

sEMG 기반 계단 보행 인식 가능성

김재훈*, 김정훈*, 최상일*

*대구가톨릭대학교 컴퓨터소프트웨어학부

e-mail:kjh3505@cu.ac.kr, fainal2@cu.ac.kr, sangilchoi@cu.ac.kr

sEMG-Based Stair Walk Recognition Possibility

Jae-Hun Kim*, Jung-Hun Kim*, Sang-Il Choi*

*School of Computer Software, Daegu Catholic University

요약

본 연구는 표면 근전도(sEMG)만으로 계단 오르기와 내리기 동작을 안정적으로 인식할 수 있는지를 확인하였다. 이를 위해 제곱평균제곱근을 활용한 Machine Learning과 단시간 푸리에 변환(STFT)으로 생성한 스펙트로그램을 입력으로 하는 Deep Learning 분류기를 체계적인 실험 설계와 평가 지표로 비교하여 공정성과 일관성을 확보하였다. 건강한 성인 6명으로부터 수집한 sEMG 신호에 60 Hz 노치 필터와 20-500 Hz 대역통과 필터를 적용해 신호 품질을 개선한 뒤, 본 연구에서 정의한 1계단 단위로 수집한 신호를 분할하였다. 분할된 신호를 활용하여 Machine Learning에는 제곱평균제곱근 특징을, 딥러닝에는 STFT 스펙트로그램을 활용하여 특징을 산출하고 각각 입력으로 사용하였다. 테스트 평가 결과, Deep Learning 분류기가 전반적으로 우수했으며 ResNet-18이 0.98, Inception-v3가 0.92 F1-score를 기록했고, Machine Learning에서는 MLP 0.87, SVM 0.74 F1-score를 보였다. 결론적으로 sEMG를 기반으로 계단 보행 인식은 가능하며, STFT 기반 딥러닝 접근이 높은 정확도와 안정적인 성능을 제공함을 확인하였다.

1. 서론

고강도 및 반복적인 작업은 근골격계 질환의 증가로 이어지며, 이는 작업자의 안전과 생산성에 심각한 영향을 미친다. [1] 산업 현장에서의 재해를 예방하고 작업자의 안전을 확보하는 것이 중요해짐에 따라, 웨어러블 보조 로봇의 도입 필요성이 점차 증가하고 있다. [2, 3] 기존 웨어러블 로봇은 사전에 정의된 알고리즘에 의존하며, 동작 전환 시 부자연스러움이 발생할 수 있다. 이는 다양한 동작 전환에서는 한계가 있음을 시사한다. [4] 이러한 한계를 극복하기 위해 근육 활성 패턴을 실시간으로 감지할 수 있는 표면 근전도(Surface Electromyography, sEMG) 신호의 활용이 주목받고 있다. [5] sEMG 신호는 사용자의 신경근 활동을 직접 반영하여 사용자의 의도인식 가능성을 높이며, 이를 통해 더욱 자연스러운 로봇 제어를 가능하게 한다. [6]

특히 일상 생활 및 산업 현장에서 빈번히 발생하는 계단 보행은 평지 보행과 비교할 때 더 높은 근력을 요구하며, 동작 단계가 복잡하게 구성되어 있어 안전 확보가 중요한 과제이다. [7, 8] 따라서 sEMG 기반 계단 보행 인식은 평지 보행 인식에 비해 더 높은 난이도를 가지는 동시에, 복잡한 동작 전환을 정밀하게 인식

할 수 있다는 점에서 학술적, 산업적 가치가 크다. [9]

이러한 접근은 산업 현장에서의 보조 로봇 제어 성능을 한층 향상시키며, 안정성과 적응성을 동시에 보장할 수 있다. [10] 더 나아가, 본 연구에서 다루는 sEMG 기반 계단 보행 인식 기술은 산업용 웨어러블 로봇뿐 아니라 재활 로봇, 착용형 보조기술, 산업 안전 기술과 같은 다양한 분야에 폭넓게 응용될 잠재력을 가진다. [11]

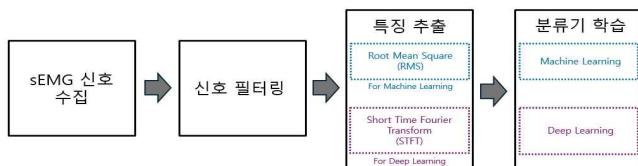
이에 본 연구는 sEMG 신호 기반 계단 보행 인식을 목적으로 신호 수집, 필터링, 특징 추출, 그리고 머신러닝(Machine Learning, ML)과 딥러닝(Deep Learning, DL) 분류기 학습의 전 과정을 체계화하여 진행하였으며, 이를 통해 sEMG 기반 계단 보행 인식의 가능성을 제시한다.

2. 연구 방법

2.1 연구 절차

연구 순서는 그림 1의 연구 순서도에 따라 체계적으로 진행되었으며, 총 네 단계로 구성되었다. 첫째, sEMG 신호를 수집하였다. 둘째, 수집한 신호의 신뢰도를 높이기 위해 필터링을 수행하

였다. 셋째, 필터링된 신호로부터 제곱평균제곱근(Root Mean Square, RMS) 또는 단시간 푸리에 변환(Short-Time Fourier Transform, STFT)을 활용해 특징을 추출하였다. 넷째, 추출된 특징을 ML 또는 DL 분류기에 입력하여 학습 및 평가를 진행함으로써 sEMG 기반 계단 보행 인식 가능성을 확인하였다.



[그림 1] 연구 진행 순서도

2.2 sEMG 신호 수집

이 연구에 사용된 데이터는 윤리 지침(IRB 번호: KNUH 2025)에 따라 경북대학교병원 기관심사위원회(IRB)의 승인을 받은 후 수집되었다.

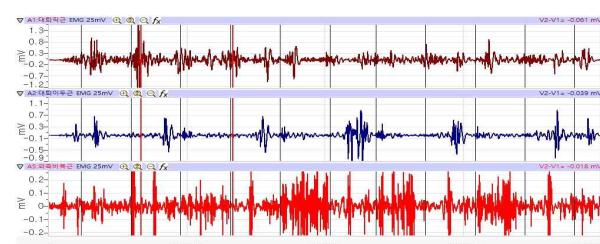
sEMG 신호 획득을 위해 계단 보행에 핵심적으로 관여하는 대퇴직근(Rectus Femoris, RF), 대퇴이두근(Biceps Femoris, BF), 외측비복근(Lateral Gastrocnemius, LG) 총 3개의 하지 근육에 전극을 부착하였다. 계단 보행은 족관절과 슬관절, 고관절의 복합 운동을 요구하며, 선정한 근육들은 각 관절의 굴곡과 신전 과정에서 중요한 기여를 한다. 실험의 일관성을 확보하기 위해 모든 참가자는 동일한 실내 계단 환경(Riser: 18cm, Tread: 29cm)에서 보행하였고, 보행 속도는 메트로놈 120 bpm에 맞춰 1초당 1계단의 속도로 표준화하였다. 이를 통해 피험자 간 속도 차이에 따른 시간축 불균형을 최소화하고 근활성 신호 분포의 변동성을 줄이기 위해 설정하였다. 계단 보행 과제는 계단 오르기와 내리기의 두 유형으로 구성되었으며, 각 보행 과제는 10계단을 1세트로 정의해 각 보행마다 10세트를 수행하였다. 모든 세트는 오른발을 선행으로 시작하도록 지정하였다.



[그림 2] sEMG 전극 패치 부착 위치 : (a)는 앞면, (b)는 후면

계단 보행에는 건강한 성인 6명(남 4명, 여 2명)이 참여했으며, 모든 참가자는 평소 계단 보행에 문제가 없음을 보고하였다. 모

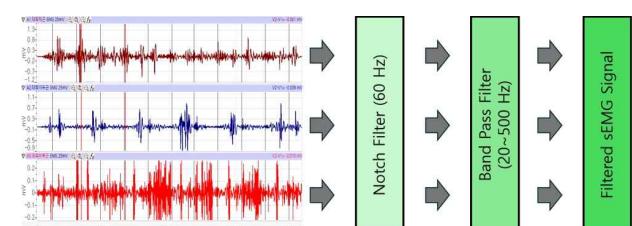
든 참가자는 오른쪽 다리에 대해 그림 2와 동일한 위치에 sEMG 전극 패치를 부착하였고, 신호 수집에는 iWorx사의 IX-BIO 8채널 시스템을 사용하였으며, Sampling Rate는 1000Hz로 설정하였다. 또한 그림 3과 같이 LabScribe 소프트웨어로 세개 근육의 sEMG 수집 과정을 실시간 모니터링하여 신호의 안정성과 품질을 상시 확인함으로써 sEMG 데이터의 신뢰성을 확보하였다.



[그림 3] LabScribe를 활용한 sEMG 신호 실시간 모니터링

2.3 신호 필터링

sEMG 신호는 피부 표면에 전극 패치를 부착해 수집하는 특성상 주변 환경 요소 간섭에 의해 노이즈가 유입되어 신호 정보가 희석될 수 있다. 이를 보완하기 위해, 본 연구에서는 수집된 모든 sEMG 신호에 동일한 필터링 절차를 적용하여 노이즈를 저감하고 신호 품질을 확보하였다.



[그림 4] sEMG 신호 필터링 순서도

필터링은 먼저 60 Hz 노치 필터로 전력선 간섭을 제거하고, 이어 sEMG의 생리적 유효 대역을 보존하기 위해 20~500 Hz 대역통과 필터를 적용하였다. 전체 필터링 과정은 그림 4의 순서도와 같다.

2.4 특징 추출

2.4.1 Machine Learning을 위한 특징 추출

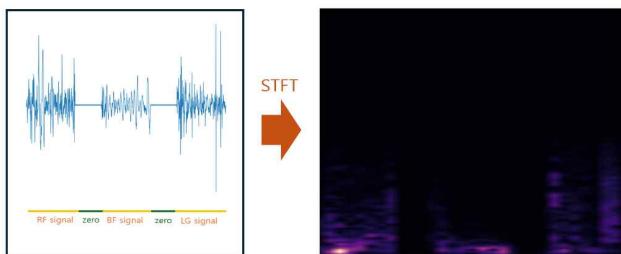
필터링을 마친 sEMG 신호는 피험자 간 진폭 차이를 보정하기 위해 수식 1의 변수 x 에 시간축의 mV 값을 순차 대입하여 Min-Max 정규화를 수행하였다. 이를 통해 모든 피험자의 신호가 동일한 진폭 범위로 스케일링(Scaling)되었다. 이후 보행 설정에 따라 신호를 1계단 단위로 분할하고, 각 분절의 오르기와 내리기

구간에 대해 수식 2를 적용하여 해당 1계단 구간의 RMS를 계산하였다. RMS는 구간 내 신호 제곱값의 평균에 제곱근을 취한 값으로, 구간 동안의 평균 진폭 크기를 나타낸다. 이를 통해 각 계단 구간에서의 균활성도를 정량화하고 특징으로 추출하였다. 이 절차는 세 근육에 동일하게 적용되었으며, 동일 시간대에 해당하는 세 근육의 RMS 값을 결합해 하나의 특징 벡터를 구성하였다. 마지막으로 각 벡터에 계단 오르기 또는 내리기 라벨을 부여하여 ML 분류기의 입력으로 사용하였다.

$$x_{scaled} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

$$RMS = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \quad (2)$$

2.4.2 Deep Learning을 위한 특징 추출



[그림 5] STFT를 활용한 시간-주파수 특징 추출 과정

Deep Learning 분류기 학습을 위해, 그림 5와 같이 필터링된 sEMG 신호를 보행 설정에 따라 1계단 단위로 분할한 뒤 각 근육의 세그먼트를 샘플 축 기준으로 순차 연결하고 근육 경계마다 0 값을 500샘플 삽입해 경계 간 시간-주파수 간섭을 완화하였다. 연결 신호에 SciPy의 `stft`를 적용하여 윈도우 크기 256샘플, 50% 중첩으로 2D 스펙트로그램을 산출하였다. 산출된 스펙트로그램의 모든 시간-주파수 성분 진폭은 수식 3에 따라 정규화했으며, 여기서 Max(Amplitude)는 해당 스펙트로그램 전 영역의 최대값으로 정의하여 피험자 간 진폭 범위를 보정하였다. 마지막으로 정규화된 특징을 가로 128, 세로 128, 채널 1의 텐서(Tensor)로 저장하고, 계단 오르기 또는 내리기 라벨을 부여해 CNN 기반 DL 분류기의 최종 입력으로 사용하였다.

$$Normalized Amplitude = \frac{Amplitude}{Max(Amplitude)} \quad (3)$$

2.5 분류기 학습

2.5.1 Machine Learning 분류기

Machine Learning 분류기 학습에는 서포트벡터 머신(Support Vector Machine, SVM)과 다층 퍼셉트론(Multi-Layer Perception, MLP)을 사용하였다. SVM은 RBF커널을 활용하여 학습을 진행하였고, MLP는 100개의 뉴런으로 되어 있는 은닉층 두개를 구성하고 ReLU 활성화 함수를 설정하여 학습을 진행하였다. 두 Machine Learning 분류기는 사이킷런(Scikit-Learn) 라이브러리를 활용하여 구현되었다.

2.5.2 Deep Learning 분류기

Deep Learning 분류기는 CNN 기반 모델을 채택하여 합성곱층으로 시간-주파수 특성을 학습하도록 설계하였다. Inception-v3와 ResNet-18을 사용하였고, 두 모델 모두 STFT 스펙트로그램의 단일 채널 입력에 맞게 첫 합성곱 계층을 1채널 입력으로 수정하였으며, 최종 분류 계층을 2개 클래스로 재구성해 계단 오르기와 내리기를 판별하도록 하였다. 학습 설정은 두 분류기 모두 Batch Size 32로 통일하였고, Inception-v3는 15 Epoch, ResNet-18은 10 Epoch로 구성하였다. 모든 Deep Learning 모델은 PyTorch로 구현하였다.

3. 학습 결과

본 연구에서는 세 근육의 1계단 단위 신호 세그먼트(Segment)에서 RMS와 STFT 기반 특징 추출을 통해 총 6480개의 특징들이 추출되었다. 해당 특징들은 동일한 시간을 기준으로 결합한 뒤, 학습 80% 테스트 20%로 분할되었으며, 각 분류기의 학습과 평가에 활용되었다. 각 분류기의 분류 성능을 평가하기 위해서 F1-score를 통해 각 모델에 대한 분류 성능을 객관적으로 평가하였으며 수식 4를 통해 계산되었다. 수식 4에서 Precision과 Recall은 수식 5와 6을 통해 계산되었으며, 각 공식의 TP, FP, FN은 True Positive(TP), False Positive(FP), False Negative(FN)를 의미한다.

$$F1-score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (4)$$

$$Precision = \frac{TP}{TP + FP} \quad (5)$$

$$Recall = \frac{TP}{TP + FN} \quad (6)$$

[그림 6] 분류기별 평가지표 막대그래프

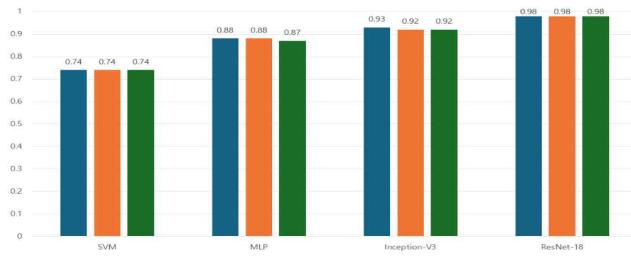


그림 6은 각 Machine Learning과 Deep Learning 분류기의 Precision, Recall, F1-score를 막대그래프로 시각화한 것이다. 테스트 평가에서 SVM과 MLP의 F1-score는 각각 0.74와 0.87이었고, Inception-v3와 ResNet-18은 각각 0.92와 0.98을 기록하였다.

4. 결론

본 연구는 sEMG 신호를 체계적으로 전처리한 뒤 Machine Learning과 Deep Learning 분류기를 학습하고 동일한 평가 지표로 평가하여, 계단 오르기와 내리기 인식 성능과 sEMG 기반 보행 인식의 가능성을 확인하였다. 연구 결과를 분석한 결과, RMS 특성을 활용한 Machine Learning 대비 STFT 기반 Deep Learning이 전반적으로 더 높은 정확도를 보였고, 이에 따라 STFT 기반 Deep Learning 분류기의 적용이 계단 오르기와 내리기 인식의 안정성 향상에 유의미하게 기여함을 확인하였다. 종합하면, STFT 기반 DL 분류기는 경쟁력 있는 성능을 제시하며, sEMG를 활용한 계단 보행 인식이 충분한 잠재력과 응용 가능성을 지님을 시사한다.

본 결과물은 2025년도 교육부의 재원으로 경상북도 지역혁신 중심 대학지원체계(RISE)–(로컬 맞춤형 R&D)의 지원을 받아 수행된 결과입니다.

참고문헌

- [1] Jacquier-Bret, J., & Gorce, P. (2023). Prevalence of Body Area Work-Related Musculoskeletal Disorders among Healthcare Professionals: A Systematic Review. *International Journal of Environmental Research and Public Health*, 20(1), 841. <https://doi.org/10.3390/ijerph20010841>
- [2] FLECHTNER, Rahel; LORENZ, Katharina; JOOST, Gesche. Designing a wearable soft-robotic orthosis: a body-centered approach. In: Proceedings of the Fourteenth International Conference on Tangible, Embedded, and Embodied Interaction. 2020. p. 863–875.
- [3] VAN DER VORM, Johan; NUGENT, Rachel;

O'SULLIVAN, Leonard. Safety and risk management in designing for the lifecycle of an exoskeleton: a novel process developed in the robo-mate project. *Procedia Manufacturing*, 2015, 3: 1410–1417.

- [4] YANG, Xiaolong, et al. Spine-inspired continuum soft exoskeleton for stoop lifting assistance. *IEEE Robotics and Automation Letters*, 2019, 4.4: 4547–4554.
- [5] WANG, Shudi, et al. Improved multi-stream convolutional block attention module for sEMG-based gesture recognition. *Frontiers in Bioengineering and Biotechnology*, 2022, 10: 909023.
- [6] SONG, Tao, et al. Review of sEMG for robot control: Techniques and applications. *Applied Sciences*, 2023, 13.17: 9546.
- [7] BAE, T. S.; CHOI, K.; MUN, M. Level walking and stair climbing gait in above-knee amputees. *Journal of medical engineering & technology*, 2009, 33.2: 130–135.
- [8] HARPER, Nicole G.; WILKEN, Jason M.; NEPTUNE, Richard R. Muscle contributions to balance control during amputee and nonamputee stair ascent. *Journal of biomechanical engineering*, 2020, 142.12: 121007.
- [9] ZHANG, Li, et al. sEMG based human motion intention recognition. *Journal of Robotics*, 2019, 2019.1: 3679174.
- [10] PROIA, Silvia, et al. Control techniques for safe, ergonomic, and efficient human–robot collaboration in the digital industry: A survey. *IEEE Transactions on Automation Science and Engineering*, 2021, 19.3: 1798–1819.
- [11] XU, Hao; XIONG, Anbin. Advances and disturbances in sEMG-based intentions and movements recognition: A review. *IEEE Sensors Journal*, 2021, 21.12: 13019–13028.