

입력 추정기로서의 신경회로망을 이용한 기동 표적 추적 시스템 설계 Design of Maneuvering Target Tracking System Using Neural Network as an Input Estimator

°김행구* 진승희* 윤태성** 박진배* 주영훈***

*연세대학교 전기공학과(Tel:+82-2-361-2773;Fax:+82-2-392-4230;E-mail:jbpark@bubble.yonsei.ac.kr)

**창원대학교 전기공학과(Tel:+82-551-79-7513;E-mail:tsyoon@sarim.changwon.ac.kr)

***군산대학교 제어계측공학과(Tel:+82-654-469-4706;E-mail:yhjoo@knusun1.kunsan.ac.kr)

Abstracts Conventional target tracking algorithms based on the linear estimation techniques perform quite efficiently when the target motion does not involve maneuvers. Target maneuvers involving short term accelerations, however, cause a bias in the measurement sequence. Accurate compensation for the bias requires processing more samples of which adds to the computational complexity. The primary motivation for employing a neural network for this task comes from the efficiency with which more features can be as inputs for bias compensation. A system architecture that efficiently integrates the fusion capabilities of a trained multilayer neural net with the tracking performance of a Kalman filter is described. The parallel processing capability of a properly trained neural network can permit fast processing of features to yield correct acceleration estimates and hence can take the burden off the primary Kalman filter which still provides the target position and velocity estimates.

Keywords Maneuvering Target Tracking, Input Estimation, Kalman Filtering, Neural Networks, Back-Propagation

1. 서론

기동 표적 추적 문제는 실제 상황에 있어서 매우 어려운 문제로 알려져 있다. 특히 기존의 등속 직선 운동 모델을 가정한 추적 필터로는 표적이 기동(maneuver)을 하는 경우 성능이 매우 저하된다. 이러한 문제를 해결하기 위하여 여러 방안 중 하나가 Bogler[4] 등에 의해 제안된 입력 추정 기법(input estimation method)이다. Bogler는 기동 입력의 크기 뿐 아니라 기동이 개시된 시간까지 동시에 추정하는 방법을 제안하였다. 그는 적응 칼만 필터의 개념을 이용하여 기동 인가 시간에 대한 필터 뱅크를 구성하고 정규화된 이노베이션의 합을 최소화하는 기동의 크기 및 기동 인가 시간을 추정하였다. 또한 최근 들어서는 이러한 기동 표적 추적 문제에 인공지능(AI) 기법을 응용하는 연구 역시 활발하게 진행되고 있다. [1][10]에서는 신경회로망의 데이터 융합 능력(data fusion capability)을 이용하여 기동 표적 추적 문제에 접근하고 있으며, 또한 [7]은 등속 표적 추적 성능에 있어 퍼지 칼만 필터가 기존의 칼만 필터보다 성능이 우수함을 입증하고 있다. 최근에는 다양한 센서의 개발과 그에 따른 알고리즘의 복잡성에 의해 여러 센서로부터의 데이터를 조합, 처리하는 과정에 있어 인공지능 기법을 이용한 연구가 수행되고 있는데 [1]에서는 그러한 데이터 융합 방식으로 신경회로망을 이용하고 있다.

본 논문에서는 일반적인 하나의 센서(TWS:track-while-scan radar)로부터의 거리 측정 데이터를 기존의 등속 직선 모델에 기반한 칼만 필터를 이용하여 처리한 후 이에 의한 이노베이션(innovation)의 피쳐(features)를 신경 회로망의 입력으로 설정하여 훈련된 신경망으로부터 미지 입력을 추정할 수 있는 방법을 제안한다. 여기에서 신경망은 기존의 기동 표적 추적 문제에 있어 주 요소가 아닌 미지 입력 추정기로서의 보조 역할을 하게 된다. 주 칼만 필터(primary Kalman filter)를 도와주는 구성요소로서 역할을 할 것이다. 일반적으로 신경망은 표적 추적 문제에

있어 입력 추정기 외에도 여러 역할을 수행할 수 있지만 본 논문에서는 특히 기존의 PDA (probability data association) 알고리즘과 기동 탐지(maneuver detection)능력 등의 두 가지에 대한 신경회로망의 적용 가능성을 타진하는 기동 표적 추적 시스템을 제시하고자 한다. 본 논문에서는 문제의 간결한 묘사를 위해서 1차원 추적 시나리오를 고려한다.

2. 표적 추적 문제

2.1 표적 모델링 (Target Modeling)

우선 식 (1)과 같이 미지 입력을 가진 경우의 기동 표적 추적을 위한 상태방정식을 고려하자.

$$\mathbf{x}(k+1) = \mathbf{F}\mathbf{x}(k) + \mathbf{G}u(k) + \mathbf{v}(k) \quad (1)$$

여기서

$$\mathbf{F} = \begin{bmatrix} 1 & T \\ 0 & 1 \end{bmatrix}, \quad \mathbf{G} = \begin{bmatrix} 0.5T^2 \\ T \end{bmatrix}$$

이고 상태 벡터 $\mathbf{x}^T(k) = [x_b(k) \ x_v(k)]$ 는 위치 및 속도 벡터로 이루어져 있다. 또한 $u(k)$ 는 표적의 기동을 나타내는 미지 입력, $\mathbf{v}(k)$ 는 공분산 Q 를 가진 영평균 백색 공정 잡음, T 는 레이더의 샘플링 주기(sampling period)이다.

레이더(TWS)의 측정방정식은 식 (2)와 같이 주어진다.

$$z(k) = \mathbf{H}\mathbf{x}(k) + w(k) \quad (2)$$

여기서 $\mathbf{H} = [1 \ 0]$ 이고 $w(k)$ 는 공분산 R 을 가진 영평균 백색 측정 잡음으로서 모든 k 및 i 에 대해 $E[w(k)w(i)^T] = 0$ 을 만족한다.

또한 입력 추정기의 역할을 하게 되는 신경회로망에 입력을 제공하게 되는 칼만 필터는 다음과 같은 기동이 없는(non-maneuvering) 등속 직선 모델에 근거한다.

$$\mathbf{x}(k+1) = \mathbf{F}\mathbf{x}(k) + \mathbf{v}(k) \quad (3)$$

이상과 같이 본 논문에서는 식 (1) 및 식 (3)의 상태 방정식에 근거한 두 가지 형태의 칼만 필터가 고려된다. 본 논문에서 제안되는 신경회로망은 식 (3)에 근거한 무기동 칼만 필터로부터의 이노베이션으로부터 미지 입력을 검출(detection) 및 추정(estimation) 하게 되고 이렇게 추정된 입력은 식 (1)에 근거한 칼만 필터에 입력 u 로서 상태 추정치를 보정하여 최종 상태 추정치를 출력하게 된다.

2.2 칼만 필터링 (Kalman Filtering)

일반적인 표적 추적 기법에서는 레이더를 통해 얻은 측정값 $z(k)$, $k=1, 2, \dots$, 는 식 (3)에 근거하여 다음과 같은 반복 알고리즘, 즉 칼만 필터에 의해 최소 평균자승오차(minimum MSE) 추정치를 제공하게 된다.

1. One-step prediction

$$\hat{\mathbf{x}}(k|k-1) = \mathbf{F} \hat{\mathbf{x}}(k-1|k-1) \quad (4)$$

2. Filtering

$$\hat{\mathbf{x}}(k|k) = \hat{\mathbf{x}}(k|k-1) + \mathbf{K}(k)[z(k) - \mathbf{H} \hat{\mathbf{x}}(k|k-1)] \quad (5)$$

3. Gain computation

$$\mathbf{K}(k) = \mathbf{P}(k|k-1) \mathbf{H}^T [\mathbf{H} \mathbf{P}(k|k-1) \mathbf{H}^T + \mathbf{R}]^{-1} \quad (6)$$

4. Covariance updating

$$\mathbf{P}(k|k-1) = \mathbf{F} \mathbf{P}(k-1|k-1) \mathbf{F}^T + \mathbf{Q} \quad (7)$$

$$\mathbf{P}(k|k) = [\mathbf{I} - \mathbf{K}(k) \mathbf{H}] \mathbf{P}(k|k-1) \quad (8)$$

이러한 경우 이노베이션 수열 $\{v(1), \dots, v(k), \dots\}$ 은 다음과 같이 정의된다.

$$v(k) = z(k) - \mathbf{H} \hat{\mathbf{x}}(k|k-1), \quad k=1, 2, \dots \quad (9)$$

일반적으로 표적이 기동하지 않는 경우 ($u(k)=0$) 이노베이션 수열의 평균은 영이다. 그러나 표적이 기동을 하기 시작하면 ($u(k) \neq 0$), 이노베이션의 평균값에는 바이어스가 발생하게 되는데 이러한 바이어스가 기동을 검출하는 데에 이용될 수 있다.

Bogler의 입력 추정 기법[4]은 이노베이션 수열을 통해 과거의 여러 비행 궤적 데이터를 고려함으로써 기동 표적의 추적 성능을 증가시킬 수 있는 방법을 제시하고 있다. 우선 이노베이션 수열로부터 확률적 테스트 방법을 통해 기동 검출을 하게 되고 일단 기동이 검출된 후에는 상태 천이 행렬(state transition matrix)의 선형 합 및 곱으로 이루어지는 전파 행렬(propagation matrix)을 계산함으로써 미지 입력에 대한 추정치를 출력하게 된다. 또한 이러한 미지 입력의 추정치가 식 (1)과 같은 상태 방정식에 근거한 칼만 필터의 입력으로 보정되어 최종적인 상태 추정치를 얻게 된다. 하지만 이러한 입력 추정 기법은 전파 행렬의 계산에 있어 복잡성이 증가하기 때문에 실제 실시간 처리가

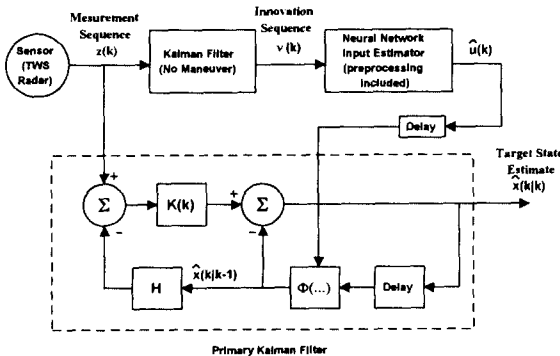


그림 1 제안된 표적 추적 시스템의 블록 선도

Fig. 1 The block-diagram of the proposed target tracking system




그림 2 제안된 다층 신경망의 구조

Fig. 2 The structure of the proposed multi-layer neural network

필요한 기동 표적 추적 문제에 있어서는 개선해야 할 사항들이 많다. 따라서 본 논문에서는 미지 입력 추정치의 계산에 있어 기존의 복잡한 전파 행렬의 계산을 대신하고 병렬적 구조에 의해 실시간 처리에 적합한 신경회로망을 이용하게 된다.

3. 제안된 표적 추적 시스템

이노베이션 수열 $\{v(1), \dots, v(k), \dots\}$ 은 표적의 기동을 나타내는 여러 가지 피치를 내포하고 있다. 그림 1은 제안된 표적 추적 시스템의 구조를 간단한 블록 선도를 통하여 보여주고 있다. 우선 무기동 모델인 식 (3)에 근거한 보조 칼만 필터의 이노베이션으로부터 얻어진 데이터가 적절히 학습된 신경망의 입력으로 작용하여 기동의 크기를 분류해내고 미지 입력 $u(k)$ 의 추정치 $\hat{u}(k)$ 를 출력한다. 또한 여기서 추정된 미지 입력은 주 칼만 필터(즉 식 (1)에 근거한 칼만 필터)에 연속적으로 입력됨으로서 최종적인 위치 및 속도의 추정치를 출력하게 된다. 주 칼만 필터의 반복 알고리즘은 무기동 칼만 필터의 식 (4)를 식 (10)과 같이 변형함으로써 얻어진다.

$$\hat{\mathbf{x}}(k|k-1) = \mathbf{F} \hat{\mathbf{x}}(k-1|k-1) + \mathbf{G} \hat{u}(k-1|k-1), \quad (10)$$

본 논문에서는 기동이 항상 양(+)인 경우만을 가정하고, 신경망의 입력을 생성하기 위하여 식 (11)과 같이 정규화된 이노베이션을 정의한다.

$$ino(k) = \frac{v^2(k)}{S(k)} \quad (11)$$

여기서 $S(k)$ 는 이노베이션의 분산이며 식 (12)로부터 계산될 수 있다.

$$S(k) = \mathbf{H} \mathbf{P}(k|k-1) \mathbf{H}^T + \mathbf{R} \quad (12)$$

본 논문에서는 시스템의 복잡성 및 신경망의 최적성과의 관계를 고려하여 두 개의 은닉층을 지닌 다층 신경망(Multi-layer NN)을 구성하였다. 식 (11)로부터 구한 신경망의 입력은 식 (13) 및 식 (14)와 같다.

$$sum(k) = 0.1(ino(k) + ino(k-1) + \dots + ino(k-9)), \quad (13)$$

$$diff(k) = 10(sum(k) - sum(k-1)) = ino(k) - ino(k-10) \quad (14)$$

와 같이 처리된다. 식 (13)은 일종의 이동 평균(moving average)의 개념으로써 가우시안 잡음의 형태를 띤 이노베이션을 보다

완만하게 근사화한 것으로 볼 수 있다. 또한 식 (14)는 식 (13)의 값의 변화에 민감하도록 처리하여 기동의 발생과 동시에 증가하며 이노베이션을 일종의 거리 오차의 개념으로 생각할 때 이노베이션 값의 변화가 기동 초기의 표적의 속도 변화에 민감하다는 것을 고려하면 다른 초기 속도의 학습 데이터가 필요하다. 그러나 이에 대한 적용성은 식 (4)의 입력 피처가 기동 초기 속도에 따른 적용성을 지니고 있다고 할 수 있다. 이상 두 가지 입력 데이터만으로 기동을 분류하기에 충분하다고 볼 수 있다.

제안된 신경망은 앞에서 살펴본 바와 같이 두 개의 입력을 가지며, 많은 경우에 적용하도록 10개의노드를 갖는 두 개의 은닉층을 구성하였다. 신경망의 학습 효율을 고려하여 바이어스를 입력층과 은닉층에 인가하였고, 출력은 가속도의 추정치만이 나오도록 구성하였다. 그림 2는 이와 같은 신경망의 구조를 보여주고 있다.

4. 모의 실험 및 결과 고찰

4.1 신경망의 학습 방법

본 논문에서 제안한 시스템의 구현을 위해서 가장 중요한 문제는 신경망의 학습이다. 이러한 신경망의 학습에는 경사법(gradient descent rule)을 이용한 오차 역전파(error back-propagation) 알고리즘을 사용하였으며, 비선형 활성화 함수로는 가장 많이 쓰이는 시그모이드 함수 $f(x) = (1 + e^{-x})^{-1}$ 를 사용하였다. 학습률을 0.1로 하여 3000번 정도 학습시킨 후에 다시 은닉층에서는 0.05, 출력층에서는 0.01로 3000번 학습을 시켰을 때 가장 적절한 학습 결과를 보여주었다. 학습 데이터는 그림 3과 같이 초기 속도는 100m/sec로 하고 500초 동안에 0-10m/sec²의 가속도의 범위 내에서 가속 지속 시간을 달리한 두 가지 경우[그림 3 (a), (b)]의 데이터를 사용하였다. 즉, 신경망은 가속의 지속 시간과 가속시의 초기 속도에 대하여 학습이 되도록 하였다. 실험 1과 실험 2는 학습 데이터가 아닌 다른 경우에 대하여 추적 성능을 시험한 것이다. 앞서서도 말했듯이 가장 강한 결과를 보여주는 것을 실험 대상으로 하였다. 학습이 끝난 신경망의 출력을 살펴본 결과 기동이 끝나는 시점은 매우 정확히 검출한다. 이것은 *diff* 입력이 그림 3과 같이 기동이 끝나는 시점에서 부호변화를 일으키며 변화가 가장 크기 때문에 일어나는 현상이다. 이로 인하여 실제 가속도의 크기에 비례하여 기동이 끝났을 때 0보다 조금 작은 값으로 떨어진다. 반면 기동이 일어나는 시점을 잘 표현해주는 입력을 찾아낸다면 더 나은

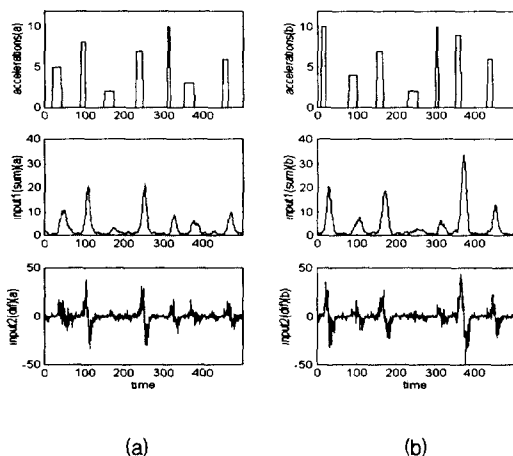


그림 3 신경망의 입출력 학습 데이터
 Fig. 3 The input-opuput data of the NN for learning
 (a) Training data a (b) Training data b

추적 성능을 보이는 신경망을 구현할 수 있을 것이다.

4.2 실험 1: 한 번의 기동

표 1은 4가지 경우의 실험 계획을 통하여 신경망의 출력이 보정된 칼만 필터가 등속 칼만 필터에 비해 나아진 추적 성능을 가지고 있음을 보여주고 있다. 그림 4는 가속 지속 시간이 30초이고, 가속도의 크기가 5m/sec²일 때의 추적 성능을 나타낸 것이다.

표 1 실험 1에 대한 평균 자승 오차 비교
 TABLE 1 The MSE comparison for experiment 1

Maneuvers		innovation(MSE)		position(MSE)		velocity(MSE)	
크기(m/s ²)	지속시간	등속KF	보정된KF	등속KF	보정된KF	등속KF	보정된KF
5	30	8.16e+3	5.23e+3	4.18e+3	1.91e+3	204.3	89.9
5	15	5.12e+3	5.35e+3	2.01e+3	1.93e+3	91.8	102.0
10	30	2.50e+4	1.51e+4	1.54e+4	8.56e+3	835.2	461.9
10	15	1.18e+4	9.28e+3	6.44e+3	4.61e+3	360.8	267.9




그림 4 실험 1에 대한 제안된 시스템의 기동 추적 성능
 Fig. 4 The tracking performance of the proposed system in expeimnt 1

4.3 실험 2: 두 번의 기동

표 2는 주어진 시간 동안 두 번의 기동이 일어나는 4가지 실험계획에 대한 추적 성능을 보여주고 있다. 두 번째 기동이 일어났을 때가 첫 번째에 비해 오차의 감소가 덜하지만 여전히 강인하게 기동에 대처하고 있다. 그림 5는 먼저 30초 동안 4m/sec²의 가속을 준 후 70초후에 다시 30초 동안 8m/sec²의 가속을 주었을 때의 추적 성능을 나타낸 것이다.

그림 4, 5의 실험 결과에 따르면 신경망의 출력이 있어서 기동이 없을 때에 실제 가속에 비해 약간의 바이어스가 있음을 알 수 있다. 위에서 행해진 실험은 모두 초기속도가 100m/sec이지만 초기속도가 변하더라도 오차의 평균자승오차에는 그다지 큰 영향을 주지 않는 것을 확인하였다. 신경망에 의한 입력 추정은 바이어스의 제거와 기동 초기의 민감한 데이터 형성의 문제만 해결된다면 보다 더 좋은 결과를 기대할 수 있을 것이다.

표 2 실험 2에 대한 평균 자승 오차 비교
TABLE 2 The MSE comparison for experiment 2

Maneuvers				innovation(MSE)		position(MSE)		velocity(MSE)	
1회 크기	지속 시간	2회 크기	지속 시간	동속KF	보정된KF	동속KF	보정된KF	동속KF	보정된KF
4	30	8	30	2.21e+4	1.35e+4	1.23e+4	6.96e+3	731.4	422.4
4	30	8	15	1.32e+4	8.29e+3	6.75e+3	3.53e+3	420.1	246.1
4	15	8	30	1.96e+4	1.37e+4	1.07e+4	7.14e+3	647.5	446.7
4	15	8	15	1.07e+4	8.54e+3	5.14e+3	3.69e+3	336.2	269.6

5. 결론

본 논문에서는 동속 모델에 기반한 칼만 필터의 이노베이션으로부터 얻어진 두 가지 데이터를 입력으로 하는 다층 신경망을 이용하여 기동 표적의 미지의 가속도를 추정하는 방법을 제안하였다. 실험 결과에서도 알 수 있듯이 제안한 표적 추적 시스템은 강인한 성질을 가지고 있으며, 표적이 기동을 할 때 두드러진 추적 성능을 지니고 있다는 것을 확인하였다. 또한 신경 회로망의 특성상 이노베이션으로부터 알맞은 데이터를 추출하여 실시간 계산이 가능하기 때문에 기존의 입력 추정 기법의 확률적 접근 방법 및 전파 행렬의 계산에 따른 계산량의 문제를 고려하지 않아도 되는 장점을 지니고 있다. 실제 본 논문은 신경망을 이용한 기동 표적 추적의 한 예를 보여주고 있으며 차후에 신경망 외에도 퍼지, 유전 알고리즘, 퍼지 신경망 등의 AI 기법을 적절하게 적용하게 된다면 기동 표적 추적 문제에 있어서 성능을 향상시킬 수 있는 기법을 마련할 수 있을 것이다.

참고문헌

[1] F. Amoozegar and M.K. Sundareshan, "Adaptive Kalman Filter Implementation by a Neural Network Scheme for Tracking Maneuvering Targets," *Proc. SPIE* vol. 2485, pp.129-140, 1995.
 [2] Y. Bar-Shalom and X.R. Li, *Estimation and Tracking: Principles, Techniques, and Software*, Artech House, Boston, 1993.
 [3] P.L. Bogler, *Radar Principles with Applications to Tracking Systems*, Wiley, New York, 1990.
 [4] P.L. Bogler, "Tracking a Maneuvering Target Using Input Estimation," *IEEE Trans. Aerosp. Electron. Syst.* vol.AES-23, No.3, pp.298-310, 1987




그림 5 실험 2에 대한 제안된 시스템의 기동 추적 성능
Fig. 5 The tracking performance of the proposed system in experiment 2

[5] C.K. Chui, G. Chen, *Kalman Filtering with Real-Time Applications*, Springer-Verlag, New York, 1991.
 [6] L. Fausett, *Fundamentals of Neural Networks: Architecture, Algorithms and Applications*, Prentice-Hall, 1994.
 [7] T.H.S. Li, "Estimation of One-Dimensional Radar Tracking via Fuzzy-Kalman Filter," *IECON'93*, vol.2, pp.2384-2388, 1993.
 [8] E. Pärt-Enander, A. Sjöberg, B. Melin, P. Isaksson, *The MATLAB® Handbook*, Addison Wesley, 1996.
 [9] R.A. Singer, "Estimating Optimal Tracking Filter Performance for Manned Maneuvering Targets," *IEEE Trans. Aerosp. Electron. Syst.*, vol. AES-6, pp.473-483, July 1970.
 [10] M.K. Sundareshan and F. Amoozegar, "Neural Network Fusion Capabilities for Efficient Implementation of Tracking Algorithms," *Optical Engineering*, vol. 36, No.3, pp.692-707, March 1997.