 가시화



특징 공간


데이터를 단순한 클러스터로 분할
클러스터마다 모델화



특징 공간


도면10

데이터의 변화 속도를 가시화



특징 공간


모델로부터의 편차를 산출



특징 공간


도면11

클러스터의 머지
모델로부터의 편차를 산출




특징 공간

개별 상태를 대상(콤팩트한 공간에서
표현하고, 놓치는 것을 방지)

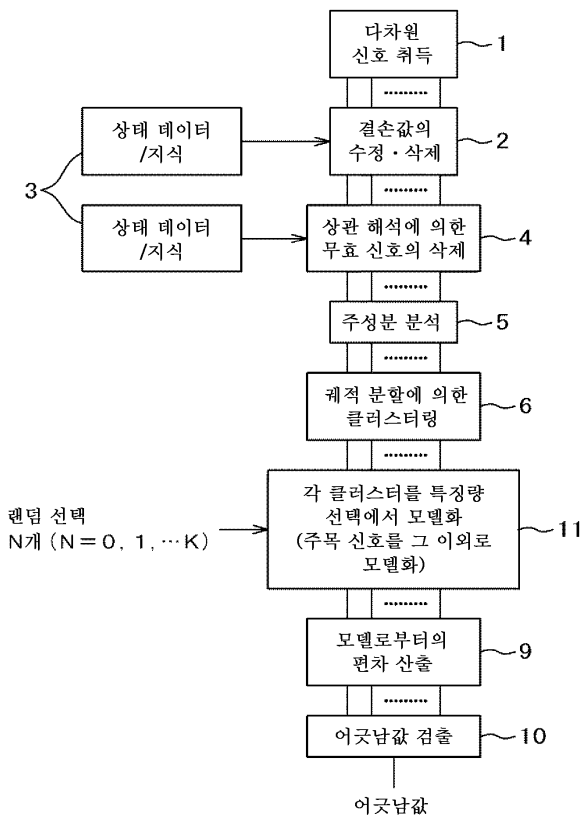


특징 공간

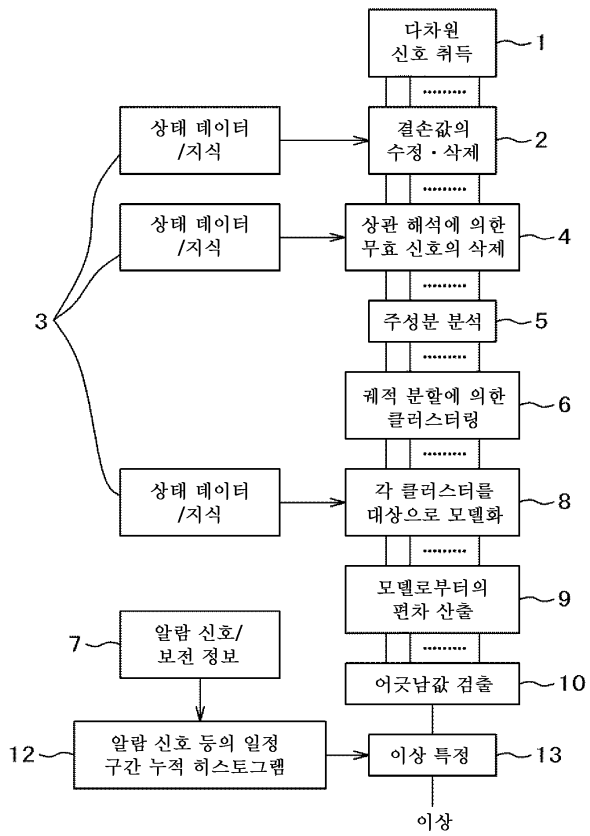
도면12



도면13




도면14




도면15

(a)

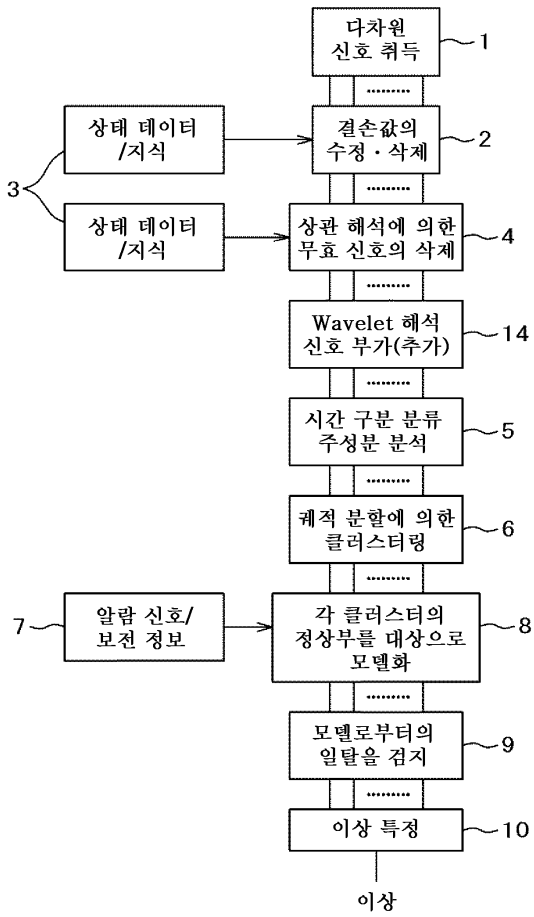


(b)



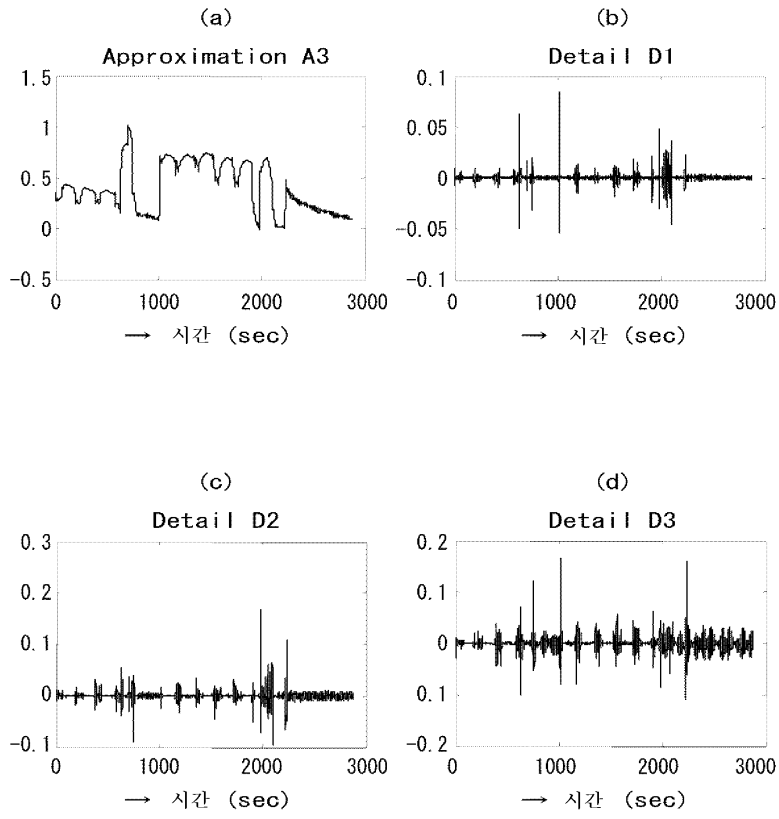
알람 신호와 어긋남값을 조합하여, 이상의 정도나 신뢰도를 부여

도면16

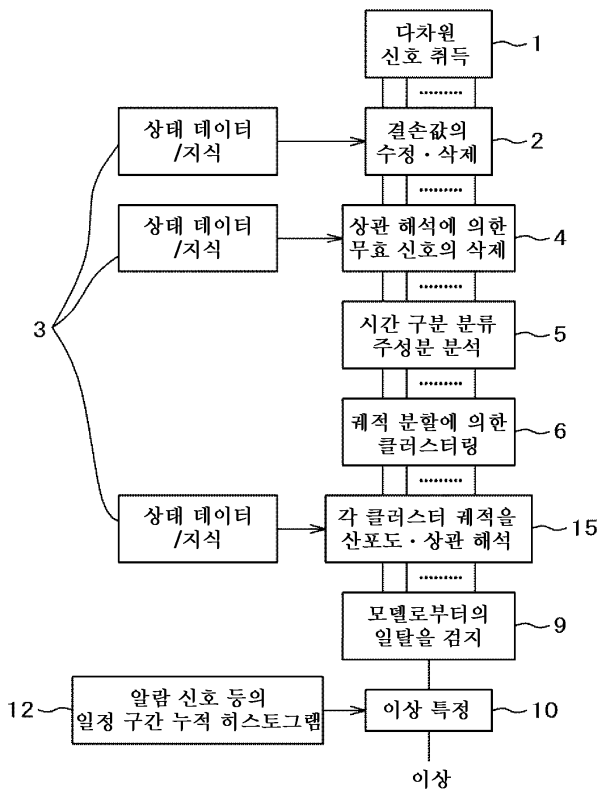


도면17

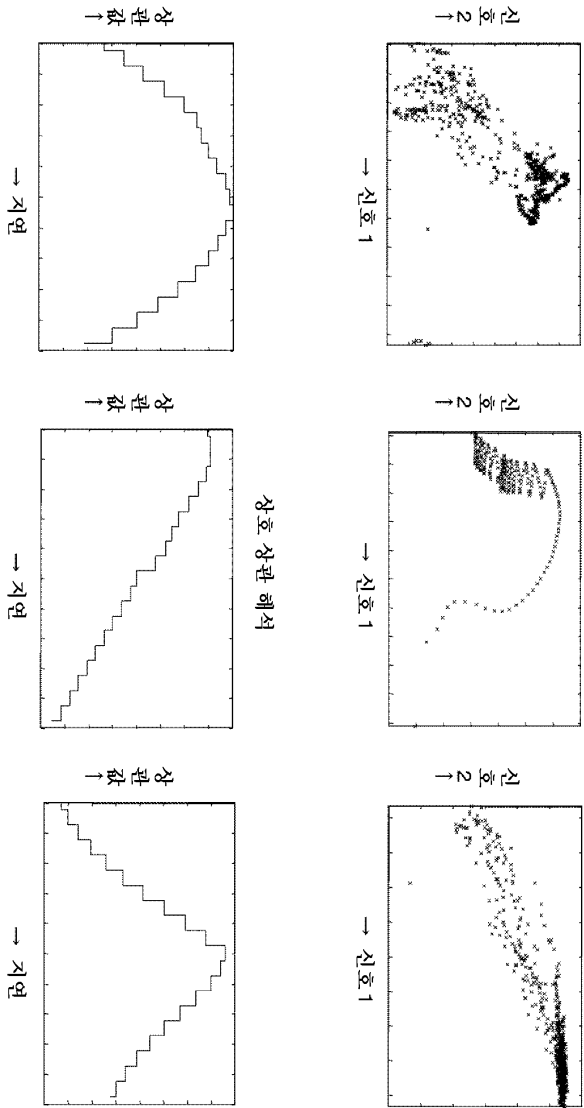
Wavelet 해석



도면18

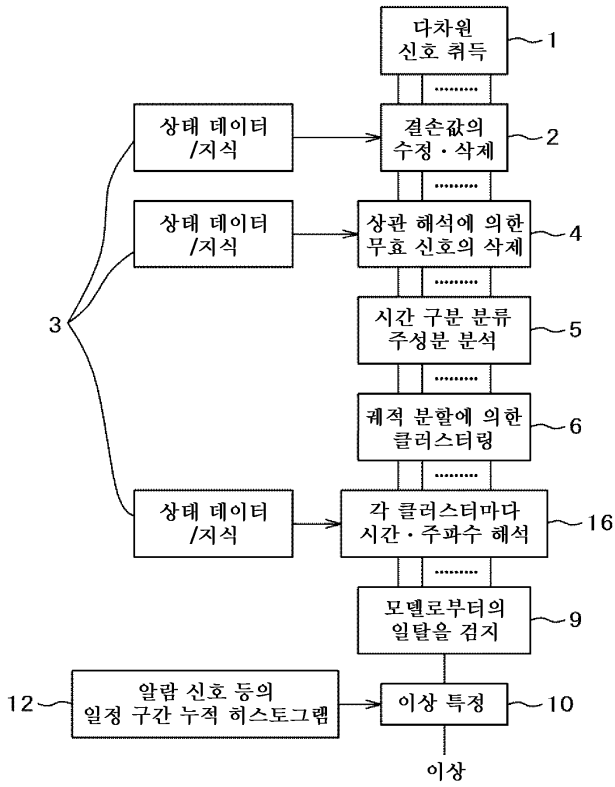


도면19



신호도 해석

도면20

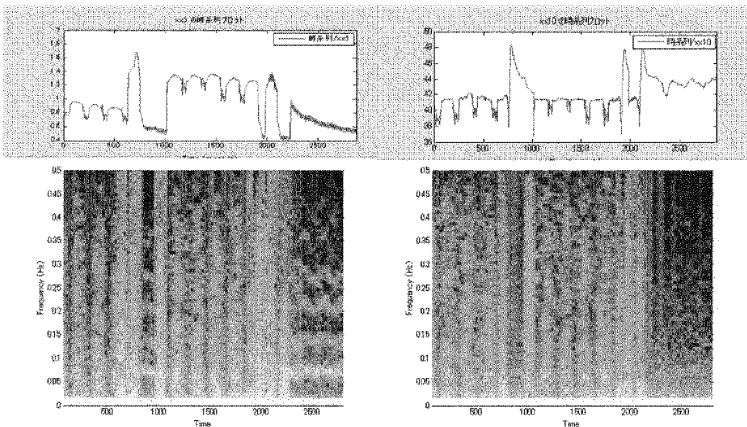


도면21

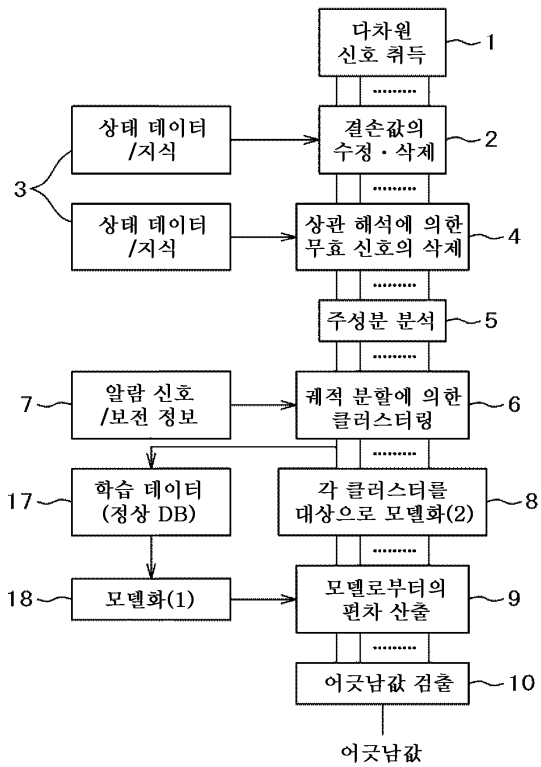
시간-주파수 해석

신호 3

신호 10

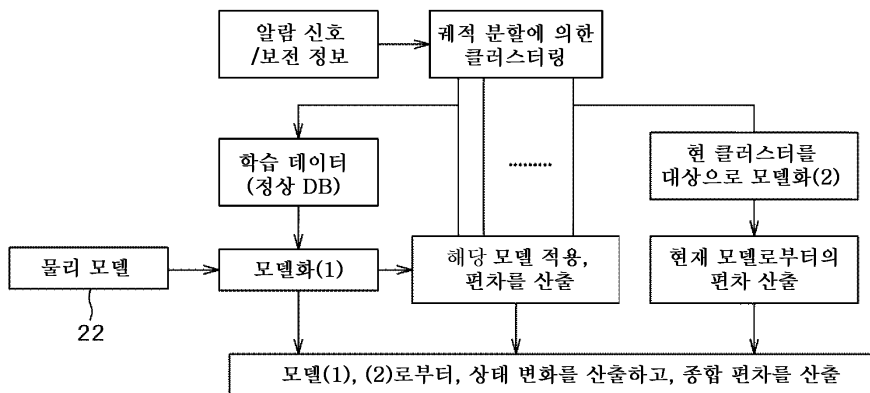


도면22




도면23

1. 해당 학습 모델(개별)과의 편차를 산출(응답성을 확보)
2. 현재 모델과의 편차를 산출(개별)
3. 학습 모델과 현재 모델로부터, 상태 변화를 산출
4. 종합 편차를 산출
5. 물리 모델을 모델화(1)에 짜넣기
(물리 모델은, 과거의 실적을 모델로서 짜넣기)



도면24




도면25

Wavelet 변환


다중 해상도 분류

스케일 1의 신호




스케일 : 값이 일정한 구간 폭
스케일의 역수 : 해상도


스케일 2의 신호



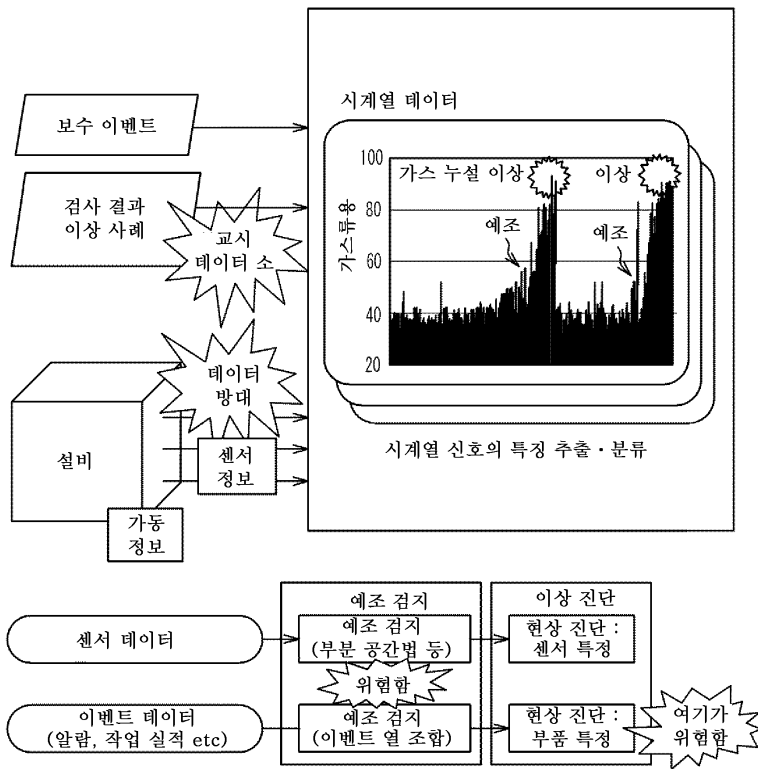
스케일 4의 신호



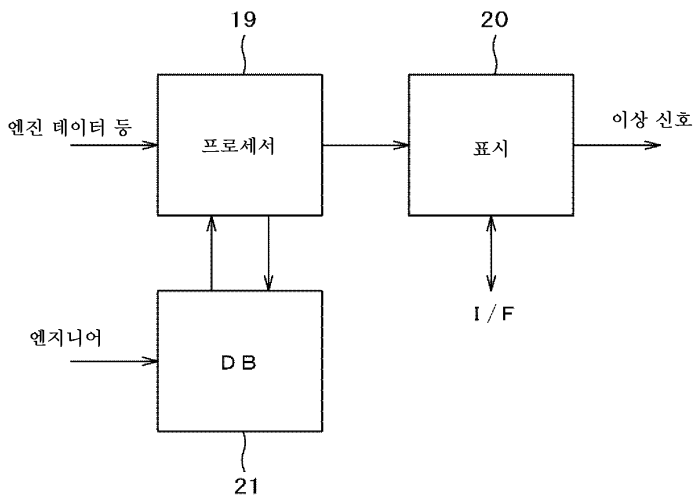
스케일 8의 신호




도면26




도면27




도면28



도면29



도면30



도면31

