(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2024-0172495
(43) 공개일자 2024년12월10일

(51) 국제특허분류(Int. Cl.)
G06N 3/045 (2023.01) *G06F 17/16* (2006.01)
G06N 3/047 (2023.01) *G06N 3/08* (2023.01)
G06N 3/09 (2023.01)
(52) CPC특허분류
G06N 3/045 (2023.01)
G06F 17/16 (2013.01)
(21) 출원번호 10-2023-0070904
(22) 출원일자 2023년06월01일
심사청구일자 2023년06월01일

(71) 출원인
고려대학교 산학협력단
서울특별시 성북구 안암로 145, 고려대학교 (안암동5가)
(72) 발명자
이남윤
서울특별시 성동구 금호로 110, 110동 1104호
최 건
서울특별시 성북구 고려대로11길 20
(74) 대리인
윤귀상

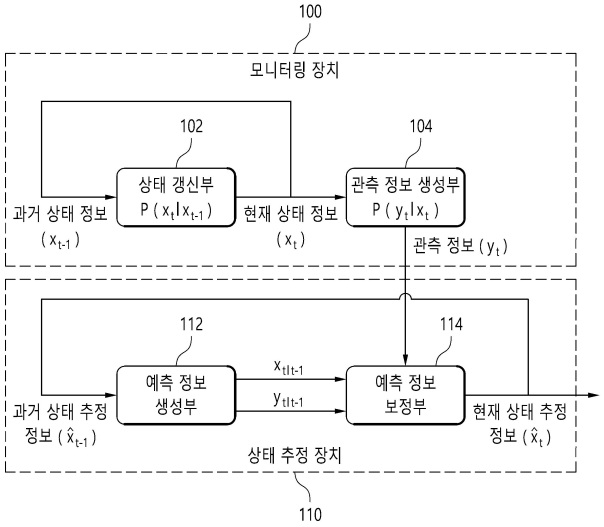
전체 청구항 수 : 총 12 항

(54) 발명의 명칭 **객체의 현재 상태를 추정하는 상태 추정 장치 및 방법**

(57) 요 약

본 발명은 객체를 동적으로 모사하기 위한 상태정보와 관측정보를 기반으로 상기 객체의 현재 상태를 추정하는 상태 추정 장치에 있어서, 상기 관측정보를 입력 받는 입력부와, 상기 관측 정보를 통해 현재상태 추정정보를 생성하는 현재상태 추정부를 포함하되, 상기 현재상태 추정부는, 상기 현재상태 추정정보를 한 타임 지연시킨 과거 상태 추정정보를 미리 마련된 상태 예측모델에 입력하여 상태 예측정보를 생성하는 예측정보 생성부와, 적어도 하나 이상의 인공신경망을 통해 상기 상태 예측정보의 보정 정도와 관련된 칼만이득행렬을 연산하고, 상기 관측정보와 상기 칼만이득행렬을 통해, 상기 상태 예측정보를 보정하여 상기 현재상태 추정정보를 생성하는 예측정보 보정부를 포함한다.

대 표 도 - 도1



(52) CPC특허분류
G06N 3/047 (2023.01)
G06N 3/088 (2023.01)
G06N 3/09 (2023.01)

명 세 서

청구범위

청구항 1

객체를 동적으로 모사하기 위한 상태정보와 관측정보를 기반으로 상기 객체의 현재 상태를 추정하는 상태 추정 장치에 있어서,

상기 관측정보를 입력 받는 입력부와,

상기 관측 정보를 통해 현재상태 추정정보를 생성하는 현재상태 추정부를 포함하되,

상기 현재상태 추정부는,

상기 현재상태 추정정보를 한 타임 지연시킨 과거상태 추정정보를 미리 마련된 상태 예측모델에 입력하여 상태 예측정보를 생성하는 예측정보 생성부와,

적어도 하나 이상의 인공신경망을 통해 상기 상태 예측정보의 보정 정도와 관련된 칼만이득행렬을 연산하고, 상기 관측정보와 상기 칼만이득행렬을 통해, 상기 상태 예측정보를 보정하여 상기 현재상태 추정정보를 생성하는 예측정보 보정부를 포함하는 상태 추정 장치.

청구항 2

제 1 항에 있어서,

상기 예측정보 생성부는,

상기 상태 예측정보를 미리 마련된 관측 예측모델에 입력하여 관측 예측정보를 더 생성하는 상태 추정 장치.

청구항 3

제 2 항에 있어서,

상기 예측정보 보정부는,

상기 상태 예측모델과 상기 관측 예측모델 간의 불일치, 상기 상태 예측정보 내의 잡음 및 상기 관측 예측정보 내의 잡음의 영향을 분리하기 위해 학습된 서로 다른 복수의 인공신경망의 출력 값을 통해 상기 칼만이득행렬을 연산하는, 상태 추정 장치.

청구항 4

제3항에 있어서,

상기 예측정보 보정부는, 상기 관측 예측모델의 자코비언 행렬과 상기 복수의 인공 신경망의 출력 값의 곱으로 상기 칼만이득행렬을 연산하는, 상태 추정 장치.

청구항 5

제4항에 있어서,

상기 인공 신경망은,

상기 상태 예측모델과 상기 관측 예측모델 간의 불일치를 고려한, 상기 현재상태 추정정보와 상기 과거상태 추정정보의 차이에 해당하는 벡터와 상기 관측정보와 상기 관측 예측정보 간의 차이에 해당하는 벡터,

상기 상태정보 내의 잡음 및 상기 관측정보 내의 잡음을 고려한, 상기 현재상태 추정정보와 상기 상태 예측정보

의 차이에 해당하는 벡터와 상기 관측정보와 상기 관측 예측정보의 차이에 해당하는 벡터, 또는

상기 상태 예측모델과 상기 관측 예측모델의 국소적 곡률을 고려한, 상기 관측 예측모델에 상기 상태 예측정보가 입력된 값과 상기 자코비언 행렬과 상기 상태 예측정보의 곱 간의 차이에 해당하는 벡터와 상기 자코비언 행렬 벡터를 입력 받는, 상태 추정 장치.

청구항 6

제4항에 있어서,

상기 인공 신경망은, 지도 학습의 경우 상기 관측정보와 상기 상태정보에 가장 근접한 상태 추정정보를 학습 데이터로 이용하고,

비지도 학습의 경우 상기 관측정보와 상기 관측 예측정보를 학습 데이터로 이용함을 특징으로 하는 상태 추정 장치.

청구항 7

객체를 동적으로 모사하기 위한 상태정보와 관측정보를 기반으로 상기 객체의 현재 상태를 추정하는 상태 추정 방법에 있어서,

상기 관측정보를 입력 받는 과정과,

상기 관측 정보를 통해 현재상태 추정정보를 생성하는 과정을 포함하되,

상기 현재상태 추정정보를 생성하는 과정은;

상기 객체의 현재상태 추정정보를 한 타임 지연시킨 과거상태 추정정보를 미리 마련된 상태 예측모델에 입력하여 상태 예측정보를 생성하는 과정과,

적어도 하나 이상의 인공신경망을 통해 상기 상태 예측정보의 보정 정도와 관련된 칼만이득행렬을 연산하고, 상기 관측정보와 상기 칼만이득행렬을 통해, 상기 상태 예측정보를 보정하여 상기 현재상태 추정정보를 생성하는 과정을 포함하는 상태 추정 방법.

청구항 8

제 7항에 있어서,

상기 상태 예측정보를 미리 마련된 관측 예측모델에 입력하여 관측 예측정보를 생성하는 과정을 더 포함하는 상태 추정 방법.

청구항 9

제 8항에 있어서,

상기 칼만이득행렬은, 상기 상태 예측모델과 상기 관측 예측모델 간의 불일치, 상기 상태 예측정보 내의 잡음 및 상기 관측 예측정보 내의 잡음의 영향을 분리하기 위해 학습된 서로 다른 복수의 인공신경망의 출력 값을 통해 연산됨을 특징으로 하는 상태 추정 방법.

청구항 10

제9항에 있어서,

상기 칼만이득행렬은, 상기 관측 예측모델의 자코비언 행렬과 상기 복수의 인공 신경망의 출력 값의 곱으로 연

산됨을 특징으로 하는 상태 추정 방법.

청구항 11

제10항에 있어서,

상기 인공 신경망은,

상기 상태 예측모델과 상기 관측 예측모델 간의 불일치를 고려한, 상기 현재상태 추정정보와 상기 과거상태 추정정보의 차이에 해당하는 벡터와 상기 관측정보와 상기 관측 예측정보 간의 차이에 해당하는 벡터,

상기 상태정보 내의 잡음 및 상기 관측정보 내의 잡음을 고려한, 상기 현재상태 추정정보와 상기 상태 예측정보의 차이에 해당하는 벡터와 상기 관측정보와 상기 관측 예측정보의 차이에 해당하는 벡터, 또는

상기 상태 예측모델과 상기 관측 예측모델의 국소적 곡률을 고려한, 상기 관측 예측모델에 상기 상태 예측정보가 입력된 값과 상기 자코비언 행렬과 상기 상태 예측정보의 곱 간의 차이에 해당하는 벡터와 상기 자코비언 행렬 벡터를 입력 받음을 특징으로 하는 상태 추정 방법.

청구항 12

제10항에 있어서,

상기 인공 신경망은,

지도 학습의 경우 상기 관측정보와 상기 상태정보에 가장 근접한 상태 추정정보를 학습 데이터로 이용하고,

비지도 학습의 경우 상기 관측정보와 상기 관측 예측정보를 학습 데이터로 이용함을 특징으로 하는 상태 추정 방법.

발명의 설명

기 술 분 야

[0001] 본 발명은 객체의 상태 추정(state estimation)에 관한 것으로, 보다 상세하게는 객체를 동적으로 모사하기 위한 상태정보와 관측정보를 기반으로 상기 객체의 현재 상태를 추정하는 방법 및 장치에 관한 것이다.

배 경 기 술

[0003] 상태를 가지는 동적 시스템에서의 잡음 섞인 관측(noisy observation)을 통한 상태 추정 문제는 신호 처리 기술의 중요한 분야이다. 레이더를 통한 타겟 추적, 자율주행 시스템을 위한 주변 환경 탐지 및 주행체의 상대적 위치 측정, 로봇의 SLAM(Simultaneous Localization and Mapping) 등의 문제가 동적 시스템에서의 상태 추정 문제로 모델링 될 수 있다. 이때, 칼만필터(Kalman Filter)는 가산 백색 가우시안 잡음(AWGN: Additive White Gaussian Noise)을 지닌 선형 동적 시스템의 재귀적 상태 추정을 위한 대표적인 알고리즘이다. 칼만필터는 동적 시스템의 정보를 이용한 상태 예측과 잡음 섞인 관측을 통한 예측 보정을 반복함으로써 상태를 추정한다. 일반적인 동적 시스템의 재귀적 상태 추정을 위해 비선형 동적 시스템을 위한 확장 칼만필터를 비롯한 칼만필터의 변형이 제안되었다.

[0004] 이와 함께, 모델 기반 심층 학습을 사용한 칼만넷(KalmanNet)을 이용한 재귀적 상태 추정 알고리즘이 모델 불일치에 의한 상태 추정 성능 열화를 줄이기 위한 방법으로 제안되었다. 칼만넷은 칼만필터의 계산 과정에서 모델 불일치가 영향을 주는 칼만이득(Kalman gain) 행렬 계산을 인공 신경망(DNN: Deep Neural Network)으로 대체하여 상태 추정을 수행한다. 이 접근 방식은 종래의 심층 학습 방법인 데이터만을 이용한 학습을 통해 인공 신경망을 학습한 경우에 비해 더 작은 규모의 신경망 및 적은 수의 데이터를 통해 모델 불일치가 없는 칼만 필터의 상태 추정 성능을 달성할 수 있다.

[0005] 그러나 칼만넷은 칼만이득 행렬에 영향을 주는 상태 변화 잡음, 관측 잡음, 그리고 비선형 잡음의 영향을 분리

하지 않고 한번에 학습한다. 따라서, 칼만넷은 비선형성이 큰 동적 시스템에서 잡음의 효과와 비선형성에 의한 효과를 분리하지 못하기 때문에 정확한 칼만이득 행렬을 학습하는데 어려움을 겪는다.

[0006] 이러한 문제를 해결하기 위해 비선형 동적 시스템에서도 정확한 칼만이득 행렬을 학습할 수 있는 알고리즘의 개발이 요구된다.

선행기술문헌

특허문헌

[0008] (특허문헌 0001) 한국 등록특허공보 제10-18295600000호

발명의 내용

해결하려는 과제

[0009] 본 발명은 상기와 같은 문제를 해결하기 위해 안출된 것으로, 본 발명의 목적은 객체의 현재 상태를 추정하는 장치 및 방법을 제공하는 것이다.

[0010] 또한 본 발명의 목적은 잡음의 발생원에 따른 칼만이득 행렬에의 영향을 분리하여 학습하는 심층 학습 기반의 분할 칼만넷 구조가 적용된 상태 추정 장치 및 이를 통한 방법을 제공하는 것이다.

과제의 해결 수단

[0012] 상기 목적을 달성하기 위한 본 발명의 일 실시예에 따른 객체를 동적으로 모사하기 위한 상태정보와 관측정보를 기반으로 상기 객체의 현재 상태를 추정하는 상태 추정 장치에 있어서, 상기 관측정보를 입력 받는 입력부와, 상기 관측 정보를 통해 현재상태 추정정보를 생성하는 현재상태 추정부를 포함하되, 상기 현재상태 추정부는, 상기 현재상태 추정정보를 한 타임 지연시킨 과거상태 추정정보를 미리 마련된 상태 예측모델에 입력하여 상태 예측정보를 생성하는 예측정보 생성부와, 적어도 하나 이상의 인공신경망을 통해 상기 상태 예측정보의 보정 정도와 관련된 칼만이득행렬을 연산하고, 상기 관측정보와 상기 칼만이득행렬을 통해, 상기 상태 예측정보를 보정하여 상기 현재상태 추정정보를 생성하는 예측정보 보정부를 포함한다.

[0013] 상기 목적을 달성하기 위한 본 발명의 일 실시예에 따른 객체를 동적으로 모사하기 위한 상태정보와 관측정보를 기반으로 상기 객체의 현재 상태를 추정하는 상태 추정 방법에 있어서, 상기 관측정보를 입력 받는 과정과, 상기 관측 정보를 통해 현재상태 추정정보를 생성하는 과정을 포함하되, 상기 현재상태 추정정보를 생성하는 과정은; 상기 객체의 현재상태 추정정보를 한 타임 지연시킨 과거상태 추정정보를 미리 마련된 상태 예측모델에 입력하여 상태 예측정보를 생성하는 과정과, 적어도 하나 이상의 인공신경망을 통해 상기 상태 예측정보의 보정 정도와 관련된 칼만이득행렬을 연산하고, 상기 관측정보와 상기 칼만이득행렬을 통해, 상기 상태 예측정보를 보정하여 상기 현재상태 추정정보를 생성하는 과정을 포함한다.

발명의 효과

[0015] 상술한 본 발명의 일측면에 따르면, 본 발명은 모델 기반 심층 학습을 통한 분할 칼만넷 구조가 적용된 상태 추정 장치 및 이를 통한 방법을 제공함으로써, 칼만넷에 비해 모델 불일치에 더욱 강인한 상태 추정 성능을 제공하는 효과가 있다.

[0016] 뿐만 아니라 모델 불일치에 의해 영향을 받는 칼만이득 행렬을 이루는 구성요소를 학습하는 과정에서 구성요소가 지배적으로 영향을 받는 잡음원의 잡음을 독립적으로 고려함으로써, 잡음원의 잡음 수준의 차이가 크거나 비선형성이 큰 시스템에서의 칼만넷 방법 대비 더 나은 상태 추정 성능을 제공하는 이점이 있다.

도면의 간단한 설명

[0018] 도 1은 본 발명의 실시예에 따른 객체의 현재 상태를 추정하는 시스템을 도시한 도면,

도 2는 본 발명의 실시예에 따른 상태 추정 장치의 내부 블록을 도시한 장치도,

도 3은 본 발명의 실시예에 따른 상태 추정 장치의 동작을 나타낸 순서도,

도 4는 선형 관측을 통한 등속 원운동 시스템에 대해 본 발명의 실시예에 따른 분할 칼만넷의 상태 추정 정확도와 확장 칼만필터, 칼만넷의 상태 추정 정확도를 비교한 그래프,

그리고, 도 5는 비선형 관측을 통한 등속 원운동 시스템에 대해 본 발명의 실시예에 따른 분할 칼만넷의 상태 추정 정확도와 확장 칼만필터, 칼만넷의 상태 추정 정확도를 비교한 그래프.

발명을 실시하기 위한 구체적인 내용

[0019] 후술하는 본 발명에 대한 상세한 설명은, 본 발명이 실시될 수 있는 특정 실시예를 예시로서 도시하는 첨부 도면을 참조한다. 이들 실시예는 당업자가 본 발명을 실시할 수 있기에 충분하도록 상세히 설명된다. 본 발명의 다양한 실시예는 서로 다르지만 상호 배타적일 필요는 없음이 이해되어야 한다. 예를 들어, 여기에 기재되어 있는 특정 형상, 구조 및 특성은 일 실시예와 관련하여 본 발명의 정신 및 범위를 벗어나지 않으면서 다른 실시예로 구현될 수 있다. 또한, 각각의 개시된 실시예 내의 개별 구성요소의 위치 또는 배치는 본 발명의 정신 및 범위를 벗어나지 않으면서 변경될 수 있음이 이해되어야 한다. 따라서, 후술하는 상세한 설명은 한정적인 의미로서 취하려는 것이 아니며, 본 발명의 범위는, 적절하게 설명된다면, 그 청구항들이 주장하는 것과 균등한 모든 범위와 더불어 첨부된 청구항에 의해서만 한정된다. 도면에서 유사한 참조부호는 여러 측면에 걸쳐서 동일하거나 유사한 기능을 지칭한다.

[0020] 본 발명에 따른 구성요소들은 물리적인 구분이 아니라 기능적인 구분에 의해서 정의되는 구성요소들로써 각각이 수행하는 기능들에 의해서 정의될 수 있다. 각각의 구성요소들은 하드웨어 또는 각각의 기능을 수행하는 프로그램 코드 및 프로세싱 유닛으로 구현될 수 있을 것이며, 두 개 이상의 구성요소의 기능이 하나의 구성요소에 포함되어 구현될 수도 있을 것이다. 따라서 이하의 실시예에서 구성요소에 부여되는 명칭은 각각의 구성요소를 물리적으로 구분하기 위한 것이 아니라 각각의 구성요소가 수행되는 대표적인 기능을 암시하기 위해서 부여된 것이며, 구성요소의 명칭에 의해서 본 발명의 기술적 사상이 한정되지 않는 것임에 유의하여야 한다.

[0021] 이하에서는 도면들을 참조하여 본 발명의 바람직한 실시예들을 보다 상세하게 설명하기로 한다.

[0022] 도 1 본 발명의 실시예에 따른 객체의 현재 상태를 추정하는 시스템을 도시한 도면이다.

[0023] 도 1을 참조하면, 객체의 상태정보를 모니터링하여 관측 정보를 생성하는 모니터링 장치(100)와 상기 객체의 상태 및 관측에 대한 예측정보를 상기 관측 정보로 수정하여 객체의 현재 상태를 추정하는 상태 추정 장치(110)를 포함하는 시스템을 가정한다. 또한 도시하지는 않았으나 상기 상태 추정 장치(110)는 상기 모니터링 장치(100)로부터 관측 정보를 입력 받는 입력부와 상기 객체의 현재상태 추정정보를 생성하는 현재상태 추정부로 구성된다고 가정한다.

[0024] 여기서 상기 객체는 일례로 레이더를 통해 추적되는 타겟 객체, 자율주행을 위한 주행체, 이동 로봇 등이 될 수 있으며, 도 1에 도시된 시스템은 일례로 레이더를 통한 타겟 추적 시스템, 자율주행을 위한 주변 환경 탐지 및 주행체의 상대적 위치 측정 시스템, 로봇의 SLAM 시스템 등에 적용될 수 있다.

[0025] 모니터링 장치(100)는 상태 갱신부(102) 및 관측 정보 생성부(104)를 포함하고, 상기 상태 추정 장치(110)의 현재상태 추정부는 예측정보 생성부(112) 및 예측정보 보정부(114)를 포함한다.

[0026] 상태 갱신부(102)는 객체의 과거(t-1 시점) 상태 정보 $\mathbf{x}_{t-1}$을 입력하여 현재(t 시점) 상태 정보 $\mathbf{x}_t$를 출력한다. 이때 객체의 현재 상태 정보 $\mathbf{x}_t$는 과거 상태 정보에 의해 결정적으로 정해지거나 특정 확률밀도함수 $P(\mathbf{x}_t|\mathbf{x}_{t-1})$에 따라 랜덤하게 정해질 수 있다.

[0027] 관측 정보 생성부(104)는 객체의 현재 상태 정보 $\mathbf{x}_t$를 입력하여 현재 상태에서 관측되는 관측 정보 $\mathbf{y}_t$를 출력한다. 이때 관측 정보 $\mathbf{y}_t$는 현재 상태에 따라 결정적으로 정해지거나 특정 확률밀도함수 $P(\mathbf{y}_t|\mathbf{x}_t)$에 따라 랜덤하게 정해질 수 있다. 이렇게 모니터링 장치(100)는 상태 정보와 관측 정보를 획득하고, 상기 상태 정보와

관측 정보를 기반으로 객체를 동적으로 모사한다.

[0028] 예측정보 생성부(112)는 현재 상태 추정 정보를 한 타임 지연시킨 과거 상태 추정 정보 $\hat{\mathbf{x}}_{t-1}$을 입력하여 현재 상태 예측 정보 $x_{t|t-1}$과 관측 예측 정보 $y_{t|t-1}$을 출력한다. 상기 현재 상태 예측 정보는 상기 과거 상태 추정 정보를 기반으로 현재 상태를 예측한 정보이고, 상기 관측 예측 정보는 상기 예측된 현재 상태에서 관측되는 정보이다.

[0029] 예측정보 보정부(114)는 예측정보 생성부(112)에서 출력되는 현재 상태 예측 정보 $x_{t|t-1}$ 및 관측 예측 정보 $y_{t|t-1}$과, 관측 정보 생성부(104)에서 출력되는 관측 정보 $\mathbf{y}_t$를 입력하여 객체의 현재 상태 추정 정보 $\hat{\mathbf{x}}_t$을 출력한다.

[0030] 이와 같이 상태 추정 장치(110)는 자신이 예측한 상태 예측 정보를 모니터링 장치(100)가 생성한 관측 정보를 이용하여 보정함으로써 객체의 현재 상태를 추정한다. 이하에서는 도 2를 통해 상태 추정 장치(110)에 대해 보다 상세히 설명하도록 한다.

[0031] 도 2는 본 발명의 실시예에 따른 상태 추정 장치의 내부 블록을 도시한 장치도이다.

[0032] 도 2를 참조하면, 도시된 상태 추정 장치(110)는 예측정보 생성부(112), 칼만이득 행렬 연산부(114-1) 및 상태 추정 정보 연산부(114-2)를 포함하며, 분할 칼만넷 구조를 적용하여 디자인될 수 있다. 상기 칼만이득 행렬 연산부(114-1) 및 상태 추정 정보 연산부(114-2)는 도 1의 예측정보 보정부(114)에 포함되는 상세 구성부이다.

[0033] 예측정보 생성부(112)는 상태 예측 모델을 이용하여 객체의 상태 예측 정보를 생성하고, 관측 예측 모델을 이용하여 관측 예측 정보를 생성한다. 하기 수학식 1은 상태 예측 모델을 나타낸 것이고, 하기 수학식 2는 관측 예측 모델을 나타낸 것이다.

수학식 1

[0034] $$\hat{\mathbf{x}}_{t|t-1} = \mathbf{f}\left(\mathbf{x}_{t-1}\right)$$

수학식 2

[0035] $$\mathbf{y}_{t|t-1} = \mathbf{h}\left(\mathbf{x}_t\right)$$

[0036] 수학식 1과 수학식 2에서 함수 $\mathbf{f}(\cdot)$와 $\mathbf{h}(\cdot)$는 미분 가능한 함수로 정해지며, 도 1의 모니터링 장치(100)의 사전 지식에 의해 정해질 수 있다. 예를 들어, 상태 변화의 랜덤성을 기술하는 확률밀도함수 $P\left(\mathbf{x}_t|\mathbf{x}_{t-1}\right)$와 관측 값의 랜덤성을 기술하는 확률밀도함수 $P\left(\mathbf{y}_t|\mathbf{x}_t\right)$가 각각 정규분포 $\mathcal{N}\left(\bar{\mathbf{f}}\left(\mathbf{x}_{t-1}\right), \mathbf{Q}\right)$와 $\mathcal{N}\left(\bar{\mathbf{g}}\left(\mathbf{x}_t\right), \mathbf{R}\right)$에 의해 주어진다고 가정하면, 상태 예측 모델 함수 $\mathbf{f}(\cdot)$와 관측 예측 모델 함수 $\mathbf{h}(\cdot)$는 각각 $\mathbf{f} = \bar{\mathbf{f}}$와 $\mathbf{h} = \bar{\mathbf{h}}$로 정의할 수 있다. 분할 칼만넷의 예측 함수로 확률밀도함수의 1차 모멘트에 해당하는 평균 값을 계산하는 함수를 사용할 수 있다.

[0037] 또한 예측정보 생성부(112)는 칼만이득 행렬 연산에 필요한 행렬인 관측 예측 모델 함수 $\mathbf{h}(\cdot)$의 자코비언 행렬 $\mathbf{H}_t$을 계산한다. 상기 자코비언 행렬은 하기 수식 3에 의해 주어진다.

수학식 3

[0038] $$\mathbf{H}_t = \frac{\partial \mathbf{h}}{\partial \mathbf{x}}\Big|_{\mathbf{x}=\hat{\mathbf{x}}_{t|t-1}}$$

[0039] 수학식 3에 따른 자코비언 행렬 $\mathbf{H}_t$은 관측 예측 모델 함수 $\mathbf{h}(\cdot)$의 도함수를 현재 상태 예측 정보인 $\hat{\mathbf{x}}_{t|t-1}$에서 평가한 행렬이다.

[0040] 상태 추정 정보 연산부(114-2)는 예측정보 생성부(112)에서 계산한 상태 예측 정보 $\hat{\mathbf{x}}_{t|t-1}$을 하기 수학식 4에 따라 수정한다.

수학식 4

[0041] $$\hat{\mathbf{x}}_t = \hat{\mathbf{x}}_{t|t-1} + \mathcal{G}_t(\Theta_1, \Theta_2, \mathbf{H}_t)\left(\mathbf{y}_t - \hat{\mathbf{y}}_{t|t-1}\right)$$

[0042] 즉 객체의 현재 상태 추정 정보 $\hat{\mathbf{x}}_t$을 얻기 위해, 도 1의 모니터링 장치(100)로부터 획득한 관측 정보 $\mathbf{y}_t$와 예측정보 생성부(112)로부터 획득한 관측 예측 정보 $\hat{\mathbf{y}}_{t|t-1}$의 차이에 해당하는 벡터를 칼만이득 행렬 연산부(114-1)에서 획득한 칼만이득 행렬 $\mathcal{G}_t(\Theta_1, \Theta_2, \mathbf{H}_t)$과 곱해서 얻은 벡터를 이용하여 예측정보 생성부(112)로부터 획득한 상태 예측 정보 $\hat{\mathbf{x}}_{t|t-1}$를 보정한다. 여기서 상기 칼만이득 행렬은 상기 상태 예측 정보의 보정 정도와 관련된다.

[0043] 한편, 칼만이득 행렬 연산부(114-1)는 확률밀도함수 $P(\mathbf{x}_t|\mathbf{x}_{t-1})$와 $P(\mathbf{y}_t|\mathbf{x}_t)$의 2차 모멘트에 해당하는 공분산 행렬(covariance matrix)를 사용하여, 칼만이득 행렬을 계산할 수 있다. 하지만 확률밀도함수의 공분산 행렬은 모니터링 장치(100)의 상태 갱신 및 관측 정보 생성 과정에서 발생하는 잡음 뿐만 아니라 상기 상태 및 관측 예측 모델 함수 $\mathbf{f}(\cdot)$와 $\mathbf{h}(\cdot)$의 모델 불일치에도 의존하므로, 공분산 행렬을 정확하게 알기는 어렵고 부정확한 공분산 행렬은 상태 추정 장치(110)의 상태 추정 성능을 저하시킨다.

[0044] 이에 본 발명의 실시예에 따른 칼만이득 행렬 연산부(114-1)는 인공 신경망을 사용해 칼만이득 행렬을 획득한다. 상기 칼만이득 행렬 연산부(114-1)는 두 개의 인공 신경망과 예측정보 생성부(112)로부터 획득한 자코비언 행렬 $\mathbf{H}_t$을 이용하여 칼만이득 행렬을 계산한다.

[0045] 특히 칼만이득 행렬 연산부(114-1)는 상태 예측 모델과 관측 예측 모델 간의 불일치, 상기 상태 예측 모델로부터 획득되는 상태 예측정보 내의 잡음 및 상기 관측 예측 모델로부터 획득되는 관측 예측정보 내의 잡음의 영향을 분리하기 위해 학습된 두 개의 인공신경망의 출력 값을 통해 칼만이득 행렬을 연산한다. 즉 칼만 이득 행렬은 관측 예측 모델의 자코비언 행렬과 적어도 두 개의 인공 신경망의 출력 값인 서로 다른 두 행렬의 곱으로 계산된다. 특히 칼만이득 행렬 연산부(114-1)를 구성하는 두 개의 인공 신경망의 출력 값을 $\mathcal{G}_t^1(\Theta_1)$와 $\mathcal{G}_t^2(\Theta_2)$라 가정할 때, 칼만이득 행렬은 하기 수학식 5와 같이 계산된다. 여기서 Θ_1와 Θ_2는 두 인공 신경망의 파라미터 값을 나타낸다.

수학식 5

[0046] $$\mathcal{G}_t(\Theta_1, \Theta_2, \mathbf{H}_t) = \mathcal{G}_t^1(\Theta_1)\mathbf{H}_t^\top \mathcal{G}_t^2(\Theta_2)$$

[0047] 수학식 5에서 알 수 있듯이, 본 발명의 실시예에서는 칼만이득 행렬의 구성요소를 별도의 인공 신경망을 사용하여 학습하고, 이러한 구조를 통해서 칼만이득 행렬을 한 번에 학습하는 칼만넷에 비해 잡음원의 잡음 수준의 차이가 크거나 비선형성이 큰 시스템에서 더 나은 상태 추정 성능을 제공할 수 있다.

[0048] 본 발명의 실시예에 따른 분할 칼만넷의 칼만이득 행렬 계산 방법의 이해를 돕기 위해 칼만필터의 칼만이득 행렬 계산 구조를 설명하면 다음과 같다. 일반적인 칼만필터의 칼만이득 행렬 $\mathbf{K}_t$는 하기 수학식 6 내지 수학식 8에 의해 계산된다.

수학식 6

[0049] $$\mathbf{K}_t = \mathbf{\Sigma}_{t|t-1}\mathbf{H}_t^\top \mathbf{S}_t^{-1}$$

수학식 7

[0050] $$\mathbf{\Sigma}_{t|t-1} = \mathbb{E}\left[(\mathbf{x}_t - \hat{\mathbf{x}}_{t|t-1})(\mathbf{x}_t - \hat{\mathbf{x}}_{t|t-1})^\top\right]$$

수학식 8

[0051] $$\mathbf{S}_t = \mathbb{E}\left[(\mathbf{y}_t - \hat{\mathbf{y}}_{t|t-1})(\mathbf{y}_t - \hat{\mathbf{y}}_{t|t-1})^\top\right]$$

[0052] 수학식 7에서 $\mathbf{\Sigma}_{t|t-1}$의 계산에는 상태 변화의 랜덤성을 기술하는 확률밀도함수 $P(\mathbf{x}_t|\mathbf{x}_{t-1})$의 공분산 행렬이 필요하고, 수학식 8에서 $\mathbf{S}_t$의 계산에는 관측 정보의 랜덤성을 기술하는 확률밀도함수 $P(\mathbf{y}_t|\mathbf{x}_t)$의 공분산 행렬이 필요하다. 이에 본 발명의 실시예에 따른 분할 칼만넷은 이를 인공 신경망으로 대체한다. 또한 분할 칼만넷은 수학식 5에서 볼 수 있듯이 각 공분산 행렬의 영향을 직접적으로 반영하기 위해 칼만필터의 칼만이득 행렬의 구성요소를 행렬 곱셈의 방식으로 조합하는 구조를 유지한다.

[0053] 칼만이득 행렬 연산부(114-1)를 구성하는 인공 신경망은 일례로 순환신경망(RNN: Recurrent Neural Network)을 사용할 수 있으며, 그 밖의 다양한 구조를 사용할 수도 있다. 순환신경망은 신경망의 내부 상태를 통해 신경망으로 입력된 과거의 정보를 기억하는 능력이 있다. 칼만이득 행렬의 계산에 사용되는 행렬 $\mathbf{\Sigma}_{t|t-1}$와 $\mathbf{S}_t$는 특정 시간 t의 상태라고 해석할 수 있으며, 이러한 상태는 각 이산 시간마다 하기 수학식 9 내지 수학식 11에 따라 변화한다.

수학식 9

[0054] $$\mathbf{\Sigma}_{t|t} = (\mathbf{I} - \mathbf{K}_t\mathbf{H}_t)\,\mathbf{\Sigma}_{t|t-1}$$

수학식 10

[0055] $$\mathbf{\Sigma}_{t|t-1} = \mathbf{F}_t\mathbf{\Sigma}_{t-1|t-1}\mathbf{F}_t^\top + \mathbf{Q}$$

수학식 11

[0056] $$\mathbf{S}_t = \mathbf{H}_t\mathbf{\Sigma}_{t|t-1}\mathbf{H}_t^\top + \mathbf{R}$$

[0057] 여기서 $\mathbf{Q}$와 $\mathbf{R}$은 각각 확률밀도함수 $P(\mathbf{x}_t|\mathbf{x}_{t-1})$와 $P(\mathbf{y}_t|\mathbf{x}_t)$의 공분산 행렬을 나타낸다. 그리고 $\mathbf{F}$는 상태 예측 모델 $\mathbf{f}(\cdot)$의 도함수를 과거 추정 상태인 $\hat{\mathbf{x}}_{t-1}$에서 평가한 행렬을 나타낸다. 따라서 본 발명의 실시예에서는 인공 신경망으로 내부 상태를 지닌 순환신경망을 사용하였다.

[0058] 인공 신경망의 입력의 선택은 인공 신경망의 출력 값의 학습에 필요한 정보를 담고 있어야 하므로 중요하다. 최

적 입력의 선택은 다음의 특성 1) 내지 3)을 고려하여 선택되며, 이렇게 선택된 입력을 사용하는 분할 칼만넷은 양호한 상태 추론 성능을 보여준다.

[0059] 1) 상태 예측 모델 $\mathbf{f}(\cdot)$와 관측 예측 모델$\mathbf{h}(\cdot)$ 간의 모델 불일치

[0060] 2) 상태정보 내의 잡음 및 관측정보 내의 잡음

[0061] 3) 상태 예측 모델 $\mathbf{f}(\cdot)$와 관측 예측 모델 $\mathbf{h}(\cdot)$의 국소적 곡률

[0062] 특성 1)을 고려한 입력은 일례로 $\hat{\mathbf{x}}_t - \hat{\mathbf{x}}_{t-1}$와 $\tilde{\mathbf{y}}_t = \mathbf{y}_t - \mathbf{y}_{t-1}$가 될 수 있다. 즉 객체의 현재 상태 추정 정보와 과거 상태 추정 정보의 차이에 해당하는 벡터가 칼만이득 행렬 연산부(114-1)의 인공 신경망 입력 1이되고, 객체의 현재 관측 정보와 과거 관측 정보 간의 차이에 해당하는 벡터가 칼만이득 행렬 연산부(114-1)의 인공 신경망 입력 2가 된다.

[0063] 특성 2)를 고려한 입력은 일례로 $\hat{\mathbf{x}}_t - \hat{\mathbf{x}}_{t|t-1}$와 $\mathbf{y}_t - \hat{\mathbf{y}}_{t|t-1}$가 될 수 있다. 즉 객체의 현재 상태 추정 정보와 현재 상태 예측 정보의 차이에 해당하는 벡터가 칼만이득 행렬 연산부(114-1)의 인공 신경망 입력 1이되고, 객체의 현재 관측 정보와 현재 관측 예측 정보의 차이에 해당하는 벡터가 칼만이득 행렬 연산부(114-1)의 인공 신경망 입력 2가 된다.

[0064] 특성 3)을 고려한 입력은 일례로 $\mathbf{h}\left(\hat{\mathbf{x}}_{t|t-1}\right) - \mathbf{H}_t\hat{\mathbf{x}}_{t|t-1}$와 $\mathbf{H}_t$가 될 수 있다. 즉 관측 예측 모델에 현재 상태 예측정보가 입력된 값과 자코비언 행렬과 상기 현재 상태 예측정보의 곱 간의 차이에 해당하는 벡터가 칼만이득 행렬 연산부(114-1)의 인공 신경망 입력 1이되고, 상기 자코비언 행렬이 칼만이득 행렬 연산부(114-1)의 인공 신경망 입력 2가 된다.

[0065] 또한 인공신경망의 학습을 위해서는 학습 데이터와 손실 함수가 필요하다. 인공신경망 학습 데이터는 일례로 지도 학습의 경우 객체의 관측 정보와 상기 객체의 상태 정보에 가장 근접한 상태 추정 정보를 이용하고, 비지도 학습의 경우 객체의 관측 정보와 관측 예측 모델을 통해 획득한 관측 예측 정보를 이용한다.

[0066] 또한 지도 학습의 경우 손실 함수는 객체의 상태 추정 정보와 학습 데이터로부터 획득한 객체의 상태정보에 가장 근접한 상태 추정 정보의 차이를 반영하는 평균 제곱 오차로 정의되고, 정의된 손실함수를 최소화하는 방향으로 지도 학습이 수행된다.

[0067] 비지도 학습의 경우 손실 함수는 관측 예측 모델을 통해 획득한 관측 예측 정보와 객체의 관측 정보의 차이를 반영하는 평균 제곱 오차로 정의되고, 정의된 손실함수를 최소화하는 방향으로 비지도 학습이 수행된다.

[0068] 학습 데이터 $\mathcal{D} = \left\{\left(\mathbf{X}^{(\ell)}, \mathbf{Y}^{(\ell)}\right)\right\}_{\ell=1}^{L}$는 L개의 상태 값/관측 값들의 경로로 이루어져 있다. ℓ번째 경로는 T_ℓ개의 데이터 샘플 $\left(\mathbf{X}^{(\ell)}, \mathbf{Y}^{(\ell)}\right)$로 이루어져 있다. 여기서 각 데이터 샘플은 $\mathbf{X}^{(\ell)} = \left[\mathbf{x}_1^{(\ell)}, \mathbf{x}_2^{(\ell)}, \ldots, \mathbf{x}_{T_\ell}^{(\ell)}\right]$와 $\mathbf{Y}^{(\ell)} = \left[\mathbf{y}_1^{(\ell)}, \mathbf{y}_2^{(\ell)}, \ldots, \mathbf{y}_{T_\ell}^{(\ell)}\right]$로 구성되어 있다. 이를 이용해 하기 수학식 12와 같이 경험적 손실 함수를 정의할 수 있다. 수학식 12에 정의한 손실 함수는 하나의 예로서 정의한 것이며, 손실 함수의 형태는 분할 칼만넷이 사용되는 환경에 따라 그에 적합하게 정의될 수 있다.

수학식 12

[0069]
$$\mathcal{L}(\Theta_1, \Theta_2) = \frac{1}{L}\sum_{\ell=1}^{L}\frac{1}{T_\ell}\sum_{t=1}^{T_\ell}\left\|\mathbf{x}_t^{(\ell)} - \hat{\mathbf{x}}_{t|t}\left(\mathbf{y}_t^{(\ell)}; \mathcal{G}_t(\Theta_1, \Theta_2, \mathbf{H}_t)\right)\right\|_2^2.$$

[0070] 상기 학습 데이터와 경험적 손실 함수를 사용하여 인공 신경망을 수학식 12를 최소화하는 방향으로, 파라미터 $\boldsymbol{\Theta}_1$와 $\boldsymbol{\Theta}_2$를 최적화할 수 있다. 이를 위해 수학식 12의 손실 함수를 하기 수학식 13 및 수학식 14의 연쇄 법칙과 수학식 15의 미분 값을 이용하여 인공 신경망 파라미터에 대해 미분할 수 있다.

수학식 13

[0071] $$\frac{\partial \mathcal{L}(\Theta_1, \bar{\Theta}_2)}{\partial \Theta_1} = \frac{\partial \mathcal{L}(\Theta_1, \bar{\Theta}_2)}{\partial \mathcal{G}_t(\Theta_1, \bar{\Theta}_2, \mathbf{H}_t)} \frac{\partial \mathcal{G}_t^1(\Theta_1)}{\partial \Theta_1} \mathbf{H}_t \mathcal{G}_t^2(\bar{\Theta}_2)$$

수학식 14

[0072] $$\frac{\partial \mathcal{L}(\bar{\Theta}_1, \Theta_2)}{\partial \Theta_2} = \frac{\partial \mathcal{L}(\bar{\Theta}_1, \Theta_2)}{\partial \mathcal{G}_t(\bar{\Theta}_1, \Theta_2, \mathbf{H}_t)} \mathcal{G}_t^1(\bar{\Theta}_1) \mathbf{H}_t \frac{\partial \mathcal{G}_t^2(\Theta_2)}{\partial \Theta_2}$$

수학식 15

[0073] $$\begin{aligned} &\frac{\partial \mathcal{L}(\Theta_1, \Theta_2)}{\partial \mathcal{G}_t(\Theta_1, \Theta_2, \mathbf{H}_t)} \\ &= \frac{1}{LT_\ell} \sum_{\ell=1}^{L} \sum_{t=1}^{T_\ell} \frac{\partial \left\| \Delta \mathbf{x}_t^{(\ell)} - \mathcal{G}_t(\Theta_1, \Theta_2, \mathbf{H}_t) \Delta \mathbf{y}_t^{(\ell)} \right\|_2^2}{\partial \mathcal{G}_t(\Theta_1, \Theta_2, \mathbf{H}_t)} \\ &= \frac{2}{LT_\ell} \sum_{\ell=1}^{L} \sum_{t=1}^{T_\ell} \left(\mathcal{G}_t(\Theta_1, \Theta_2, \mathbf{H}_t) \Delta \mathbf{y}_t^{(\ell)} - \Delta \mathbf{x}_t^{(\ell)} \right) \left(\Delta \mathbf{y}_t^{(\ell)} \right)^\top \end{aligned}$$

[0074] 여기서 $\Delta \mathbf{x}_t^{(\ell)} = \mathbf{x}_t^{(\ell)} - \hat{\mathbf{x}}_{t|t-1}^{(\ell)}$ 이고, $\Delta \mathbf{y}_t^{(\ell)} = \mathbf{y}_t^{(\ell)} - \hat{\mathbf{y}}_{t|t-1}^{(\ell)}$ 이다.

[0075] 상기 미분 값을 이용하여 파라미터를 최적화하기 위해 확률적 경사 하강법(SGD: Stochastic Gradient Descent) 등의 알고리즘을 이용할 수 있다. 또한, 파라미터 Θ_2를 고정하고 수학식 13을 0으로 만드는 방향으로 확률적 경사 하강법을 적용한 뒤, 파라미터 Θ_1을 고정하고 수학식 14를 0으로 만드는 방향으로 확률적 경사 하강법을 적용하는 과정을 반복하는 최적화 방법을 사용할 수 있다.

[0076] 먼저, 선형 등속 원운동 시스템의 상태 변화와 관측 데이터는 하기 수학식 16 및 수학식 17에 따라 주어진다.

수학식 16

[0077] $$\mathbf{x}_{t+1} = \begin{bmatrix} \cos\theta & -\sin\theta \\ \sin\theta & \cos\theta \end{bmatrix} \mathbf{x}_t + \mathbf{w}_t$$

수학식 17

[0078] $$\mathbf{y}_t = \mathbf{x}_t + \mathbf{v}_t$$

[0079] 여기서 $\mathbf{w}_t$와 $\mathbf{v}_t$는 각각 다변량 정규분포 확률밀도함수 $\mathcal{N}\left(0, 10^{-3}\mathbf{I}\right)$와 $\mathcal{N}\left(0, 10^{-3}\nu\mathbf{I}\right)$를 따르는 확률 벡터를 나타낸다. 또한 θ는 이산 시간에 따른 회전 각도를 라디안 단위로 나타낸 것으로 상태 추정 알고리즘이 사전에 알고 있는 값이라고 가정한다. ν는 상태 변화와 관측 데이터의 잡음의 정도를 조절하기 위해 도입한 변수를 나타낸다.

[0080] 도 3은 본 발명의 실시예에 따른 상태 추정 장치의 동작을 나타낸 순서도이다.

[0081] 도 3을 참조하면, S302에서 상태 추정 장치는 객체의 현재상태 추정정보를 한 타임 지연시킨 과거상태 추정정보를 미리 마련된 상태 예측 모델에 입력하여 현재 상태 예측 정보를 생성하고 S304로 진행한다.

[0082] S304에서 상태 추정 장치는 S302에서 생성한 현재 상태 예측 정보를 미리 마련된 관측 예측 모델에 입력하여 현재 관측 예측 정보를 생성하고 S306으로 진행한다.

[0083] S306에서 상태 추정 장치는 적어도 하나 이상의 인공신경망을 통해 상태 예측 정보의 보정 정도와 관련된 칼만 이득 행렬을 연산하고 S308로 진행한다.

[0084] S308에서 상태 추정 장치는 S302에서 생성한 현재 상태 예측 정보를 S306에서 연산한 칼만 이득 행렬로 보정하여 객체의 현재 상태 추정 정보를 생성한다.

[0085] 도 4는 선형 관측을 통한 등속 원운동 시스템에 대해 본 발명의 실시예에 따른 분할 칼만넷의 상태 추정 정확도와 확장 칼만필터, 칼만넷의 상태 추정 정확도를 비교한 그래프이다.

[0086] 도 4를 참조하면, 도시된 그래프는 모델 불일치가 없을 때 이론적으로 최소 평균 제곱 오차(MMSE: Minimum Mean Square Error)를 산출하는 알고리즘의 확장 칼만필터(EKF: Extended Kalman Filter)와 모델 불일치의 영향을 데이터를 통해 제거하는 칼만넷의 ν 변화에 따른 평균 제곱 오차(MSE: Mean Square Error)를 본 발명의 실시예에 따른 분할 칼만넷의 MSE와 비교한 그래프이다. 여기서 ν는 상태 변화와 관측 데이터의 잡음의 정도를 나타낸다.

[0087] 두 잡음의 영향이 비슷할 때, 즉 ν가 작을 때는 모든 알고리즘이 최소 평균 제곱 오차를 내는 상태 추정을 수행하는 것을 확인할 수 있다. 하지만 관측 데이터의 잡음이 커질 때, 즉 ν가 클 때는 본 발명의 실시예에 따른 분할 칼만넷은 잡음의 공분산 행렬에 대한 정보를 사용하지 않고 최소 평균 제곱 오차를 내는 상태 추정을 수행하지만, 확장 칼만필터와 칼만넷은 그렇지 못한 것을 확인할 수 있다.

[0088] 도 5는 비선형 관측을 통한 등속 원운동 시스템에 대해 본 발명의 실시예에 따른 분할 칼만넷의 상태 추정 정확도와 확장 칼만필터, 칼만넷의 상태 추정 정확도를 비교한 그래프이다.

[0089] 도 5를 참조하면, 비선형 관측을 통한 등속 원운동 시스템의 상태 변화와 관측 데이터는 각각 하기 수학식 18 및 수학식 19에 따라 주어진다.

수학식 18

[0090] $$\mathbf{x}_{t+1} = \begin{bmatrix} \cos\theta & -\sin\theta \\ \sin\theta & \cos\theta \end{bmatrix} \mathbf{x}_t + \mathbf{w}_t$$

수학식 19

[0091] $$\mathbf{y}_t = \left[\|\mathbf{x}_t\|_2^2 \quad \text{atan2}(\mathbf{x}_t) \right]^\top + \mathbf{v}_t$$

[0092] 여기서 $\text{atan2}(\cdot)$는 x축과 상태 벡터 간의 각도를 유클리드 평면 상에서 라디안으로 출력하는 함수를 나타낸다. 그리고 $\mathbf{w}_t$와 $\mathbf{v}_t$는 각각 다변량 정규분포 확률밀도함수 $\mathcal{N}\left(0, 10^{-3}\mathbf{I}\right)$와 $\mathcal{N}\left(0, 10^{-3}\nu\mathbf{I}\right)$를 따르는 확률 벡터를 나타낸다. 또한 θ는 이산 시간에 따른 회전 각도를 라디안 단위로 나타낸 것으로, 상태 추정 알고리즘이 사전에 알고 있다고 가정한다. ν는 상태 변화와 관측 데이터의 잡음의 정도를 조절하기 위해 도입한 변수를 나타낸다.

[0093] 도 4 및 도 5에서는 본 발명의 실시예에 따른 분할 칼만넷의 효과를 확인하기 위해, 일반적인 상태 추정 알고리

즘의 확장 칼만필터와 칼만넷의 MSE를 분할 칼만넷의 MSE와 ν 축 상에서 비교하였다.

[0094] 비선형 관측 데이터가 주어진 경우 확장 칼만필터는 더 이상 최소의 평균 제곱 오차를 내는 상태 추정을 하지 못하고, 특히 두 잡음의 영향이 비슷할 때, 즉 ν가 작을 때는 칼만넷과 분할 칼만넷이 잡음의 공분산 행렬을 정확히 사용한 확장 칼만필터의 상태 추정 성능을 뛰어넘는 것을 확인할 수 있다. 특히 분할 칼만넷이 칼만넷보다 뛰어난 상태 추정 성능을 보여주는데, 이는 분할 칼만넷이 칼만넷과는 달리 칼만이득 행렬을 계산할 때 관측 모형의 국소적 형태의 정보를 자코비언 행렬과 선형화 에러를 통해 추가적으로 고려하는 것에서 기인한다.

[0095] 관측 데이터의 잡음이 커질 때, 즉 ν가 클 때는 칼만넷은 선형 데이터 관측의 경우와 같이 칼만이득 행렬을 학습하는데 실패하지만, 본 발명의 실시예에 따른 분할 칼만넷은 잡음의 공분산 행렬을 정확히 사용하는 확장 칼만필터의 상태 추정 성능에 근접하는 상태 추정 성능을 보여준다. 이를 통해, 본 발명의 실시예에 따른 분할 칼만넷이 다양한 잡음원에 따른 잡음의 영향을 일반적인 알고리즘들에 비해 효과적으로 처리하는 것을 확인할 수 있다.

[0096] 이와 같은 본 발명에서 제안하는 객체의 현재 상태 추정 방법은 다양한 컴퓨터 구성요소를 통하여 수행될 수 있는 프로그램 명령어의 형태로 구현되어 컴퓨터 판독 가능한 기록 매체에 기록될 수 있다. 상기 컴퓨터 판독 가능한 기록 매체는 프로그램 명령어, 데이터 파일, 데이터 구조 등을 단독으로 또는 조합하여 포함할 수 있다.

[0097] 상기 컴퓨터 판독 가능한 기록 매체에 기록되는 프로그램 명령어는 본 발명을 위하여 특별히 설계되고 구성된 것들이거나 컴퓨터 소프트웨어 분야의 당업자에게 공지되어 사용 가능한 것일 수도 있다.

[0098] 컴퓨터 판독 가능한 기록 매체의 예에는, 하드 디스크, 플로피 디스크 및 자기 테이프와 같은 자기 매체, CD-ROM, DVD 와 같은 광기록 매체, 플롭티컬 디스크(floptical disk)와 같은 자기-광 매체(magneto-optical media), 및 ROM, RAM, 플래시 메모리 등과 같은 프로그램 명령어를 저장하고 수행하도록 특별히 구성된 하드웨어 장치가 포함된다.

[0099] 프로그램 명령어의 예에는, 컴파일러에 의해 만들어지는 것과 같은 기계어 코드뿐만 아니라 인터프리터 등을 사용해서 컴퓨터에 의해서 실행될 수 있는 고급 언어 코드도 포함된다. 상기 하드웨어 장치는 본 발명에 따른 처리를 수행하기 위해 하나 이상의 소프트웨어 모듈로서 작동하도록 구성될 수 있으며, 그 역도 마찬가지이다.

[0100] 이상에서는 본 발명의 다양한 실시예에 대하여 도시하고 설명하였지만, 본 발명은 상술한 특정의 실시예에 한정되지 아니하며, 청구범위에서 청구하는 본 발명의 요지를 벗어남이 없이 당해 발명이 속하는 기술분야에서 통상의 지식을 가진 자에 의해 다양한 변형실시가 가능한 것은 물론이고, 이러한 변형실시들은 본 발명의 기술적 사상이나 전망으로부터 개별적으로 이해되어져서는 안될 것이다.

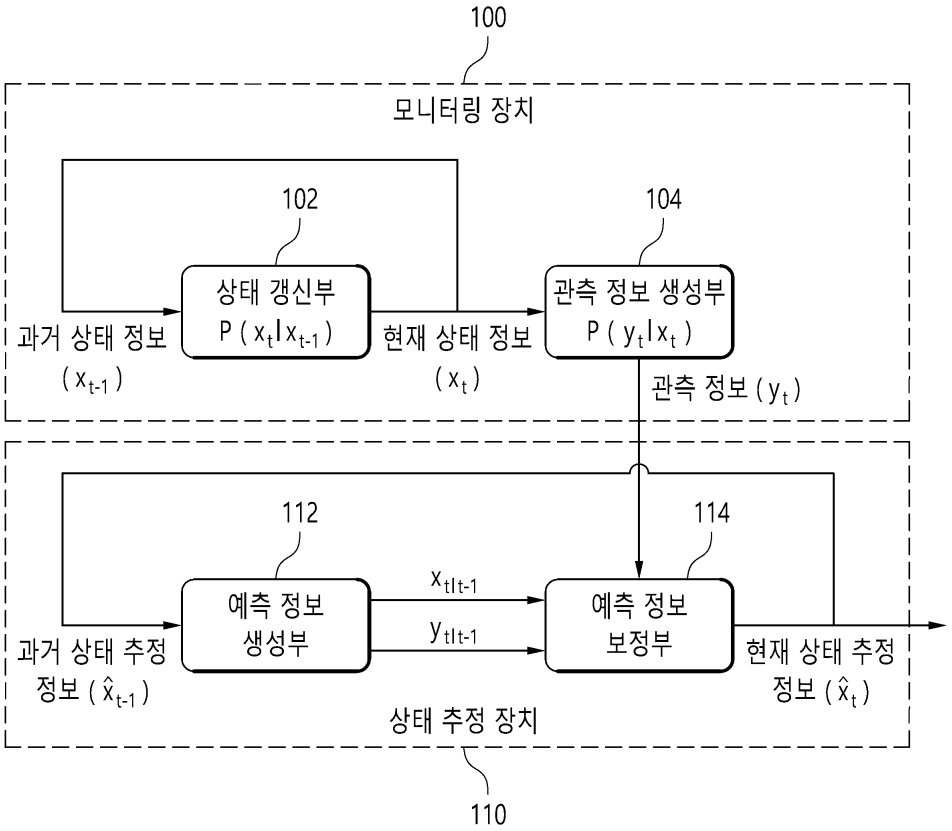
부호의 설명

[0102] 114-1: 칼만이득 행렬 연산부

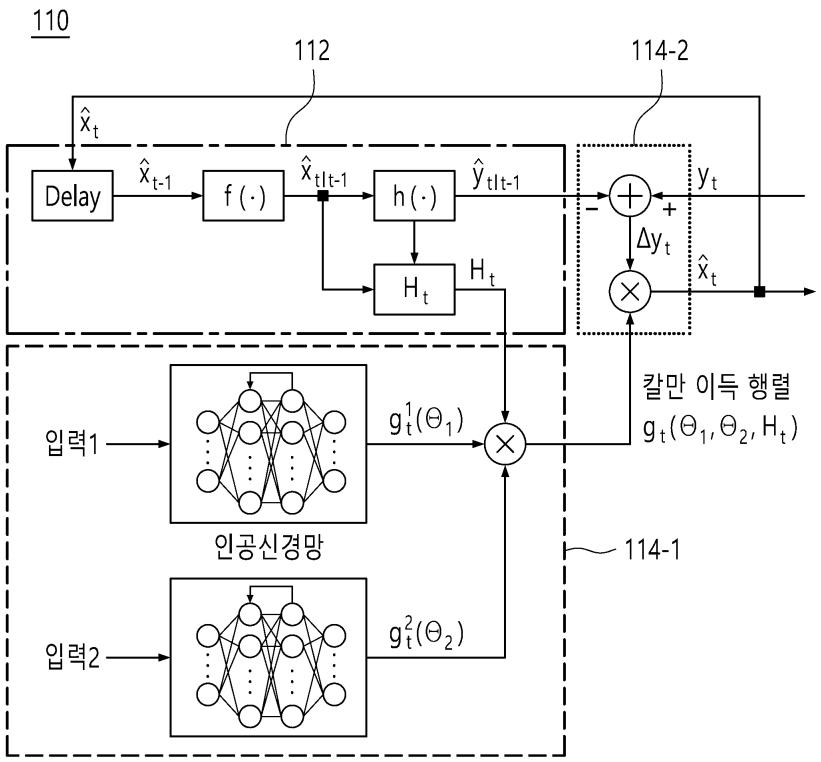
114-2: 상태추정정보 연산부

도면

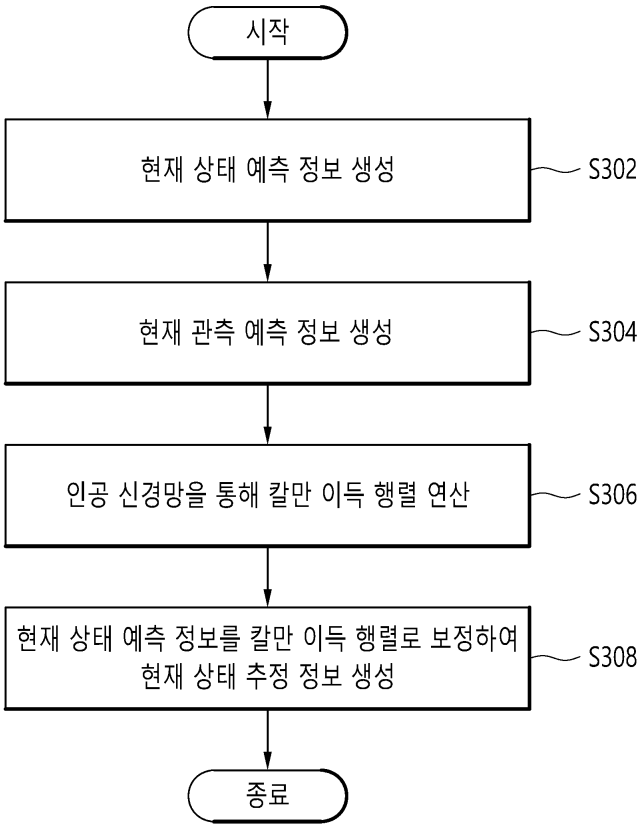
도면1


100
모니터링 장치
102
상태 갱신부
P (x_t | x_{t-1})
104
관측 정보 생성부
P (y_t | x_t)
과거 상태 정보
(x_{t-1})
현재 상태 정보
(x_t)
관측 정보 (y_t)
112
예측 정보
생성부
$x_{t|t-1}$
$y_{t|t-1}$
114
예측 정보
보정부
과거 상태 추정
정보 ($\hat{x}_{t-1}$)
현재 상태 추정
정보 ($\hat{x}_t$)
상태 추정 장치
110

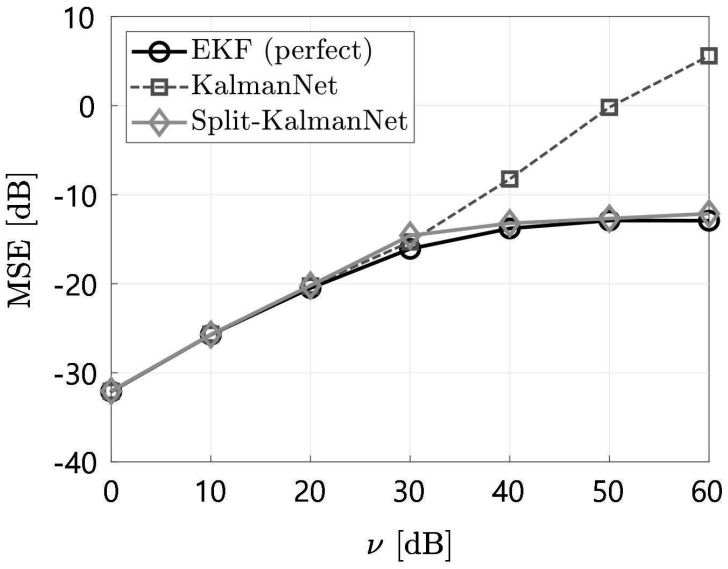
도면2


110
112
114-2
$\hat{x}_t$
Delay
$\hat{x}_{t-1}$
f (·)
$\hat{x}_{t|t-1}$
h (·)
$\hat{y}_{t|t-1}$
y_t
Δy_t
$\hat{x}_t$
H_t
H_t
칼만 이득 행렬
$g_t(\Theta_1, \Theta_2, H_t)$
입력1
$g_t^1(\Theta_1)$
인공신경망
114-1
입력2
$g_t^2(\Theta_2)$

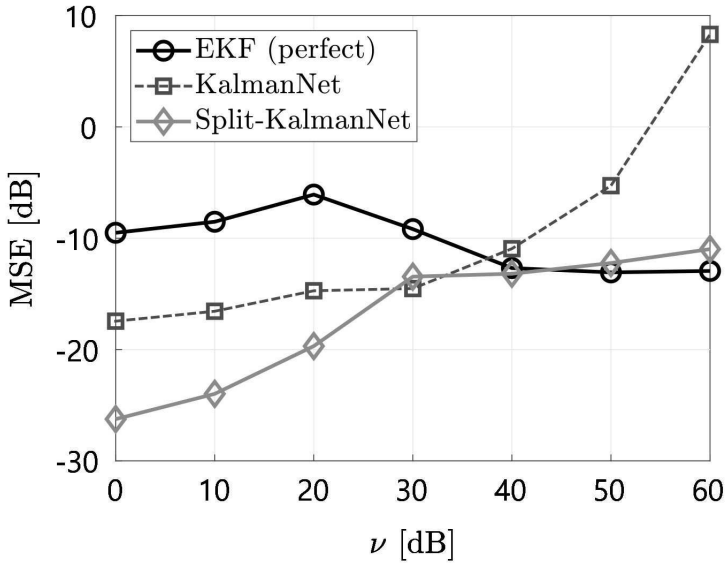
도면3


시작
현재 상태 예측 정보 생성
S302
현재 관측 예측 정보 생성
S304
인공 신경망을 통해 칼만 이득 행렬 연산
S306
현재 상태 예측 정보를 칼만 이득 행렬로 보정하여 현재 상태 추정 정보 생성
S308
종료

도면4


EKF (perfect)
KalmanNet
Split-KalmanNet
MSE [dB]
10
0
-10
-20
-30
-40
0
10
20
30
40
50
60
ν [dB]

도면5


EKF (perfect)
KalmanNet
Split-KalmanNet
MSE [dB]
10
0
-10
-20
-30
0
10
20
30
40
50
60
ν [dB]