

최적 EN를 사용한 MNN에 의한 Mobile Robot제어

Mobile robot control by MNN using optimal EN

최우경, 김성주, 서재용*, 전홍태

Woo-Kyung Choi, Seong-Joo Kim, Jae-Yong Seo, Hong-Tae Jeon

중앙대학교 일반대학원 전자전기공학부

*한국기술교육대학교 정보기술공학부

요 약

이동로봇(Mobile Robot)의 자율주행 기능에는 추종, 접근, 충돌회피, 경고 등의 여러 기능이 있다. 이 기능들을 하나의 Neural Network로 구성하고 학습하는 것은 쉬운 일이 아니다. 이동로봇의 자율주행 기능들을 각각의 Module로 구성하고 상황에 맞게 학습된 Module의 출력 값으로 이동로봇을 제어하면 단일 신경망의 단점을 보완할 수 있을 것이다. 이동로봇은 인간의 감각을 대신할 수 있는 다중 초음파 센서와 USB 카메라를 장착하고 있으며, 이곳에서 측정된 환경정보 데이터들은 Modular Neural Network(MNN)을 통해 학습을 한다. Expert Network(EN)의 활성화 함수를 최적결함으로 MNN을 구성하였고, 그 구조는 학습시간과 오차를 개선할 수 있을 것으로 본다. Gating Network(GN)는 MNN의 출력값인 이동로봇의 진행 방향과 속도를 스위칭 함으로써 제어하는 역할을 한다.

본 논문에서는 Modular Neural Network(MNN) 내의 Expert Network(EN)를 최적설계 하였고, 제안한 MNN의 검증을 위해 실시간으로 반복하여 이동로봇에 구현하였다. 그 실험의 결과값은 로봇을 상황에 맞게 운행, 제어하였고, 만족할 만한 성과를 얻을 수 있었다.

Abstract

Skills in tracing of the MR divide into following, approaching, avoiding and warning and so on. It is difficult to have all these skills learned as neural network. To make this up for, skills consisted of each module, and Mobile Robot was controlled by the output of module adequate for the situation. A mobile Robot was equipped multi-ultrasonic sensor and a USB Camera, which can be in place of human sense, and the measured environment information data is learned through Modular Neural Network. MNN consisted of optimal combination of activation function in the Expert Network and its structure seemed to improve learning time and errors. The Gating Network(GN) used to control output values of the MNN by switching for angle and speed of the robot.

In the paper, EN of Modular Neural network was designed optimal combination. Traveling with a real MR was performed repeatedly to verify the usefulness of the MNN which was proposed in this paper. The robot was properly controlled and driven by the result value and the experimental is rewarded with good fruits.

Key Words : Mobile Robot, Modular Neural Network, Expert Network, Gating Network

1. 서 론

로봇은 급속도로 발전을 거듭하여 산업현장에서 물류운반, 우주공간 등의 미개척 지역의 탐색, 재난 등의 위험한 환경에서의 구조임무 등의 일을 수행해 왔다. 그러나 요즘 로봇의 궁극적인 목표는 인간의 말을 이해하고, 스스로 학습하고, 감정도 지닐 수 있는 인공지능 컴퓨터를 내장한 로봇이다. 즉 인간과 친구가 될 수 있는 인간 친화형 로봇을 말한다. 그러나 모든 기능을 수행하도록 모델링하는 것은 어려움이 따른다. 그리하여 최근에는 어려운 모델을 해결하기 위해 인간의 사고능력과 적응 능력을 모방한 지능형 기법이 제안되고 있다. 대표적인 방법으로는 소프트 컴퓨팅(Soft

Computing)으로 이 기법은 학습 능력, 병렬계산 및 처리능력, 적응성, 추론 능력 등을 보유하여 어느 알고리즘보다 인간의 문제 해결 능력과 유사한 기법이라 할 수 있다. 다양한 분야에 적용되고 있는 다층 신경망(Multilayer Neural network ; MLNN)과 퍼지 이론 등이 이에 속한다[1][2].

MLNN은 주어진 정보를 이용하여 학습을 가능하게 함으로써 주어진 시스템의 특징을 추출하는데 매우 우수한 능력을 발휘하고 있다[3][4]. MLNN은 전역적인 매핑 구조로 근사화를 수행하지만, 바람직하지 못한 지역 최소치에 수렴하는 단점이 있다. 또한 초기 매개변수 설정문제와 느린 학습 속도, 다차원 문제에 적용할 경우 크기가 늘어나 조정되는 매개변수가 많아지기 때문에 계산량이 증가하는 문제점이 있다. 이러한 문제점에도 불구하고 현재 MLNN은 음성처리, 패턴인식, 함수 근사화, 제어 및 로봇분야[3] 등의 다양한 분야에 적용되고 있다.

지역적인 매핑방법과 전역적인 매핑방법의 장점을 수용한 모듈화 설계방법이 최근 MLNN을 연구하는 학자들에게 판

접수일자 : 2002년 10월 19일

완료일자 : 2003년 1월 29일

본 연구는 '산업자원부 IWM요소기술 개발과제[00013078]'에 의해 일부 지원 받았습니다.

심의 대상이 되어 왔다. 모듈화된 시스템은 복잡한 문제를 단순한 부문제로 나누어 해결하는 방식이다. 따라서 단순한 부문제를 해결하기 때문에 학습속도가 향상되고, 사용되는 매개변수가 감소하며 표현능력을 증가시킨다. 또한 모듈화는 전체 시스템에서 계산의 지역화를 달성함으로써 전체 시스템의 행동에서 부시스템의 역할을 정의하고, 모듈화 설계를 통해 신경망의 다른 활성화 함수나 다른 망 구조를 사용할 수 있으며, 각 모듈에 다른 종류의 학습 알고리즘을 사용할 수 있는 장점을 가지고 있다[8][9][10].

본 논문은 이동로봇이 인간을 추종하는 과정에서 여러 가지의 기능을 모듈화 개념을 활용하였다.

2. Modular Neural Network

모듈화된 시스템의 장점 때문에 현재 모듈화된 시스템에 대한 이론적인 토대가 마련되고, 다양한 분야에 많은 응용사례가 등장하고 있다.

특히 Jacobs와 Jordan[5][6][7]이 제안한 모듈화된 신경망(Modular Neural Network; MNN)은 작업재구성과 학습 재결합의 관점에서 탁월한 성능을 발휘하고 있다. MNN은 모듈을 구성하는 엑스퍼트 망(Expert network; EN)과 게이팅 망(Gating Network; GN)으로 구성된다. EN은 모듈화식 설계 방식을 도입하여 복잡한 문제를 단순한 부문제로 나눌 경우 부문제를 학습하게 된다.

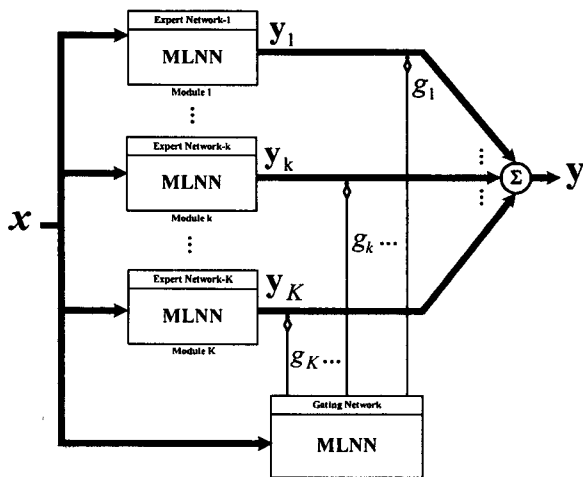


그림 1. MLNN을 이용한 모듈화된 신경망의 블록도.
Fig. 1. Block diagram of Modular Neural Network using MLNN.

일반적으로 MNN은 단일신경망(Single Neural network ; SNN)이나 MLNN으로 구성한다. 또한 GN은 복잡한 문제를 단순한 부문제로 나누는 작업 재구성과 부문제를 학습한 EN의 출력을 조합하여 최종출력을 생성하는 재결합을 담당한다. 즉 입력공간을 적당하게 분할하여 EN이 해당 입력공간에서 학습이 수행되도록 조정해 주며, EN의 출력을 조합하여 최종출력을 생성하도록 스위칭을 수행한다.

Jacobs와 Jordan이 제안한 MNN은 이론적인 근거와 구조의 단순성 때문에 다양한 응용분야에 적용되고 있다.

그림 1은 Jacobs와 Jordan이 제안한 MNN 구조에 MLNN을 사용한 구조로 표현하였다.

3. MultiLayer Neural Network 구조

이동로봇의 여러 기능을 수행하기 위해 다수의 모듈이 사용된다. 앞절에 소개한 MNN은 각 모듈에 동일한 수의 입력을 인가하여 망을 구성하고 있기 때문에 입력 수의 개수에 따라 망의 size나 연산시간에 큰 영향이 있을 것으로 생각된다. 또 모듈이 추가 될 때마다 학습 데이터도 그만큼 많이 진다. 그러나 각 모듈의 기능에 필요한 입력만을 선택적으로 인가하면 망의 크기를 작게 하고 학습 데이터 수를 줄일 수 있다. 이 구조를 이용하여 기존의 MNN과 같은 기능을 수행할 수 있는지를 확인하였다.

3.1 System 구조

본 논문에서 제안한 MNN의 구조는 그림2와 같다. 그림에서와 같이 각 모듈들은 기능에 필요한 입력값만을 취하여 학습을 하게 된다. 그리고 EN와 GN은 MLNN을 사용하였다.

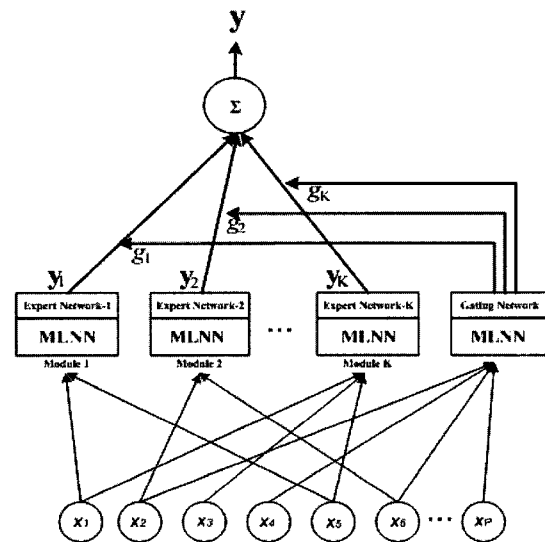


그림 2. 개선된 MNN의 블록도.
Fig. 2. Block diagram of improved MNN.

3.2 MNLL 구조

MLNN으로 구성된 EN구조는 두가지로 나뉘어 진다. 첫 번째 출력층에 활성화 함수를 사용하지 않고, 은닉층과 출력층의 가중치와 은닉층 출력의 곱의 합을 선형조합으로 출력층을 구성한다. 두 번째는 출력층에 sigmoid나 tanh와 같은 비선형 활성화 함수를 사용하여 다층 신경망 출력층을 구성한다. 각각의 j번째의 출력을 식 1, 2에 나타내었고, 구조는 그림 3와 같다.

$$y_k^j = \sum_{i=1}^M [w_{ki}^j f \left(\sum_{i=1}^P w_{ki}^i x_i \right)] \quad (1)$$

$$y_k^j = f \left(\sum_{i=1}^M [w_{ki}^j f \left(\sum_{i=1}^P w_{ki}^i x_i \right)] \right) \quad (2)$$

Gating Network의 구조도 역시 EN의 경우와 같이 MLNN 구조를 두가지로 나눌 수 있다. 식 3과 식4는 k번째의 출력이다. 구조는 그림 4에 나타내었다.




그림 3. MLNN 사용한 EN의 구조.
Fig. 3. EN structure using MLNN.

$$u_k = \sum_{m=1}^N a_k^m f \left(\sum_{i=1}^P a_m^i x_i \right) \quad (3)$$

$$u_k = f \left(\sum_{m=1}^N a_k^m f \left(\sum_{i=1}^P a_m^i x_i \right) \right) \quad (4)$$

GN의 최종출력은 정규화된 soft-max 함수를 사용하여 식 5와 같이 표현할 수 있다.

$$g_k = \frac{\exp(u_k)}{\sum_{j=1}^K \exp(u_j)} \quad (5)$$

MNN의 최종출력은 식 6에 같이 표현 된다.

$$y = \sum_{k=1}^K g_k y_k \quad (6)$$




그림 4. MLNN을 사용한 GN 구조.
Fig. 4. GN structure using MLNN.

3.3 기울기 하강 학습 알고리즘

학습 알고리즘으로는 기울기 하강 학습 알고리즘을 사용하고 체인룰을 적용하면 EN와 GN의 가중치 갱신규칙은 아래에 같이 나타낼 수 있다.

MLNN으로 구성한 EN 가중치는 출력층과 은닉층, 은닉층과 입력층에서 갱신되고 식7, 8에 유도되었다.

(출력층과 은닉층)

$$\begin{aligned} \Delta w_{kl}^j &= \eta \frac{\partial L(w, g)}{\partial w_{kl}^j} = \eta \frac{h_k}{\sigma_k^2} e_k^j f'(v_k^j) s_k^l \\ w_{kl}^j(t+1) &= w_{kl}^j(t) + \eta \frac{h_k(t)}{\sigma_k^2(t)} e_k^j(t) f'(v_k^j) s_k^l(t) \\ \delta_k^j &\equiv e_k^j f'(v_k^j) \\ \therefore w_{kl}^j(t+1) &= w_{kl}^j(t) + \eta \frac{h_k(t)}{\sigma_k^2(t)} \delta_k^j(t) s_k^l(t) \end{aligned} \quad (7)$$

(은닉층과 입력층)

$$\begin{aligned} \Delta w_{ki}^l &= \eta \frac{\partial L(w, g)}{\partial w_{ki}^l} = \eta \sum_{j=1}^Q \left\{ h_k \frac{e_k^j}{\sigma_k^2} w_{kl}^j \right\} s_k^l x_i \\ &= \eta \delta_k^l x_i \\ \delta_k^i &\equiv \sum_{j=1}^Q \left\{ h_k \frac{e_k^j}{\sigma_k^2} w_{kl}^j \right\}, \quad \sigma_k^l \equiv \sigma_k^l s_k^l x_i \\ \therefore w_{ki}^l(t+1) &= w_{ki}^l(t) + \eta \delta_k^l x_i \end{aligned} \quad (8)$$

GN의 가중치 갱신도 역시 EN과 같으며 식9, 10에 나열하였다.

(출력층과 은닉층)

$$\begin{aligned} \Delta a_k^m &= \eta \frac{\partial L(w, x)}{\partial a_k^m} = \eta (h_k - g_k) f'(net_k^m) v_m \\ &= \eta \delta_k^g v_m \\ \therefore a_k^m(t+1) &= a_k^m(t) + \eta \delta_k^g v_m \end{aligned} \quad (9)$$

(은닉층과 입력층)

$$\begin{aligned} \Delta a_m^i &= \eta \frac{\partial L(w, g)}{\partial a_m^i} \\ &= \eta \sum_{k=1}^K \{ (h_k - g_k) f'(v_k^m) a_k^m \} v_m x_i \\ &= \eta \delta_m^g x_i \\ \delta_m^g &= \delta_k^g v_m, \quad \delta_k^g = \sum_{l=1}^K \{ (h_k - g_k) f'(v_k^m) a_k^m \} \\ \therefore a_m^i(t+1) &= a_m^i(t) + \eta \delta_m^g x_i \end{aligned} \quad (10)$$

4. Mobile Robot System

실험에 사용되는 이동로봇의 몸체는 3개의 구동 바퀴를 가진 동기식 구동 방식이다. 동기식 구동 방식은 이동로봇 내에 부착되어 있는 바퀴들의 구동(Driving)과 조향(Steering)이 동시에 이루어지도록 구성된 방식으로 각 바퀴들에 일치된 동력을 전달하도록 되어있다. 모터 제어기는 PID 제어 방식을 사용하고 PID 제어를 통하여 모터를 구동한다. 거리측정기는 최대 24개의 초음파 센서를 구동할 수 있으며, 선택적으로 초음파 센서를 구동하고 최대 거리와 최소 거리 및 선택한 센서의 우선순위를 설정하여 사용할 수 있다. 비전처리를 위해 이동로봇에 USB 카메라를 연결하였다. 모든 제어 장치들은 USB 허브를 통하여 노트북과 연결하여 제어한다. 노트북은 센서에서 얻은 데이터를 통하여 이동로봇의 주행이 가능하도록 프로그램으로 구현한다. 이동로

봇 시스템의 구성과 외관은 그림 5과 같다.




그림 5. 이동로봇 시스템의 구성과 외관.
Fig. 5. Structure and appearance of Mobile Robot system.

5. 시뮬레이션 / 구현

이동로봇은 제안된 MNN의 구조를 사용하여 학습시키고, 그 결과값으로 이동로봇을 실시간 구현을 하였다. 먼저 EN와 GN의 구조를 최적화시키기 위해 활성화 함수를 결정하고 결합한다. 활성화 함수로는 선형함수, sigmoid와 tanh함수를 사용하였다. 활성화 함수로 결합된 모듈의 RMSE를 측정하여 가장 작은 값을 갖는 모델이 전체의 MNN에 좋은 영향을 줄 것이다. 즉 각 모듈의 RMSE가 작으면 MNN도 작은 RMSE를 갖게 될 것이다.

MLNN의 활성화 함수 조합은 은닉층과 출력층에 Sigmoid / Linear, tanh / Sigmoid, Sigmoid / Sigmoid, tanh/tanh의 4가지로 정하였다. 최적의 활성화 함수 조합을 결정하기 위해 63개의 모델로 Error / RMSE를 측정하였다. 그 결과는 그림 8, 9에 나타나 있다. 그림의 결과에서 알 수 있듯이 tanh / tanh 함수의 조합이 다른 조합에 비해 월등히 우수하였고, Sigmoid / Linear과는 약간의 차이로 우수하였다.

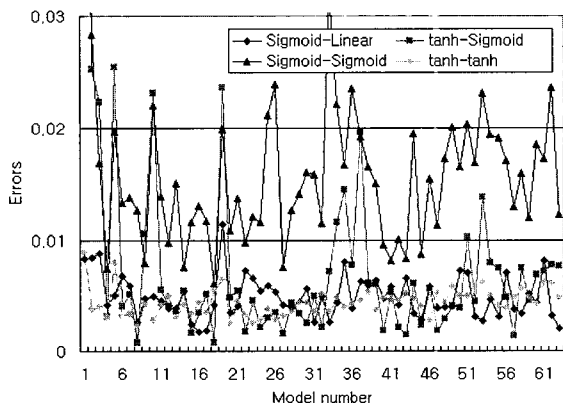


그림 6. 활성화 함수 조합에 따른 Error.
Fig. 6. Error of activation function combination.

최적의 활성화 함수 조합으로 구성된 EN를 이용하여 MNN을 학습하였다. 학습된 결과값을 사용하여 이동로봇이 타겟에 접근할 때 상황에 맞게 대처할 수 있도록 실시간으로




그림 7. 활성화 함수 조합에 따른 RMSE.
Fig. 7. RMSE of activation function combination.

구현하였다. 이동로봇 구현의 조건들은 초음파 센서의 측정 거리는 0~3m, 카메라의 시각범위는 ±20도로 제한하였고, 인간, 즉 타겟으로는 A4 크기의 RGB(빨간,녹색,파란)중 하나의 색을 선택하였다. 모듈의 기능은 추종, 접근, 충돌회피와 목표찾기로 정의하였다. MNN의 입력값은 이동로봇에 부착된 7개의 초음파 센서와 USB 카메라에서 획득한 여러 가지의 거리와 이미지 정보들로써 총 8개이며, 목표값은 속도와 회전각도이다. 이 값들은 퍼지제어에 의해 얻어진 값을 사용하였다. 퍼지추론시 속력의 전건부에는 7개와 5개, 후건부에는 9개의 멤버쉽 함수로 추론하였다. 또 회전각도의 멤버쉽으로는 전건부에는 7개와 3개, 후건부에는 9개를 사용하였다. MLNN의 은닉층은 각 모듈당 20개, 실측 데이터는 2000개, 학습률은 0.01와 가중치 갱신을 위한 역전파 학습은 100000번을 수행하였다.

입력이 모든 모듈에 들어가는 경우와 선택적으로 들어가는 경우 두가지를 망을 구성하여 비교하여 보았다. Error와 RMSE는 많은 차가 생기지는 않았지만 망의 크기가 전자에 비해 후자의 경우가 작아져 평균학습시간이 단축됨을 알 수 있었다. 그림 8과 표 1에 두 모델의 Error와 RMSE를 비교하였다.




그림 8. 두 모델의 Error 비교.
Fig. 8. Error comparison between two model.

표 1. 두 모델의 평균학습시간 비교.
Table 1. Average Learning Time comparison between two model.

구분	전체입력 MNN	선택입력 MNN
평균학습시간	2751 회	1962 회

다음 그림 9은 실험에 의해 각 모듈의 입력값과 목표값을 측정하는 모습이다.




그림 9. 입력/목표값 획득 실험.

Fig. 9. Experimental to obtain input and desired value.

시뮬레이션을 통해 구축된 알고리즘을 0.2초의 실시간으로 MR에 적용한 것을 그림 10에 보였다.

6. 결론 및 향후과제

본 논문에서는 MNN을 이용하여 이동로봇의 여러기능을 수행하는 알고리즘을 구축하였다. 추종물체와 이동로봇의 거리는 초음파 센서를 사용하여 비교적 정확한 값을 얻어 사용하였고, 위치는 USB 카메라에서 산출한 이미지 정보값을 활용하여 추종물체를 인식하였다. 전체 입력을 이용한 것보다 선택적인 입력을 사용한 MNN은 Error에서 15.56% 향상되었고, 학습 평균시간에서는 약 28.7%가 단축됨을 확인할 수 있었다. 제안된 MNN으로 구성된 프로그램을 사용하여 실시간으로 이동로봇을 구동한 결과가 만족할 만한 수준에 도달하였다. 향후 과제는 더 정확한 데이터를 얻고 다양한 경우에 대하여 학습을 시킴으로서 다양한 변화에서의 동작 특성이 구현될 수 있는 알고리즘과 시뮬레이터를 개발하는 것이다.




그림 10. MNN을 이용한 MR 구현.
Fig. 10. Traveling with a real MR using MNN.

참고문헌

- [1] Simon Haykin, "Neural Network - A Comprehensive Foundation" Prentice-Hall, Inc, 2nd Ed. 1999
- [2] 변중남, "퍼지논리제어". 홍릉과학출판사, 1997.
- [3] A. Guez, J. L. Eilbert, and M. Kam, "Neural Network Architecture for Control," IEEE Control System Magazine, pp. 22-25, 1988
- [4] Jack M. Zurada, Introduction to Artificial Neural System, West Publishing Company, 1992.
- [5] Michael I. Jordan and R. A. Jacobs, "Modular and Hierarchical Learning System," In M. Arbib(Ed.), The Handbook of Brain Theory and Neural Network, Cambridge MA: MIT Press, 1995.
- [6] Simon Haykin, "Neural Network - A comprehensive Foundation", Prentice-Hall Inc., 1999
- [7] Michael I. Jordan and Robert A. Jacobs, "Hierarchical Mixtures of Experts and the EM Algorithm," Neural Computation, Vol. 6, No. 1, pp181-214, 1994
- [8] Tomas Hrycej, "Modular Learning in Neural Network," John Wiley & Sons Inc., 1992
- [9] Gasser Auda and M. Kamel, "Modular neural network Classifiers:A Comparative Study," Journal of Neural system, Vol. 9, No. 2, pp 129-151, 1999.
- [10] Gasser Auda and M. Kamel, "CMNN: Cooperative Modular Neural Networks for pattern recognition," Pattern Recognition Letters, Vol. 18, pp 11-13, 1997.

저 자 소 개



최우경(Woo-Kyung Choi)
2000년 : 전남대학교 전기공학과 공학사
2001년~현재 : 중앙대학교 전자공학과
석사과정

관심분야 : 퍼지 이론, 신경회로망, 웨이블릿, 로보틱스

E-mail : chwk001@hanmail.net



김성주(Seong-Joo Kim)
1999년 : 중앙대학교 전저공학과 공학사
2001년 : 동 대학원 전자공학과 석사
현재 : 동 대학원 전저전기공학부
박사과정

관심분야 : 신경망, 로보틱스, 퍼지이론, 웨이블릿, 신경망 등

서재용(Jae-Yong Seo)

1996년 : 중앙대학교 전자공학과 공학사
1998년 : 동 대학원 전자공학과 공학석사
2001년 9월 : 동 대학원 전자공학과 공학박사
현재 : 한국기술교육대학교 정보기술공학부 객원교수

관심분야 : 퍼지, 유전알고리즘, 신경망, FNN, 웨이블릿
신경망

전 흥태(Hong-Tae Jeon)

현재 중앙대학교 전자전기공학부 교수