

궤 환 신경회로망을 사용한 모듈라 네트워크

최 우 경, 김성주, *서 재 용, 전 흥 태
중앙대학교 전자전기공학부, *한국기술교육대학교
전화 : 02-820-5297 / 핸드폰 : 017-335-6366

Modular Nerual Network Using Recurrent Neural Network

Woo-Kyung Choi, Seong-Joo Kim, *Jae-Yong Seo, Hong-Tae Jeon
School of Electrical and Electronic Engineering Chung-Ang University
*Korea University of Technology and Education
E-mail : chwk001@hanmail.net

Abstract

In this paper, we propose modular network to solve difficult and complex problems that are seldom solved with multi-layer neural network. The structure of modular neural network in researched by Jacobs and Jordan is selected in this paper. Modular network consists of several expert networks and a gating network which is composed of single-layer neural network or multi-layer neural network. We propose modular network structure using recurrent neural network, since the state of the whole network at a particular time depends on an aggregate of previous states as well as on the current input. Finally, we show excellence of the proposed network compared with modular network.

I. 서론

로봇은 급속도로 발전을 거듭하여 산업현장, 우주공간, 재난현장 등에서 반복적이고 단순한 업무 대체용으로 맹목적인 인간의 명령만을 수행해 왔다. 그러나 요즘 로봇의 궁극적인 목표는 인간의 명령을 이행하고, 스스로 학습하며, 감정을 지닌 인공지능 로봇으로써 인간 친화형 로봇을 말한다. 그리하여 영상인식, 음성인식 등의 인간의 능력을 모방한 기술들이 로봇에 적용되면서 점차 인간 같은 로봇이 등장하고 있다. 그

리나 단순히 인간의 기능만을 모방한 로봇이 인간 친화형 로봇이라 말할 수는 없다.

감정은 지능을 가진 존재의 사고 과정으로부터 나오는 것으로 이성과는 불가분 관계이다. 즉 인간은 이성적인 판단에 있어서 감정의 영향을 받는다는 것이다. 그래서 기본적인 환경정보에 의해 형성되는 일차적인 감정을 로봇에 첨가하면 더욱 인간에 가까운 지능 로봇이 될 것이다. 그리고 수학적 모델링의 어려운 문제 해결을 위해 인간의 사고능력과 적용 능력을 모방한 지능형 기법이 제안되고 있다. 대표적인 방법으로는 소프트 컴퓨팅(Soft Computing)으로 어느 알고리즘보다 인간의 문제 해결 능력과 유사한 기법이라 할 수 있다. 다양한 분야에 적용되고 있는 다층 신경망(Multilayer Neural Network; MLNN)과, 방사기저함수망(Radial Basis Function Network; RBFN) 등이 이에 속한다[1][2][3].

신경망은 주어진 정보를 이용하여 학습함으로써 시스템의 특징을 추출하는데 매우 우수한 능력을 발휘하고 있다. 그러나 이전에 학습한 매핑 결과를 잊어버리는 일시적 혼선(temporal cross talk)현상이 발생하고 전역적인 매핑 구조로 근사화를 수행함으로써 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 모듈화 설계방법이 관심을 갖게 되었다[1].

특히 Jacobs와 Jordan이 제안한 모듈라 신경망(Modular Neural Network; MNN)은 작업 재구성과

학습, 재결합의 관점에서 탁월한 성능을 발휘하고 있다[4]. MNN은 복잡한 문제를 단순한 부문제로 나누어 학습시키는 엑스퍼트 네트워크(Expert Network; EN)와 출력을 조합하여 최종출력을 생성하도록 스위칭 역할을 수행하는 게이팅 네트워크(Gating Network; GN)로 구성된다[1][10]. 지금까지 MNN의 대부분의 연구에서는 EN과 GN을 SLNN이나 MLNN으로 구성하였다.

학습에 있어서 전체 네트워크는 입력되는 값만큼 그 이전 상태에서 활성화되는 상태도 많은 영향을 받게 된다. 그리하여 제한 루프를 통해 상황의 재 표현이 가능하고 작은 네트워크 구조로 그보다 큰 전방향 네트워크의 역할을 수행할 수 있는 제한 신경망(Recurrent Neural Network; RNN)을 MNN 구조에 적용하였다.

본 논문에서는 감정평가에 기반한 감각 정보의 학습 데이터 패턴들을 이용하여 Jacobs와 Jordan이 제안한 MNN에 RNN을 사용하여 학습하였다. 이 구조의 우수성을 증명하고자 학습결과를 비교, 분석하였다.

II. Emotion을 고려한 정보처리

1870년 이후부터 독일에서 시작한 대뇌기능의 임상 실험을 통해 뇌의 기능이 밝혀지기 시작하였다. 그중 해마는 의식적인 기억 시스템이고 편도체는 정서와 정서 학습으로 감정을 형성한다. 두 기관들은 인간의 기억과 행동에 커다란 영향을 준다.

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. 복잡하고 개인적인 감정들을 우리가 알고 있는 보편적인 것만을 사용하여 지능 로봇의 학습에 이용하고자 한다. 감정에 영향을 주는 정보들은 여러 가지가 있지만 본 논문에서는 온도, 연기 상태, 밝기, 장애물과의 거리를 센서를 통해 측정된 값을 환경 정보 입력값으로 이용하였다. 이 환경 정보값은 각각 상, 중, 하로 나누어져 9가지의 형태로 감정요소에 영향을 준다. 감정요소는 놀람, 기분상태, 만족도 세 가지로 나누었다. 놀람은 급작스런 환경 변화로 인하여 현재 운동 패턴의 중지 및 새로운 패턴 요구의 의지로 표현된다. 기분상태는 환경변화에 따른 감정적인 좋아함과 싫어함 정도를 표현하며 이러한 요소들과 각각의 환경정보에 대한 민감도의 결합으로 만족도를 결정하게 된다. 놀람(E_a)과 기분상태(E_h)는 식 (1)에 의해 결정된다.

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

여기서 $x_i(n)$ 는 환경요소, s_i 는 환경 요소에 대한 민감도, $\langle x_i(n-1), x_i(n) \rangle$ 는 환경 요소 변화에 따른 호감도이다.

만족도(S)는 놀람과 기분상태에 의해 결정되는데 기분상태 변화에 따른 만족도(S_{emo})와 행동패턴 결과에 따른 만족도(S_{act})로 이루어진다. 만족도(S)는 식 (2)에 의해서 구해진다.

$$S = F(S_{emo}) \times \lambda_{emo} + F(S_{act}) \times \lambda_{act} \quad (2)$$

$$S_{emo} = \lambda_{emo} * \Delta E_k^{n-1}, \quad S_{act} = \lambda_{act} * \Delta E_k^{n-T}$$

$\lambda_{emo}, \lambda_{act}$: 만족도 적용지수

$n-T$: 행동패턴 결정 시점

여기서 $F(\cdot)$ 는 시그모이드 함수이다.

행동패턴은 앞에서 결정된 놀람(E_a), 기분상태(E_h) 그리고 만족도(S)에 판단된다.

III. MLNN을 사용한 MNN 구조

본 논문에서는 작업 재구성 과 학습, 재결합 관점에서 탁월한 성능을 발휘하는 Jacobs와 Jordan이 제안한 가우스 혼합 모듈과 신경망을 사용하였다. MNN은 서로 다른 모듈로 분할되고 각각 독립적으로 서로 경쟁하는 i 개의 EN와 EN의 중재역할을 담당하는 GN으로 구성된다. MNN의 EN와 GN는 MLNN을 사용하였고 그림 1에 나타내었다.

입력벡터는 $x = [x_1 \ x_2 \ \dots \ x_p]^T$ 로 P 차원이고, 최종출력 벡터는 $y = [y_1 \ y_2 \ \dots \ y_q]^T$, k 번째의 EN의 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.

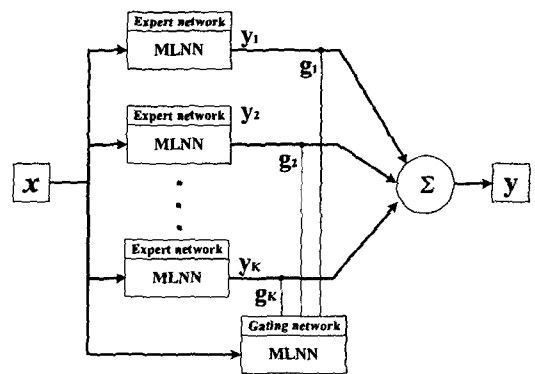


그림 1 MLNN을 사용한 MNN

MNN의 최종 출력은 식 3과 같다.

$$y = \sum_{i=1}^M g_i y_i \quad (3)$$

게이팅 네트워크의 출력값이 u_i 일 때, 사전 확률(priori probability)인 게이팅 네트워크의 최종 출력은 soft-max 함수를 사용하여 다음과 같이 나타낼 수 있다.

$$g_i = \frac{\exp(u_i)}{\sum_{j=1}^M \exp(u_j)} \quad (4)$$

IV. RNN을 사용한 MNN 구조

RNN을 사용한 MNN은 MLNN을 사용한 MNN는 GN 구조는 같지만 EN에 RNN을 사용한 점이 다르며, 이점이 네트워크 출력에 큰 영향을 줄 것이다.

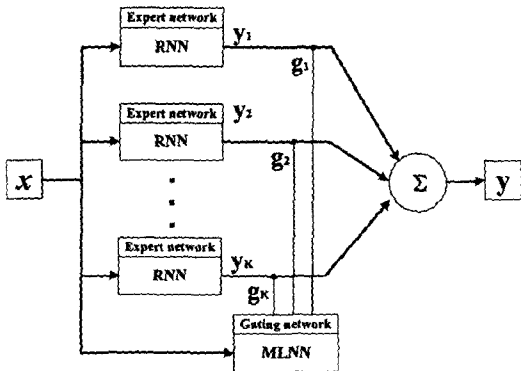


그림 2 RNN을 사용한 MNN

EN은 여러 가지의 RNN 중에서 Elman에 의해 연구 발표된 Elman network 구조를 사용한다[5]. Elman 네트워크를 "simple recurrent network(SRN)"라고도 한다. 은닉 뉴런은 네트워크의 상태를 명시하고 은닉층의 출력은 지연(delay) 유닛 बैं크(bank)을 거쳐 입력층에 재환된다. 입력층은 게환 노드(node)와 입력 노드로 구성된다. 이 네트워크는 입력 노드를 통해 외부의 환경과 연결되고 영향을 받는다[6]. Elman의 RNN의 구조는 그림 3과 같다.

EN의 RNN은 은닉층에는 바이폴라 시그모이드, 출력층에는 선형함수를 사용하였다. 입력은 P개, 은닉층 노드는 M개, 출력층은 Q개의 노드로 구성되었다.

k번째 EN의 은닉층 l번째 출력은 다음과 같다.

$$s_k^l(n+1) = f\left(\sum_{i=1}^P w_{ki}^l x_i(n) + \sum_{r=1}^M w_{kr}^l r_r(n)\right) \quad (5)$$

$$= f(w_k^l x(n) + w_{kr}^l r(n)) = f(n et_k^{l(e)})$$




그림 3 RNN으로 구성된 EN

함수 $f(\cdot)$ 는 bipolar sigmoid 함수이다.

k번째 EN의 j번째 출력은 식 (6)에 나타내었다.

$$y_k^j(n+1) = f\left(\sum_{i=1}^M w_{ki}^j f\left(\sum_{r=1}^P w_{ki}^r x_r(n) + \sum_{r=1}^M w_{kr}^r r_r(n)\right)\right)$$

$$= f(w_k^j s_k(n+1)) = f(n et_k^{j(e)}) \quad (6)$$

$f(\cdot)$ 는 선형함수를 나타낸다.

V. 학습 알고리즘

MNN와 재환 신경망을 이용한 모달라 네트워크(MRNN)를 학습하는데 사용되는 알고리즘의 궁극적인 목적은 학습패턴의 확률분포를 모델링하는 것이다. 이를 위해 학습 알고리즘은 확률적인 기울기 학습 알고리즘을 사용하였다. 사전분포된 임의의 입력벡터 x 에 의해 k번째 규칙이 일어날 확률을 의미하는 확률분포를 이용하여 선택된 엑스퍼트와 게이팅 네트워크가 동시에 학습된다. 엑스퍼트 네트워크와 게이팅 네트워크에 확률적인 기울기 상승 학습 알고리즘과 체인룰을 적용하였다.

EN의 출력층과 은닉층의 가중치 w_{ki}^l 의 갱신 규칙

$$w_{ki}^l(t+1) = w_{ki}^l(t) + \eta \cdot h_k(t) \frac{e_k^l(t)}{\sigma_k^l(t)} \cdot s_k^l(t) \quad (7)$$

은닉층과 입력층의 가중치 w_{kr}^l 의 최종갱신 규칙

$$w_{kr}^l(t+1) = w_{kr}^l(t) + \Delta w_{kr}^l(t)$$

$$= w_{kr}^l(t) + \eta \delta_k^l X_i \quad (8)$$

GN의 출력층과 은닉층의 가중치 a_k^m 의 갱신 규칙

$$a_k^m(t+1) = a_k^m(t) + \eta(h_k - g_k)v_m \quad (9)$$

은닉층과 입력층의 가중치 a_m^i 의 최종 갱신 규칙

$$a_m^i(t+1) = a_m^i(t) + \eta \cdot \delta_m^g \cdot x_i \quad (10)$$

VI. 모의 실험

환경정보에 의한 감정을 고려한 데이터 패턴을 학습하고 시뮬레이터를 구현하여 100회의 실험을 하였다. 그중 경험횟수가 많고 만족도가 높은 데이터를 사용하여 테스트하였다.

MNN은 EN 4개와 각 EN에 사용한 MLNN의 은닉층 노드를 6개로 구성되고 MRNN은 크기가 다른 4개의 네트워크로 나누었다. MRNN-1, MRNN-2, MRNN-4는 4개의 EN와 각각 4, 5, 6개의 은닉층을 가지고 있다. 그리고 MRNN-3는 3개의 EN와 6개의 은닉층으로 구성된다. 활성화함수는 은닉층에 바이폴라 시그모이드와 출력층에 선형함수를 이용하였다. 활성화함수 경사는 모두 1로 하였고 학습률 0.01, 학습 반복 10000회 바이어스는 1로 하여 모의 실험을 하였다.




그림 4 MNN와 MRNN의 학습결과 비교

학습 결과를 표 1에 종합/정리하였다.

표 1 네트워크의 학습결과 정리

Network	구 성	RMSE
MNN	EN : 4개 은닉층 노드 6	0.0324
MRNN-1	EN : 4개 은닉층 노드 4	0.0293
MRNN-2	EN : 4개 은닉층 노드 5	0.0271
MRNN-3	EN : 3개 은닉층 노드 6	0.0266
MRNN-4	EN : 4개 은닉층 노드 6	0.0238

VII. 결론

인간과 비슷한 행동·생각을 갖는 로봇을 만들기 위해서는 인간처럼 감정(Emotion)이 고려되어야 한다. 그러나 학습에 필요한 데이터의 양과 패턴들이 무수히 많을 것이다. 그래서 MLNN의 단점을 보완하기 위해 복잡한 문제를 단순한 부분제로 나누어 해결하는 모듈라 네트워크가 제안되었다. 또 상황의 재 표현이 가능하며 작은 크기로 그보다 큰 전방향 네트워크의 역할을 수행할 수 있는 RNN을 MNN의 EN에 적용하였다.

MRNN은 MNN보다 EN 모듈 개수와 신경망의 은닉층 노드 개수가 작은 네트워크에서도 우수하거나 비슷한 효과를 낼 수 있었다. 이는 모의 실험을 통해 MRNN은 MNN보다 학습오차가 작았으며, 네트워크 크기를 줄임으로써 학습에 필요한 시간도 절약할 수 있었다. 이것은 RNN의 영향이라 생각된다.

추후 과제는 세분화된 감정과 다양한 감정평가를 이용해서 정밀한 시뮬레이터를 구성하고 MRNN의 최적화 구조를 찾는 것이다. 또 인간과 로봇의 상호 협력적인 행동에 대한 감정처리 부분을 추가하여 인간과 더욱 친근한 시스템 구현이다.

감사의 글 : 본 연구는 '산업자원부 IWM요소기술 개발과제'에 의해 지원 받았습니다.

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 Systems*, Prentice Hall PTR, 1996.
- [3] 강훈, 심귀보, *지능 정보 시스템*, 대영사, 2000.
- [4] 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.
- [5] 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.
- [6] Chin-Teng Lin and C. S. George Lee, *Neural Fuzzy Systems - A Neuro-Fuzzy Synergism to Intelligent Systems*, A Simon & Schuster Company., 1996.