

신경회로망을 이용한 다중모델 차량추적 시스템

Interacting Multiple Model Vehicle-Tracking System Based on Neural Network

황재필 · 박성근 · 김은태

Jae pil Hwang, SeongKeun Park and Euntai Kim

연세대학교 전기전자공학부

Yonsei University, School of Electrical and Electronic Engr.

요 약

본 논문에서는 새로운 방식의 적응형 순항제어 필터링 방식을 제안한다. 제안한 알고리즘은 선행 차량의 모드를 추정하는 문제를 분류기의 문제로 보고 신경망 분류기를 이용하여 이를 수행한다. 신경망은 각 모드에 대한 사후 확률을 출력하며 이를 IMM과 결합하여 선행차량의 추적을 수행한다. 끝으로 10가지 시나리오에 대하여 신경망 분류기와 IMM을 결합한 NIMM (Neural Network IMM)을 적용하여 성능을 확인한다.

Abstract

In this paper, a new filtering scheme for adaptive cruise control (ACC) system is presented. In the proposed scheme, the identification of the mode of the preceding vehicle is considered as a classification problem and it is done by a neural network classifier. The neural network classifier outputs a posterior probability of the mode of the preceding vehicle and the probability is directly used in the IMM framework. Finally, ten scenarios are made and the proposed NIMM is tested on them to show its validity.

Key Word : Interacting multiple model, Kalman filter, Adaptive Cruise Control

1. 서 론

최근 자동차 기술의 발달은 자동차의 성능 향상 뿐 아니라 운전자의 편의성을 향상시키기 차량 주행 지원 시스템(driving assistance system)에 대한 연구가 함께 진행되었다. 이러한 운전자 편의성에 대한 연구는 운전자의 운전 부담을 덜어주는 것을 목적으로 하고 있으며 종국적으로는 차량 주행의 안전성도 향상시키도록 되어 있다. 이러한 운전자 편의시스템의 대표적인 예로는 차선유지 지원 시스템(lane-keeping support), 충돌경고 및 회피시스템(collision warning and collision avoidance), 차선변경 지원 시스템(assisted lane change), 도로신호 인식시스템, 사각경고 시스템(blind spot alert) 등이 이에 속한다. 이러한 차량주행 지원시스템중에서 특히 최근에 많은 관심을 받고 있는 것이 적응형 순항 제어(Adaptive Cruise Control System)으로 지능형 교통 시스템과도 연결되어 연구가 널리 진행되고 있다 [1,2].

적응형 순항제어 시스템의 성능은 주로 앞서가는 차량에 대한 추적을 얼마나 정확하게 할수 있는가와 앞선 차량의 의도를 얼마나 정확히 판단하는가에 따라 결정된다. 이러한 차량의 적응형 순항 제어에 주로 사용되는 방법이 Bar Shalom에 의해 제안된 방법이 IMM (Interacting multiple

model)이다. IMM의 특징은 여러개의 다중 모델을 가지고 이동체의 움직임을 예측하는 방식인데 모델간의 변동은 Markov 모델을 이용하며 모델내에서의 움직임은 칼만필터를 이용한다. 이러한 IMM방식의 추적은 확률적으로 차량의 모델을 예측하지만 현재 차량의 움직임 패턴은 무시하는 단점을 가지고 있다.

본 논문에서는 신경회로망을 이용한 새로운 방식의 IMM을 제시하도록 한다. 신경회로망을 이용한 Neural IMM(NIMM)의 기본아이디어는 차량의 모델변화를 단순히 Markov모델로 보고 확률예측에 맡기는 것이 아니라 차량의 움직임을 보고 이를 *classification*의 문제로 접근한다는 것이다. 즉 차량의 움직임에 대한 모드와 다시 측정값을 저장해서 데이터베이스를 구축하고 이를 학습하는 신경회로망을 이용하여 전방주행차량의 모드를 예측하는 방식이다. 신경회로망의 출력은 나머지 IMM의 확률시스템과 그대로 결합이 가능한 특징이 있다.

본 논문의 구성은 다음과 같다. 2장에서는 클래스의 확률값을 출력하는 신경회로망에 대해서 설명한다. 3장에서는 IMM의 문제점과 신경회로망을 이용하여 전방차량의 주행 모드를 예측하는 NIMM을 제안한다. 4장에서는 NIMM을 장착한 적응형 순항제어 시스템의 전방차량 추적 성능을 컴퓨터 모의실험을 통하여 확인하고 5장에서 논문을 마무리한다.

접수일자 : 2008년 10월 17일

완료일자 : 2009년 9월 12일

본 연구는 한국과학재단 특정기초연구(R01-2006-000-11016-0)지원으로 수행되었음.

2. 신경회로망 분류기와 IMM

2.1 확률적 신경회로망 분류기

신경망은 인간뇌의 동작을 모방하는 알고리즘으로 입출력간의 복잡한 관계를 표현하는데 좋다. 우선 $X = \{X_1, X_2, \dots, X_N\}$ 과 같이 N 개의 데이터셋이 있고 각각의 데이터 $X_n = [x_1^n, x_2^n, \dots, x_d^n]^T$ 는 C 개의 클래스중 하나 ω_l 에 속한다고 한다.




그림 1. 신경회로망 분류기
Fig. 1. Neural Network Classifier

이때 이 신경망의 출력은 다음의 식으로 표현된다.

$$g^{NN}(X_n) = [g_1^{NN}(X_n), g_2^{NN}(X_n), \dots, g_C^{NN}(X_n)]^T \quad (1)$$

$$g_l^{NN}(X_n) = f \left\{ \sum_{i=1}^{n_h} w_{ij}^{oh} f \left(\sum_{i=1}^d w_{ji}^{hi} x_i^n + w_{j0} \right) + w_{l0} \right\} \quad (2)$$

즉 $g^{NN}(X_n)$ 는 C 개의 출력을 갖는 신경망의 출력이고 각 요소 $g_l^{NN}(X_n), (l = 1, \dots, C)$ 는 선형함수 $\sum_{i=1}^{n_h} w_{ij}^{oh} f \left(\sum_{i=1}^d w_{ji}^{hi} x_i^n + w_{j0} \right) + w_{l0}$ 에 활성화함수 $f(\cdot)$ 를 적용한 것이다. 여기서 w_{ji}^{hi} 는 i 번째 입력노드와 j 번째 은닉노드, w_{ij}^{oh} 는 j 번째 은닉노드와 l 번째 출력노드사이 가중치를 나타내고 n_h 는 은닉노드의 수이다. 우리는 신경망이 다음과 같은 출력을 갖도록 학습을 한다.

$$t(X_n) = [t_1, t_2, \dots, t_C]^T \quad (3)$$

$$t_l(X_n) = \begin{cases} 1 & \text{if } X_n \in \omega_l \\ 0 & \text{otherwise} \end{cases} \quad (4)$$

즉 $t(X_n)$ 는 해당 클래스에 따라 $[1, 0, 0, \dots, 0], [0, 1, 0, \dots, 0], [0, 0, 1, \dots, 0]$ 등의 값을 갖으며 $t_l(X_n), l = 1, \dots, C$ 는 벡터 $t(X_n)$ 의 요소를 나타낸다. 신경망 출력 $g^{NN}(X_n)$ 이 원하는 출력 $t(X_n)$ 이 되도록 참고문헌 [11,12]에서처럼 다음의 함수를 최소화하도록 가중치를 결정한다.

$$\begin{aligned} \mathcal{J}(W) &= \sum_{n=1}^N \sum_{l=1}^C [g_l^{NN}(X_n) - t_l(X_n)]^2 \\ &= \sum_{l=1}^C \left\{ \sum_{X_n \in \omega_l} [g_l^{NN}(X_n) - 1]^2 + \sum_{X_n \notin \omega_l} [g_l^{NN}(X_n) - 0]^2 \right\} \quad (5) \end{aligned}$$

$$\begin{aligned} &= N \sum_{l=1}^C \left\{ \frac{N_l}{N} \frac{1}{N_l} \sum_{X_n \in \omega_l} [g_l^{NN}(X_n) - 1]^2 \right. \\ &\quad \left. + \frac{N - N_l}{N} \frac{1}{N - N_l} \sum_{X_n \notin \omega_l} [g_l^{NN}(X_n) - 0]^2 \right\} \end{aligned}$$

여기서 W 은 가중치 벡터이고 N_l 은 ω_l 에 속한 데이터 수이다. 위에서는 $X_n \in \omega_l$ 에 대해서 $t_l(X_n) = 1$ 이고 $X_n \notin \omega_l$ 에 대해서 $t_l(X_n) = 0$ 이라는 성질을 사용하였다. $N \rightarrow \infty$ 에서 Bayes 정리를 이용하면

$$\begin{aligned} \lim_{N \rightarrow \infty} \frac{1}{N} \mathcal{J}(W) &\equiv \tilde{\mathcal{J}}(W) \\ &= \sum_{l=1}^C \left\{ P(\omega_l) \int [g_l^{NN}(X_n) - 1]^2 p(X_n | \omega_l) dX_n \right. \\ &\quad \left. + P(\omega_l \neq l) \int [g_l^{NN}(X_n) - 0]^2 p(X_n | \omega_l \neq l) dX_n \right\} \\ &= \sum_{l=1}^C \left\{ \int [g_l^{NN}(X_n)]^2 p(X_n) dX_n \right. \\ &\quad \left. - 2 \int g_l^{NN}(X_n) p(X_n, \omega_l) dX_n + \int p(X_n, \omega_l) dX_n \right\} \\ &= \sum_{l=1}^C \left\{ \int [g_l^{NN}(X_n) - p(\omega_l | X_n)]^2 p(X_n) dX_n \right. \\ &\quad \left. + \int P(\omega_l | X_n) p(\omega_l \neq l | X_n) p(X_n) dX_n \right\} \quad (6) \end{aligned}$$

여기서 마지막 식의 2번째 항은 W 와 무관하므로 $\tilde{\mathcal{J}}(W)$ 를 최소화 하면

$$g_l^{NN}(X_n) \approx p(\omega_l | X_n) \quad (7)$$

즉 신경망 분류기의 출력은 각 클래스의 사후확률에 접근함을 알 수 있다.

2.2 IMM

항공/방위산업에서 물체추적에 널리 사용되던 IMM은 최근 자동차산업에서 적응 순환시스템의 구현에 사용되고 있으며 추적 대상 시스템은 다음의 식으로 표현되는 것으로 하다.

$$x(k) = F_j x(k-1) + \Gamma_j w_j(k-1) \quad (8)$$

$$z(k) = H_j x(k) + v_j(k) \quad (9)$$

여기서 $x(k)$ 와 $z(k)$ 는 추적대상의 상태변수와 출력을 나타내며 인덱스 j 는 타겟의 모드 (모델)을 나타낸다. IMM은 다수개의 필터를 병렬로 연결하여 사용하고 각 필터는 추적하는 시스템의 특정모드에 해당하여 동작하게 된다. 다음의 그림은 IMM의 기본동작을 설명하는 그림이다.




그림 2. IMM의 기본구조
Fig. 2. Schematic of IMM

각각의 모델은 칼만필터에 의해 독립적으로 타겟을 추적하며 Markov모형을 통한 모드 예측을 통해 여러모델의 결과를 융합한다.

3. 신경회로망 Interacting Multiple Model (NIMM)

3.1. 개요

IMM의 운영에 있어서 가장중요한 것은 타겟의 모델을 예측하는 일이며 전통적으로 추적차량의 모델변화를 Markov 모델로 표현하여 확률적으로 접근하는 방식을 취하고 있다. 본 논문에서는 차량모델 예측을 분류기의 문제로 해석하고 차량의 운전 패턴을 신경망 분류기로 분리함으로써 IMM의 성능을 향상시킨다. 이러한 모델은 실제 사람이 차량을 운전하는 경우 앞차의 운전 상황 및 움직임 패턴을 보고 모델을 파악하며 Markov 모델에 의지하지 않는다는 것을 이용한 것이다.

3.2. 앞선차량의 동적모델

본 논문에서 사용되는 전방차량의 다이내믹스는 다음의 식 (10)으로 표현된다.

$$x(k) = Fx(k-1) + \Gamma w(k) \quad (10)$$

$$F = \begin{pmatrix} 1 & T & \frac{1}{2}T^2 & 0 & 0 & 0 \\ 0 & 1 & T & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & T & \frac{1}{2}T^2 \\ 0 & 0 & 0 & 0 & 1 & T \\ 0 & 0 & 0 & 0 & 0 & 1 \end{pmatrix} \quad (10.1)$$

$$\Gamma = \begin{pmatrix} \frac{1}{2}T^2 & 0 \\ T & 0 \\ 1 & 0 \\ 0 & \frac{1}{2}T^2 \\ 0 & T \\ 0 & 1 \end{pmatrix} \quad (10.2)$$

여기서 장착된 장거리 레이더를 중심으로 가로축은 ξ , 세로축은 η 로 표시할 때 $x = (\xi \dot{\xi} \ddot{\xi} \eta \dot{\eta} \ddot{\eta})^T$ 이다. 즉 상태변수 x 는 ξ 와 η 의 두종류 변수의 위치, 속도, 가속도의 세가지 정보를 의미하며 T 는 샘플링 타임이다. $w(k)$ 는 프로세스 노이즈이며 그 공분산은 $Q(k)$ 로 나타낸다. 실제로 $w(k)$ 는 차량의 가속 및 감속을 의미한다. 추적차량은 그림과 같이 “주행모드”와 “차선변경모드”의 두가지 모드를 갖는 것으로 한다. 두 모드 모두 직선 주행이므로 식 (10)의 F 와 Γ 를 사용하며 단지 프로세스 노이즈만이 다르게 나타난다. 즉 주행모드를 1, 차선변경모드를 2로 할때 식 (10)의 모델에서

$$F_1 = F_2 = F \quad (11.1)$$

$$\Gamma_1 = \Gamma_2 = \Gamma \quad (11.2)$$

$$H_1 = H_2 = H \quad (11.3)$$

이고 다만 $j=1$ (주행모드)의 경우

$${}^T Q \Gamma = \begin{pmatrix} \frac{1}{4}T^4 & \frac{1}{2}T^3 & \frac{1}{2}T^2 & 0 & 0 & 0 \\ \frac{1}{2}T^3 & T^2 & T & 0 & 0 & 0 \\ \frac{1}{2}T^2 & T & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & \frac{1}{4}T^4 & \frac{1}{2}T^3 & \frac{1}{2}T^2 \\ 0 & 0 & 0 & \frac{1}{2}T^3 & T^2 & T \\ 0 & 0 & 0 & \frac{1}{2}T^2 & T & 1 \end{pmatrix}^q \quad (13)$$

$$\sqrt{q} = 9.81 \times 10^{-4} \equiv \sqrt{q_1} \quad (13.1)$$

으로 사용하였고 $j=2$ (차선변경모드)의 경우

$$\sqrt{q} = 5 \times 9.81 \times 10^{-4} \equiv \sqrt{q_2} \quad (13.2)$$

로 하였다.

3.3 신경회로망 IMM

앞에서 기술한 바와 같이 차량의 모드추정을 신경회로망의 분류문제로 파악하여 알고리즘을 구축한다. IMM의 경우 모드추정은 예측 (prediction)과 수정 (correction)의 두 단계로 이루어지고 있다.

- 예측-

$$\begin{aligned} \bar{\mu}_j(k|k-1) &\equiv P(m_j(k)|Z^{k-1}) \\ &= \sum_{i=1}^r \{P(m_j(k)|m_i(k-1), Z^{k-1})P(m_i(k-1)|Z^{k-1})\} \\ &= \sum_{i=1}^r \{\pi_{ij}\mu_i(k-1)\} \end{aligned} \quad (14)$$

- 수정-

$$\begin{aligned} \mu_j(k) &\equiv P(m_j(k)|Z^k) \\ &= P(m_j(k)|z(k), Z^{k-1}) \\ &= \frac{P(z(k)|m_j(k), Z^{k-1})P(m_j(k)|Z^{k-1})}{P(z(k)|Z^{k-1})} \\ &= \frac{P(z(k)|m_j(k), Z^{k-1})\bar{\mu}_j(k)}{\sum_{j=1}^r \{P(z(k)|m_j(k), Z^{k-1})\bar{\mu}_j(k)\}} \end{aligned} \quad (15)$$

여기서 $\pi_i = P(m_i(k-1)|m_j(k), Z^{k-1})$ 으로 하였고 Z^k 는 $z_1 z_2 \dots z_k$ 의 누적치를 나타낸다. 이러한 기존 IMM의 문제점은

- 1) 선행차량의 모드변화 (차선바꿈)을 기존의 움직임에서 탐지하는 사람과 달리 IMM은 이를 Markov모델로만 들음으로써 성능이 떨어지며
- 2) Markov 모델링을 위해서 기존의 움직임 Z^{k-1} 에 의존해야 하는 transition확률

$$\pi_{ij} = P(m_i(k-1)|m_j(k), Z^{k-1}) \quad (16)$$

을 단순히

$$\pi_{ij} = P(m_j(k)|m_i(k-1)) = P(m_j(k+1)|m_i(k)) \quad (17)$$

으로 보고 있다. 이것은 사람은 기존의 움직임 Z^{k-1} 을 관측하는데 IMM은 단순히 Markov 모델링을 한다는 1)의 지적과도 일맥상통한다. 따라서 본 NIMM에서는 추적차량의 모드 예측에서부터 신경회로망 분류기를 사용한다. 즉

$$\begin{aligned} \bar{\mu}_j(k|k-1) &\equiv P(m_j(k)|Z^{k-1}) \\ &= \sum_{i=1}^r \{P(m_j(k)|m_i(k-1), Z^{k-1})P(m_i(k-1)|Z^{k-1})\} \\ &= g_j^{NN}(z_{k-d:k-1}, P(m_i(k-1)|Z^{k-1})|_{i=1 \dots r}) \end{aligned} \quad (18)$$

즉 Z^{k-1} 만을 신경망 분류기의 입력으로 사용해야 하지만 이 경우 입력노드가 너무 많은 관계로 이 진순간의 확률 $P(m_i(k-1)|Z^{k-1})|_{i=1 \dots r}$ 을 입력으로 포함하고 기존의 움직임은 $z_{k-d:k-1}$ 으로 제한한다. 식 (7)에서 언급한바와 같이 신경망 분류기 $g_j^{NN}(\cdot)$ 의 출력은 사후(a posteriori) 확률 특징을 가지고 있기 때문에 IMM의 기존식과 융합이 가능하다. 즉

- 예측

$$\begin{aligned} \bar{\mu}_j(k|k-1) &\equiv P(m_j(k)|Z^{k-1}) \\ &= \sum_{i=1}^r \{P(m_j(k)|m_i(k-1), Z^{k-1})P(m_i(k-1)|Z^{k-1})\} \\ &= g_j^{NN}(z_{k-d:k-1}, P(m_i(k-1)|Z^{k-1})|_{i=1 \dots r}) \end{aligned} \quad (19)$$

- 수정-

$$\begin{aligned} \mu_j(k) &\equiv P(m_j(k)|Z^k) \\ &= P(m_j(k)|z(k), Z^{k-1}) \\ &= \frac{P(z(k)|m_j(k), Z^{k-1})P(m_j(k)|Z^{k-1})}{P(z(k)|Z^{k-1})} \\ &= \frac{P(z(k)|m_j(k), Z^{k-1})g_j^{NN}(z_{k-d:k-1}, P(m_i(k-1)|Z^{k-1})|_{i=1 \dots r})}{\sum_{j=1}^r \{P(z(k)|m_j(k), Z^{k-1})g_j^{NN}(z_{k-d:k-1}, P(m_i(k-1)|Z^{k-1})|_{i=1 \dots r})\}} \end{aligned} \quad (20)$$

과 같이 차량의 모델을 추정할수 있다. 이제 신경망 분류기를 포함한 NIMM 알고리즘은 다음과 같다.

Neural Interacting Multiple Model (NIMM)

STEP 1. Interaction

$$\begin{aligned} \bar{\mu}_j(k|k-1) &\equiv P(m_j(k)|Z^{k-1}) \\ &= g_j^{NN}(z_{k-d:k-1}, P(m_i(k-1)|Z^{k-1})|_{i=1 \dots r}) \\ \mu_{ij}(k-1) &= \frac{\pi_{ij}\mu_i(k-1)}{\mu_j(k|k-1)} \\ \hat{x}_{(k-1)}^o &\equiv E(x(k-1)|m_j(k), Z^{k-1}) = \sum_{i=1}^r \{\hat{x}_i(k-1)\mu_{ij}(k-1)\} \\ P_j^o(k-1) &\equiv E\left[(x(k-1) - \hat{x}_{(k-1)}^o)(x(k-1) - \hat{x}_{(k-1)}^o)^T | m_j(k), Z^{k-1}\right] \\ &= \sum_{i=1}^r \left\{ \left[P_i(k-1) + (\hat{x}_i(k-1) - \hat{x}_{(k-1)}^o)(\hat{x}_i(k-1) - \hat{x}_{(k-1)}^o)^T \right] \mu_{ij}(k-1) \right\} \end{aligned}$$

STEP 2. Filtering (KF)

$$\begin{aligned} \hat{x}_j(k|k-1) &= F_j \hat{x}_{j^o}(k-1) \\ P_j(k|k-1) &= F_j P_j^o(k-1) F_j^T + \Gamma_j Q_j(k) \Gamma_j^T \\ v_j(k) &= z(k) - \hat{z}_j(k|k-1) = z(k) - H_j \hat{x}_j(k|k-1) \\ S_j(k) &= H_j P_j(k|k-1) H_j^T + R_j(k). \\ W_j(k) &= P_j(k|k-1) H_j^T S^{-1}(k) \\ \hat{x}_j(k) &= \hat{x}_j(k|k) = \hat{x}_j(k|k-1) + W_j(k) v_j(k) \\ P_j(k) &= P_j(k|k) = P_j(k|k-1) - W_j(k) S_j(k) W_j^T(k) \\ &= [I - W_j(k) H_j] P_j(k|k-1) \end{aligned}$$

STEP 3. Model Probability Update


$$\begin{aligned} \mu_j(k) &\equiv P(m_j(k)|Z^k) \\ &= \frac{A_j(k) g_j^{NN}(z_{k-d:k-1}, P(m_i(k-1)|Z^{k-1})|_{i=1 \dots r})}{\sum_{j=1}^r \{A_j(k) g_j^{NN}(z_{k-d:k-1}, P(m_i(k-1)|Z^{k-1})|_{i=1 \dots r})\}} \\ A_j(k) &= P(z(k)|m_j(k), Z^{k-1}) \\ &= |2\pi S_j(k)|^{-1/2} \exp\left\{-\frac{1}{2} v_j^T(k) S_j^{-1}(k) v_j(k)\right\} \end{aligned}$$

STEP 4. Combination


$$\begin{aligned} \hat{x}(k) &\equiv E(x(k)|Z^k) = \sum_{i=1}^r \hat{x}_i(k) \mu_i(k) \\ P(k) &\equiv E\left[(x(k) - \hat{x}(k))(x(k) - \hat{x}(k))^T | Z^k\right] \\ &= \sum_{j=1}^r \left\{ \left[P_j(k) + (\hat{x}(k) - \hat{x}_j(k))(\hat{x}(k) - \hat{x}_j(k))^T \right] \mu_j(k) \right\} \end{aligned}$$

4. 컴퓨터 모의실험


본 모의실험에서는 제안된 NIMM의 성능을 모의실험을 통하여 확인한다. 적응형 순항제어 차량은 30 m/s로 주행하고 있고 추적차량은 33m/s으로 주행하는 것으로 한다. 앞에서 언급한 바와 같이 추적차량은 “주행모드”와 “차선변경모드”의 두가지 모드를 자기로 진행하며 20초가 모의실험을 진행한다. NIMM의 기본아이디어는 추적차량의 모드를 분류기로 구분하는 것이므로 분류기의 실험에서와 같은 학습과 테스트를 반복실행한다. 즉 차량주행의 10개의 시나리오를 구성하고 번갈아 가면서 9개에서 데이터를 취득해서 나머지 하나에 적용하는 10 cross validation을 수행한다. 다음의 그림 2는 실험에 사용된 10개의 시나리오를 나타낸다. 예를 들어 시나리오 1의 경우 적응형 순항제어 차량은 2차선을 주행하고 있고 추적차량은 1차선의 같은위치에서 주행을 시작하여 1-4초동안 적응형 순항제어 차량을 앞으로 끼어들기를 실시하고 약 15초 후 다시 1차선으로 돌아가는 주행을 한다. 여기서 센서 데이터는 식 (10)에 의해서 생성되었다.




(a)




(d)




(b)




(e)




(c)



(f)




(g)




(j)

그림 3. 10개의 시나리오
Fig. 3. 10 Senario

다음의 그림3는 한 특정한 모의실험에 대해서 기존의 IMM에서의 모드추정과 NIMM에서의 모드추정 결과를 비교한 것이다.



(h)



(i)




그림 4. 추적차량의 모드 변화 추정
Fig. 4. Real mode and estimated mode

그림에서 쇠선은 실제의 추적차량 모드이고 점선은 IMM을 통한 확률적 추적이며 'o'는 신경망 분류기를 이용한 추적차량의 모드이다. IMM에 비해서 NIMM이 좋은 성능을 내는 것을 볼 수 있다. 다음의 표는 10-crossvalidation을 10회 반복해서 추정오차를 비교한 표이다. 그림에서와 같이 NIMM이 IMM 보다 개선된 성능을 보이는 것을 알 수 있다.

표 1. 성능비교

Table 1. The performance between IMM and Proposed method(NIMM)

| | IMM | NIMM |
|--|-------|-------|
| $MSE = \frac{1}{N} \sum_{k=0}^N (x(k) - \hat{x}(k))^2$ | 0.542 | 0.525 |

5. 결 론

본 논문에서는 적응형 순항제어 시스템개발에 필수적인 필터링 방식에 대한 연구를 진행하였다. 제안한 시스템은 추적차량의 주행모드 결정을 분류기 문제로 보고 신경망 분류기를 이용하여 추적차량의 주행모드를 분석하고 이를 사후확률로 이용하여 필터링을 진행하는 방법이다. 제안한 시스템을 실제시스템과 비슷한 차량의 주행환경에 적용하여 성능을 확인하였고 기존의 IMM보다 좋은 성능을 보이는 것을 확인하였다.

참 고 문 헌

- [1] 류경진, 박성근, 황재필, 김은태, 강형진, "물체 인식을 위한 레이더 센서 데이터의 그룹핑," 한국 퍼지 및 지능시스템 학회 2007년도 춘계학술대회 학술발표 논문집, Vol. 17, No 1, pp. 394-396, 2007년 4월.
- [2] 류경진, 박성근, 김은태, 강형진, "최소자승법을 이용한 레이더 센서 데이터에서 자동차 선별 시스템," 한국자동차공학회 2007년도 춘계학술대회논문집 pp.2275~2279, 2007년 6월.
- [3] X.R.Li, Y. Bar-Shalom, "Design of an interacting multiple model algorithm for air traffic control tracking," *IEEE Trans on Control Systems Technology*, Vol.1, no. 3, pp. 186 - 194, Sept. 1993.
- [4] E. Mazor, A. Averbuch, Y. Bar-Shalom, J. Dayan, "Interacting multiple model methods in target tracking: a survey," *IEEE Trans. on Aerospace and Electronic Systems*, vol. 34, no. 1, Jan. Page(s):103 - 123, 1998.
- [5] 손현승, 주영훈, 박진배, "퍼지뉴럴 네트워크 기반 다중모델기법 추정시스템," 퍼지 및 지능시스템학회 논문지, vol. 16, no. 4. 472-478, 2006.
- [6] M. Sugeno and G. T. Kang, "Fuzzy modeling and control of multilayer incinerator", *Fuzzy Sets and Systems*, Vol. 18, pp 329-346, 1986.
- [7] E. Kim, M. Park, S. Ji and M. Park, "A new approach to fuzzy modeling," *IEEE Trans. Fuzzy Systems*, vol. 5, No. 3, pp. 328-337, Aug, 1997.
- [8] E. Kim, M. Park, S. Kim and M. Park, "A transformed input-domain approach to fuzzy modeling," *IEEE Trans. Fuzzy Systems*, vol. 6, no. 4, pp.596-604, 1998.
- [9] W. Chung and E. Kim, "A New Two-phase Approach to Fuzzy Modeling for Nonlinear Function Approximation," *IEICE Trans. Inf. & Syst.*, Vol. E89-D, no.9, 2473-2483, Sep., 2006.
- [10] D. S. Caveney, *Multiple Target Tracking in the Adaptive Cruise Control Environment Using Multiple Models and Probabilistic Data Association*, Master Thesis, UC Berkeley, 1999.
- [11] R. Duda, P. Hart, and D. Stork, *Pattern Classification*. Addison Wesley, 2001.

- [12] H. Lee, S. Hong and E. Kim, "A New Genetic Feature Selection with Neural Network Ensemble," *International Journal of Computer Mathematics*, vol. 86, no. 7, pp. 1105-1117, Jul. 2009.

저 자 소 개



황재필(Jae Pil Hwang)

2003년: 연세대학교 전기전자공학과 학사
 2005년: 연세대학교 전기전자공학과 석사
 2005년~현재: 연세대학교 전기전자공학부 박사과정

관심분야 : 지능형차량, 로봇 비전
 Phone : 02-2123-2863
 Fax : 02-313-2879
 E-mail : purmnara@yonsei.ac.kr



박성근(Seongkeun Park)

2004년: 연세대학교 전기전자공학과 학사
 2004년~현재: 연세대학교 전기전자공학과 석박통합과정

관심분야 : 노이즈 필터링, 지능형차량, 레이더 신호처리
 Phone : 02-2123-2863
 Fax : 02-313-2879
 E-mail : keiny@yonsei.ac.kr



김은태(Euntai Kim)

1992년: 연세대학교 전자공학과 학사
 1994년: 연세대학교 전자공학과 석사
 1999년: 연세대학교 전자공학과 박사

관심분야 : 생체인식, 홈네트워크, 지능형차량
 Phone : 02-2123-2863
 Fax : 02-313-2879
 E-mail : etkim@yonsei.ac.kr