Master's Thesis

Motion Effect Synthesis and Reduction Method Based on Human Walking Motion

Hyoseung Lee (이 효 승)

Department of Computer Science and Engineering

Pohang University of Science and Technology

2021

인간 보행 운동 기반 모션 효과 생성 및 축약 방법

Motion Effect Synthesis and Reduction Method Based on Human Walking Motion

Motion Effect Synthesis and Reduction Method Based on Human Walking Motion

by

Hyoseung Lee
Department of Computer Science and Engineering
Pohang University of Science and Technology

A thesis submitted to the faculty of the Pohang University of Science and Technology in partial fulfillment of the requirements for the degree of Master of Science in the Computer Science and Engineering

Pohang, Korea
11. 27. 2020
Approved by
Seungmoon Choi
Academic advisor

Motion Effect Synthesis and Reduction Method Based on Human Walking Motion

Hyoseung Lee

The undersigned have examined this thesis and hereby certify that it is worthy of acceptance for a master's degree from POSTECH

11. 27. 2020

Committee Chair Seungmoon Choi

Member Sunghyun Cho

Member Keehoon Kim

MCSE 이 효 승. Hyoseung Lee
20182540
Motion Effect Synthesis and Reduction Method Based on Human Walking Motion,
인간 보행 운동 기반 모션 효과 생성 및 축약 방법
Department of Computer Science and Engineering , 2021, 57p, Advisor : Seungmoon Choi.

ABSTRACT

In this thesis, a synthesis algorithm for a gait motion effect and a reduction method for the motion effect are proposed. The synthesis algorithm transforms gait motion data into a representative single cycle gait motion effect through 5 processes: Data collection, motion effect synthesis, segmentation, averaging, and dimension reduction. The motion effects generated by the algorithm were highly evaluated for expressiveness and activeness in the user study. The reduction method uses PCA to express complex a gait motion effect as a vector of length 6 with principal components. We confirmed through the user experiment that the motion effect reduction does not cause significant loss of perceptual characteristics and that a mathematical space consisting of the principal components can explain the characteristics of the gait motion effects.

목 차

표 목 차 IV
그 림 목 차 V

I. 서론 1

II. 관련 연구 4
2.1 데이터 기반 물리 효과 생성 연구 4
2.2 모션 효과 저작 관련 연구 4
2.3 보행 동작 표현 연구 5

III. 인간 보행 운동 정보 기반 보행 모션 효과 생성 7
3.1 보행 모션 효과 생성 방법 7
3.1.1 데이터 수집 7
3.1.2 모션 효과 변환 과정 9
3.1.3 분할 과정 12
3.1.4 평균 과정 16
3.1.5 차원 축소 19
3.2 사용자 평가 실험 22
3.2.1 실험 목적 22
3.2.2 실험 참여자 22
3.2.3 실험 장비 22
3.2.4 실험 방법 23
3.2.5 실험 결과 26
3.2.6 토의 30
3.2.7 결론 31

IV. 보행 동작 효과 공간 기반 보행 동작 효과 생성 32
4.1 보행 동작 효과 dataset 수집 32
4.2 보행 동작 효과 공간 생성 33
4.3 사용자 평가 실험 41

4.3.1 실험 참여자 41
4.3.2 실험 방법 41
4.3.3 실험 자극 42
4.3.4 실험 결과 46
4.3.5 토의 48
4.3.6 결론 49

V. 결론 51

참 고 문 헌 52

표 목 차

3.1 AHRS 모션 센서 EBIMU-9DOFV5, XA3300 성능표 23

3.2 측정 부위별 생성 보행 모션 효과 scaling 비율의 평균 및 표준편차 . 30

4.1 추출된 성분별 분산 설명 비율 37

4.2 원본 보행 모션 효과의 p-p 진폭 및 PCA 주성분을 통한 근사 모션 효과의 RMSE 39

4.3 보행 유형에 따른 주성분 계수 분포에 대한 ANOVA test 결과 40

4.4 모션 효과 분류 정밀도 46

4.5 오리걸음과 발 구르며 뛰기 병합 후 모션 효과 분류 정밀도 48

그 림 목 차

1.1 4D 영화로 제공하는 다양한 효과 예시 (그림 출처: [1]) 1
1.2 모션 체어의 동작 축 명칭 2
1.3 다양한 캐릭터를 보유한 콘텐츠 예 (그림 출처: [2]) 3

3.1 보행 동작 효과 생성 방법 8
3.2 보행 운동 측정 부위 9
3.3 보행 운동 중 가속도 측정 결과 10
3.4 보행 운동 중 방향각 측정 결과 10
3.5 가속도 정보 FIR 필터 처리 결과 11
3.6 모션 효과로 변환된 위치 명령 (FIR 필터 및 이중 적분 처리) 11
3.7 모션 효과로 변환된 방향각 명령 (FIR 필터 처리) 12
3.8 보행 주기 추정 과정 요약 15
3.9 보행 모션 효과를 분할 하였을 때 1번째 분할 모션과 30번째 분할 모션의 roll 성분 16
3.10 그림 3.9의 두 파형 DTW 결과 17
3.11 DBA 과정 예시, 상단 주황색 신호와 하단 파란색 신호에 대해 DBA 연산을 취해 중앙 검은색 평균 신호를 얻는 과정, 출처: [3] 18
3.12 서로 다른 초기 위상을 가진 신호들의 DTW 적용 결과 20
3.13 보행 모션 효과 차원 축소 과정 20
3.14 sway 성분 및 surge 성분 근사 개요도 (출처: [4]) 21
3.15 4DPLEX 3자유도 모션 체어 22
3.16 3.2 절 사용자 평가 실험 과정 요약 23
3.17 사용자 평가 실험에 사용된 사인파 기반 보행 모션 효과 25
3.18 사용자 평가 실험에 사용된 모션 효과 평가 설문조사 26

3.19 머리 부위 운동 정보 기반 보행 모션 효과 생성 결과 예시 27
3.20 흉추 부위 운동 정보 기반 보행 모션 효과 생성 결과 예시 27
3.21 요추 부위 운동 정보 기반 보행 모션 효과 생성 결과 예시 28
3.22 골반 부위 운동 정보 기반 보행 모션 효과 생성 결과 예시 28
3.23 보행시 골반의 roll 방향 움직임 (pelvic obliquity) 출처: [5] 29
3.24 보행 모션 효과 표현력 평가 결과 (*: p-value <0.05, **: p-value <0.01) 29
3.25 보행 모션 효과 능동성 평가 결과 (*: p-value <0.05, **: p-value <0.01) 30

4.1 걷기 (walk)의 평균 모션 효과(파란색 실선)와 표준 편차 영역 (점선 영역) 34
4.2 조깅 (jog)의 평균 모션 효과(파란색 실선)와 표준 편차 영역 (점선 영역) 34
4.3 오리걸음 (waddle)의 평균 모션 효과(파란색 실선)와 표준 편차 영역 (점선 영역) 35
4.4 발 구르며 뛰기 (stump)의 평균 모션 효과(파란색 실선)와 표준 편차 영역 (점선 영역) 35
4.5 전력질주(sprint)의 평균 모션 효과(파란색 실선)와 표준 편차 영역 (점선 영역) 36
4.6 보행 모션 효과 시간 정규화 및 위상 일치 과정 38
4.7 원본 모션 효과와 PCA 근사 모션 효과 간 비교 39
4.8 SVM 분류기의 보행 모션 효과에 대한 confusion matrix 41
4.9 4.3 절 실험의 각 세션별 실험 자극 구성 44
4.10 원본 보행 모션 효과 분류 confusion matrix 45
4.11 근사 보행 모션 효과 분류 confusion matrix 45
4.12 Random sampling 보행 모션 효과 분류 confusion matrix 45
4.13 원본 보행 모션 효과 분류 confusion matrix 47

4.14 근사 보행 모션 효과 분류 confusion matrix 47
4.15 Random sampling 보행 모션 효과 분류 confusion matrix 47
4.16 Comp. #5를 제외하였을 때 SVM 분류기 학습 결과 49

I. 서론

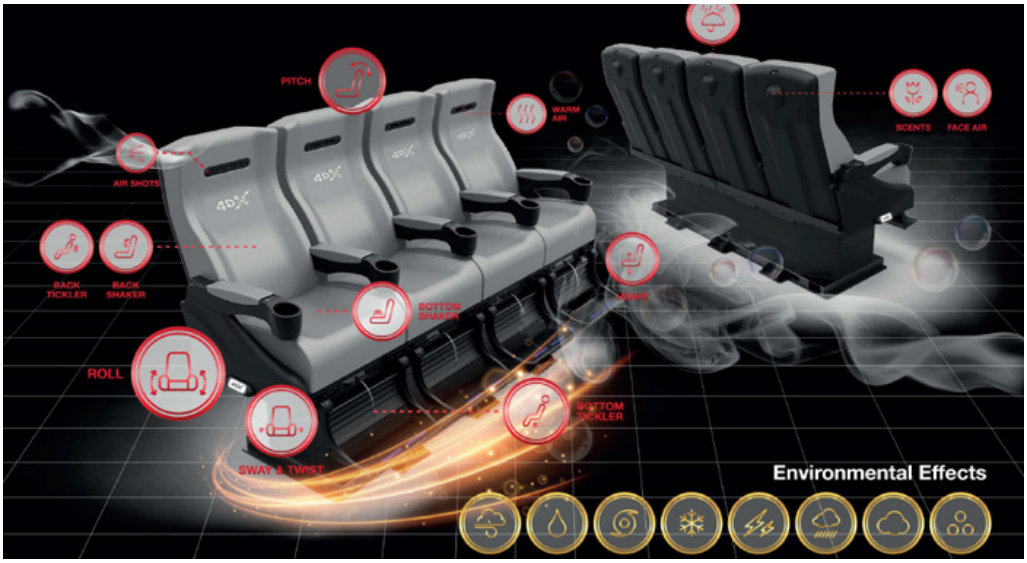

그림 1.1: 4D 영화로 제공하는 다양한 효과 예시 (그림 출처: [1])

최근 관객들에게 영상 이외의 다양한 형태의 자극을 제공하는 실감형 콘텐츠, 그중에서 특히 4D 영화라 불리는 형태의 콘텐츠가 주목을 받고 있다. 4D 영화는 그림 1.1와 같이 관람자가 앉는 의자의 위치 및 방향각을 조절할 수 있는 모션 의자(그림 1.2 참고)를 이용한 모션 효과를 중심으로 바람, 연기 등의 다양한 물리적 효과를 영화와 함께 제공하는 콘텐츠이다. 4D 영화는 영상만이 아닌 영화의 주인공들이 받는 물리적인 효과들을 관람자들도 함께 체험하면서 높은 몰입감을 제공할 수 있다. 4D 영화 시장은 관련 대기업들을 중심으로 큰 규모로 성장하고 있는 콘텐츠 시장이기에 다양한 주목을 받고 있다.

하지만 이러한 장점을 갖추고 있음에도 이 모션 효과를 제작하는 과정은 모두 수동으로 이루어지고 있다고 한다. Lee et al.이 과거 CJ 4DPLEX의 모션 효과 디자이너를 대상으로 진행한 설문조사에 따르면 4D 영화 1개당 평균적으로 3명의 인원이 16일에 걸쳐 모션 효과를 제작하게 된다고 한다[4]. 해당 모션 효과를 제

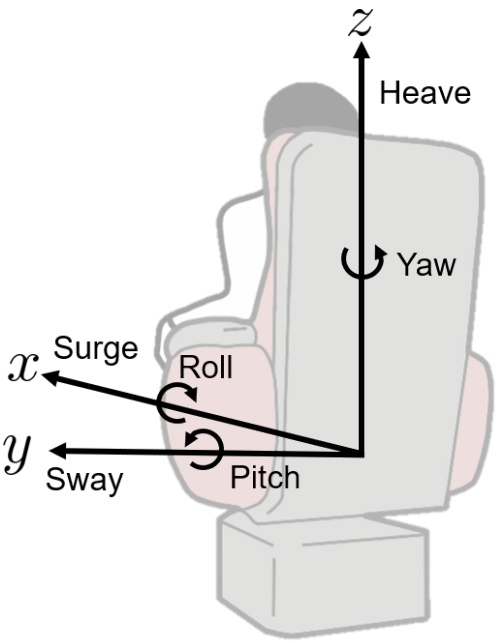

그림 1.2: 모션 체어의 동작 축 명칭

작하는 데에는 일반적인 모션 효과 패턴을 도입하는 등의 방식을 사용하지 않고 디자이너의 영화 문맥의 이해도와 예술적 감각에 의존하여 모션 효과를 제작했었다. 이는 상당한 인력과 숙련도가 필요한 작업이기에 모션 효과 콘텐츠를 생산하는 데 큰 어려움으로 작용한다. 이에 다양한 연구들이 4D 모션 효과 제작을 자동화하거나 보조하는 것을 목표로 이루어지고 있다.

4D 모션 효과를 제작할 때 사용하는 영상 콘텐츠는 영화와 같이 인간형의 주인공들이 다수 포함되어있어 인간의 동작, 그중에서도 보행과 관련된 모션 효과를 표현해야 할 필요성이 있다. 대부분의 보행 모션 효과 연구는 다양한 모션 효과를 만들고 그중에서 가장 보행 운동을 잘 표현한 모션 효과를 찾는 데 초점이 맞춰져 있다. 하지만 이러한 방법은 다양한 보행 운동에 대한 모션 효과를 표현할 때 어려움을 겪게 된다는 단점이 있다. 특히 그림 1.3의 게임과 같이 다양한 인물들의 신체적 특징과 보행 운동이 포함된 영상 콘텐츠에 동일한 보행 모션 효과를 적용하면 몰입도가 크게 떨어질 것이고 각각에 대해 모두 다른 모션 효과를 생성하고자 하면 그만큼 개발에 필요한 정보와 비용이 커질 것이다. 더욱이 대부분의 보행 모션 효과

그림 1.3: 다양한 캐릭터를 보유한 콘텐츠 예 (그림 출처: [2])

연구가 사인파의 진폭, 주기 등만을 조절하여 이루어지고 있다는 점으로 미루어볼 때 다양한 특징을 표현하기엔 한계가 있다.

본 논문은 기존 보행 모션 효과 관련 연구에서 표현하기 어려웠던 다양한 보행 특징을 모션 효과로 표현하는 방법과 보행 모션 효과의 인지적 특성을 잃지 않으면서 보행 모션 효과를 생성하는 데 필요한 정보량을 줄이는 방법을 제안한다. 2장에서는 본 연구와 관련된 연구 결과들을 소개한다. 3장에서는 인간의 보행 운동 정보를 수집하여 모션 효과를 생성하는 방법을 소개하고 이 방법을 통해 생성된 모션 효과들의 사용자 평가 결과를 보고하고자 한다. 4장에서는 다양한 보행 유형에 따른 모션 효과를 수집하고 이러한 모션 효과들을 주성분 분석 (principal component analysis, PCA)을 통해 축약하여 표현하였을 때 결과와 보행 동작들의 분포와 이에 대한 인지 실험 결과를 소개하고자 한다.

II. 관련 연구

2.1 데이터 기반 물리 효과 생성 연구

가상 환경 내에 실제와 유사한 물리 효과들을 표현할 목적으로 데이터 기반 물리 효과 생성 연구가 이루어진 바 있다. 물체 표면의 질감을 표현하고자 stylus를 긁었을 때 발생하는 진동 정보를 수집하여 linear predicted coding[6], neural network[7, 8, 9], radial basis function network[10]을 이용하여 모델을 생성한 바 있다. Shin et al.은 물체 표면 주위로 다양한 위치의 광원을 두고 찍은 사진들을 합성하여 10μm급 고해상도 height map을 생성하여 진동으로 생성한 질감 모델에 접목하여 표면 질감 모델을 생성하였다[11]. 표면 질감뿐 아니라 다양한 물체와 접촉하였을 때 느끼는 열을 표현하기 위해 Choi et al.은 손의 온도, 물체 온도, thermal flux 정보를 수집하여 Peltier 소자를 통해 열 자극을 표현하였다[12]. 스펀지, 실리콘과 같은 deformable object를 눌렀을 때 느낄 수 있는 viscoelastic 특성을 구현하기 위해 여러 재질의 물체들을 눌렀을 때 받는 힘을 수집하여 이를 random forest로 모델을 구현한 연구도 진행되었다[13, 14]. 이러한 데이터 기반 물리 효과 생성 방법은 정확한 물리 수치나 모델이 없더라도 실제 현실과 유사한 효과를 생성할 수 있다는 장점을 가지고 있으나 이러한 효과를 생성하기 위해서는 다수의 데이터가 필요하다.

2.2 모션 효과 저작 관련 연구

많은 모션 효과 저작 관련 연구는 영상 정보가 주어진 상태에서 모션 효과를 만드는 사용자 시나리오를 가정한 경우가 많다. 이와 관련된 연구들은 영상 내용으로부터 정보를 추출하여 이를 이용해 직접적으로 모션 효과를 생성하는 것을 목표로 하거나 혹은 추출된 정보를 이용하여 해당 영상에서 설계해야하는 모션 효과의 특징들을 추천하는 것을 목표로 진행되는 경우가 많다.

먼저 영상을 기반으로 모션 효과를 직접적으로 생성하고자 하는 연구에 대해

살펴보자. Lee et al.은 4D 영화에 사용되는 모션 효과를 자동으로 생성하기 위해 기존 모션 효과를 조사하여 생성된 모션 효과들의 근거를 기준으로 분류하고 각 분류별로 모션 효과 생성 알고리즘을 개발하였다[4]. 그는 모션 효과를 크게 camera motion class, object motion class, impulse and vibration class, context class로 분류하였다. 이 중 camera motion class와 impulse and vibration class에 해당하는 모션 효과를 자동으로 생성하기 위해 영상의 카메라 움직임을 추정하는 vision 기술을 통해 모션 효과를 생성하는 알고리즘과 소리의 intensity 정보를 이용하여 모션 효과를 생성하는 알고리즘을 개발하였다. 이후 후속 연구에서 object motion class의 모션 효과를 만들기 위해 화면 내 object의 동선을 이용하여 모션 효과를 제작하였다[15]. Goh et al.은 영상으로부터 물체 및 인물의 움직임과 소리 정보를 학습하여 적절한 4D 모션 효과를 생성하는 모델을 개발하였다[16]. 그는 영상의 optical flow 정보와 salient object 정보를 추출하여 이를 통해 영상 내 object의 움직임을 추정하는 neural network model을 학습시켜 모션 효과를 만들어 내었다.

다음으로 모션 효과 설계 방향을 추천하는 방법에 대한 연구를 살펴보도록 하겠다. Zhou et al.은 'Movie4D'라 불리는 63개의 영화에 대해 약 9천 개에 달하는 4D 효과들을 라벨링 한 dataset을 수집하고 이를 기반으로 영상 클립에 적합한 4D 효과 유형을 추천하는 모델을 개발하였다[17]. Abreu et al.은 영상 클립으로부터 4D 효과를 통해 표현해야 할 구간과 내용을 자동으로 labeling 하는 저작 도구를 개발하였다[18].

2.3 보행 동작 표현 연구

보행 동작을 표현하는 연구는 사용자가 가상 콘텐츠 내의 주인공의 보행 운동을 느낄 수 있도록 다양한 물리 자극을 주는 방법에 대한 연구들이 다수 존재한다. 특히 현실에서 보행 운동은 먼 거리를 이동할 수 있는 운동이기 때문에 이 운동을 사용자가 그대로 하게될 경우 넓은 작업 공간을 필요로 할 수 있다. 이에 한정된 공간 내에서 보행 운동을 표현하는 방법에 대한 연구들이 활발하게 이루어지고 있다.

햅틱 자극을 제공하는 신발[19, 20, 21], 바람 자극[22], 팔의 왕복 운동[23] 등을

이용하여 보행을 표현하는 연구들이 진행되었다. 특히 본 연구와 깊이 관련된 모션 의자를 이용하여 보행 모션 효과 표현하는 것과 관련된 연구들도 진행된 바 있다. Ikei et al.[24]은 걷기 모션 효과를 생성하기 위해 보행 중 상반신의 roll 방향 운동과 heave 방향 운동을 수집하고 이와 유사한 모션 효과를 생성하였다. 그러나 피험자들은 해당 모션 효과를 체험하였을 때 느껴지는 움직임이 실제로 걸었을 때 느껴지는 움직임의 크기보다 매우 크다고 응답하였다. 이에 사용자 실험을 통해 보행 운동과 유사하게 느껴지는 모션 효과의 진폭 및 파형을 추가로 조사하였다.

Shimabukuro et al.[25]은 실제 걷기 운동과 보행 모션 효과 간의 인지적 특성의 차이를 확인하는 연구를 진행하였다. 이 연구는 주기성 (“periodicity”)은 모션 효과가 더 분명하게 표현할 수 있음을 보였지만 속도 (“walk speed”), 근육의 긴장감 (“muscle tension”), 균형 조절 (“balance control”), 발 부위의 촉감 (“sole taction”) 측면에서는 부족한 부분이 있어 다른 자극을 통해 보충할 필요가 있음을 시사하였다. 실제 후속 연구로 Ikei et al.[26]이 슬라이더에 부착된 페달을 이용하여 하반신 자극을 추가하면서 모션 효과 만으로 부족했던 인지 특성들을 보충할 수 있음을 보였다.

Shimizu et al.[27]은 평지, 계단 오르고 내려가는 걷기 동작들을 roll, pitch, heave 성분을 포함한 모션 효과들을 생성하는 연구를 진행했었다. 3가지 동작에 대하여 실제 걸었을 때 느껴지는 움직임의 크기와 유사한 크기로 느껴지는 사인파 모션 효과들을 찾고자 사용자 실험을 진행하였다. Amemiya et al.[28]은 HMD를 착용한 상태에서 heave 방향의 걷기 모션 효과와 yaw 방향의 걷기 모션 효과를 비교하는 연구를 진행하여 heave 방향의 모션 효과에 비해 yaw 방향의 모션 효과는 실제 걷는 느낌을 효과적으로 제공하지 못한다는 점을 확인했다.

III. 인간 보행 운동 정보 기반 보행 모션 효과 생성

보행 운동은 사람마다 신체적 특성 등의 이유로 고유한 특징을 갖고 있기 때문에 이러한 보행 특징을 조사하려면 각 사람의 보행을 대표할 수 있는 보행 모션 정보가 필요하다. 이는 높은 자유도의 복잡한 정보이므로 간단한 수학적 함수만으로는 완벽히 표현하기 어려울 수 있다. 또한 최종적으로는 개인의 고유한 보행 운동을 모션 효과로 잘 표현할 수 있어야한다. 이에 본 절에서는 사람의 보행 중 특정 부위의 움직임을 기록한 보행 운동 정보를 수집하여 이를 바탕으로 대표성 있는 1주기 보행 동작 효과를 생성하는 방법을 제안하고 생성된 보행 동작 효과에 대한 사용자 평가 결과를 소개하고자 한다.

3.1 보행 모션 효과 생성 방법

보행 동작 효과 생성 방법의 전체 과정은 그림 3.1와 같다. 보행 동작 정보로부터 보행 동작 효과를 생성할 때는 크게 5단계의 과정을 거친다: 데이터 수집 과정, 모션 효과 변환 과정, 분할 과정, 평균 과정, 차원 축소 과정.

3.1.1 데이터 수집

먼저 보행 동작 효과 생성에 필요한 정보인 보행 운동 정보를 수집한다. 보행중 특정 부위의 방향각 및 가속도 정보를 수집하기 위해 Attitude & heading reference system(AHRS) 센서를 부착하였다. 부착 부위는 사람이 모션 의자에 앉았을 때 접촉하는 골반, 요추, 흉추, 머리를 선정하여 모션 효과로 생성하였을 때 모션 의자를 통해 해당 부위가 보행 중 움직임과 유사하게 동작할 수 있도록 하였다. 센서가 부착 부위의 움직임을 대변하는 정보를 얻을 수 있도록 부착 부위를 고정하고자 그림 3.2과 같이 골반 부위에 역도 가죽 벨트를 착용하였고 흉추 및 요추 부위에 상체 자세 교정밴드를 착용하였으며 머리는 모자를 씌웠고 각 보조 용구에 나사를 이용하여 센서를 부착하였다. 보행 운동 측정 대상자가 반복적으로 실내 약 30 m 직선 구간을

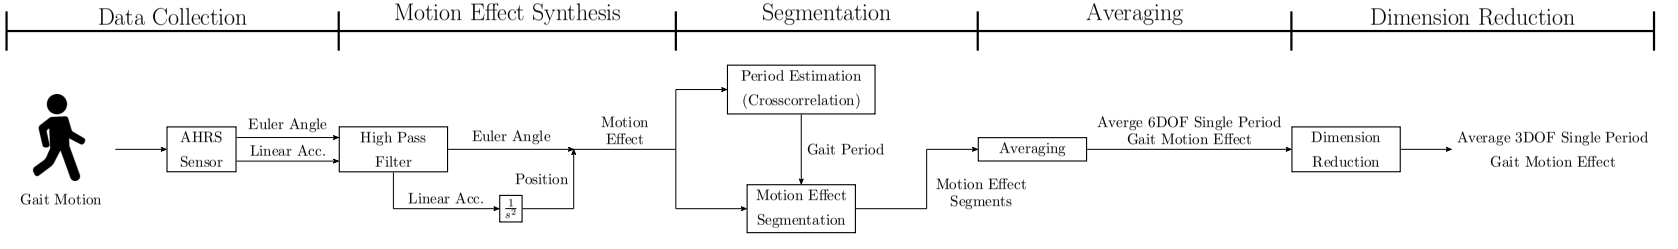

그림 3.1: 보행 동작 효과 생성 방법

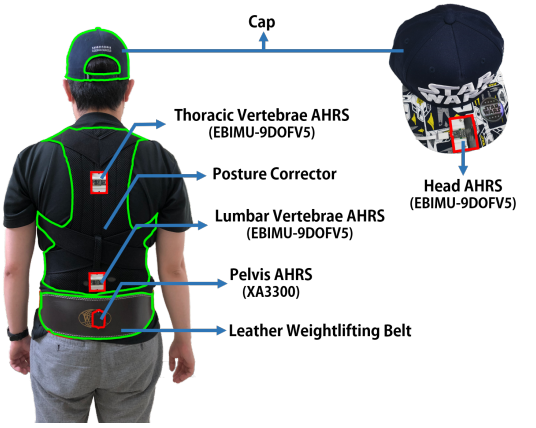

그림 3.2: 보행 운동 측정 부위

걸어가며 통과하는 동안 센서가 부착된 부위의 보행 운동을 수집하게 된다. 이때 센서가 yaw 방향도 측정하게 되므로 왕복하진 않았다.

3.1.2 모션 효과 변환 과정

보행 동작 효과 변환 과정은 이전에 수집한 보행 운동 중 방향각 및 가속도 정보를 모션 체어의 방향각과 위치로 이루어진 모션 효과 명령으로 변환하는 과정이다. 모션 효과 생성에 자주 사용되는 알고리즘인 Nahon과 Reid의 washout filter[29]와 달리 각속도 정보를 입력으로 활용하지 않고 방향각 정보를 사용하였다. 이는 washout filter에서 각속도를 적분하여 방향각을 생성하는 과정이 있는데 AHRS 센서는 Kalman filter 처리 결과로 noise가 제거된 방향각 정보를 제공 하기 때문에 적분 연산으로 noise가 더 축적된 방향각 정보보다 노이즈가 제거된 정보를 사용하는 것이 더 적절하다고 판단하여 방향각 정보를 사용하였다.

수집된 보행 운동 방향각 및 가속도 정보를 cutoff frequency가 1.8Hz인 high pass filter (HPF)로 처리한다. 이는 넓은 동작 공간을 갖는 저주파 성분을 모션 체어의 좁은 동작 범위로는 표현하기 어렵기 때문에 이를 제거하기 위한 작업이다. HPF는 butterworth filter 기반 linear-phase finite impulse response (FIR) filter를 사용하였다[30]. 보행 운동은 3축 가속도 방향각이 동시에 바뀌는 운동이므로 변환 후 가속도와 방향각 축 간에 위상차가 발생하면 원하지 않는 모션 효과가 생성될

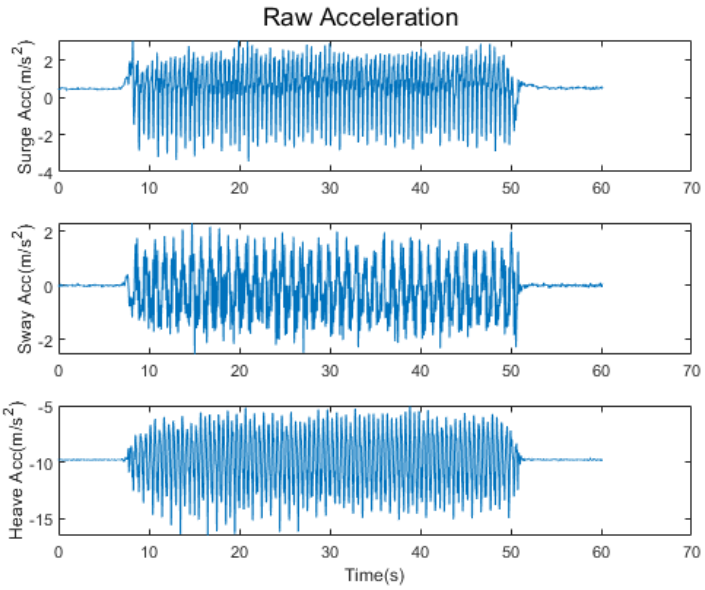

그림 3.3: 보행 운동 중 가속도 측정 결과

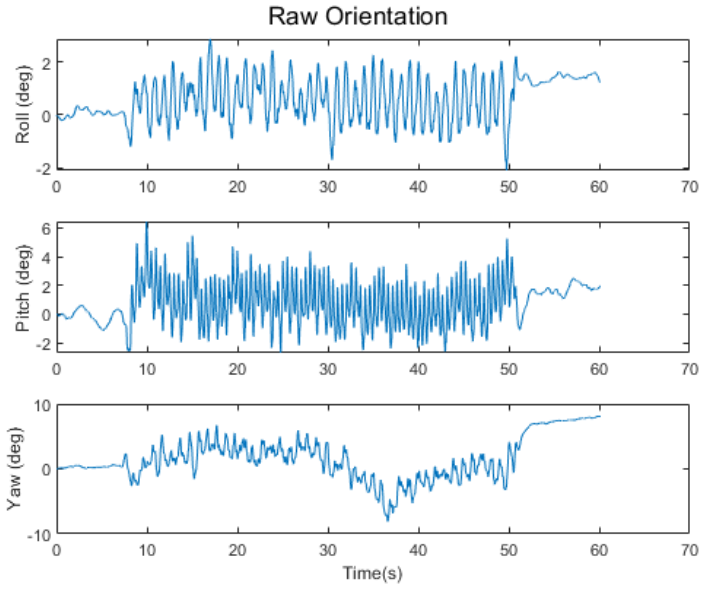

그림 3.4: 보행 운동 중 방향각 측정 결과

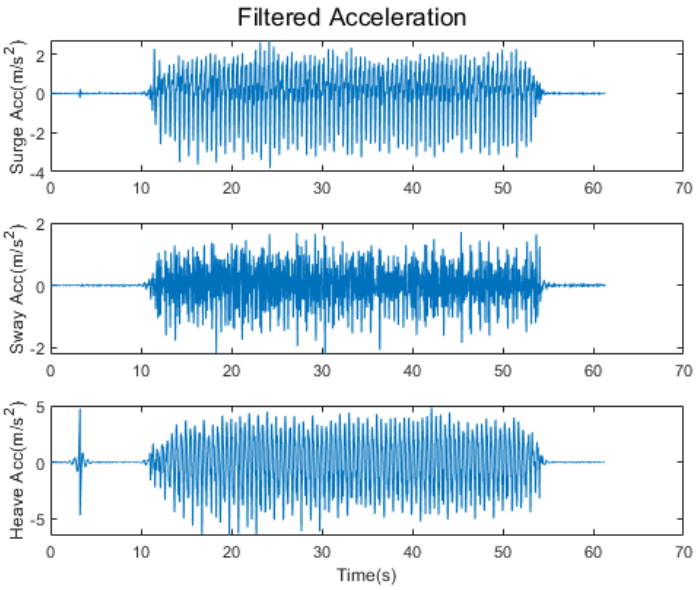

그림 3.5: 가속도 정보 FIR 필터 처리 결과

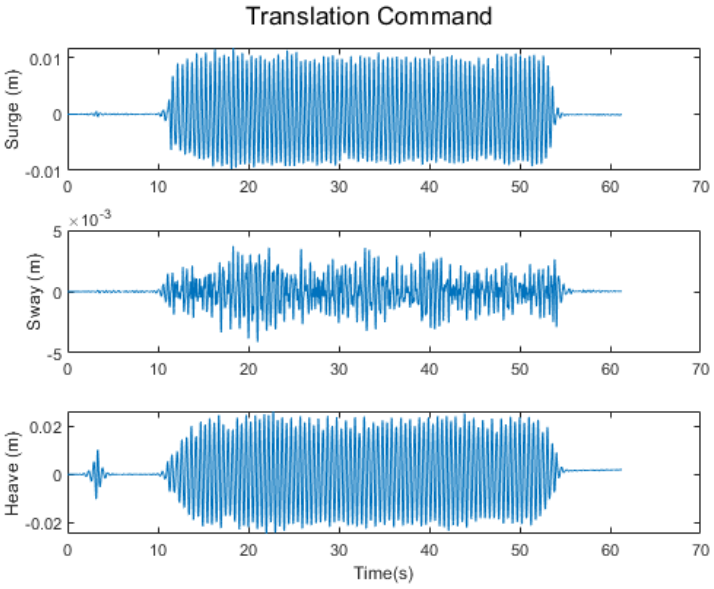

그림 3.6: 모션 효과로 변환된 위치 명령 (FIR 필터 및 이중 적분 처리)

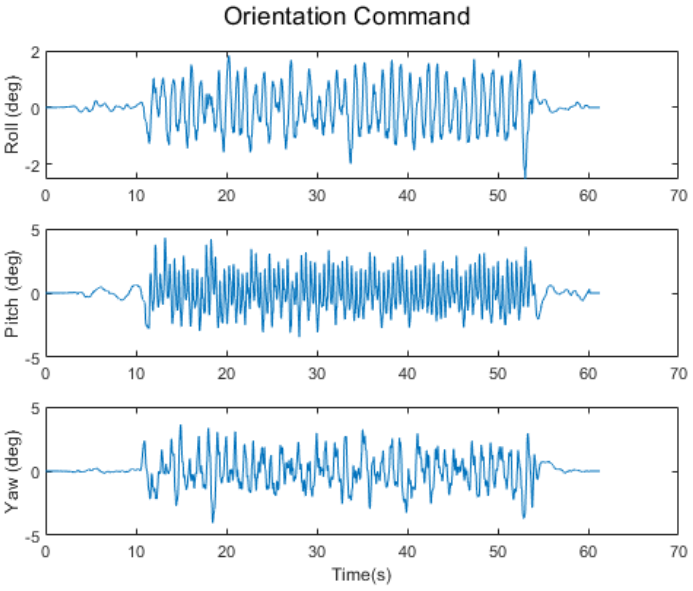

그림 3.7: 모션 효과로 변환된 방향각 명령 (FIR 필터 처리)

수 있다. 이에 모든 주파수 대역에서 동일한 group delay를 갖는 linear-phase FIR 필터를[30] 사용하여 필터에 의해 위상차가 생기지 않도록 하였다. AHRS 센서에 Kalman filter가 내장되어 있어 추가적인 noise 제거는 하지 않았다.

3.1.3 분할 과정

분할 과정에서는 이전에 생성된 여러 보행 주기로 이루어진 보행 모션 효과를 2주기 단위로 분할하게 된다. 인간의 걸음마다 걸린 시간이 다를 수 있으므로 분할 과정에서는 매 걸음의 걸린 시간을 추정하는 과정을 거친다. 만약 모든 걸음 시간이 같다고 가정하고 보행 동작 효과를 나누게 된다면 걸음마다 오차가 누적되어 분할된 보행 동작들이 모두 다른 구간을 나타낼 수 있으므로 매 걸음마다 걸린 시간을 추정한다. 본 추정 과정은 그림 3.8에 나타나 있다.

각 걸음 시간을 추정하는데 가장 중요한 연산은 교차 상관 (cross-correlation)이다. 교차 상관은 두 신호가 얼마나 유사한 지를 나타내는 척도로 두 불연속 실수 신호 $f[t], g[t]$에 대해 교차 상관은

$$(f \bigstar g)[\tau] \triangleq \sum_{-\infty}^{\infty} f\left[t-\tau\right] g[t] dt \tag{3.1}$$

와 같이 정의되며 이때 τ는 두 신호에 가한 시간 지연을 말한다[31]. 교차 상관은 두 신호가 유사할 수록 커지므로 특정 τ에서 cross-correlation의 최대값을 가지게 된다면 두 신호 간의 유사 파형간 시간차는 τ라고 말할 수 있다. 이러한 성질을 이용하여 보행 파형이 반복하여 나타나는 시간, 즉 보행 시간을 구하고자 한다.

하지만 위 cross-correlation 정의를 모션 효과에 직접적으로 적용하기는 어려운 점들이 있다. 본 논문에서 사용하는 모션 효과의 최대 자유도는 회전 3축, 위치 3축에 총 6자유도 모션 명령으로 6차원 vector 신호로 이루어져 있어 1차원 신호에 대한 cross-correlation 정의를 직접적으로 사용하는데 어려움이 있다. 또한, 각 축의 운동 범위가 다르므로 scale 조정 없이 수치를 직접적으로 사용하였을 때 운동 범위가 큰 축에 편향된 결과를 얻을 수 있다.

이러한 어려움들을 고려하여 모션 효과간의 유사성과 시간차를 용이하게 판단할 수 있는 새로운 척도를 고안하였다. k자유도 모션 효과 $\mathbf{f}[n] = [f_1[n], \ldots, f_k[n]]^T$, $\mathbf{g}[n] = [g_1[n], \ldots, g_k[n]]^T$에 대하여 $\mathbf{S}(\mathbf{f}, \mathbf{g}, \tau)$는 식 3.2와 같이 정의된다.

$$\mathbf{S}(\mathbf{f}, \mathbf{g}, \tau) \triangleq \sum_{i=1}^{n} \left(\bar{f}_i \bigstar \bar{g}_i\right)[\tau] \tag{3.2}$$

이때 $\bar{f}_i$, $\bar{g}_i$는 $\mathbf{f}(\mathbf{n})$와 $\mathbf{g}(\mathbf{n})$의 i번째 성분 $\bar{f}_i$, $\bar{g}_i$들을 z-score로 정규화한 것으로 식 3.3, 3.4 같다.

$$\bar{f}_i[n] = \frac{f_i[n] - \mu_{f_i}}{\sigma_{f_i}} \tag{3.3}$$

$$\bar{g}_i[n] = \frac{g_i[n] - \mu_{g_i}}{\sigma_{g_i}} \tag{3.4}$$

μ_{f_i}, μ_{g_i}는 각각 f_i, g_i의 평균이며 σ_{f_i}, σ_{g_i}는 각각 f_i, g_i의 표준편차를 의미한다. $\mathbf{S}(\mathbf{f}, \mathbf{g}, \tau)$를 사용하면 모든 축을 고려하여 다차원 모션 효과 간의 유사성을 알 수 있으며 특정 축의 운동 범위로 인해 편향 되는 문제도 정규화를 이용하여 완화된다.

2주기 단위로 모션 효과를 분할하기 위해서 시작 부분의 보행 모션이 2번 반복되는 지점을 찾을 필요가 있다. 이에 분할을 진행할 모션 효과에 대하여 비교할 시작 부분의 모션 효과가 필요하다. 분할 하고자 하는 6자유도 모션 효과 $\mathbf{f}[n] =$

$[f_1[n], \ldots, f_6[n]]^T$에 대해 시작 부분의 모션 효과 $\mathbf{f}_{short}[n] = [f_{1,short}[n], \ldots, f_{6,short}[n]]^T$를 식 3.5와 같이 정의하였다.

$$f_{i,short}[n] = \begin{cases} f[n] & (\text{if } 0 < n < T_{short}) \\ 0 & (\text{otherwise}) \end{cases} \tag{3.5}$$

이때 본 알고리즘에 사용된 T_{short}값은 250 샘플 (sampling rate 100Hz 기준 2.5 초)였다. $\mathbf{f}[n]$와 $\mathbf{f}_{short}[n]$간의 $\mathbf{S}(\mathbf{f}_{short}, \mathbf{f}, \tau)$값을 구하면 식 3.6와 같다.

$$\begin{aligned} \mathbf{S}(\mathbf{f}_{short}, \mathbf{f}, \tau) &= \sum_{i=1}^{6} \left(\bar{f}_{i,short} \bigstar \bar{f}_i\right)[\tau] \\ &= \sum_{i=1}^{6} \sum_{-\infty}^{\infty} \bar{f}_{i,short}[n-\tau]\, \bar{f}_i[n] \\ &= \sum_{i=1}^{6} \sum_{\tau}^{\tau+T_{short}} \bar{f}_{i,short}[n-\tau]\, \bar{f}_i[n] \; (\because \text{식 } 3.5) \end{aligned} \tag{3.6}$$

즉, 그림 3.8에서 표현한 바와 같이 $\mathbf{f}[n]$의 τ부터 $\tau + T_{short}$ 구간이 $\mathbf{f}_{short}[n]$와 얼마나 유사한 지 나타내는 척도가 $\mathbf{S}(\mathbf{f}_{short}, \mathbf{f}, \tau)$라고 할 수 있다. 보행 운동의 한 주기가 끝나게 되면 시작 보행 모션 효과가 다시 반복 되므로 $\mathbf{S}(\mathbf{f_s hort}, \mathbf{f}, \tau)$가 극대값을 이루게 되어 해당 τ값이 보행 주기라 할 수 있다. 하지만 보행 운동의 파형은 복잡하므로 그림 3.8과 같이 $\mathbf{S}$의 극대값을 추출하였을 때 보행 주기에 의한 극대값 지점 이외에 소규모 극대값들이 섞여있다. 이를 분리하기 위해 k-means clustering 을 사용하여 $\mathbf{S}(\mathbf{f}_{short}, \mathbf{f}, \tau)$ 의 극대값을 2개의 그룹으로 분할한 뒤 평균값이 큰 그룹만을 취한다. 이 그룹 중 가장 작은 τ값 2개, 즉 1주기와 2주기 시간을 각각 T_1, T_2를 구할 수 있다.

분할 과정에서는 $\mathbf{f}[n]$를 T_1,T_2를 이용하여 식 3.7, 3.8와 같이 2주기 모션 효과 $\mathbf{f}_{seg}$와 이후 다시 분할을 진행할 모션 효과 $\mathbf{f}_{next}$로 분할하게 된다.

$$\mathbf{f}_{seg}[n] = \begin{cases} \mathbf{f}[n] & (\text{if } 0 < t < T_2) \\ 0 & (\text{otherwise}) \end{cases} \tag{3.7}$$

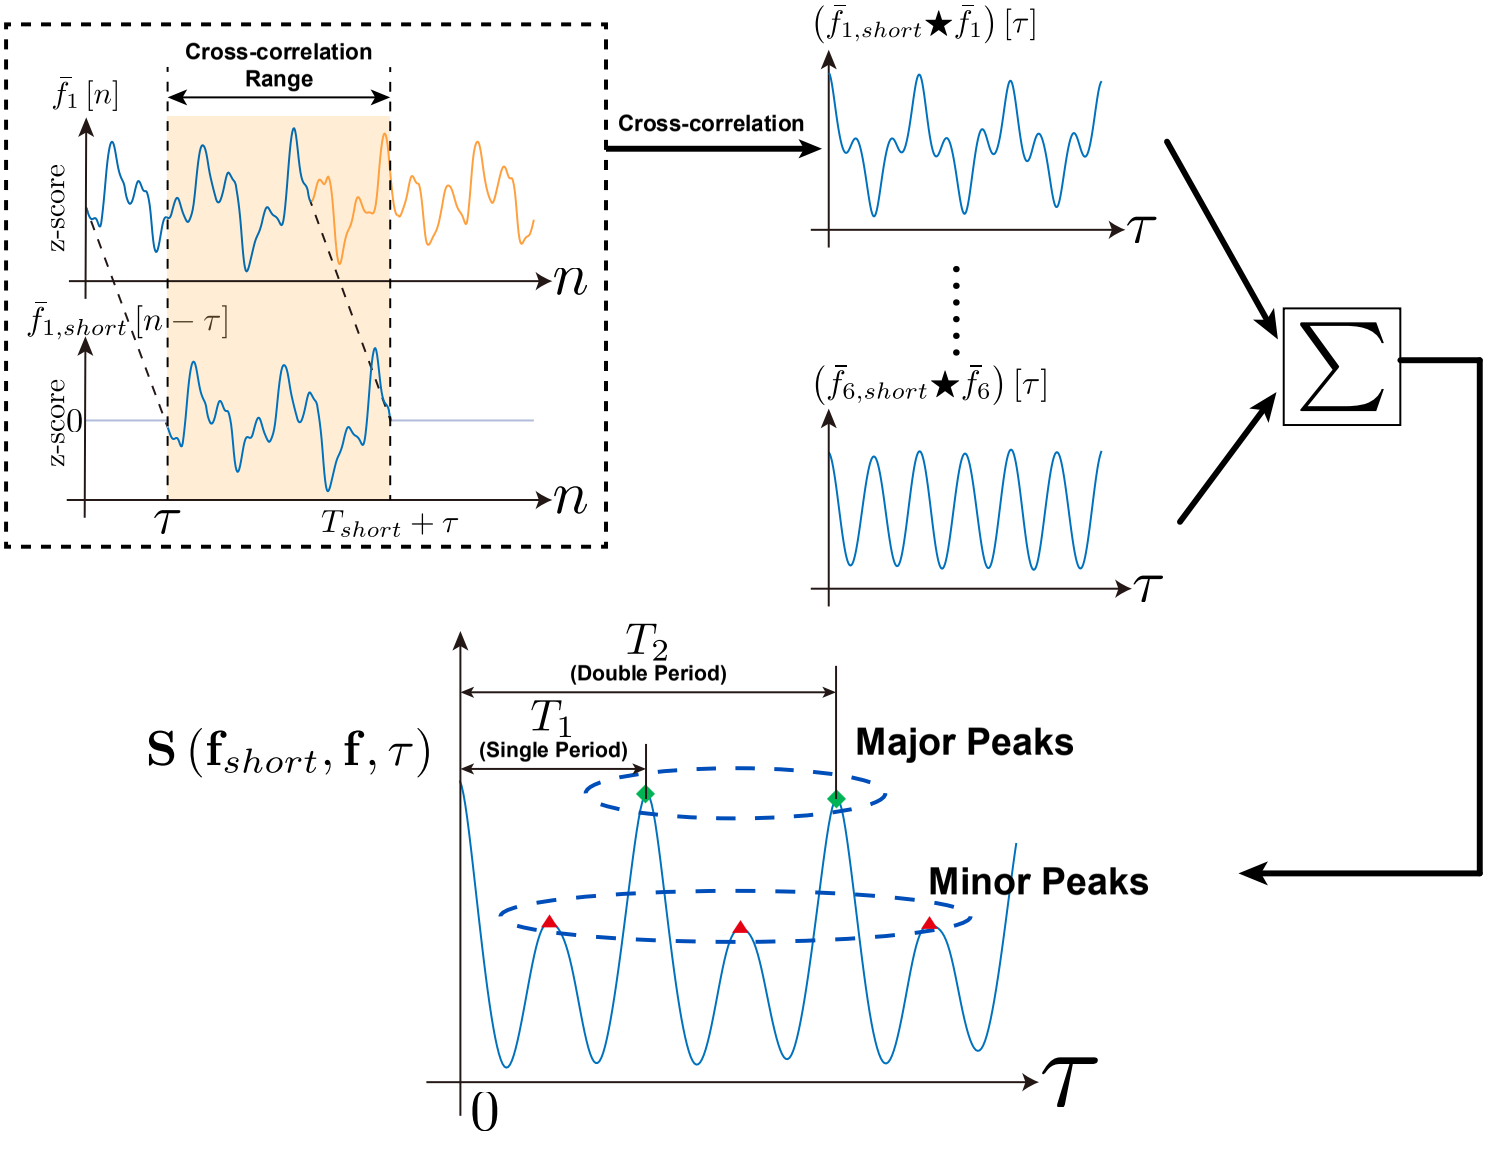

그림 3.8: 보행 주기 추정 과정 요약

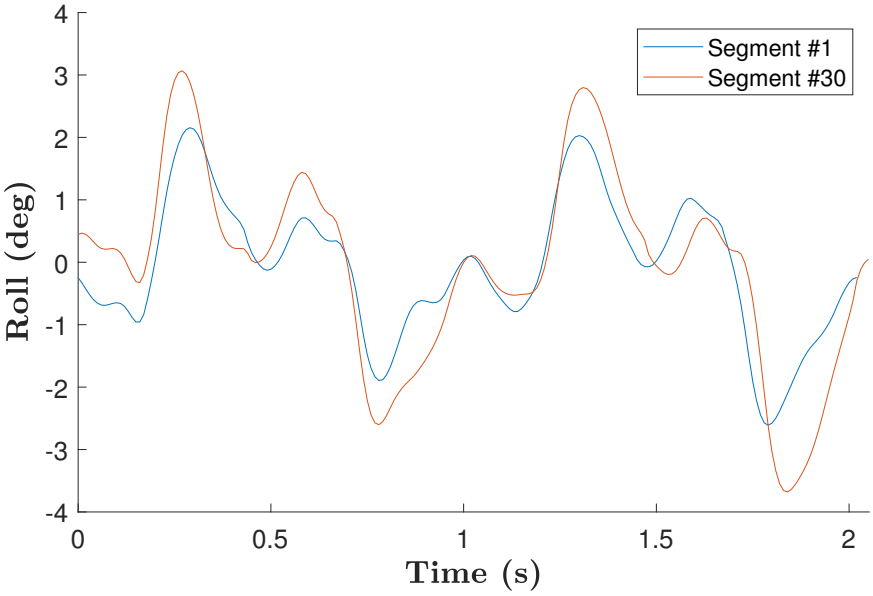

그림 3.9: 보행 모션 효과를 분할 하였을 때 1번째 분할 모션과 30번째 분할 모션의 roll 성분

$$\mathbf{f}_{next}[n] = \begin{cases} \mathbf{f}[n+T_1] & (\text{if } t > 0) \\ 0 & (\text{otherwise}) \end{cases} \tag{3.8}$$

T_2 단위로 분할 하면서 다음 분할에 사용되는 모션 효과는 T_1 이후 시점의 모션 효과를 사용하여 데이터 분할한 뒤에는 $\mathbf{f}_{next}$에 대해 다시 반복적으로 분할과정을 거친다. 만약 k-means clustering 결과 필터링 된 극대값들이 1개 이하로 T_2값을 구할 수 없다면 이 과정을 종료한다. 이를 통해 보행 모션 효과를 2주기 단위로 분할하게 된다. 이 방법으로 보행 모션 효과를 분할 하였을 때 보행 주기 오차의 누적이 크지 않아 그림 3.9와 같이 첫 분할 모션 효과와 마지막 분할 모션 효과의 위상차가 거의 없음을 알 수 있다.

3.1.4 평균 과정

평균 과정에서는 대표성있는 단일 주기 보행 동작을 생성하고자 Petitjean et al. 의 dynamic time warping barycenter averaging (DBA) 방법을[3] 이용하여 분할된 모션 효과들의 평균 값을 구하고 이중 단일 주기 모션 효과 만을 추출한다. Sakoe와

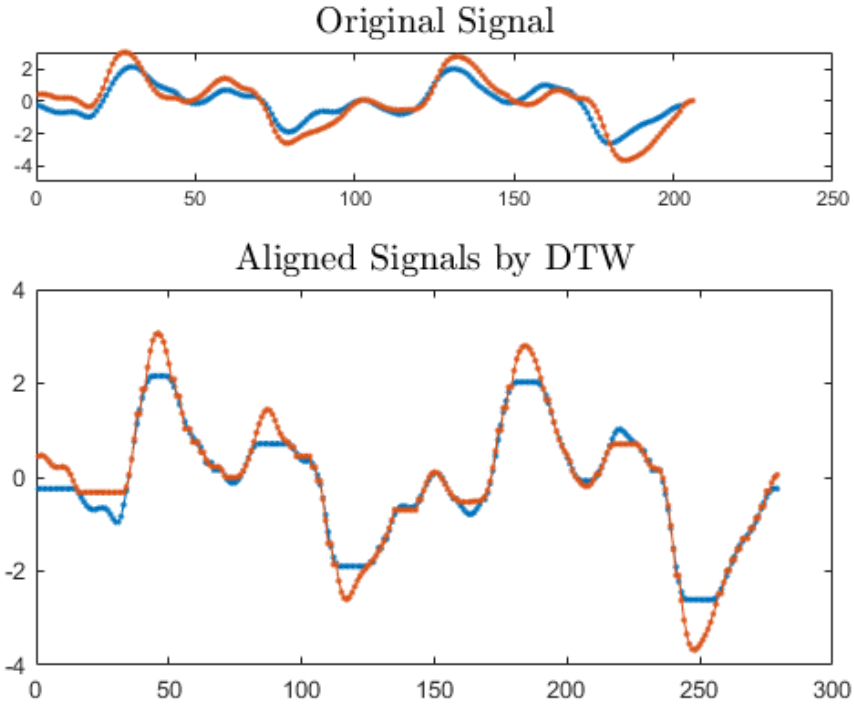

그림 3.10: 그림 3.9의 두 파형 DTW 결과

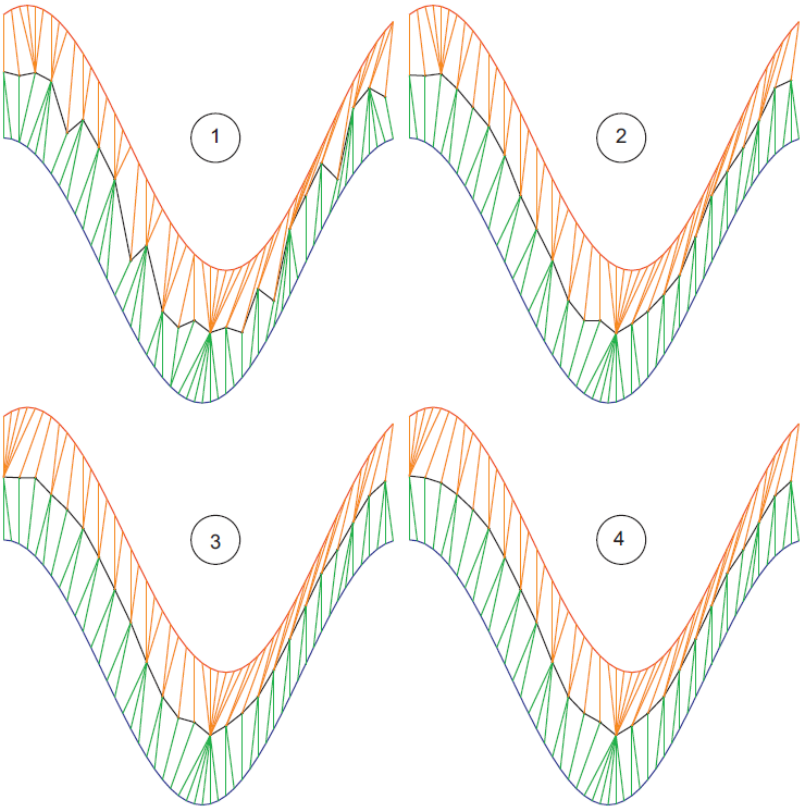

그림 3.11: DBA 과정 예시, 상단 주황색 신호와 하단 파란색 신호에 대해 DBA 연산을 취해 중앙 검은색 평균 신호를 얻는 과정, 출처: [3]

Chiba는 파형이 유사하지만 속도가 다른 두 신호를 비교하고자 두 신호간의 차이를 최소화 하도록 시간축을 왜곡하는 방법인 dynamic time warping (DTW) 기법을 개발하였다[32]. 두 불연속 신호에 DTW를 사용하면 두 신호 사이의 차이가 최소화 되도록 각 시간별 데이터 지점들을 대응시킨다. 이때 서로 중복된 점들도 대응될 수 있어 진폭이 맞지 않거나 파형이 다르면 중복된 점들과 대응되어 유사한 신호라도 3.10와 같이 DTW 결과에서 일부 구간에 대해 수평 구간이 나타나게 된다. DBA는 DTW를 이용하여 2개 이상 속도가 다른 신호들의 평균을 계산하는 알고리즘이다. DBA는 평균 값과 평균을 취하고자 한 신호들 간의 거리의 제곱의 합이 최소가 되는 평균 신호를 구하는 것을 목표로하는 알고리즘이다.

DBA의 기본적인 아이디어는 그림 3.11와 같이 기준 신호를 하나 선정하여 평균을 취하고자 하는 신호들 각각에 대해 기준 신호와의 DTW를 진행한 뒤 기준 신호의

각 시간별 대응된 지점들에 대해 평균을 취하는 것이다. 이렇게 생성된 평균 신호는 다시 기준 신호로 지정하여 반복적으로 DTW와 평균 과정을 거치게 된다. Petitjean et al.[3]은 최초 기준 신호를 DBA를 취하고자 하는 신호들 중에서 임의로 하나를 선정하는 것이 무작위로 생성된 신호를 기준으로 한 것 보다 결과 신호와 평균을 취하고자 하는 신호들 사이의 차이가 더 작았다고 보고한 점을 참고하여 본 알고리즘도 동일한 방법을 사용하였다. DBA를 진행한 직후의 모션 효과를 smooting 하기 위해 추가적으로 cutoff frequency 15Hz FIR low pass filter를 처리하였다.

최종적으로 DBA를 통해 산출된 2주기 평균 보행 모션 효과에서 중앙의 1주기 모션 효과만을 분할한다. DBA를 통해 평균 보행 모션 효과를 생성하였을 때 시작과 끝 부분에 발생한 왜곡의 영향을 줄이고자 하는 작업이다. 수집된 보행 운동들의 매 회차 마다 초기 보행 자세가 달라 초기 위상이 달라지게 되어 동일 회차 내에서 분할된 보행 모션 효과들의 초기 위상은 같지만 다른 회차일 경우 초기 위상이 달라진다. 초기 위상이 다른 신호에 DTW를 적용하면 그림 3.12와 같이 양 끝 부분에서는 파형이 거의 일치하지 않아 유사한 파형이 나올 때 까지 수평 구간이 넓게 생성된다. 이에 비교적 유사한 파형을 가지는 중앙 부분이 유효하게 되므로 DBA 결과 역시 중앙 부분이 양 끝에 비해 왜곡이 적다고 할 수 있다. 그러나 왜곡이 시작되는 부분을 뚜렷하게 정의하기 어려운 점이 있어 수동으로 분할 시작 지점을 지정하고 이전 cross-correlation을 활용한 주기 추출 방법을 사용하여 주기를 추정하여 중앙 부분을 분할하였다.

3.1.5 차원 축소

보행 모션 효과 생성 결과 3축 방향각 및 3축 위치로 총 6자유도 모션 효과 명령을 생성하나 실제 사용하는 모션 의자는 3자유도 의자이기 때문에 차원 축소 과정을 통해 모션 효과의 차원을 축소하였다. Lee et al.이 개발했던 카메라의 3차원 선형 가속도 및 3차원 각속도를 roll, pitch, heave 3자유도 모션 효과로 차원을 축소 하여 표현하는 Fast camera 방법을[4] 참고하여 그림 3.13와 같이 차원을 축소하였다. 신체 좌우 방향성과 관련된 sway, roll, yaw 성분을 이용하여 roll 명령을 합성하고

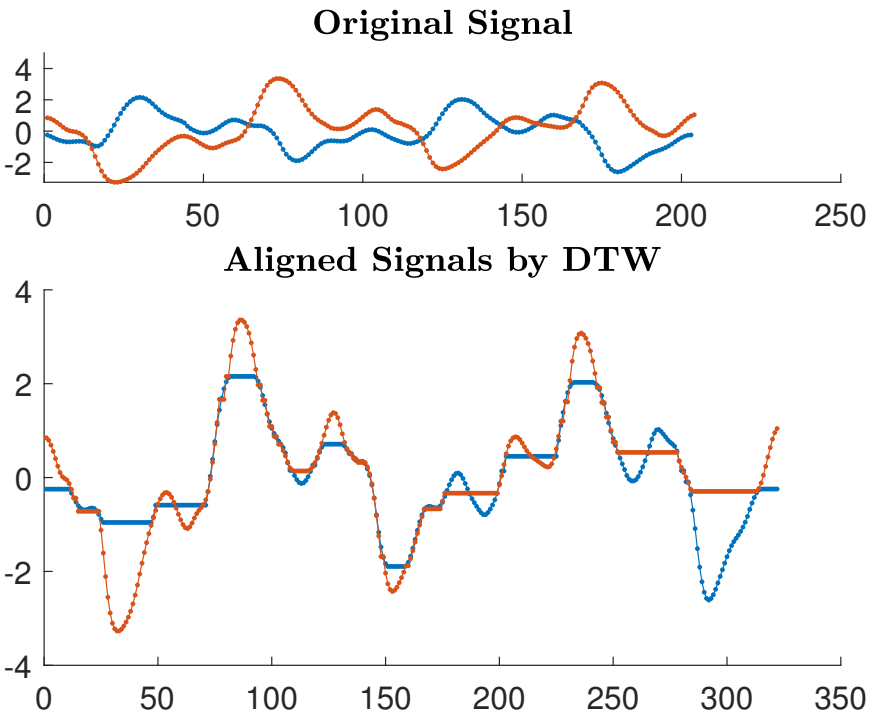

그림 3.12: 서로 다른 초기 위상을 가진 신호들의 DTW 적용 결과

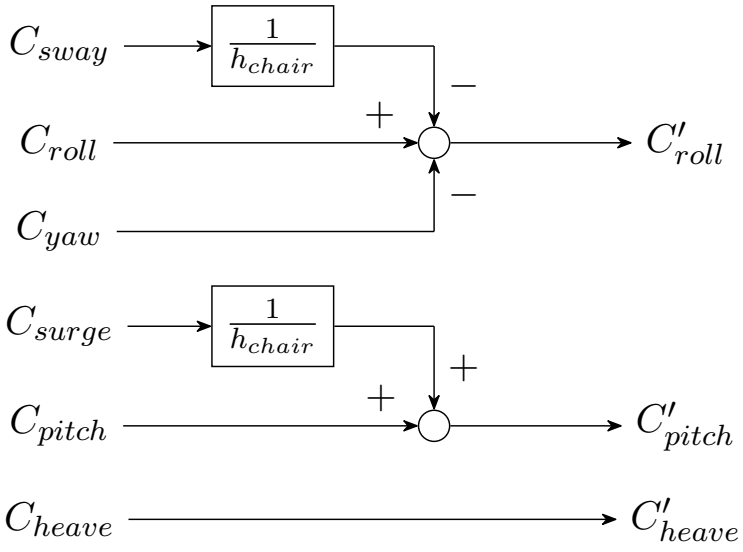

그림 3.13: 보행 모션 효과 차원 축소 과정

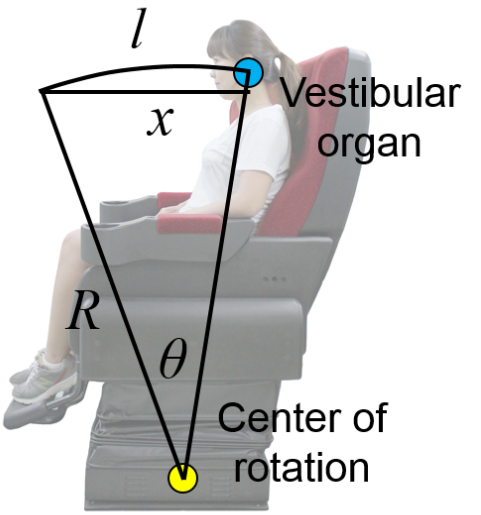

그림 3.14: sway 성분 및 surge 성분 근사 개요도 (출처: [4])

신체 전후 방향성과 관련된 pitch와 surge 성분은 pitch 명령으로 합성되었다.

sway 성분과 surge 성분에 의자의 높이 성분인 h_{chair}를 이용하여 $1/h_{chair}$를 곱한 뒤 합성하였다. 이는 그림 3.14와 같이 Lee et al.이 sway및 surge와 같은 linear translation 성분 (x)을 사람의 전정 감각이 위치한 머리의 높이(l)와 방향각(θ)을 이용하여 $x \approx l\theta$ 근사했던 점을 참고한 것이다. Sway와 surge는 위치이지만 합성 대상인 roll과 pitch는 방향각이기 때문에 이를 방향각으로 변환한 뒤 roll과 pitch 성분을 합성하고자 이런 과정을 거치게 되었다.

또한 C'_{pitch} 성분을 합성할 때 C_{surge}성분을 Lee et al.의 기존 fast camera 합성 방식과 달리 빼지 않고 더하였는데 이는 본 모션 효과가 가속도에 의한 관성 효과를 표현하는 목적을 가지고 있지 않기 때문에 기존과 다르게 더하도록 하였다.

차원 축소 이후에 모션 효과의 진폭은 1/40로 축소하였다. Ikei et al.[24]과 Shimizu et al.[27]이 실제 보행 중 신체의 움직임과 동일한 크기의 모션 효과를 피험자에게 가했을 경우 보행 중 느끼는 움직임의 크기보다 더 크다고 느낀다는 결과를 발표한 바 있다. 이에 따라 파일럿 테스트를 통해 모션 효과의 크기를 1/40배 축소하기로 하였다. 하지만 이 배율은 최적화된 값이라 보기 어려우므로 3.2절과 4.1절에서 진행하는 실험에서는 추가적으로 모션 효과의 크기를 조절하는 단계를 두었다.

그림 3.15: 4DPLEX 3자유도 모션 체어

3.2 사용자 평가 실험

3.2.1 실험 목적

본 알고리즘으로 보행 모션 효과를 생성했을 때 사인파로 만든 모션 효과 보다 인간의 보행 모션 효과를 더 잘 표현했다고 느낄지 여부를 확인하고 골반, 요추, 흉추, 머리 부위 중 어떤 측정 부위의 보행 운동 정보를 사용하였을 때 가장 효과적인 보행 동작 효과를 생성할 수 있을지 검증하기 위해 본 실험을 진행하였다.

3.2.2 실험 참여자

본 실험은 19세에서 31세 사이의 보행 운동과 감각 기관에 이상이 없는 남성 10명 (평균 연령 25.4 세, 평균 신장 173.0 cm, 평균 체중 68.0 kg)과 여성 10명 (평균 연령 25.1 세, 평균 신장 162.3 cm, 평균 체중 51.9 kg), 총 20명을 대상으로 이루어졌다. 각 피험자에게는 사례금 2만원을 지급하였다.

3.2.3 실험 장비

본 실험에서 사용된 모션 효과 재생 장치는 CJ 4DPLEX사의 roll, pitch, heave 모션을 지원하는 3 자유도 모션 체어를 사용하였다. 해당 제품은 roll 방향 $\pm 4°$, pitch 방향 $\pm 7°$, heave 방향 $\pm 4\ cm$의 동작 범위를 가지고 있다.

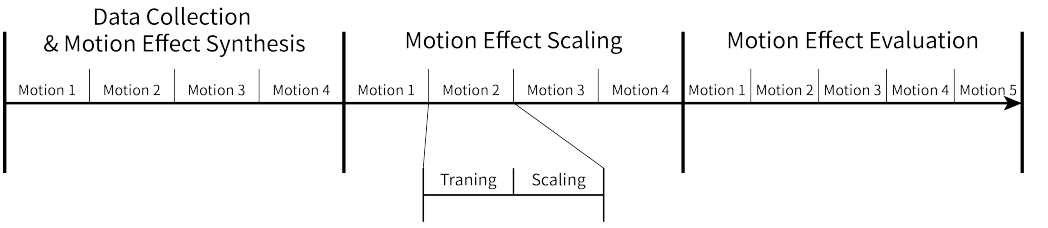

그림 3.16: 3.2 절 사용자 평가 실험 과정 요약

			EBIMU-9DOFV5	XA3300
Sampling Rate			100Hz	100Hz
Rotation Angle	Static Accuracy	Roll, Pitch	$< 0.2°$	$< 0.5°$
		Yaw	$< 0.5°$	$< 1°$
	Dynamic Accuracy		$1.5°$	$< 2°$
Acceleration	Input Range		$\pm 24g$	$\pm 1.7g$

표 3.1: AHRS 모션 센서 EBIMU-9DOFV5, XA3300 성능표

3.2.4 실험 방법

본 실험은 그림 3.2에 나타난 것과 같이 보행 동작 정보 수집, 모션 효과 scaling, 모션 효과 평가 3가지 세션으로 진행하였다.

보행 동작 정보 수집

피험자에게 그림 3.2와 같이 측정 장비를 부착한 뒤 약 30m 직선 구간에 대하여 편도 방향으로 4회 걷도록하여 측정하였다. 측정에 사용된 AHRS 센서는 골반 부위에 대해서는 Microinfinity사의 XA3300 제품을 사용하였고 요추, 흉추, 머리 부위에 대해서는 E2BOX사의 EBIMU-9DOFV5 제품을 사용하였으며 센서의 성능은 표 3.1에 표기해두었다. 골반 부위의 움직임이 4부위 중 가장 커서[33] 내구도가 약한 EBIMU-9DOFV5 제품이 아닌 XA3300제품을 사용하였다.

모션 효과 scaling

이 과정에서는 각 피험자들의 측정 부위별로 3.1절의 알고리즘을 통해 걷기 동작에 대한 모션 효과들을 생성한 뒤 모션 효과의 크기를 조절하였다. Ikei et al.도 보행 모션 효과 생성시 실제 물리적인 수치로 모션 효과를 생성했을 때 실제 사람들은 본인이 보행 중 느끼는 움직임의 크기보다 더 크다고 느꼈다고 보고하였다[24]. 이를 고려하여 생성된 모션효과의 크기를 실제 피험자가 보행 중 느끼는 크기와 최대한 동일한 크기로 느낄 수 있도록 크기 조절을 진행하였다. 그림 3.2에 나타난 것과 같이 본 과정은 모션 효과마다 training과 scaling 과정을 거치게 된다. Training 과정에서는 피험자들에게 자유롭게 걸어볼 수 있는 시간을 주어 본인의 걸음 걸이 움직임의 크기를 파악할 수 있도록 하였다. 그 뒤 scaling 과정에서는 크기 조절을 위해 먼저 원본 모션 효과를 체험 시킨다. 원본 모션 효과의 크기를 100이라고 하였을 때 피험자가 느끼는 본인의 보행 동작 움직임의 크기를 숫자로 알려달라고 요청하였다. 응답 받은 숫자를 R이라고 하였을 때 모션 효과의 크기를 $R/100$ 비율로 재조정하여 피험자에게 다시 체험시키고 다시 본인의 보행 동작 움직임의 크기를 요청한다. 이때 기준 크기 100은 재조정된 모션 효과의 크기가 아닌 원본 모션 효과 크기를 기준으로 한다. 이 과정을 피험자가 본인의 보행 동작의 크기와 모션 효과의 크기가 유사하다고 응답할 때까지 반복한다.

동작 효과 평가

모션 평가는 사전에 만든 4가지 측정 부위에 대한 모션 효과들과 사인파를 대상으로 이루어졌다. 사인파는 Shimizu et al.이 실험을 통해 평지 걸음과 가장 유사하다고 평가 받은 모션 효과를 사용하였으며 단일 주기 파형은 그림 3.17과 같다[27]. 각 보행 모션 효과는 총 20 주기로 반복되어 피험자들에게 제공되었다. 본 모션 효과는 Latin square 순으로 제공되었으며 피험자별 반복은 하지 않았다.

피험자들은 백색 소음을 재생하고 있는 노이즈 캔슬링 헤드폰을 착용한 상태에서 각 모션 효과를 느껴본 뒤 설문지를 통해 평가하도록 요청하였다. 각 평가는 0-100점 사이로 평가할 수 있는 수평 슬라이더로 구성되었으며 9.7인치 터치 스크린

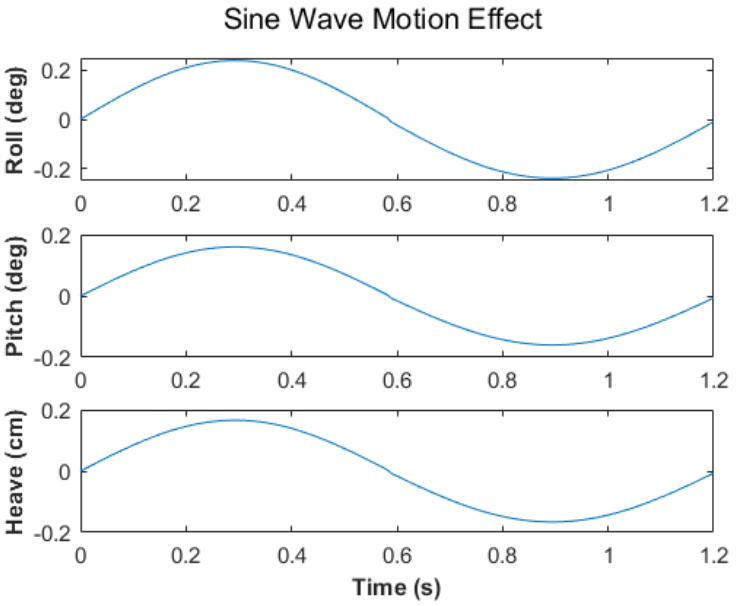

그림 3.17: 사용자 평가 실험에 사용된 사인파 기반 보행 모션 효과

을 탑재한 iPad 6세대 제품과 이에 호환되는 스타일러스인 애플 펜슬 1세대 제품을 통해 설문을 평가하도록 하였다. 설문지 양식은 그림 3.18와 같다. 첫번째 질문인 "이 모션 효과는 나의 걸음걸이를 잘 표현한 모션이다" 항목은 본 모션 생성 방법의 '표현력'을 평가하기 위한 항목이고 두번째 질문인 "이 모션 효과는 내가 스스로 걷는 것 같다 / 이 모션 효과는 탈 것에 의해 옮겨지는 것 같다" 항목은 실제로 능동적으로 걷는 것과 유사한 감각을 느끼는 지 여부를 평가하는 '능동성'을 평가하는 항목이다. 질문 1번은 '매우 동의하지 않는다'를 0점, '매우 동의한다'를 100점으로 평가하도록 구성 하였고 질문 2번은 '탈 것에 의해 옮겨지는 것 같다'를 0점, '내가 스스로 걷는 것 같다'를 100점으로 설정하였다.

피험자 입장에서 모션 효과는 모션 의자의 외력에 의해 움직이는 수동적인 효과임에도 불구하고 능동성에 대한 질문을 넣은 이유는 Ikei et al.이 특정 신체 부위를 강제적으로 보행 동작 움직임을 모방하였을 때 자발적으로 걷는 것과 유사하게 인지할 수 있다는 가설을 제기했기 때문이다[24]. 실제로 걷기와 유사한 하반신의 반복적인 동작인 자전거 페달을 밟는 행동에 대하여 페달을 외부의 힘에 의해 돌렸을 때와 자발적으로 돌렸을 때 체성감각피질 (somatosensory cortex, S1)에서 유사한

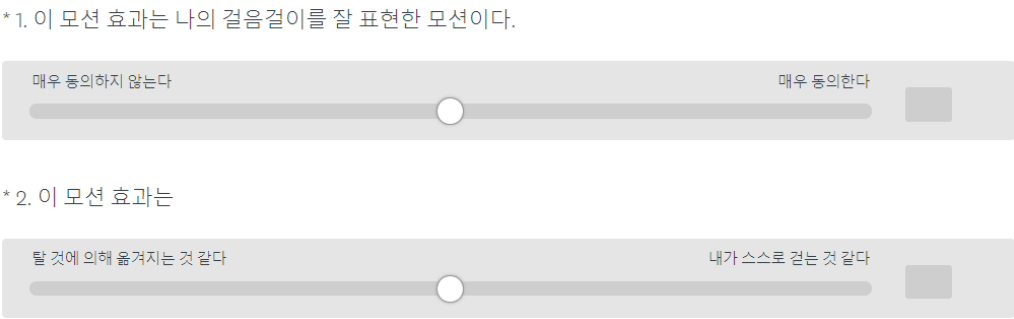

그림 3.18: 사용자 평가 실험에 사용된 모션 효과 평가 설문조사

활성 패턴을 보였다는 연구 결과가 있었다[34].

3.2.5 실험 결과

먼저 rescaling까지 처리되어 최종적으로 생성된 보행 모션 효과를 살펴보고자 한다. 그림 3.19, 3.20, 3.21, 3.22으로 각 부위별로 생성된 보행 모션 효과의 예시들을 확인해 볼 수 있다. 모션 효과의 heave 부분은 대부분 2주기 사인파 형태를 띄고 있었다. 골반 운동 정보로부터 생성된 모션 효과의 roll 성분의 경우 그림 3.23와 같이 인간의 보행중 골반의 움직임[5]과 유사한 파형을 보였다. 다른 부위의 모션 효과는 골반 파형을 변형한 형태의 파형을 띄고 있었으나 보행 유형별로 파형이 어떻게 변화하는 지에 대한 뚜렷한 경향은 찾을 수 없었다.

다음으로 그림 3.24에 나타난 모션 효과의 표현력 평가에 대한 결과를 살펴보겠다. 사인파를 기반으로 생성한 모션 효과의 평균 점수는 41.7점 이었으나 보행 정보를 기반으로 생성한 모션 효과들의 평균 점수는 모두 60점 이상의 높은 점수 결과를 보여주었다. ANOVA test 결과 $F(4, 16) = 4.28$, p-value는 0.004로 유의수준 0.05 이하의 값을 가지면서 자극에 따른 표현력 점수의 차이가 유의미하다는 것을 확인할 수 있었다. Tukey 방법으로 post-hoc test를 진행한 결과 요추를 제외한 나머지 모든 부위의 보행 동작을 통해 생성된 모션 효과가 사인파와 유의미한 차이를 보이고 있음을 확인할 수 있었다. 하지만 인간 보행 동작을 통해 생성된 모션 효과 간에는 통계적으로 유의미한 차이를 확인할 수 없었다.

다음은 그림 3.25에 나타난 모션 효과의 능동성 평가에 대한 결과를 살펴보

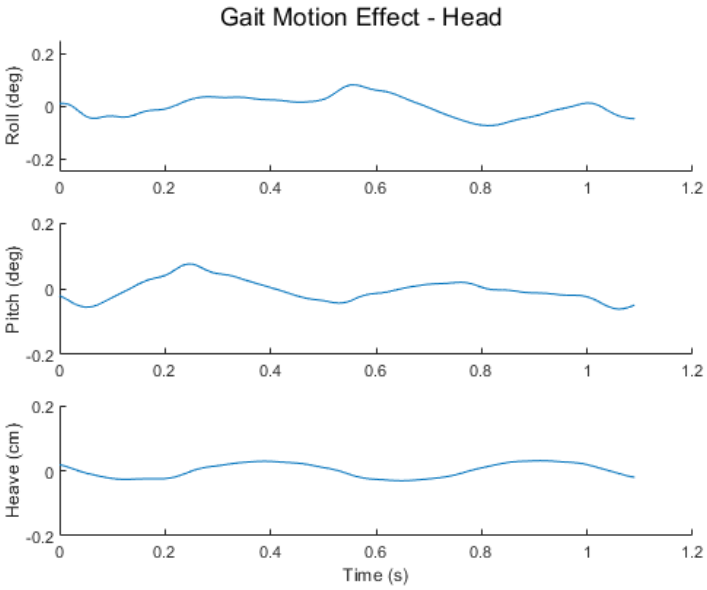

그림 3.19: 머리 부위 운동 정보 기반 보행 모션 효과 생성 결과 예시

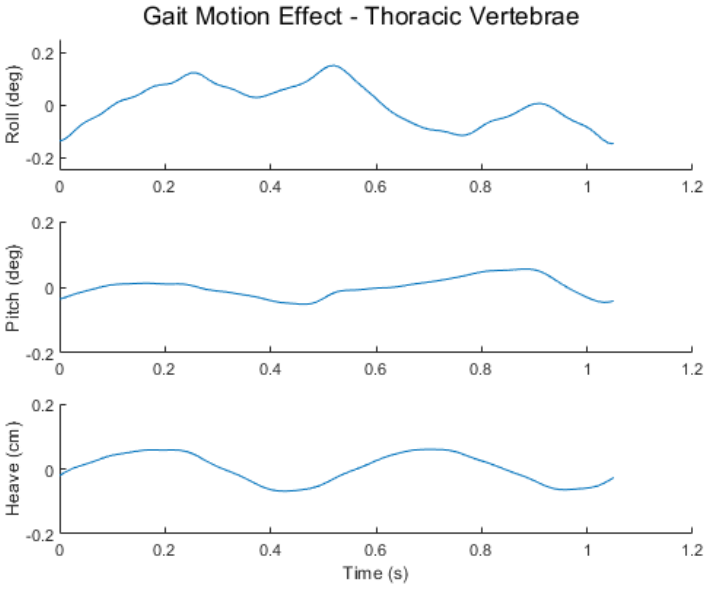

그림 3.20: 흉추 부위 운동 정보 기반 보행 모션 효과 생성 결과 예시

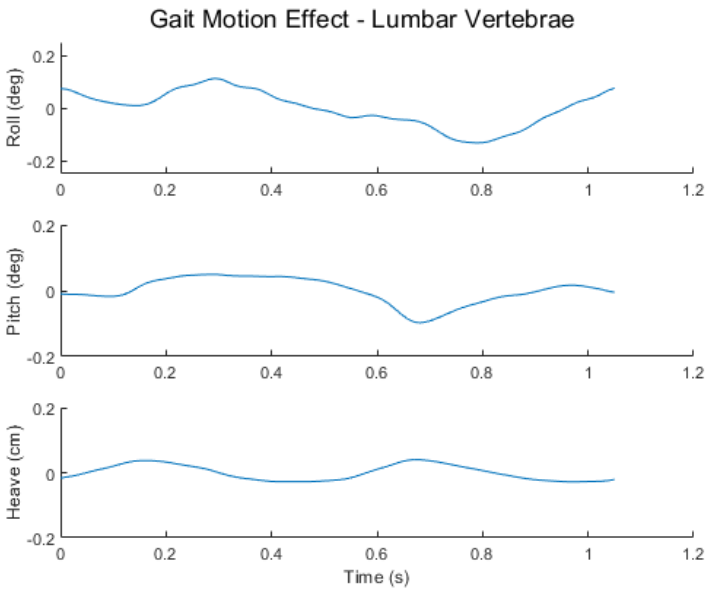

그림 3.21: 요추 부위 운동 정보 기반 보행 모션 효과 생성 결과 예시

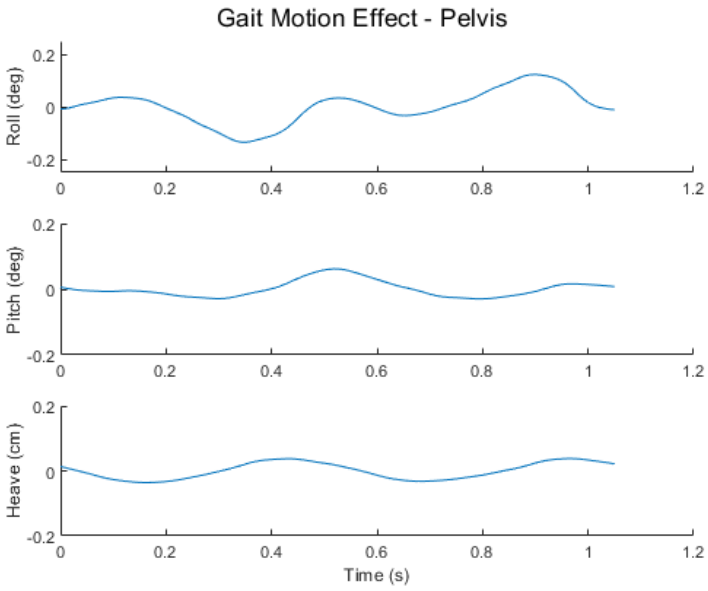

그림 3.22: 골반 부위 운동 정보 기반 보행 모션 효과 생성 결과 예시

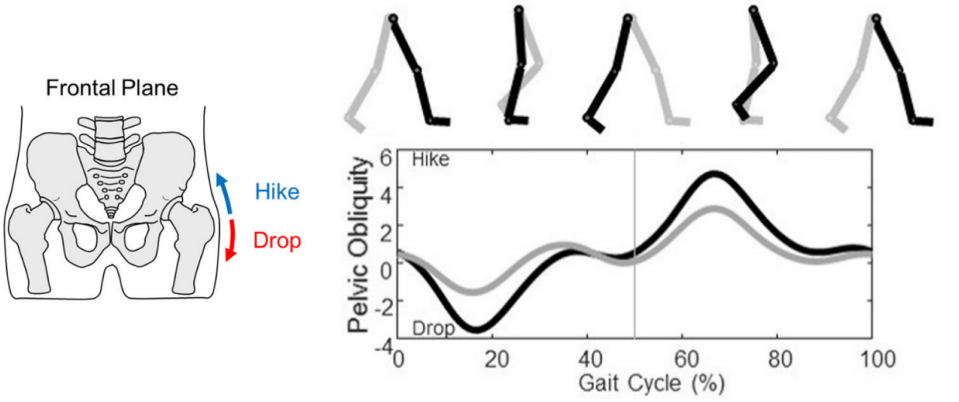

그림 3.23: 보행시 골반의 roll 방향 움직임 (pelvic obliquity) 출처: [5]

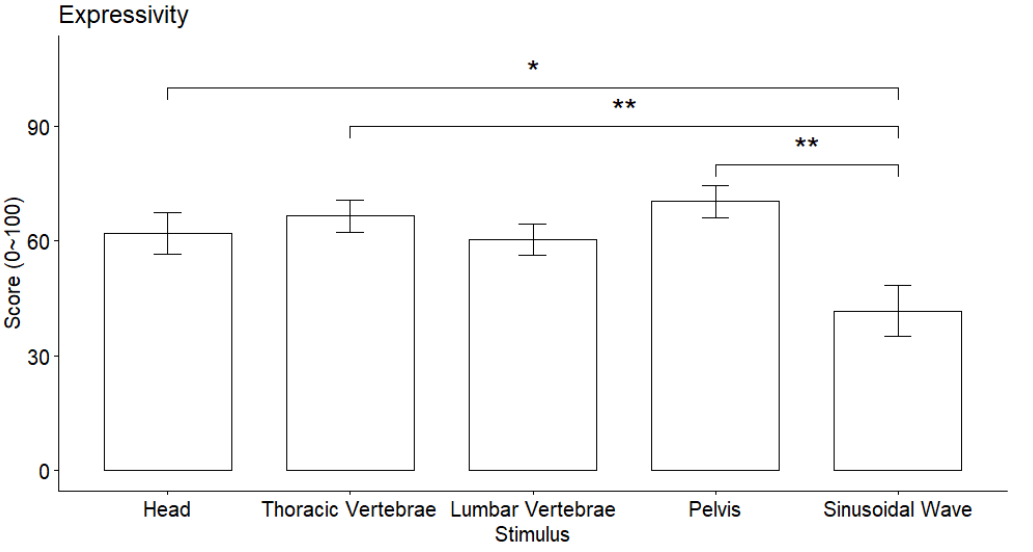

그림 3.24: 보행 모션 효과 표현력 평가 결과 (*: p-value <0.05, **: p-value <0.01)

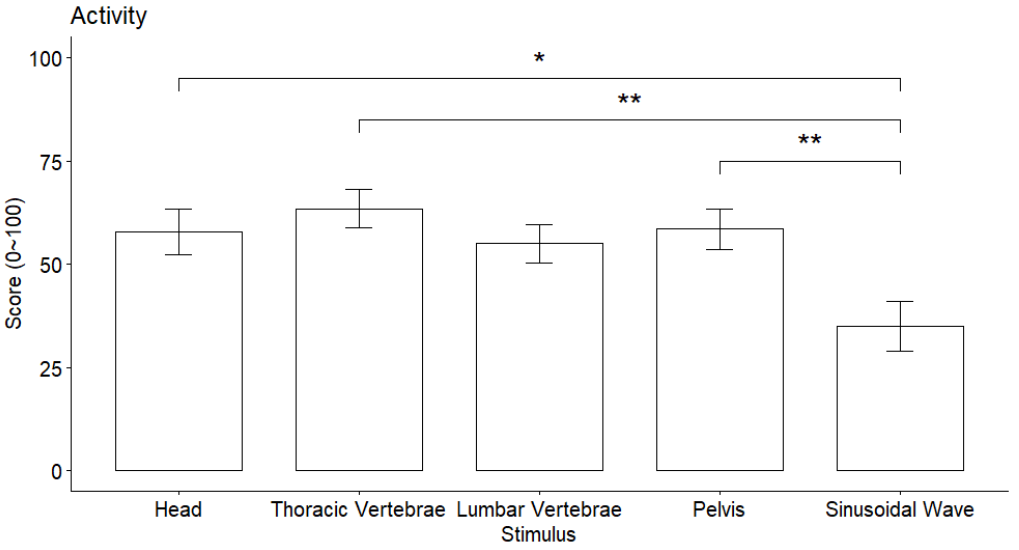

그림 3.25: 보행 모션 효과 능동성 평가 결과 (*: p-value <0.05, **: p-value <0.01)

	Head	Thoracic Vertebrae	Lumbar Vertebrae	Pelvis	Total
Amp. Scaling Ration (Mean ± Stdev.%)	80.0 ± 22.5	80.3 ± 27.0	77.5 ± 15.6	75.9 ± 25.3	78.5 ± 23.1

표 3.2: 측정 부위별 생성 보행 모션 효과 scaling 비율의 평균 및 표준편차

겠다. 사인파를 기반으로 생성한 모션 효과의 평균 점수는 35.1점 이었으나 보행 정보를 기반으로 생성한 모션 효과들의 평균 점수는 모두 55점 이상의 점수를 보였다. ANOVA test 결과 $F(4, 16) = 3.57$, p-value가 0.03으로 유의 수준 0.05 이하의 값을 가지면서 자극에 따른 능동성 평가가 유의미한 차이를 보이는 것을 확인할 수 있었다. Tukey 방법으로 post-hoc test를 진행한 결과 표현력과 동일하게 요추를 제외한 나머지 모든 부위의 보행 동작을 통해 생성된 모션 효과가 사인파와 유의미한 차이를 보이고 있음을 확인할 수 있었다. 하지만 이 역시 인간 보행 동작을 통해 생성된 모션 효과 간에는 통계적으로 유의미한 차이를 확인할 수 없었다.

3.2.6 토의

진폭을 조절하였을 때 원본 모션 효과 대비 비율을 조사한 결과를 표 3.2에서 확인할 수 있다. 머리, 흉추 부위의 움직임을 기반으로 생성한 모션 효과는 scaling

은 80% 수준임에 반해 요추 및 골반의 모션 효과는 76, 78% 수준으로 비교적 더 작게 scaling 되었음을 확인할 수 있다. 이는 골반과 요추의 모션 효과의 크기가 머리와 흉추의 모션 효과 크기보다 비교적 더 큰 경향성이 있어 사람들이 더 많이 줄이고자 했던 것으로 보인다. 실제로 Imai et al.은 보행 중 척추가 damper 역할을 하게 되면서 상반신으로 갈 수록 움직임이 더 작아진다고 보고한 바 있다[33].

본 실험 결과를 살펴보면 특정 부위의 보행 동작이 모션 효과를 만드는데 최적이라고 말하기에는 근거가 불충분하다고 할 수 있다. 표현력, 능동성 평가 모두 보행 동작 기반 모션 효과들 간의 평가 점수의 통계적 유의성을 보이지 못했기 때문이다. 이는 골반을 제외한 다른 부위 모션 효과의 특징이 뚜렷하지 않다는 점이 원인으로 작용한 것으로 보인다. 다만 사인파와 비교하였을 때 요추와 사인파 간에는 통계적으로 유의미한 차이를 보이지 못했고 흉추와 골반 동작을 기반으로 만든 모션 효과의 p-value가 0.01보다 작은 것에 비해 머리 동작을 기반으로 만든 모션 효과는 p-value가 0.01보다는 크므로 4개 부위 중 흉추와 골반이 가장 좋은 평가를 받았다고 할 수 있다. 또한 표현력과 능동성을 합산하여 평가하였을 때 흉추가 가장 좋은 평가를 받은 것으로 나타났다. 이를 근거로 이후 4.1절에서 이루어진 모션 효과 수집은 흉추 동작을 기반으로 생성한 모션 효과를 대상으로 이루어졌다.

3.2.7 결론

본 실험은 머리, 흉추, 요추, 골반 부위의 보행 중 움직임을 기반으로 생성한 모션 효과와 사인파로 생성한 모션 효과간의 표현력과 능동성 성능을 평가하였다. 특정 부위의 동작 정보로 생성한 모션 효과가 더 좋다는 결과는 얻지 못하였지만 실제 보행 운동을 기반으로 만든 모션 효과가 사인파로 생성한 보행 모션 효과보다 표현력과 능동성 측면에서 모두 더 높은 평가를 받았다. 이를 통해 3.1 절에서 제안한 실제 보행 운동 기반으로 모션 효과를 생성하는 방법이 사인파로 표현할 수 없는 보행 운동의 인지적 특징을 표현할 수 있다는 점을 확인하였다.

IV. 보행 동작 효과 공간 기반 보행 동작 효과 생성

효율적인 보행 모션 효과를 생성하기 위해서는 모션 효과 생성에 필요한 정보량을 줄이면서 다양한 보행의 특징을 표현할 수 있어야한다. 모션 효과는 자유도가 높은 정보이기 때문에 모션 효과를 생성하는데 필요한 정보량이 많다. 이 때문에 다양한 보행 모션 효과를 생성하는데에도 많은 정보가 필요하다. 특히 가상 캐릭터를 대상으로 한 보행 모션 효과 생성은 III 장과 같은 실제 보행 정보가 없기 때문에 큰 어려움으로 작용한다. 캐릭터의 신체적 특징이 다양할 수록 표현해야하는 보행 동작 특징도 다양해지기 때문에 더 많은 정보를 필요로 하게 된다. 이에 본 절에서는 보행 모션 효과를 효율적으로 생성할 수 있도록 PCA를 이용하여 모션 효과 생성에 필요한 정보량을 축약한 연구를 소개하고자 한다. 본 절에는 축약된 정보를 이용하여 보행 모션 효과의 특징을 설명할 수 있는지 여부와 축약된 정보로 생성한 모션 효과의 인지적 성능에 대한 평가 실험 결과를 포함하고 있다.

4.1 보행 동작 효과 dataset 수집

이전 dataset 수집에서는 '걷기' 동작 만을 수집하였지만 이번 dataset 수집은 '걷기' 이외의 보행 동작까지 수집하여 다양한 보행 유형을 표현할 수 있는 모델을 구축하고자 했다.

먼저 수집할 보행 유형을 선정하기 위해 Blizzard Entertainment 사의 1인칭 슈팅 게임인 'Overwatch'와 Epic Games 사의 멀티플레이어 온라인 배틀 아레나 게임인 'Paragon'에 등장하는 캐릭터들의 보행 동작을 수집하였다. 이 게임들은 다양한 인종, 종족의 캐릭터들이 등장하여 다양한 체형의 캐릭터들로부터 보행 동작들을 취득할 수 있으므로 조사 대상으로 선정되었다. 이족 보행을 하는 인간형 캐릭터를 대상으로 조사를 진행하였다. Overwatch 캐릭터 22명, Paragon 캐릭터 32명, 총 54명의 캐릭터들의 보행 동작 영상을 수집하여 이들을 분류하였다. 분류

된 보행 유형은 총 5가지였다: 걷기 (walk), 조깅 (jog), 발구르며 뛰기 (stump), 오리걸음 (waddle), 전력 질주 (sprint).

위 선정된 보행 유형에 대해서 실제 인간 보행 운동의 측정 기록을 수집하였다. 22-26세 남성 피험자 10명을 (평균 신장: 175.5 cm, 평균 체중: 70.3 kg) 대상으로 데이터 수집을 진행하였다. 본 데이터 수집에 참가한 피험자들에게는 4만원의 사례금을 지급하였다. 피험자들은 실험을 진행하는데 앞서 이전에 분류한 5가지 보행 유형에 대한 영상을 보게 된다. 해당 영상은 이전에 분류한 게임 캐릭터 보행 영상과 함께 각 보행 유형의 이름을 보여준다. 피험자는 영상을 본 뒤에 약 110m 편도 직선 구간을 영상의 게임 캐릭터를 모방하여 이동하게 되고 그 동안 동작의 정보를 수집하였다. 흉추 부위에 E2BOX사의 EBIMU-9DOFV5 AHRS 센서를 (표 3.1 참고) 부착하여 보행 중 센서 기록을 수집하였다. 수집된 센서 기록을 이용하여 보행 유형 별로 3.1절의 방법을 통해 보행 동작 효과를 생성하였다. 생성된 보행 동작 효과는 3.2.4절과 동일한 방법으로 피험자들 본인이 느끼는 보행 움직임의 크기와 모션 효과의 크기가 동일하도록 조절하였다.

4.2 보행 동작 효과 공간 생성

보행 동작 효과들 각각의 특징을 소수의 변인들로 설명할 수 있는 수학적 모델을 구축하기 위해 4.1절에서 수집된 보행 동작들에 PCA를 적용하여 상위 주성분들을 추출하였다. PCA는 주어진 dataset을 linear combination 형태로 가장 유사하게 표현할 수 있는 orthonormal한 주성분들을 찾는 방법으로 N개의 k차원 data, $\mathbf{x}_1, \ldots, \mathbf{x}_N \in \mathbb{R}^k$에 대하여 D개의 주성분 $\tilde{\mathbf{u}}_1, \ldots, \tilde{\mathbf{u}}_D$를 찾는다고 하였을 때 식 4.1와 같이 표현할 수 있다[35].

$$\tilde{\mathbf{u}}_i = \arg\min_{\mathbf{u}_i} \sum_{n=1}^{N} ||\mathbf{x}_n - \tilde{\mathbf{x}}_n||^2 \tag{4.1}$$

$$\text{where } \tilde{\mathbf{x}}_n = \sum_{1}^{D} \alpha_{ni}\mathbf{u}_i, \ \left(\alpha_{ni} \in \mathbb{R}, \mathbf{u}_i \in \mathbb{R}^k\right)$$

보행 모션 효과에 대해 PCA를 적용하면 고차원의 모션 효과 정보 $\mathbf{x}_n$을 근사하여 근사 모션 효과 $\tilde{\mathbf{x}}_n$을 주성분 $\tilde{\mathbf{u}}_i$와 주성분 계수α_{ni}만으로 생성할 수 있게 된다. 또한

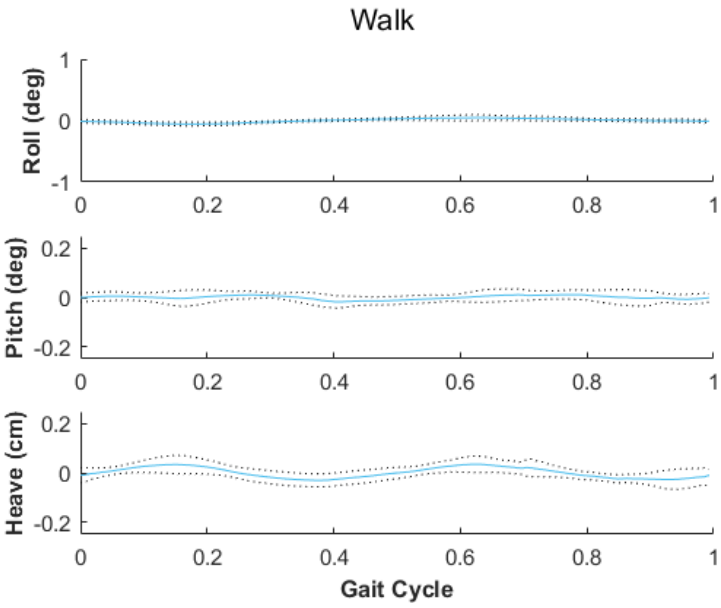

그림 4.1: 걷기 (walk)의 평균 모션 효과(파란색 실선)와 표준 편차 영역 (점선 영역)

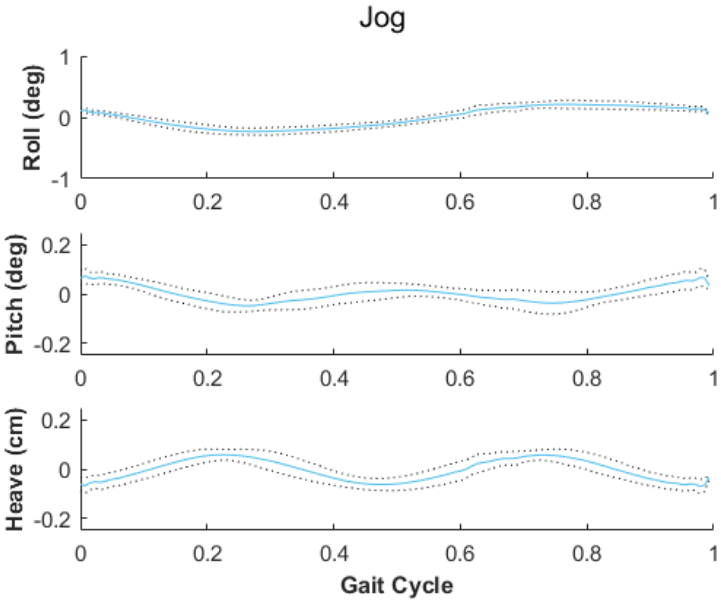

그림 4.2: 조깅 (jog)의 평균 모션 효과(파란색 실선)와 표준 편차 영역 (점선 영역)

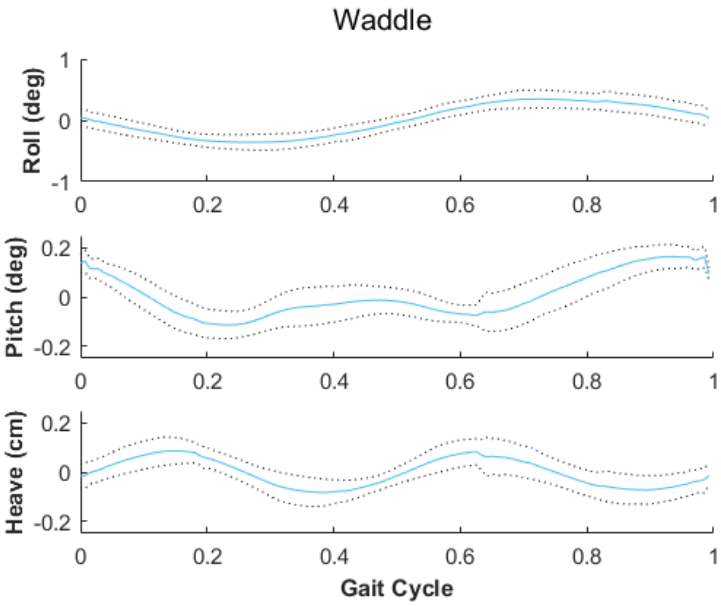

그림 4.3: 오리걸음 (waddle)의 평균 모션 효과(파란색 실선)와 표준 편차 영역 (점선 영역)

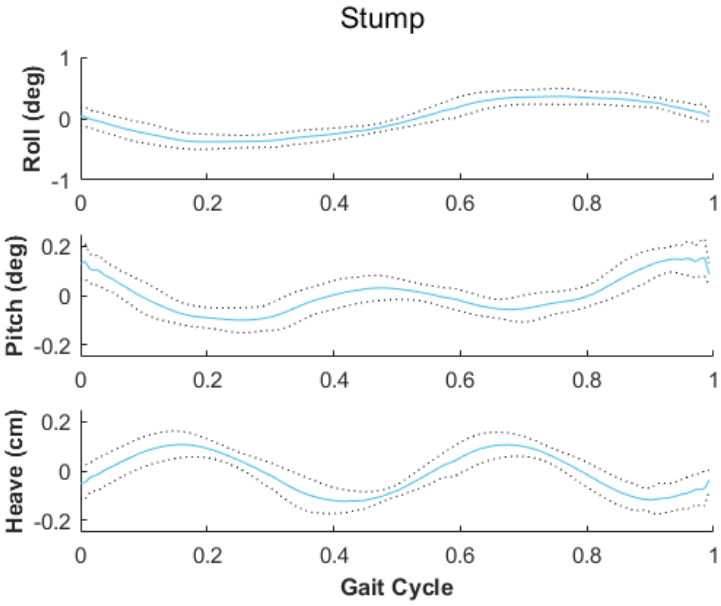

그림 4.4: 발 구르며 뛰기 (stump)의 평균 모션 효과(파란색 실선)와 표준 편차 영역 (점선 영역)

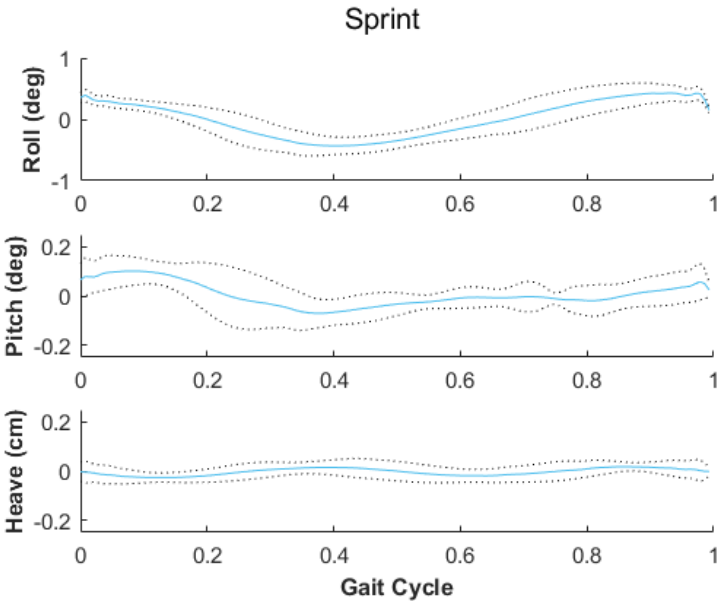

그림 4.5: 전력질주(sprint)의 평균 모션 효과(파란색 실선)와 표준 편차 영역 (점선 영역)

근사 보행 모션 효과의 분포를 주성분 계수로 표현할 수 있게 된다.

PCA 과정을 거치기 이전에 4.1절에서 수집한 모든 보행 모션 효과의 초기 위상을 일치시키고 시간을 정규화하는 과정을 거쳤다. 모션 효과의 초기 위상이 모두 달라 분산이 커지게 되면 분산을 이용하는 PCA[35]를 시행하였을 때 주성분의 수가 많아질 수있다. 또한 수집한 피험자의 보행 주기가 다르기 때문에 입력 차원이 맞지 않아 PCA를 진행할 수 없어 초기 위상과 시간 정규화 과정을 진행하였다. 각 과정을 거친 결과는 그림 4.6에서 확인할 수 있다.

초기 위상은 수집한 모션 효과들 중 하나를 기준 모션 효과 $\mathbf{f}_{std}[n]$로 선정하여 이 모션 효과의 위상에 맞추었다. $\mathbf{f}_{std}[n]$와 초기 위상을 맞추고자 하는 모션 효과 $\mathbf{f}[n]$에 대해 식 4.2, 4.3과 같이 모션 효과 $\hat{\mathbf{f}}_{std}[n]$과 $\hat{\mathbf{f}}[n]$를 정의하였다.

$$\hat{\mathbf{f}}_{std}[n] = \begin{cases} \mathbf{f}_{std}[n] & (\text{if } 0 < t < N_{std},\ N_{std}\text{: a period of the } \mathbf{f}_{std}[n]) \\ 0 & (otherwise) \end{cases} \tag{4.2}$$

Comp. #1	Comp. #2	Comp. #3	Comp. #4	Comp. #5	Comp. #6
47.52%	36.76%	4.50%	3.80%	1.52%	1.20%

표 4.1: 추출된 성분별 분산 설명 비율

$$\hat{\mathbf{f}}[n] = \begin{cases} \mathbf{f}[n] & (\text{if } 0 < t < N,\ N\text{: a period of the } \mathbf{f}[n]) \\ 0 & (otherwise) \end{cases} \tag{4.3}$$

$\hat{\mathbf{f}}_{std}[n]$과 다른 모션 효과 $\hat{\mathbf{f}}[n]$ 간의 $\mathbf{S}(\hat{\mathbf{f}}_{std}, \hat{\mathbf{f}}, \tau)$ 함수가 최대값을 가지는 τ 값인 $\tilde{\tau}$를 산출하였다. $\tilde{\tau}$는 두 모션 효과간의 시간 차라 할 수 있으므로 이를 이용하여 $\mathbf{f}_{new}[n] = \mathbf{f}\left[n + \tilde{\tau}\right]$와 같이 보정하였다.

주기는 수집한 보행 모션 효과들 중 가장 긴 139 sample (sampling rate 100Hz, 1.39초)로 맞추고자 모든 모션 효과에 139 / 원래 주기 비율로 MATLAB의 'resample'[36] 기능을 이용하여 resampling 처리를 하였다. 초기 위상을 맞추기 위해 기준 모션 효과를 임의로 하나 선정하여 이 모션 효과의 위상에 맞추었다.

또한 보행 모션에서 roll, pitch, heave 모션이 독립적으로 이루어지는 것이 아니라 동시에 일어나는 것이므로 PCA 분석시 각 data의 roll, pitch, heave 정보를 결합시켜 분석을 진행할 필요가 있었다. 이에 주기가 N인 보행 모션 효과 $\mathbf{f}[n] = [f_{roll}[n], f_{pitch}[n], f_{heave}[n]]$를 PCA에 입력하는 data $\mathbf{x}$로 식 4.4 같이 정의하였다.

$$\begin{aligned} \mathbf{x} &= \left[{C'_{roll}}^T, {C'_{pitch}}^T, {C'_{heave}}^T\right]^T \\ C'_{roll} &= [f_{roll}[0], \ldots, f_{roll}[N-1]]^T \\ C'_{pitch} &= [f_{pitch}[0], \ldots, f_{pitch}[N-1]]^T \\ C'_{heave} &= [f_{heave}[0], \ldots, f_{heave}[N-1]]^T \end{aligned} \tag{4.4}$$

PCA결과 주성분들을 이용하여 모션 효과를 재합성할 때는 식 4.1의 $\tilde{\mathbf{x}}_n$와 같이 연산 후 결합된 roll, pitch, heave 정보로 다시 분할하였다.

PCA 결과 전체 모션 효과 dataset의 분산 중 95.3%를 설명할 수 있는 6개의 주성분을 추출할 수 있었다. 표 4.1는 추출된 각 성분들의 분산 설명 비율을 나타내

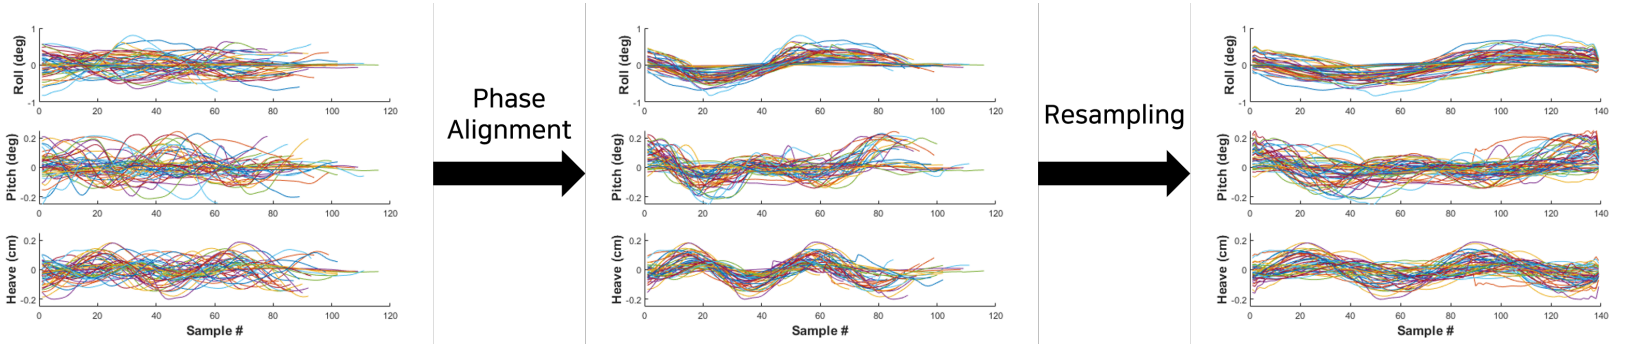

그림 4.6: 보행 모션 효과 시간 정규화 및 위상 일치 과정

Axis	Roll (deg)	Pitch (deg)	Heave (cm)
P-P Amplitude	0.64	0.22	0.16
Approximated Motion RMSE (amplitude ratio)	0.024 (3.8%)	0.024 (10.9%)	0.015 (9.4%)

표 4.2: 원본 보행 모션 효과의 p-p 진폭 및 PCA 주성분을 통한 근사 모션 효과의 RMSE

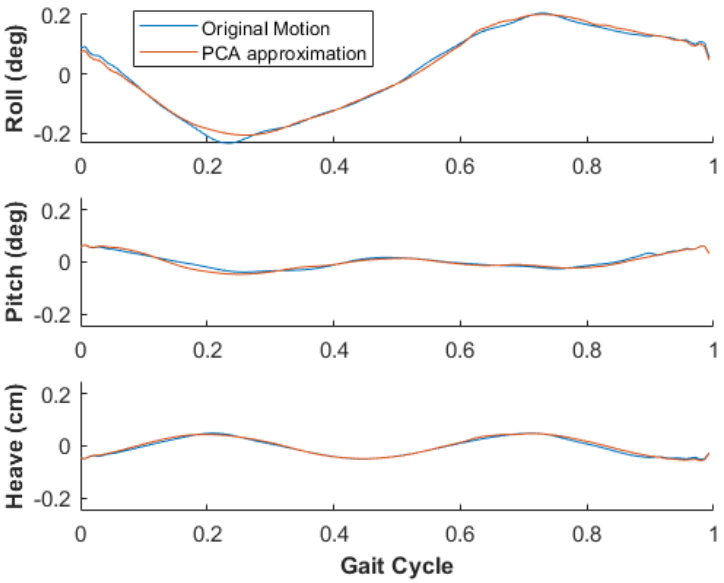

그림 4.7: 원본 모션 효과와 PCA 근사 모션 효과 간 비교

고 있다. 이들을 가지고 실제 모션 효과를 근사하였을 때 표 4.2와 같이 roll, pitch, heave 축별로 진폭 대비 3.8%, 10.9%, 9.4% 수준의 error를 보였다.

PCA 근사 후 주성분 계수 내에 보행 유형의 정보를 그대로 가지고 있을지 검증해보았다. 근사 모션 효과들은 주성분과 주성분 계수 정보로 생성할 수 있으며 동일 dataset을 기반으로 생성한 근사 모션 효과들이라면 주성분은 동일하므로 모션 효과들 간의 차이는 주성분 계수로 설명할 수 있다. 따라서 각 근사 모션 효과의 고유한 특징 정보는 주성분 계수가 가지고 있다고 할 수 있다. 보행 모션 효과에서 PCA를 통해 근사된 모션 효과가 보행 정보의 특징을 크게 잃지 않았다면 주성분 계수에 각 보행 유형의 특징에 대한 정보가 있을 것이므로 주성분 계수만으로 해당 근사

	F(4, 6)	P-value
Component 1 coefficient	18.2	0.002
Component 2 coefficient	25.0	0.001
Component 3 coefficient	1.2	0.404
Component 4 coefficient	11.4	0.006
Component 5 coefficient	8.9	0.011
Component 6 coefficient	1.9	0.238

표 4.3: 보행 유형에 따른 주성분 계수 분포에 대한 ANOVA test 결과

모션 효과가 어떤 보행 유형을 표현하고자 하였는지 구분이 가능할 것이다. 실제로 보행 유형에 따라 주성분 계수 분포에 대한 ANOVA test를 시행하였을 때 결과를 나타낸 표 4.3를 살펴보면 유의 수준 0.05를 기준으로 주성분 1, 2, 4, 5번에 대한 계수 분포가 보행 유형에 따라 유의미한 차이를 보이고 있음을 확인할 수 있었다.

실제로 주성분 계수를 이용하여 보행 유형을 구분할 수 있을 지 확인해보고자 support vector machine (SVM) 모델로 classifier를 구축하고 그 성능을 검증해보았다. SVM은 각 training data에 입력 정보와 그에 대응하는 label 정보를 모두 요구하는 supervised learning에 해당하는 기계 학습 모델로 서로 다른 label을 가진 데이터 분포들을 구분할 수 있는 hyperplane을 학습하여 입력 정보를 분류하는 모델이다[35]. 본 연구에서 구축한 classifier는 분류하고자 하는 근사 모션 효과의 6개의 주성분 계수들을 입력받고 (식 4.1의 $\alpha_{n1}, \ldots, \alpha_{n6}$) 해당 모션 효과의 보행 유형을 label로 출력하는 모델이다. 4.1절 에서 수집한 모든 모션 효과의 PCA 근사 결과로 생성된 주성분 계수들과 그에 대응되는 보행 유형을 training data로 이용하여 학습을 진행하였다. 학습 결과 생성된 classifier로 training data를 분류한 결과 그림 4.8과 같이 92%의 높은 정확도를 가지고 분류하였다. 이를 통해 보행 유형에 따라 주성분 계수 분포를 잘 분류할 수 있는 hyperplane이 존재한다는 것을 확인할 수

		SVM Prediction				
		Walk	Jog	Waddle	Stump	Sprint
Motion Effect	Walk	100%	-	-	-	-
	Jog	-	90%	-	10%	-
	Waddle	-	10%	90%	-	-
	Stump	-	10%	-	80%	10%
	Sprint	-	-	-	-	100%

그림 4.8: SVM 분류기의 보행 모션 효과에 대한 confusion matrix

있었다. 즉, 주성분 계수는 보행 유형에 대한 정보를 담고 있다고 할 수 있다. 또한 특정 보행 유형 분포 영역 내의 주성분 계수로 생성한 모션 효과는 해당 보행 유형의 특징을 가지고 있을 가능성이 존재한다.

4.3 사용자 평가 실험

본 평가 실험에서는 PCA를 통해 근사된 보행 모션 효과가 원본 모션 효과의 인지적 특성을 얼마나 보존하고 있는지 평가하며 각 보행 유형의 주성분 계수 분포 영역 내에서 생성한 모션 효과가 인지적으로 유효한 보행 유형의 특징을 실제로 가지고 있는지 확인해보고자 한다.

4.3.1 실험 참여자

본 실험에는 19세에서 28세의 남성 7명, 여성 3명 총 10명의 전정 감각에 이상이 없는 일반인들로 구성되었다. 본 실험 참가자들 중 4.1절에 참가한 피험자들은 포함되지 않았다. 본 실험 참가자에게는 사례금 2만원이 지급되었다.

4.3.2 실험 방법

실험은 크게 training session, test session, main session 1, 2, 3 총 5가지 세션으로 구성되어있다. 먼저 training session에서는 보행 모션 효과에 익숙해질 수 있도록 각 5가지 보행 유형별로 5가지 모션 효과, 총 25개 모션 효과를 피험자에게

제공하면서 각 보행 모션 효과가 표현하고자 했던 보행 유형의 이름과 이에 대응되는 이전 보행 모션 효과 수집에 사용된 게임 캐릭터 보행 모션 영상을 보여주었다. 피험자들이 보행 유형별 모션 효과의 특징을 잘 비교할 수 있도록 training session을 6개의 subsession으로 나눠 각 subsession에서는 보행 유형별로 1개씩 무작위 순서로 모션 효과를 제공하였다. 약 30초의 간격을 두고 모션 효과를 재생하였다.

test session에서는 이전 training session으로 피험자들이 성실히 학습하였는 지 확인하고자 진행하였다. 이전 training session에 사용된 모션 효과들 중 각 보행 유형별로 2개씩 선정하여 무작위 순서로 재생하면서 각 모션 효과가 어떤 보행 유형을 표현한 것인지 구두로 답해달라고 요청하였다.

각 main session 1, 2, 3에서는 3가지 보행 모션 효과 생성 방법 및 5가지 보행 유형 별로 3개 모션 효과, 총 45개의 보행 유형을 피험자에게 제공하였다. 각 main session은 3개의 subsession으로 나뉘어 각 subsession별로 보행 모션 효과 생성 방법 및 보행 유형 조합을 각각 1개씩 무작위 순서로 제공한다. 피험자는 보행 모션 효과를 느껴보고 각 보행 모션 효과가 5가지 보행 유형 중 어떤 보행 운동을 표현하고자 했을지 설문조사를 진행하였다. 해당 설문지는 5가지 보행 유형 및 '어떠한 것도 아니다'라는 선택지로 구성되었다. 첫번째 main session은 피험자들이 아직 보행 모션 효과에 충분히 training이 이루어지지 않았을 것이라 판단하여 실험 결과에 포함시키지 않았다.

4.3.3 실험 자극

본 실험 자극의 구성은 그림 4.9에 나타나있다. 본 실험에서 사용된 모션 효과들은 크게 3가지 방법으로 생성되었다: 1) 기존 보행 모션 효과 dataset에서 선정된 원본 모션 효과 (S_o), 2) 원본 모션 효과를 PCA를 통해 근사한 모션 효과 (S_a), 3) 보행 유형별 모션 효과의 주성분 계수 분포 영역 내에서 주성분 계수를 random sampling하여 생성된 모션 효과 (S_r). S_o는 기존 보행 모션 효과 dataset에서 선정된 8개의 모션 효과이다. 선정 기준은 주기가 N인 resampling된 모션 효과 $\mathbf{f}[n] \in \mathbb{R}^3$에 대해 각 보행 유형별 평균 모션 효과 $\mathbf{f}_{mean}[n] \in \mathbb{R}^3$와의 $\sum_{n=0}^{N-1} \|\mathbf{f}[n] - \mathbf{f}_{mean}[n]\|^2$의

값이 작은 순으로 상위 8개의 모션 효과를 사용하였다. 이들 중 1, 3, 5, 7, 8번째 모션 효과를 training session에 사용하였고 2, 4, 6번째 모션 효과들은 main session에 사용되었다. 이때 모션 효과의 주기는 resampling을 적용하기 전의 주기를 적용하여 모션 효과의 주기에 의해 해당 보행 유형으로 인지하지 못하는 문제를 방지하였다. S_a는 main session 실험 자극으로 선정된 원본 모션 효과들을 근사한 모션 효과로 모션의 주기는 각 원본 모션 효과에 resampling을 적용하기 전 주기를 사용하였다.

S_r을 생성하기 위한 보행 유형별 주성분 계수 분포 영역 (D_m)은 보행 유형 (m), m 유형에 대한 각 주성분 계수의 평균 ($\mu_{m,1}, \ldots, \mu_{m,6}$), m유형에 대한 각 주성분 계수의 표준편차 ($\sigma_{m,1}, \ldots, \sigma m, 6$)를 통해 식 4.5 같이 정의한다.

$$D_m = \left\{ [\alpha_1, \ldots, \alpha_6]^T \mid \mu_{m,i} - \sigma_{m,i} < \alpha_i < \mu_{m,i} + \sigma_{m,i} \right\} \tag{4.5}$$

이 범위 내에 포함된 무작위 주성분 계수를 만들고자 각 원소가 –1과 +1사이 범위의 값을 가지는 6차원 random vector $\boldsymbol{\beta} \in \mathbb{R}^6$를 이용하여 S_r을 생성하기 위한 주성분 계수 $\alpha_{random,i}, i \in \{1, \ldots, 6\}$를 식 4.6와 같이 정의하였다.

$$\alpha_{random,i} = \mu_{m,i} + \sigma_{m,i}\beta_i \tag{4.6}$$
$$\boldsymbol{\beta} = [\beta_1, \ldots, \beta_6]^T$$

이때, μ_i, σ_i는 각 보행 유형별 i번째 주성분의 계수이다. random sample로 생성한 $\boldsymbol{\beta}$ 값들 중 일부가 서로 유사할 수 있으므로 이를 방지하기 위해 각 edge의 길이가 2인 6차원 hypercube 내의 임의의 두 점을 찍었을 때 이 점들 사이 평균 거리가 1.94라는[37] 점을 고려하여 $\boldsymbol{\beta}$간의 거리가 이보다 큰 $\boldsymbol{\beta}$들을 각 보행 유형별로 3개씩 만들어 모션 효과를 생성하였다. Random sampling을 통해 생성된 모션 효과의 주기는 원본 보행 모션 효과 dataset의 각 보행 유형별 평균 주기(μ_{T_m})와 표준 편차(σ_{T_m})를 이용하여 '$\mu_{T_m} - \sigma_{T_m}$'와 '$\mu_{T_m} + \sigma_{T_m}$' 사이의 임의의 값을 사용하였다. 이는 주기에 의해 해당 보행 유형으로 느끼지 못하는 것을 방지해야 하면서도 주기에 의해서만 보행 유형을 판단하는 것을 막기 위해 이를 시행하였다.

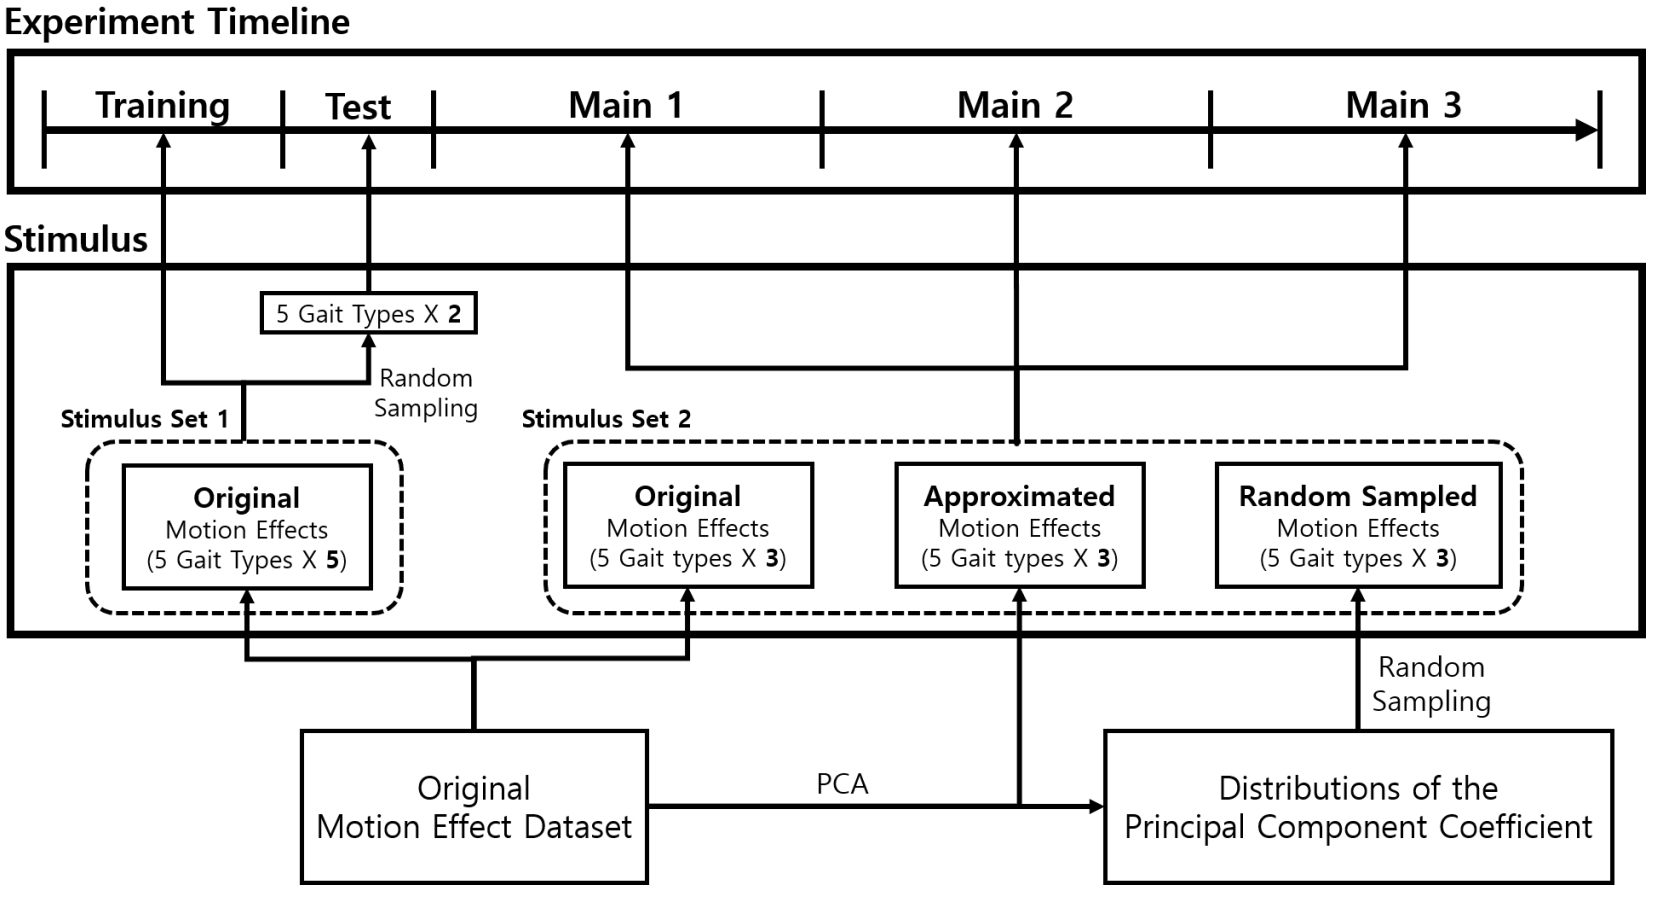

그림 4.9: 4.3 절 실험의 각 세션별 실험 자극 구성

		Response					
		Walk	Jog	Waddle	Stump	Sprint	Nothing
Original Motion Effect	Walk	83%	-	-	2%	-	15%
	Jog	7%	58%	5%	17%	2%	12%
	Waddle	-	28%	32%	22%	-	18%
	Stump	-	7%	25%	65%	-	3%
	Sprint	-	2%	2%	3%	83%	10%

그림 4.10: 원본 보행 모션 효과 분류 confusion matrix

		Response					
		Walk	Jog	Waddle	Stump	Sprint	Nothing
Approximated Motion Effect	Walk	83%	-	-	-	-	17%
	Jog	8%	55%	18%	13%	-	5%
	Waddle	-	18%	23%	40%	-	18%
	Stump	-	3%	50%	47%	-	-
	Sprint	-	7%	3%	3%	82%	5%

그림 4.11: 근사 보행 모션 효과 분류 confusion matrix

		Response					
		Walk	Jog	Waddle	Stump	Sprint	Nothing
Random Sampled Motion Effect	Walk	88%	2%	2%	-	-	8%
	Jog	5%	65%	12%	18%	-	-
	Waddle	3%	12%	63%	15%	-	7%
	Stump	-	13%	48%	37%	-	2%
	Sprint	-	12%	7%	3%	60%	18%

그림 4.12: Random sampling 보행 모션 효과 분류 confusion matrix

4.3.4 실험 결과

그림 4.10, 4.11, 4.12를 통해 각 모션 효과별 분류 결과의 정확도를 살펴보자. 정확도는 동일한 자극들 중 실제 응답이 올바른 경우의 비율이다. 걷기는 원본, 근사, random sampling 모션 효과 3가지 모두 83%이상 올바른 분류를 하였고 조깅은 55%이상 올바른 분류를 하였다. 전력질주는 random sampling에 대해 60%의 정확도를 보인 것을 제외하면 원본 모션 효과와 근사 모션 효과 모두 82% 이상의 높은 정확도를 보였다. 하지만 오리걸음과 발 구르며 뛰기에 대해서는 3가지 유형 모두 분류를 제대로 하지 못하고 서로 혼동하고 있는 모습을 보였다. 전체 응답중 어떠한 것도 아니라고 평가한 항목을 살펴보면 원본 모션 효과 12%, 근사 모션 효과 9%, random sampling 모션 효과 7%로 대다수의 모션 효과를 특정한 보행을 표현한 모션 효과로 인지하였음을 확인할 수 있었다.

	Walk	Jog	Waddle	Stump	Sprint
Original	93%	61%	50%	59%	98%
Approximated	91%	66%	25%	45%	100%
Random Sampled	91%	63%	48%	50%	100%

표 4.4: 모션 효과 분류 정밀도

다음으로 표 4.4을 통해 정밀도를 살펴보자. 정밀도는 동일한 응답들 중 실제 응답이 올바른 경우의 비율이다. walk와 sprint는 각각 최소 91%, 98%의 높은 정밀도를 보였다. 조깅은 61% 이상의 정밀도를 보이고 있다. 한편, 오리걸음과 발 구르며 뛰기는 최소 25%에서 최대 59%정도로 낮은 정밀도를 보여주고 있었다. 오리걸음과 발구르기에 대해 정확도와 정밀도 모두 높지 않은 수치를 보이고 있어 원본, 근사, random sampling 관계 없이 이들을 혼동하고 있음을 알 수 있다. 이에 따라 오리걸음과 발 구르며 뛰기를 구분하지 않고 동일한 유형으로 가정하여 다시 분석하였다.

그림 4.13, 4.14, 4.15를 통해 오리걸음과 발 구르며 뛰기를 동일 유형으로 간

		Response				
		Walk	Jog	Waddle +Stump	Sprint	Nothing
Original Motion Effect	Walk	83%	-	2%	-	15%
	Jog	7%	58%	22%	2%	12%
	Waddle +Stump	-	18%	72%	-	10%
	Sprint	-	2%	5%	83%	10%

그림 4.13: 원본 보행 모션 효과 분류 confusion matrix

		Response				
		Walk	Jog	Waddle +Stump	Sprint	Nothing
Approximated Motion Effect	Walk	83%	-	-	-	17%
	Jog	8%	55%	32%	-	5%
	Waddle +Stump	-	11%	80%	-	9%
	Sprint	-	7%	7%	82%	5%

그림 4.14: 근사 보행 모션 효과 분류 confusion matrix

		Response				
		Walk	Jog	Waddle +Stump	Sprint	Nothing
Random Sampled Motion Effect	Walk	88%	2%	2%	-	8%
	Jog	5%	65%	30%	-	-
	Waddle +Stump	2%	13%	82%	-	4%
	Sprint	-	12%	10%	60%	18%

그림 4.15: Random sampling 보행 모션 효과 분류 confusion matrix

	Walk	Jog	Waddle + Stump	Sprint
Original	93%	61%	84%	98%
Approximated	91%	66%	81%	100%
Random Sampled	91%	63%	80%	100%

표 4.5: 오리걸음과 발 구르며 뛰기 병합 후 모션 효과 분류 정밀도

주했을 때 정확도를 살펴보자. 이 경우 오리걸음과 발 구르며 뛰기 유형의 정확도는 원본, 근사, random sampling 3가지 모두 72% 이상의 높은 정확도를 보여주고 있음을 확인할 수 있다.

다음으로 표 4.5을 통해 정밀도를 살펴보자. 오리걸음과 발 구르며 뛰기를 동일 유형으로 취급하였을 때 병합된 유형의 정밀도가 최소 80% 이상의 높은 수치를 보이고 있음을 확인할 수 있다. 두 가지 보행 유형을 분리하였을 때 정확도 및 정밀도가 크게 떨어지고 병합하였을 때 두 수치가 높은 값을 가리키고 있다는 점으로 미루어보아 피험자들은 두 보행 유형을 구분하지 못했다고 할 수 있다. 두 보행 유형을 동일 유형으로 간주한다면 원본, 근사, random sampling 모션 효과 모두 전력질주를 제외한 나머지 보행 모션 효과의 유형별 특징을 유사한 수준으로 인지하고 구분할 수 있음을 확인할 수 있다.

4.3.5 토의

피험자들이 오리걸음과 발 구르며 뛰기를 구분하지 못하는 결과는 PCA 주성분의 분산 설명 비율과 관련이 있을 것으로 보인다. 주성분 별로 계수 분포에 대해 보행 유형 간 Tukey 검정을 시행하였을 때 두 보행 유형간의 통계적 유의성을 확인할 수 있었던 Comp #5 성분 뿐이었다. 해당 성분은 그림 4.1에서 확인할 수 있듯 보행 모션 효과 dataset 내의 전체 분산 중 1.5% 만을 설명할 수 있었던 성분이기에 모션 효과의 큰 차이를 설명하진 못한다고 할 수 있다. 이 성분에 의한 차이를 느끼지 못했다고 가정하고 나머지 주성분 계수 5개만을 가지고 다시 SVM classifier를 구축 및, 성능 측정을 진행한 결과 그림 4.16에 나타난 것 처럼 사용자 실험 결과와

		SVM Prediction				
		Walk	Jog	Waddle	Stump	Sprint
Motion Effect	Walk	100%	-	-	-	-
	Jog	-	90%	-	10%	-
	Waddle	-	20%	50%	30%	-
	Stump	-	10%	20%	60%	10%
	Sprint	-	-	-	10%	90%

그림 4.16: Comp. #5를 제외하였을 때 SVM 분류기 학습 결과

유사하게 waddle과 stump 간의 혼동이 발생하였음을 확인할 수 있었다.

Random sampling을 통해 생성된 모션 효과 중 sprint 유형의 모션 효과에 대해 정확도가 떨어지는 문제가 있었는데 이는 한 모션 효과가 전체 어떠한 보행 유형으로도 느껴지지 않는다는 응답이 많이 나와 발생한 문제로 보인다. Random sampling 전력 질주 모션 효과들의 어떠한 보행 유형으로도 느껴지지 않는다는 응답 중 55%에 해당하는 응답이 해당 모션 효과로 인해 발생했다. 이 모션 효과는 sprint 모션 효과들 중 평균 모션 효과와 유사하여 진폭이 크지 않은 편이었다. 하지만 training에 사용된 sprint 모션 효과들은 대부분 진폭이 매우 크게 느껴지는 모션이었기에 sprint 보행 유형으로 생각하기 어려웠을 것으로 추측한다.

4.3.6 결론

본 실험은 5가지의 보행 유형을 표현한 보행 모션 효과와 이를 PCA로 근사한 모션 효과, 그리고 근사 모션 효과의 보행 유형별 분포 영역 내에서 random sampling으로 생성한 모션 효과들에 대하여 피험자들이 각 모션 효과의 보행 유형을 얼마나 잘 분류할 수 있을지를 확인하였다. 그 결과 세가지 유형 모두 유사한 수준으로 보행 유형을 분류할 수 있음을 확인하였다.

이를 통해 우리는 크게 2가지 사항을 알 수 있었다. 먼저 PCA를 통해 보행 모션 효과를 근사하였을 때 보행 유형을 인지적으로 구분할 수 있는 특징들을 크게 잃지 않고 보유하고 있다는 점이다. 원본 모션 효과와 이를 근사한 모션 효과들 간

의 보행 유형을 피험자들이 분류한 결과가 크게 다르지 않았기 때문에 근사 후에도 보행 유형 특징을 크게 잃어버리지 않았다고 할 수 있다. 다음은 주성분 계수 분포가 보행 유형의 인지적 특징과 연관이 있다는 점이다. 본 실험에서 각 PCA 근사 모션 효과의 보행 유형별 주성분 계수 분포 내에서 임의로 생성한 모션 효과가 근사 모션 효과와 인지적 분류 성능이 유사하다는 것을 보였다. 즉, 실제 보행 정보를 기반으로 하지 않더라도 각 보행 유형의 주성분 계수 분포 영역 내에 있다면 해당 보행 유형의 인지적 특징을 갖고 있다고 말할 수 있다.

V. 결론

본 논문에서는 인간의 실제 보행 운동을 기반으로 하여 모션 효과를 생성하는 방법을 제안 및 평가하고 PCA를 통해 6개의 주성분들로 축약하여 표현할 수 있다는 것을 보였다. 기존 보행 모션 효과 연구에서는 사인파를 기반으로 생성된 모션 효과를 연구 하였기에 다양한 보행 운동의 특징을 담는데 한계점이 있었다. 본 연구에서는 실제 보행 운동을 기반으로 생성한 모션 효과는 사인파로 생성한 모션 효과로는 표현할 수 없는 보행 운동의 인지적 특성을 표현하였다. 또한 이 방법을 통해 생성된 모션 효과가 사인파 모션 효과와 비교하였을 때 수동적인 모션임에도 불구하고 스스로 보행하는 느낌을 제공하였다. 다양한 보행 특징을 수집하고자 5가지 보행 유형에 대한 모션 효과들을 수집하였고 PCA를 통해 6가지 주성분 계수로 축약하여 원본 모션 효과와 유사한 인지적 특징을 제공하는 근사 모션 효과를 생성할 수 있었다. 또한 모션 효과의 정보량이 모션 효과의 길이에 비례하기 때문에 기존에는 모션 효과의 특징을 비교하는데 어려움이 있었으나 주성분 계수 분포가 보행 유형별 특징과 연관되어 있음을 밝혀내어 보행 모션 효과의 특징을 더 간단하게 표현할 수 있게 되었다.

본 연구로 다양한 보행 특징을 가진 데이터를 수집하고 이를 모션 효과로 생성할 수 있게 되었으며 보행 모션 효과를 구성하는데 필요한 정보량을 줄이면서 보행 모션 효과 사이의 차이를 기존보다 간단하게 설명할 수 있는 수학적 공간도 구축하였다. 이는 모션 효과 콘텐츠 제작자에게 더 사실적이며 다양한 보행 특징을 표현하는 모션 효과를 생성할 수 있게 되었다. 또한, 모션 효과 관련 연구에 있어서는 보행 모션 효과의 다양한 특징을 수집하고 분석할 수 있게 되었다. 하지만 보행 모션 특징이 주성분 계수 분포와 연관성이 있다는 것을 밝혔을 뿐 주성분 계수 분포에 따라 어떤 보행 특징을 갖게 되는지에 대해서는 연구가 필요하다. 향후에는 주성분 계수 분포에 따라 어떤 보행 특징을 갖게되는 지에 대해 연구하여 나아가 필요한 보행 특징에 따라 보행 모션 효과를 생성할 수 있는 방법을 개발하고자 한다.

참 고 문 헌

[1] Tshaka Armstrong. Is 4DX the movie theater experience of the future? https://editorial.rottentomatoes.com/article/is-4dx-the-movie-theater-experience-of-the-future/, 2020. Online; accessed 5 Nov. 2020.

[2] Blizzard Entertainment. Cheers to four years: Dev memories of overwatch. https://playoverwatch.com/en-us/news/23442716/cheers-to-four-years-dev-memories-of-overwatch/, 2020. Online; accessed 5 Nov. 2020.

[3] François Petitjean, Alain Ketterlin, and Pierre Gançarski. A global averaging method for dynamic time warping, with applications to clustering. *Pattern Recognition*, 44(3):678–693, 2011.

[4] Jaebong Lee, Bohyung Han, and Seungmoon Choi. Motion Effects Synthesis for 4D Films. *IEEE Transactions on Visualization and Computer Graphics*, 22(10):2300–2314, 2016.

[5] Cara L Lewis, Natalie M Laudicina, Anne Khuu, and Kari L Loverro. The Human Pelvis: Variation in Structure and Function During Gait. *Anatomical record (Hoboken, N.J. : 2007)*, 300(4):633–642, 2017.

[6] Joseph M. Romano, Takashi Yoshioka, and Katherine J. Kuchenbecker. Automatic filter design for synthesis of haptic textures from recorded acceleration data. In *Proceedings of the 2010 IEEE International Conference on Robotics and Automation*, pages 1815–1821, 2010.

[7] Sunghwan Shin, Reza Haghighi Osgouei, Ki Duk Kim, and Seungmoon Choi. Data-driven modeling of isotropic haptic textures using frequency-decomposed neural networks. In *Proceedings of the 2015 IEEE World Haptics Conference*, pages 131–138, 2015.

[8] Reza Haghighi Osgouei, Sunghwan Shin, Jin Ryong Kim, and Seungmoon Choi. An inverse neural network model for data-driven texture rendering on electrovibration display. In *Proceedings of the 2018 IEEE Haptics Symposium*, pages 270–277, 2018.

[9] Reza Haghighi Osgouei, Jin Ryong Kim, and Seungmoon Choi. Data-Driven Texture Modeling and Rendering on Electrovibration Display. *IEEE Transactions on Haptics*, 13(2):298–311, 2020.

[10] Arsen Abdulali and Seokhee Jeon. Data-driven modeling of anisotropic haptic textures: Data segmentation and interpolation. In *Proceedings of the 2016 EuroHaptics*, pages 228–239, 2016.

[11] Sunghwan Shin and Seungmoon Choi. Hybrid Framework for Haptic Texture Modeling and Rendering. *IEEE Access*, 8:149825–149840, 2020.

[12] Hyejin Choi, Seongwon Cho, Sunghwan Shin, Hojin Lee, and Seungmoon Choi. Data-driven thermal rendering: An initial study. In *Proceedings of the 2018 IEEE Haptics Symposium*, pages 344–350, 2018.

[13] Hojun Cha, Amit Bhardwaj, Chaeyong Park, and Seungmoon Choi. Random Forest for Modeling and Rendering of Viscoelastic Deformable Objects. In *Proceedings of the 2018 AsiaHaptics*, pages 48–53, 2019.

[14] Amit Bhardwaj, Hojun Cha, and Seungmoon Choi. Data-driven haptic modeling of normal interactions on viscoelastic deformable objects using a random forest. *IEEE Robotics and Automation Letters*, 4(2):1379–1386, 2019.

[15] Jaebong Lee, Bohyung Han, and Seungmoon Choi. Interactive motion effects design for a moving object in 4D films. *Proceedings of the 2016 ACM Conference on Virtual Reality Software and Technology*, pages 219–228, 2016.

[16] Eunsu Goh, Daeyeol Kim, Suyeong Oh, and Chae Bong Sohn. Automatic effect generation method for 4d films. *International Journal of Computing and Digital Systems*, 9(2):281–288, 2020.

[17] Yuhao Zhou, Makarand Tapaswi, and Sanja Fidler. Now you shake me: Towards automatic 4d cinema. In *Proceedings of the 2018 IEEE Conference on Computer Vision and Pattern Recognition*, 2018.

[18] Raphael Abreu, Douglas Mattos, Joel dos Santos, Gheorghita Ghinea, and Debora Muchaluat-Saade. Towards content-driven intelligent authoring of mulsemedia applications. *IEEE Multimedia*, 2020.

[19] Dominik Schmidt, Robert Kovacs, Vikram Mehta, Udayan Umapathi, Sven Köhler, Lung Pan Cheng, and Patrick Baudisch. Level-Ups: Motorized stilts that simulate stair steps in virtual reality. In *Proceedings of the 2015 Conference on Human Factors in Computing Systems*, pages 2157–2160, 2015.

[20] Tomohiro Yokota, Motohiro Ohtake, Yukihiro Nishimura, Toshiya Yui, Rico Uchikura, and Tomoko Hashida. Snow Walking: Motion-Limiting Device that Reproduces the Experience of Walking in Deep Snow. In *Proceedings of the 2015 Augmented Human International Conference*, pages 45–48, 2015.

[21] Hyungki Son, Inwook Hwang, Tae Heon Yang, Seungmoon Choi, Sang Youn Kim, and Jin Ryong Kim. RealWalk: Haptic Shoes Using Actuated MR Fluid for Walking in VR. In *Proceedings of the 2019 IEEE World Haptics Conference*, number July, pages 241–246, 2019.

[22] Masato Kurosawa, Ken Ito, Yasushi Ikei, Koichi Hirota, and Michiteru Kitazaki. Evaluation of airflow effect on a VR walk. In *Proceedings of the 2017 IEEE Virtual Reality*, pages 283–284, 2017.

[23] N Saka, Y Ikei, T Amemiya, K Hirota, and M Kitazaki. Passive arm swing motion for virtual walking sensation. In *Proceedings of the 2016 International Conference on Artificial Reality and Telexistence & Eurographics Symposium on Virtual Environments*, pages 17–23, 2016.

[24] Yasushi Ikei, Seiya Shimabukuro, Shunki Kato, Yujiro Okuya, Koji Abe, Koichi Hirota, and Tomohiro Amemiya. Rendering of virtual walking sensation by a passive body motion. In *Proceedings of the 2014 EuroHaptics*, pages 150–157, 2014.

[25] Seiya Shimabukuro, Shunki Kato, Yasushi Ikei, Koichi Hirota, Tomohiro Amemiya, and Michiteru Kitazaki. Characteristics of virtual walking sensation created by a 3-dof motion seat. In *Proceedings of the 2015 IEEE Virtual Reality Conference*, pages 279–280, 2015.

[26] Yasushi Ikei, Shunki Kato, Kohei Komase, Shogo Imao, Sho Sakurai, Tomohiro Amemiya, Michiteru Kitazaki, and Koichi Hirota. Vestibulohaptic passive stimulation for a walking sensation. In *Proceedings of the 2016 IEEE Virtual Reality*, pages 185–186, 2016.

[27] Koichi Shimizu, Vibol Yem, Kentaro Yamaoka, Gaku Sueta, Tomohiro Amemiya, Michiteru Kitazaki, and Yasushi Ikei. Rendering of Virtual Walking Sensation by a Vestibular Display. In *Proceedings of the 2019 HCII*, pages 36–46, 2019.

[28] Tomohiro Amemiya, Michiteru Kitazaki, and Yasushi Ikei. Pseudo-Sensation of Walking Generated by Passive Whole-Body Motions in Heave and Yaw Directions. *IEEE Transactions on Haptics*, 13(1):80–86, 2020.

[29] Meyer A. Nahon and Lloyd D. Reid. Simulator motion-drive algorithms - A designer's perspective. *Journal of Guidance, Control, and Dynamics*, 13(2):356–362, 1990.

[30] A. V. Oppenheim and R. W. Schafer. *Discrete-time signal processing.* Pearson, 3rd edition, 2010.

[31] Ronald Bracewell. *The Fourier Transform and Its Applications.* McGraw Hill, 3rd edition, 2000.

[32] Hiroaki Sakoe and Seibi Chiba. Dynamic Programming Algorithm Optimization for Spoken Word Recognition. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 26(1):43–49, 1978.

[33] Takao Imai, Steven T. Moore, Theodore Raphan, and Bernard Cohen. Interaction of the body, head, and eyes during walking and turning. *Experimental Brain Research*, 136(1):1–18, 2001.

[34] L. O.D. Christensen, P. Johannsen, T. Sinkjaer, N. Petersen, H. S. Pyndt, and J. B. Nielsen. Cerebral activation during bicycle movements in man. *Experimental Brain Research*, 135(1):66–72, 2000.

[35] Christopher M. Bishop. *Pattern Recognition and Machine Learning (Information Science and Statistics).* Springer-Verlag, Berlin, Heidelberg, 2006.

[36] MathWorks. resample. `https://www.mathworks.com/help/signal/ref/resample.html`, 2020. Online; accessed 24 Nov. 2020.

[37] Eric W. Weisstein. Hypercude Line Picking. https://mathworld.wolfram.com/CubeLinePicking.html, 2020. Online; accessed 24 Nov. 2020.

Acknowledgements

약 8년 동안 포항에서 지내며 지금도 부족하다고 여기는 제가 졸업을 하게 되었습니다. 여러 사람들의 도움이 없었다면 이룰 수 없었을 것이기에 감사를 전해드리고자 합니다. 먼저 부족했던 저를 격려해주시고 지도해주신 최승문 교수님께 감사의 말씀을 드립니다. 글을 잘 못쓴다고 털어 놓았을 때도 함께 고민해 주시며 제게 도움이 될 수 있는 조언을 아끼지 않고 느리더라도 기다려주셔서 정말 감사드립니다. 교수님께서 제공해주신 다양한 기회 덕분에 조금이나마 성장하며 무사히 석사 졸업을 할 수 있게 되었습니다.

3년 동안 가까운 곳에서 저를 함께 생활하며 서로 도왔던 Interaction 연구실 식구들이 있어 좋은 추억을 많이 남길 수 있었습니다. 제 연구 뿐 아니라 다양한 조언을 아끼지 않고 도움을 주었던 승재형, 호준이 형 정말 감사드립니다. 실수도 많았고 부족했던 저와 함께 짧지 않은 기간동안 삼성 4D 연구를 함께 진행했던 상윤이 형, 겨레형, 지완이, 범수, 민재에게 정말 미안했고 정말 고마웠다는 말을 전하고 싶습니다. 연구실을 항상 즐겁게 만들었던 채용이, 성원이, 다진이, 진수, 영규, 동근이 덕분에 재미있는 연구실 생활을 보낼 수 있었습니다.

마지막으로 항상 믿고 응원해주셨던 어머니와 아버지, 그리고 동생 효경이에게 감사의 말씀을 전합니다.

저를 향한 여러분들의 도움과 응원을 잊지 않으며 앞으로 더 나아가도록 하겠습니다.

Curriculum Vitae

Name : Hyoseung Lee

Education

2013. 3. – 2017. 8. Department of Electirical Engineering, Pohang University of Science and Technology (B.S.)

2018. 2. – 2021. 2. Department of Computer Science and Engineering, Pohang University of Science and Technology (M.S.)

Experience

2017. 01. – 2017. 02. Intern, Electronics and Telecommunications Research Institute (ETRI)

Affiliation

1. Interaction Lab., Department of Computer Science and Engineering, Pohang University of Science and Technology