

근전도 신호를 이용한 퍼지 최대-최소 신경망 기반 보행 단계 분류 방법

A Fuzzy Min-Max Neural Network(FMMNN) Based Gait Phase Classification Method using Electromyography(EMG) Signal

이태엽, Tae-youb Yi*, 이상완, Sang-Wan Lee*, 장효영, Hyoyoung Jang*, 김현희, Heon-Hui Kim**, 정진우, Jin-Woo Jung***, 변중남, Zeungnam Bien*

*한국과학기술원 전자전산학부, **한국과학기술원 인간친화 복지 로봇시스템 연구센터,

***동국대학교 컴퓨터 공학과

요약 최근 삶의 수준의 향상과 의학 기술의 발전으로 노인 인구가 증가하고 있다. 하지만 늘어나는 노인 인구에 비례하여 신체적 노화로 거동이 어려운 노인의 수 또한 증가하는 추세이다. 실제로 많은 노인 인구가 거동이 불편해 정상적인 생활을 하지 못하고 있기 때문에 보행 시 적절한 힘을 보조해 줄 수 있는 보행 보조 장치의 개발이 필요하다. 이 같은 보행 보조 장치를 개발함에 있어 보행자의 보행 패턴이 고려된다면 보행자의 걸음걸이에 맞춰 자연스럽게 힘을 보조해 줄 수 있기 때문에 보행자의 보행 단계 분류에 관한 연구가 선행되어야 한다. 그래서 본 논문에서는 하지 근전도 신호를 이용해 보행 단계를 구분하는 방법을 제안하고자 한다.

근전도 신호는 근육이 움직일 때 발생하는 아주 작은 전기적인 신호이다. 근전도 신호는 작은 잡음에도 민감하며, 전극을 부착하는 근육의 위치에 따라라도 값의 차이가 크기 때문에 근전도 신호의 획득 및 처리 방법이 중요하다. 이를 위해 피실험자 별 근육의 위치와 보행 속도를 달리하여 근전도 신호를 획득하고 획득한 신호로부터 여러 특징 값을 추출한다. 그리고 새로운 데이터에 대해 적응성이 강하고 시간에 따라 변하는 근전도 신호의 특성을 잘 반영할 수 있으며 각 집합(class)의 비선형 분리가 가능한 퍼지 최대-최소 신경망(Fuzzy Min-Max Neural Network: FMMNN)을 이용해 보행 단계를 분류해 본다. 실험 결과를 통해 제안한 방법의 타당성을 검증해 보고 보행자, 보행속도, 근전도 측정용 전극의 위치가 보행 패턴 분류에 미치는 영향을 알아본다.

핵심어: 보행 단계 분류, 근전도, 퍼지최대최소 신경망

1. 서론

최근 삶의 질의 향상과 의학기술의 발전으로 노인 인구는 증가하고 있으며 이와 함께 신체적 노화로 인해 정상적인 보행이 어려운 노인의 수 또한 증가하고 있다. 보행 부자유 노인들의 대부분은 신체적 노화로 인해 보행 시 근육에서 충분한 힘을 내지 못하기 때문이며 이를 위해 근육의 힘을 대신 보조해 줄 수 있는 보행 보조 장치의 개발이 필요하다. 이 같은 보행 보조 장치의 개발을 위해서 보행자의 보행 패턴 분류가 선행되어야 하겠다. 이는 보행자의 보행 패턴을 통해서 각 보행 단계에 필요한 적절한 힘을 보조해 주어 실제 보행자의 걸음걸이를 자연스럽게 해 줌으로써 보다 사용자 친화적인 보행 보조 장치를 개발할 수 있기 때문이다. 그래서 본 논문에서는 하지 근전도 신호로부터 퍼지 최대-최소 신경망을 이용해 보행 패턴을 분류하는 방법을 제안한다. 퍼지 최대-최소 신경망(Fuzz Min-Max Neural Network: FMMNN)은 집합의 비선형 분리가 가능하고

새로운 집합(class)의 추가 시 기존의 집합에 대한 학습 정보를 파괴시키지 않고 계속적으로 학습할 수 있기 때문에 근전도 신호의 시간에 따라 변하는 성질을 잘 반영할 수 있다[4]. 그리고 빠르고 효율적인 구현이 가능하여 실시간 시스템의 구현이 가능하기 때문에 이번 근전도 신호를 이용한 보행 패턴 분류에 적용해 보았다[4]. 또한 근전도 신호는 아주 작은 전기적 신호로 전극의 부착위치나 보행 환경에 영향을 많이 받기 때문에 보행 패턴 분류를 위한 적절한 신호의 취득을 위해 하지 근전도 신호의 취득과정과 특징 추출 과정을 제안한다.

본 논문의 구성은 먼저 2 장에서는 근전도 신호가 무엇인지 알아보고 그리고 근전도 신호의 획득 및 처리방법을 알아본다. 그리고 3 장에서는 보행 단계를 정의하고 퍼지 최대-최소 신경망을 이용하여 보행 패턴을 분류하는 과정을 다룬다. 마지막으로 실험을 통해 보행자의 근전도 측정위치 및 보행속도가 보행패턴에 미치는 영향에 대한 분석 결과를 제시한다.

2. 근전도 신호의 획득 및 처리 방법

2.1 근전도 신호의 획득

근전도(Electromyogram, EMG)는 근육의 수축과 이완 시에 발생하는 전기적 신호이다[1]. 근전도 신호는 수백 μV 에서 수 mV 정도의 작은 신호로 주위의 작은 잡음에도 영향을 많이 받으며, 하나의 운동 단위를 구성하는 근섬유의 수가 사람마다 다르기 때문에 같은 동작에도 근전도 신호의 차이를 보인다[2]. 그리고 근전도 신호는 피부의 두께와 다른 근육 조직에 의해서도 차이를 보이기 때문에 근전도 신호를 획득하기 위해서는 근전도 증폭기의 성능과 측정하려는 근육 및 근육의 위치 선정이 중요하다[2].

2.1.1 근전도 신호 측정을 위한 근육 선정

근전도 신호 측정을 위한 근육 선정을 위해 1980년 이후 발표된 하지 근전도 신호 측정에 관한 53 편의 논문을 참고하여 기존 연구에서 근전도 신호 분석을 위해 선택한 근전도 측정 근육의 선호도를 조사하였다.

Muscles	Preference
① tibialis anterior	5
② rectus femoris	4
③ gastrocnemius	3
④ gluteus maximus	3
⑤ vastus lateralis	2
⑥ gluteus medius	2
⑦ peroneus longus	2
⑧ vastus medialis	2
biceps femoris, long head	2
soleus	2
gastrocnemius medialis	1
gastrocnemius lateralis	1
semitendinosus	1
adductor longus	1
adductor magnus	1
hamstrings	1

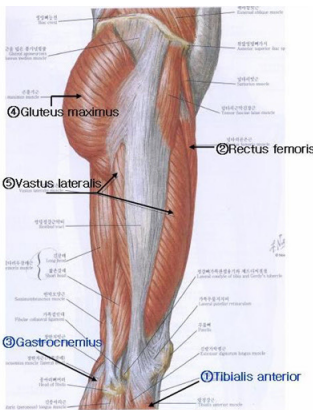


그림 1. 하지 근전도 신호 측정을 위한 근육 선호도[6]

그림 1 에서처럼 앞 정간근(tibialis anterior), 넓다리곧은근(rectus femoris), 장딴지근(gastrocnemius)의 순으로 측정위치가 선호됨을 알 수 있다. 또한 Fleischer의 근전도 신호를 이용한 의도적 행동의 예측에 관한 연구에서 반막양근(semimembranosus)과 내측광근(vastusmedialis)은 보행에 관여하는 근육이며 비교적 깨끗한 신호를 내는 근육이다[3]. 이를 참고하여 본 논문에서는 그림 2 와 같이 넓다리곧은근(rectus femoris), 내측광근(vastus-medialis), 대퇴이두근(Biceps femoris), 반막양근(Semimembranosus)의 4 개의 근육을 근전도 신호 측정을 위한 근육으로 선정하였다.




그림 2. 실험에서 이용한 근육의 위치[6]

2.1.2 근전도 신호의 측정

앞에서 선정한 4 개의 근육에 근전도 측정용 전극을 부착하여 근전도 신호를 측정하였다. 전극을 통해 측정된 근전도 신호는 1360V/V의 증폭도와 전원 잡음을 고려하여 60Hz에서 -32.5dB 의 감쇠를 갖고 23Hz~470Hz의 통과대역을 갖는 근전도 신호 증폭기에 의하여 증폭된다. 증폭된 근전도 신호는 1kHz로 샘플링된 후 근거리 무선통신(Blue-tooth)을 통해 펜티엄 4/2.8GHz의 메인 컴퓨터로 보내진다.

2.2 근전도 신호 처리

보행 단계를 분류하기 위해 앞서 측정된 가공되지 않은 근전도 신호로부터 근전도 신호 처리에 자주 사용되는 아래 14 개의 특징 값을 추출한다. 그리고 각 특징 별 분리도를 측정해 봄으로써 보행 단계를 구분을 위해 사용할 수 있는 특징 값을 선정하였다.

특징 1. 누적 절대값 (Integral of Absolute Value: IAV)

$$IAV = \frac{1}{N} \sum_{i=1}^N |x_i|$$

특징 2. 분산 (Variance: VAR)

$$VAR = \frac{1}{N-1} \sum_{i=1}^N x_i^2$$

특징 3. Wilson 진폭 (Wilson Amplitude: WAMP)

$$WAMP = \sum_{i=1}^N u(|x_i - x_{i+1}| - T),$$

where $u(\cdot)$: 계단함수

특징 4. 영점 교차 (Zero Crossing: ZC)

$$ZC = \sum_{i=1}^N u(-x_i x_{i+1})$$

특징 5. 기울기 변화수 (Number of Turns: NT)

$$NT = \sum_{i=1}^N u\{-(x_i - x_{i+1})(x_{i+1} - x_{i+2})\}$$

특징 6. 진폭의 평균 (Mean of Amplitude: MA)

연속된 두 샘플의 진폭 차이의 평균

특징 7. 파장(Wavelength)

$$W(n) = \sum_{i=n-N+1}^n |x_i - x_{i-1}|$$

특징 8. 평균 주파수(Mean Frequency: MF)

주파수의 평균값

특징 9. 히스토그램(Histogram: HIST)

-5V~5V의 21개 진폭에서의 입력 값에 대한 각 진폭의 샘플수

특징 10. 자동회귀계수(Auto-regressive Coefficient: AR)

현재 신호를 이전 신호들의 선형 결합으로 추정하는데 필요한 계수

특징 11. 3차 누적으로부터의 자동회귀계수(Auto-regressive Coefficient from third-order cumulant: ARCU)

시간영역에서 신호의 3차 누적에 의한 자동 회귀 계수

특징 12. 웨이블릿 계수의 에너지(Energy of wavelet coefficient: EWT)

웨이블릿 변환된 신호의 에너지

특징 13. 웨이블릿 패킷 계수의 에너지(Energy of wavelet packet coefficient: EWP)

EWT와 유사

특징 14. 웨이블릿 계수의 영점 교차(Zero crossing of the wavelet coefficient: ZCWT)

웨이블릿 영역에서의 영점교차 수

위의 여러 특징 값들 중에서 데이터 분포의 흩어진 정도를 평가하는 산재 기준(scattering criterion)을 이용해 각 데이터 집합(class)의 크기 및 집합(class)간의 거리를 구하고 이를 통해 근전도 신호의 분류 정도를 측정하였다. 그 결과 분류도가 높은 특징을 선택하고 그 특징을 보행 패턴 분류를 위한 특징 값으로 선정한다.

데이터 분포의 흩어진 정도를 평가하는 산재 기준(scattering criterion)에는 집합 내부의 흩어진 정도를 나타내는 내부 집합의 산재 행렬(within-class scatter matrix)과 집합끼리의 흩어진 정도를 나타내는 집합간의 산재 행렬(between-class scatter matrix)이 있으며 다음과 같다.

■ 내부 집합의 산재 기준 행렬(within-class scatter matrix)

$$S_w = \frac{1}{N} \sum_{j=1}^C \sum_{i=1}^{N_j} (x_i - m_j)(x_i - m_j)^T$$

- x_i : j 번 집합의 i 번째 샘플 벡터, m_j : j 번째 집합의 중심, N_j : j 번째 집합의 샘플수, N : 전체 샘플수, C : 집합의 수를 나타낸다.

- 모든 집합들의 공분산의 평균을 의미하며 작은 값을 가질수록 주어진 데이터는 분리가 잘 되는 것으로 평가된다.

■ 집합간의 산재 기준 행렬(between-class scatter matrix)

$$S_B = \sum_{j=1}^C \frac{N_j}{N} (m_j - \bar{m})(m_j - \bar{m})^T, \quad \bar{m} = \sum_{j=1}^C m_j$$

- 모든 집합의 평균의 공분산을 의미하며, 큰 값을 가질수록 주어진 데이터는 분리가 잘되는 것으로 평가된다.

■ 전체 산재 기준 (scatter criterion)

$$J = \text{tr}(S_B) / \text{tr}(S_w)$$

- $\text{tr}(S_w)$, $\text{tr}(S_B)$ 는 각각 내부 집합의 산재 기준 행렬(within scatter matrix)과 집합간의 산재 기준 행렬(between scatter matrix)의 대각 값들의 합을 나타낸다.

- 집합간의 산재 기준 행렬(between scatter matrix) 대각 값의 합이 크고 집합 내부의 산재 기준 행렬(within scatter matrix) 대각 값의 합이 작을수록 전체 산재 기준(scattering criterion)의 값은 커지고 그 데이터는 분리가 잘되는 것으로 평가된다.

위의 전체 산재 기준(total scatter criterion)을 이용하여 전극의 부착 위치에 따른 분리도를 측정하였다. 그림 3-1 과 같이 전극의 부착 위치 1 번과 4 번에서의 분리도가 좋았으며, 특징 별로는 그림 3-2 와 같이 1, 2, 3, 9, 12, 13 번 특징의 분리도 평균값들이 높음을 확인하였다. 이중 특징 3 번, 9 번, 12 번의 분리도는 근육의 위치에 따른 편차가 적었다.




그림 3-1 전극의 부착 위치에 따른 분리도 결과




그림 3-2 각 특징 별 분리도의 편차

14 개의 특징 중 전체 산재 기준(total scatter criterion)에 의해 분리도가 좋은 1 번, 2 번, 3 번, 9 번, 12 번, 13 번의 6 개 특징을 선정하였고 이 특징을 3 장에서 보행 단계 분류를 위한 특징 값으로 사용하였다.

3. 근전도 신호를 이용한 보행패턴 분류

3.1 보행 단계 정의

본 논문에서는 사람의 보행 단계를 표 1 과 같이 정지단계를 포함하여 총 9 단계로 정의하였다. 그림 4 에서처럼 발바닥의 앞꿈치와 뒤꿈치에 부착된 압력 센서가 지면과 접촉을 하게 되면 1, 떨어지게 되면 0 으로 정의하였다. 초기 상태 0 은 1111 로 두발 모두가 지면과 접촉한 상태를 의미하고 상태 8 의 1110 는 오른쪽 뒤꿈치만 지면과 떨어지고 나머지는 지면과 접촉한 상태를 의미한다. 그리고 8 단계 후 정지를 하게 되면 상태는 0 으로 돌아가고 계속 걷는 상태가 되면 다음 단계는 1 이 된다.



그림 4 발바닥에 부착된 압력센서

표 1 실험에서 정의한 9 단계의 보행 단계 구분

상태	왼발 앞	왼발 뒤	오른발 앞	오른발 뒤
0 (초기상태)	1	1	1	1
1	1	1	0	0
2	1	1	0	1
3	1	0	0	1
4	1	0	1	1
5	0	0	1	1
6	0	1	1	1
7	0	1	1	0
8	1	1	1	0

0: 지면으로부터 떨어진 상태, 1: 지면과 접촉한 상태

3.2 퍼지 최대-최소 신경망을 이용한 보행 패턴 분류

3.2.1 퍼지 최대-최소 신경망 (Fuzzy Min-Max Neural Network : FMMNN)

퍼지 최대-최소 신경망(FMMNN) 은 그림 5 와 같은 구조를 가지는 지도 학습(supervised learning) 신경망 패턴 분류기이다[4]. 여러 개의 초상자(hyper-box)들의 확장과 중복, 축소를 통해 학습을 하며 각 집합(class)은 퍼지 집합으로 표현되는 초상자의 합집합으로 표현된다. 그리고 초상자(hyper-box)는 그림 6 과 같이 n 차의 최대-최소값에 의하여 결정된다.




그림 5. FMMNN 의 구조




그림 6. 3 차원의 최대 최소값을 갖는 초상자(hyper-box)

퍼지 최대-최소 신경망(FMMNN)은 새로운 데이터에 대해 초상자(hyper box)의 크기를 변화시켜 적응하도록 구성이 되기 때문에 온라인 학습이 가능하고 하나의 집합(Class)에 대하여 여러 개의 초상자(hyper-box)를 잡을 수 있어서 비선형 분리가 가능하다[4][5]. 그리고 빠르고 효율적인 구현이 가능하기 때문에 실시간 시스템에 구현이 가능하다 [4]. 그래서 본 논문에서는 근전도 신호의 시간에 따라 변하는 성질을 잘 반영하고 비 선형적인 특징을 잘 분류할 수 있는 퍼지 최대-최소 신경망(FMMNN)을 이용하여 보행 패턴을 분류하였다.




그림 7. FMMNN 을 이용한 두 클래스의 구분[4]

그림 7 은 퍼지 최대-최소 신경망(FMMNN)을 이용한 두 클래스의 구분을 보여주며 초상자(hyper-box)들의 확장, 중복, 축소에 의해 두 클래스를 비 선형적으로 분리할 수 있다.

3.2.2 FMMNN 를 이용한 보행 패턴 분류기의 설계

퍼지 최대-최소 신경망(FMMNN)은 초상자(hyper-box)들의 확장, 중복, 축소과정을 거치면서 학습을 하게 된다. 학습 과정에서는 초상자(hyper-box)가 확장될 수 있는지를 확인하고, 확장될 수 있는 초상자(hyper-box)가 없다면 새로운 초상자(hyper-box)를 생성한다. 그리고 중복 테스트를 통해 다른 클래스와 겹침을 확인한 후 겹침이 있다면 축소과정을 통해 각 초상자(hyper-box)를 최소로 변화시키면서 초상자(hyper-box)를 축소시킨다.

학습 과정에서는 초상자가 확장되기 위한 최소값을 의미하는 아래의 확장기준(expansion criterion)과

$$\theta \geq \sum_{i=1}^N (\max(w_{ji}, x_{hi}) - \min(v_{ji}, x_{hi})) / n$$

소속함수의 감소 정도를 나타내는 민감도 계수(sensitivity parameter) γ 를 변화시킴으로써 적절한 패턴분류기를 설계할 수 있다.

이번 보행 패턴 분류에서는 학습 시 전체 초상자(hyper-box)의 수는 300 개로 제한하였고 민감도 계수(sensitivity parameter) γ 는 3 을 사용하였다. 그리고 확장기준(expansion criterion)은 0.004 로 설정하였다.

3.2.3 FMMNN 를 이용한 보행 패턴 분류 실험

퍼지 최대-최소신경망(FMMNN)을 이용한 보행 패턴 분류 테스트에서는 3 명의 피실험자를 대상으로 1km/h 와 2km/h 속도에서 4 개의 근전도 측정위치에 따라 근전도 신호를 취득하였으며, 취득한 근전도 신호로부터 2 장에서 선정한 9 개 특징 값들을 추출하였다. 그리고 추출된 특징 값을 이용하여 3.2.2 에서 설계한 퍼지 최대-최소 신경망(FMMNN)으로 학습과 테스트를 하여 다음과 같은 결과를 얻었다.

표 2. 피실험자 1 의 인식률 결과(%)

	속도 1 km/h				속도 2 km/h			
	위치1	위치2	위치3	위치4	위치1	위치2	위치3	위치4
특징 1	61.49	56.90	58.29	58.70	92.68	65.93	85.54	91.13
특징 2	56.83	47.25	42.70	60.55	91.46	54.65	80.72	89.04
특징 3	52.63	50.78	48.63	52.54	86.07	42.66	72.41	81.01
특징 9	68.52	67.00	64.46	61.42	90	70.11	84.53	78.31
특징 12	60.71	53.19	56.5	55.67	86.51	67.39	83.33	90
특징 13	51.5	44.79	53.76	39	88.23	52.52	77.17	86.74
특징 1&9	75.98	73.22	69.49	66.14	93.67	82.05	97.53	94.67
특징 1&12	72.63	64.48	59.32	65.08	93.67	82.05	92.59	92
특징 1&13	66.48	61.2	62.72	62.43	92.41	78.21	92.59	89.33




그림 8-1 피실험자 1 의 속도 1에서의 인식률 결과




그림 8-2 피실험자 1 의 속도 2에서의 인식률 결과

표 2 는 피실험자 1 의 속도 1km/h 와 2km/h 에서의 보행 패턴 인식 결과를 보여준다. 그리고 그림 8-1 과 그림 8-2 는 인식 결과를 그래프로 나타내었다. 속도 2km/h 에서의 인식률이 속도 1km/h 에서의 인식률 보다 좀 더 높게 나왔다. 그리고 전극의 부착위치 1 번이 전체적으로 높은 인식률을 보였으며 여러 특징들 중에서는 특징 1 번과 9 번의 조합이 높은 인식결과를 보였다.

다음은 피실험자 2 에 대한 결과이다.

표 3. 피실험자 2 의 인식률 결과(%)

	속도 1 km/h				속도 2 km/h			
	위치1	위치2	위치3	위치4	위치1	위치2	위치3	위치4
특징 1	84.35	83.45	51.76	85.59	97	92.92	67.81	78.21
특징 2	77.69	69.17	44.70	56.41	91.11	91.95	70	69.29
특징 3	81.74	61.15	59.52	70	93.33	91.48	69.33	84.04
특징 9	81.48	77.70	66.32	83.60	97.05	96.11	80.48	91.91
특징 12	79.56	76.15	67.77	71.01	92.78	90	86.04	87.61
특징 13	63.81	53.29	32.38	37.20	96.11	90.52	64.19	66.94
특징 1&9	87.97	86.67	67.39	87.5	100	98.86	88	95.83
특징 1&12	85.71	86.67	70.65	85.83	98.88	96.59	93.33	91.67
특징 1&13	84.96	87.41	64.13	88.33	98.88	97.72	90.67	93.75




그림 9-1 피실험자 2 의 속도 1에서의 인식률 결과




그림 9-2 피실험자 2 의 속도 2에서의 인식률 결과

피실험자 2 의 결과에서도 피실험자 1 에서처럼 속도 2km/h 에서 높은 인식률을 보이고, 전극의 부착 위치 1 에서 고른 인식률을 보였다. 그리고 특징 1 번과 9 번의 조합이 다른 특징들에 비해 높은 인식결과를 보였다.

마지막으로 피실험자 3 에 대한 결과를 표 4 와 그림 10-1, 그림 10-2 를 통해 확인할 수 있다. 전체적으로 앞의 피실험자들과 비슷한 결과를 보이고 있으나 피실험자 3 의 경우 전극의 부착 위치 3 번에서의 인식률 결과가 부착 위치 1 번 보다 더 높은 인식 결과를 보여 조금의 차이를 보였다.

표 4. 피실험자 3의 인식을 결과(%)

	속도 1 km/h				속도 2 km/h			
	위치1	위치2	위치3	위치4	위치1	위치2	위치3	위치4
특징 1	43.97	54.86	69.50	69.59	90.76	71.87	86.36	76.56
특징 2	25.15	51.47	60.43	54.72	76.66	65.62	92.18	72.22
특징 3	60.36	53.42	41.98	43.50	73.46	66	87.93	46.95
특징 9	72.22	57.33	59.28	77.5	90.32	82.81	92.64	87.30
특징 12	66.86	46.80	55.86	51.11	80.64	75	90.32	80.32
특징 13	59.60	53.65	51.35	46.36	75	75.86	92.85	86.15
특징 1&9	73.08	67.41	77.69	78.95	96.72	89.9	96.67	92.85
특징 1&12	75	59.26	71.54	64.47	88.52	89.83	95	83.33
특징 1&13	69.87	59.26	70.77	61.18	88.52	88.14	96.67	86.67




그림 10-1 피실험자 3의 속도 1에서의 인식을 결과




그림 10-2 피실험자 3의 속도 2에서의 인식을 결과

3.2.4 결과 분석

하지 근전도 신호를 피실험자 별 근육의 위치와 보행 속도를 달리하여 측정하여 보았다. 그리고 측정된 근전도 신호로부터 14 개의 특징 중 산재 기준(scatter criterion)을 이용하여 분리도가 좋은 6 개의 특징과 3 개의 조합된 특징을 선택하였다. 선택된 특징 값을 퍼지 최대-최소 신경망을 이용하여 각 조건 별 보행 패턴 인식 정도를 테스트 해 보았다. 실험 결과에서 볼 수 있듯이 근육의 위치 별로는 1 번 위치가 평균적으로 높은 인식률을 보였고, 3 번과 4 번 위치가 인식률이 가장 낮았던 2 번 위치 보다 다소 나은 인식결과를 보였다. 그리고 속도에 따른 인식률을 보았을 때 속도 2km/h 에서의 인식률이 속도 1km/h 보다 높은 결과를 보였다. 선정된 6 개의 특징 값과 3 개의 조합된 특징 값들 중에서는 특징 1 번과 9 번의 조합이 다른 특징 값들에 비해 높은 인식 결과를 보였다. 피실험자 별로는 약간씩의 차이를 보였지만 속도 2km/h, 근육 위치 1 에서 특징 1 번과 9 번의 조합을 이용했을 때 평균 96%정도의 인식 결과를 보임을 확인했다. 이를 통해 근전도 신호로부터 보행 단계를 인식하기 위해서는 넓다리 곧은근(rectus femoris), 내측광근(vastus-medialis), 대퇴이두근(Biceps femoris), 반막양근(Semime-mbranosus)의 4 개 근육의 1 번 위치를 이용하는 것이 좋은 결과를 얻을 수 있고, 1km/h 의 속도

보다 2km/h 의 속도에서 더 나은 결과를 얻을 수 있겠다. 그리고 특징 1 번과 9 번의 조합을 이용하여 보다 높은 인식결과를 얻을 수 있었다.

4. 결론 및 추후 과제

지금까지 근전도 신호 측정을 위한 근육의 위치 선정 과정 및 보행 패턴 분류를 위한 특징 추출과정을 살펴보았다. 그리고 선정된 특징 값으로부터 퍼지 최대-최소 신경망을 이용해 보행 단계를 분류하여 보았다. 실험 결과를 통해 제안한 방법의 타당성을 검증해 보았고, 근전도 신호라는 불안정적이고 외부 잡음에 민감한 신호로부터 보행 단계를 구분할 수 있었다.

하지 근전도 신호를 이용한 보행 단계 구분이 보행 보조 장치에서 이용된다면 사용자의 보행 패턴을 고려할 수 있어서 보다 사용자 친화적인 보행 보조 장치를 만들 수 있으며, 또한 근전도라는 생체신호를 이용하기 때문에 사용자의 거부감을 줄일 수 있다고 생각된다.

그러나 보행 단계 분류에 관한 연구가 보행 보조 장치에 활용되기 위해서는 보행자의 안전이 우선시 되어야 한다. 이를 위해 앞으로 더 높은 인식 결과를 낼 수 있는 연구가 진행되어야 하겠다. 그리고 사람마다의 다양한 보행 속도를 고려하여 여러 속도에서의 실험이 필요하고 실험 결과의 일반성을 갖기 위해 더 많은 피실험자를 대상으로 한 실험이 진행 되어야 하겠다.

감사의 글

본 연구는 유도 실업주의 지원을 받아 수행되었음.

참고문헌

- [1] John V. Basmajian and Carlo J. De Luca, "Muscles Alive", Williams & Sons, fifth edition 1985.
- [2] Daisuke NISHIKAWA, Wenwei YU, Hiroshi YOKOI, and Yukinori KAKAZU, "EMG Prosthetic Hand Controller Discriminating Ten Motions using Real-time Learning Method", IROS'99, vol. 3, pp.1592-1597, Kyungju, Korea, 1999.
- [3] Christian Fleischer, Christian Reinicke, Gunter Hommel, "Predicting the Inteded Motion with EMG Signals for an Exoskeleton Orthosis Controller.", IROS 2005, pp.2029-2034, 2005.
- [4] Song, Jae-Hoon, "Design of Robust EMG Pattern Classifier to Muscular Fatigue Effects: Adaptation of FMMNN to Time-varying Features", Master's Thesis of EE dept. KAIST, 2006
- [5] Simpson, P.K, "Fuzzy min-max neural networks," Neural Networks IEEE International Joint conferece 1991. vol.2, pp.1658-1669, 1991.

[6] Frank H. Netter, "Atlas of Human Anatomy",
Second Edition, NOVARTIS.