

상대분할 신경회로망에 의한 자율주행 차량 도로추적 제어기의 개발

Development of Road-Following Controller for Autonomous Vehicle using Relative Similarity Modular Network

류영재, 임영철
(Young-Jae Ryoo, and Young-Cheol Lim)

Abstract : This paper describes a road-following controller using the proposed neural network for autonomous vehicle. Road-following with visual sensor like camera requires intelligent control algorithm because analysis of relation from road image to steering control is complex. The proposed neural network, relative similarity modular network(RSMN), is to learn the complex relation. RSMN is composed of some learning networks and a partitioning network. The partitioning network divides input space into multiple sections by similarity of input data. Because divided section has similar input patterns, RSMN can learn nonlinear relation such as road-following with visual control easily. Visual control uses two criteria on road image from camera; one is position of vanishing point of road, the other is slope of vanishing line of road. The controller using neural network has input of two criteria and output of steering angle. To confirm performance of the proposed neural network controller, a software is developed to simulate vehicle dynamics, camera image generation, visual control, and road-following. Also, prototype autonomous electric vehicle is developed, and usefulness of the controller is verified by physical driving test.

Keywords : relative similarity modular network, road-following, visual control, autonomous vehicle.

I. 서론

오늘날 도시화가 진행되고 인구밀도가 높아짐에 따라 개인의 운송수단이 대단위로 증가하여, 이에 따라 고속 도로에서 교통 혼잡이 증가하고, 시간과 에너지의 낭비 뿐만 아니라 운전자의 실수로 인한 사고는 커다란 인명 손실을 초래한다. 이에 대한 미래지향적 해결방안으로 1970년대부터 미국, 일본, 유럽 등 선진국에서는 지능적인 차량과 도로 시스템에 관심과 투자가 점점 증대되었으며, 차량이 카메라 영상에 의하여 자율적으로 주행하는 연구가 시작되었다[1].

자율주행시스템에 관한 대부분의 연구에서는 2차원 도로영상을 3차원 좌표로 변환하여 도로지도를 생성한 후, 차량의 위치를 파악하고 Kalman filter 모델링, PD 제어 및 독자적인 수학적 방법을 이용하여 차량의 조향 및 속도를 제어하였다[2][3]. 이 방법들은 대단히 복잡하고 방대한 양의 연산이 요구되므로 이를 고속주행의 제어기로 실용화하는데는 한계점이 있다. 이러한 한계상황에서 도로지도를 생성하고 복잡하게 제어해야 하는 번거로움을 뛰어넘어 도로영상 자체를 차량의 제어에 직접 적용하는 도로영상기반 제어방법이 연구되었다[4].

한편 인간이 조작하는 차량의 제어는 비선형적이고 복잡할 뿐만 아니라 도로영상과 차량과의 관계는 수학적으로 적절히 나타내는데는 한계가 있었다. 따라서 비선

형 및 복잡한 제어가 요구되는 곳에 적용하여 우수한 효과를 나타낸 신경회로망의 지능제어분야의 도입이 필요하게 되었다[5]~[9]. 제어에 사용되는 신경회로망을 크게 분류하면 전체학습 신경회로망과 부분 분할학습 신경회로망으로 나눌 수 있다. 전체학습 신경회로망은 균사화의 일반화 특성 때문에 부분적 규모로 변동을 갖는 합수를 학습하는 것은 일반적으로 매우 어렵다. 이런 문제는 복잡한 비선형 합수 균사화와 제어 분야에서 두드러진다. 이와같은 문제를 해결하기 위하여 부분 분할학습 신경회로망은 훈련 데이터를 특성에 따라 분류하고 특성별로 다른 파라미터들을 사용함으로써 학습 성능을 개선하는 구조의 신경회로망으로 제안되었다[10].

본 논문에서는 새로운 구조의 부분분할 신경회로망(locally partitioning neural network)을 제안하고 이를 자율주행시스템의 도로영상기반 제어에 적용하여 도로추적제어기를 설계한다. 제안하는 부분분할 신경회로망인 상대분할 신경회로망(relative similarity modular network ; RSMN)에는 입력공간을 분할하는 분할망이 필요하며, 이를 위하여 상대유사 경쟁학습망을 정의한다. 이를 도로영상기반 제어에 적용하기 위하여 도로영상의 특징요소인 도로의 소실점 위치와 소실선 각도를 제어기의 입력으로 직접 이용하는 방법[11][12]에 대하여 간략히 알아본다. 제안한 상대분할 신경회로망을 도로영상기반 제어에 적용하여 도로추적 제어기를 구현한다. 또 컴퓨터상에서 카메라의 도로영상과 차량과 도로관계를 분석하고 제어기의 성능을 모의실험하기 위하여 시뮬레이션 프로그램을 개발한다. 모의실험에서는 기존에 제어기인 다

접수일자 : 1998. 9. 28., 수정완료 : 1999. 4. 7.

류영재, 임영철 · 전남대학교 전기공학과 및 지역협력연구센터

※ 본 논문은 한국과학재단 지정 전남대학교 고품질전기전자부품 및 시스템 연구센터의 연구비 지원에 의하여 연구하였습니다.

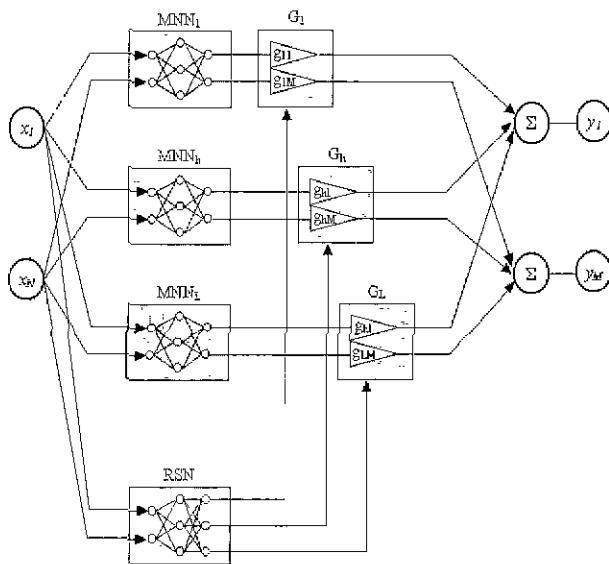


그림 1. 상대분할 신경회로망의 구조.

Fig. 1. Structure of RSMN (Relative Similarity Modular Network).

총 신경회로망에 의한 제어결과와 제안한 상대분할 신경회로망의 제어결과를 분석한다. 마지막으로 제안된 도로 추적 제어기의 유용성을 검증하기 위하여 전기자동차를 설계 제작한다. 제작된 전기자동차를 이용하여 곡선도로에서 자율주행 실험을 수행하고, 도로영상에서 도로의 특징요소를 검출하고 조향각을 출력한 결과를 분석한다.

II. 상대분할 신경회로망

1. 상대분할 신경회로망의 구조

상대분할 신경회로망(relative similarity modular network : RSMN)의 구조는 그림 1과 같이 학습망과 분할망으로 구성한다. 학습망은 여러 개($1, \dots, h, \dots, L$)의 다층신경회로망(multilayer neural network : MNN)으로 구성되고, 분할망은 여러 개($1, \dots, h, \dots, L$)의 출력소자를 갖는 상대유사 경쟁학습망(relative similarity neural network : RSN)으로 구성한다.

상대분할 신경회로망에서는 분할망 내의 하나의 출력소자와 학습망 내 하나의 다층 신경회로망이 하나의 부분 신경회로망이 되어 입력공간을 분할하고 학습을 수행한다. 입력벡터(x_1, \dots, x_N)는 학습망과 분할망에 공통으로 연결되고 출력은 학습망의 출력에 분할망의 출력을 곱하여 이득($G_1, \dots, G_h, \dots, G_L$)으로 작용한다. 여러 개의 출력(y_1, \dots, y_M)을 갖는 상대분할 신경회로망의 경우는 다층 신경회로망의 출력소자 수가 최종 출력의 수와 같게 되며, 한 조의 다층 신경회로망의 모든 출력에는 한 개의 분할 신경소자 출력이 동일한 이득($(g_{11}, \dots, g_{1M}), \dots, (g_{h1}, \dots, g_{hM}), \dots, (g_{L1}, \dots, g_{LM})$)으로 곱해져서 최종 출력소자에 하나씩 인가된다. 최종 출력단 소자는 모든 입력 값을 합하여 출력한다.

신경회로망에 입력벡터가 인가되면 분할망 내의 소자 중 입력벡터와 가장 유사한 연결강도 벡터를 갖는 소자가 활성화되어, 이 소자와 짹을 이루는 학습 신경회로

망의 출력이 선택되고 전체 신경회로망의 출력으로 사용된다.

2. 상대유사 경쟁학습망

본 장에서는 상대분할 신경회로망의 분할망으로 사용되는 상대유사 경쟁학습망을 제안한다. 제안하는 신경회로망의 경쟁학습은 상대적인 거리를 이용하며 이에 대한 원리를 정리하여 기술한다.

1) 상대유사도의 정의

집합 \mathbf{x} 가 N 차원으로 구성된 다음과 같은 벡터라고 가정한다.

$$\mathbf{x} = [x_1, x_2, \dots, x_i, \dots, x_N]^T, x_i \in R \quad (1)$$

L 개의 출력 $\mathbf{y} = [y_1, y_2, \dots, y_j, \dots, y_L]^T$ 에 연결되는 가중치의 벡터는 다음과 같이 가정한다.

$$\begin{aligned} \mathbf{w} &= [\mathbf{w}_1, \dots, \mathbf{w}_j, \dots, \mathbf{w}_L]^T \\ \mathbf{w}_j &= [w_{j1}, \dots, w_{ji}, \dots, w_{jN}] \end{aligned} \quad (2)$$

가중치 패턴 \mathbf{w} 가 입력패턴 \mathbf{x} 와 얼마나 유사한가에 따라서 출력의 값이 영향을 받는다. 기존의 신경회로망의 경우 출력은 입력과 가중치와의 곱인 $\mathbf{y} = \mathbf{wx}$ 로 연산이 된다.

제안하는 방식에서 출력은 입력패턴과 출력에 영향을 미치는 가중치와의 유사성에 따라 결정한다. 입력패턴과 가중치 패턴의 유사성은 입력벡터와 가중치 벡터의 가까운 정도로 구분이 가능하며 Euclidean 거리 ($d = \|\mathbf{x}-\mathbf{w}\|$)는 가장 일반적인 표현이다.

그런데 d 는 입력패턴의 종류에 따라 달라지므로 일반성이 결여된다. 따라서 입력패턴의 종류에 관계없이 정규화가 가능하도록 다음과 같은 상대적 거리(relative distance)를 정의한다.

$$\begin{aligned} R_j &= \left[\sum_{k=1}^L \frac{\|\mathbf{x} - \mathbf{w}_k\|^q}{\|\mathbf{x} - \mathbf{w}_j\|^q} \right]^{\frac{1}{q}} \\ &= \left[\sum_{k=1}^L \left(\frac{d_j}{d_k} \right)^q \right]^{\frac{1}{q}} \end{aligned} \quad (3)$$

상대적 거리 R_j 는 출력 j 에 관여하는 가중벡터 \mathbf{w}_j 와 다른 가중벡터들 \mathbf{w}_k 와의 상대적인 거리를 나타낸다. 이 때 norm에 사용되는 q 는 일반적으로 2를 사용한다.

입력 \mathbf{x} 에 대한 가중벡터의 상대적 거리 R_j 는 서로 가까운 거리일수록 적은 값을 가진 반면, 상호유사성은 커진다. 따라서 출력 y_j 는 상대적 거리의 역수를 이용하여 유사성의 크기를 갖도록 하여 상대유사도(relative similarity)를 다음과 같이 정의한다.

$$y_j = R_j^{-1} \quad (4)$$

이 상대유사도는 현재 입력패턴이 어떤 가중벡터에 가장 유사한가를 나타낸다. 상대유사도가 분할망 상대유사 경쟁학습망의 출력이 되고, 상대분할 신경회로망의 학습망 출력에 이득으로 전달된다. 따라서 가장 입력패턴이 유사한 학습망이 최종출력에 영향을 많이 주게된다.

2) 가중벡터의 학습

입력벡터 \mathbf{x} 가 다음과 같이 p 개의 패턴으로 구성되어 있다고 가정하자.

$$\mathbf{X} = \{\mathbf{x}^1, \mathbf{x}^2, \dots, \mathbf{x}^h, \dots, \mathbf{x}^p\}, \mathbf{x}^h \in R^N \quad (5)$$

입력패턴과 가중벡터의 유사성을 나타내는 p 개의 출력벡터는 다음과 같이 나타낸다

$$\mathbf{y} = [y^1, y^2, \dots, y^p] \quad (6)$$

가중벡터 \mathbf{w} 는 p 개의 입력패턴에 대하여 가장 유사한 특성을 갖는 출력에 대해서 큰 반응을 갖도록 하여 입력 패턴에 접근하도록 하여야 한다. 이는 입력 \mathbf{x} 에 의한 출력 $\mathbf{y} = f(\mathbf{x})$ 의 관계에서 무게중심을 구하는 문제와 동일하며, 이를 이산치에 적용하고 출력인 유사도에 대한 감도를 높이기 위하여 제곱의 형태를 취하면 다음과 같다.

$$\mathbf{w}_j = \frac{\sum_{h=1}^p (y_j^h)^2 \mathbf{x}^h}{\sum_{h=1}^p (y_j^h)^2} \quad (7)$$

모평균의 정의를 이용하여 정리하면, 가중치 변화량은 다음과 같이 나타낼 수 있다.

$$\begin{aligned} \Delta \mathbf{w}_j &= \frac{\sum_{h=1}^p y_j^h (\mathbf{x} - \mathbf{w}_j)}{\sum_{h=1}^p y_j^h} \\ &= \frac{\mathbf{w}_{u_j}}{\mathbf{w}_1}, \end{aligned} \quad (8)$$

III. 도로영상 기반 도로추적제어

1. 도로영상의 특징요소

근접한 거리에서 도로의 노면은 평면이고 도로 경계선이 평행하다고 가정을 한다면, 차량과 도로와의 기하학적인 관계에 의해 도로영상에서는 다음과 같은 특징점을 찾을 수 있다.

1) 소실점(vanishing point)의 측방향 위치(PD):

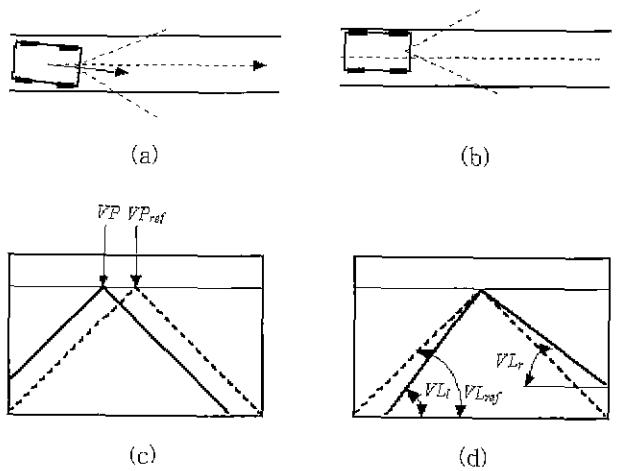
차량중심이 도로의 중앙에 위치하고 차량방향과 도로방향이 일치하면, 영상에서 도로는 그림 2(c) 또는 (d)의 점선과 같이 나타나며 소실점은 중앙에 나타나며 소실선은 좌우대칭이 된다. 이때를 기준 도로로 설정하여 기준 소실점(VP_{ref})과 기준 소실선(VL_{ref})으로 정의한다.

만약 차량이 그림 2(a)와 같이 차량중심은 도로 중앙에 위치하지만 차량방향이 도로방향에 대해 우측으로 향하면, 영상에서 도로는 그림 2(c)의 실선과 같이 나타난다. 이때 소실점의 위치(VP)는 기준 소실점에서 좌측으로 이동하며, (9)와 같은 기준 소실점과 현재 소실점의 차(PD)를 도로에서 차량을 조작하기 위한 특징요소로 나타낼 수 있다.

$$PD = VP_{ref} - VP \quad (9)$$

2) 소실선(vanishing line)의 좌우 기울기 차(LD):

도로영상에서 좌측 소실선의 기울기(VL_l)는 양의 값



----- 기준 도로 소실점
현재 도로 소실점
 VP_{ref} 기준 도로의 소실점 위치 VL_{ref} 기준 도로의 소실선 수평각
 VP 현재 도로의 소실점 위치 VL_l 현재 좌측도로의 소실선 수평각
 VL 현재 우측도로의 소실선 수평각

그림 2. 도로영상의 특징 요소.

Fig. 2. Criteria of road image.

을, 우측 소실선의 기울기(VL_r)는 음의 값을 가지며, 그 합은 0이 된다.

만약, 그림 2(b)와 같이 차량방향과 도로방향이 일치하지만 차량중심이 도로중앙에서 좌측으로 이동되면, 영상에서 도로는 그림 2(d)의 실선과 같이 나타난다. 이때 좌측 소실선 기울기의 크기는 커지고 우측 소실선 기울기의 크기는 작아지며, (10)과 같이 좌측 소실선 기울기와 우측 소실선 기울기의 차를 도로에서 차량을 조작하기 위한 특징요소로 사용할 수 있다.

$$LD = VL_l + VL_r \quad (10)$$

2. 시각제어기법

카메라의 영상은 도로의 소실점과 소실선을 포함하고 있다. 이 데이터는 기하학적 추론을 통하여 차량이 도로상에서 어떠한 위치와 방향을 가지고 있는지를 파악하게 한다. 이러한 관계에 근거하여 소실점과 소실선을 차량의 시각제어에 적용한다.

숙련된 운전자가 주행할 때의 도로영상을 살펴보면 도로의 중앙에서 벗어난 그림 3(a)과 같은 영상에서 차량이 도로의 중앙에 위치하고 차량의 방향이 도로방향과 일치한 그림 3(b)와 같이 영상으로 변화된다. 이와같은 도로영상에서 소실점의 위치와 소실선의 기울기는 도로 영상을 파악하는 특징요소이며, 이것에 따라 운전자는 차량의 조향각을 결정한다. 이때 조향각과 소실점, 소실선의 관계는 대단히 비선형적인 관계이다. 따라서 이러한 비선형적인 관계를 적절히 모델링하기 위한 신경회로망을 사용하여 제어기를 구성한다.

한편, 곡선도로를 주행할 경우에 도로영상은 그림 4(a)의 실선과 같이 곡선의 소실선을 갖게된다. 하지만 주행을 하기 위한 조향각은 가까운 거리에만 관심이 있게

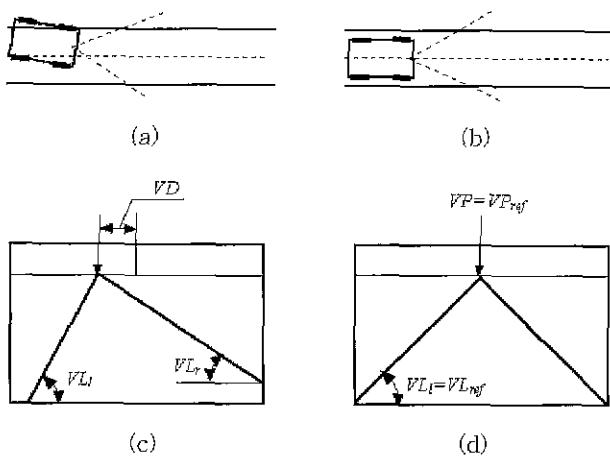


그림 3. 시각제어의 원리.

Fig. 3. Principle of visual control.

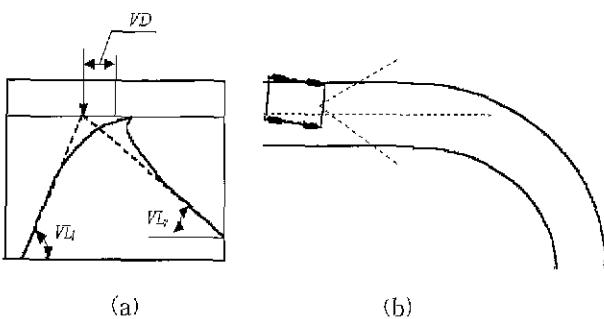


그림 4. 곡선도로에서 직선도로의 근사화.

Fig. 4. Approximation of linear road from curved road.

된다. 도로의 가까운 거리는 도로영상의 아래 영역에 해당하며 이 영역에 나타난 도로 경계선을 (a)의 점선과 같이 직선으로 근사화하여 소실선을 구하고 이로부터 소실점을 검출한다.

IV. 상대분할 신경회로망 제어기 구성

1. 학습데이터 획득

일반적으로 숙련된 운전자가 차량을 운전하면 대부분을 바른 경우만 발생하게 된다. 즉 도로의 중앙으로만 주행하므로 잘못된 경우에서 복원하는 과정의 데이터를 얻을 수 없다. 따라서 초기의 차량 위치를 도로 중앙에서 좌측이나 우측으로 벗어나게 하거나, 도로 방향과 각도가 어긋나도록 하여 출발한다. 운전자는 초기 오차에서 도로의 중앙으로 접근할 것이다. 이때 도로영상의 소실점의 위치와 소실선의 각도를 검출하여 제어기의 입력으로 사용하고, 운전자의 조향 제어 명령치를 획득한다. 그림 5는 획득된 학습데이터의 입력변수 PD 와 LD 에 따른 분포를 나타낸다. 초기에 차량방향이 도로방향과 어긋나고, 차량중심이 도로중앙에서 벗어나면, PD 와 LD 는 큰 값을 가져 데이터는 외곽에 위치한다. 반면 차량이 도로중심으로 이동함에 따라 PD 와 LD 는 감소하게되고 데이터의 위치는 내부에 위치한다. 차량이 다양한 초기 위치에서 출발하여 도로중심으로 이동한 결과 데이터를 나타내면

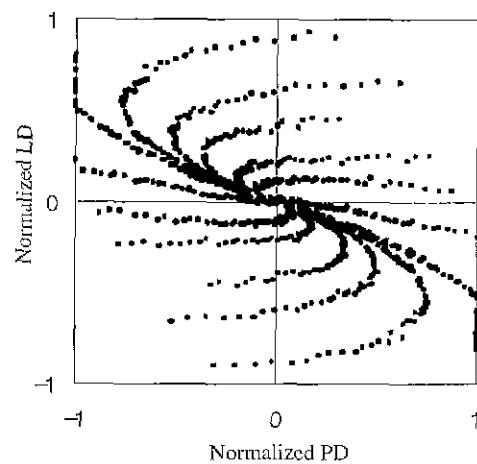


그림 5. 입력 테이터의 분포.

Fig. 5 Distribution of input data.

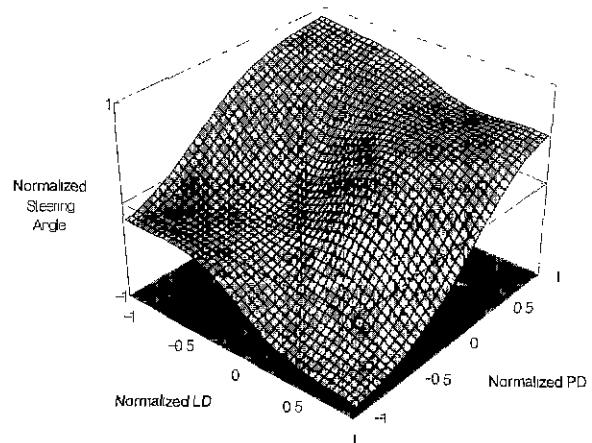


그림 6. 다층 신경회로망의 제어평면.

Fig. 6. Control surface of MNN.

그림 5와 같이 나선형 은하계 모양의 그래프를 얻는다.

2. 다층 신경회로망 제어기의 설계

다층 신경회로망을 이용하여 제어기를 설계한다. 다층 신경회로망의 구조는 입력층은 2개, 은닉층은 100개, 그리고 출력층은 1개의 세포로 구성하였다. 신경회로망의 학습율은 0.1로 하였으며, 충분한 학습을 위하여 100,000회를 수행하였다. 이는 PC상에서 개발한 시뮬레이션 프로그램을 통하여 학습하였다. 그림 6은 학습이 완료된 후 입력에 따른 제어기의 출력분포를 나타내는 제어평면이다.

다층 신경회로망은 은닉층의 세포를 증가시키고 학습회수를 크게 하더라도 학습결과에 의한 제어평면은 부분적인 특이점을 일반화시켜 나타남을 볼 수 있다.

3. 상대분할 신경회로망 제어기의 설계

상대분할 신경회로망을 이용하여 제어기를 설계한다. 상대유사도 경쟁학습을 이용한 분할 신경회로망에 의하여 입력공간은 데이터의 밀도에 따라 16개로 분할되었다. 이때 입력공간이 복잡한 부분이나 특이점이 존재하는 경우는 작은 영역으로 분할된다. 분할된 영역은 각 영역을 담당하는 16개의 학습 신경회로망에서 입력과 출

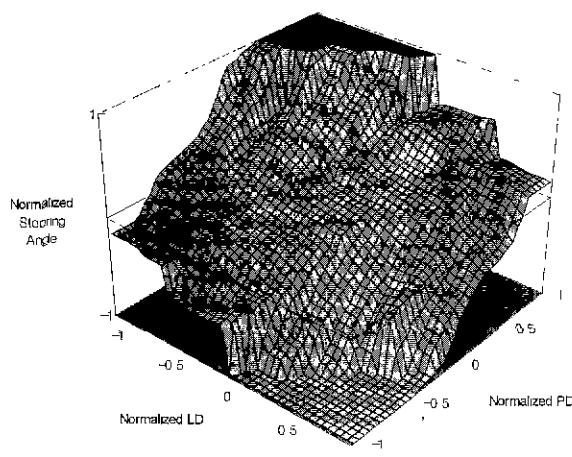


그림 7. 상대분할 신경회로망의 제어평면.

Fig. 7. Control surface of RSMN.

력의 관계를 학습한다. 1개의 학습 신경회로망은 3개의 은닉층으로 구성되었다. 따라서 분할 신경회로망의 출력 소자(16개)와 학습 신경회로망의 은닉층의 소자($16 \times 3 = 48$ 개)는 총 64개의 소자로 구성하여 다층 신경회로망보다 적은 소자로 구성하였다. 상대분할 신경회로망에 의한 학습결과를 보면 그림 7과 같이 부분적으로 복잡한 공간을 작은 공간으로 분할하여 학습하였음을 볼 수 있다. 이는 그림 6의 다층 신경회로망의 제어평면이 일반화되어 특정부분의 제어 출력이 무시되었던 부분을 학습할 수 있음을 나타낸다. 따라서 입출력 관계가 복잡하여 다층 신경회로망으로는 제어할 수 없었던 부분을 상대분할 신경회로망에서는 가능하게 됨에 따라 더 우수한 제어성능을 갖게된다.

V. 차율주행 모의실험

설계된 제어기의 타당성을 검증하기 위하여 시뮬레이터를 개발하였다. 먼저 차량을 구성하는 각종 요소들을 모델링하고, 도로와 차량, 카메라와의 관계들을 해석한 다음, 요소들을 이용하여 제작할 차량과 도로 환경에 맞도록 시뮬레이터를 구성하였다. 이때 사용된 차량의 모델, 카메라좌표 모델 등은 기존의 연구결과를 이용하였다[8][11][12].

프로그램 환경은 Windows 95^o이고 언어로는 C++을 사용하였다.

1. 직진도로에서 주행실험

직진 도로에서 초기 차량위치에 축면변위와 방향각을 변화시키는 외란을 주입하여 얼마나 빨리 도로 중앙으로 복귀하는가를 살펴보았다.

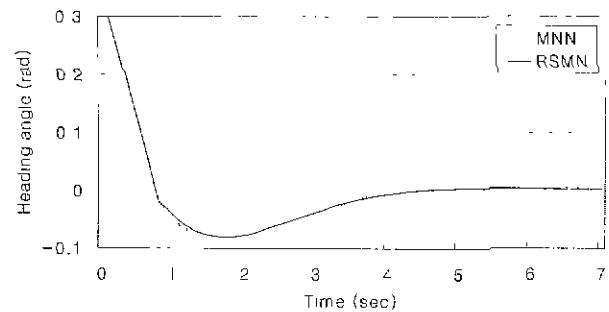
1) 초기 방향각(0.3[rad]) 오차에 대한 복원

최초의 차량중심을 도로중심에 일치를 하고 도로방향에 대해 차량방향을 좌측으로 0.3[rad] 회전시킨 상태에서 차량을 출발시켰다. 이 때 얼마나 신속하게 도로의 중앙으로 복귀하는가를 평가지표로 삼아 실험하였다. 실험결과로 그림 8을 보면 초기 방향각 오차에 대한 복원 능력은 RSMN가 MNN의 제어성능에 비해 다소 우수함

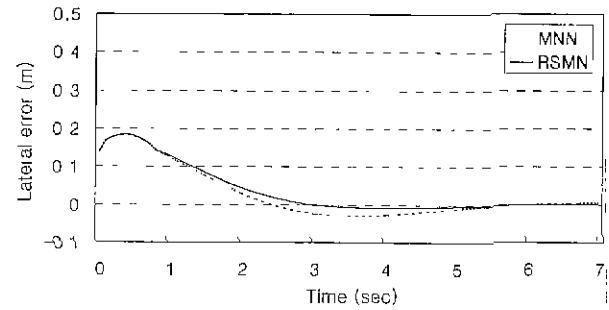


그림 8. 초기 방향각 오차에 대한 차량 주행 궤적.

Fig. 8. Trajectory of vehicle for initial heading angle.



(a)



(b)

그림 9. 초기 방향각 오차에 대한 결과.

Fig. 9. Results for initial heading angle (0.3[rad]) error. (a) Heading angle, (b) Lateral error.

을 볼 수 있다.

2) 초기 축면 변위 오차에 대한 복원

그림 10과 같이 최초의 차량중심을 도로의 좌측으로 0.5[m] 평행 이동시킨 상태에서 차량을 출발시켰을 때, 얼마나 신속하게 도로의 중앙으로 복귀하는가를 평가지표로 삼아 실험하였다.

실험 결과인 그림 10의 축면변위오차의 오버슈트를 살펴보면, MNN에 의한 제어결과는 우측으로 0.32[m] 벗어난 반면 RSMN은 0.12[m]만 벗어나 제한한 RSMN 제어가 MNN의 제어보다 우수함을 볼 수 있다.

2. 곡선도로(곡률반경 6[m])에서 주행실험

직선도로 5[m]와 곡률반경 6[m]인 곡선도로가 결합된 도로에서 주행결과를 살펴보았다. 그림 13과 표 1의 실험결과와 같이 곡률반경이 적은 곡선도로에서 부분적 학습이 양호한 RSMN이 일반화 특성을 가진 MNN보다 우수한 제어 결과를 나타내었다.

VI. 차율주행 전기자동차의 실험

설계 제작된 차율주행 전기자동차는 차체를 구성하는 기계적인 부분과 제어를 위한 전기적인 부분으로 구성되



그림 10. 초기측면 변위 오차에 대한 차량 주행 궤적.
Fig. 10. Trajectory of vehicle for initial lateral error.

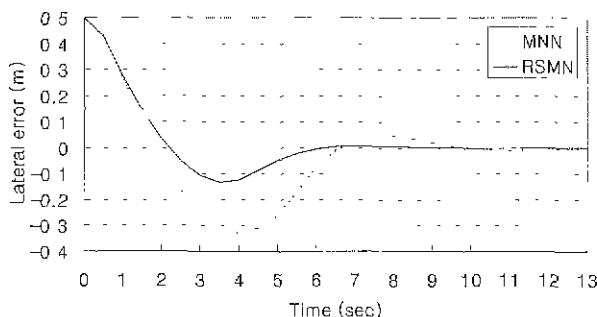


그림 11. 초기 측면오차(0.5[m])에 대한 결과
Fig. 11. Results for initial lateral error (0.5[m]).

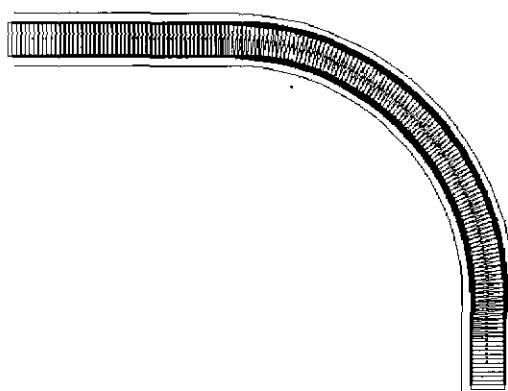


그림 12. 곡선도로에서 차량 주행 궤적.
Fig. 12. Trajectory of vehicle driving on curved road.

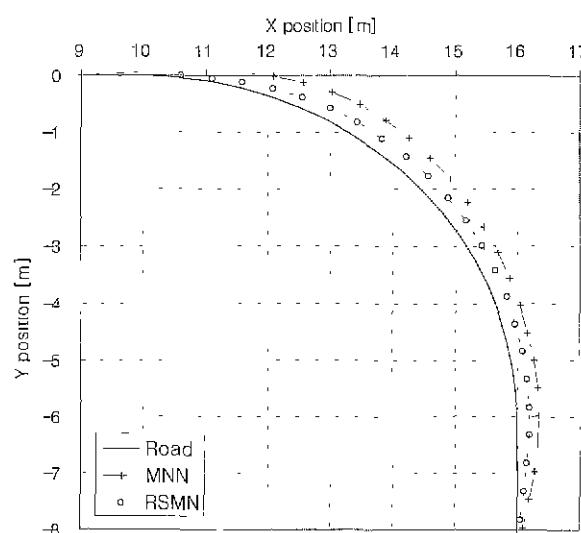


그림 13. 곡선도로에서 결과.
Fig. 13. Result in curved road.

표 1. 곡선도로에서 주행성능의 비교.

Table 1 Comparison of performance on curved road.

DPI Network	Integration of absolute lateral error [m]	Ratio [%]
MNN	4.5632	100.00
RSMN	2.0883	45.76

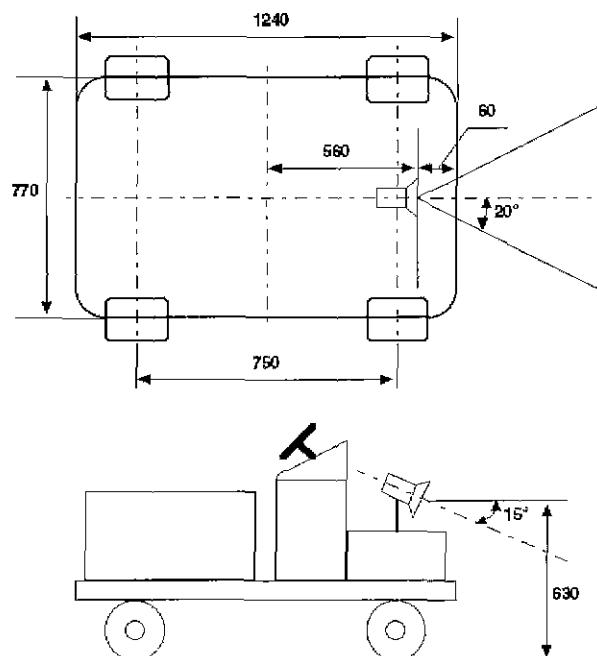


그림 14. CEVA-I의 기계적인 구성도.
Fig. 14. Mechanical structure of CEVA-I.

었으며, "Chonnam national university Electrical Vehicle for Autonomous driving - I (CEVA-I)"이라고 명명하였다. 차량선두에 탑재된 CCD카메라로부터 도로영상이 시각시스템에 입력되면 도로의 특징요소 인식 알고리즘에 따라 소실점의 위치와 소실선의 각도를 계산한다. 계산된 도로 특징요소가 상대분할 신경회로망 제어기에 입력되어 차량 전방에 나타난 도로를 벗어나지 않도록 알맞은 조향값과 속도를 계산한다. 조향 제어부는 컴퓨터의 조향 명령에 따라 모터를 좌, 우로 회전시키며, 후륜 구동모터의 속도 제어부는 지시된 차량속도에 따라 3상 유도 전동기를 구동시킨다.

1. 기계적인 구성

차량의 크기는 소형 승용차의 약 1/4 크기로 축소하여 설계하였다. 조향장치의 기계적인 구조는 실제 차량과 동일한 구조를 사용하였으며 구동을 위해 DC모터를 이용하였다. 따라서 DC모터의 회전력을 왕복운동으로 변환하는 기어에 의하여 앞바퀴는 좌우로 움직이도록 하고 최대 조향 각도는 좌 20[deg]에서 우 20[deg]이다. 뒷바퀴에는 차량의 구동력을 발생하는 구동장치로서 기어 내장형 유도 전동기를 이용하였다. 또한 차량 바닥의 요철을 흡수하고 충격완화 및 접지성을 향상시키기 위해 전륜과 후륜 전체에 스프링 현가장치(suspension)를 설치하였다. 제작 차량의 기계적인 구성 및 치수는 그림 14

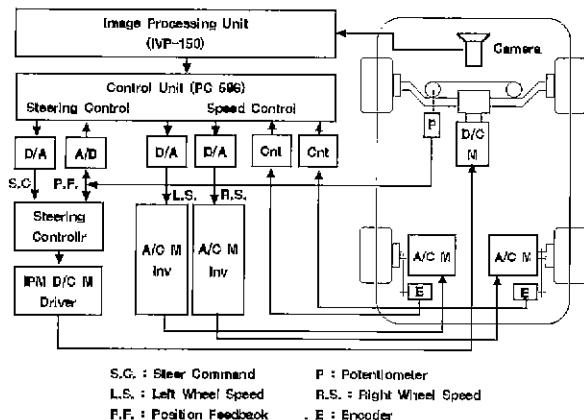


그림 15. CEVA-I의 제어장치 블록도.

Fig. 15. Block diagram of control system of CEVA-I.

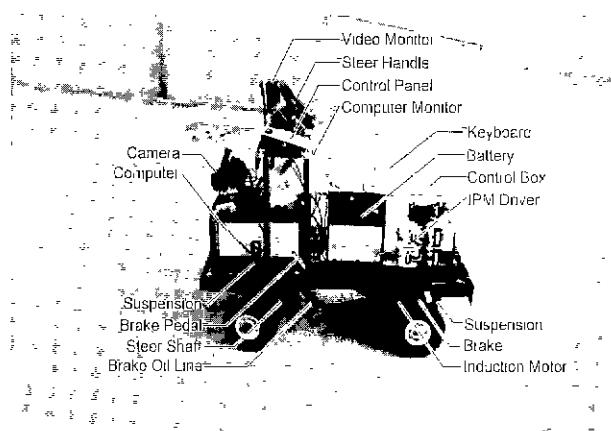


그림 16. CEVA-I의 사진.

Fig. 16 Photograph of CEVA-I

와 같다.

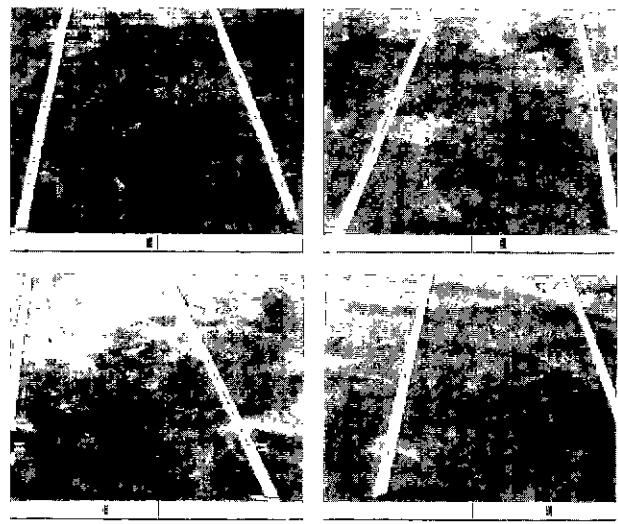
2 전기적인 구성

CEVA-I의 주 제어 컴퓨터는 전체 시스템을 총괄 관리하는 기능을 가지며 주로 주행 중에는 도로인식 알고리즘 및 상대분할 신경회로망 제어를 실행하여 입력된 카메라 영상에서 도로방향을 인식하고 조향각과 속도 제어신호를 발생한다. 또 각종 신호로부터 입력되는 정보를 처리, 관리하며 시스템의 상태를 점검하거나 감시하는 기능을 수행한다. 본 실험에 사용되는 주 컴퓨터는 시스템의 확장과 자유로운 프로그램을 고려하여 범용 PC (CPU: Pentium -200MHz)를 채택하였고 모든 주변 장치들은 일반 PC와 호환성을 유지하도록 설계하여 제작하였다.

3 도로 주행 실험

카메라에서 도로영상이 입력되면 DSP 영상처리 보드 (IPV-150)는 도로영상의 특징요소인 소실점의 위치와 소실선의 각도를 검출한다. 그리고 신경회로망을 이용한 도로추적제어기의 알고리즘에 의하여 조향각을 계산한다.

이와같은 과정이 정상적으로 처리되었는지를 실시간으로 확인하기 위해 DSP보드의 영상편집기능을 이용하여



(a)

(b)

그림 17. 도로영상에 따른 조향 명령. (a) 좌측방향, (b) 우측방향.

Fig. 17. Steering command according to road image. (a) Left direction, (b) Right direction.

획득된 도로영상에 계산된 값을 중첩시킨 영상을 출력하도록 하였다.

그림 17에 실시간으로 출력된 영상중 일부를 나타내었다. 도로영상에는 검출된 좌우측 도로와 소실선을 중첩하였으며 화면하단에는 차량 알고리즘에 의하여 계산된 조향각을 사각점으로 나타내었다. 조향각의 값을 나타내는 사각점은 중앙을 기준으로 좌우로 멀수록 조향각이 커지는 것을 의미한다. 그림 17(a)의 도로영상을 살펴보면 우측 도로경계선이 영상중앙으로 이동되어있다. 이로서 차량이 도로중심에서 우측으로 이동되어있음을 알 수 있다. 따라서 차량이 좌측으로 이동할 수 있도록 조향각을 좌측방향으로 출력해야 한다. 화면 하단의 사각점은 조향출력을 나타내며, 좌측으로 출력해야함을 나타내고 있다. 반면, 그림 17(b)의 도로영상을 살펴보면 좌측 도로경계선이 영상중앙으로 이동되어있다. 이는 차량이 도로중심에서 우측으로 이동되어있음을 알 수 있다. 따라서 차량이 좌측으로 이동할 수 있도록 조향각을 좌측방향으로 출력해야 한다. 화면 하단의 사각점은 조향출력을 나타내며, 좌측으로 출력해야함을 나타내고 있다.

실험조건으로 도로의 폭은 1.2[m]이고, 도로 경계선의 두께는 5[cm]이며, 직선부분과 좌우로 굽은 곡선부분을 혼용하여 약 30[m]로 설정하였다. 곡선부분은 좌회전 시곡률 반경은 6[m], 회전각도 90[deg]로 하였고, 우회전 시곡률 반경은 7[m], 회전각도는 90[deg]로 구성하였다. 차량의 속도는 70[cm/s]로 정속 주행하였다. 그림 18은 위와 같은 조건에서 차량을 자율주행하는 실험 장면을 나타낸다. 이와 같은 실험을 통하여 제안한 도로추적 제어기를 차량에 적용하여 곡선도로를 주행할 수 있음을 확인하였다.

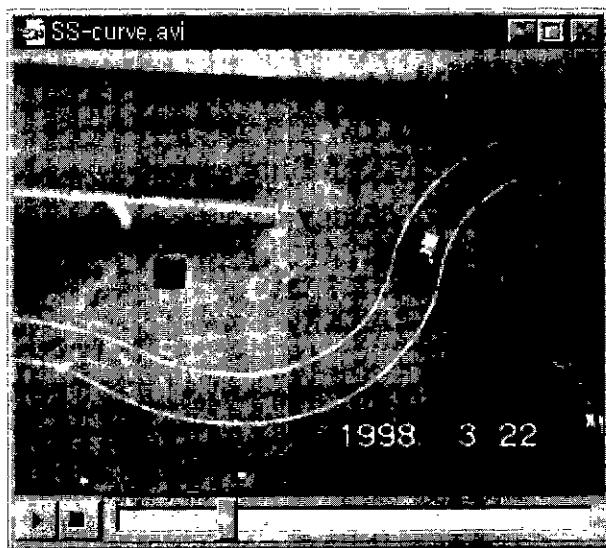


그림 18. 곡선도로에서 자율주행실험.

Fig. 18. Autonomous driving test on curved road.

VII. 결론

본 논문에서는 새로운 구조의 상대분할 신경회로망을 제안하고 이를 자율주행시스템의 도로영상기반제어에 적용하여 도로추적제어기를 설계하였다. 제안한 상대분할 신경회로망의 분할망을 위하여 상대유사 경쟁학습망을 정의하였다. 컴퓨터 상에서 카메라의 도로영상과 차량과 도로관계를 분석하고 제안한 제어기의 성능을 모의실험하기 위한 시뮬레이션 프로그램을 개발하였다. 모의실험을 통하여 제안한 상대분할 신경회로망이 기존의 다층 신경회로망의 제어 결과보다 우수함을 분석하였다. 마지막으로 제안한 도로추적제어기의 유용성을 검증하기 위하여 전기자동차를 설계하였다. 제작된 전기자동차를 이용하여 곡선도로에서 도로영상의 특징요소를 검출하고 적절한 조향각을 출력함으로써 차량의 도로추적제어를 구현하였다.

참고문헌

- [1] R. K. Jurgen, "Smart cars and highways go global," *IEEE Spectrum*, pp. 26-36, May, 1991.
- [2] S. Tsugawa, "Vision-based vehicles in Japan: machine vision system and driving control systems," *IEEE Trans. Industrial Electronics*, vol.

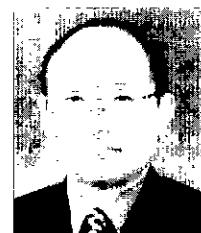


류영재

1968년 1월 9일생. 1991년 전남대학교 전기공학과 학사. 1993년 전남대학교 전기공학과 석사. 1998년 전남대학교 전기공학과 박사. 현재 전남대학교 고품질전기전자부품및시스템 연구센터 조교 및 Post-Doc. 연구원.

41, no. 4, August, 1994.

- [3] 임영철, 류영재, "자율주행차량의 연구동향", 전기학회지, 제45권, 제5호, pp. 42-46, 1996.
- [4] S. Baluja, "Evolution of an artificial neural network based autonomous land vehicle controller," *IEEE Trans. Systems, Man, and Cybernetics-Part B: Cybernetics*, vol. 26, no. 3, pp. 450-463, June, 1996.
- [5] K. M. Passino, "Intelligent control for autonomous systems," *IEEE Spectrum*, pp. 55-62, June, 1995.
- [6] M. Dorigo, "Introduction to the special issue on learning autonomous robots," *IEEE Trans. Systems, Man, and Cybernetics-Part B: Cybernetics*, vol. 26, no. 3, pp. 361-364, June, 1996.
- [7] T. Hessburg and M. Tomizuka, "Fuzzy logic control for lateral vehicle guidance," *IEEE Control Systems*, pp. 55-63, August, 1994.
- [8] S.-H. Yang, F. Harashima, Y.-C. Lim, K.-Y. Cho, Y.-J. Ryoo, "Steering control system for autonomous road vehicle using fuzzy neural network," *Transactions IEE of Japan*, vol. 115D, no. 11, pp. 1373-1379, Nov., 1995.
- [9] 류영재, 홍지영, 임영철, "인공지능을 이용한 자율주행차량의 제어", 전기학회지, 제46권, 제3호, 20-25, 1997.
- [10] R. A. Jacobs and M. I. Jordan, "Learning piecewise control strategies in a modular neural network architecture," *IEEE Trans. SMC*, vol. 23, no. 2, pp. 337-345, 1993.
- [11] Y.-C. Lim, Y.-J. Ryoo, J.-K. Park, E.-S. Kim, T.-G. Kim, C.-J. Moon, "Visual control of an autonomous vehicle using neural networks," *IEEE Proceedings of the IECON'96*, pp. 1064-1069, Aug., 1996.
- [12] Y.-J. Ryoo and Y.-C. Lim, "Visual control of autonomous vehicle by neural networks using fuzzy-supervised learning," *Journal of Electrical Engineering and Information Science*, vol. 2, no. 2, pp. 77-85, 1997.



임영철

1953년 4월 23일생. 1975년 전남대학교 전기공학과 학사. 1977년 고려대학교 전기공학과 석사. 1990년 고려대학교 전기공학과 박사. 현재 전남대학교 전기공학과 교수. 전남대학교 고품질전기전자부품 및 시스템 연구센터 소장.