

◆ 특집 ◆ 고령자 / 장애인의 활동 보조 기계 기술

물리적 인간-기계 상호작용을 위한 표면 근전도 신호 기반의 어깨 굴곡 토크 및 각도 추정

Estimation of Shoulder Flexion Torque and Angle from Surface Electromyography for Physical Human-Machine Interaction

박기한¹, 이동주¹, 김정^{1✉}
Kihan Park¹, Dong Ju Lee¹ and Jung Kim^{1✉}

1 한국과학기술원 기계공학과 (Department of Mechanical Engineering, KAIST)

✉ Corresponding author: jungkim@kast.ac.kr, Tel: 042-350-3231

Manuscript received: 2011.3.30 / Accepted: 2011.4.28

This paper examines methods to estimate torque and angle in shoulder flexion from surface electromyography(sEMG) signals for intuitive and delicate control of robotic assistance device. Five muscles on the upper arm, three for shoulder flexion and two for shoulder extension, were used to offer favorable sEMG recording conditions in the estimation. The methods tested were the mean absolute value (MAV) with linear regression and the artificial neural network (ANN) method. An optimal condition was sought by varying combination of muscles used and the parameters in each method. The estimation performance was evaluated using the correlation values and normalized root mean square error values. In addition, we discussed their possible use as an estimation of motion intent of a user or as a command input in a physical human-machine interaction system.

Key Words: Surface Electromyography (표면 근전도), Shoulder Flexion Torque/Angle (어깨 굴곡 토크/각도)

1. 서론

인간의 수의적 움직임은 뇌와 척수의 중추신경계(central nervous system, CNS)에 의해 조절되는 근골격계(musculoskeletal system)의 반응이며, 어떤 동작들을 수행하기 위한 사용자의 의도는 사용자의 현재 상태나 주변 환경에 따라 최적의 응답을 내도록 근골격계에 반영된다. 근육 수축에 의해 근력이 발생하면 골격에 의해 관절의 토크로 변형되고, 이 때 발생된 관절 힘/토크에 의해 신체의 역학적 거동이 나타난다. 즉, 물리적 인간-기계 상호작용(human-machine interaction, HMI)을 위해서는 사

용자의 관절 힘/토크와 거동을 파악하는 것이 중요하며, 이러한 정보는 근육이 수축하는 정도에 따라 변하므로 근전도(electromyography)를 사용하여 계측할 수 있다.¹

근전도는 근육의 수축 정도를 측정할 수 있는 전기생리학적 신호로써 의수 로봇(robotic prosthesis), 외골격로봇(exoskeleton)과 같은 인간-기계 상호작용분야에서 인간의 거동 의도를 추출하기 위해 많이 사용되는 대표적인 생체 신호 중 하나이다.²⁻⁴ 근전도는 근육 표면에 부착하는 전극을 통해 비침습적으로 쉽게 취득할 수 있어 뇌전도(electroencephalography, EEG)나 신경전도

(electroneurography ENG) 등의 다른 생체 신호에 비해 사용이 간편하며, 근육의 움직임 명령 신호로써 실제 신체의 움직임이 일어나기 이전에 신호가 관측되므로 힘/토크 센서나 모션카메라를 이용하여 사용자의 움직임 의도를 예측하는 것에 앞서 해석할 수 있어 기계와 상호작용 하는 연산을 추가적으로 수행할 수 있다는 장점이 있다.⁵ 하지만 인간의 신경체계는 각 근육에 개별적 운동명령을 내리는 것이 아니라 여러 근육을 그룹화하여 제어한다. 근육 그룹들은 각 움직임 의도에 맞는 다양한 명령 패턴이 존재하며, 이에 의해 전체적인 거동이 나타난다는 연구 결과가 있지만,⁶ 근육 그룹화와 명령 패턴에 대한 정확한 메커니즘은 아직 밝혀지지 않아 근전도를 통한 힘/토크 및 거동 예측에 어려움이 있다.

사람의 섬세한 움직임까지 표현 가능한 다자유도 로봇이 개발된 것에 반해,⁷ 인간-기계 상호작용을 위한 사용자의 힘/토크 및 거동 의도를 추출하는 연구는 손목, 팔꿈치 관절에 적용된 것 뿐으로 로봇 연구에 비해 상대적으로 미흡하다.^{8,9} Tenore et al.¹⁰은 근전도 신호로부터 손가락의 굽힘/펴 등 10 가지 이상의 움직임 의도를 분석하는 데 성공하였으며, 사용자가 근전도 신호를 이용하여 의수 로봇의 손가락을 개별적으로 제어할 수 있는 가능성 을 보였다. 하지만 이 연구는 굽힘/펴과 같은 On/Off 상태의 의도만 추출하였으며, 어느 정도의 힘으로 로봇의 동작을 수행할 것인지에 관한 힘 정보는 추출하지 않았다. 재활과 운동생리학 분야에서 근전도 신호로부터 근육의 힘을 추정한 연구들이 있지만, 바늘 전극을 사용하여 침습적으로 근전도를 측정했거나 오프라인 해석을 수행한 것에 그쳐 인간-기계 상호작용 분야에 적용하기에는 부적절하다.^{11,12} 최근 생체의 기계적 신호인 근진동 (mechanomyogram, MMG) 신호로부터 근육 힘을 추정한 연구가 수행되었다. 근진동 신호는 센서 위치에 따른 신호 취득의 변동이 적어 근전도 전극에 의해 부착 위치에 구애 받지 않는 장점이 있지만 예측 성능이 근전도 신호를 이용한 것에 미치지 못하는 것으로 나타났다.^{13,14}

본 연구에서는 인간-기계 상호작용을 위해 근전도 신호로부터 어깨 굴곡 힘/토크 및 각도를 추정하는 연구를 수행하였다. 어깨는 볼 조인트 형태의 관절과 견갑골의 조합으로 거동이 매우 복잡하여 상지부 중 근전도 신호를 이용한 힘/토크 예측이 많이 이루어지지 않았다. 이에 어깨 움직임

중 일상생활에 가장 많이 사용하는 어깨 굴곡 (flexion)을 목표 동작으로 선정했다. 어깨 굴곡과 신전(extension)을 관장하는 5 개의 근육을 선정하고, 인공 신경망과 선형 회귀방정식을 이용한 절대 평균 값 방법을 이용하여 정적 상태에서의 등 척성(isometric) 어깨 굴곡 토크와 동적 상태에서의 어깨 굴곡 각도를 추정하였다. 실시간 인간-기계 상호작용에 적용할 수 있으며 어깨 굴곡 움직임을 주도하는 근전도 신호 추출 근육의 조합과 추정 방법 알고리즘을 변화시키며 추정 성능을 비교하였다.

2. 본론

2.1 근육 선정

어깨 관절은 3 개의 뼈{상완골(humerus), 견갑골(scapula), 쇄골(clavicle)}, 5 개의 관절{견갑상완 관절(scapulohumeral joint), 견쇄 관절(acromioclavicular joint), 흉쇄 관절(sternoclavicular joint), 견흉 관절(scapulothoracic joint), 상완상 관절(suprahumeral joint)}, 12 개의 인대 및 15 개 이상의 근육을 포함하는 복합 관절(complex joint)로 이루어져 있다. 어깨 관절은 인체 내에서 움직임이 가장 자유롭고, 가동 범위(range of motion, ROM)가 넓기 때문에 다양한 운동 동작을 가능하게 가능하게 하고, 또한 팔의 무게를 지지하는 역할을 한다. 인체 내 근육은 상호 영향을 주기 때문에 어깨의 움직임 시 어깨를 구성하는 근육 외에 가슴, 등, 팔, 목 등의 부위의 근육들이 직접 혹은 간접적으로 함께 사용된다. 본 연구의 목표 동작인 어깨 굴곡의 경우에

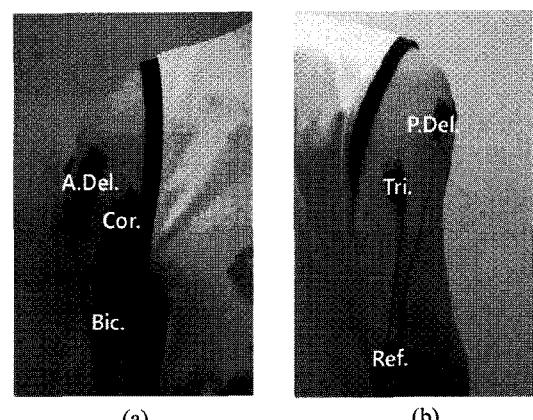


Fig. 1 Electrodes placement for sEMG data acquisition
(a) anterior view (b) posterior view

는 전면 삼각근(anterior deltoid), 이두근 장두(long head of biceps), 오훼완근(coracobrachialis), 대흉근(pectoralis major), 앞톱니근(serratus anterior), 승모근(trapezius)의 6 개의 근육에 의해 거동하며, 어깨 신전의 경우 후면 삼각근(posterior deltoid), 삼두근 장두(long head of triceps), 광배근(latissimus dorsi), 대원근(teres major)의 4 개의 근육에 의해 관장된다. 사전 실험을 통해 어깨 굴곡/신전 동작 시 사용되는 총 10 개의 근육 중 근 활성도가 크면서, 움직임 시 신호 애곡이 적은 5 개의 근육(굴곡:전면 삼각근, 이두근 장두, 오훼완근, 신전:후면 삼각근 삼두근 장두)을 선정하였다(그림 1).

2.2 계측 장치

어깨 굴곡에 의해 발생되는 관절 토크와 각도를 측정하기 위해 그림 2 와 같이 계측 장치를 고안하였다. 감속비 91:1 기어 모터(RE40), 엔코더(HEDS5540), 브레이크(Brake AB 40, 이상 Maxon Precision motors, Switzerland), 토크 센서(SDN-2kgf.m, CTA Plus, Korea)가 연결된 계측부와 팔꿈치 각도가 90 도인 기능적 자세를 유지하며 어깨 굴곡을 수행할 수 있는 기구부로 구성되어 있다. 근육의 활성도를 측정하기 위해 표면 전극(DE-2.1, Delsys, USA)을 사용했고, 데이터 획득 보드(Q8-usb, Quanser, Canada)를 이용하여 1kHz로 원 근전도 신호(raw EMG signal)를 수집하였다.

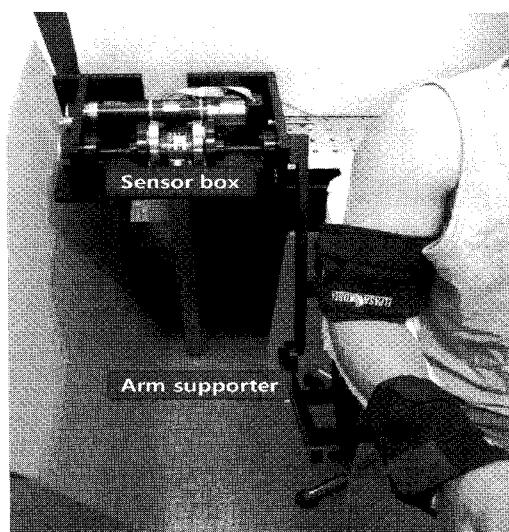


Fig. 2 Instrumentation system setup

2.3 추정 방법

2.3.1 인공 신경망 회로

인공 신경망 회로(artificial neural network, ANN)는 근골격계의 모델 없이도 근전도 신호와 관절 토크/각도 관계를 예측할 수 있는 장점을 가지며, 이 성능은 신경망의 구조에 따라 결정된다. 인공 신경망은 그림 3 와 같이 여러 층(layer)으로 구성되어 있으며, 각각의 층은 다수의 은닉 뉴런(hidden neuron)으로 구성된다. 은닉 뉴런의 수와 층의 수가 많아질수록, 즉, 신경망의 구조가 복잡해질수록 입출력신호간의 비선형적 관계를 잘 추정할 수 있게 되지만 초기 학습시간이 길어지며, 실제 모델보다 복잡한 구성을 가지게 되어 over-fitting 이 발생하는 단점이 있다. 반대로 은닉 뉴런과 층의 수가 적어질수록 초기 학습시간이 줄어들지만 복잡한 입출력관계의 추정 성능은 떨어져 under-fitting 이 발생한다. 근전도 신호와 관절 토크/각도와의 관계를 잘 추정할 수 있는 복잡도의 신경망을 구성하기 위해 은닉 뉴런과 층의 개수에 따른 추정 성능 파악을 위한 사전 시뮬레이션을 수행하였다. N 개의 데이터 세트에서 하나의 층에 대해 은닉 뉴런의 수를 증가시키면서 측정 신호($x_{1,i}$)와 추정 신호($\hat{x}_{2,i}$)의 상관 계수(correlation coefficient, CORR)를 식 (1)을 통해 확인한 결과 토크/각도 모두 15 개 이상의 은닉 뉴런일 때 추정 성능이 수렴하며, 15 개의 은닉 뉴런으로 구성된 층의 개수에 대해서는 뚜렷한 경향이 나타나지 않으면서 모두 높은 추정성능을 나타냈다. 이는 입출력신호간의 복잡도는 15 개의 은닉 뉴런을 갖는 하나의 층으로 구성된 인공 신경망으로 모사가 가능하다는 것을 의미한다.

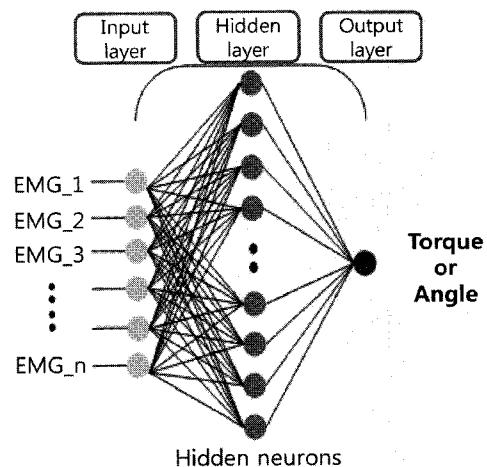


Fig. 3 Structure of artificial neural network

$$\text{CORR} = \frac{N \sum \mathbf{x}_{1,i} \mathbf{x}_{2,i} - \sum \mathbf{x}_{1,i} \sum \mathbf{x}_{2,i}}{\sqrt{N \sum \mathbf{x}_{1,i}^2 - (\sum \mathbf{x}_{1,i})^2} \sqrt{N \sum \mathbf{x}_{2,i}^2 - (\sum \mathbf{x}_{2,i})^2}} \quad (1)$$

2.3.2 선형 회귀 방정식을 이용한 절대 평균 값

절대 평균 값(mean absolute value, MAV)은 식 (2)와 같이 절대값의 이동 평균(moving average)을 나타내는 값으로, 간단한 모델이지만 고주파의 생체신호인 근전도, 근진동 신호의 특징을 잘 나타낸다. 식 (2)에서 $x_{i,k}$ 는 i 번 째 채널에서 측득된 k 번째 원 근전도 신호, 식 (3)의 n은 추정에 사용한 근육 개수, 식 (4)의 N은 데이터 세트수를 나타낸다. 이를 이용하여 목표 동작에 관련된 여러 근육의 선형 조합으로 관절 토크/각도를 추정하는 방법을 수행한다. 선형 회귀 방정식을 적용한 MAV 토크/각도 추정은 식 (3)과 같으며, 평균 값을 내는 데이터 샘플 수(=창 길이(window length), L)에 따라 근활성도의 반응성과 신호 대 잡음비(signal to noise ratio, SNR)의 상충이 발생하는 특성을 가진다.¹⁵ 따라서 추정 성능을 결정하는 변수는 각 근육에서 추출된 근전도 신호 평균 값을 내는 데이터 샘플 수와 선형 계수(a_i) 두 가지이며, 각 근전도 신호의 창 길이를 변화시키면서 얻어낸 절대 평균 값을 선형회귀방정식을 이용해 측정치와 상관 계수가 높으면서 식 (4)와 같이 구한 normalized root mean square error(NRMSE) 가 작은 선형 계수 값을

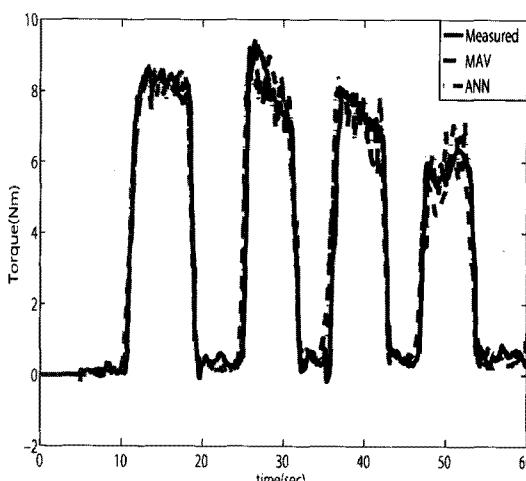


Fig. 4 The torque estimation results. solid, dashed and dotted-dashed line indicate measured torque, estimated torque using MAV with linear regression and ANN, respectively

얻는다. 각 근육의 선형적 가중치를 각 선형계수를 통해 알아볼 수 있으며, 굴곡 토크/각도 추정 시 신전 근육의 기여도 또한 확인할 수 있다.

$$\bar{X}_i = \frac{1}{L} \sum_{k=1}^L |x_{i,k}| \quad (2)$$

$$Y = \sum_{i=1}^n a_i \bar{X}_i \quad (3)$$

$$\text{NRMSE} = \sqrt{\frac{\sum (\mathbf{x}_{1,i} - \mathbf{x}_{2,i})^2}{N(\mathbf{x}_{\max} - \mathbf{x}_{\min})^2}} \quad (4)$$

2.4 실험

23 세 건강한 남자에 대해 등척성 어깨 굴곡 토크와 자유 움직임에서의 각도를 개별적으로 측정하고, 동시에 5 개의 근육에서부터 수집된 근전도 신호를 상기에서 제안한 두 알고리즘에 적용하여 각각을 추정하였다. 어깨 굴곡 토크를 측정하기 위해 그림 2 와 같이 계측장치의 팔 지지부에 피실험자의 상완/하완을 고정하였고, 기계적으로 회전축을 고정시킨 후 등척성 어깨 굴곡 토크를 측정하였다. 또한 각도를 측정함에 있어서 계측장치의 팔 지지부의 무게로 인한 피실험자의 추가적 토크 발생을 방지하기 위해 외란 관측기(disturbance observer, DOB)를 이용한 중력 및 구동기 임피던스 보상 알고리즘을 구현하였다. 피실험자에게 자유롭게 3~5 회 어깨 굴곡을 요구하였으며, 어깨 굴곡 토크 추정을 위한 정적 실험과 각도 추정을 위한 동적 실험을 각 10 회씩 실험하였다.

어깨 굴곡 토크/각도 추정 시 각 근육의 기여도와 최적의 근육 조합을 확인하기 위해 1 개의 굴곡 근육만을 사용할 경우, 3 개의 굴곡 근육을 사용할 경우, 1 개의 굴곡 근육과 1 개의 신전 근육을 사용할 경우, 3 개의 굴곡 근육과 2 개의 신전 근육을 사용할 경우로 나누어 인공 신경망 회로와 선형 회귀방정식을 이용한 절대 평균 값의 두 가지 방법으로 추정 성능을 분석하였다.

3. 결과 및 고찰

그림 4, 5는 MAV 와 ANN 을 이용해 토크/각도

를 추정한 결과를 보여준다. 또한 표 1, 2에 추정 성능을 NRMSE 와 CORR 를 이용하여 정량적으로 분석한 결과를 나타내었다. 우선 토크 추정 결과 MAV 와 ANN 의 두 방법 모두 하나의 굴곡 근육을 사용하여 추정한 경우(1F)보다 측정된 모든 근육을 사용한 경우(3F 2E) 토크/각도 모두 추정 성능이 높아진 것을 확인할 수 있다. 입력 데이터 수가 많아지면 추정 성능이 향상하는 ANN 의 경우에는 입력 데이터 수가 많을수록 추정 성능이 높아지고(1F < 1F 1E < 3F < 3F 2E), MAV 의 경우에는 굴곡/신전 근육 하나씩만 사용한 경우(1F 1E 가 3 개의 굴곡 근육을 사용한 경우(3F)보다 추정 성능이 좋은 것으로 나타나(1F < 3F < 1F 1E < 3F 2E) MAV 방법에서는 신전 근육의 기여도가 큰 것으로 추정할 수 있다. 토크 추정에서 두 방법의 성능은, 1F 1E 경우를 제외하고 ANN 이 조금 더 우수한 추정 성능을 나타냈지만 그 NRMSE 차이가 1% 내외로 크지 않았다. 반면 각도 추정에서는 MAV 와 ANN 모두 신전 근육의 기여도가 높아 1F < 1F 1E < 3F < 3F 2E 순으로 추정 성능을 나타났으며, 모든 경우에 대해 ANN 이 좋은 성능을 나타냈다. 각도 추정에서 MAV 는 under-fitting 되는 현상을 나타냈으며(그림 5), 1F 와 3F 2E 의 NRMSE 차이의 경우 약 3%로 근육 개수가 많아져도 성능향상이 그리 크지 않은 것으로 나타났다. MAV 를 이용하여 각도 추정을 하기에는 추정해야 될 모델의 복

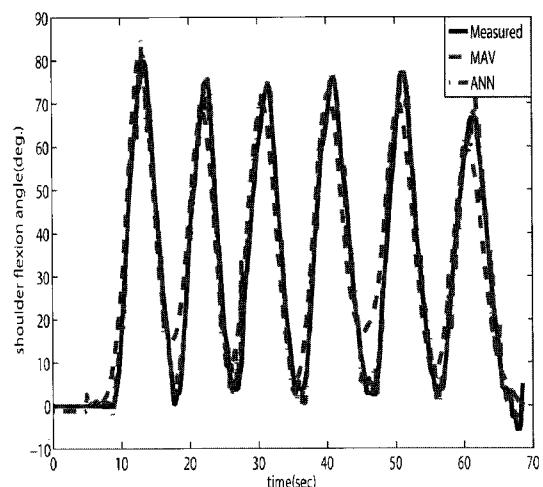


Fig. 5 The angle estimation results. solid, dashed and dotted-dashed line indicate measured angle, estimated angle using MAV with linear regression and ANN, respectively

잡도가 더 크기 때문에 나타나는 현상으로 풀이된다. 같은 맥락으로, ANN 의 경우 구조의 복잡도를 은닉 뉴런과 층의 수를 통해 조절해 주어 under-fitting 현상을 막을 수 있었다. 이를 통해 각도 추정에서는 분명 ANN 의 성능이 우수하다고 판단된다.

Table 1 Estimation performance of shoulder flexion torque using MAV with linear regression and ANN

Muscles	MAV		ANN		
	CORR	NRMSE (%)	CORR	NRMSE (%)	
1F*	A.Del.	0.949 ± 0.015	10.98 ± 1.42	0.964 ± 0.008	10.51 ± 1.41
	Bic.	0.890 ± 0.060	14.62 ± 4.43	0.954 ± 0.019	11.01 ± 2.62
	Cor.	0.896 ± 0.053	14.76 ± 4.64	0.967 ± 0.007	10.96 ± 1.74
3F	A.Del. + Bic. + Cor.	0.955 ± 0.009	8.13 ± 1.47	0.981 ± 0.005	8.09 ± 1.11
1F	A.Del. + P.Del	0.957 ± 0.009	7.91 ± 1.61	0.969 ± 0.005	9.74 ± 1.33
1E	A.Del. + Tri.	0.949 ± 0.015	9.97 ± 1.59	0.970 ± 0.007	9.17 ± 1.71
3F 2E	A.Del. + Bic. + Cor. + P.Del. + Tri.	0.960 ± 0.011	7.31 ± 1.32	0.986 ± 0.005	6.69 ± 1.08

*F : flexion muscle, E : extension muscle

Table 2 Estimation performance of shoulder flexion angle using MAV with linear regression and ANN

Muscles	MAV		ANN	
	CORR	NRMSE (%)	CORR	NRMSE (%)
1F	A.Del.	0.947 ± 0.016	11.65 ± 1.04	0.940 ± 0.010
	Bic.	0.948 ± 0.014	11.86 ± 1.15	0.893 ± 0.018
	Cor.	0.917 ± 0.014	12.74 ± 1.10	0.932 ± 0.009
3F	A.Del. + Bic. + Cor.	0.952 ± 0.011	10.10 ± 1.30	0.964 ± 0.007
1F	A.Del. + P.Del	0.950 ± 0.014	9.01 ± 1.41	0.982 ± 0.002
1E	A.Del. + Tri.	0.947 ± 0.014	9.89 ± 1.36	0.959 ± 0.010
3F	A.Del. + Bic. + Cor. +	0.959 ± 0.011	8.92 ± 0.95	0.992 ± 0.003
2E	P.Del. + Tri.			4.84 ± 0.08

그러나 ANN의 내부 변수들은 학습 데이터에 지배적으로 영향을 받으므로 일반화(generalization)에 취약한 것으로 알려져 있다. 실제로 학습 데이터 이외의 데이터를 입력으로 사용했을 때 일부 모델의 추정 성능이 MAV 이하의 수준으로 떨어지는 것을 확인하였다. 또한 MAV에 비해 상대적으로 더 고주파 대역의 신호가 많아 인간-기계 상호작용에서 직접 모터 입력으로 사용하기 어려움이 있을 것으로 예상된다.

4. 결론

본 연구에서는 표면 근전도 신호로부터 선형 회귀 방정식을 이용한 절대 평균 값 방법과 인공 신경망 회로 방법을 이용하여 어깨 굴곡 시 관절 토크와 각도를 추정하였다. MAV의 경우에는 각도 보다는 토크 추정에서 높은 성능을 나타냈으며, 1 개의 굴곡 근육과 1 개의 신전 근육 신호만으로도 높은 추정 성능을 보였으며, ANN의 경우에는 추정에 사용한 근육의 수가 많을 수록 토크/각도 추정 성능이 향상되는 결과를 나타냈다. 두 방법의 추정 성능 비교에서는 ANN이 앞선 것으로 나타났지만, 일반화에 취약한 것과 상대적으로 고주파의 추정 신호를 갖는다는 단점을 보이기 때문에 실제 인간-기계 상호작용을 위한 의도 추출을 위해서는 추후 신호처리 작업이 필요할 것으로 생각된다.

근전도 신호는 전극 부착 위치에 따라 신호 대 잡음비가 크게 달라지기 때문에 표면 전극의 부착 위치를 결정하는데 상당한 시간이 소요된다. 이 점을 고려하면 신호 처리 알고리즘의 성능 비교와 각각의 알고리즘에 사용하는 최적의 근육 조합을 밝히는 것은 근전도 신호를 이용한 인간-기계 상호작용 분야에서 사용자의 의도 파악에 응용 가능성이 높을 것으로 기대된다.

절대 평균 값 방법과 인공 신경망 회로 방법은 생체 역학적 요소가 고려되지 않고, 단순히 입출력 데이터만 연결해 주는 기능을 하므로 물리적 의미를 갖지 못한다는 한계가 존재한다. 따라서 생체 역학적으로 근육 움직임을 해석할 수 있는 Hill 근육 모델이나 기계적 근육 모델 등을 이용하여 등속성(isokinetic), 등장성(isotonic), 더 나아가 일반적인 신체 거동 예측이 요구될 것이다. 또한 어깨 굴곡 시 구동기를 통해 보조할 수 있는 장비를 통해 인간-기계 상호작용에서의 근전도 신호를 통한 움직임 의도 파악 검증이 수행되어야 할 것이다.

후기

이 논문은 2010년도 정부(교육과학기술부)의 재원으로 한국연구재단-공공복지안전사업의 지원을 받아 수행된 연구임(No. 2010-0020449).

참고문헌

1. Choi, C., Shin M., Kwon, S. and Kim, J., "EMG-based Real-time Finger Force Estimation for Human-Machine Interaction," *J. of KSPE*, Vol. 26, No. 8, pp. 132-141, 2009.
2. Dallon, B. and Matsuoka, Y., "Prosthetics, Exoskeletons, and Rehabilitation - Now and for the Future," *IEEE Robotics & Automation Magazine*, Vol. 14, No. 1, pp. 30-34, 2007.
3. Cipriani, C., Zaccone, F., Micera, S. and Carrozza, M. C., "On the Shared Control of an Emg-Controlled Prosthetic Hand: Analysis of User-Prosthesis Interaction," *IEEE Trans. Robotics*, Vol. 24, No. 1, pp. 170-184, 2008.
4. Artemiadis, P. K. and Kyriakopoulos, K. J., "Emg-Based Teleoperation of a Robot Arm in Planar Catching Movements Using Armax Model and Trajectory Monitoring Techniques," *Proc. IEEE Int. Conf. Robotics and Automation*, pp. 3244-3249, 2006.
5. Cavanagh, P. R. and Komi, P. V., "Electromechanical Delay in Human Skeletal Muscle under Concentric and Eccentric Contractions," *Eur. J. Appl. Physiol. Occup. Physiol.*, Vol. 42, No. 3, pp. 159-163, 1979.
6. Maier, M. A. and Hepp-Reymond, M. C., "Emg Activation Patterns During Force Production in Precision Grip. II. Muscular Synergies in the Spatial and Temporal Domain," *Exp. Brain Res.*, Vol. 103, No. 1, pp. 123-136, 1995.
7. Nagata, K., Ando, K., Magatani, K. and Yamada, M., "Development of the Hand Motion Recognition System Based on Surface Emg Using Suitable Measurement Channels for Pattern Recognition," *Proc. 29th Annu. Int. Conf. IEEE EMBS*, pp. 5214-5217, 2007.
8. Staudenmann, D., Kingma, I., Daffertshofer, A., Stegeman, D. F. and Van Dieen, J. H., "Improving Emg-Based Muscle Force Estimation by Using a High-Density EMG Grid and Principal Component Analysis," *IEEE Trans. Biomed. Eng.*, Vol. 53, No. 4, pp. 712-719, 2006.
9. Mobasser, F., Eklund, J. M. and Hashtrudi-Zaad, K., "Estimation of Elbow-Induced Wrist Force with Emg Signals Using Fast Orthogonal Search," *IEEE Trans. Biomed. Eng.*, Vol. 54, No. 4, pp. 683-693, 2007.
10. Tenore, F., Ramos, A., Fahmy, A., Acharya, S., Etienne-Cummings, R. and Thakor, N. V., "Towards the Control of Individual Fingers of a Prosthetic Hand Using Surface Emg Signals," *Proc. 29th Annu. Int. Conf. IEEE EMBS*, pp. 6145-6148, 2007.
11. Valero-Cuevas, F. J., Zajac, F. E. and Burgar, C. G., "Large Index-Fingertip Forces Are Produced by Subject-Independent Patterns of Muscle Excitation," *J. Biomech.*, Vol. 31, No. 8, pp. 693-703, 1998.
12. Maier, M. A. and Hepp-Reymond, M. C., "Emg Activation Patterns During Force Production in Precision Grip. I. Contribution of 15 Finger Muscles to Isometric Force," *Exp. Brain Res.*, Vol. 103, No. 1, pp. 108-122, 1995.
13. Yoon, W. and Kim, J., "Estimation of elbow flexion force during isometric muscle contraction from mechanomyography and electromyography," *Med. Biol. Eng. Compt.*, Vol. 48, No. 11, pp. 1149-1157, 2010.
14. Yoon, W. and Kim, J., "Feasibility of using an artificial neural network model to estimate the elbow flexion force from mechanomyography," *J. Neuroscience Methods*, Vol. 194, No. 2, pp. 386-393, 2011.
15. Merletti, R. and Parker, P., "Electromyography : physiology, engineering, and noninvasive applications," John Wiley & Sons, 2004.