

◆ 특집 ◆ 고령자 / 장애인의 활동 보조 기계 기술

역전파 신경망 이론을 이용한 팔꿈치 관절의 관절토크 추정에 관한 연구

Joint Torque Estimation of Elbow joint using Neural Network Back Propagation Theory

장혜연¹, 김완수¹, 한정수², 한창수^{1,✉}
Hye Youn Jang¹, Wan Soo Kim¹, Jung Soo Han² and Chang Soo Han^{1,✉}

¹ 한양대학교 기계공학과 (Department of Mechanical Engineering, Hanyang Univ.)

² 한성대학교 기계시스템공학과 (Department of Mechanical System Engineering, Hansung Univ.)

✉ Corresponding author: cshan@hanyang.ac.kr, Tel: 031-400-4062

Manuscript received: 2011.3.30 / Accepted: 2011.4.28

This study is to estimate the joint torques without torque sensor using the EMG (Electromyogram) signal of agonist/antagonist muscle with Neural Network Back Propagation Algorithm during the elbow motion. Command Signal can be guessed by EMG signal. But it cannot calculate the joint torque. There are many kinds of field utilizing Back Propagation Learning Method. It is generally used as a virtual sensor estimated physical information in the system functioning through the sensor. In this study applied the algorithm to obtain the virtual sensor values estimated joint torque. During various elbow movement(Biceps isometric contraction, Biceps/Triceps Concentric Contraction (isotonic), Biceps/Triceps Concentric Contraction/Eccentric Contraction (isokinetic)), exact joint torque was measured by KINCOM equipment. It is input to the (BP)algorithm with EMG signal simultaneously and have trained in a variety of situations. As a result, Only using the EMG sensor, this study distinguished a variety of elbow motion and verified a virtual torque value which is approximately(about 90%) the same as joint torque measured by KINCOM equipment.

Key Words Neural Network (신경망이론), Back Propagation (역전파), Electromyogram (근전도), Joint Torque (관절토크)

1. 서론

최근 근전도(Electromyogram), 심전도(Electrocardiogram), 뇌파(Electroencephalogram) 등 다양한 생체신호들이 피험자의 상태 측정을 위한 계측신호로만 쓰이지 않으며, 다양한 분야에 응용된 새로운 연구들이 이루어지고 있다.¹⁻³ 하지만 생체신호의 특징인 개인적인 정상치의 기준이 각각 다르며, 그 측정이 까다롭고 많은 신호처리를 거쳐야 하는 단점이 있다. 하지만 근전도 신호의 경우, 최근 한국, 미국, 일본 등 로봇 강국에서 활발히 개발 중인 착용형 로봇의 동작의도 감지센서로

사용되고 있다.^{4-6,11}

근전도 신호는 물리적인 변위를 일으키지 않고, 측정자의 동작의도를 미리 미세한 근신호로 측정 가능한 장점이 있으며, 타 생체신호보다 측정이 비교적 간단하지만, 개인적인 값의 차이와 근전도 신호와 관절 토크와의 관계가 있음은 유추되고 있으나, 이는 상대적 근력의 차이로 표현될 뿐 정확한 근력 토크를 추정하기는 힘들다. 따라서 본 연구에서는 인공신경망 이론을 적용하여 근전도 신호만으로 관절 토크를 정량적으로 추정하기 위한 연구를 수행하였다.

인공신경망 이론(artificial neural network)은 다양

한 분야에서 활발히 연구가 진행되고 있으며, 그 적용 분야에 대해서 무한한 가능성을 갖고 있다. 특히, 복잡한 공학모델에 대해서 좋은 결과를 보이고 있다. 인공신경망의 장점은 입력에 대해 원하고자 하는 출력에 대한 자세한 정보가 없이도 학습 알고리즘을 통하여 제어대상에 대한 모델링이 가능하며 간단하게 구현, 적용할 수 있다는 점이다. 또한, 학습 알고리즘을 이용하기 때문에 비선형 모델에 대한 적용성능이 높다.⁷ 따라서 수학적으로 모델링 하기 어려운 링크의 동역학 모델, 인체 동역학 모델과 같은 비선형 시스템에 대해서 적용하기 위해 많은 연구가 이루어 지고 있다.^{15,16}

비선형적인 모델을 간단하게 구현, 적용할 수 있다는 인공신경망 이론의 학습 알고리즘에는 다양한 방법이 존재하지만 가장 많이 사용되는 것은 Rumelhart 가 제안한 입력과 출력에 대한 에러의 가중치를 이용한 역전파(back-propagation)방법이다.⁸ 역전파 학습방법을 활용한 분야는 다양하지만 그 중에서 시스템에 작용하는 물리적 정보를 하나의 센서를 통하여 추정하는 가상센서의 개념이 가장 대표적이라고 할 수 있다. 가상센서의 의미는 여러가지 의미로 다양한 연구분야에서 시도되고 있으며 특히, 착용형 로봇 분야에서 소량의 센서를 이용하여 다양한 거동을 예측하기 위하여 G. Caurin(1994)은 보행로봇의 다리에 장착된 다축 힘센서를 기반으로 접촉되는 물리적 특징을 분석, 보행패턴에 반영하는 시스템을 연구하였다.^{9,10} 본 연구에서는 상지 거동 시 발생하는 각도 별 근력 토크와 근전도를 동시에 측정하고, 이를 이용하여 역전파 신경망 학습방법에 적용하여, 학습 후 근전도 신호만으로 정확한 근력토크를 추정함을 증명하였다.

2. 상지 동작 별 근력 토크 및 근전도 측정

2.1 연구목표

본 연구의 목표는 신경망이론(Neural network) 중 역전파 (Back Propagation)을 이용하여 최소한의 근전도 신호를 이용하여 정확한 관절 토크를 추정할 수 있도록 하는데 있다. 다양한 팔꿈치 동작 시 관절 각도, 관절 토크 및 주동근 및 길항근의 근전도 신호 등 다양한 운동정보를 이용하여 역전파 신경망 이론을 이용하여 훈련 후 근전도 신호만으로 정확한 관절 토크를 추정하고, 이를 실제 관절 토크값과 비교하였다.

2.2 관절 토크 측정을 위한 동작의 정의

상지 동작 중 팔꿈치 동작의 경우, 팔꿈치 신전/굴곡(Extension/Flexion) 동작으로 분리 할 수 있으며, 근육의 활성화 및 주동근/길항근(agonist/antagonist)의 근육 팽창/수축여부에 따라 크게 5 가지 동작으로 분리 할 수 있다.³ 팔꿈치 신전/굴곡 시 주동근은 이두근(Biceps brachii muscle)과 삼두근(Triceps brachii muscle)으로 각 근육이 활성화 상태에서 근육의 수축 및 팽창여부에 따라 팔꿈치 운동동작을 Table 1 과 같이 분리하였다.

Table 1 Elbow joint's agonist muscle motion

Muscle	Dynamic muscle action	Motion
Biceps brachii muscle	Isometric	Biceps isometric contraction
	Concentric	Biceps Concentric Contraction
	Eccentric	Biceps Eccentric Contraction
Triceps Brachii muscle	Concentric	Triceps Concentric Contraction
	Eccentric	Triceps Eccentric Contraction

Biceps isometric contraction 의 경우, 근 수축은 일어나지만 근육의 길이 변화가 없는, 즉 동작이 없는 경우를 말한다. Concentric/ Eccentric Contraction 의 경우 근력이 발생되어 근 수축이 일어남과 동시에 근육의 길이가 짧아지거나(Concentric) 길어지는 경우(Eccentric)를 말한다. 팔꿈치의 신전/굴곡이 일어나는 동안에도 근육의 수축 형태에 따라 다양하게 동작의도를 분리할 수 있다.

본 연구에서는 정확한 관절토크의 레퍼런스 값을 측정하기 위해 각 관절 별 등속성(isokinetic)/등척성(isometric)/등장성(isotonic)운동 및 이에 따른 정확한 속도 및 관절토크를 모니터링 할 수 있는 KINCOM 장비를 사용하였다.

총 3 가지의 실험을 통해 위의 5 가지 동작에 따른 관절 토크를 측정하였으며, 이와 동시에 이두근(biceps brachii muscle)과 삼두근(Triceps brachii muscle)의 근전도를 동시에 측정하여 각 동작 시 관절 각도(joint angle), 근전도(EMG, Electromyogram), 관절 토크를 동시에 얻을 수 있다. 동작은 ① Biceps isometric contraction 동작/② 활성화된 근육의 길이가 짧아지는 Concentric 상태의 팔꿈치 신전/굴곡(elbow extension/flexion)동작/ ③각 근육의

Concentric 과 Eccentric contraction 이 섞여 있는 복합 동작 시 각 정보를 수집하여 역전파 신경망 알고리즘에 적용하였다.

2.3 근전도 측정 및 근전도 신호처리

팔꿈치 신전/굴곡(Extension/Flexion)운동의 경우 주동근(agonist)은 이두근이며, 길항근(antagonist)은 삼두근이 되므로, 표면 근전도(surface EMG)를 각각 근육에 부착하였다.

일반적인 근전도 신호의 경우 전원노이즈 및 주변 노이즈에 의해 high/low pass filter 가 기본적으로 내장되어 측정되게 되어있다. 또한 그 형태가 일정한 축을 따라 Oscillation 되어 원데이터(Raw data)를 그냥 사용하기에 적합하지 않다. 따라서 여러가지 방법으로 필터링 하여 사용한다. 본 연구의 경우 EMG 신호를 이용하여 근력 토크를 추정해야 하므로 그 경향성을 뚜렷하게 나타 낼 줄 수 있도록 신호처리 되어야 한다.^{12,13}

근전도의 신호처리 방법은 많은 연구가 이루어져 왔으며, 본 연구에서는 버터워스 필터(Butterworth filter), 베셀필터(Bessel filter), 이동평균필터(Moving average filter)를 이용하여 신호처리 하였다.

Fig. 1, 2 와 같이 여러가지 필터를 적용한 근전도

신호처리 결과, 베셀필터(Bessel filter)와 이동평균필터(Moving average filter)를 함께 적용하였을 때 근전도 신호의 oscillation 신호특성을 없애며 가장 좋은 응답을 얻을 수 있었다. 근전도의 원데이터(raw data)의 경우, 관절 토크 발생 방향과 관계없이 그 크기에 비례한 경향의 진폭으로 oscillation 되지만, 이동평균 필터와 베셀필터를 함께 사용하였을 때, 한번의 굴곡/신전 운동을 할 경우, 신호의 진폭이 가장 작고, 관절 토크 발생방향이 같은 주기 동안 신호의 변곡점이 가장 적게 나타났다. 필터링 된 근전도 데이터를 역전파 신경망 알고리즘의 훈련 데이터 및 관절 토크 추정을 위한 레퍼런스 데이터로 사용하였다.

2.4 KINCOM 을 이용한 근력토크 측정




Fig. 3 Measurement of real joint torque using KINCOM device

팔꿈치 동작 시 정확한 근력 토크 값, 관절 각도 등을 측정하기 위해 KINCOM 장비를 사용 및 훈련을 위한 레퍼런스 데이터를 수집하였다. KINCOM 의 경우, 일정 각도에서 등척성(Isometric) 운동이 가능하며, 동작 범위 및 관절 토크제한, 등장성 운동이 모두 가능하다. KINCOM 에서 측정가능한 범위에서 3 가지의 측정동작을 기반으로 실험 프로토콜을 임의 정의하였으며, 측정 시 이두근(Biceps brachii muscle)과 삼두근(Triceps brachii muscle)의 근전도를 동시에 측정하여 Motion 과 Time Domain 을 일치화 하였다.

첫번째 Biceps isometric contraction 측정 시 고정각도는 최대근력 측정이 가능한 110(deg)로 하였고¹⁴ 이두근의 Concentric 이 가능한 방향으로 다양한 크기의 근력을 발생시켰다.




Fig. 1 EMG Signal of Elbow extension/flexion




Fig. 2 Filtering Data of EMG Raw Signal

Table 2 Elbow joint's agonist/antagonist muscle motion

No	Measurement
1	<p>Biceps isometric contraction</p>
2	<p>Biceps/Triceps Concentric Contraction (isotonic)</p>
3	<p>Biceps/Triceps Concentric Contraction → Eccentric Contraction (isokinetic)</p>

두번째는 이두근과 삼두근의 Concentric contraction 의 반복 동작으로 0~60(deg)사이를 신전/굴곡 운동을 피험자가 임의의 근력 토크를 발생하여 동작할 수 있도록 하였다. 마지막으로 두 근육의 Concentric/Eccentric contraction 을 복합적으로 수행하였으며, 이때 등장성 운동이 가능하도록 동작을 위한 관절토크와 동작 속도를 25N, 30deg/sec 로 제한하여 측정하였다.

3. 측정 결과 및 역전파 신경망 알고리즘 구성

3.1 측정결과 (Reference data of Back propagation Training algorithm)

① Biceps isometric contraction

피험자가 일정각도(110deg)에서 임의로 관절토크를 변화시키며 이두근/삼두근의 근전도 신호와 KINCOM 에서 측정되는 관절 토크와 각도를 동시 측정하였다.




Fig. 4 KINCOM Data (Biceps isometric contraction)




Fig. 5 EMG Data (Biceps isometric contraction)

② Biceps/Triceps Concentric Contraction

피험자가 0-60deg 사이에서 Biceps Concentric Contraction 과 Triceps Concentric Contraction 을 반복적으로 동작하며, 동작 속도 및 힘은 피험자의 의지대로 움직일 수 있도록 하였다.




Fig. 6 KINCOM Data (Biceps/Triceps Concentric Contraction)




Fig. 7 EMG Data (Biceps/Triceps Concentric Contraction)

③ Biceps/Triceps Concentric Contraction
→ Eccentric Contraction

피험자가 0-90deg 사이를 반복 운동을 하며, 이 두근과 삼두근의 Concentric Contraction 과 Eccentric Contraction 을 교차해가며 동작하는 복합 동작이다. 각 운동 정보는 Fig. 8 에 기재된 바와 같다.

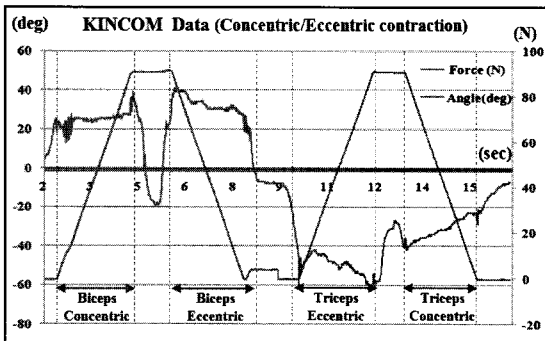


Fig. 8 KINCOM Data according to experimental scenario





Fig. 9 EMG Data according to experimental scenario


3.2 역전파 신경망 알고리즘 구성

역전파 학습 알고리즘은 원하는 출력을 위하여

다층 신경망을 훈련시키기 위해 사용되는 기술이며, Fig. 10 은 일반적인 다층 신경망을 나타내고 있다. 입력 층(input layer), 출력 층(output layer), 은닉 층(hidden layer) 등으로 구분되는데, 역전파 알고리즘은 출력 층으로부터 은닉 층으로 목표 출력값에 대한 에러를 역으로 전파하는 원리로 동작한다.



(a) Generalized Multi-layered Neural Networks



(b) Basic Input/output expression of multi-layered neural networks

Fig. 10 Basic concept of multi-layered neural networks

본 연구에서는 상지 동작별 관절 토크 값을 근전도 센서를 통해 측정된 근육활성도 데이터를 이용하여 학습하고, 역전파 학습알고리즘을 이용하여 학습된 가중치를 이용하여 근육활성도 데이터만을 이용하여 상지 동작에 대한 관절 토크를 추정하는 방법을 적용하였다. 이를 위해서는 근전도 신호를 신경망의 입력으로 사용하며 관절 토크 값을 신경망의 목표 값에 대해 비교 및 훈련한다. 신경망에 대한 각 층의 입출력은 Fig. 10(b)와 같이 나타낼 수 있으며 각 층의 입력 x_i 에 대한 출력 y_j 와 학습을 통해 생성되는 결과값 z_k 는 다음의 수식과 같이 나타낼 수 있다. w_{ji} 는 각 층의 가중치를 나타내며 학습을 통해 변화된다.

$$y_j = f(net_j) = f\left(\sum_{i=1}^d w_{ji}x_i\right) \quad (1)$$

$$z_k = f(net_k) = f\left(\sum_{j=1}^H w_{kj}y_j\right) \quad (2)$$

역전파 알고리즘은 Gradient descent error minimization 에 기반하며, 학습을 통하여 변화되는 가중치 w 는 아래와 같이 표현할 수 있다.

$$\begin{aligned} \mathbf{w}(k+1) &= \mathbf{w}(k) + \Delta\mathbf{w}(k) \\ \Delta\mathbf{w} &= -\eta \frac{\partial J(\mathbf{w})}{\partial \mathbf{w}} \end{aligned} \quad (3)$$

η 는 학습율이며, J 는 아래와 같이 표현된다.

$$J(\mathbf{w}) = \frac{1}{2} \sum_{k=1}^c (t_k - z_k)^2 = \frac{1}{2} \|\mathbf{t} - \mathbf{z}\|^2 \quad (4)$$

출력 층과 은닉 층을 Chain Rule 을 적용하여 정리하면 다음과 같이 표현된다.⁷

$$\begin{aligned} \Delta w_{ji} &= -\eta \frac{\partial J}{\partial w_{ji}} \\ &= \eta \left[\sum_{k=1}^c \delta_k w_{kj} \right] f'(net_j) x_i = \eta \cdot \delta_j \cdot x_i \end{aligned} \quad (5)$$

이를 통하여 학습에 따른 Δw_{ji} 가 신경망에 적용되어 입력값과 목표 출력값에 대한 오차를 줄인다. 일반적으로 역전파 알고리즘의 가중치는 -0.5~0.5 사이의 값으로 초기화하여 사용된다.

4. 역전파 근전도를 이용한 관절 토크 추정

위의 역전파 알고리즘을 적용하여 근전도, 관절토크, 각도 등의 레퍼런스 데이터를 이용하여 역전파 신경망 알고리즘 훈련을 수행하며, 훈련된 알고리즘은 EMG 신호만으로 관절토크를 추정한다.

Fig. 12 는 EMG 신호만으로 추정된 관절 토크와 실제 관절 토크 값을 비교한 것이다. 기존의 근전도신호의 RMS 등의 신호처리를 통해 근력의 상대적 크기를 구별 가능하였지만, 본 연구결과는 근육의 길이가 변하지 않는 상태에서 임의로 변화하는 관절 토크의 경향뿐 아니라 토크의 변화 정도까지 근사하게 추정해 내는 것을 알 수 있다. 특히

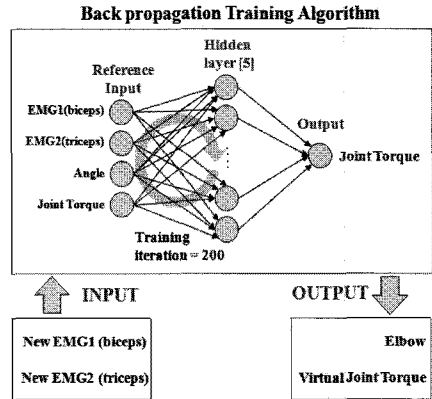


Fig. 11 Basic concept of Back propagation algorithm

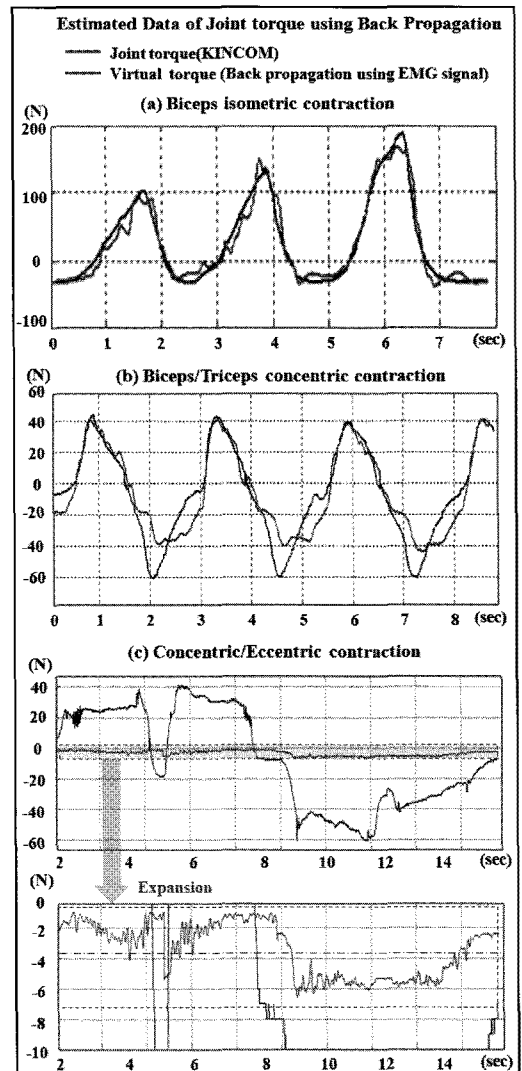


Fig. 12 Estimated Data of joint torque using EMG

① Biceps isometric contraction 실험동작에서 고정된 각도에서 근력크기가 100N-135N-185N 으로 증가할 때[Fig. 12(a)], 필터링 된 EMG 신호와 역전파 신경망 알고리즘으로 추정된 근력값의 첫번째 측정값을 100N 으로 Normalization 하여 근력변화를 비교한 결과, 필터링 된 EMG 신호[Fig. 5]는 각각 100N-270N-360N 으로 실제 근력 변화 정도를 유의하게 추종한다고 할 수 없으며, 역전파 신경망 알고리즘을 이용하였을 경우에는 100N-150N-175N 으로 약 90% 유사하게 추정하였다. 또한 똑같은 팔꿈치 신전/굴곡의 동작에서도 동작 의도(Concentric / Eccentric Contraction)에 따른 주동근과 길항근에서 발생하는 근전도신호로 실제로 측정된 관절토크와 유사한 경향을 나타냄을 알 수 있다.

5. 결론

본 연구를 통해 역전파 신경망 이론(Neural Network Back propagation)을 이용한 알고리즘 훈련을 통하여 팔꿈치 관절의 주동근/길항근(agonist/antagonist)이 두가지의 근전도 신호만으로 팔꿈치 동작 시의 관절토크를 추정할 수 있었다. 이는 토크 발생의 경향성뿐만 아니라 활성 근육 및 관절 토크 발생방향에 따른 여러가지 동작상태 및 그 변화 정도까지 KINCOM 장비를 통해 측정된 관절 토크값과 매우 근사하게 추정 가능함을 알 수 있었다. 본 연구를 통해 사용된 관절토크 추정 알고리즘의 경우, 정량적인 근력 표현이 어려운 EMG 신호의 단점을 극복 할 수 있으며, 외골격 로봇의 동작의도신호로 활용될 경우, 다양한 동작에 대한 훈련을 통하여 물리적 신호에 앞서 착용자의 동작의도를 습득하는데 효과적으로 활용될 수 있을 것이다.

후 기

이 논문은 2010 년도 정부(교육과학기술부)의 재원으로 한국연구재단-공공복지안전사업의 지원을 받아 수행된 연구임(No. 2010-0020487).

참고문헌

1. Moon, I., Lee, M., Chu, J. and Moon, M., "Wearable EMG-Based HCI for Electric-Powered Wheelchair Users with Motor Disabilities," IEEE International

- Conference on Robotics and Automation, pp. 2649-2654, 2005.
2. Bethel, C. L., Salomon, K., Murphy, R. R. and Burke, J. L., "Survey of Psychophysiology Measurements Applied to Human-Robot Interaction," IEEE International Symposium on Robot and Human Interactive Communication, pp. 732-737, 2007.
3. Jang, H. Y., Han, C. S., Kim, T. S., Jang, J. H. and Han, J. S., "Development of Wearable Robot for Elbow Motion Assistance of Elderly," Journal of Korean Society for Precision Engineering, Vol. 25, No. 3, pp. 141-146, 2008.
4. Hayashi, T., Kawamoto, H. and Sankai, Y., "Control method of robot suit HAL working as operator's muscle using biological and dynamical information," IEEE/RSJ International Conference on Intelligent Robots and Systems, pp. 3063-3068, 2005.
5. Kazerooni, H., Racine, J.-L., Huang, L. and Steger, R., "On the Control of the Berkeley Lower Extremity Exoskeleton (BLEEX)," IEEE International Conference on Robotics and Automation, pp. 4353-4360, 2006.
6. Jang, J. H., Lee, H. D., Jang, H. Y., Han, J. S., Han, C. S. and Son, W. H., "Development of Wearable Robot System based the Analysis of the Lower Limbs," Journal of Korean Society for Precision Engineering, Vol. 26, No. 7, pp. 7-14, 2009.
7. Kim, D. S., "Neural Networks - Theory and Applications," Jinhan M&B, 1993.
8. Miller, T., Sutton, R. S. and Werbos, P. J., "Neural Networks for Control," MIT Press, 1990.
9. Caurin, G. and Tschichold-Gurman, N., "The Development of a Robot Terrain Interaction System for Walking Machines," IEEE International Conference on Robotics and Automation, Vol. 2, pp. 1013-1018, 1994.
10. Ko, K. J., Kim, W. S., Yu, S. N. and Han, C. S., "Virtual Sensor Verification using Neural Network Theory of the Quadruped Robot," Trans. on KSME A, Vol. 33, No. 11, pp. 1326-1331, 2009.
11. Jeon, B. L. and Cho, H. C., "EXOSKELETON ROBOT ARM Control By Fuzzy Algorithm Using EMG Signal," Proceedings of KIIS Fall Conference, Vol. 19, No. 2, pp. 218-221, 2009.
12. Harald, R., Jiri, S. and Gunter, R., "Spatial Filtering

- of Noninvasive Multielectrode EMG: Part-2-Filter Performance in Theory and Modeling,” IEEE Transactions on Biomedical Engineering, Vol. BME-34, No. 2, pp. 106-113, 1987.
13. Kang, D. B., Kim, S. J., Hwang, J. H. and Jung, C. S., “Design of bandpass filter for flat passband and sharp steepness,” The 40th KIEE Summer Conference, pp. 14-17, 2009.
 14. Linnamo, V., Strojnik, V. and Komi, P. V., “Maximal force during eccentric and isometric actions at different elbow angles,” European Journal of Applied Physiology, Vol. 96, No. 6, pp. 672-678, 2006.
 15. Hanzevack, E. L. Long, T. W., Atkinson, C. M. and Traver, M. L., “Virtual Sensor for Spark Ignition Engines Using Neural Network,” Proc. of American Control Conference, Vol. 1, pp. 669-673, 1997.
 16. Wickstrom, N., Taveniku, M., Linde, A., Larsson, M. and Svensson, B., “Estimating Pressure Peak Position and Air-Fuel Ratio Using the Ionization Current and Artificial Neural Networks,” IEEE Conference of Intelligent Transportation System, pp. 972-977, 1997.