

# 딥러닝을 활용한 블라인드 칼만 필터 설계

오민택, 최진석, \*박정훈  
울산과학기술원 전기전자공학과, \*경북대학교 IT 대학

ohmin@unist.ac.kr, jinseokchoi@unist.ac.kr, jeonghun.park@knu.ac.kr

## Deep Learning-Aided Blind Kalman Filter Design

Mintaek Oh, Jinseok Choi, and \*Jeonghun Park  
Dept. of Electrical Engineering, UNIST  
\*College of IT Engineering, Kyungpook National University

### 요 약

실시간 상태 추정의 목표는 주어진 정보를 최대한 활용하여 다음 상태를 추정하는 것이다. 이를 위해 칼만 필터(Kalman filter)가 선형 모델에서 널리 사용되어 왔으며, 비선형 모델에 대한 여러 이형들이 존재한다. 여기서 실제 목표의 동작 모델은 실시간으로 바뀔 수 있으며, 이를 정확하게 알고 있는 것은 어렵기 때문에 해당 모델을 몇가지의 독립적인 기저들과 각 기저에 해당하는 가중치들의 선형 조합으로 정의할 수 있다. 이를 바탕으로 본 논문에서는 실시간 동작 모델의 기저들만 알고 있는 상황에서 딥러닝 방식을 활용하여 칼만 이득(Kalman Gain)을 학습하는 심층 신경망(DNN) 구조를 제안한다.

### I. 서론

칼만 필터(Kalman filter)는 동적 시스템의 상태 공간 모델과 노이즈 정보를 이용하여 다음 상태를 추정하는데 가장 널리 사용되는 방법이다. 여기서 모델이 선형적으로 주어지고 노이즈가 가우시안 분포를 따를 경우 최적의 순차적인 추정이 가능하며, 최소 평균 제곱 오차(MMSE)를 달성할 수 있다. 만약 상태 공간 모델이 비선형 함수로 주어진다면, 선형 근사화를 통해 기존 칼만 필터에 적용하는 방식을 이용하며, 이를 확장형 칼만 필터(Extended Kalman filter)로 부른다. 그 밖에도 비선형 모델과 랜덤 분포를 따르는 노이즈에 대해 샘플링 기법을 통한 여러 칼만 필터의 대안들이 연구되어 왔다 [1].

칼만 필터의 동작 원리는 이전 단계에서 계산된 예측값에 현재 단계에서 받은 정보를 기반으로 칼만 이득(Kalman gain)을 계산하여 다음 상태를 추정한다. 이때 칼만 이득은 현재 상태에서 사전 정보와 관측정보의 신뢰 비율을 최적으로 정해주는 역할을 한다. 확장형 칼만 필터는 기존 칼만 필터와 동일한 구조를 가지지만, 선형 근사화를 통해 모델의 비선형성을 극복하므로 모델의 비선형성 정도에 따라 성능의 차이가 있다.

만약 칼만 이득이 주어졌다고 가정하면, 상태를 추정하기 위한 방식은 간소화될 수 있으며 비선형 상태 공간 모델에 대해서는 선형 근사화나 샘플링이 필요 없어진다.

최근 제안된 칼만넷(KalmanNet)은 딥러닝이 활용된 칼만 필터 구조이며, 칼만 이득을 학습하여 비선형 상태 공간 모델에서 기존의 확장형 칼만 필터보다 더 나은 성능을 달성하는 것이 확인되었다 [2]. 또한 칼만넷은 노이즈 정보 없이 동작하며 MMSE를 달성한다. 이 때문에 부정확한 상태 공간 모델이 주어졌을 때 학습을 통한 방식이 모델의 부정확성을 보상해준다. 따라서 칼만넷은 제한된 정보에 대해 뛰어난 성능을 보인다.

기존 칼만 필터부터 칼만넷까지 상태 공간 모델이 변하지 않고 동작 모델 정보가 주어졌다고 가정되었지만, 실제 목표의 동작 모델은 실시간으로 바뀔 수 있으며, 이를 정확하게 알고 있는 것은 어려우며 우리는 이를 가려진(blind) 상황이라 부른다. 동작 모델을 독립적인 기저들과 각 기저에 해당하는 가중치들의 선형 조합으로 정의하여 모델이 바뀌어도 기저들은 고정된 채 가중치들이 바뀌는 형태로 생각할 수 있다. 예를 들어 차량, 미사일 등의 움직임은 몇 가지의 핵심 축을 기반으로 동작되며 실시간으로 동작 모델이 바뀌어도 가중치들만 바뀌어 선형 조합으로 표현할 수 있다. 본 논문에서는 비선형 동작 모델이 가려진 상황에서 모델의 핵심 축들의 정보만으로 학습하는 딥러닝 모델을 제안한다. 구체적으로 제안된 모델은 서브 칼만 이득과 동작 모델의 기저들의 정보를 입력 받아 칼만 이득을 학습하여 다음 상태를 추정한다.

## II. 본론

본 논문에서 고려한 상태 공간 모델은 다음과 같다.

$$\mathbf{x}_t = \mathbf{f}(\mathbf{x}_{t-1}) + \mathbf{e}_t, \quad \mathbf{e}_t \sim \mathcal{N}(\mathbf{0}, \mathbf{Q}), \quad \mathbf{x}_t \in \mathbb{R}^m$$

$$\mathbf{y}_t = \mathbf{h}(\mathbf{x}_t) + \mathbf{v}_t, \quad \mathbf{v}_t \sim \mathcal{N}(\mathbf{0}, \mathbf{R}), \quad \mathbf{y}_t \in \mathbb{R}^m$$

여기서 동작 모델은 다음과 같이 정의한다.

$$\mathbf{f}(\mathbf{x}_t) = \sum_{k=1}^K w_k \mathbf{f}_k(\mathbf{x}_t), \quad \mathbf{f} \in \mathcal{V}$$

$$\mathcal{V} = \text{span}(\mathbf{f}_1, \mathbf{f}_2, \dots, \mathbf{f}_K)$$

위의 모델을 기반으로 순차적 MMSE 추정 기반 온라인 최적화 문제를 나타낼 수 있다.

$$\underset{\hat{\mathbf{x}}_t}{\text{argmin}} \mathbb{E}[(\mathbf{x}_t - \hat{\mathbf{x}}_t)^2 | \mathbf{y}_1, \dots, \mathbf{y}_t]$$

여기서  $\hat{\mathbf{x}}_t$ 은 추정된 상태이며 칼만 필터를 기반으로 위의 온라인 최적화 문제를 풀면 다음과 같다.

$$\hat{\mathbf{x}}_{t|t} = \hat{\mathbf{x}}_{t|t-1} + \mathbf{K}_t (\mathbf{y}_t - \hat{\mathbf{y}}_{t|t-1})$$

위의 수식에서  $\hat{\mathbf{x}}_{t|t}$ 는 사후 추정 값(a posterior),  $\hat{\mathbf{x}}_{t|t-1} = \sum_{k=1}^K w_k \mathbf{f}_k(\mathbf{x}_{t-1|t-1})$ 는 사전 추정 값(a prior)이며,  $\hat{\mathbf{y}}_{t|t-1} = \mathbf{h}(\hat{\mathbf{x}}_{t|t-1})$ 로 정의된다. 칼만 이득을 학습하기 위한 제안된 블라인드 칼만넷 구조는 아래 그림과 같다.

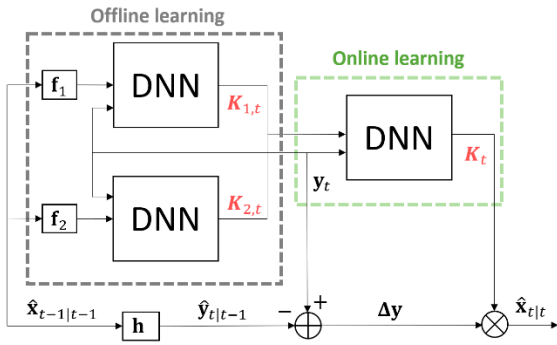


그림 1. 블라인드 칼만넷 구조 ( $K = 2$ )

그림 1에서는  $K = 2$ 인 블라인드 칼만넷 구조를 나타내고 있다. 서브 칼만 이득( $\mathbf{K}_{1,t}, \mathbf{K}_{2,t}$ )을 구하는 신경망에서 오프라인 학습이 이용되며, 칼만 이득( $\mathbf{K}_t$ )은 온라인 학습을 통해 구해지도록 설계되어 있다. 또한 입력으로 상태 공간 모델의 가중치와 노이즈 정보를 이용하지 않고 있다. 각 심층 신경망(DNN)은 [2]에서 제안된 칼만넷 구조를 따른다. 심층 신경망에 입력으로 들어가는 값들은 다음과 같이 특징지를 수 있다. 그림 2에서는  $K = 2$ 인 블라인드 칼만넷에서 고려된 입력 특징들을 나타내며 각 입력 특징들은 다음과 같다.

$$\mathbf{F1}: \Delta \tilde{\mathbf{y}}_t = \mathbf{y}_t - \mathbf{y}_{t-1}, \quad \mathbf{F2}: \Delta \mathbf{y}_t^{(k)} = \mathbf{y}_t - \hat{\mathbf{y}}_{t|t-1}^{(k)},$$

$$\mathbf{F3}: \Delta \hat{\mathbf{x}}_{t|t}^{(k)} = \hat{\mathbf{x}}_{t|t}^{(k)} - \hat{\mathbf{x}}_{t-1|t-1}^{(k)}, \quad \mathbf{F4}: \Delta \hat{\mathbf{x}}_{t|t}^{(k)} = \hat{\mathbf{x}}_{t|t}^{(k)} - \hat{\mathbf{x}}_{t|t-1}^{(k)},$$

$$\mathbf{F5}: \mathbf{K}_{k,t} \quad \forall k \in \{1, \dots, K\}.$$

실험에서는 합성 비선형 모델이 고려되었으며 비교를




그림 2. 제안된 입력 특징들 ( $K = 2$ )

위해 다음으로 오는 필터들과 함께 노이즈 파워에 대한 평균 제곱 오차(MSE)를 측정하였다: (1) 확장형 칼만 필터, (2) 칼만넷. 또한 가중치 정보가 없는(partial)과 모든 정보를 가진(full)로 나눠 비교하였다.




그림 3. 학습된 신경망들의 MSE 측정 결과

그림 3을 통해 알 수 있듯이, 제한된 블라인드 칼만넷 구조가 가중치 정보가 없어도 기존 칼만넷(partial)보다 더 낮은 MSE를 달성하는 것이 확인된다.

## III. 결론

본 논문에서는 비선형 동작 모델이 가려진 상황에서 모델의 핵심 축들의 정보만으로 학습하는 딥러닝 기반 칼만 필터를 제안하였다. 시뮬레이션을 통해 제안된 구조가 가중치의 정보가 없는 상황에서 기존 기법들보다 뛰어난 성능을 보였다.

## 참고 문헌

- [1] Grewal, Mohinder S., and Angus P. Andrews. "Applications of Kalman filtering in aerospace 1960 to the present." *IEEE Control System Mag.* pp. 69-78, 2010
- [2] Revach, Guy, et al. "KalmanNet: Neural network aided Kalman filtering for partially known dynamics." *IEEE Trans. on Signal Processing*, pp. 1532-1547, 2022