

감정평가에 기반한 환경과 행동패턴 학습을 위한 궤환 모듈라 네트워크

Learning for Environment and Behavior Pattern Using Recurrent Modular Neural Network Based on Estimated Emotion

김성주, 최우경, 김용민*, 전홍태

Seong-Joo Kim, Woo-Kyung Choi, Yong-Min Kim*, Hong-Tae Jeon

중앙대학교 일반대학원 전자전기공학부

*충청대학 컴퓨터학부

요약

감정은 지능을 지닌 존재의 이성판단에 영향을 준다. 그래서 주변 환경정보에 의해 평가된 기본적이고 보편적인 감정을 로봇에 가미하면 더욱 인간과 가까운 지능 로봇이 될 것이다. 그러나 인간의 감정을 학습하기 위해서는 다양한 감각정보의 학습과 패턴 분류가 선행되어야 하고 이를 위해서 적합한 네트워크 구조가 요구된다. 신경망은 시스템의 특징을 추출하는데 매우 우수한 능력을 발휘하고 있다. 그러나 일시적 혼선현상과 지역 최소치에 수렴하는 단점이 있다. 그래서 복잡한 문제를 단순한 여러 개의 부분적인 문제로 나누어 해결하는 모듈라 설계방법이 관심의 대상이 되고 있다.

본 논문에서는 수많은 감정평가와 학습 데이터 패턴들을 학습하기 위해서 제결합과 재구성에 탁월한 성능을 지닌 Jacobs 와 Jordan이 제안한 모듈라 네트워크와 상황의 재 표현이 가능하고 예측값과 모델링에 적합한 특징을 지닌 궤환 신경망을 결합하였다. 구성된 구조는 기존의 모듈라 네트워크의 학습결과와 비교 검토하였다.

Abstract

Rational sense is affected by emotion. If we add the factor of estimated emotion by environment information into robots, we may get more intelligent and human-friendly robots. However, various sensory information and pattern classification are prescribed for robots to learn emotion so that the networks are suitable for the necessity of robots. Neural network has superior ability to extract character of system but neural network has defect of temporal cross talk and local minimum convergence. To solve the defects, many kinds of modular neural networks have been proposed because they divide a complex problem into simple several sub problems. The modular neural network, introduced by Jacobs and Jordan, shows an excellent ability of re-composition and re-combination of complex work. On the other hand, the recurrent network acquires state representations and representations of state make the recurrent neural network suitable for diverse applications such as nonlinear prediction and modeling.

In this paper, we applied recurrent network for the expert network in the modular neural network structure to learn data pattern based on emotional assessment. To show the performance of the proposed network, simulation of learning the environment and behavior pattern is proceeded with the real time implementation. The given problem is very complex and has too many cases to learn. The result will show the performance and good ability of the proposed network and will be compared with the result of other method, general modular neural network.

Key Words : Emotion, Neural Network, Modular Network, Recurrent Neural Network.

1. 서 론

로봇은 산업현장뿐만 아니라 인간의 생활에까지 적용범위가 점차 확대되고 있다. 영상인식, 음성인식 등의 인간능력은 모방한 기술들이 로봇에게 이전·적용되면서 인간형 로봇이 등장하고 있다. 지금까지는 인간의 이성만을 생각하여 모델링 했지만 감정도 역시 인간의 중요한 의사결정에 영향을 주

므로 고려되어야 할 사항이다. 감정은 지능을 지닌 존재의 사고 과정으로부터 나오는 것으로 인간의 이성판단에 영향을 준다. 그래서 감각센서에서 얻은 정보에 감정적 요소를 가미하면 보다 인간과 유사한 지능 로봇이 될 것이다. 감정은 기본적으로 여러 가지 환경 변화에 영향을 받으므로 여러 가지 센서를 이용하여 정보를 수집하고 환경 정보에 따른 로봇의 감정을 평가하였다. 많은 감정 정보의 처리와 패턴분류를 위해서는 이에 적합한 네트워크가 필요하다. 지능형 기법이 가져야 하는 두 가지 필수 요소는 불확실성의 취급 기능과 반복운전을 통해 성능을 향상시키는 학습 기법이다. 대표적인 방법으로는 소프트 컴퓨팅으로 이 기법은 학습 능력, 병렬분산 처리와 계산능력, 적응성, 추론 능력 등을 보유하여 어느 알고리즘보다 인간의 문제 해결능력과 유사한 기법이라 할

접수일자 : 2003년 11월 10일

완료일자 : 2003년 12월 29일

감사의 글 : 본 연구는 2003년도 중앙대학교 학술연구비 지원에 의한 것임.

수 있다. 다양한 분야에 적용되고 있는 다층 신경망(Multilayer Neural Network; MLNN)과, 퍼지 논리(Fuzzy Logic), 유전 알고리즘(Genetic Algorithm)등이 이에 속한다[1][2][3].

신경망은 주어진 정보를 이용하여 학습을 가능하게 함으로써 주어진 시스템의 특징을 추출하는데 매우 우수한 능력을 발휘하고 있다. 그러나 이전에 학습한 매핑 결과를 잊어버리는 일시적 혼선(temporal cross talk)현상이 발생하고, 학습과정에서 비선형성과 역전파(Back-propagation) 학습 알고리즘으로 인해 지역 최소치에 수렴하는 단점이 있다.

그리하여 각각의 지역적인 매핑방법과 전역적인 매핑방법의 장점을 수용하고 하나의 복잡한 문제를 단순한 여러 개의 부분적인 문제로 나누어 해결하는 방식을 수용한 모듈라 설계방법이 관심의 대상이 되고 있다[1]. 모듈화된 시스템은 학습속도가 향상되고, 전체망의 규모가 축소된다. 또한 전체 문제를 해결함과 동시에 세부적인 문제들에 대한 해결능력이 뛰어나며, 구종의 단순화로 하드웨어 구현이 용이하다. 결국 모듈화 설계에 의한 시스템은 전체의 복잡한 문제를 지역화 시킨 부문제로 분산하여 연산을 행한다. 따라서 전체 시스템의 동작을 통해 부분적인 시스템의 역할을 정의할 수 있다. 그리고 모듈화 설계를 통해 신경망의 다른 활성화 함수나 다른 네트워크 구조를 사용할 수 있으며, 각 모듈에 다른 종류의 학습 알고리즘을 사용할 수 있는 장점을 가지고 있다[1][4][5][6][7].

특히 Jacobs와 Jordan이 제안한 모듈라 신경망(Modular Neural network; MNN)은 작업 재구성과 학습, 재결합의 관점에서 탁월한 성능을 발휘하고 있다[8]. MNN은 모듈을 구성하는 엑스퍼트 네트워크(Expert Network; EN)과 게이팅 네트워크(Gating Network; GN)로 구성된다. 지금까지 MNN의 대부분의 연구에서는 EN에 단층 신경망(Single Layer Neural Network; SLNN)이나 MLNN으로 구성하였다.

학습에 있어서 전체 네트워크의 상태는 순차적으로 입력되는 값만큼 그 이전 상태에서 연산된 값에도 많은 영향을 받게 된다. 궤환 신경망(Recurrent Neural Network; RNN)은 궤환 루프를 통해 상황의 재 표현이 가능하므로 비선형 시스템(non-linear system)의 예측값과 모델링에 적합한 장치(device)들을 만드는 데 도움을 주고 작은 네트워크 구조로 그 보다 큰 전방향 네트워크(feed-forward network)의 역할을 수행할 수 있다[1]. 여러 종류의 궤환 신경망들은 통신 채널의 평준화, 음성처리, 플랜트 조절, 자동차 엔진진단, 자연어의 문법의 추론[15] 등에 사용되고 있다.

본 논문에서는 인간의 이성 판단에 영향을 주는 다양한 감정들 평가와 학습 데이터 패턴들을 학습하기 위해서 재결합과 재구성에 탁월한 성능을 지닌 Jacobs와 Jordan이 제안한 MNN에 상황의 재 표현이 가능하고 예측값과 모델링에 적합한 특징을 지닌 RNN을 결합하고자 한다. 그래서 기존의 연구결과를 바탕으로 EN을 구성하는 네트워크를 RNN을 사용하여 궤환 모듈라 신경망(Recurrent Modular Neural Network; RMNN)을 구성하였다. 그리고 구성된 구조는 기존의 MNN 학습결과와 비교 검토하였다.

2. 감정을 고려한 감각정보 처리

2.1 감정 정보처리를 위한 공학적 해석

인간은 감정 반응을 이용하여 강한 감정 반응을 유도하는 감각 입력에 대해서는 강한 기억을 하게 되고, 반대의 경우

에는 약한 기억을 하게 되는 특징으로 인해 그 감정에 따라 같은 감각 입력에도 여러 종류의 행동패턴을 수행할 수 있다. 일반적인 기계적 제어 시스템과는 달리 인간 두뇌 시스템의 경우 감정적인 요인이 제어에 상당한 영향을 미친다는 의학적 보고에 따라 일차적인 환경요소에 의한 감정요인을 적용하여 학습 데이터를 얻었다.

인간의 복잡한 감정 중에서 우리가 알고 있는 보편적인 것들만을 정의하고 지능 로봇의 학습에 이용하고자 한다. 감정은 일차적으로 여러 가지 환경 변화에 따라 결정된다. 감정에 영향을 주는 환경정보들은 여러 가지가 있지만, 본 논문에서는 현재의 온도, 연기 상태, 밝기, 장애물의 거리로 정하였다. 그 값들은 각각의 센서에 의해 측정되었으며, 감정 형성의 입력값으로 사용하였다. 이 환경 정보값은 상, 중, 하로 나누어져 총 9가지 형태의 감정요소에 영향을 준다. 감정요소로는 놀람, 기분상태, 만족도 세 가지로 나누었다. 놀람(E_*)은 급작스런 환경 변화로 인하여 현재 운동 패턴의 중지 및 새로운 패턴 요구의 의지로 표현된다. 기분상태(E_H)는 환경변화에 따른 감정적인 좋아함과 싫어함 정도를 표현하며, 이러한 두 요소들과 각각의 환경정보에 대한 민감도의 결합으로 만족도(S)를 결정하게 된다. 기분상태는 식 (1)에, 놀람은 식 (2)에서 계산된다.

$$E_H(n) = F(E_h(n) + E_*(n)) \quad (1)$$

$$E_*(n) = F(E_*) \quad (2)$$

$$E_h(n) = \sum_{i=1}^m (\langle x_i(n-1), x_i(n) \rangle \times s_i)$$

$$E_*(n) = \sum_{i=1}^m (\langle x_i(n-1), x_i(n) \rangle \times s_i)$$

여기서 $x_i(n)$ 은 시간 n 에서의 환경상태를 나타내며 i 는 적용되는 환경요소의 개수이다. 본 논문에서는 4가지의 환경요소를 사용하였다. 환경요소 변화에 따른 호감도는 $\langle x_i(n-1), x_i(n) \rangle$ 이며 표 1과 같다. \langle , \rangle 은 전 단계와 현재의 환경상황 변화에 따른 호감도를 표현하는 연산자로 정의하였다. s_i 는 환경요소에 대한 민감도로 표 2에 나타내었다. $F(\cdot)$ 는 시그모이드 함수이다. 먼저 E_h 는 온도의 시간 $n-1$ 와 n 에서 값을 구하고 이 값에 온도 민감도를 곱한다. 나머지 연기, 밝기, 장애물 거리들도 표 1을 이용하여 호감도를 구하고 표 2의 환경요소의 민감도와 곱한 다음 구한 환경요소 4개의 값을 더한다. E_* 도 역시 위의 방법과 같이 계산하고 호감도의 조건이 없는 경우는 0으로 한다. 식 (1)에서처럼 기분상태는 E_h 와 E_* 를 더하여 시그모이드 함수에 적용한다. 만족도(S)는 놀람과 기분상태에 의해 결정되는데 기분상태에 따른 만족도(S_{emo})와 행동패턴 결과에 따른 만족도(S_{act})로 이루어진다. 만족도는 식 (3)에 의해서 구해진다.

표 1. 환경요소 변화에 따른 호감도
Table 1. Emotion Maps

		Temperature			Smog			
		H	N	L	H	N	L	
Astonished (n-1 \ n)	H	0.8	0.2	0	L	0.6	0.4	0
	L	0.8	0.2	0	H	0	0.2	0.8
Brightness								
		Distance						
Astonished (n-1 \ n)	H	0.8	0.2	0	L	0.6	0.4	0
	L	0.8	0.2	0	H	0	0.2	0.8

(a) 놀람에 대한 Emotion Map

			Temperature			Smog			
			H	N	L	H	N	L	
Likable (n-1 \ n)	H	-0.7	0.6	-0.4		H	-1.0	0.4	0.8
	N	-0.5	0.5	-0.5		N	-0.6	-0.5	0.6
	L	-0.6	0.7	-0.5		L	-0.8	-0.6	0.5
			Brightness			Distance			
Likable (n-1 \ n)	H	-0.7	0.6	-0.5	HG	0.8	-0.4	-0.8	
	N	-0.5	0.5	-0.5	NM	0.6	0.5	-0.6	
	L	-0.6	0.6	-0.5	LO	0.7	0.5	-0.8	

(b) 기분상태에 대한 Emotion Map

표 2. 환경정보에 대한 민감도

Table 2. Sensitive of environment

	TMP	SMG	BRT	DIS
Sensitivity	0.3	0.8	0.3	0.5

$$S = S_{emo} + S_{act} \quad (3)$$

$$S_{emo} = E_H \times \lambda_{emo}$$

$$S_{act} = \Delta E_{H_{n-T}^n} \times \lambda_{act}$$

여기서 λ_{emo} 와 λ_{act} 는 기분상태와 행동패턴 결과에 따른 만족도 적용지수이고, 각각 0.3, 0.7로 하였다. S_{act} 는 행동패턴이 시작된 시간($n-T$)과 현재의 시간(n)의 기분상태 변화량을 나타내고 있다. 행동패턴은 감정의 상태 중 만족도와 기분상태의 영향을 받으며 각 상태의 High, Normal, Low로 9가지의 경우로 나누어진다. 로봇은 주어진 환경의 주위환경 상황을 파악하여 이전의 만족도와 현재의 만족도를 비교하여 만족도가 좋아질 경우는 같은 행동을 수행하고 나빠질 경우는 이동한 행동패턴을 제외한 다른 행동패턴이 선택되어진다. 이렇게 함으로써 만족도가 좋은 장소를 찾아 이동하게 하였다. 행동패턴은 일정시간동안의 방향을 가진 행동에 대해 사전에 정의한 것이다. 상황변경이 어렵다고 판단될 경우 환경이 바뀔 때까지 기다리는 수면상태로 들어가게 되고 환경이 바뀌게 되면 다시 활동 상태로 변경하게 된다.

3. Modular Neural Network

다층 신경망의 단점을 보완한 모듈라 신경망은 복잡한 문제를 단순한 부문제로 나누어 해결하기 때문에 학습속도 향상, 사용되는 매개변수 감소, 표현능력 증가, 그리고 구조를 단순화시킬 수 있다. 이런 장점 때문에 모듈라 시스템에 대한 이론적인 토대가 마련되고, 다양한 분야에서 이용되고 있다[9][10][11]. 대표적인 구조에는 Hierarchical modules, ART-BP model, Decoupled modules, Multiple experts, Multiple identical networks 등이 있다[12].

3.1 다층 신경망을 사용한 모듈라 네트워크

작업 재구성과 학습, 재결합의 성능이 탁월한 Jacobs와 Jordan이 제안한 모듈라 신경망은 EN에 단층 또는 다층 신경망을 사용하였다. 모듈라 네트워크의 EN은 모듈화식 설계 방식을 도입하여 복잡한 문제를 단순한 부문제로 나누어 부문제로 학습한다. 또한 GN은 입력공간을 적당하게 분할하여 EN이 해당 입력공간에서 학습이 수행되도록 조정해 주며,

EN의 출력을 조합하고 최종출력을 생성하도록 스위칭 역할을 수행한다[1][8]. 구조는 그림 1에 표현하였다.

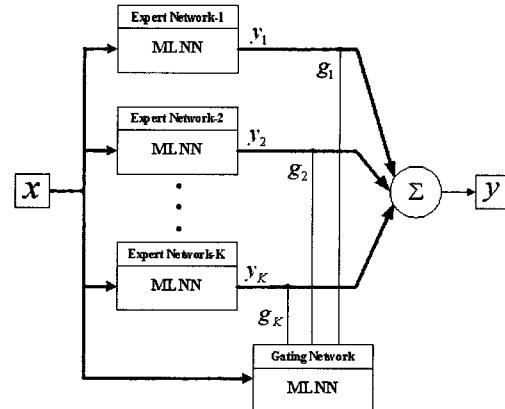


그림 1. 다층신경망을 이용한 모듈라 신경망

Fig. 1. Block diagram of MNN using MLNN

입력벡터는 $x = [x_1 \ x_2 \ \dots \ x_p]^T$ 로 P차원이고, MNN의 최종출력 벡터는 $y = [y_1 \ y_2 \ \dots \ y_Q]$, k 번째 EN의 $Q \times 1$ 출력벡터는 $y_k = [y_k^1 \ y_k^2 \ \dots \ y_k^Q]^T$, 응답벡터는 $d = [d_1 \ d_2 \ \dots \ d_Q]^T$ 이다.

MNN의 최종출력은 식 (4)과 같다.

$$y = \sum_{i=1}^M g_i y_i \quad (4)$$

i 는 EN의 개수이고, g_i 는 i 번째 GN의 출력이며, y_i 는 i 번째 EN의 출력벡터이다.

GN의 i 번째 가중치(weight)와 입력의 곱의 합이 u_i 일 때, 사전확률(prior probability)인 GN의 최종출력은 soft-max 함수를 사용하여 다음과 같이 나타낼 수 있다.

$$g_i = \frac{\exp(u_i)}{\sum_{j=1}^M \exp(u_j)} \quad (5)$$

여기서 EN의 수와 GN의 출력수가 일치해야 하며, 표준화(normalize)함수인 g_i 는 모든 i 에 대해서 $0 \leq g_i \leq 1$ 과 $\sum_{i=1}^M g_i = 1$ 을 만족한다. 매개변수 GN 출력 g 와 EN의 가중치 w 는 확률적인 강화 학습과 체인룰을 적용하고, 분석을 좀더 용이하게 하기 위해 $f(dx)$ 의 자연로그 형태인 단조증가 로그비용함수(logarithm cost function)가 최대가 되도록 동시에 개선하며 식은 다음과 같다.

$$\begin{aligned} l(w, g) &= \ln f(d | x) \\ &= \ln \sum_{i=1}^L g_i \exp\left(-\frac{1}{2} | d - y_i |^2\right) \end{aligned} \quad (6)$$

결국, 위에서 언급한 학습 패턴의 가우스 분포는 로그 비용함수의 기울기 상승(gradient ascent) 방법에 의해서 모델링된다. 이러한 기울기를 계산하기 위해서는 GN의 출력에 관하여 로그 비용함수의 편미분을 고려해야 하는데 soft-max 함수와 체인룰을 이용 사후 확률(posterior probability)을 정의할 수 있다[13].

$$h_i = \frac{g_i \exp\left(-\frac{1}{2} |d - y_i|^2\right)}{\sum_{j=1}^k g_j \exp\left(-\frac{1}{2} |d - y_j|^2\right)} \quad (7)$$

3.2 케환 신경망을 사용한 모듈라 네트워크

케환 신경망을 사용한 모듈라 네트워크는 다층 신경망을 사용한 모듈라 네트워크의 GN 구조는 같지만, EN에 다층 신경망 대신 케환 신경망을 사용한 점이 다르며, 이점이 네트워크의 학습에 큰 영향을 줄 것이다. 이 네트워크의 구조는 다음 그림에 나타내었다.

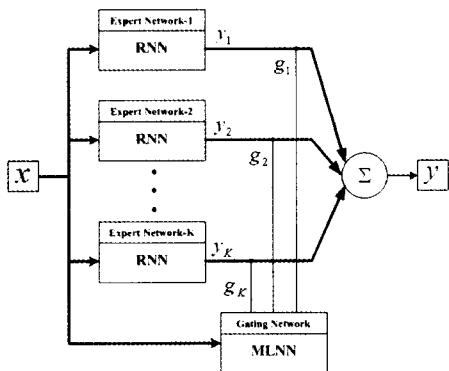


그림 2. 케환 신경망을 이용한 모듈라 네트워크
Fig. 2. Block diagram of MNN using RNN

3.2.1 엑스퍼트 네트워크의 구조

기본적인 RNN의 전역 케환의 형태는 다층 신경망 출력층에서 입력층으로 케환하는 형태와 은닉층에서 입력층으로 전역 케환하는 형태가 있다. MLNN의 은닉층이 둘 또는 그 이상일 때 지역 또는 전역 케환의 형태는 한층 더 확장된다. 여러 번의 처리 과정이 지난 후, 케환 노드는 가중치와 함께 케환 루프를 통해 전 단계로부터 케환값의 활성화에 대한 정보를 가진다[14].

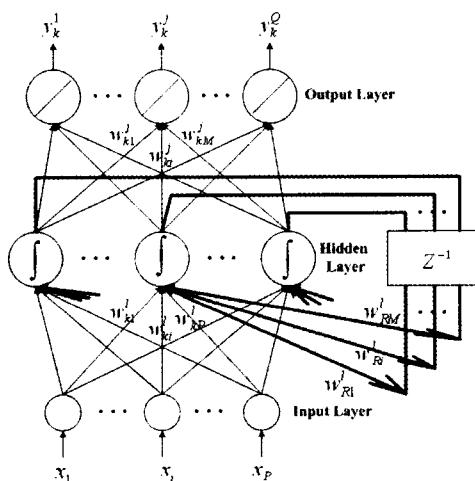


그림 3. 케환 신경망으로 구성된 엑스퍼트 네트워크
Fig. 3. The expert network with recurrent neural network

본 논문에서는 Elman에 의해 연구 발표된 Elman network 구조를 사용하였다. Elman 네트워크를 “simple

recurrent network(SRN)”라고도 한다[1][15]. 은닉 뉴런은 네트워크의 상태를 명시하고 은닉층의 출력은 지연(delay) 유닛 뱅크(bank)를 거쳐 입력층에 케환한다. 입력층은 케환 노드와 입력 노드로 구성된다. 이 네트워크는 입력 노드를 통해 외부의 환경과 연결되고 영향을 받는다. Elman 네트워크 구조는 그림 1에 나타내었다.

입력은 P개, 은닉층은 M개 노드, 출력층은 Q개의 노드로 구성되었다.

k 번째 EN의 은닉층 l 번째 출력은 다음과 같다.

$$\begin{aligned} s_k^l(n+1) &= f \left(\sum_{i=1}^P w_{ki}^l x_i(n) + \sum_{i=1}^M w_{kRi}^l r_i(n) \right) \\ &= (\mathbf{w}_k^l \mathbf{x}(n) + \mathbf{w}_{KR}^l \mathbf{r}(n)) = f(\# t_k^{(l)}) \end{aligned} \quad (8)$$

여기서 w_{ki}^l 은 입력-은닉층의 가중치, 가중치 벡터는 $\mathbf{w}_k^l = [w_{k1}^l \ w_{k2}^l \ \dots \ w_{kP}^l]$, 입력은 $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_P]^T$, x_i 는 i번째 입력이다. 그리고 w_{kRi}^l 은 케환 루프의 가중치, $\mathbf{w}_{KR}^l = [w_{kR1}^l \ w_{kR2}^l \ \dots \ w_{kRM}^l]$ 는 가중치 벡터, r_i 는 시간 n에서 i번째 은닉층의 출력으로 다시 은닉층의 입력값으로 사용된다. 함수 $f(\cdot)$ 는 bipolar sigmoid 함수이다.

k 번째 EN의 j 번째 출력은 식 (9)에 나타내었다.

$$\begin{aligned} y_k^j(n+1) &= f \left(\sum_{i=1}^M w_{kj}^i f \left(\sum_{i=1}^P w_{ki}^l x_i(n) + \sum_{i=1}^M w_{kRi}^l r_i(n) \right) \right) \\ &= f(\mathbf{w}_k^j \mathbf{s}_k(n+1)) = f(\# t_k^{(e)}) \end{aligned} \quad (9)$$

$j = 1, 2, \dots, Q$, w_{kj}^j 는 은닉-출력층의 가중치, $\mathbf{w}_k^j = [w_{k1}^j \ w_{k2}^j \ \dots \ w_{kM}^j]$ 는 가중치 벡터, 은닉층 출력 벡터는 $\mathbf{s}_k(n+1) = [s_k^1(n+1) \ s_k^2(n+1) \ \dots \ s_k^M(n+1)]^T$ 이다. 또 $f(\cdot)$ 는 선형함수를 나타낸다.

4. 학습 알고리즘

MNN와 RMNN을 학습하는데 사용되는 알고리즘의 궁극적인 목적은 학습 패턴의 확률분포를 모델링하는 것이다. 이를 위해 학습 알고리즘은 확률적인 기울기 학습 알고리즘을 사용하였다. 사전 분포된 임의의 입력 벡터 x 에 의해 k번 째 규칙이 일어날 확률을 의미하는 확률분포를 이용하여 선택된 EN와 GN이 동시에 학습된다. EN와 GN에 확률적인 기울기 상승 학습 알고리즘과 체인룰을 적용하였다.

EN의 출력층과 은닉층의 가중치 벡터 w_{kl}^j 갱신 규칙은 다음 식과 같다.

$$w_{kl}^j(t+1) = w_{kl}^j(t) + \eta \cdot h_k(t) \frac{e_k^j(t)}{\sigma_k^2(t)} \cdot s_k^l(t) \quad (11)$$

은닉층과 입력층의 가중치 w_{KRi}^l 의 최종 갱신 규칙은 다음 식(12)와 같다

$$\begin{aligned} w_{KRi}^l(t+1) &= w_{KRi}^l(t) + \Delta w_{KRi}^l(t) \\ &= w_{KRi}^l(t) + \eta \delta_k^l X_i \end{aligned} \quad (12)$$

여기서 \mathbf{w}_{KR}^l 은 입력층 가중치와 케환 루프 가중치를 합하

여 $w_{KR}^I = [w_{k1}^I \ w_{k2}^I \cdots \ w_{kP}^I \ w_{kR1}^I \ w_{kR2}^I \cdots \ w_{kRM}^I]$ 로 정의 한다. X_i 는 외부 입력값과 케환 루프 입력값을 합한 행렬로 $X_i = [x_1 \ x_2 \cdots \ x_P \ r_1 \ r_2 \cdots \ r_M]$ 으로 표현할 수 있다. GN의 학습 알고리즘은 MNN과 RMNN은 같다.

5. 시뮬레이션

5.1 시뮬레이터 모의실험

환경정보에 의해서 감정이 정해지면 이것에 의해 행동패턴과 만족도가 정해지게 되는 과정은 컴퓨터 시뮬레이터로 구현하고 이를 사용하여 100회의 실험을 실시하였다. 시뮬레이션에 의한 실험은 로봇이 행동패턴에 의해 이동하는 동안의 데이터는 메모리에 저장한 후, 로봇이 이동할 때 메모리에 저장되어 있지 않은 데이터만을 메모리에 저장하게 하는 방식이다. 실험결과 경험회수가 많고, 만족도가 높은 626가지의 실측 데이터를 얻을 수 있었다.

그림 4은 일정 크기의 맵에서 온도, 연기 상태, 밝기 그리고 장애물의 거리(2개)의 상태를 각각 3가지 경우로 설정하고, 앞의 환경정보에 의해 평가된 감정에 따라 로봇이 행동하는 시뮬레이터이다. 그리고 로봇이 평가된 감정에 의해 이동할 때 로봇의 현재 상태들을(놀람, 기분상태, 만족도, 이동방향, 환경정보들의 현재상태) 쉽게 볼 수 있도록 시뮬레이터를 구성하였다.

5.2 학습에 대한 모의실험

감정을 고려한 4개의 환경정보(온도, 연기상태, 밝기, 장애물) 변화는 각 9가지 상황으로 나누어지며 많은 패턴으로 구성된다. 입력값은 이전/현재의 환경정보, 감정의 놀람과 기분상태로 10개이며 출력값은 현재상태의 만족도와 이동해야 할 행동패턴으로 정하였다.

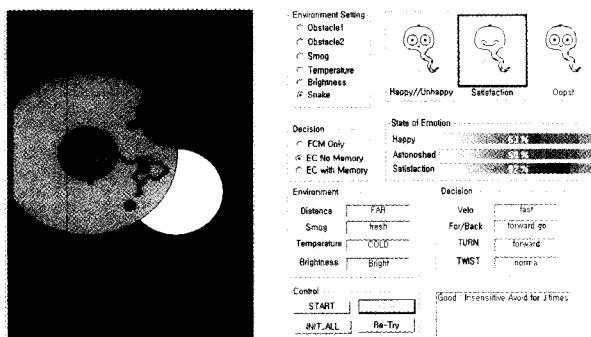


그림 4. 로봇 주행 시뮬레이션과 주행 시 상태

Fig. 4. Simulation of robot traveling and the state of robot on traveling

MNN은 4개의 EN을 가지며, 각 EN은 MLNN으로 은닉층의 노드는 6개이다. 또한 GN도 역시 MLNN을 사용하고 은닉층은 6개로 구성되었다.

RMNN은 EN에 3단 RNN을, 그리고 GN에는 MLNN을 이용하여 네트워크 크기에 따라 4가지 경우로 나누었으며 표 3과 같다.

학습률 0.01, 학습반복 회수 10000회, 활성화 함수의 기울기와 바이어스는 각각 1로 하여 구성하였다. 결과는 학습 반

복회수 2회당 1회씩 그래프에 나타내었다.

그림 5의 그래프를 살펴보면, 케환 노드로 추가로 가중치 개수가 많아 된 RMNN-4은 MNN보다 좋은 결과값을 얻었다.

표 3. 네트워크의 학습결과

Table 3. Learning result of networks

Network	구성(EN/Hidden)	가중치	RMSE
MNN	▪ 4/6개	288	0.0324
RMNN-1	▪ 4/4개	256	0.0293
RMNN-2	▪ 4/5개	340	0.0271
RMNN-3	▪ 3/6개	324	0.0266
RMNN-4	▪ 4/6개	432	0.0238

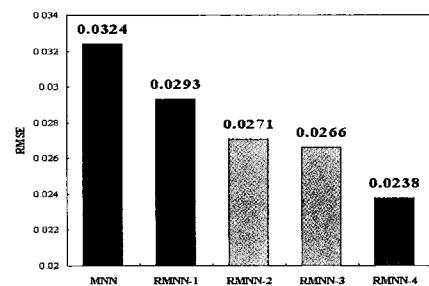


그림 5. 네트워크의 학습결과

Fig. 5. Learning result of networks

RMNN의 가중치 (RMNN-2, RMNN-3)를 점점 적게 하여 MNN과 비교하였다. RMNN은 케환 노드의 가중치로 인해 네트워크의 가중치 개수가 늘어나지만 은닉층의 노드수를 줄임으로써 네트워크의 크기를 줄였다. 또 은닉층의 노드가 줄어들어 은닉층과 출력층의 가중치 개수도 동시에 줄어들었다. 그중 RMNN-1은 MNN보다 EN의 가중치 개수가 적은데 비해 더 좋은 결과를 얻을 수 있었다. 즉, 작은 RMNN의 구조로 MNN보다 좋은 학습 결과를 얻을 수 있었다.

6. 결론 및 향후과제

MLNN은 생물학적인 시스템과 신경세포를 수학적으로 모델링하고, 주어진 정보를 이용하여 학습을 가능하게 함으로써 주어진 시스템의 특징을 추출하는데 우수한 능력을 발휘하고 있지만 지역 최소치 수렴과 매개변수 증가함에 따라 계산량도 증가하는 단점이 있다. 해결책으로 복잡한 문제를 단순한 부문제로 나누어 해결하는 모듈라 네트워크가 제안되었다. 또 상황의 재 표현이 가능하고 작은 네트워크 구조로도 보다 큰 역할을 수행할 수 있어 상당히 많은 메모리 요건들을 줄일 수 있는 RNN이 있다. 본 논문에서는 MNN의 EN에 RNN을 적용하였다.

RNN의 영향으로 부분적인 학습에 있어서 전체 네트워크의 상태는 순차적으로 입력되는 값만큼 그 이전 상태에도 영향을 받기 때문이다. 복잡하고 다양한 환경을 표현하기 위해서는 더욱 많은 입력값이 필요하고 여러 가지의 일을 수행하기 위해서는 출력값도 많아진다. 그리고 MNN의 장점을 부각시키기 위해서는 EN의 수도 증가하게 된다. 더욱 많은 상황과 복잡한 경우에 RMNN은 MNN보다 더 좋은 효과가 발휘될 것이다.

추후과제는 인간의 다양한 감정을 평가할 수 있는 시뮬레이

이터를 구성하고, 인간의 보편화된 감정을 세분화하여 그 상황의 감정 패턴들을 학습하는데 RMNN을 최적화시키는 것이다. 또 학습이 완료된 네트워크를 간단한 시스템에 적용하여 인간과 더욱 친밀한 시스템을 구현하는 것이다. 그리고 요즈음 감정처리 부분에서 많이 연구되고 있는 얼굴 표현이나 몸의 자세나 동작을 이용한 감정 패턴을 분석하여 인간과 로봇의 상호 협력을 위한 감정처리 분야에 응용할 수 있을 것으로 기대된다.

참고문헌

- [1] Simon Haykin, Neural Networks - A Comprehensive Foundation, Macmillian college Publishing company Inc., 1994.
- [2] Chin-Teng Lin and C. S. George Lee, Neural Fuzzy Systems - A Neuro Fuzzy Synergism to intelligent System, Prentice Hall PTR, 1996.
- [3] 강훈, 심귀보, 지능정보 시스템, 대영사, 2000.
- [4] Jacek M. Zurada, Introduction to Artificial Neural System, West Publishing Company, 1992.
- [5] Gasser Auda and M. Kamel, "Modular neural networks : A survey", Int. Journal of Neural Systems, Vol. 9, No. 2, pp 129-151, 1999.
- [6] Tomas Hrycej, Modular Learning in Neural Network, John Wiley & Sons Inc., 1992.
- [7] Gasser Auda and Mohamed Kamel, "Modular neural networks Classifier: A Comparative Study", Journal of Intelligent and Robotic Systems, Vol. 21, pp 117-129, 1998.
- [8] R. A. Jacobs, M. I. Jordan, S. J. Nowlan, and G. E. Hinton, "Adaptive Mixtures of Local Experts", Neural Computation, Vol. 6., pp. 181-214, 1994.
- [9] Sung-Bae Cho, "Evolutionary Modular Neural Networks for Intelligent Systems", International Journal of Intelligent Systems, Vol. 13, pp. 483-493, 1998.
- [10] G. Aada and M. Kamel, "CMNN: Cooperative Modular Neural Networks for pattern recognition", Pattern Recognition Letters, Vol. 18, pp. 11-13, 1997.
- [11] Ke Chen, Liping Yang, Xiang Yu and Huisheng Chi, "A self-generating modular neural network architecture for supervised learning", Neurocomputing, Vol. 16, pp. 33-48, 1997.
- [12] Gasser Auda, Mohamed Kamel and Hazem Raafat, "Modular Neural Network for Classifier", IEEE Trans. on Neural Network, pp. 1279-1284, 1996.
- [13] Michael I. Jordan and Robert A. Jacobs, "Hierarchical Mixtures of Experts and the EM Algorithm", Neural computation, Vol. 6, No. 1, pp. 181-214, 1994.
- [14] Chin-Teng Lin and C. S. George Lee, Neural Fuzzy Systems - A Neuro-Fuzzy Synergism to Intelligent Systems, A Simon & Schuster Company, 1996.
- [15] Steve Lawrence, C. Lee Giles and Sandiway Fong, "Natural Language Grammatical Inference with Recurrent Neural Networks", IEEE Trans. on Knowledge and Data engineering, Vol. 12, No. 1, pp. 126-140, 2000.

저자소개

김성주(Seong-Joo Kim)

2003년 제 13권 제 1호 참조

최우경(Woo-Kyung Choi)

2003년 제 13권 제 2호 참조

김용민(Yong-Min Kim)

현재 충청대학 컴퓨터학부 교수

전홍태(Hong-Tae Jeon)

현재 중앙대학교 전자전기공학부 교수