creative commons

COMMONS DEED

저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:

저작자표시. 귀하는 원저작자를 표시하여야 합니다.

비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.

변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 이용허락규약(Legal Code)을 이해하기 쉽게 요약한 것입니다.

Disclaimer

dCollection

체육학 박사 학위논문

인공지능 피드백을 활용한 야구 치기 기술의 학습 효과

2023년 02월

서울대학교 대학원

체육교육과

서 동 휘

인공지능 피드백을 활용한 야구 치기 기술의 학습 효과

지도 교수 김 선 진

이 논문을 체육학 박사 학위논문으로 제출함

2023년 02월

서울대학교 대학원

체육교육과

서 동 휘

서동휘의 체육학 박사 학위논문을 인준함

2023년 02월

위 원 장	권 성 호	(인)
부위원장	박 재 범	(인)
위 원	안 주 은	(인)
위 원	한 동 욱	(인)
위 원	김 선 진	(인)

국문초록

인공지능 피드백을 활용한 야구 치기 기술의 학습 효과

서 동 휘
서울대학교 대학원
체 육 교 육 과

본 연구에서는 인간의 움직임 중 복잡한 운동기술인 치기 기술에 대해서 머신러닝을 통해 그 숙련도가 분류되는지, 그리고 이를 바탕으로 제작된 인공지능 피드백(AIfb)이 운동학습의 결과와 폼의 향상에 효과가 있었는지 관찰하였다. 이를 위해 머신러닝의 검증을 위한 실험에서는 440명의 남자 청소년 초보자(age: 14.9±0.8)와 48명의 남자 청소년 숙련자(age:16.3±0.9)가 배팅티 위에 올려진 공을 치는 과제를 수행했고 이를 신체의 정면에서 촬영하였다. 촬영된 데이터는 영상 분석을 통해 관절의 데이터로 표현되었고, 이는 주성분 분석과 SVM을 통해 머신러닝이 진행됐다. 운동학습 실험에서는 위의 머신러닝 검증 실험에 참여하지 않은 42명의 남자 청소년 초보자(age: 15.0±0)가 통제집단, AIfb집단, Gfb집단으로 각각 14명씩 분류되어 사전 검사와 연습단계, 사후 검사와, 파지 검사를 수행했다. 이때 모든 검사는 10회의 치기 기술을 수행하는 것이었고, 연습단계에서는 10회씩 다섯 블록을 5일간 진행하여 총 250회의 치기를 수행하면서 해당 피드백을 부여 받았다.

그 결과, 머신러닝의 검증 실험에서 높은 정확도와 높은 AUC로 해당 머신러닝 프로그램은 성능이 우수한 머신러닝으로 판단됐다. 이때 숙련

자의 주성분 개수는 4개에서 최빈값을 얻었고, 초보자의 주성분 개수는 5개에서 최빈값을 얻었기에 숙련자의 치기 동작에서 더 적은 수의 dynamical degrees of freedom이 나타났다고 볼 수 있다.

두 번째 실험인 운동학습 실험에서는 먼저 운동 수행 결과의 경우, 타구 각도의 정확성을 표현하는 절대오차에서 피드백을 받은 집단간에 유의한 차이가 없었고, 타구 각도의 일관성을 표현하는 가변오차에서 피드백을 받은 집단이 통제집단보다 증가하는 모습을 보였다. 하지만 타구 속도는 AIfb집단이 Gfb집단보다 유의하게 향상되는 결과가 나타났다. 운동 수행 폼의 경우, 골반-몸통-왼쪽 팔꿈치 순서의 최대 각속도 발현 비율은 AIfb집단이 Gfb과 통제집단보다 유의한 향상이 나타났고, 주성분 개수는 AIfb집단은 3개로 감소하였고, Gfb집단은 2개로 감소했다. 이에 따라 주성분의 분산은 PC1에서는 Gfb집단이 AIfb집단보다 유의하게 컸지만, PC2이하에서는 Gfb집단이 AIfb집단보다 유의하게 작았다. 이는 AIfb집단이 숙련자의 것과 가깝게 변화하였기에 AIfb이 운동 수행 폼의 향상에 기여했다고 볼 수 있다. 적재값의 경우, AIfb집단은 PC1에서 상지, 골반과 무릎을 PC2에서는 상지, 상체, 골반과 하지를, PC3에서는 상지, 골반과 하지를 협응군으로 이용하지만, Gfb집단은 PC1에서 상지, 상체와 골반을 PC2에서는 상지만을 협응군으로 이용하는 것을 확인했다.

본 연구는 빅데이터의 머신러닝을 통해 복잡한 운동 기술인 치기 기술의 숙련도를 분류하여 신뢰도를 검증하고, 인공지능 피드백의 효과를 확인했다. 해당 연구는 관찰하기 어려운 복잡한 운동 동작에서 그 숙련도를 분류할 수 있었고, 부족한 부분에 대해 적절한 운동학적 피드백을 자동적으로 제공하는 인공지능 피드백을 통해 운동 수행 폼의 향상에 기여할 수 있다는 점을 확인했다. 또한 인공지능 피드백이 dynamical degrees of freedom을 효과적으로 변화시킬 수 있다는 것도 확인했다. 이는 빅데이터를 활용한 인공지능 피드백이 운동학습 현장에서 지도자와 학습자에게 필요한 피드백을 제공하는데 도움을 주며, 인간 움직임의 협응구조에 대해 깊이 이해할 수 있는 과학적 근거로 의미가 있을 것이라 기대한다.

주요어 : 인공지능 피드백, 운동학습, 치기 기술, 운동의 협응, 머신러닝, 피드백

학　번 : 2019-37841

목 차

Ⅰ. 서 론 1
1. 연구의 필요성 1
2. 연구의 목적 8
3. 연구의 가설 8
4. 연구의 제한점 9
5. 용어의 정의 10

Ⅱ. 이론적 배경 12
1. 머신러닝 12
2. 운동학습에서의 피드백 15
3. 인간의 협응 18
4. 치기 기술 21

Ⅲ. 연구 방법 24
1. 연구 대상 24
2. 실험 과제 및 도구 25
3. 실험 절차 28
4. 실험 설계 36
5. 자료 분석 37
6. 통계 분석 43

Ⅳ. 연구 결과 44
1. 머신러닝의 검증 44
1) 혼동행렬 45
2) ROC 커브 45
3) 숙련자와 초보자의 야구 치기에 대한 주성분 개수 46

4)주성분으로 설명되는 분산 47
5) 적재값(loading data) 48

2. 운동학습 실험 53
1) 운동 수행 결과 53
2) 운동 수행 폼 59

Ⅴ. 논의 82
1. 머신러닝의 검증 82
2. 운동학습 실험 85

Ⅵ. 결론 및 제언 90
1. 결 론 90
2. 제 언 91

참고 문헌 93

Abstract 103

표 목차

[표 1] 27
[표 2] 34
[표 3] 34
[표 4] 36
[표 5] 37
[표 6] 42
[표 7] 45
[표 8] 47
[표 9] 47
[표 10] 48
[표 11] 50
[표 12] 54
[표 13] 56
[표 14] 58
[표 15] 60
[표 16] 62
[표 17] 66
[표 18] 72
[표 19] 74
[표 20] 76

그림 목차

[그림 1] 12

[그림 2] 14
[그림 3] 26
[그림 4] 29
[그림 5] 31
[그림 6] 38
[그림 7] 44
[그림 8] 46
[그림 9] 48
[그림 10]..... 52
[그림 11]..... 53
[그림 12]..... 55
[그림 13]..... 57
[그림 14]..... 59
[그림 15]..... 61
[그림 16]..... 67
[그림 17]..... 67
[그림 18]..... 68
[그림 19]..... 68
[그림 20]..... 69
[그림 21]..... 77
[그림 22]..... 78
[그림 23]..... 79
[그림 24]..... 80
[그림 25]..... 81

Ⅰ. 서 론

1. 연구의 필요성

인공지능을 활용한 구글의 알파고가 이세돌 9단과의 대국에서 승리한 후 인공지능(AI)에 대한 관심과 시장규모는 급속도로 증가했으며 이는 금융, 의료, 경제, 교육 등 전반적인 사회문화적 측면에서 발전하고 있다(서형준, 2019; Feriani & Hossain, 2021; Lee & Lee, 2021). 미래의 생활방식 및 교육방식은 디지털 기반, 개인화, 인공지능, 변화 수용 등을 골자로 패러다임의 변화를 맞았으며, 최근 COVID-19의 유행과 장기화로 인공지능을 접목한 교육 인프라 구축이 빠르게 진행됐다(권정선, 2021). 또한, 학교 교육에서도 언택트라는 새로운 개념이 도입됐지만 비대면 교육이 미흡하다는 지적이 있었다(이의재 등, 2020; 서동휘 등, 2022). 결국 팬데믹은 학교 교육에서 시간과 공간의 제약을 넘어설 수 있는 새로운 방식을 모색하도록 강제하였다. 개학이 미루어지고 등교가 어려워진 상황에서 교육의 단절을 막기 위해 도입된 비대면 학습은 학습자의 학습 집중도 저하와 교수자와 상호작용을 더 어렵게 만들었다는 것이다(Varea & Gonzalez-Calvo, 2021). 즉 운동학습을 진행할 때에 참여자들이 동시 다발적으로 움직이는 상황에서 교수자는 개인에게 적합한 피드백 정보를 제시하지 못하거나 학습자는 적절한 정보에 대해 그것을 받아들이지 못하는 한계가 나타났다.

이러한 한계를 극복하기 위해서 ICT(Information & Communication Technology) 융합 교육을 활용할 필요가 있다. 왜냐하면 ICT는 실시간으로 움직임 영상을 공유하거나 빅데이터를 활용하는 인공지능 교육을 가능하게 만들기 때문이다. 이것을 학교 체육과 스포츠 활동에 접목한다면 가까운 미래에 시간과 공간의 제약을 극복한 움직임 교육이 성공적으로 실행될 수 있을 것이다(Lee & Lee, 2021; Yuan, 2021). 간단한 영상을 기반으로 생성된 움직임 정보는 위와 같은 세련된 움직임

교육의 자료로 적절하다. 움직임 정보는 데이터화되어 프로그램으로 모델링 될 때에 과학적인 정보로써 학습자에게 객관적인 제공이 가능하다. 이를 위해 인간 움직임의 빅데이터 분류가 자동화되어야 하며, 인공지능의 한 형태인 머신러닝 분석을 통해 운동학습을 위한 피드백 정보가 추출되고 그 정보를 효과적으로 제시할 수 있어야 한다.

머신러닝은 인공지능을 구현하는 구체적인 접근 방식 중 하나로 알고리즘을 이용해 데이터를 분석하고 학습하며, 이를 기반으로 현상을 판단하거나 예측하는 기술을 뜻한다(Bonaccorso, 2017). 즉 머신러닝은 빅데이터와 알고리즘을 통해 컴퓨터를 학습시켜 시스템으로 하여금 작업 수행 방법을 익히게 한다. 따라서 실시간으로 진행되는 움직임 교육을 위해 신체의 움직임에 대한 빅데이터 기반의 머신러닝과 이를 활용한 피드백을 제공한다면 운동학습에 효과적일 것이다. 왜냐하면 빅데이터는 통계자료에 근거가 되는 자료로 활용될 수 있기 때문에 논리적이고 과학적이며, 인공지능에 의해 자동적으로 부족한 부분에 대해 피드백이 제공되는 것이 학습자로 하여금 도전적인 과제수행 의지와 흥미를 유발할 수 있기 때문이다(Chassignol et al., 2018; Du Boulay, 2016). 인공지능을 활용한 운동학습은 일반적인 기존의 피드백 방법보다 학습자에게 필요한 정보를 더욱 논리적으로 제시할 수 있다. 기존의 피드백 방법은 운동 수행의 일부분에 대한 관찰을 통해 피드백을 제시하지만, 인공지능을 활용할 경우 운동 수행에 필요한 학습자에 대한 모든 정보를 비교하여 가장 필요한 정보를 찾아서 최적의 피드백 방법으로 제공할 수 있기 때문이다.

전인으로의 성장과 학습자의 개별성 신장, 사회 변화에 대응하는 신체적, 정신적 역량 함양을 목표로 하는 학교 교육에서는 현재의 교육이 마주하고 있는 문제를 개선하기 위해 위와 같이 빅데이터와 인공지능을 도입한 움직임 교육이 더욱 요구된다(권정선, 2021). 머신러닝을 활용한 움직임 분석의 선행연구에서는 운동 패턴이나 자세에 대한 연구를 진행하였다. 그 중에는 노화로 인한 보행변화를 자동으로 인식하기 위해 두발의 이중 지지기 시간이나 운동학적, 운동역학적 데이터를 감지하여 낙상의 위험이 있는 보행패턴을 구별(Begg &

Kamruzzaman, 2005)하는 연구가 있었고, 파킨슨병을 예측(Salmanpour et al., 2020)하는 연구도 있었다. 또한 무거운 짐을 드는 과제에서 생체역학적 위험요소를 파악(Conforti et al., 2020)하기도 하고, 압력정보를 이용한 앉은 자세 분석 시스템을 개발(Roh et al., 2018)하는 등의 연구가 진행되었다. 나아가 운동기술을 분류하고 분석하는 머신러닝 시스템 개발 연구에서는 스쿼트나 팔굽혀펴기 등의 연구가 진행되어 숙련자와 초보자를 분류하고, 피드백을 줄 수 있었다(이용준 & 김태영, 2021). 이는 팔굽혀펴기 수행을 할 때에 팔꿈치가 90° 이하로 굽혀지는 것을 올바른 팔굽혀펴기로 인식하고, 스쿼트 수행을 할 때에 양발의 적절한 폭과 무릎이 적절하게 굽혀진 각도를 올바른 스쿼트 자세로 인식하여 학습자에게 피드백을 줄 수 있도록 숙련자 모델과 초보자 모델의 관절 움직임을 프로그램으로 하여금 머신러닝을 진행시켜 분류의 신뢰도를 구축하는 연구였다. 하지만 운동기술을 머신러닝에 적용하는 경우 운동기술의 복잡성과 머신러닝에 필요한 기초 움직임 데이터의 판별 부재로 인해 위와 같은 단순한 움직임에 대한 머신러닝만을 진행해 왔다. 그렇지만 복잡한 운동기술 일수록 나타나는 움직임의 종류가 다양하기 때문에 인공지능은 다양한 종류의 빅데이터를 분류해야 한다. 따라서 복잡한 운동기술에서 나타나는 다양한 생체역학적 특징들을 바르게 정의해줄 필요가 있다. 또한 잘 정의된 생체역학적 특징들을 인공지능으로 선별할지라도 인간의 운동학습에 있어서 학습자가 정보로써 지각하고 인지할 수 있는 범위의 정보인지는 판별될 필요가 있다. 즉 객관적으로 규명된 데이터를 분류한 뒤 운동학습을 목적으로 정보가 학습자에게 제공된다 할지라도 학습자가 지각하거나 인지하지 못하는 경우 이는 학습으로 이어질 수 없다(Power, 2014)는 것이다. 따라서 학습자가 수용 가능한 정보를 제공받을 때에는 이를 고려한 시각, 청각 또는 촉각 피드백을 제공해야 한다(서동휘, 2019; Frankel & Reid, 2008; Sigrist et al, 2013). 왜냐하면 바르게 정제된 피드백은 학습자로 하여금 지각하거나 인지하지 못하는 범위의 데이터를 역치의 범위로 범주화하여 효과적인 피드백으로의 기능을

가능하게 하기 때문이다(Sabic & Chen, 2016). 예시로 영상정보를 활용한 운동학습에 있어서 목표한 움직임에 대한 유의한 차이가 나타나더라도 미세한 차이는 시각적으로 지각하기 어렵다. 따라서 이를 피드백으로 제공할 때에 단순히 영상정보를 제공하기보다는 영상정보의 질적 데이터를 특정한 시간 및 공간에서 반복적으로 보여주거나 이를 변형시켜 색깔이나 등고선으로 표현하기도 한다(Sigrist et al, 2013). 이러한 영상정보를 데이터화하는 것은 움직임에 대해 양적정보로 표현하는 것이 가능하다. 양적정보는 학습자마다 다른 역치의 범위를 누락하지 않고 모든 범위의 움직임을 구체적으로 제공할 수 있다. 따라서 목표한 특정 값에 대한 범위를 알맞게 결정할 경우 효과적인 운동학습의 피드백으로 가치가 있다.

따라서 본 연구에서는 학교체육에서 스포츠의 형태로 많이 다루어지고 흥미롭게 접근할 수 있는 다소 복잡한 운동기술에 대한 머신러닝을 통해 움직임을 분류 및 판별하고 피드백을 줄 수 있는 모델을 만들고 검정하여 효과적인 인공지능 움직임 교육을 제공하고자 한다. 그 중 치기 기술은 복잡한 운동기술로 스포츠 활동에서 자주 활용되며, 팔이나 다리와 같은 신체를 사용하거나 라켓이나 방망이 등의 도구를 활용하여 물체를 투사시키는 기초 움직임 동작이다. 이러한 치기 기술은 학교체육과 생활체육에서 전체 체육활동 중 약 36.6%의 비율을 차지할 만큼 다양한 종목의 스포츠활동으로 비중이 높은 편이다(한국통계청, 2018). 스포츠에서 치기 기술은 야구의 치기, 테니스나 탁구의 스트로크 등의 동작으로 나타난다. 이를 잘 수행하기 위해서는 눈-손 협응을 통해 내적 타이밍과 외적 타이밍이 잘 이루어져야 하며 효율적인 동작이 수행되기 위해 신체 중심에서 신체 말단으로 관절의 순차적 가속이 이루어지는 순차적 패턴(proximal to distal sequence pattern, PDS)이 작용하게 된다(Putnam, 1983). 왜냐하면 치기 기술을 수행하는 신체의 사지가 생체역학적으로 연결되어 있고, 움직임을 생성할 때 복합관절이 서로 상호작용하여 신체 말단 관절의 속도를 극대화시켜 역동적인 사지 움직임을 만들어지기

때문이다(Dounskaia et al., 2011; Hirashima et al., 2007). 초보자의 경우 이러한 패턴은 일관적이지 않거나 관절들이 동시에 회전하게 되는 경우가 많다(Vereijken et al., 1992). 이 외에도 야구의 치기 기술에서는 백스윙 구간에서 임팩트 시점을 기준으로 숙련자에게 나타나는 골반의 최대 회전 각도가 나타나는 시점(-392ms)이, 초보자의 시점(-518ms)보다 빨랐다. 포워드스윙 구간에서는 숙련자의 골반(99.6°) 및 몸통(126.1°)의 각변위가 초보자의 골반(61.0°) 및 몸통(79.5°)의 각변위보다 크게 나타나는 연구가 있었다(Nakata et al., 2014). 또한 야구의 치기에서 지면반력을 최대한 이용하기 위한 신체 분절의 움직임으로 엉덩관절과 무릎관절의 신전을 통해 두 다리를 측면/내측(lateral-medial)방향으로 움직여야 한다는 연구가 있었다(Ae et al., 2017). 숙련자의 야구 치기에서 나타나는 눈-머리-손의 협응에 대한 연구에서는 숙련자에 따라 다양한 방법을 통해 공과 배트가 접촉하는 부분을 응시하고, 눈보다 머리의 움직임이 더 많은 경향이 나타났다(Toole & Fogt, 2021). 하지만 정지되어 있는 공을 타격하는 골프 스윙의 연구에서는 숙련성에 따라 머리와 퍼터의 움직임간에 서로 다른 상관관계를 나타내는 연구가 있었다(Lee et al., 2008). 그래서 치기 기술을 향상시키기 위해 위와 같은 정보를 바탕으로 적합한 피드백을 줄 수 있는 프로그램 기반의 운동학습이 필요하다(이동연 등, 2022).

이러한 치기 기술을 사용하는 스포츠 중에 티볼의 치기가 있다. 이것은 면이 존재하는 라켓 스포츠와 비교할 때, 멀리 타격 하고자 하는 목표를 가지고 운동을 수행한다면 타구되는 공과 타격하는 물체가 편심력보다는 향심력으로 충돌하게 된다. 즉 배트가 정지된 공의 중앙에 가깝게 타격해야 멀리 보낸다는 목표를 달성할 수 있다는 것이다. 반면 라켓 면이 존재하는 치기 기술인 테니스나 탁구 등은 멀리 타격 하려는 목표보다는 지면의 특정 위치에 공이 낙하하도록 공을 타구시켜야 한다는 목표를 가지고 운동을 수행하기 때문에 탑스핀이나 백스핀 등을 활용한 편심력이 나타나야 그 목표를 달성하기 쉽다. 그런데 티볼 배트의 경우 공을 타구하는 면이 존재하지 않아 치기 도구에서 그립으로

인해 발생하는 타구 면의 기울기를 조절하지 않아도 된다는 점에서 초보자들로 하여금 치기 기술에 대한 습득이 용이하고 멀리 타격하고자 하는 목표를 세울 수 있다. 또한 티볼의 치기는 배팅티 위에 올려져 정지된 공을 친다는 점에서 난이도가 더 쉬운 편이다. 그렇기 때문에 티볼은 야구의 치기를 연습할 때에 활용되고, 운동발달 평가 항목 중 대근운동 기술의 치기 기술을 평가하는데 사용될 만큼(Burton & Rodgerson, 2001; Ulrich, 2013; 남수미 등, 2022) 치기 기술의 기초 동작으로 적절하다. 티볼의 치기에서 나타나는 대근운동기술의 운동발달은 청소년기에 이르러 움직임이 세분되며 정교해진다. 왜냐하면 이 시기에는 전문화된 움직임 기술이 발달하고 기본 움직임들은 복잡한 스포츠 기술의 성공적인 수행을 위해 다듬어지고 결합되는 특징(김선진, 2003)이 나타나기 때문이다.

그간 운동학습에 대한 피드백의 효과 연구는 제시되는 순서나 방법, 형태를 가지고 비교해왔다(Shea & Wulf, 1999; Sigrist et al., 2013). 이러한 피드백의 효과는 운동학습의 목표에 따라 달라진다. 이것은 크게 운동 수행 결과의 향상과 운동 수행 폼의 향상으로 나뉠 수 있다. 이 두가지 목표와 직접적으로 관련한 정보를 운동학습에서는 각각 결과지식(knowledge of result, KR)과 수행지식(knowledge of performance, KP)이라 하고 있다. 그 이유는 결과지식이란 동작에 대한 결과를 연구참여자에게 제공하는 외적인 정보인 운동 수행 결과를 의미하기 때문이다. 그리고 수행지식은 실제 수행 혹은 동작의 특징에 대한 정보를 환경과 관련지어 연구참여자에게 제공하는 정보를 의미하기 때문이다(Magill & Anderson, 2010). 제공되는 정보의 종류인 결과지식이나 수행지식은 학습자가 지각하고 인지하게 되면 동작으로 나타나게 된다. 과학기술의 발달은 위와 같은 정보들을 동시에 실시간으로 제공하는 것을 가능하게 했지만, 초보자의 경우 인지 과부하로 인해 학습 효과의 저하(Sigrist, 2011; Sigrist et al., 2013)를 가져올 수 있다. 따라서 학습자의 상황과 운동기술 및 운동학습의 목표를 고려하여 피드백으로 제공해야 할 정보의 종류가 달라져야

한다(이한우 & 육동원, 2004; Van Vilet & Wulf, 2006; Wulf, 2013). 이에 따라 결과지식과 수행지식이 운동 수행 결과나 운동 수행 폼에 대한 향상을 가져오는지에 대한 많은 연구가 이루어졌다(Weeks & Kordus, 1998; Winstein, 1991).

결과지식과 수행지식을 피드백으로 부여하여 초보자에게 운동학습을 진행한 연구 중에는 움직임의 자유도가 많은 멀리 던지기에 대해 이루어진 것이 있는데, 이 연구에서는 운동 수행 결과의 경우 수행지식과 함께 변화의 방향에 대한 처방적 정보를 함께 제공한 피드백(transitional information and KP)이 가장 우수한 효과를 나타냈다. 이는 멀리 던지기의 폼에 향상에 있어서도 다른 피드백들(KP 또는 KR) 보다 가장 우수한 효과를 나타낸 것이었다(Kernodle & Carlton, 1992).

하지만 해당 선행연구들은 운동 수행 폼의 변화를 확인하는 과정에서 숙련자들이 설문지에 체크하는 방법을 사용하거나(박수범 & 홍승분, 2019; Post et al., 2016), 두 관절의 움직임에 대한 질적 해석의 방법으로 평가하였기에(Lawrence et al., 2011; Schücke & Parrington, 2019) 이를 빅데이터화하여 프로그램 내에서 머신러닝을 시키기에는 무리가 있다. 따라서 인공지능 피드백이 초보 학습자의 야구 치기에 대한 운동 수행 결과 또는 운동 수행 폼의 향상을 데이터화하여 판별하고 그에 따라 필요한 처방적 수행지식과 결과지식이 피드백으로 자동 분류되어 학습자에게 적절하게 제시될 수 있다면 운동 수행 폼에 대한 데이터 없이 운동 수행의 범주로 제한된 일반 언어적 피드백 방법보다 효과적일 것이라는 가설을 바탕으로 본 연구를 진행하고자 했다. 즉 이를 통해 일반적인 야구 전문 코치의 코칭에 큰 도움을 줄 것을 기대했다. 따라서 해당 연구는 청소년들의 움직임 기술을 간단한 영상과 빅데이터를 이용한 머신러닝으로 자동 분류하여, 과학적인 학습을 가능케 한다. 해당 연구는 시간과 공간의 제약을 극복한 과학적인 움직임 교육을 제공하는 역할을 할 수 있다. 즉 비대면 인공지능 기반 움직임 교육의 가능성이라는 측면에서 이 연구의 의의와 필요성이 있다.

2. 연구의 목적

본 연구의 목적은 시간과 공간의 제약을 극복한 비대면 움직임 교육이 효과적으로 실행될 수 있도록, 머신러닝을 이용하여 치기 기술의 숙련도를 자동으로 분류할 수 있는 프로그램을 만들어 그 신뢰도를 검정하고, 이를 이용한 인공지능 피드백을 활용하여 학습자들에게 치기 기술의 운동학습 효과가 나타나는지 살펴보는 것이다. 이와 같은 연구목적을 달성하기 위해 다음과 같은 세부 목표를 설정했다.

첫째, 치기 기술을 수행하는 숙련자의 폼과 초보자의 폼을 머신러닝을 통해, 높은 신뢰도로 자동 분류하는 프로그램을 제작하고자 한다.

둘째, 제작된 프로그램을 활용한 인공지능 피드백이 운동 수행 결과의 향상에 미치는 영향을 규명하고자 한다.

셋째, 제작된 프로그램을 활용한 인공지능 피드백이 운동 수행 폼의 향상에 미치는 영향을 규명하고자 한다.

3. 연구의 가설

본 연구의 목적을 달성하기 위해 다음과 같은 연구가설을 설정했다.

1) 숙련성에 따른 치기 기술의 운동 수행 폼을 머신러닝 기반 운동기술 측정 프로그램으로 분류할 수 있을 것이다.

2) 인공지능 피드백이 일반 피드백에 비해 치기 기술의 운동 수행 결과의 향상에서 효과적일 것이다.

3) 인공지능 피드백이 일반 피드백에 비해 치기 기술의 운동 수행 폼의 향상에서 효과적일 것이다.

4. 연구의 제한점

본 연구는 다음과 같은 제한점을 가진다.

첫째, 운동학습 실험에서 연구대상자의 신체에 부착된 관성 측정 센서는 실제 운동 상황과 다른 감각을 부여할 수 있다.

둘째, 본 연구에서는 치기 기술 학습 프로그램 이외의 연구참여자 개개인이 가지고 있는 생리적 특성 및 심리적 특성을 완전하게 통제하지 못한다.

셋째, 인공지능이 판별하는 운동학적 데이터들은 변인에 따라 상호관련성이 존재하더라도 그 관련성이 배제되어 독립적으로 분류된다.

넷째, 일반 피드백의 경우 인공지능 피드백과의 동등성을 위해 야구 전문 코치의 언어적 피드백만 네 가지의 큰 범주에서 제공되는 것으로 제한되었다.

5. 용어의 정의

1) 야구의 치기

본 연구에서 치기 기술로 사용된 야구 치기는 티볼 공과 배팅티 및 티볼 배트를 이용하여 제자리에서 스윙하는 것으로 제한하였다.

2) 인공지능 피드백(AIfb)

본 연구에서 활용된 인공지능 피드백(AIfb)은 학습자의 운동 수행 결과와 운동 수행 폼에 따라 자동으로 적합한 피드백을 제시하는 것으로 정의하였다. 이는 연구참여자가 치기 시에 나타나는 운동 수행 결과와 운동 수행 폼에 대해 판별하여 기준점에 도달하지 못하는 부분에 대해 처방적 수행지식과 결과지식으로 피드백을 제시하는 구조로 만들었기 때문이다.

3) 일반 피드백(Gfb)

본 연구에서의 일반 피드백(Gfb)은 연구참여자가 야구 치기 수행 시에 나타나는 운동 수행 결과 및 운동 수행 폼에 대하여 야구 전문 코치가 전반적으로 연구 참여자의 스윙을 관찰하여 움직임에 대한 기술적 수행지식 또는 처방적 수행지식과 타구 각도에 대한 결과지식을 언어적 피드백으로 제공하는 것이다.

4) 머신러닝

본 연구에서 활용된 머신러닝은 Microsoft 사의 MediaPipe pose를 사용하여 얻은 숙련자와 초보자의 데이터 세트로 야구 치기 동작을 학습하여 야구의 치기 기술에서 나타나는 운동 수행 폼을 숙련도에 따라 분류하는 것이다.

5) 운동 수행의 폼(협응구조)

본 연구에서 운동 수행의 폼은 야구 치기의 포워드 스윙에서 나타나는 골반, 몸통, 왼쪽 팔꿈치의 순차적인 회전 타이밍을 의미한다. 또한 운동 수행의 폼 중에 복합관절의 협응구조는 주성분 분석(principal component analysis, PCA)을 진행하여 29개의 주성분 중 kasier criterion(Kaiser, 1960)을 만족하는 주성분의 개수와 주성분에 기여하는 변인들의 적재값(로딩값)으로 나타냈다(Ko & Newell, 2015).

Ⅱ. 이론적 배경

1. 머신러닝

머신러닝은 인공지능의 한 형태로 컴퓨터가 데이터를 통해 스스로 학습할 수 있도록 하는 알고리즘과 기술을 개발하는 분야를 의미한다. 즉 머신러닝은 경험을 통해 자동으로 문제를 개선하는 컴퓨터 알고리즘이다(Jordan, & Mitchell, 2015). 머신러닝은 문제 해결방법에 따라 정답이 있는 데이터로 학습하는 지도학습(Supervised Learning), 정답이 없이 데이터로만 학습하는 비지도학습(Unsupervised Learning) 그리고 주변과의 상호작용으로 학습하는 강화학습(Reinforcement Learning)으로 나뉜다<그림 1>.

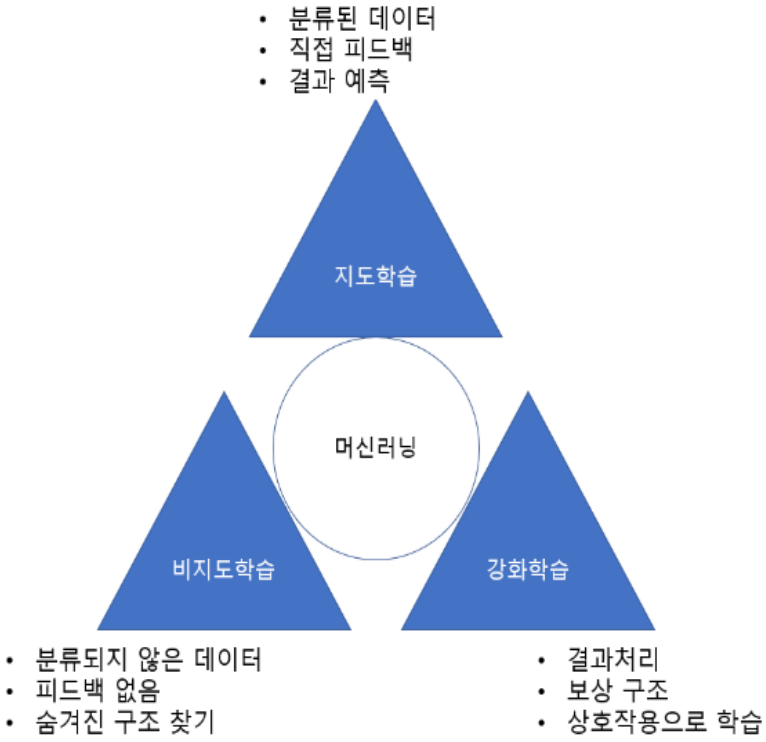

그림 1. 머신러닝의 분류

이중 지도학습은 숙련자와 초보자의 분류된 데이터를 통해 학습하는 과정을 거칠 수 있기 때문에 운동 수행의 숙련도를 구분하는 것에 적합하다. 이러한 지도학습의 알고리즘 중 하나인 SVM(Support vector machine)은 주요 데이터(Support vectors)를 선정하여 데이터를 구분하는 분석 모델로 데이터를 분류하는데 적합하다. 이는 다른 분석모델들에 비해 빠른 학습 속도를 띄며, 데이터 특징의 개수에 별다른 영향 없이 균일한 성능을 발휘한다. 이것은 입력 데이터 전처리가 필수로 진행되어야 한다.

SVM은 1992년 Vapnik에 의해 소개된 것으로 경험을 통해 학습한 것을 바탕으로 사물들을 분류하는 컴퓨터 알고리즘이다. 이것은 분류를 위한 기준선을 정의하는 것이며, 분류되지 않은 새로운 데이터가 발생하면 경계의 한쪽을 확인하여 분류 과제를 수행하는 것이다. 따라서 SVM은 패턴인식이나 자료 분석에서 많이 활용된다(Noble, 2006). SVM에서 데이터를 분류하기 위한 기준선은 결정 경계(Decision Boundary)라고 하며 이것은 데이터의 속성에 따라 선이 아닌 평면이 될 수도 있고, 고차원인 초평면(Hyperplane)이 될 수도 있다. 이러한 결정 경계는 데이터의 특징에 따라 무수히 많이 나타날 수 있기 때문에 데이터 군으로 부터 최대한 멀리 떨어져 있는것이 좋다. 따라서 결정 경계와 가까이 있는 데이터 포인트(Support vector)들을 통해 결정 경계를 선택할 수 있다<그림 2>. 예시로 데이터 속성이 두개라면 최소한 세개의 Support vector를 통해 마진(margin)이 가장 큰 결정 경계를 구해지게 된다. 즉 n개의 속성을 가진 데이터는 최소 n+1개의 Support vector가 존재하게 된다. 따라서 SVM은 불필요한 수 많은 데이터를 무시하고 Support vector로 머신러닝을 진행한다. 마진의 경우 아웃라이어를 허용하지 않고 까다로운 기준을 설정하는 것을 하드 마진(hard margin)이라 하고, 아웃라이어를 마진 안에 포함시켜 너그러운 기준을 설정하는 것을 소프트 마진(soft margin)이라 한다. 이때 아웃라이어를 허용하지 않는 기준은 overfitting의 문제가 발생할 수 있다. 반면 소프트 마진으로 support vector와 결정 경계가 멀어지면 낮은 수준의 학습이 진행되어

underfitting의 문제가 발생할 수 있다. 데이터의 속성과 특징에 따라 SVM은 선형적인 분류 이외에도, Kernel형과 Polynomial형 등에 대한 분류를 위한 결정 경계의 설정 방법이 존재한다.

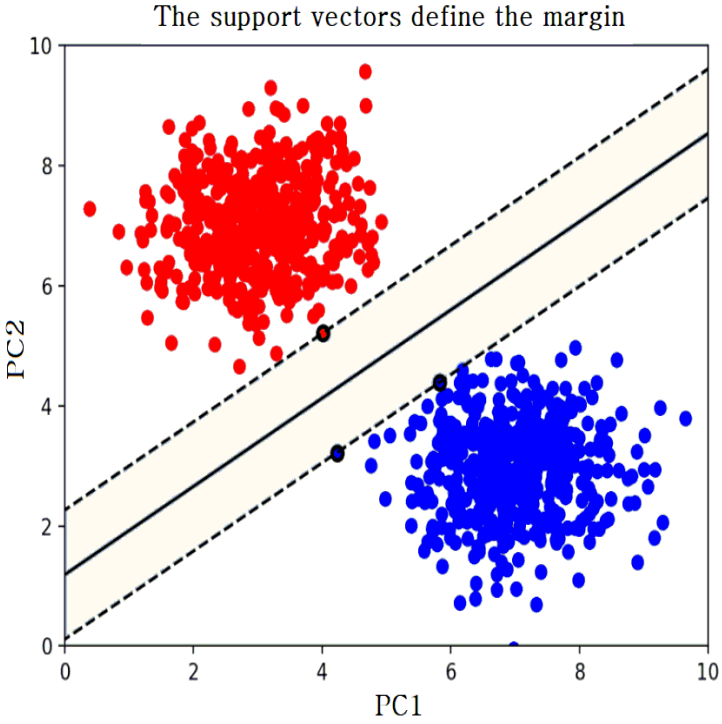

그림 2. SVM의 support vector 결정[①]

① https://hleecaster.com/ml-svm-concept/ [2022/06/01]

2. 운동학습에서의 피드백

운동학습은 운동 수행의 변화를 영구적으로 이끄는 것을 의미하는데, 운동학습은 움직임 제어의 이론적 관점에 따라 여러 형태로 나타난다. 정보처리 이론의 관점에서 운동학습은 반복 학습을 통해 중추표상을 강화하는 것이며, 정확성 참조 준거와 운동결과로 나타나는 피드백을 비교해 효율적인 도식체계로 재구성하는 것이다. 그리고 다이내믹 시스템 이론의 관점에서 운동학습은 특정한 환경과 과제가 학습자에게 주어져서 가장 효율적인 협응구조가 나타나도록 적응성을 향상시키는 것이다. 이외에도 Newell(1991)의 생태학적 관점에서 운동학습은 연습과 경험을 통해 지각-운동 활동 영역(perceptual-motor workspace)에서 과제와 환경적 요구에 적합하도록 지각과 동작 간의 협응을 향상시키는 과정이라고 할 수 있다. 이러한 운동학습은 Magill & Anderson(2007)이 그 특징을 세가지로 제시하였다. 첫째, 운동학습은 학습자 개인의 영구적인 운동기술로 습득되는 내적인 변화를 유도한다. 둘째, 운동학습은 일회적으로 시행되는 수행과 달리 직접 관찰이 어렵고 수행 과정에서 변화를 거치며 습득된다. 셋째, 운동학습은 개인의 성장이나 일시적 변화를 포함하지 아니하는 연습과 경험에 의해 나타나는 현상이다. 이를 바탕으로 운동학습을 정리하면 운동학습은 과제와 환경에 적합한 효율적인 운동기술을 습득하기 위해 연습과 경험으로 개인의 협응구조를 도식화하여 체계적으로 재구성하는 과정으로 요약할 수 있다.

이러한 운동학습의 과정은 학습자의 지각과 인지적 처리과정, 연습과 오류 수정 등을 통한 일련의 과정을 통해 수행을 향상시키는 것이다. 먼저 운동기술의 학습은 자신이 수행할 운동기술 동작을 보는 것에서부터 시작된다. 이를 움직임의 역동성에 대한 지각이라고 한다(김선진, 2015). 이러한 신체의 움직임은 절대적 운동, 상대적 운동, 공통적 운동으로 구분되며, 운동 형태의 차이를 지각하여 각각의 기술 동작을 구별할 수 있다(Newell, 1996). 절대적 운동은 움직임에

동원되는 각각의 자유도의 시간적, 공간적 움직임을 의미하며, 상대적 운동은 어떤 인체 분절의 움직임에 대한 특정 인체 분절의 상대적인 움직임이다. 마지막으로 공통적 운동은 시간의 흐름에 따라 모든 자유도가 동원된 시스템 전체의 움직임을 의미한다. 학습자는 이처럼 시각을 통해 움직임의 역동성을 지각하는 것으로 운동학습의 과정을 시작한다. 두 번째로는 움직임 구성 수준의 결정과 운동 구조를 형성하는 과정을 거친다. 이것은 움직임 기술의 협응을 만들어 내기 위한 과정으로 장력 수준, 근육과 관절의 연결 수준, 공간 수준, 동작 수준으로 구분된다(Bernstein, 1966). 장력 수준은 동작에 대한 자세조절이나 균형 유지와 관련하며, 근육과 관절의 연결 수준은 사지의 근육 활동을 통한 기본적인 공동 작용을 조직한다. 공간 수준은 환경적 요구에 대처하기 위해 협응 형태를 변화시키는 것이며, 동작 수준은 자유도와 관련하여 움직임의 구성 요인 간에 순서를 결정하는 것이다. 세 번째로 오류 수정의 과정은 움직임 자체에 대한 느낌과 감각 오류를 내부적으로 느끼는 것으로 직접 경험과 반복적인 연습을 통해 오류 정보를 많이 경험하는 것이 중요하다. 마지막으로 자동화와 안정성 획득의 과정이 이루어진다. 자동화는 많은 연습을 통해 수행의 질적인 변화를 경험하는 것으로 의식적인 주의 없이 운동 수행이 가능해지는 상태이다. 안정성 획득은 운동과제와 관련이 적은 내적, 외적 요인에 대처하는 전환 능력을 갖추는 과정이다(김선진, 2015).

운동학습은 연습 과정에서의 변화를 포함한다. 따라서 운동학습의 측정은 과정에서 결과까지 진행해여야 하고, 특정 기간이 지난 뒤의 수행에서도 진행하여야 한다. 이를 각각 운동 수행과 파지라고 한다. 운동 수행은 연습과정에 관한 것으로 수행점수나 오차점수를 수치화하여 그래프로 나타낼 수 있다. 이를 수행곡선이라고 한다. 그러나 이것은 과정에 따른 변화 양상을 쉽게 파악할 수 있지만 영구적인 변화를 의미하는 학습여부를 파악하기 어렵고 개개인의 가변성을 반영하지 못하는 단점이 있다(Schmidt, 1991). 파지는 반복된 운동 수행이 학습을 통해 운동기술을 습득한 것으로 장기기억에 운동기술의 방법이 저장된

것이다. 이를 검사하는 것을 파지 검사라고 한다. 이것은 일정기간이 지난 뒤에도 운동기술이 효과적으로 발현되는지를 파악하는 것인데 두가지로 구분된다. 하나는 학습단계의 마지막에 얻은 점수를 얼마나 유지하고 있는지를 반영하는 절대파지 점수가 있고, 다른 하나는 학습단계의 마지막에 얻은 점수와 초기 파지점수의 차이를 통해 정보의 손실 정도를 파악하는 상대파지 점수가 있다(Christina & Shea, 1993).

운동학습에서 피드백은 위와 같은 변화를 잘 이끌어내기 위해 다양한 감각 시스템을 통해 제공되는 운동기술에 대한 정보이며, 내재적 피드백과 외재적 피드백으로 구분된다. 내재적 피드백은 학습자가 운동 중이나 후에 자각하는 감각에 대한 정보를 제공받는 것이며, 외재적 피드백은 운동 중이나 후에 학습자가 외부의 정보로부터 제공받는 것이다. 그런데 외재적 피드백은 결과지식과 수행지식으로 나뉜다. 결과지식은 움직임의 결과로 나타나는 정보이며, 수행지식은 움직임 유형 자체에 대한 정보이다(김선진, 2015). 운동학습 과정 중에서 나타나는 운동학습의 목표는 크게 두가지로 나뉠 수 있는데, 각각 결과지식 또는 수행지식의 제공으로 연결될 수 있다. 첫째로 운동 수행 결과의 향상을 목표로 하는 경우 결과지식의 제공을 통해 그 향상을 기대하며, 둘째로 운동 수행 폼의 향상을 목표로 하는 경우 수행지식의 제공을 통해 그 향상을 기대한다. 하지만 이러한 피드백은 과제의 복잡성이나 환경 그리고 유기체의 숙련정도라는 특성에 따라 다른 효과를 나타내며, 따라서 운동학습에서 피드백은 그 목적에 따라 과제, 환경, 유기체가 최적으로 상호작용할 수 있게끔 잘 구성되어야 한다.

Gentile은 환경의 변화가 없는 폐쇄운동기술의 경우 결과지식보다 수행지식이 움직임의 특정한 요소에 대해 집중할 수 있기 때문에 더욱 효과적일 것이라고 주장했다(Gentile, 1972; Gentile & Nacson, 1976). 또한 단순 움직임 제어를 위한 피드백으로는 결과지식이 효과적이며, 여러 움직임을 제어해야 하는 복잡한 운동제어에 대한 학습의 경우 여러 정보를 포함한 피드백이 요구되기 때문에 수행지식이 결과지식과 더해져 움직임을 학습하는데 효과적이라는 연구가 있었다(Maier et al., 2019;

Triano et al., 2012). 나아가 수행지식을 분류하여 그 학습효과를 비교한 연구도 있었는데, 수행지식의 경우 운동학습의 목표를 해결하기 위한 방법으로 제공되어 지각-운동 작업 공간이 활성화 된다면 결과지식보다 우수할 수 있다는 결론이 제시되었다(Oppici & Narciss, 2021). 수행지식은 기술적(움직임 묘사)일수도 있고, 처방적(움직임 개선의 방향을 제시)일 수도 있는데 위와 같이 운동학습의 목표를 직접 해결하는 방향에 대한 정보를 처방적 수행지식이라고 할 수 있다(Newell et al., 1985). 숙련자의 경우 이미 운동 과정에서 피드백이 지각-운동 작업공간을 활성화하기 때문에 기술적 수행지식이 효과적이지만, 초보자의 경우 피드백이 지각-운동 작업공간으로 안내되기 위해서는 수행지식은 운동학습의 목표와 관련되어 처방적일 필요가 있다는 것이다(Newell, 1991; McErlain- Naylor et al., 2021). 결과지식과 수행지식을 피드백으로 부여하여 초보자에게 운동학습을 진행한 연구 중에는 움직임의 자유도가 많은 멀리 던지기에 대해 이루어진 것이 있는데, 이 연구에서는 운동 수행 결과의 경우 수행지식과 함께 변화의 방향에 대한 처방적 정보를 함께 제공한 피드백(transitional information and KP)이 가장 우수한 효과를 나타냈다. 이는 멀리 던지기의 폼에 향상에 있어서도 다른 피드백들(KP 또는 KR) 보다 가장 우수한 효과를 나타낸 것이었다(Kernodle & Carlton, 1992).

3. 인간의 협응

인간은 움직임을 시행함에 있어 조화로움을 선호한다. 이는 자연스러운 움직임으로 어트랙터(attractor)라고도 한다. 조화로운 움직임은 신체의 복합적인 관절의 움직임이나 근육군의 움직임을 통해 나타난다. 이를 협응(운동 수행의 폼)이라고 하며 다이나믹 시스템 이론에서는 다 차원적인 요인들의 상호작용에 의해서 협응의 변화가 나타날 수 있다고 한다(김선진, 2015). 이는 자기조직(self-organization)의 원리와 비선형성(nonlinearity)의 원리라는 개념으로

설명된다. 즉 제한요소가 어떠한 상황과 맞물리게 될 때 사지의 움직임 유형이 저절로 나타나는 것이며, 그 협응의 변화가 선형적인 변화를 따르지 않는다는 것이다. 이러한 변화는 질서변수와 제어변수로 설명이 된다. 질서변수는 움직임의 특성과 유형을 나타내는 개념으로 상대위상이나 평형점, 근육의 강직성 등으로 표현되며, 제어변수는 움직임의 속도나 범위, 그리고 유기체가 나타내는 힘에 대한 물체의 무게 등이 있다. 예시로 야구공을 던질 때에는 상지의 관절과 근육이 어깨 관절을 축으로 원심력을 이용하는 움직임이 나타나지만 투포환의 경우 어깨 관절을 기점으로 밀어내는 듯한 움직임을 나타낸다. 이는 야구공을 던지는 것에 비해 투포환은 던질 때 그 무게가 더욱 무겁기 때문에 무게라는 제어변수에 의해 상지의 움직임 패턴이라는 협응구조가 변화하는 것이다. 이러한 인간의 협응은 운동학습의 단계에 따라 달라지는 경향이 있는데 Bernstein(1967)은 여분의 자유도를 활용하는 정도를 통해 운동기술의 수행 수준을 결정한다고 보았다. 이에 따라 자유도의 활용 정도에 따라 운동학습의 단계를 자유도의 고정(freezing of degree of freedom) 단계, 자유도 풀림(release of degree of freedom) 단계, 반작용 활용(use of reactive phenomena) 단계로 구분하였다. 이는 움직임이 자동화되어가면서 자유도를 조절하여 움직임이 협응을 통해 효율적으로 변화해가는 과정이라고 할 수 있다. 이러한 자유도는 mechanical degrees of freedom이나 dynamical degrees of freedom으로 판단될 수 있다. Mechanical degrees of freedom은 관절 수준에서의 자유도를 말하는 것으로 3차원 공간상에서 수직축, 전후축, 좌우축에서 회전하는 관절의 움직임을 의미하기 때문에 한 관절이 회전할 수 있는 independent coordination(축)의 수로 계산된다. 반면에 dynamical degrees of freedom은 시공간에서 나타나는 mechanical degrees of freedom의 수 만큼의 차원을 가진 움직임에서 독립적인 변수의 수(independent variable)를 말한다. 따라서 여러 가지 관절의 움직임이 서로 상관관계가 없다면 dynamical degrees of freedom은 여러 가지 관절의 움직임 수 만큼이 되지만, 여러 가지 관절의 움직임이

모두 같은 어떤 상관관계를 가진다면 dynamical degrees of freedom은 한 개가 되는 것이다. 이처럼 선형적이고 다수의 변수 간의 관계를 찾아서 biomechanical degrees of freedom을 dynamical degrees of freedom으로 줄이는 방법으로 주성분 분석(PCA, principle component analysis)을 사용한다. Control hypothesis에 따르면 중추신경계(CNS, Central nervous system)가 약 1000개 정도가 되는 근육 모두를 독립적으로 제어하지 못하기 때문에 여러가지 근육들을 그룹화하여 자유도의 수를 줄이고, 이를 muscle synergy라고 한다. 즉 인간은 과제의 특성에 따라 여러가지 근육들을 협응구조(coordination structure)로 재구성하여 muscle synergy를 만들어 내는 것이다(Hong & Newell, 2006).

이처럼 인간의 협응은 과제와 환경과 상호작용하며 제한요소에 따라 최적의 협응 형태를 구성하게 되는데, 이는 지각-운동 활동영역을 탐색하는 과정에서 이루어진다. 이것은 지각하고 움직이는 과정이 역동적이며 지각-동작의 특성을 발견하면서 상호작용의 결과로 나타나는 동작 시스템을 조절하는 과정이다. 예를 들어 치기 기술의 타격에서 배트를 잡는 방법, 골반과 상체의 회전에 대한 생각 뿐만 아니라 배팅티 위에 올려진 공에도 집중해야 하기 때문이다. 결국 협응구조의 형성은 지각-동작 연합이 중요하게 적용된다(Magill & Anderson, 2010). 지각-동작 연합은 지각된 변수의 특징에 따라 나타나는 동작의 관계를 의미하는 상호작용의 결과이다. 이는 배팅티 위에 올려진 공의 높이, 배트의 무게 등을 지각하고 자신의 키나 근력 등을 함께 고려하여 요구되는 동작을 파악하는 것을 예로 들 수 있다. 이러한 관계를 기초로 과제와 환경, 유기체 간에 상호작용이 이루어져 상황에 적합한 협응구조를 만드는 것이다. 이처럼 인간의 학습을 통한 협응구조의 형성은 반복학습을 통해 현재의 기억구조를 변화시킬 수 있으며, 이전의 기억구조로 돌아가는 가소성도 존재한다(Tallet et al., 2008). 이러한 현상은 어트랙터로 설명할 수 있다. 어트랙터를 형성하는 것은 신경 구조 속에 강한 연결체를 형성한다는 의미로 반복적인 학습을

통해 강화되고 유지가 가능하다. 게다가 어트랙터는 운동 수행의 제한요소가 변화하는 경우 새로운 상태로 수정되기도 한다(Tallet et al., 2008). 이렇게 인간의 협응은 고정되어 있는 것이 아니고 외부 환경과의 상호작용과 연습을 통해 지속적으로 변화하는 특징이 있기 때문에 적합한 환경을 조성하고, 적절한 피드백을 통한 협응구조의 질적인 변화를 추구할 수 있다. 따라서 인간의 협응은 특정 운동기술과 유기체, 환경에서 가장 적합한 최적 유형의 협응으로 변화해가는 과정을 의미한다고 볼 수 있다(Newell, 1985).

4. 치기 기술

운동기술이란 운동협응의 관점에서 그것을 구성하고 있는 변인들을 통제하여 최적의 협응이 이루어진 상태를 의미한다(Kugler et al., 1980). 운동기술은 여러 가지로 분류될 수 있는데 기술 수행에 필요한 근육의 크기에 따라 대근운동기술과 소근운동기술로 분류된다(김선진, 2015). 그런데 치기 기술은 전신의 협응을 요구하는 대근운동기술로 분류된다. 또한 치기 기술은 동작의 유형에 따라 오버헤드 치기, 사이드암 치기, 언더핸드 치기로 구분할 수 있고, 한 손 또는 양손 치기로 구분되는데, 야구의 치기는 사이드암 치기이며 양손 치기로 분류된다(김선진, 2003). 사이드암 치기는 발달 단계에서 가장 기본이 되는 치기 동작이며, 이는 백스윙, 포워드 스윙, 임팩트, 폴로스루로 구성된다. 이때 구분 동작이 조화롭게 이루어져야 공이 멀리 그리고 정확하게 타구된다. 이 치기 기술은 신체 중심에서 말단으로 멀어지는 순차적 패턴(proximal to distal sequence pattern, PDS)이 작용한다는 것을 의미한다. 즉 이 패턴은 회전운동이 관여된 운동기술로 효과적인 수행을 위해서는 신체 중심과 가장 가까운 골반으로부터 멀리 위치한 몸통, 어깨, 그리고 팔꿈치 등의 순으로 회전의 가속이 이루어져야 한다는 것이다(Putnam, 1993). 이 치기 기술은 숙련된 단계로 넘어갈수록 신체 중심 부위 근육의 토크를 활용하여 신체 말단 관절의 움직임 속도를 증가시켜 역동적인 사지 움직임

이 발생하게 된다(Hirashima et al., 2007). 이러한 치기 기술은 청소년기에 전문화된 움직임 기술로 나타나는데, 이는 움직임 기술을 결합하여 복잡하고 정교한 움직임으로 발전하는 것이다. 즉, 숙련된 기술을 수행하기 위해서는 움직임 패턴을 연습하여 움직임이 정교해지는 단계를 거쳐야 한다. 또한, 치기 기술이 전문화된 움직임 기술로 발달하기 위해서는 연습과 적절한 피드백을 제공하여 효율적인 학습이 이루어질 때 가능하다(Totsika & Wulf, 2003).

또한 치기 기술을 효과적으로 수행하기 위해서는 눈과 머리 및 손의 협응을 통해 물체를 추적할 수 있는 능력이 요구된다(김선진, 2003). 골프 퍼팅의 연구에서는 숙련자의 경우 퍼터와 머리 움직임 간에 부적 상관관계가 나타나 퍼터와 머리가 함께 움직였음을 의미하였다. 반면 비숙련자의 경우 퍼터와 머리 움직임 간에 정적인 상관관계가 나타나 퍼터와 머리가 별개로 움직였음을 의미했다(Lee et al., 2008). 특히 야구의 치기 기술에서는 머리의 움직임 범위가 눈의 움직임보다 더 큰 경향이 있다(Hubbard & Seng, 1954). 하지만 야구의 치기는 숙련자에 따라 눈-머리-손 협응이 시간과 공간의 타이밍을 이루기 위해 상호 보완하는 형태로 나타나기도 하고, 독립적으로 나타나기도 하는 등, 다양한 연구 결과로 나타난다(Toole & Fogt, 2021).

이것 뿐만 아니라 지면반력이라는 외부의 반작용을 사용하는 정도를 파악하기 위한 뻗는 발, 뻗는 쪽 하지의 무릎관절, 전신의 무게중심 및 압력중심의 이동, 엉덩 관절의 수직축을 중심으로 한 회전의 범위 및 각속도의 차이도 초보자에 비해 숙련자에서 더욱 크게 나타난다(Welch et al., 1995; Ae et al., 2017). 이는 숙련자의 경우 지면반력을 활용하여 관절의 회전토크를 더욱 크게 생성하기 위해 뻗는 발의 이동과 뻗는 하지의 무릎관절 신전 정도가 초보자에 비해 크고, 무게중심 및 압력중심의 이동이 더욱 크게 나타나는 것이다. 뿐만 아니라 백스윙 시에 골반의 최대 각도 타이밍이 숙련자가 초보자에 비해 임팩트 시점에 더욱 가까웠고, 포워드 스윙에서는 골반과 몸통의 각변위가 더욱 크게 나타났다(Nakata et al., 2014). 이러한 치기 기술은 발달 단계나 학습 단계에 따라 수평

방향의 스윙, 상체와 골반의 회전이 나타나는 스윙, 엉덩이와 몸통의 순차적 가속이 발생하는 스윙의 특징을 가지며 변화하게 된다(김선진, 2003).

Ⅲ. 연구 방법

본 연구에서는 전문적인 야구 선수로 경험이 없는 일반 남자 청소년과 야구 선수로 등록된 남자 청소년 숙련자를 대상으로 야구의 치기 기술을 실시하여 운동 수행 폼의 차이를 살펴보았다. 그 후 영상을 이용한 머신러닝을 통해 숙련자와 비숙련자를 자동으로 분류하는 프로그램을 제작하고 그 신뢰도를 검정해보기로 했다. 그 후에는 야구 선수로의 경험이 없는 일반 청소년을 대상으로 야구의 치기를 실시하고 인공지능 피드백, 또는 일반 피드백을 통해 학습한 후 나타나는 운동 수행 결과와 운동 수행 폼의 변화를 살펴보았다. 이를 위한 연구대상, 실험 과제 및 도구, 실험 절차, 자료 분석, 통계처리의 구체적인 내용은 다음과 같다.

1. 연구 대상

본 연구는 신경학적, 신체적, 인지적, 정신적으로 이상이 없는 만13세에서 만15세 사이의 남자 청소년 총 488명이 참여하였다. 이들 중 48명은 야구선수로 등록되어 있는 숙련자 집단이며, 440명은 야구선수 경험이 없는 초보자 집단이다. 그 후 인공지능 피드백을 활용한 운동학습의 연구에서는 신경학적, 신체적, 인지적, 정신적으로 이상이 없는 만13세에서 만15세 사이의 청소년 총 60명이 참여하였다. 이는 G*power (version 3.1.9.4; Düsseldorf University, Düsseldorf, Germnay; Faul et al., 2009)를 이용하여 α=.05, 파워=.80, 효과크기=.40를 입력하여 얻은 최소 샘플 사이즈로 40명의 값을 얻었고, 약 33%의 중도포기율을 고려한 값이다. 중도포기를 하지 않고 끝까지 연구에 참여한 운동학습 연구의 연구참여자는 총 42명이다.

2. 실험 과제 및 도구

1) 실험 과제

본 실험 과제는 야구의 치기 기술을 10회 시행하는 것으로, 야구 치기의 목표는 공을 가장 멀리 보내는 것이며, 이것은 타구 각도와 타구 속도에 의해 거의 결정된다. 이때 연구 참여자 몸통의 정면(타격 방향의 측면)에서 3.5m 떨어진 위치에 배팅티와 같은 높이에 삼각대와 카메라(Galaxy S9, Samsung, Korea)를 세팅하고 촬영하여 MediaPipe 프로그램과 python 3.10 및 MATLAB 프로그램(Mathworks, Inc., Natick, MA, USA)을 이용해 숙련자모델과 초보자모델의 머신러닝을 진행하는 것이다<그림 3>. 배팅티의 높이는 연구참여자의 엉덩 관절(iliac crest)로 설정하였다. 이는 스트라이크 존의 가운데 부분으로, 이에 비해서 상대적으로 높거나 낮은 배팅티에 위치한 공을 타격하는 것과 비교해 볼 때 어깨의 기울어짐 현상이 적게 나타난다. 따라서 엉덩 관절 높이에 위치한 배팅티는 초보자로 하여금 야구의 치기를 수행할 때에 연구참여자가 활용하는 신체의 자유도가 줄어들어 그 수행이 용이하다(Katsumata et al., 2017). 머신러닝이 완료되면 숙련자와 초보자를 구분하는 예상될 변인들을 백스윙, 하지의 움직임, 포워드 스윙, 골반-몸통-왼쪽 팔꿈치 타이밍으로 분류했다. 분류된 변인을 차후에 인공지능 피드백(AIfb)으로 제공하기 위해서 사전에 인터뷰한 야구 전문 코치의 큐(cue)를 각각 매칭하였다.

연구참여자에게 직접 제공되는 AIfb의 구조는 야구 전문 코치와 상의하여 청소년에게 인지하기 쉽게 제작되었고, 야구 전문 코치는 초등학생부터 고등학생때까지 야구 선수로 등록된 적이 있으며, 그 이후 선수 및 일반 학생들을 코칭한 경험이 있었다. Gfb을 제공한 야구 전문 코치는 AIfb을 함께 제작한 야구 전문 코치와는 다른 전문가이며, 초등학생부터 고등학생까지 야구 선수로 등록되

어 선수로 생활하였고, 그 이후 선수 및 일반 학생들을 코칭한 경험이 있었다.

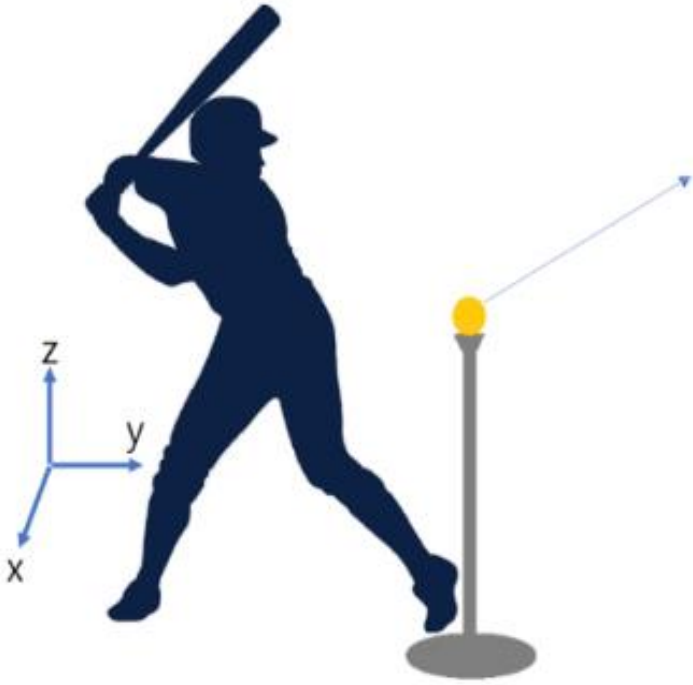

그림 3. 카메라가 촬영하는 야구의 치기 모습

이후 야구의 치기 학습에서는 운동 수행 폼의 향상과 운동 수행 결과의 향상을 목적으로 운동학습을 진행하였다. 운동 수행 폼은 백스윙 시 골반의 최대 회전 각도 타이밍, 하지의 움직임에서 뻗는 발의 타구 방향으로의 움직임 범위, 포워드 스윙 시 골반과 몸통의 회전 범위, 골반-몸통-왼쪽 팔꿈치 관절의 최대 각속도 발현 순서를 통해 확인한다. 운동 수행 결과의 향상은 공의 타구 속도와 타구 각도를 통해 확인한다.

2) 실험 도구

본 실험은 MediaPipe와 Python 3.10을 활용하여 제작한 움직임 동작 분석 및 숙련도 선별 프로그램을 통해 진행하였다. 각 실

험도구들의 구체적인 정보는 <표 1>과 같다.

표 1. 실험도구

실험도구		모델명	제조사 및 제조국
동작 분석 프로그램	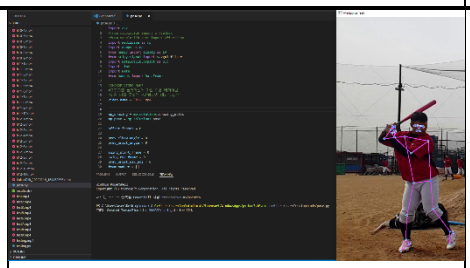	MediaPipe	Google, USA
노트북		TUF Gaming F17 Windows 11, an Intel Core™ i7-12700H	ASUS, Taiwan
카메라		갤럭시 S9	Samsung, Korea
무선 관성 센서		isen	STT, Spain

야구의 치기를 수행 및 촬영하기 위한 도구는 프로그램을 실행하기 위한 노트북, 티볼 공, 배팅티, 티볼 배트, 촬영을 위한 카메라가 사용되었다. 이후 운동학습 실험에서는 추가로 3차원 무선 관성센서(isen system, STT, Spain)를 사용하였다. 이때 전신의 움직임을 파악하고자 관련 부위(이마, 가슴뼈, 요추 5번, 상완, 전완, 손등, 대퇴사두근, 정강이, 발등, 티볼 배트)에 무선 센서를 흔들리지 않게 스트랩으로 부착하여 분절의 각도 및 각속도를 측정하였다. 각각의 센서는 100Hz로 정보를 수집하며 카메라와 동조(synchronization)되어 있다. 이를 통해 운동기술에 대한 신체 움직임의 각도, 각속도, 및 위상각 등을 실시간으로 산출하여 그래프로 표현할 수 있다. 또한 전체 스윙 구간에서 나타나는 골반, 몸통, 팔꿈치 관절의 최대 회전 각속도와 발현 시점, 관절들의 가동범위, 그리고 하지의 움직임을 파악하였다.

3. 실험 절차

1) 머신러닝의 검증

본 연구의 목적에 따라 야구의 치기를 촬영하여 MediaPipe를 통해 데이터를 수집하고, 머신러닝을 통해 숙련도를 분류하여 신뢰도를 검증하는 절차는 <그림 4>과 같다.

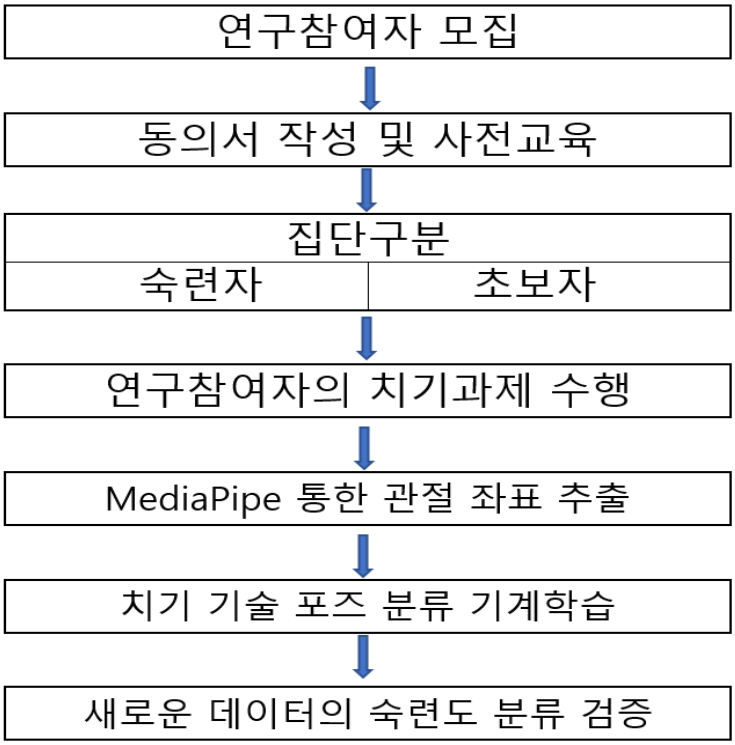

그림 4. 머신러닝의 검증

(1) 연구참여자 모집 및 사전교육

본 연구에 참여하는 연구대상자에게 실험 전 연구에 대해 자세하게 설명한 후 서울대학교 연구윤리위원회에서 승인(IRB No. 2210/002-016)한 연구 참여에 대한 동의서를 받을 것이다. 또한 실험 과제에 영향을 미칠 수 있는 연구참여자의 신경학적, 정형학적 이상 유무를 파악하였다. 이후 준비자세에서 두발의 위치와 그립 방법 및 스윙, 그리고 타구 목표에 대한 사전교육을 실시하였다.

(2) 실험 과제 수행

본 연구에서는 연구참여자가 서있을 때 엉덩 관절 높이만큼 위치한 티볼 공을 10번(1블록)씩 타구하는 실험 과제를 수행했다.

(3) 데이터 수집

본 실험의 데이터는 청소년 야구 선수로 등록된 숙련자 48명과 초보자 440명이 야구의 치기 기술을 실시할 때 발생하는 시간에 따른 분절들의 위치 및 속도, 관절들의 각도 및 각속도, 그리고 타구된 공의 속도 및 각도이다.

머신러닝 트레이닝을 위한 충분한 데이터를 획득하고, 이를 적절히 전처리하여 시스템 부하를 최소화 하고자 하였다. 시뮬레이션을 위해 MATLAB 프로그램 (Mathworks, Inc., Natick, MA, USA)의 주성분 분석 (principal component analysis, PCA) 코드를 사용하여 29개의 관절 및 분절의 움직임 데이터를 분석하여 설정한 전체 90%를 차지하는 PC값의 개수에 해당하는 주성분을 찾았다. 이를 바탕으로 SVM(Support Vector Machine) 알고리즘 모듈을 활용하여 학습을 진행했다.

(4) 머신러닝

본 실험의 데이터 중 숙련자 34명과 초보자 308명의 야구 치기 기술에 대한 값으로 머신러닝을 진행하였다. 이때 필요한 특정 관절 좌표를 수집하여 치기 기술의 포즈 분류 모델 학습 데이터를 생성하였다. 학습 데이터는 숙련자 14명과 초보자 132명의 데이터를 통해 관절 좌표를 생성하여 전체적인 숙련도 분류 모델의 틀을 잡고 학습 데이터를 생성하였다. 이는 머신러닝을 위한 훈련 데이터 세트와 테스트 데이터 세트를 7:3의 비율로 지정한 것이다. 치기 기술 학습에 필요한 관절 좌표를 각각 정의하고 MediaPipe Pose를 통해 관절 좌표 정보를 가져 올 때 잘못된 관절 좌표가 저장되는 문제를 방지하기 위해 치기 기술의 숙련도 분류 모델에 사용된 특징점을 비교해 신뢰도 값이 90% 이상인 좌표만 가져와 학습 데이터를 구성할 것이고, 이를 통해 숙련도 분류 모델의 정확도를 개선할 것이다(이용준 & 김태영). 시뮬레이션은 29개의 분절 및 관절 움직임에 대해 PCA 분석을 통해

유효한 주성분에 대해 MATLAB 프로그램(Mathworks, Inc., Natick, MA, USA)의 SVM(Support Vector Machine) 알고리즘 모듈을 활용하여 학습을 진행할 것이다. 숙련자 34명과 초보자 308명의 데이터 세트를 기반으로 PCA 분석을 거친 후, 머신러닝 프로그램을 학습시킬 것이다. 이를 바탕으로 숙련자 14명과 초보자 132명의 데이터 세트를 통해 학습된 모델의 유효성을 검증하기로 했다. 따라서 머신러닝의 연구에 참여한 연구참여자는 숙련자 48명, 초보자 440명으로 총 488명이다.

2) 운동학습의 절차

인공지능 피드백을 활용한 운동학습 실험 절차는 <그림 5>와 같다.

그림 5. 운동학습 실험의 절차

(1) 사전 검사

실험 1일 차에 연구참여자들은 실험 장소에 도착하여 준비된 실험동의서에 서약 후 실험 안내서를 정독했다. 연구자는 연구참여자가

참여할 실험에 대한 전반적인 설명을 하였다. 그 후 야구 전문 코치가 연구참여자에게 배트의 그립을 잡는 법, 준비자세, 스윙 등에 대한 설명을 하였다. 그 후 연구참여자는 8초 간격으로 배팅티에 놓여진 티볼공 10개를 최대한 멀리 타구하는 숙련자의 시범을 보고 2회 연습하게 한 후 지정된 위치에서 개인별로 총 10개의 타구를 8초 간격으로 실시하도록 할 것이다. 이때 수집된 데이터는 집단별로 사전 검사에서 수행오차에 대한 차이를 띄지 않게 하여 집단간 유의한 차이가 없게 하기 위해 사용하였다.

(2) 학습 단계

학습 단계는 5 일에 걸쳐 이루어졌다. 학습 단계에서는 하루에 5 블록을 타구하게 하였다. 1 블록은 10 개의 티볼공을 최대한 멀리 타구하는 것이며, 이상적인 타구 각도는 홈런이 가장 많이 발생되는 29°로 설정하였다. 이는 메이저리그에서 실행된 홈런의 타구 각도가 평균 24°에서 34° 사이였기 때문에 이 두 값을 평균한 값으로 설정한 것이다(Kagan, 2010). 이때 2 개의 티볼공을 타구 한 후 두 번째 타구에 대해서만 집단별로 집단에 따른 피드백을 부여 받았다. 따라서 한 블록에 5 번의 피드백을 부여 받은 것이다. 블록 사이에는 3 분의 휴식 시간을 두었다. 인공지능 피드백(AIfb)의 경우 운동 수행 폼과 운동 수행 결과가 모두 만족될 때에는 최종적으로 도달하고자 하는 폼인 골반-몸통-왼쪽 팔꿈치의 움직임 순서에 대한 긍정적인 수행지식과 타구 각도라는 결과지식이 제공됐다. 운동 수행 폼이 만족되고 운동 수행 결과가 만족되지 않는 경우도 위와 같이 긍정적인 수행지식과 타구 각도라는 결과지식이 제공됐다. 그런데 운동 수행 폼이 불만족되고 운동 수행 결과가 만족되는 경우에는 백스윙, 뻗는 발, 포워드 스윙, 그리고 순차적 가속(Sequence) 이 개선되기 위한 처방적 수행지식과 타구 각도라는 결과지식이 제공됐다. 해당하는 처방적 수행지식은 백스윙 시 골반의 최대 회전 각도 타이밍을 앞당기기 위한 것이며, 뻗는 발을 타구

방향으로 적절히 이동하기 위함이다. 또한 포워드 스윙 시 골반과 몸통의 회전 범위를 증가시키기 위한 것이며, 관절의 최대 각속도 발현 순서가 골반-몸통-왼쪽 팔꿈치로 나타나게 하기 위함이다. 이것들 중 부족한 움직임 부분에 대해서만 해당되는 처방적 수행지식을 타구 각도라는 결과지식과 함께 제시하였다. 운동 수행의 불만족 기준은 <표 2>와 같다. 타구 각도의 불만족 기준은 홈런이 가장 많이 발생되는 24°에서 34°를 벗어난 경우이며(Kagan, 2010), 관절의 움직임은 초보자와 숙련자 데이터의 평균값으로 설정하였다(Nakata et al., 2014).

이때 부족한 부분이 여러 개가 나타나는 경우 움직임이 나타나는 순서에 따라서 백스윙 부분의 수행지식, 뻗는 하지에 대한 수행지식, 포워드 스윙에서 상체의 각변위에 대한 수행지식, Sequence(관절의 연속 운동)에서 골반-몸통-왼쪽 팔꿈치 관절의 최대 각속도 타이밍에 대한 수행지식 중 동작이 나타나는 시간 순서대로 오류가 먼저 발생하는 부분의 처방적 수행지식 한가지를 제시하였다. 운동 수행 폼과 운동 수행 결과가 모두 만족되지 않을 때에도 부족한 부분이 나타나는 동작에 대한 처방적 수행지식과 타구 각도라는 결과지식을 함께 제공하였다.

또한 Gfb 의 경우 야구 전문 코치가 학습자를 직접 관찰하여 운동 수행 폼과 운동 수행 결과에 대해 각각 움직임에 대한 긍정적 또는 처방적 수행지식과 타구 각도라는 결과지식을 언어적 피드백으로 제시했다<표 3>. 긍정적 수행지식은 잘된 수행의 폼에 대한 지식으로, 백스윙, 하지, 포워드 스윙, sequence 의 범주에서 야구 전문 코치가 언어로 제공하였다. 백스윙에서의 예시로는 “골반과 무릎이 잘 굽혀졌습니다.”, 하지에서의 예시로는 “발이 티대까지 잘 뻗어졌습니다.”, 포워드 스윙에서의 예시로는 “상체가 비스듬히 잘 기울어진 상태로 스윙했습니다.”, sequence 에서의 예시로는 “골반-몸통-왼쪽 팔꿈치 순서로 움직임이 잘 나타났습니다.” 등이 야구 전문 코치에 의해 제공됐다. Gfb 의 처방적 수행지식은 일반화를 위해 백스윙, 하지의 움직임, 포워드 스윙, 순차적 가속이라는 범주에서 제공될 수 있도록 야구 전문 코치와 상의하였다.

표 2. 운동 수행의 불만족 기준

운동 수행 결과의 불만족 기준	운동 수행 폼의 불만족 기준
타구 각도 : 24°미만, 34°초과	1) 백스윙 : 오른손 잡이 기준으로 위에서 볼 때에 시계방향의 최대 골반 회전 각도의 시점부터 임팩트까지의 타이밍이 455ms 보다 긴 경우 2) 하지 : 뻗는 동작이 과하거나 부족하여 뻗는 발의 발목이 목표한 위치(티대의 중앙)보다 뻗는 방향으로 20cm 초과하거나 20cm 부족한 경우 3) 포워드 스윙 : 골반과 몸통의 각변위가 각각 80.3°와 102.8°에 못 미치는 경우 4) sequence : 골반-몸통-왼쪽 팔꿈치의 최대 각속도 순서가 일치하지 않는 경우

표 3. 피드백 내용

인공지능 피드백	운동 수행 결과 만족	운동 수행 결과 불만족
운동 수행 폼 만족	Sequence(골반-몸통-왼쪽 팔꿈치) “골반-몸통-왼쪽 팔꿈치 순서로 움직임이 잘 나타났습니다.” 타구 각도와 목표 각도(29°)	Sequence(골반-몸통-왼쪽 팔꿈치) “골반-몸통-왼쪽 팔꿈치 순서로 움직임이 잘 나타났습니다.” 타구 각도와 목표 각도(29°)
운동 수행 폼 불만족	1) 백스윙 “백스윙 시 양쪽 엄지발가락 쪽에 힘을 모으고, 골반과 무릎을 굽혀 모여진 모습으로 백스윙 한 후 순간적으로 타격 하세요.” 2) 하지의 움직임 “뻗는 발을 접을 때 몸이 뒤로 기울지 않게 하고, 뻗는 위치는 티대까지만 뻗으세요.” 3) 포워드 스윙 “몸을 비스듬히 하여 무릎과 골반을 사용하고, 뒤쪽 팔꿈치를 몸의 안쪽(가슴쪽)으로 가까이하여 스윙하세요.”	1) 백스윙 “백스윙 시 양쪽 엄지발가락 쪽에 힘을 모으고, 골반과 무릎을 굽혀 모여진 모습으로 백스윙 한 후 순간적으로 타격 하세요.” 2) 하지의 움직임 “뻗는 발을 접을 때 몸이 뒤로 기울지 않게 하고, 뻗는 위치는 티대까지만 뻗으세요.” 3) 포워드 스윙 “몸을 비스듬히 하여 무릎과 골반을 사용하고, 뒤쪽 팔꿈치를 몸의 안쪽(가슴쪽)으로 가까이하여 스윙하세요.”

	4) Sequence(골반-몸통-왼쪽 팔꿈치) “골반을 먼저 회전하고, 팔꿈치를 안쪽으로 하여 임팩트 후 멈추지 말고 멀리에 공이 있다고 생각하여 끝까지 회전하세요.” 타구각도와 목표 각도(29°)	4) Sequence(골반-몸통-왼쪽 팔꿈치) “골반을 먼저 회전하고, 팔꿈치를 안쪽으로 하여 임팩트 후 멈추지 말고 멀리에 공이 있다고 생각하여 끝까지 회전하세요.” 타구 각도와 목표 각도(29°)
일반 피드백	운동 수행 결과 만족	운동 수행 결과 불만족
운동 수행 폼 만족	운동 수행 폼에 대한 야구 전문 코치의 긍정적 수행지식 1) 백스윙 2) 하지의 움직임 3) 포워드 스윙 4) Sequence(골반-몸통-왼쪽 팔꿈치) 타구각도와 목표 각도(29°)	운동 수행 폼에 대한 야구 전문 코치의 긍정적 수행지식 1) 백스윙 2) 하지의 움직임 3) 포워드 스윙 4) Sequence(골반-몸통-왼쪽 팔꿈치) 타구각도와 목표 각도(29°)
운동 수행 폼 불만족	운동 수행 폼에 대한 야구 전문 코치의 처방적 수행지식 1) 백스윙 2) 하지의 움직임 3) 포워드 스윙 4) Sequence(골반-몸통-왼쪽 팔꿈치) 타구각도와 목표 각도(29°)	운동 수행 폼에 대한 야구 전문 코치의 처방적 수행지식 1) 백스윙 2) 하지의 움직임 3) 포워드 스윙 4) Sequence(골반-몸통-왼쪽 팔꿈치) 타구각도와 목표 각도(29°)

(3) 사후 검사

사후 검사는 학습 단계가 종료된 후 충분한 휴식을 취한 뒤에 사전 검사와 동일한 절차에 따라 실험을 진행하였다. 10개의 티볼공을 8초 간격으로 타구하여 한 블록을 실시하였다.

(4) 파지 검사

파지 검사는 학습 단계가 종료된 후 48시간 뒤에 사전 검사와 동일한 절차에 따라 실험을 진행하였다. 10개의 티볼공을 8초 간격으로 타구하여 한 블록을 실시하였다.

4. 실험 설계

본 연구는 집단(3 수준)과 검사 시점(3 수준)이 독립변인인 이원혼합설계(two factor mixed design)를 활용하였다. 또한 종속변인은 운동 수행 결과인 목표한 타구 각도에 대한 정확성 및 일관성과 타구된 공의 속도를 사용하였으며, 운동 수행 폼인 골반-몸통-왼쪽 팔꿈치의 최대 각속도의 발현 순서 및 관절 각도나 분절 움직임의 주성분 개수와 적재값(로딩값)으로 설계하였다<표 4>.

표 4. 실험 설계

독립변인			종속변인
피드백의 형태			1. 운동 수행 결과
AIfb	Gfb	control	-타구 각도의 정확성 -타구 각도의 일관성 -타구 속도
검사시점			2. 운동 수행 폼
사전 검사	사후 검사	파지 검사	-골반-몸통-왼쪽 팔꿈치 관절의 최대 각속도 순서 -관절 및 분절 움직임의 주성분 개수 -주성분의 분산 -주성분의 적재값 (로딩값)

5. 자료 분석

머신러닝의 알고리즘을 평가하기 위한 데이터의 분석으로 혼동행렬(Confusion matrix)와 ROC 커브(Receiver operating characteristic curve)를 사용하였다. 자료산출과 분석은 공학용 소프트웨어(MATLAB, Mathworks, USA)와 엑셀(MS Excel, Microsoft, USA)을 사용하였다.

본 운동학습연구의 종속변인은 목표한 타구 각도에 대한 정확성 및 일관성, 타구 속도, 그리고 관절의 최대각속도 순서 및 관절과 분절 움직임의 주성분 개수, PC에 기여하고 있는 변인들의 적재값(로딩값)이다. 이에 따른 산출은 MATLAB 프로그램 (Mathworks, Inc., Natick, MA, USA)과 MS Excel 프로그램(Microsoft, USA)을 사용하여 분석한다.

1) 혼동행렬(Confusion matrix)

혼동행렬은 알고리즘의 성능을 판단하기 위한 지표로 양성(positive)샘플 중에서 올바르게 판정된 것과 올바르지 않게 판정된 것을 쉽게 정리할 수 있다. 이는 추론된 결과와 실제 결과 간의 일치 여부에 따라서 <표 5>와 같이 분류할 수 있다.

표 5. 혼동행렬

	Predicted	
	Positive	Negative
Actual true	TP(true positive)	FN(false negative)
Actual false	FP(false positive)	TN(true negative)

이를 활용하여 머신러닝 모델의 성능 지표를 아래와 같이 구할 수 있는데, 본 연구에서 머신러닝 모델의 성능을 평가하는 지표로 정확도(Acurracy)를 사용했다.

(1) 정확도(Accuracy) $=\frac{TP+TN}{TP+TN+FP+FN}$

(2) 민감도(Sensitivity) $= \frac{TP}{TP+FN}$

(3) 특이도(Specificity) $= \frac{TN}{TN+FP}$

2) ROC 커브(Receiver operating characteristic curve)

ROC 커브는 민감도와 특이도의 관계를 표현한 그래프로 False positive의 비율을 x축, true positive의 비율을 y축에 배치하여 분석할 수 있다. 이때 ROC 커브의 x, y축의 평면상에서 아래쪽의 면적은 AUC(Area under the Curve)라고 하는데, 이것이 1에 가까우면 민감도와 특이도가 모두 높은 것으로 머신러닝의 알고리즘 성능이 좋은 분류라고 할 수 있다<그림 6>. 반면 AUC가 0.5 아래로 낮아지면 성능이 저하된 머신러닝 알고리즘으로 평가된다.

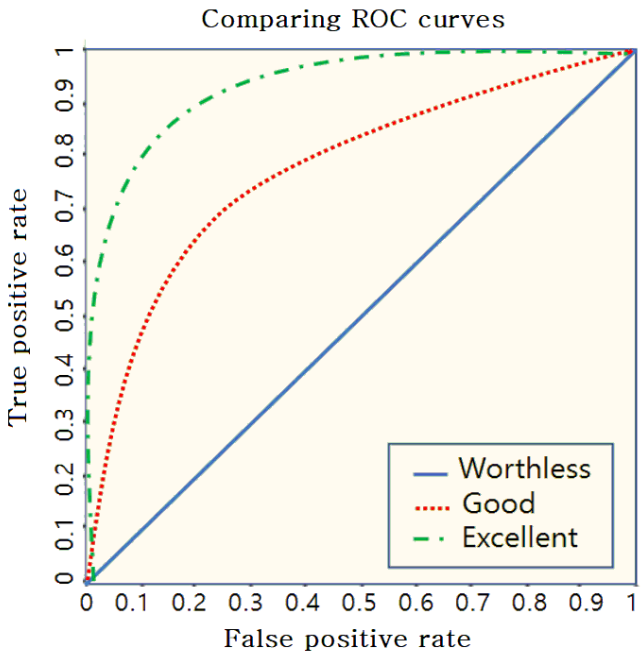

그림 6. ROC curve

3) 노이즈 제거

치기를 수행할 때 전신의 움직임을 분석하기 위해 사용된 무선 관성센서의 데이터들은 버터워즈저역 필터(4th lower pass Butterworth filter)로 필터링하였다. 본 실험에서 나타나는 움직임의 frequency에 대한 상한점을 설정하기 위해 FFT(Fast fourier transformations)를 이용했다. PSD(power spectrum density)가 99%를 차지하는 주파수는 10Hz였고, 이를 차단 주파수로 설정했다.

4) 주요변인 산출방법

(1) 운동 수행 결과

목표한 타구 각도는 24°~34° 이다. 정확성 및 일관성은 다음과 같다.

① 타구 각도의 정확성

타구된 공은 수평축(타구 방향)과 수직축을 기준으로 만들어지는 평면에서 발사되는 각도를 2차원 공간에서 파악하여 정확성을 측정하였다. 계산 과정에서 사용된 목표타구 각도는 29°이다. 1블록 당 총 10회의 타구를 모두 측정하였고 이에 대한 정확성으로 절대오차(AE: Absolute error)를 사용하였다<수식 1>.

수식 1. 절대오차(AE) $=\sum|x_i - T|/n$

[x_i는 i번째에 타구한 타구 각도, T=29°, n = 총 시행 수]

② 타구 각도의 일관성

일관성은 가변오차(VE: Variable error)를 사용하였다. 이것은 매 시행된 타구 각도와 시행된 타구 각도의 평균을 낸 값의 차이를 이용하여 계산한다. 다음<수식 2>에 의해 계산된다.

수식 2. 가변오차(VE) =$\sqrt{\sum(x_i - M)^2/n}$

[x_i는 i번째에 타구한 타구 각도, M=시행된 타구 각도의 평균, n = 총 시행 수]

③ 타구 속도

타구 속도는 km/hour의 단위로 측정하며, 속도 측정 프로그램(Kinovea software)을 사용할 것이다.

(2) 운동 수행 폼

관절의 굴곡(flexion)은 (+)방향, 신전(extension)은 (-)방향, 내전(adduction)은 (-)방향, 외전(abduction)은 (+)방향, 오른손잡이 기준 백스윙 시 발생하는 시계방향의 회전(clockwise)을 (-)방향, 포워드 스윙 시 발생하는 반시계방향의 회전(counter clockwise)을 (+)방향으로 설정하였고, iSen 3.0 장비의 무선 관성 센서를 사용하여 측정하였다. 분절의 타구 방향으로의 직선 움직임(medial-lateral)은 (+)방향으로 설정하였고 MediaPipe program을 사용하여 측정하였다. 전체 스윙 구간의 시점은 뻗는 다리인 왼쪽 무릎이 백스윙을 위해 최대로 굴곡했을 때의 각도에서 최대로 무릎이 신전된 각도의 차이값에 20%를 초과하는 시점으로 정하였고, 전체 스윙 구간의 종점은 배트의 아랫부분을 잡은 팔(오른손 잡이 기준으로 왼팔)의 팔꿈치가 임팩트 후 최대로 신전된 곳으로 정하였다. 임팩트 시점은 공이 타격되어 최대 속도의 10%를 넘는 시점으로 정하였다(Katsumata et al., 2017).

① 관절의 최대 각속도 발현 순서

관절의 최대 각속도 발현 순서는 골반의 회전 각속도, 몸통의 회전 각속도, 팔꿈치 관절의 각속도가 최대로

발현되는 시간의 순서를 의미한다.

② 관절 각도 및 분절 위치의 주성분

산출된 관절 각도 및 분절 위치의 데이터를 바탕으로 주성분 분석(principal component analysis, PCA)을 활용할 것이다(Ko & Newell, 2015). 주성분 분석에 사용하는 관절 및 분절은 <표 6>와 같다. 첫 번째부터 28번째까지의 데이터는 시간에 따른 각도 데이터이고, 29번째 데이터는 왼발이 오른발에 대해 공을 타구하는 방향(x축)으로의 시간에 따른 상대적 위치(거리)이다. 스윙 구간에서 나타나는 관절 및 분절의 29가지 움직임을 각각 시간에 따라 100개의 지점으로 선형보간(Linear interpolation)하여 100×29 행렬을 산출한 뒤 상관(correlation) 행렬(29×29)로 변환한다. 상관 행렬의 고유벡터(eigenvector)와 고유치(eigenvalue)을 산출하여 29개의 주성분(principal component, PC)중에 고유치(eigenvalue)가 주로 차지하는 PC값을 찾을 것이다. 각 PC(주성분)에 미치는 관절 및 분절들의 기여도를 나타내는 적재값(로딩값)은 가장 큰 값을 나타내는 5개의 관절에서 살펴볼 것이다.

표 6. 주성분 분석에 사용되는 관절 및 분절의 움직임

관절/분절	운동면	움직임
Shoulder	sagittal plane	flexion-extension
	frontal plane	adduction-abduction
	horizontal plane	horizontal adduction -horizontal abduction
elbow	sagittal plane	flexion-extension
	horizontal plane	pronation-supination
wrist	sagittal plane	flexion-extension
	frontal plane	adduction-abduction
torso	horizontal plane	clockwise-counter clockwise
Hip	sagittal plane	flexion-extension
	horizontal plane	clockwise-counter clockwise
	frontal plane	adduction-abduction
pelvis	horizontal plane	clockwise-counter clockwise
knee	sagittal plane	flexion-extension
ankle	sagittal plane	flexion-extension
	frontal plane	inversion-eversion
Left foot	frontal plane	medial-lateral

6. 통계 분석

본 연구에서는 GraphPad Prism 7.0의 통계 프로그램을 활용하여 다음과 같은 통계 분석을 실시하였다. 가설 검증을 위한 유의 수준은 .05로 하였다.

* 집단과 검사시점에 따른 기술 통계치를 산출하였다.

* 집단과 검사시점에 따른 타구 각도의 정확성 및 일관성, 타구 속도, 관절의 최대 각속도 발현 순서 비율, 주성분의 분산을 비교하기 위한 반복측정 이원 분산 분석(Two-way ANOVA with repeated measures on the second factor)을 실시한 뒤 유의한 차이가 있는 경우 Tukey's multiple comparison test를 통해 사후검정(Post-Hoc analysis)을 실시할 것이다. 그리고 관절 협응구조의 주성분 개수는 그룹 간의 비교에서는 Kruskal-Wallis test를, 검사 시점 간의 비교에서는 Friedman test를 통해 검정하며, Dunn's multiple comparison test를 통해 다중비교하여 사후검정을 실시할 것이다.

Ⅳ. 연구 결과

1. 머신러닝의 검증

본 연구에서는 Matlab 프로그램을 활용하여 29개의 관절 및 분절의 움직임에 대하여 주성분 분석(principal component analysis, PCA)을 실시한 후, 고유치(eigenvalue)가 주로 차지하는 PC값을 찾았다. 그 후 6개의 PC에서 score(주성분 점수)에 해당하는 데이터로 SVM을 실시하여 머신러닝의 학습을 진행하였고<그림 7>, 새로운 데이터를 바탕으로 신뢰도를 검증하여 아래와 같은 결과가 나타났다. SVM을 실행하기 위한 하나의 데이터 세트는 시간에 따른 29개의 관절에 대해서 50개로 선형보간한 데이터를 1행×1450열로 정렬되었다. 이때 머신러닝을 위한 dataset의 구성은 아래와 같다.

* 초보자 dataset
 -SVM 모델 학습을 위한 3080 cycles의 초보자 운동 데이터
* 숙련자 dataset
 -SVM 모델 학습을 위한 340 cycles의 숙련자 운동 데이터

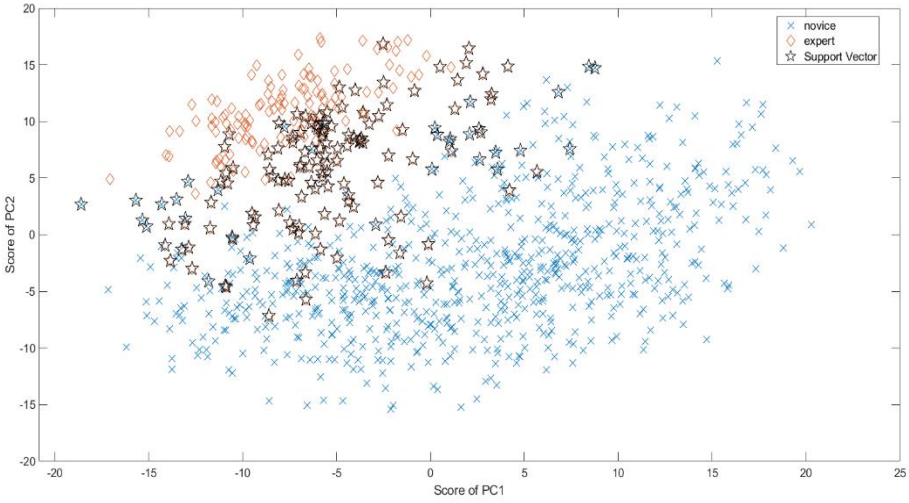

그림 7. PC1과 PC2로 시각화한 숙련도 분류

1) 혼동행렬

본 실험에서 머신러닝 검증의 결과로 나온 혼동행렬은 아래와 같다 <표 7>.

표 7. SVM을 활용한 머신러닝의 혼동행렬

	Predicted	
	초보자	숙련자
실제 초보자	TP=1310	FN=10
실제 숙련자	FP=33	TN=107

이를 활용하여 머신러닝 모델의 성능 지표는 아래와 같다. 본 연구에서 머신러닝 모델의 성능을 평가하는 지표로 정확도(Accuracy)는 97.1%가 나왔다.

(1) 정확도(Accuracy) = $\frac{TP+TN}{TP+TN+FP+FN} = \frac{1418}{1460} = .971233$

(2) 민감도(Sensitivity) = $\frac{TP}{TP+FN} = \frac{1310}{1320} = .992424$

(3) 특이도(Specificity) = $\frac{TN}{TN+FP} = \frac{107}{140} = .764286$

2) ROC 커브(Receiver operating characteristic curve)

ROC 커브는 민감도와 특이도의 관계를 표현한 그래프로 본 연구에서는 SVM을 활용하여 기계학습을 진행한 후 ROC 커브를 생성하였다<그림 8>. 1460개의 데이터 세트에 대한 5겹 교차검증을 완료한 후, curve의 아랫부분의 넓이 AUC(Area Under the Curve)는 .9809가 나왔다.

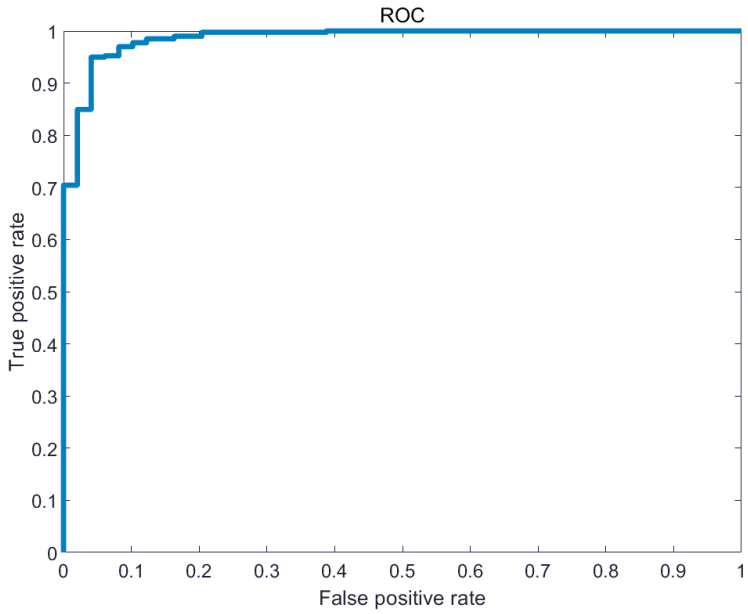

그림 8. ROC curve(Receiver operating characteristic curve)

3) 숙련자와 초보자의 야구 치기에 대한 주성분 개수

야구 치기에 대한 관절 간 협응구조를 확인하기 위해 주성분 분석(principal component analysis, PCA)을 실시하였고, 주성분으로 설명되는 분산(latent)이 90%를 초과하는 첫 PC 개수를 파악하였다<표 8>.

$\vec{X} = (X_1, X_2, \dots, X_n)^T, \sum(\sigma_{ij})_{n\times n}$의 상관행렬은 n개의 latent인 $\lambda_1, \lambda_2, \dots, \lambda_n$와 n개의 벡터를 갖는다. $\lambda_1 \geq \lambda_2 \geq \cdots \geq \lambda_n \geq 0$ 그리고 직교하는 고유 벡터 $\overrightarrow{e_1}, \overrightarrow{e_2}, \dots, \overrightarrow{e_n}$를 가정하면, $X_1, X_2, \dots, X_n$의 i번째 주성분은 아래와 같이 표현된다.

<수식 3> $Y_i = e_{i1}X_1 + e_{i2}X_2 + \cdots + e_{in}X_n,\ i = 1,2,\dots,n$

$\mathrm{Var}(Y_i) = \overrightarrow{e_i}^T \cdot \sum \cdot \overrightarrow{e_i} = \lambda_i,\ Cor(Y_i, Y_j) = \overrightarrow{e_i}^T \cdot \sum \cdot \overrightarrow{e_i} = 0,\ \mathrm{i} \neq \mathrm{j}.$

p번째 주성분에서 누적되는 분산의 양의 비율 $= \sum_{i=1}^{p} \lambda_i / \sum_{i=1}^{n} \lambda_i$

표 8. 주성분으로 설명되는 분산(latent)이 90%를 초과하는 첫 PC 개수의 백분율

주성분 개수	숙련자(%)	초보자(%)
1	0	0
2	0	0
3	4.15	3.50
4	52.70	40.55
5	34.85	47.43
6	7.05	7.76
7	1.24	0.75

숙련자의 경우 전체 수행 중 4개의 주성분이 가장 높은 빈도를 나타냈고, 초보자의 경우 전체 수행 중 5개의 주성분이 가장 높은 빈도를 나타냈다. 숙련성에 따라 주성분으로 설명되는 분산이 90%를 초과하게 되는 주성분의 개수 차이의 유의성을 확인하기 위해 비모수 검정을 실시하였다<표 9>. 검정 결과 숙련자가 초보자에 비해서 주성분 개수가 유의하게 적었다(p <.01).

표 9. 숙련성에 따른 주성분 개수의 차이 검정

변량원	자유도	검정값	p
숙련성	1	U=85098	.0027**

서열변수인 주성분 개수의 차이 검정을 위해 Mann-Whitney U-test를 실시하였다. *유의한 차이(p <.05); **유의한 차이(p <.01), ***유의한 차이(p <.001)

4) 주성분으로 설명되는 분산

각각의 주성분으로 설명되는 분산의 양은 <표 10>과 같다. 숙련성에 따라 각각의 주성분 비율에서 유의한 차이가 나타났다<그림 9>. PC1의 경우, 숙련자가 초보자에 비해 유의하게 높은 분산을 나타냈다(t=3.817, p <.001). PC2의 경우, 숙련자가 초보자에 비해 유의하게 높은 분산을 나타냈다(t=9.834, p <.001). PC3의 경우, 숙련자가 초보자에 비해 유의하게 높은 분산을 나타냈다(t=4.546, p <.001). PC4의 경우, 숙련자가 초보자에 비해 유의하게 높은 분산을 나타냈다(t=3.218, p=.0013). PC5의 경우, 숙련자가 초보자에 비해 유의하게 높은 분산을 나타냈다(t=5.617,

p <.001). PC6의 경우, 숙련자가 초보자에 비해 유의하게 높은 분산을 나타냈다(t=10.48, p <.001).

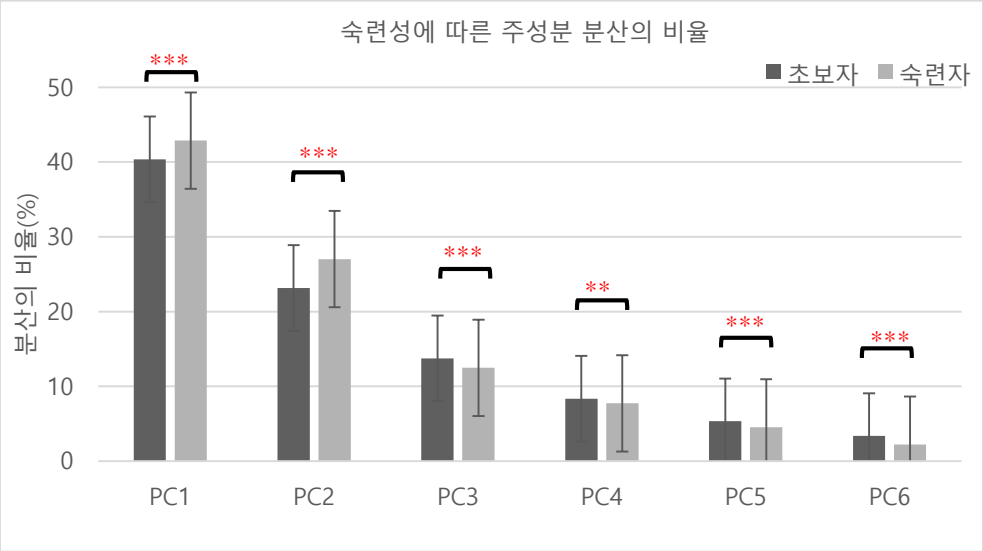

그림 9. 숙련성에 따른 각 주성분의 분산 차이 비교(평균과 표준오차)
(단, *유의한 차이(p <.05); **유의한 차이(p <.01); ***유의한 차이(p <.001))

표 10. 주성분으로 설명되는 분산

숙련성	Variance(%)	PC1	PC2	PC3	PC4	PC5
숙련자	Explained	42.86	27.02	12.47	7.73	4.51
	Accumulated	42.86	69.88	82.35	90.08	94.59
초보자	Explained	40.38	23.14	13.74	8.34	5.32
	Accumulated	40.38	63.52	77.26	85.60	90.92

5) 적재값(loading data)

관절 각도 및 분절의 이동에 대한 적재값은 <표 11>와 같다<그림 10>. 숙련자의 경우 주성분으로부터 설명된 분산이 가장 높은 주성분1(PC1)에서는 왼쪽 어깨의 좌우면 움직임(내전-외전), 오른쪽 어깨의 수평면 움직임(회내-회외), 오른쪽 손목의 좌우면 움직임(척골 굴곡-요골 굴곡), 골반의 수평면 움직임, 오른쪽 발목의 시상면 움직임(굴곡-신전)이 높은 기여도를 나타냈다. 주성분2(PC2)에서는 왼쪽 엉덩 관절의 시상면 움직임(굴곡-신전), 오른쪽 엉덩 관절의 수평면 움직임, 오른쪽 엉덩 관절의 좌우면 움직임(내전-외전), 왼쪽 엉덩

관절의 좌우면 움직임(내전-외전), 왼쪽 무릎의 시상면 움직임(굴곡-신전)이 높은 기여도를 나타냈다. 주성분3(PC3)에서는 오른쪽 어깨의 시상면 움직임(굴곡-신전), 왼쪽 어깨의 시상면 움직임(굴곡-신전), 왼쪽 어깨의 수평면 움직임(회내-회외), 오른쪽 엉덩 관절의 좌우면 움직임(내전-외전), 왼쪽 발의 내측-외측 움직임에서 높은 기여도를 나타냈다. 주성분4(PC4)에서는 오른쪽 어깨의 시상면 움직임(굴곡-신전), 오른쪽 어깨의 좌우면 움직임(내전-외전), 오른쪽 팔꿈치의 시상면 움직임(굴곡-신전), 몸통의 수평면 움직임, 왼쪽 엉덩 관절의 수평면 움직임(회내-회외)에서 높은 기여도를 나타냈다.

초보자의 경우 주성분1(PC1)에서는 오른쪽 어깨의 좌우면 움직임(내전-외전), 왼쪽 어깨의 수평면 움직임(회내-회외), 오른쪽 팔꿈치의 시상면 움직임(굴곡-신전), 골반의 수평면 움직임, 왼쪽 무릎의 시상면 움직임(굴곡-신전)에서 높은 기여도를 나타냈다. 주성분2(PC2)에서는 오른쪽 팔꿈치의 시상면 움직임(굴곡-신전), 왼쪽 팔꿈치의 시상면 움직임(굴곡-신전), 왼쪽 엉덩 관절의 시상면 움직임(굴곡-신전), 골반의 수평면 움직임, 왼쪽 무릎의 시상면 움직임(굴곡-신전)에서 높은 기여도를 나타냈다. 주성분3(PC3)에서도 주성분2와 같이 오른쪽 팔꿈치의 시상면 움직임(굴곡-신전), 왼쪽 팔꿈치의 시상면 움직임(굴곡-신전), 왼쪽 엉덩 관절의 시상면 움직임(굴곡-신전), 골반의 수평면 움직임, 왼쪽 무릎의 시상면 움직임(굴곡-신전)에서 높은 기여도를 나타냈다. 주성분4(PC4)에서는 오른쪽 어깨의 수평면 움직임(회내-회외), 오른쪽 팔꿈치의 시상면 움직임(굴곡-신전), 왼쪽 팔꿈치의 시상면 움직임(굴곡-신전), 왼쪽 엉덩 관절의 시상면 움직임(굴곡-신전), 왼쪽 무릎의 시상면 움직임(굴곡-신전)에서 높은 기여도를 나타냈다. 주성분5(PC5)에서는 오른쪽 팔꿈치의 시상면 움직임(굴곡-신전), 왼쪽 팔꿈치의 시상면 움직임(굴곡-신전), 몸통의 수평면 움직임, 왼쪽 무릎의 시상면 움직임(굴곡-신전), 왼쪽 발목의 수평면 움직임(내번-외번)에서 높은 기여도를 나타냈다.

표 11. 주성분 계수(적재값)

	관절 및 분절	PC1	PC2	PC3	PC4	PC5
숙련자	R-shoulder-sagittal	0.131	0.146	0.216	0.189	0.170
	L-shoulder-sagittal	0.166	0.145	0.210	0.182	0.150
	R-shoulder-frontal	0.194	0.120	0.159	0.198	0.117
	L-shoulder-frontal	0.237	0.109	0.135	0.106	0.102
	R-shoulder-horizontal	0.221	0.109	0.099	0.096	0.136
	L-shoulder-horizontal	0.161	0.146	0.222	0.151	0.125
	R-elbow-sagittal	0.164	0.082	0.185	0.197	0.185
	L-elbow-sagittal	0.134	0.144	0.152	0.140	0.155
	R-elbow-horizontal	0.194	0.095	0.118	0.103	0.185
	L-elbow-horizontal	0.092	0.127	0.171	0.183	0.243
	R-wrist-sagittal	0.161	0.132	0.157	0.145	0.152
	L-wrist-sagittal	0.161	0.145	0.168	0.185	0.170
	R-wrist-frontal	0.240	0.101	0.090	0.085	0.094
	L-wrist-frontal	0.115	0.166	0.173	0.192	0.200
	Torso-turn-horizontal	0.143	0.133	0.123	0.209	0.168
	R-hip-sagittal	0.161	0.145	0.168	0.185	0.170
	L-hip-sagittal	0.103	0.242	0.164	0.137	0.145
	R-hip-horizontal	0.102	0.301	0.120	0.112	0.108
	L-hip-horizontal	0.168	0.136	0.164	0.187	0.149
	R-hip-frontal	0.103	0.204	0.217	0.136	0.162
	L-hip-frontal	0.109	0.268	0.115	0.116	0.113
	Pelvis-turn-horizontal	0.236	0.093	0.099	0.108	0.118
	R-knee-sagittal	0.142	0.163	0.197	0.170	0.187
	L-knee-sagittal	0.195	0.202	0.084	0.081	0.086
	R-Ankle-sagittal	0.248	0.116	0.093	0.098	0.083
	L-Ankle-sagittal	0.210	0.166	0.085	0.082	0.091
	R-Ankle-frontal	0.197	0.137	0.115	0.130	0.098
	L-Ankle-frontal	0.191	0.159	0.098	0.112	0.097
	L-foot-medial-lateral	0.161	0.146	0.222	0.151	0.125

	관절 및 분절	PC1	PC2	PC3	PC4	PC5
초보자	R-shoulder-sagittal	0.118	0.160	0.176	0.195	0.159
	L-shoulder-sagittal	0.210	0.174	0.147	0.136	0.144
	R-shoulder-frontal	0.287	0.166	0.185	0.173	0.196
	L-shoulder-frontal	0.212	0.183	0.169	0.191	0.151
	R-shoulder-horizontal	0.121	0.170	0.181	0.227	0.175
	L-shoulder-horizontal	0.235	0.193	0.170	0.156	0.157
	R-elbow-sagittal	0.368	0.280	0.232	0.236	0.254
	L-elbow-sagittal	0.152	0.201	0.225	0.260	0.205
	R-elbow-horizontal	0.007	0.013	0.016	0.020	0.027
	L-elbow-horizontal	0.007	0.011	0.016	0.022	0.029
	R-wrist-sagittal	0.007	0.012	0.017	0.019	0.028
	L-wrist-sagittal	0.007	0.013	0.018	0.022	0.028
	R-wrist-frontal	0.009	0.014	0.018	0.016	0.019
	L-wrist-frontal	0.008	0.013	0.017	0.022	0.025
	Torso-turn-horizontal	0.189	0.199	0.203	0.159	0.217
	R-hip-sagittal	0.113	0.115	0.165	0.151	0.137
	L-hip-sagittal	0.177	0.221	0.241	0.214	0.191

R-hip-horizontal	0.061	0.080	0.103	0.090	0.123
L-hip-horizontal	0.061	0.116	0.096	0.134	0.145
R-hip-frontal	0.058	0.106	0.116	0.089	0.098
L-hip-frontal	0.080	0.108	0.099	0.110	0.140
Pelvis-turn-horizontal	0.310	0.274	0.248	0.175	0.180
R-knee-sagittal	0.087	0.137	0.136	0.137	0.130
L-knee-sagittal	0.325	0.287	0.285	0.235	0.213
R-Ankle-sagittal	0.046	0.075	0.083	0.087	0.099
L-Ankle-sagittal	0.067	0.101	0.117	0.138	0.168
R-Ankle-frontal	0.046	0.079	0.085	0.069	0.074
L-Ankle-frontal	0.080	0.116	0.134	0.212	0.217
L-foot-medial-lateral	0.007	0.014	0.016	0.020	0.025

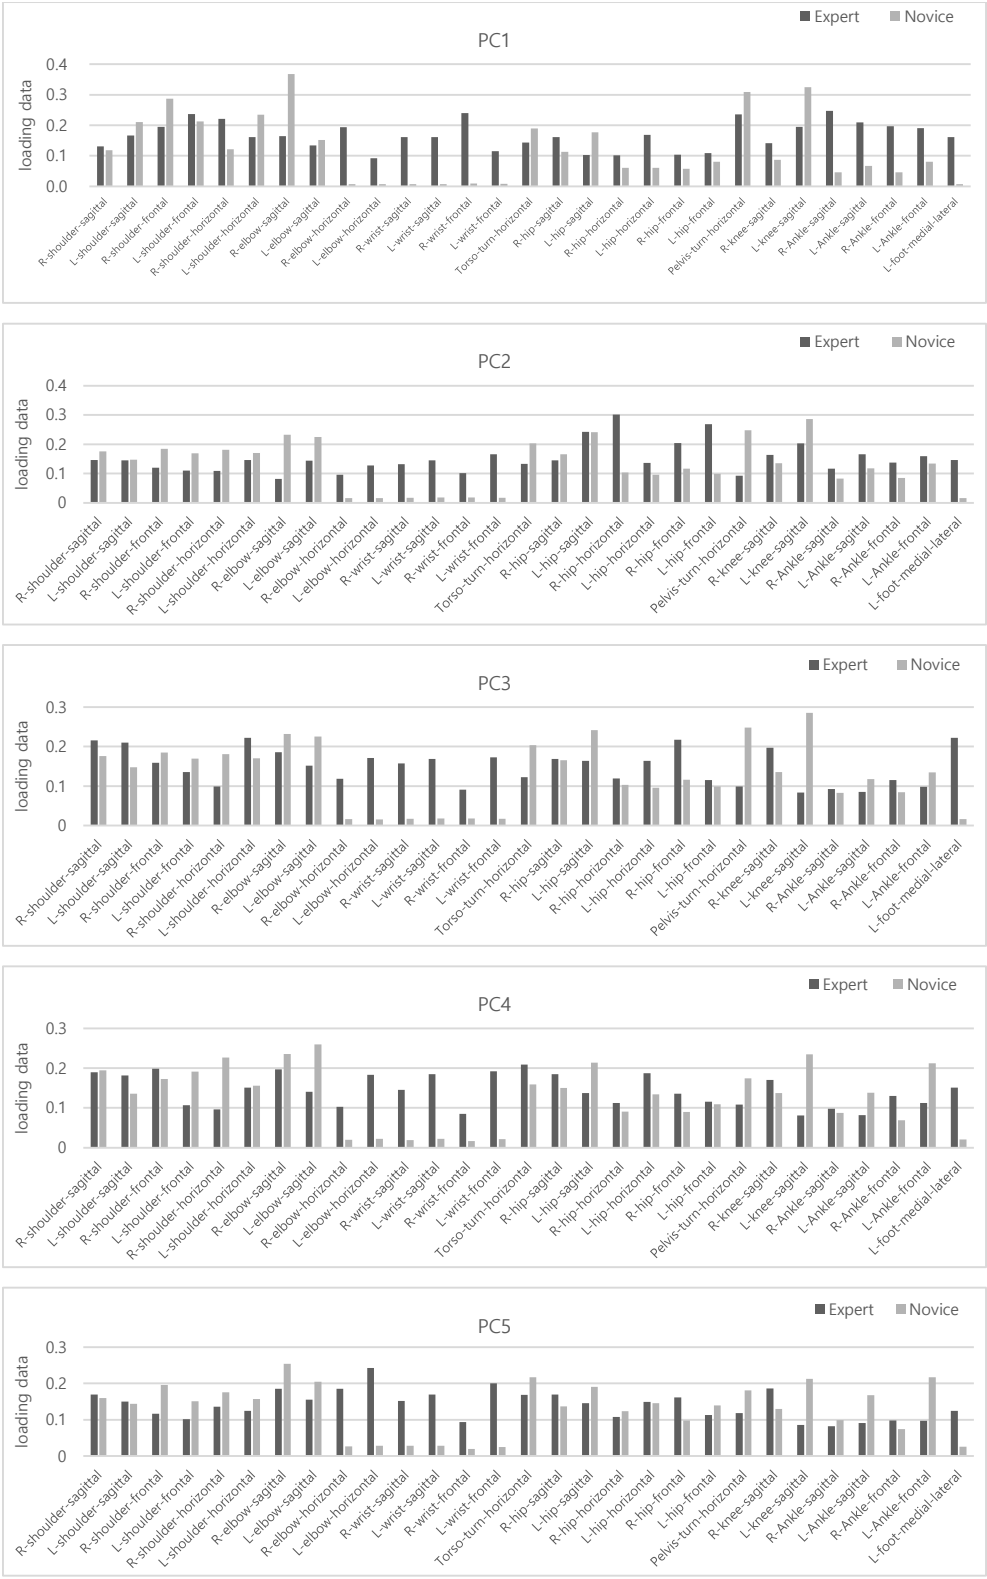

그림 10. 숙련성에 따른 각 PC의 계수(적재값)

2. 운동학습 실험

1) 운동 수행 결과

운동 수행 결과는 타구 각도의 정확성과 일관성, 그리고 타구 속도로 살펴봤으며, 아래와 같은 결과가 나타났다.

(1) 타구 각도의 정확성

타구 각도의 정확성은 목표 타구 각도인 24° ~ 34°의 중간 값인 29°에서 차이값의 크기를 비교했다. 집단과 검사 시점에 따른 평균과 표준편차는 <표 12>과 같고 차이와 변화는 <그림 11>으로 표현했다.

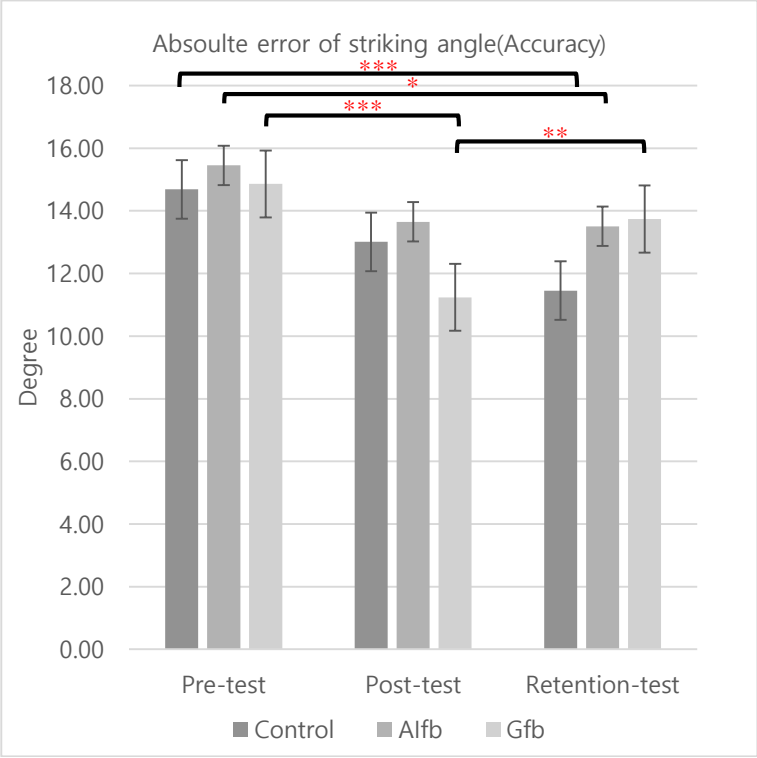

그림 11. 집단과 검사 시점에 따른 타구 각도의 절대오차(정확성)

(단, *유의한 차이(p <.05); **유의한 차이(p <.01); ***유의한 차이(p <.001))

분석결과 집단에 대한 주효과 검증에서 타구 각도의 정확성 차이는 유의하지 않았다[F(2, 39) = 2.075, p <.1392]. 반면 검사 시점에 대한 주효과 검증 유의한 차이가 나타났다[F(2, 78) = 17.54, p <.001]. 마지막으로 집단과 검사 시점에 따른 상호작용 효과는 유의미하게 나타났다[F(4, 78) =3.806, p <.01].

시점에 따른 차이를 분석하기 위해 3가지 그룹에서 3가지 시점 간의 다중 비교인 사후검정(post-hoc analysis)을 실시한 결과, 통제집단은 사후 검사에서 사전 검사보다 절대오차가 유의하게 낮았다(p <.001). AIfb집단의 경우 파지 검사에서 사전 검사보다 절대오차가 유의하게 낮았다(p <.05). Gfb집단의 경우, 사후 검사에서 사전 검사보다 절대오차가 유의하게 낮았고(p <.001), 사후 검사에서 파지 검사보다 절대오차가 유의하게 낮았다(p <.01).

표 12. 집단과 검사 시점에 따른 타구 각도의 정확성(절대오차)

검사 시점	통제집단	AIfb 집단	Gfb 집단
사전 검사	14.68°±6.81	15.45°±5.94	15.43°±4.86
사후 검사	13.01°±0.86	13.65°±1.56	11.24°±2.79
파지 검사	11.45°±2.09	13.51°±1.39	13.74±9.41

(2) 타구 각도의 일관성

타구 각도의 일관성은 수행한 타구의 평균 각도에서의 차이값 크기를 비교하였다. 각 집단과 검사 시점에 따른 평균과 표준편차는 <표 13>과 같다. <그림 12>은 집단과 검사 시점에 따른 차이를 표현했다.

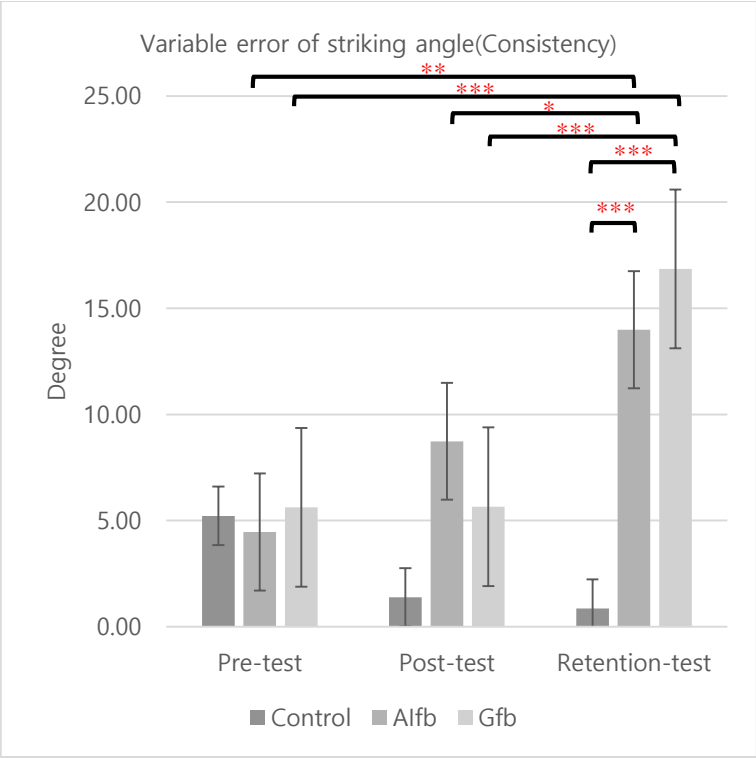

그림 12. 집단과 검사 시점에 따른 타구 각도의 가변오차(일관성)

(단, *유의한 차이(p <.05); **유의한 차이(p <.01); ***유의한 차이(p <.001))

분석결과 집단에 대한 주효과 검증에서 타구 각도의 일관성(가변오차) 차이는 유의미하게 나타났다[F(2, 39) =11.3, p <.001]. 또한 검사 시점에 대한 주효과 검증 유의한 차이가 나타났다[F(2, 78) = 14.65, p <.001]. 마지막으로 집단과 검사 시점에 따른 상호작용 효과는 유의미하게 나타났다[F(4, 78) =5.636, p <.001]. 그룹에 따른 차이를 분석하기 위해 3가지 시기에서 3가지 그룹 간의 다중 비교인 사후검정(post-hoc

analysis)을 실시한 결과 파지 검사(retention-test)에서 AIfb집단이 통제집단에 비해 가변오차가 유의하게 낮았고(p <.001), Gfb집단이 통제집단에 비해 가변오차가 유의하게 낮았다(p <.001).

시점에 따른 차이를 분석하기 위해 3가지 그룹에서 3가지 시점 간의 다중 비교인 사후검정(post-hoc analysis)을 실시한 결과, AIfb집단의 경우 파지 검사에서 사전 검사보다 가변오차가 유의하게 낮았고(p <.01), 파지 검사에서 사후 검사보다 가변오차가 유의하게 낮았다(p <.05). Gfb 집단의 경우, 파지 검사에서 사전 검사보다 가변오차가 유의하게 낮았고(p <.001), 파지 검사에서 사후 검사보다 가변오차가 유의하게 낮았다(p <.001).

표 13. 집단과 검사 시점에 따른 타구 각도의 일관성

검사 시점	통제집단	AIfb 집단	Gfb 집단
사전 검사	5.22°±11.73°	4.46°±10.81°	5.63°±9.96°
사후 검사	1.39°±1.52°	8.74°±2.96°	5.66°±9.97°
파지 검사	0.86°±0.89°	13.99°±3.72°	16.86°±27.50°

(3) 타구 속도

타구 속도는 3차원에서 생성되는 타구된 공의 속도 크기를 비교하였다. 각 집단과 검사 시점에 따른 평균과 표준편차는 <표 14>과 같다. <그림 13>은 집단과 검사 시점에 따른 차이를 표현했다.

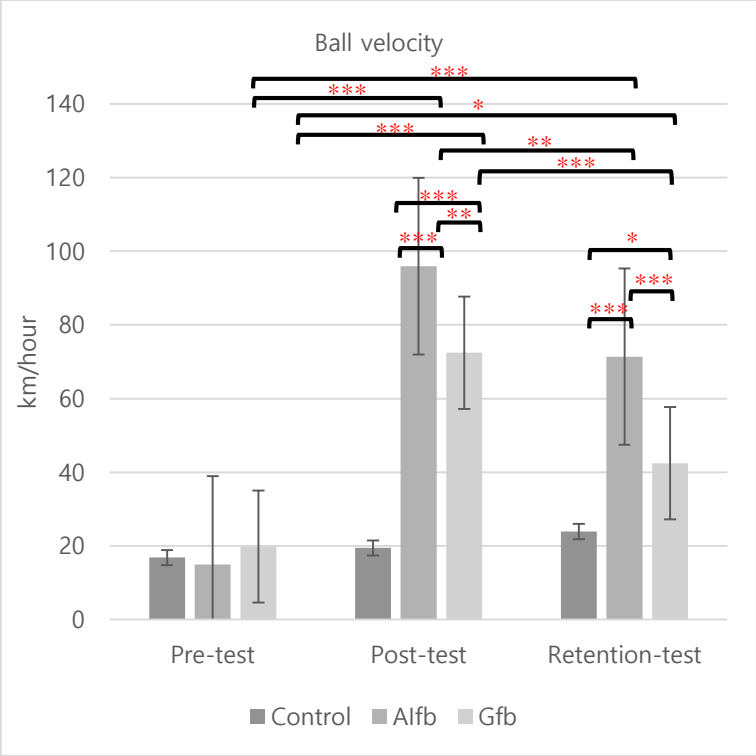

그림 13. 집단과 검사 시점에 따른 타구 속도

(단, *유의한 차이(p <.05); **유의한 차이(p <.01); ***유의한 차이(p <.001))

분석결과 집단에 대한 주효과 검증에서 타구 속도 차이는 유의미하게 나타났다[F(2, 39) =62.84, p <.001]. 또한 검사 시점에 대한 주효과 검증 유의한 차이가 나타났다[F(2, 78) = 53.05, p <.001]. 마지막으로 집단과 검사 시점에 따른 상호작용 효과는 유의미하게 나타났다[F(4, 78) =14.27, p <.001]. 그룹에 따른 차이를 분석하기 위해 3가지 시기에서 3가지 그룹 간의 다중 비교인 사후검정(post-hoc analysis)을 실시한 결

과, 사후 검사(post-test)에서 AIfb집단이 통제집단에 비해 타구 속도가 유의하게 높았고(p <.001), Gfb집단이 통제집단에 비해 타구 속도가 유의하게 높았으며(p <.001), AIfb집단이 Gfb집단에 비해 타구 속도가 유의하게 높았다(p <.01). 파지 검사(retention-test)에서도 AIfb집단이 통제집단에 비해 타구 속도가 유의하게 높았고(p <.001), Gfb집단이 통제집단에 비해 타구 속도가 유의하게 높았으며(p <.05), AIfb집단이 Gfb집단에 비해 타구 속도가 유의하게 높았다(p <.001).

시점에 따른 차이를 분석하기 위해 3가지 그룹에서 3가지 시점 간의 다중 비교인 사후검정(post-hoc analysis)을 실시한 결과, AIfb집단의 경우 사후 검사에서 사전 검사보다 타구 속도가 유의하게 높았고(p <.001), 파지 검사에서 사전 검사보다 타구 속도가 유의하게 높았으며(p <.001), 사후 검사에서 파지 검사보다 타구 속도가 유의하게 높았다(p <.01). Gfb집단의 경우에도, 사후 검사에서 사전 검사보다 타구 속도가 유의하게 높았고(p <.001), 파지 검사에서 사전 검사보다 타구 속도가 유의하게 높았으며(p <.05), 사후 검사에서 파지 검사보다 타구 속도가 유의하게 높았다(p <.001).

표 14. 집단과 검사 시점에 따른 타구 속도의 평균과 표준편차

검사 시점	통제집단	AIfb 집단	Gfb 집단
사전 검사	16.82 ±8.90 km/h	14.97±7.80 km/h	19.80±6.53 km/h
사후 검사	19.43±13.53 km/h	95.97±64.63 km/h	72.43±50.89 km/h
파지 검사	23.90±10.13 km/h	71.38±60.11 km/h	42.44±42.11 km/h

2) 운동 수행 폼

운동 수행 폼은 관절의 최대 각속도가 발현되는 순서와 관절 각도 및 분절 위치의 주성분으로 파악하였다.

(1) 관절의 최대 각속도 발현 순서 비율

숙련자의 골반 회전의 최대 각속도, 몸통 회전의 최대 각속도, 그리고 왼쪽 팔꿈치 신전의 최대 각속도가 나타나는 순서는 근위-원위 협응패턴의 원리에 따라 골반-몸통-왼쪽 팔꿈치 순서로 나타났다. 이에 따라 학습자의 검사 시점과 집단에 따라 골반-몸통-왼쪽 팔꿈치 순서로 최대 각속도가 나타나는 비율을 파악하였다<표 15>. <그림 14>는 집단과 검사 시점에 따른 차이를 표현했다.

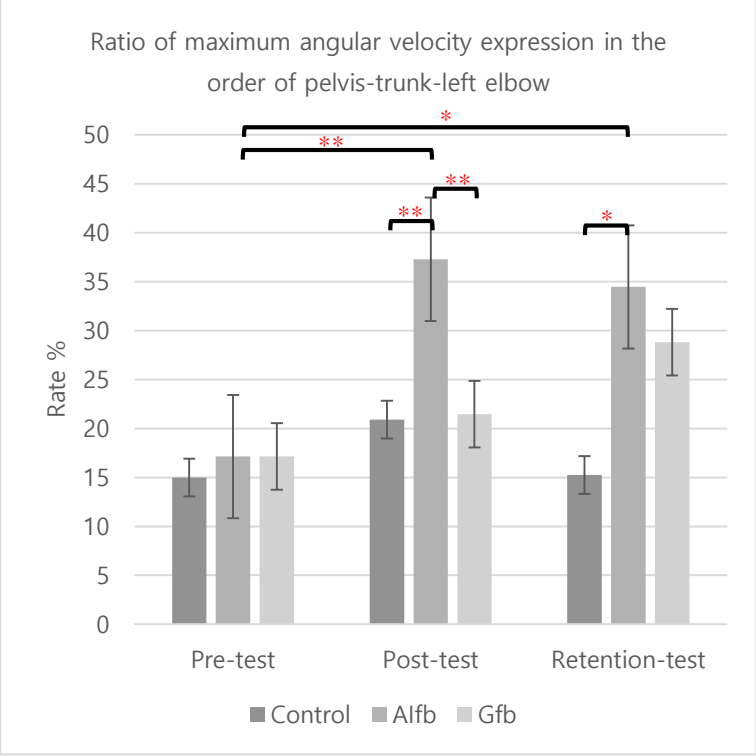

그림 14. 집단과 검사 시점에 따른 골반-몸통-왼쪽 팔꿈치 순서의 최대 각속도 발현 비율

(단, *유의한 차이(p <.05); **유의한 차이(p <.01); ***유의한 차이(p <.001))

분석결과 집단에 대한 주효과 검증에서 최대 각속도 발현 순서 비율 차이는 유의미하게 나타났다[F(2, 39) =4.38, p <.05]. 또한 검사 시점에 대한 주효과 검증 유의한 차이가 나타났다[F(2, 78) = 4.355, p <.05]. 집단과 검사 시점에 따른 상호작용 효과는 유의미하지 않았다[F(4, 78) =2.05, p >.05]. 그룹에 따른 차이를 분석하기 위해 3가지 시기에서 3가지 그룹 간의 다중 비교인 사후검정(post-hoc analysis)을 실시한 결과, 사후 검사(post-test)에서 AIfb집단이 통제집단에 비해 관절의 최대 각속도 발현 순서 비율이 유의하게 높았고(p <.01), AIfb집단이 Gfb집단에 비해 관절의 최대 각속도 발현 순서 비율이 유의하게 높았다(p <.01). 파지 검사(retention-test)에서는 AIfb집단이 통제집단에 비해 관절의 최대 각속도 발현 순서 비율이 유의하게 높았다(p <.05).

시점에 따른 차이를 분석하기 위해 3가지 그룹에서 3가지 시점 간의 다중 비교인 사후검정(post-hoc analysis)을 실시한 결과, AIfb집단의 경우 사후 검사에서 사전 검사보다 관절의 최대 각속도 발현 순서 비율이 유의하게 높았고(p <.01), 파지 검사에서 사전 검사보다 관절의 최대 각속도 발현 순서 비율이 유의하게 높았다(p <.05).

표 15. 골반-몸통-왼쪽 팔꿈치 순서의 최대 각속도 발현 비율

검사 시점	통제집단	AIfb 집단	Gfb 집단
사전 검사	15.00±11.18%	17.42±10.30%	17.14±14.36%
사후 검사	20.90±16.41%	37.29±30.85%	21.47±20.30%
파지 검사	15.25%±25.71	34.46±28.58%	28.81±27.70%

(2) 관절 각도 및 분절 위치의 주성분 개수

29개의 관절에 대한 야구 치기에서 주성분 분산 90%이상의 설명력을 갖는 PC개수의 최빈값을 파악하였다<표 16>. <그림 15>는 비모수 검정을 결과를 나타냈다.

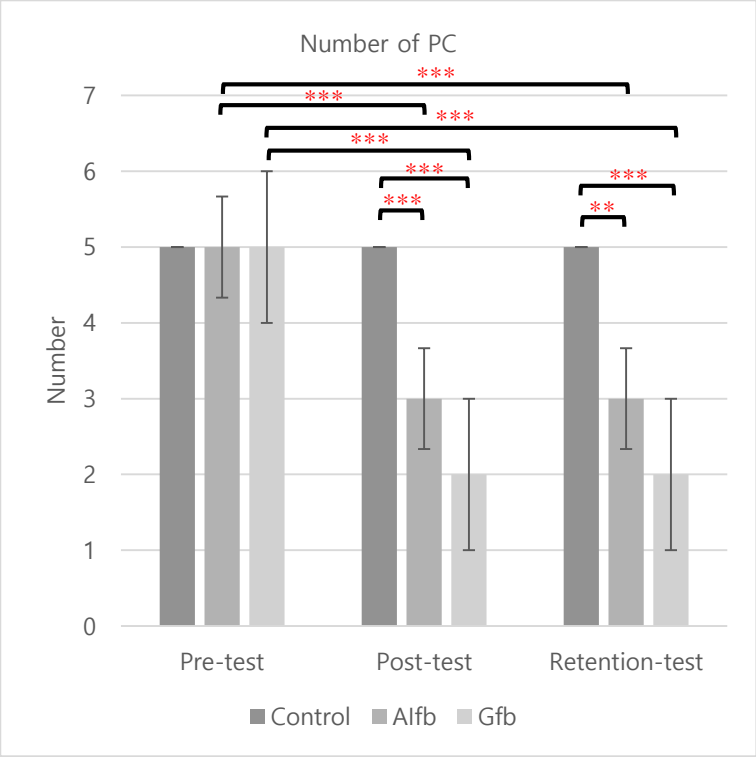

그림 15. 집단과 검사 시점에 따른 주성분 개수의 최빈값

(단, *유의한 차이(p <.05); **유의한 차이(p <.01); ***유의한 차이(p <.001))

집단에 따른 주성분 개수는 사전 검사(pre-test)에서 유의한 차이가 없었다[χ^2 (df=2; N=42)= 0.02551, p =.9873]. 사후 검사(post-test)에서는 유의한 차이가 나타났다[χ^2(df=2; N=42)= 28.89, p <.001]. 사후 검사(post-test)에서 Dunn's multiple comparison test를 이용한 사후 검정(post-hoc)결과는 AIfb집단이 통제집단보다 주성분 개수가

유의하게 낮았고(p < .001), Gfb집단이 통제집단보다 주성분 개수가 유의하게 낮았으며(p < .001), AIfb집단과 Gfb집단 간에 주성분 개수는 유의한 차이가 없었다(p = .2468). 집단에 따른 주성분 개수는 파지 검사(post-test)에서도 유의한 차이가 나타났다[χ^2(df=2; N=42)= 33.43, p <.001]. 파지 검사(retention-test)에서 Dunn's multiple comparison test를 이용한 사후 검정(post-hoc)결과는 AIfb집단이 통제집단보다 주성분 개수가 유의하게 낮았고(p < .01), Gfb집단이 통제집단보다 주성분 개수가 유의하게 낮았으며(p < .001), AIfb집단과 Gfb집단간에 유의한 차이는 없었다(p = .0949).

시점에 따른 주성분 개수는 통제집단에서 유의한 차이가 나타나지 않았다[χ^2(df=2; N=42)= 0.6, p =.7408]. 반면 AIfb집단에서 유의한 차이가 나타났다[χ^2(df=2; N=42)= 25.74, p <.001]. AIfb집단에서 Dunn's multiple comparison test를 이용한 사후 검정(post-hoc)결과는 AIfb집단의 사후 검사 시점이 그 사전 검사 시점에서 보다 주성분 개수가 유의하게 낮았고(p <.001), 파지 검사 시점에서 사전 검사 시점에서 보다 주성분 개수가 유의하게 낮았다(p < .001). 시점에 따른 주성분 개수는 Gfb집단에서도 유의한 차이가 나타났다[χ^2 (df=2; N=42)= 26.73, p <.001]. Gfb집단에서 Dunn's multiple comparison test를 이용한 사후 검정(post-hoc)결과는 Gfb집단의 사후 검사 시점이 그 사전 검사 시점에서 보다 주성분 개수가 유의하게 낮았고(p <.001), 파지 검사 시점에서 사전 검사 시점에서 보다 주성분 개수가 유의하게 낮았다(p <.001).

표 16. 집단과 검사 시점에 따른 주성분 개수의 최빈값

검사 시점	통제집단	AIfb 집단	Gfb 집단
사전 검사	5	5	5
사후 검사	5	3	2
파지 검사	5	3	2

(3) 주성분으로 설명되는 분산

집단과 검사 시점에 따라 주성분으로부터 설명되는 분산의 양은 <표 17>과 같다. 이때 누적된 분산의 양이 90%를 초과하는 부분에 대해 음영으로 표시하였다. <그림 16>은 PC1, <그림 17>은 PC2, <그림 18>은 PC3, <그림 19>는 PC4, 그리고 <그림 20>은 PC5로부터의 집단과 검사 시점에 따른 변화를 나타낸 것이다.

분석결과 집단에 대한 주효과 검증에서 PC1의 분산 차이는 유의미하게 나타났다[$F(2, 39) = 111.4$, $p < .001$]. 또한 검사 시점에 대한 주효과 검증 유의한 차이가 나타났다[$F(2, 78) = 289.9$, $p < .001$]. 마지막으로 집단과 검사 시점에 따른 상호작용 효과는 유의미하게 나타났다[$F(4, 78) = 81.79$, $p < .001$]. 그룹에 따른 차이를 분석하기 위해 3가지 시기에서 3가지 그룹 간의 다중 비교인 사후검정(post-hoc analysis)을 실시한 결과, 사후 검사(post-test)에서 AIfb집단이 통제집단에 비해 PC1의 분산이 유의하게 높았고($p < .001$), Gfb집단이 통제집단에 비해 PC1의 분산이 유의하게 높았으며($p < .001$), AIfb집단이 Gfb집단에 비해 PC1의 분산이 유의하게 높았다($p < .001$).

시점에 따른 차이를 분석하기 위해 3가지 그룹에서 3가지 시점 간의 다중 비교인 사후검정(post-hoc analysis)을 실시한 결과, AIfb집단의 경우 사후 검사에서 사전 검사보다 PC1의 분산이 유의하게 높았고($p < .001$), 파지 검사에서 사전 검사보다 PC1의 분산이 유의하게 높았다($p < .001$). Gfb집단의 경우에도, 사후 검사에서 사전 검사보다 PC1의 분산이 유의하게 높았고($p < .001$), 파지 검사에서 사전 검사보다 PC1의 분산이 유의하게 높았다($p < .001$).

주효과 검증에서 집단에 따른 PC2의 분산 차이는 유의미하게 나타났다[$F(2, 39) = 28.15$, $p < .001$]. 또한 검사 시점에 대한 주효과 검증 유의한 차이가 나타났다[$F(2, 78) = 20.91$, $p < .001$]. 마지막으로 집단과 검사 시점에 따른 상호작용 효과는 유의미하게 나타났다[$F(4, 78) = 7.81$, $p < .001$]. 그룹에 따른 차이를 분석하기 위해 3가지 시기에서 3가지 그룹

간의 다중 비교인 사후검정(post-hoc analysis)을 실시한 결과, 사후 검사(post-test)에서 AIfb집단이 통제집단에 비해 PC2의 분산이 유의하게 낮았고(p <.001), Gfb집단이 통제집단에 비해 PC2의 분산이 유의하게 낮았으며(p <.001). Gfb집단이 AIfb집단에 비해 PC2의 분산이 유의하게 낮았다(p <.05). 파지 검사에서는 AIfb집단이 통제집단에 비해 PC2의 분산이 유의하게 낮았고(p <.001), Gfb집단이 통제집단에 비해 PC2의 분산이 유의하게 낮았다(p <.001).

시점에 따른 차이를 분석하기 위해 3가지 그룹에서 3가지 시점 간의 다중 비교인 사후검정(post-hoc analysis)을 실시한 결과, AIfb집단의 경우에는, 사후 검사에서 사전 검사보다 PC2의 분산이 유의하게 낮았고(p <.01), 파지 검사에서 사전 검사보다 PC2의 분산이 유의하게 낮았다(p <.001). Gfb집단의 경우 사후 검사에서 사전 검사보다 PC2의 분산이 유의하게 낮았고(p <.001), 파지 검사에서 사전 검사보다 PC2의 분산이 유의하게 낮았다(p <.001).

주효과 검증에서 집단에 따른 PC3의 분산 차이는 유의미하게 나타났다[$F(2, 39) = 65.34$, p <.001]. 또한 검사 시점에 대한 주효과 검증 유의한 차이가 나타났다[$F(2, 78) = 133.5$, p <.001]. 마지막으로 집단과 검사 시점에 따른 상호작용 효과는 유의미하게 나타났다[$F(4, 78) = 40.06$, p <.001]. 그룹에 따른 차이를 분석하기 위해 3가지 시기에서 3가지 그룹 간의 다중 비교인 사후검정(post-hoc analysis)을 실시한 결과, 사후 검사(post-test)에서는 AIfb집단이 통제집단에 비해 PC3의 분산이 유의하게 낮았고(p <.001), Gfb집단이 통제집단에 비해 PC3의 분산이 유의하게 낮았으며(p <.001), Gfb집단이 AIfb집단에 비해 PC3의 분산이 유의하게 낮았다(p <.001). 파지 검사(retention-test)에서는 AIfb집단이 통제집단에 비해 PC3의 분산이 유의하게 낮았고(p <.001), Gfb집단이 통제집단에 비해 PC3의 분산이 유의하게 낮았으며(p <.001), Gfb집단이 AIfb집단에 비해 PC3의 분산이 유의하게 낮았다(p <.001).

시점에 따른 차이를 분석하기 위해 3가지 그룹에서 3가지 시점 간의 다중 비교인 사후검정(post-hoc analysis)을 실시한 결과, AIfb집단의 경

우에는, 사후 검사에서 사전 검사보다 PC3의 분산이 유의하게 낮았고(p <.001), 파지 검사에서 사전 검사보다 PC3의 분산이 유의하게 낮았다(p <.001). Gfb집단의 경우 사후 검사에서 사전 검사보다 PC3의 분산이 유의하게 낮았고(p <.001), 파지 검사에서 사전 검사보다 PC3의 분산이 유의하게 낮았다(p <.001).

주효과 검증에서 집단에 따른 PC4의 분산 차이는 유의미하게 나타났다[F(2, 39) =59.32, p <.001]. 또한 검사 시점에 대한 주효과 검증 유의한 차이가 나타났다[F(2, 78) = 40.79, p <.001]. 마지막으로 집단과 검사 시점에 따른 상호작용 효과는 유의미하게 나타났다[F(4, 78) =40.79, p <.001]. 그룹에 따른 차이를 분석하기 위해 3가지 시기에서 3가지 그룹 간의 다중 비교인 사후검정(post-hoc analysis)을 실시한 결과, 사후 검사(post-test)에서는 AIfb집단이 통제집단에 비해 PC4의 분산이 유의하게 낮았고(p <.001), Gfb집단이 통제집단에 비해 PC4의 분산이 유의하게 낮았다(p <.001). 파지 검사(retention-test)에서는 AIfb집단이 통제집단에 비해 PC4의 분산이 유의하게 낮았고(p <.001), Gfb집단이 통제집단에 비해 PC4의 분산이 유의하게 낮았다(p <.001).

시점에 따른 차이를 분석하기 위해 3가지 그룹에서 3가지 시점 간의 다중 비교인 사후검정(post-hoc analysis)을 실시한 결과, AIfb집단의 경우에는, 사후 검사에서 사전 검사보다 PC4의 분산이 유의하게 낮았고(p <.001), 파지 검사에서 사전 검사보다 PC4의 분산이 유의하게 낮았다(p <.001). Gfb집단의 경우 사후 검사에서 사전 검사보다 PC4의 분산이 유의하게 낮았고(p <.001), 파지 검사에서 사전 검사보다 PC4의 분산이 유의하게 낮았다(p <.001).

주효과 검증에서 집단에 따른 PC5의 분산 차이는 유의미하게 나타났다[F(2, 39) =64.31, p <.001]. 또한 검사 시점에 대한 주효과 검증 유의한 차이가 나타났다[F(2, 78) = 102, p <.001]. 마지막으로 집단과 검사 시점에 따른 상호작용 효과는 유의미하게 나타났다[F(4, 78) =29.29, p <.001]. 그룹에 따른 차이를 분석하기 위해 3가지 시기에서 3가지 그룹 간의 다중 비교인 사후검정(post-hoc analysis)을 실시한 결과, 사후 검

사(post-test)에서는 AIfb집단이 통제집단에 비해 PC5의 분산이 유의하게 낮았고(p <.001), Gfb집단이 통제집단에 비해 PC5의 분산이 유의하게 낮았다(p <.001). 파지 검사(retention-test)에서는 AIfb집단이 통제집단에 비해 PC5의 분산이 유의하게 낮았고(p <.001), Gfb집단이 통제집단에 비해 PC5의 분산이 유의하게 낮았다(p <.001).

시점에 따른 차이를 분석하기 위해 3가지 그룹에서 3가지 시점 간의 다중 비교인 사후검정(post-hoc analysis)을 실시한 결과, AIfb집단의 경우에는, 사후 검사에서 사전 검사보다 PC5의 분산이 유의하게 낮았고(p <.001), 파지 검사에서 사전 검사보다 PC5의 분산이 유의하게 낮았다(p <.001). Gfb집단의 경우 사후 검사에서 사전 검사보다 PC5의 분산이 유의하게 낮았고(p <.001), 파지 검사에서 사전 검사보다 PC5의 분산이 유의하게 낮았다(p <.001).

표 17. 집단과 검사 시점에 따라 주성분으로부터 설명되는 분산의 양

검사 시점	집단	Variance(%)	PC1	PC2	PC3	PC4	PC5
Pre-test	Control	Explained	41.57	23.20	13.57	8.05	5.07
		Accumulated	41.57	64.77	78.34	86.39	91.46
	AIfb	Explained	39.19	23.30	13.91	8.59	5.39
		Accumulated	39.19	62.49	76.40	85.00	90.39
	Gfb	Explained	38.62	22.76	14.37	8.30	5.95
		Accumulated	38.62	61.38	75.75	84.05	90.00
Post-test	Control	Explained	41.00	23.24	13.45	8.25	5.30
		Accumulated	41.00	64.24	77.69	85.94	91.24
	AIfb	Explained	65.06	20.27	8.61	3.32	1.40
		Accumulated	65.06	85.33	93.91	97.23	98.63
	Gfb	Explained	77.20	14.66	4.41	2.03	0.93
		Accumulated	77.20	91.86	96.27	98.30	99.23
Retention-test	Control	Explained	41.32	23.32	13.44	8.51	5.29
		Accumulated	41.32	64.57	78.02	86.52	91.81
	AIfb	Explained	65.97	19.72	8.53	3.17	1.34
		Accumulated	65.97	85.69	94.22	97.39	98.73
	Gfb	Explained	76.81	14.68	4.50	2.20	0.97
		Accumulated	76.81	91.49	95.99	98.19	99.16

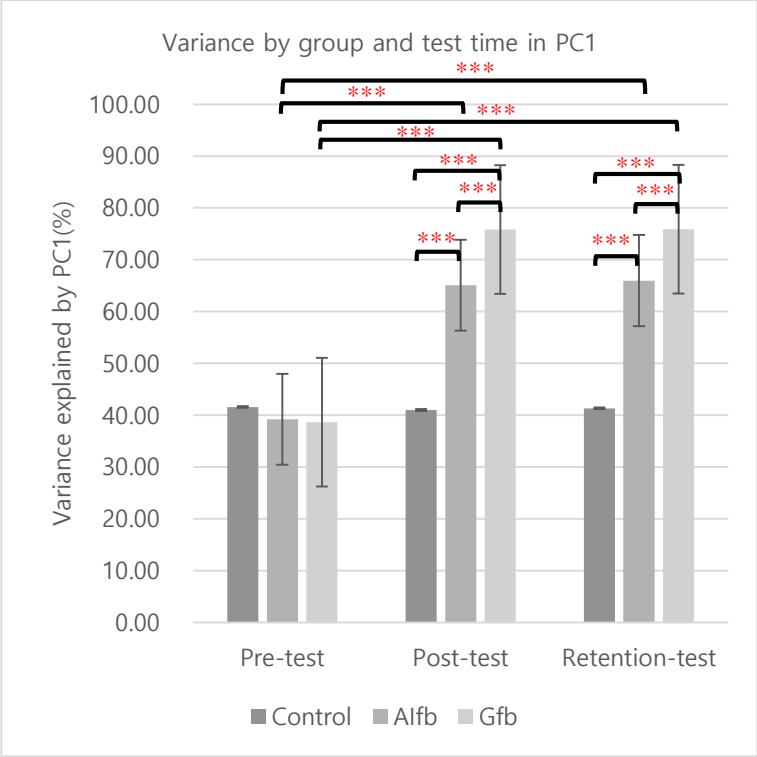

그림 16. 집단과 검사 시점에 따른 PC1에서의 분산 변화

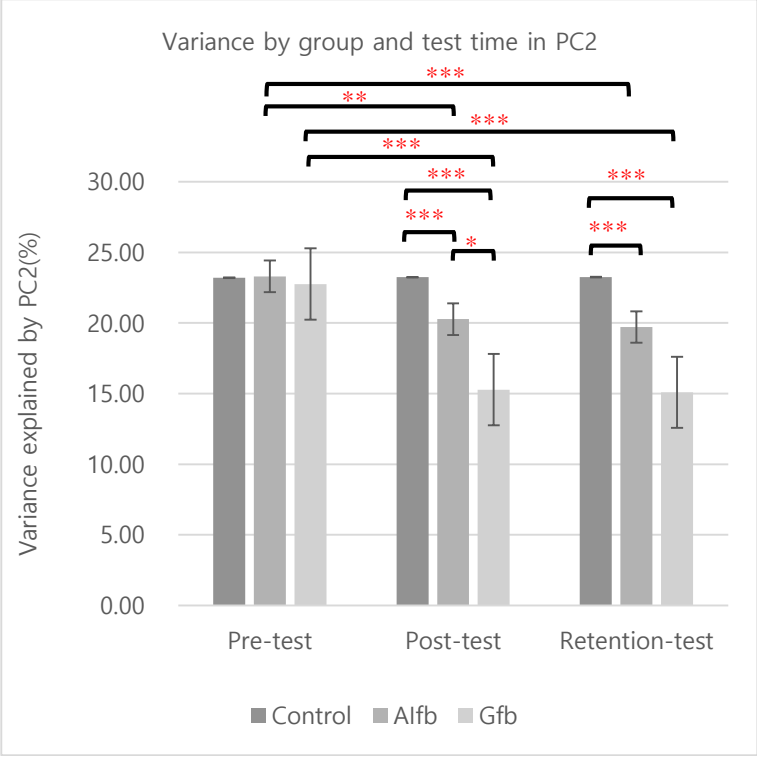

그림 17. 집단과 검사 시점에 따른 PC2에서의 분산 변화

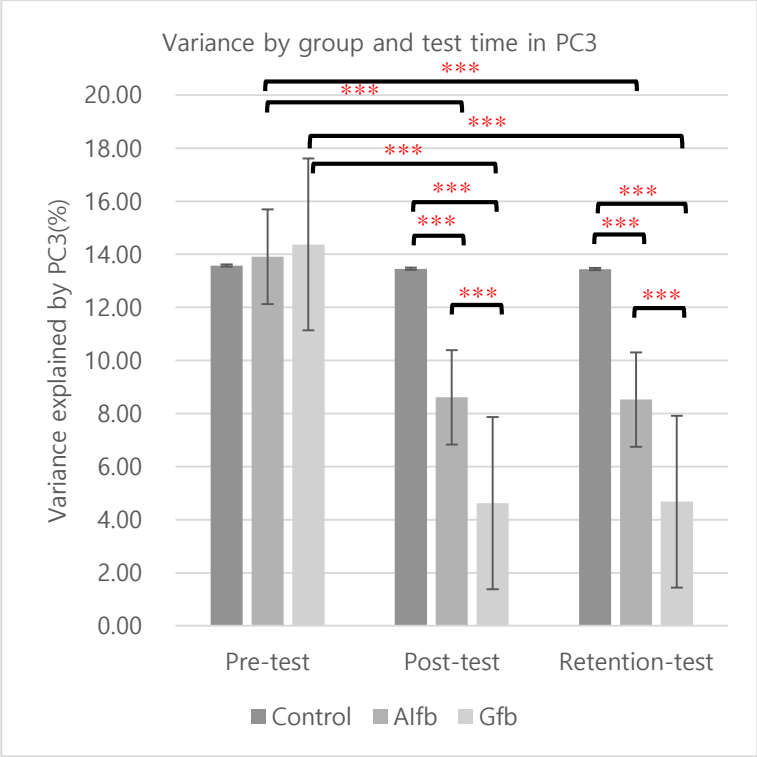

그림 18. 집단과 검사 시점에 따른 PC3에서의 분산 변화

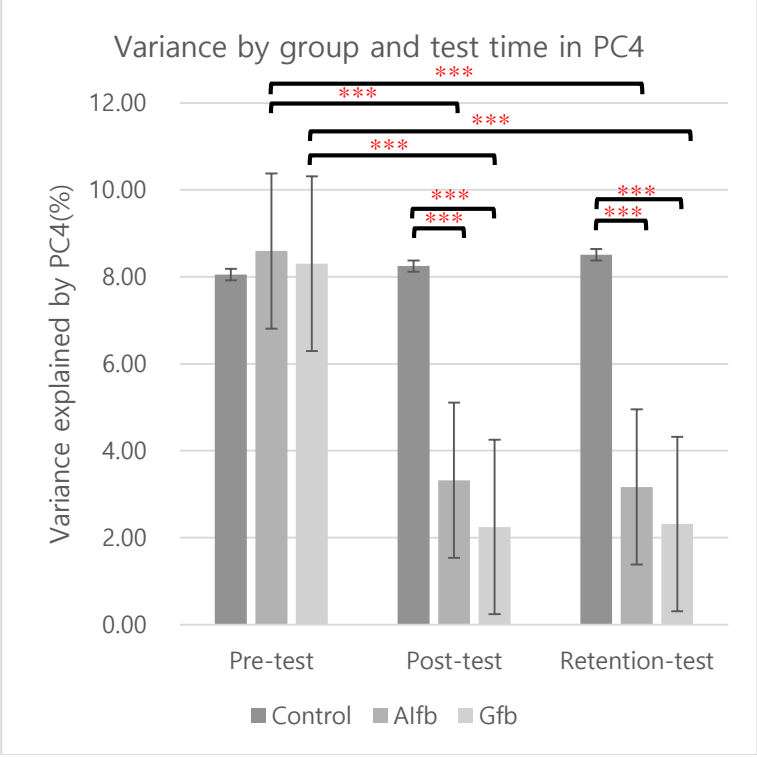

그림 19. 집단과 검사 시점에 따른 PC4에서의 분산 변화

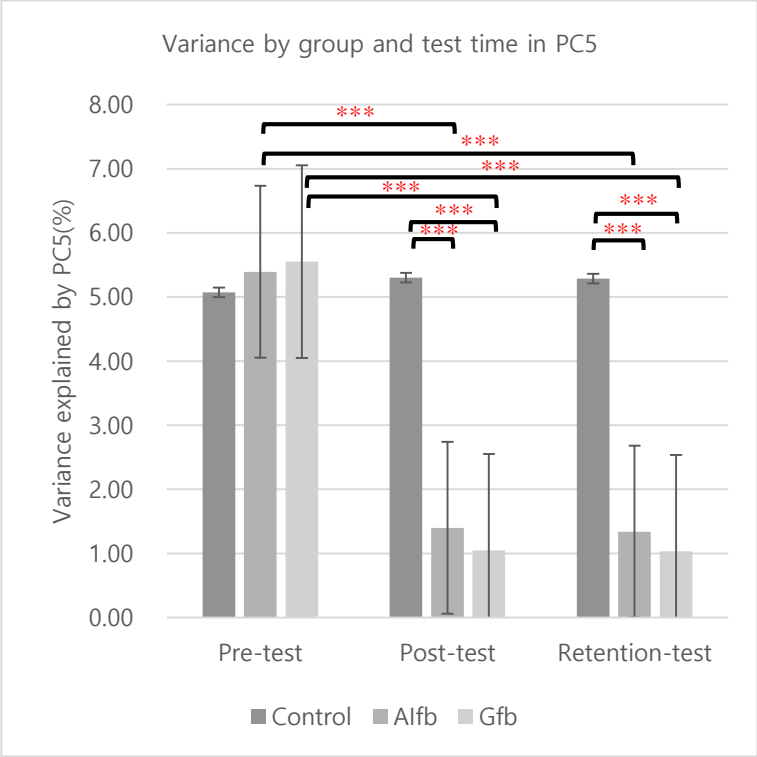

그림 20. 집단과 검사 시점에 따른 PC5에서의 분산 변화

(단, *유의한 차이(p <.05); **유의한 차이(p <.01); ***유의한 차이(p <.001))

(4) 주성분 계수(적재값)

통제집단의 검사 시점에 따른 관절 각도 및 분절 이동의 적재값은 <표 18>, AIfb집단의 검사 시점에 따른 관절 각도 및 분절 이동의 적재값은 <표 19>, 그리고 Gfb집단의 검사 시점에 따른 관절 각도 및 분절 이동의 적재값은 <표 20>과 같다. 이때 주성분을 표현하는 분산이 90%를 넘는 주성분의 개수는 통제집단의 경우 5개였으며, AIfb집단의 경우 사전 검사에서 5개, 사후 검사와 파지 검사에서는 3개였다. Gfb집단의 경우 사전 검사에서 5개, 사후 검사와 파지 검사에서는 2개였다. 적재값의 경우 각 PC에서 29개의 관절 및 분절 움직임에서 가장 큰 5개의 데이터를 음영으로 표시하였고<표 18 ~ 20>, 이에 대한 해석은 아래와 같다.

통제집단의 사전 검사는 PC1에서 왼쪽 어깨의 시상면(굴곡-신전), 왼쪽 어깨의 수평면(회내-회외), 오른쪽 팔꿈치의 수평면(회내-회외), 골반의 수평면, 왼쪽 무릎의 시상면(굴곡-신전)이 높은 기여도를 나타냈다. PC2에서는 오른쪽 팔꿈치의 시상면(굴곡-신전), 몸통의 수평면, 왼쪽 엉덩 관절의 시상면(굴곡-신전), 골반의 수평면, 왼쪽 무릎의 시상면(굴곡-신전)에서 높은 기여도를 나타냈다. PC3에서는 PC2에서와 같은 분절5개의 움직임에서 높은 기여도를 나타냈다. PC4에서는 오른쪽 어깨의 수평면(회내-회외), 왼쪽 팔꿈치의 시상면(굴곡-신전), 왼쪽 무릎의 시상면(굴곡-신전), 왼쪽 발목의 좌우면(내번-외번) 움직임에서 높은 기여도를 나타냈다.

통제집단의 사후 검사는 PC1에서 오른쪽 어깨의 좌우면(내전-외전), 왼쪽 어깨의 수평면(회내-회외), 오른쪽 팔꿈치의 시상면(굴곡-신전), 골반의 수평면, 왼쪽 무릎의 시상면(굴곡-신전)에서 높은 기여도를 나타냈다. PC2에서는 왼쪽 어깨의 수평면(회내-회외), 오른쪽 팔꿈치의 시상면(굴곡-신전), 왼쪽 팔꿈치의 시상면(굴곡-신전), 왼쪽 엉덩 관절의 시상면(굴곡-신전), 왼쪽 무릎의 시상면(굴곡-신전)에서 높은 기여도를 나타냈다. PC3에서는 왼쪽 어깨의 좌우면(내전-외전), 오른쪽 팔꿈치와 왼쪽 팔꿈치의 시상면(굴곡-신전), 왼쪽 엉덩 관절의 시상면(굴곡-신전),

골반의 수평면 움직임이 높은 기여도를 나타냈다. PC4에서는 오른쪽 어깨의 수평면(회내-회외), 오른쪽 팔꿈치와 왼쪽 팔꿈치의 시상면(굴곡-신전), 왼쪽 엉덩 관절의 시상면(굴곡-신전), 골반의 수평면 움직임에서 높은 기여도를 나타냈다.

통제집단의 파지 검사는 PC1에서 오른쪽 어깨의 좌우면(내전-외전), 왼쪽 어깨의 수평면(회내-회외), 오른쪽 팔꿈치의 시상면(굴곡-신전), 골반의 수평면, 왼쪽 무릎의 시상면(굴곡-신전) 움직임에서 높은 기여도를 나타냈다. PC2에서는 왼쪽 어깨의 수평면(회내-회외), 오른쪽과 왼쪽 팔꿈치의 시상면(굴곡-신전), 몸통의 수평면, 골반의 수평면, 왼쪽 무릎의 시상면(굴곡-신전) 움직임에서 높은 기여도를 나타냈다. PC3에서는 왼쪽 어깨의 좌우면(내전-외전), 오른쪽 팔꿈치의 시상면(굴곡-신전), 왼쪽 엉덩 관절의 시상면(굴곡-신전), 골반의 수평면, 왼쪽 무릎의 시상면(굴곡-신전) 움직임에서 높은 기여도를 나타냈다. PC4에서는 오른쪽 어깨의 좌우면(내전-외전), 오른쪽과 왼쪽 팔꿈치의 시상면(굴곡-신전), 왼쪽 엉덩 관절의 시상면(굴곡-신전), 왼쪽 무릎의 시상면(굴곡-신전) 움직임에서 높은 기여도를 나타냈다.

표 18. 통제집단의 검사 시점에 따른 주성분 계수(적재값) 변화

Control group	Pre-test				Post-test				Retention-test			
관절 및 분절	PC 1	PC 2	PC 3	PC 4	PC 1	PC 2	PC 3	PC 4	PC 1	PC 2	PC 3	PC 4
R-shoulder-sagittal	0.133	0.120	0.132	0.189	0.116	0.188	0.201	0.192	0.120	0.185	0.171	0.193
L-shoulder-sagittal	0.242	0.183	0.127	0.103	0.227	0.201	0.152	0.135	0.201	0.171	0.142	0.121
R-shoulder-frontal	0.234	0.142	0.175	0.177	0.356	0.185	0.198	0.189	0.317	0.211	0.181	0.220
L-shoulder-frontal	0.222	0.169	0.150	0.204	0.221	0.231	0.266	0.192	0.211	0.213	0.225	0.165
R-shoulder-horizontal	0.137	0.129	0.137	0.217	0.114	0.201	0.203	0.223	0.121	0.203	0.184	0.213
L-shoulder-horizontal	0.267	0.189	0.139	0.115	0.240	0.238	0.184	0.145	0.216	0.214	0.176	0.139
R-elbow-sagittal	0.473	0.205	0.244	0.203	0.389	0.256	0.252	0.272	0.370	0.230	0.208	0.286
L-elbow-sagittal	0.124	0.167	0.193	0.215	0.132	0.253	0.173	0.303	0.162	0.263	0.195	0.215
R-elbow-horizontal	0.006	0.013	0.017	0.020	0.008	0.009	0.010	0.018	0.008	0.012	0.012	0.017
L-elbow-horizontal	0.006	0.010	0.018	0.022	0.005	0.008	0.012	0.018	0.005	0.009	0.015	0.022
R-wrist-sagittal	0.006	0.011	0.017	0.018	0.007	0.009	0.012	0.014	0.006	0.011	0.016	0.022
L-wrist-sagittal	0.007	0.013	0.018	0.022	0.008	0.009	0.012	0.016	0.007	0.012	0.016	0.019
R-wrist-frontal	0.007	0.014	0.020	0.016	0.009	0.010	0.009	0.017	0.008	0.013	0.012	0.015
L-wrist-frontal	0.007	0.013	0.016	0.021	0.006	0.008	0.012	0.020	0.007	0.010	0.015	0.022
Torso-turn-horizontal	0.128	0.244	0.244	0.176	0.175	0.189	0.184	0.193	0.158	0.220	0.188	0.187
R-hip-sagittal	0.066	0.108	0.178	0.133	0.111	0.101	0.130	0.160	0.101	0.105	0.119	0.162
L-hip-sagittal	0.219	0.254	0.294	0.223	0.144	0.223	0.227	0.224	0.162	0.193	0.216	0.234
R-hip-horizontal	0.052	0.093	0.104	0.105	0.035	0.047	0.054	0.078	0.041	0.051	0.068	0.101
L-hip-horizontal	0.078	0.110	0.119	0.198	0.078	0.128	0.090	0.112	0.103	0.118	0.118	0.109
R-hip-frontal	0.074	0.120	0.121	0.100	0.035	0.077	0.074	0.066	0.035	0.058	0.085	0.068
L-hip-frontal	0.074	0.107	0.114	0.105	0.091	0.078	0.111	0.104	0.090	0.104	0.109	0.135
Pelvis-turn-horizontal	0.289	0.347	0.231	0.141	0.338	0.210	0.213	0.210	0.310	0.214	0.231	0.193
R-knee-sagittal	0.079	0.163	0.124	0.141	0.072	0.110	0.163	0.148	0.065	0.114	0.172	0.131
L-knee-sagittal	0.341	0.282	0.299	0.299	0.277	0.320	0.327	0.183	0.290	0.314	0.312	0.221
R-Ankle-sagittal	0.043	0.104	0.070	0.091	0.053	0.058	0.065	0.115	0.055	0.064	0.102	0.095
L-Ankle-sagittal	0.068	0.104	0.144	0.150	0.063	0.081	0.127	0.097	0.065	0.086	0.151	0.133
R-Ankle-frontal	0.043	0.093	0.097	0.070	0.045	0.047	0.069	0.085	0.040	0.062	0.082	0.067
L-Ankle-frontal	0.082	0.121	0.134	0.236	0.070	0.075	0.111	0.143	0.068	0.075	0.124	0.151
L-foot-medial-lateral	0.007	0.013	0.015	0.020	0.007	0.010	0.013	0.014	0.008	0.013	0.014	0.019

음영된 값은 적재값 중에 가장 큰 5개의 데이터를 의미한다.

AIfb집단의 사전 검사는 PC1에서 오른쪽 어깨의 좌우면 움직임(내전-외전), 오른쪽 팔꿈치의 시상면(굴곡-신전), 몸통의 수평면, 골반의 수평면, 왼쪽 무릎의 시상면 움직임(굴곡-신전)에서 높은 기여도를 나타냈다. PC2의 경우 오른쪽 어깨의 수평면, 오른쪽과 왼쪽 팔꿈치의 시상면(굴곡-신전), 골반의 수평면, 왼쪽 무릎의 시상면(굴곡-신전) 움직임 에서 높은 기여도를 나타냈다. PC3의 경우 오른쪽 어깨의 좌우면(내전-외전), 오른쪽과 왼쪽 팔꿈치의 시상면(굴곡-신전), 골반의 수평면, 왼쪽 무릎의 시상면(굴곡-신전) 움직임에서 높은 기여도를 나타냈다. PC4의 경우 왼쪽 어깨의 좌우면(내전-외전), 오른쪽 어깨의 수평면(회내-회외), 오른쪽과 왼쪽 팔꿈치의 시상면(굴곡-신전), 왼쪽 발목의 좌우면 움직임(내번-외번)에서 높은 기여도를 나타냈다.

AIfb집단의 사후 검사는 PC1에서 오른쪽 어깨의 좌우면(내전-외전), 오른쪽 팔꿈치의 시상면(굴곡-신전), 몸통의 수평면, 골반의 수평면, 왼쪽 무릎의 시상면 움직임(굴곡-신전)에서 높은 기여도를 나타냈다. PC2에서는 왼쪽 어깨의 좌우면(내전-외전), 오른쪽 팔꿈치의 시상면(굴곡-신전), 몸통의 수평면, 왼쪽 엉덩 관절의 시상면(굴곡-신전), 왼쪽 무릎의 시상면 움직임(굴곡-신전)에서 높은 기여도를 나타냈다. PC3의 경우 왼쪽 어깨의 좌우면(내전-외전), 왼쪽 팔꿈치의 시상면(굴곡-신전), 왼쪽 엉덩 관절의 시상면(굴곡-신전), 골반의 수평면, 왼쪽 무릎의 시상면(굴곡-신전)에서 높은 기여도를 나타냈다.

AIfb의 파지 검사는 PC1에서 오른쪽과 왼쪽 어깨의 좌우면(내전-외전), 오른쪽 팔꿈치의 시상면(굴곡-신전), 골반의 수평면, 왼쪽 무릎의 시상면 움직임(굴곡-신전)에서 높은 기여도를 나타냈다. PC2에서는 오른쪽 팔꿈치의 시상면(굴곡-신전), 몸통의 수평면, 왼쪽 엉덩 관절의 시상면(굴곡-신전), 골반의 수평면, 왼쪽 무릎의 시상면 움직임(굴곡-신전)에서 높은 기여도를 나타냈다. PC3에서는 왼쪽 어깨의 좌우면(내전-외전), 왼쪽 팔꿈치의 시상면(굴곡-신전), 왼쪽 엉덩 관절의 시상면(굴곡-신전), 골반의 수평면, 왼쪽 무릎의 시상면 움직임(굴곡-신전)에서 높은 기여도를 나타냈다.

표 19. AIfb집단의 검사 시점에 따른 주성분 계수(적재값) 변화

AIfb 관절 및 분절	Pre-test				Post-test				Retention-test			
	PC 1	PC 2	PC 3	PC 4	PC 1	PC 2	PC 3	PC 4	PC 1	PC 2	PC 3	PC 4
R-shoulder-sagittal	0.124	0.197	0.199	0.172	0.114	0.169	0.154	0.156	0.106	0.173	0.160	0.164
L-shoulder-sagittal	0.206	0.169	0.170	0.155	0.173	0.200	0.158	0.112	0.180	0.189	0.160	0.108
R-shoulder-frontal	0.376	0.191	0.235	0.177	0.342	0.149	0.177	0.167	0.332	0.156	0.183	0.173
L-shoulder-frontal	0.235	0.200	0.182	0.224	0.219	0.225	0.233	0.169	0.248	0.196	0.243	0.153
R-shoulder-horizontal	0.134	0.205	0.198	0.207	0.121	0.184	0.158	0.187	0.113	0.191	0.165	0.197
L-shoulder-horizontal	0.224	0.184	0.195	0.181	0.188	0.221	0.188	0.118	0.194	0.203	0.197	0.130
R-elbow-sagittal	0.253	0.366	0.227	0.257	0.332	0.235	0.149	0.223	0.319	0.246	0.162	0.208
L-elbow-sagittal	0.155	0.211	0.232	0.281	0.125	0.170	0.235	0.232	0.121	0.191	0.232	0.238
R-elbow-horizontal	0.008	0.013	0.017	0.018	0.012	0.009	0.012	0.016	0.009	0.009	0.013	0.015
L-elbow-horizontal	0.007	0.012	0.017	0.023	0.008	0.010	0.016	0.019	0.005	0.007	0.012	0.019
R-wrist-sagittal	0.007	0.014	0.016	0.020	0.012	0.010	0.013	0.015	0.008	0.008	0.013	0.015
L-wrist-sagittal	0.007	0.014	0.019	0.022	0.009	0.011	0.011	0.019	0.006	0.008	0.014	0.017
R-wrist-frontal	0.011	0.013	0.016	0.016	0.011	0.010	0.016	0.015	0.009	0.009	0.012	0.016
L-wrist-frontal	0.007	0.014	0.017	0.021	0.007	0.012	0.012	0.020	0.007	0.007	0.012	0.015
Torso-turn-horizontal	0.262	0.160	0.183	0.181	0.226	0.275	0.208	0.241	0.236	0.294	0.207	0.243
R-hip-sagittal	0.151	0.113	0.162	0.159	0.102	0.142	0.152	0.130	0.102	0.125	0.169	0.131
L-hip-sagittal	0.133	0.189	0.199	0.184	0.173	0.243	0.258	0.249	0.167	0.216	0.231	0.262
R-hip-horizontal	0.059	0.083	0.129	0.089	0.037	0.050	0.074	0.079	0.036	0.046	0.081	0.090
L-hip-horizontal	0.047	0.131	0.079	0.108	0.074	0.101	0.153	0.129	0.075	0.090	0.156	0.143
R-hip-frontal	0.053	0.093	0.102	0.086	0.062	0.059	0.104	0.104	0.060	0.060	0.107	0.105
L-hip-frontal	0.081	0.098	0.075	0.110	0.077	0.092	0.111	0.115	0.080	0.085	0.121	0.101
Pelvis-turn-horizontal	0.358	0.223	0.247	0.180	0.367	0.214	0.271	0.145	0.364	0.216	0.284	0.152
R-knee-sagittal	0.104	0.124	0.126	0.116	0.054	0.134	0.119	0.131	0.063	0.117	0.136	0.139
L-knee-sagittal	0.252	0.239	0.257	0.190	0.301	0.285	0.300	0.254	0.286	0.288	0.256	0.266
R-Ankle-sagittal	0.048	0.048	0.078	0.088	0.057	0.063	0.075	0.086	0.060	0.067	0.091	0.090
L-Ankle-sagittal	0.062	0.096	0.080	0.145	0.053	0.067	0.097	0.164	0.054	0.067	0.119	0.170
R-Ankle-frontal	0.060	0.078	0.082	0.066	0.076	0.058	0.092	0.060	0.077	0.059	0.089	0.070
L-Ankle-frontal	0.081	0.098	0.142	0.211	0.093	0.126	0.152	0.289	0.101	0.141	0.162	0.273
L-foot-medial-lateral	0.007	0.014	0.020	0.021	0.008	0.014	0.013	0.020	0.007	0.010	0.014	0.017

음영된 값은 적재값 중에 가장 큰 5개의 데이터를 의미한다.

Gfb의 사전 검사는 PC1에서 오른쪽 어깨의 좌우면(내전-외전), 왼쪽 어깨의 수평면(회내-회외), 오른쪽 팔꿈치의 시상면(굴곡-신전), 왼쪽 무릎의 시상면 (굴곡-신전) 움직임에서 높은 기여도를 나타냈다. PC2에서는 오른쪽과 왼쪽 팔꿈치의 시상면(굴곡-신전), 왼쪽 엉덩 관절의 시상면(굴곡-신전), 골반의 수평면, 왼쪽 무릎의 시상면(굴곡-신전) 움직임에서 높은 기여도를 나타냈다. PC3도 PC2와 같은 관절 움직임에서 높은 기여도를 나타냈다. PC4는 오른쪽 어깨의 시상면(굴곡-신전), 오른쪽 어깨의 수평면(회내-회외), 오른쪽과 왼쪽 팔꿈치의 시상면(굴곡-신전), 왼쪽 엉덩 관절의 시상면(굴곡-신전) 움직임에서 높은 기여도를 나타냈다.

Gfb의 사후 검사는 PC1에서 오른쪽 어깨의 좌우면(내전-외전), 왼쪽 어깨의 수평면(회내-회외), 오른쪽 팔꿈치의 시상면(굴곡-신전), 몸통의 수평면, 골반의 수평면 움직임에서 높은 기여도를 나타냈다. PC2에서는 오른쪽 어깨의 시상면(굴곡-신전), 왼쪽 어깨의 좌우면(내전-외전), 오른쪽과 왼쪽 어깨의 수평면(회내-회외), 오른쪽과 왼쪽 팔꿈치의 시상면(굴곡-신전)에서 높은 기여도를 나타냈다.

Gfb의 파지 검사는 PC1에서 오른쪽 어깨의 좌우면(내전-외전), 왼쪽 어깨의 수평면(회내-회외), 오른쪽 팔꿈치의 시상면(굴곡-신전), 몸통의 수평면, 골반의 수평면 움직임에서 높은 기여도를 나타냈다. PC2에서는 오른쪽 어깨의 시상면(굴곡-신전), 왼쪽 어깨의 좌우면(내전-외전), 오른쪽 어깨의 수평면(회내-회외), 오른쪽과 왼쪽 팔꿈치의 시상면(굴곡-신전) 움직임에서 높은 기여도를 나타냈다.

표 10. Gfb집단의 검사 시점에 따른 주성분 계수(적재값) 변화

Gfb 관절 및 분절	Pre-test				Post-test				Retention-test			
	PC 1	PC 2	PC 3	PC 4	PC 1	PC 2	PC 3	PC 4	PC 1	PC 2	PC 3	PC 4
R-shoulder-sagittal	0.097	0.163	0.197	0.224	0.121	0.230	0.129	0.132	0.112	0.257	0.129	0.135
L-shoulder-sagittal	0.184	0.170	0.145	0.149	0.167	0.163	0.141	0.127	0.190	0.151	0.137	0.132
R-shoulder-frontal	0.250	0.166	0.145	0.165	0.433	0.158	0.304	0.229	0.439	0.165	0.272	0.232
L-shoulder-frontal	0.179	0.181	0.176	0.144	0.174	0.244	0.160	0.169	0.199	0.253	0.155	0.179
R-shoulder-horizontal	0.092	0.177	0.209	0.257	0.130	0.240	0.122	0.155	0.122	0.268	0.116	0.153
L-shoulder-horizontal	0.213	0.205	0.177	0.171	0.179	0.191	0.156	0.157	0.202	0.180	0.155	0.165
R-elbow-sagittal	0.376	0.271	0.226	0.248	0.388	0.282	0.334	0.255	0.412	0.240	0.337	0.245
L-elbow-sagittal	0.177	0.226	0.251	0.283	0.172	0.405	0.254	0.201	0.137	0.415	0.257	0.218
R-elbow-horizontal	0.008	0.012	0.016	0.021	0.011	0.011	0.021	0.029	0.009	0.010	0.014	0.024
L-elbow-horizontal	0.007	0.010	0.013	0.022	0.008	0.015	0.018	0.032	0.008	0.013	0.018	0.021
R-wrist-sagittal	0.008	0.012	0.018	0.019	0.011	0.015	0.018	0.032	0.009	0.011	0.018	0.022
L-wrist-sagittal	0.008	0.011	0.016	0.021	0.006	0.012	0.027	0.038	0.006	0.011	0.019	0.032
R-wrist-frontal	0.009	0.013	0.018	0.017	0.013	0.014	0.017	0.019	0.011	0.013	0.014	0.019
L-wrist-frontal	0.008	0.012	0.017	0.023	0.009	0.015	0.023	0.029	0.008	0.012	0.021	0.027
Torso-turn-horizontal	0.178	0.192	0.183	0.121	0.239	0.172	0.164	0.201	0.251	0.188	0.154	0.212
R-hip-sagittal	0.123	0.124	0.157	0.160	0.155	0.117	0.132	0.141	0.161	0.116	0.130	0.134
L-hip-sagittal	0.181	0.220	0.230	0.234	0.102	0.139	0.227	0.218	0.090	0.137	0.241	0.217
R-hip-horizontal	0.072	0.065	0.075	0.077	0.060	0.064	0.098	0.125	0.060	0.063	0.109	0.117
L-hip-horizontal	0.057	0.107	0.089	0.097	0.086	0.099	0.142	0.142	0.086	0.114	0.162	0.162
R-hip-frontal	0.047	0.103	0.126	0.082	0.048	0.062	0.088	0.109	0.058	0.068	0.084	0.103
L-hip-frontal	0.086	0.118	0.108	0.114	0.091	0.072	0.092	0.134	0.104	0.073	0.111	0.123
Pelvis-turn-horizontal	0.282	0.253	0.266	0.203	0.367	0.186	0.175	0.162	0.356	0.225	0.158	0.158
R-knee-sagittal	0.079	0.125	0.156	0.156	0.102	0.093	0.128	0.121	0.115	0.075	0.109	0.130
L-knee-sagittal	0.381	0.341	0.301	0.216	0.167	0.160	0.268	0.264	0.143	0.150	0.279	0.263
R-Ankle-sagittal	0.046	0.072	0.101	0.082	0.073	0.080	0.090	0.087	0.074	0.067	0.080	0.081
L-Ankle-sagittal	0.070	0.102	0.128	0.118	0.068	0.058	0.104	0.153	0.051	0.045	0.092	0.118
R-Ankle-frontal	0.036	0.068	0.075	0.069	0.092	0.081	0.087	0.108	0.084	0.082	0.088	0.119
L-Ankle-frontal	0.078	0.131	0.128	0.190	0.088	0.104	0.147	0.182	0.093	0.134	0.168	0.195
L-foot-medial-lateral	0.007	0.014	0.015	0.021	0.009	0.016	0.023	0.032	0.010	0.013	0.016	0.019

음영된 값은 적재값 중에 가장 큰 5개의 데이터를 의미한다.

그림 21. PC1에서 검사시점과 집단에 따른 적재값(주성분 계수)

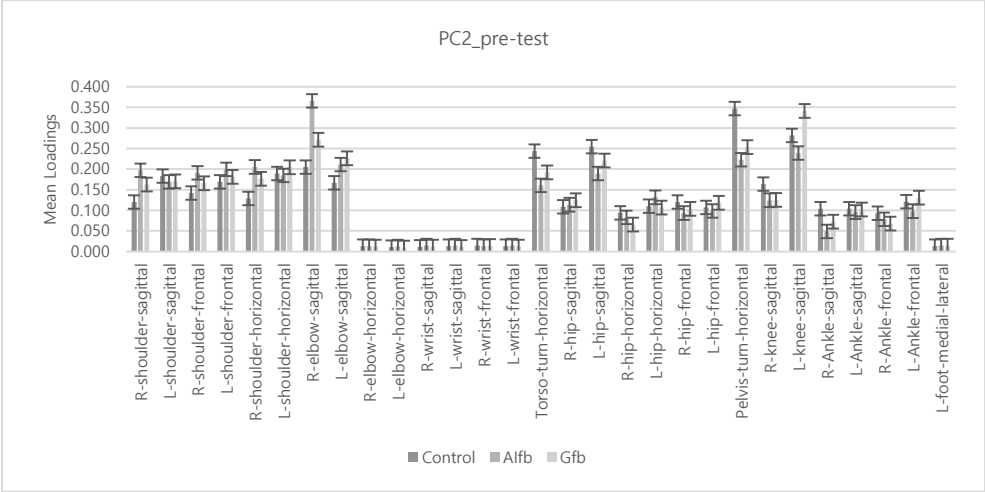

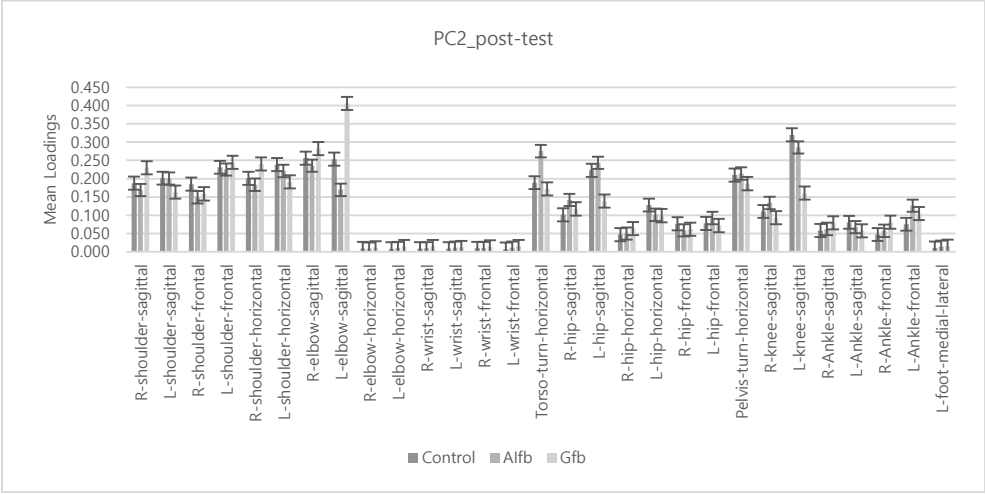

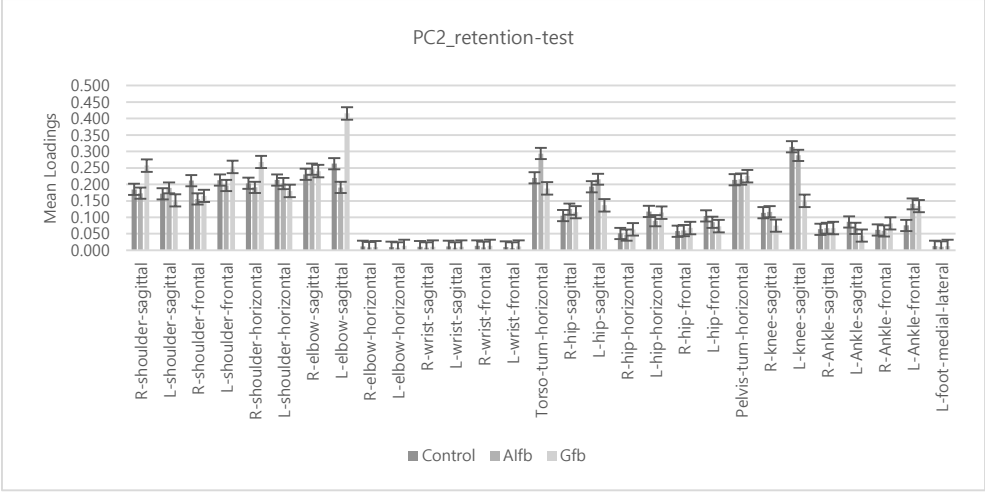

그림 22. PC2에서 검사시점과 집단에 따른 적재값(주성분 계수)

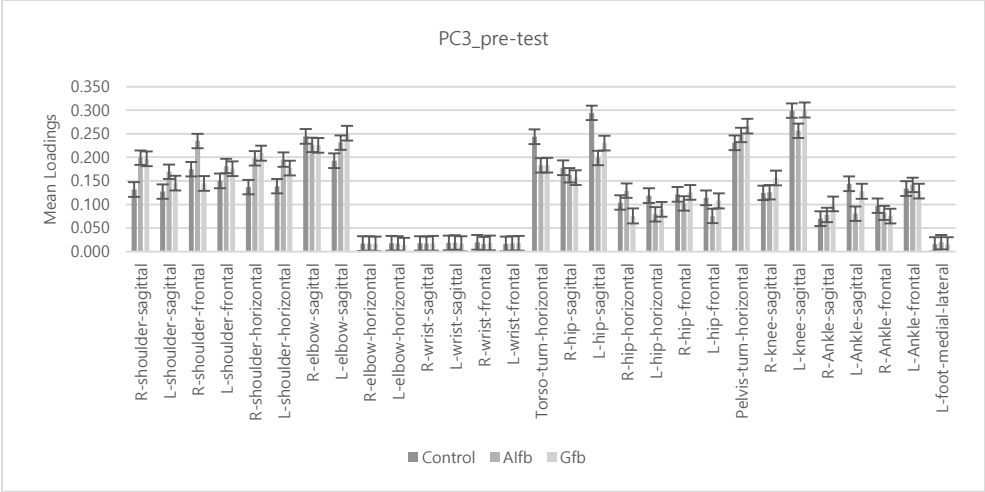

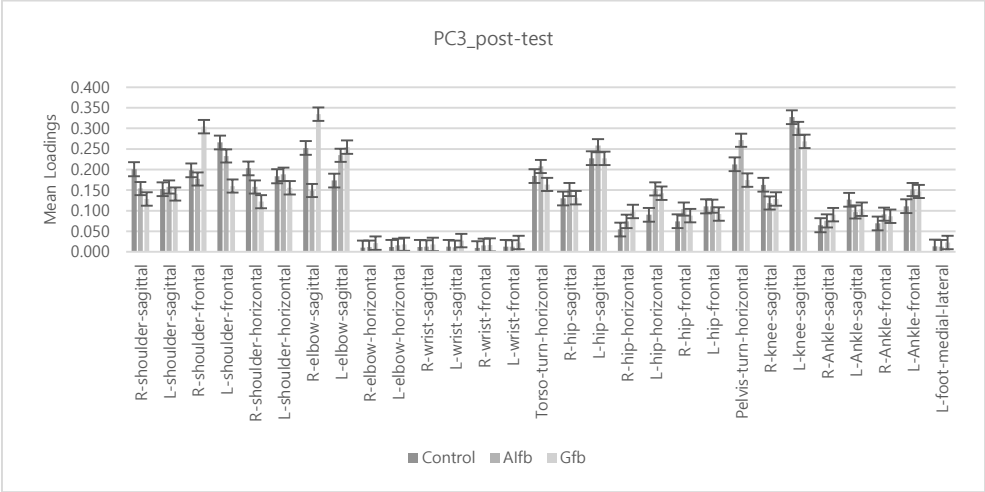

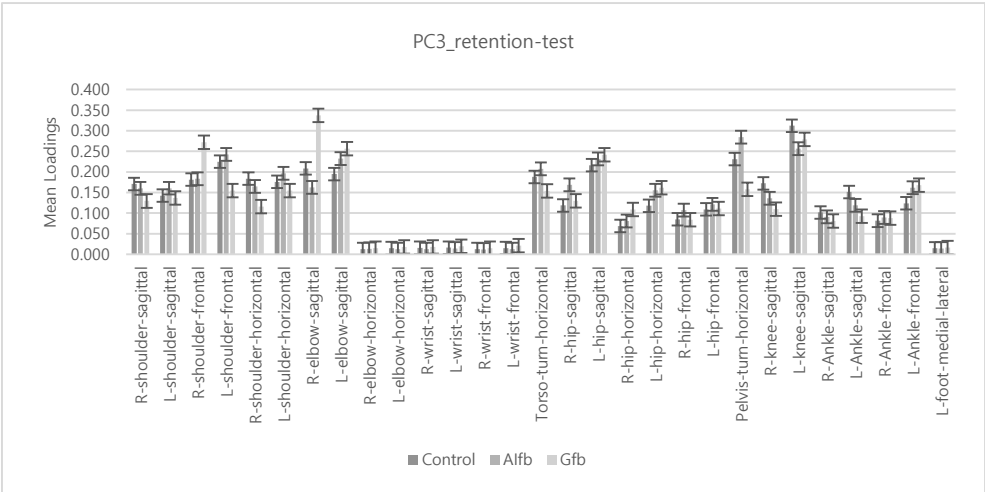

그림 23. PC3에서 검사시점과 집단에 따른 적재값(주성분 계수)

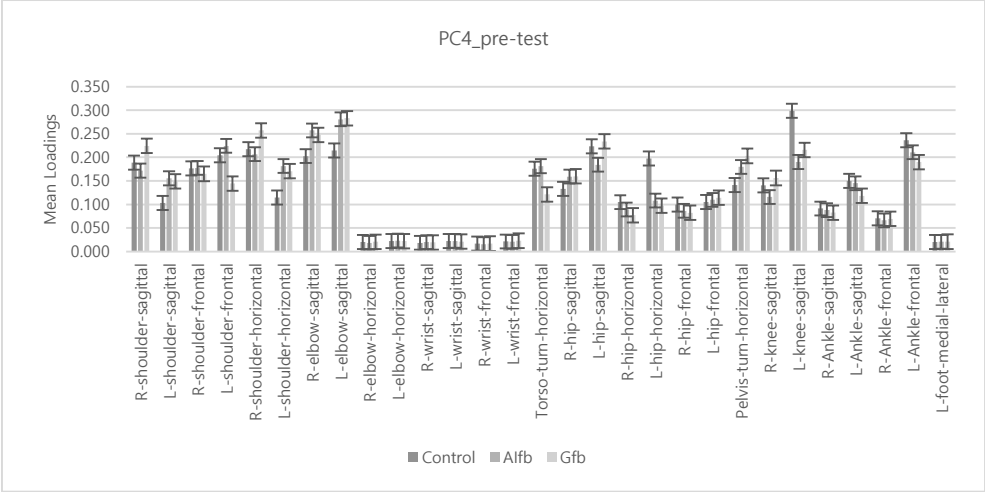

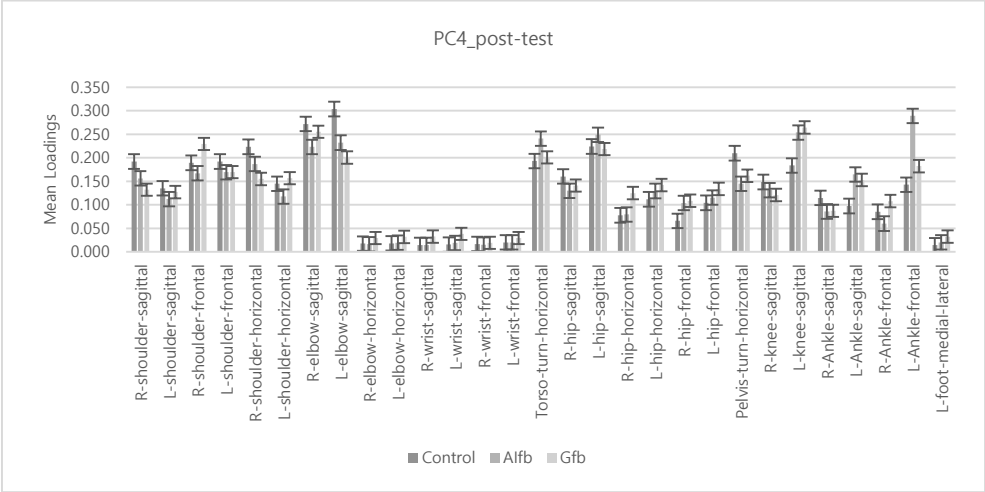

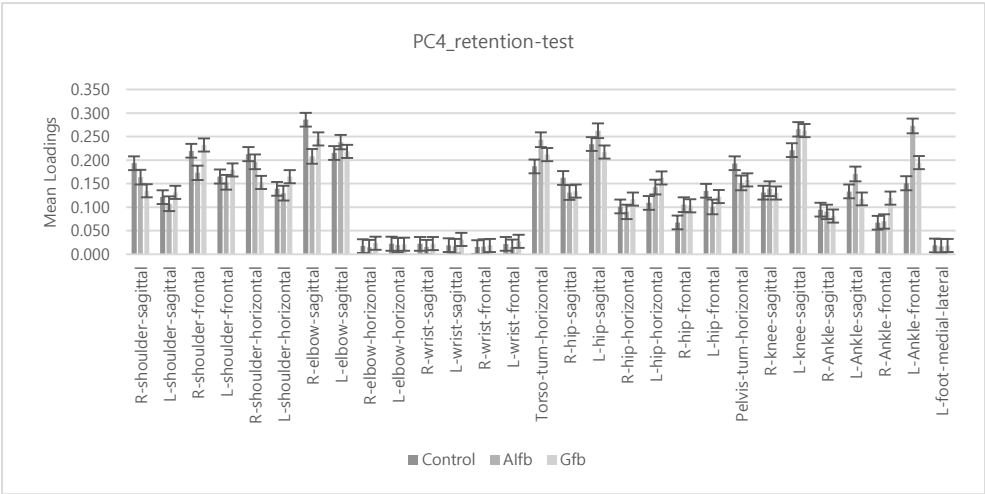

그림 24. PC4에서 검사시점과 집단에 따른 적재값(주성분 계수)

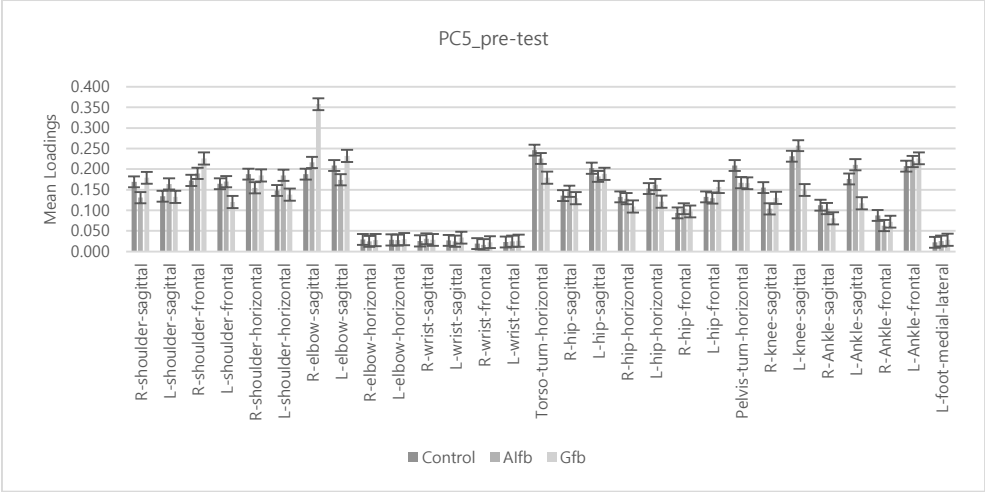

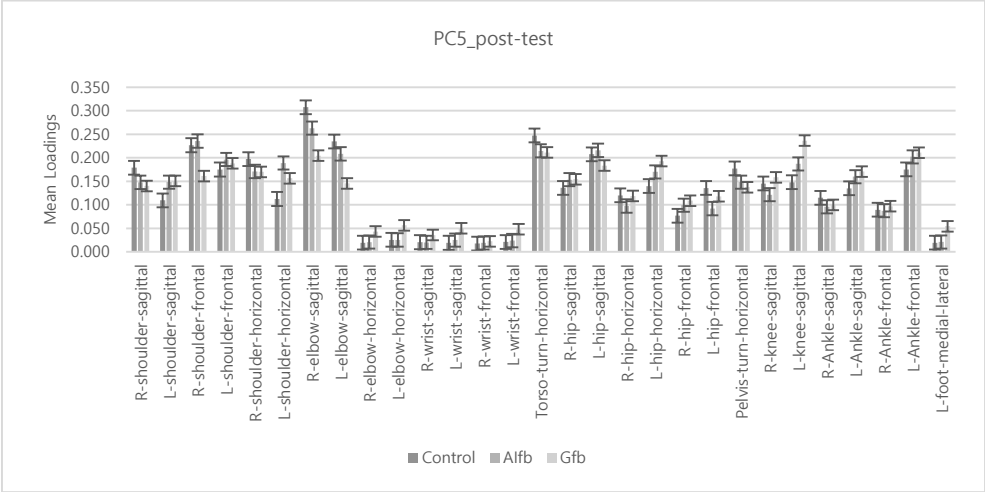

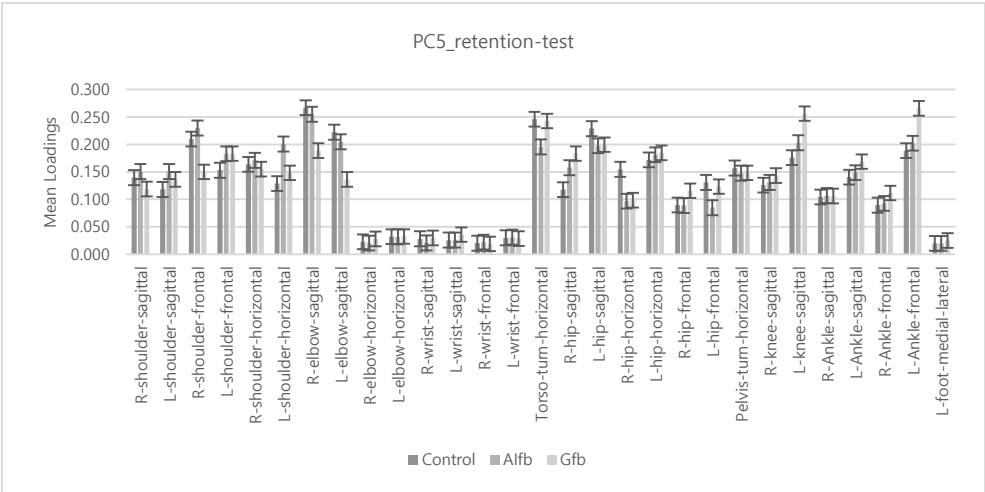

그림 25. PC5에서 검사시점과 집단에 따른 적재값(주성분 계수)

Ⅴ. 논의

본 연구의 목적은 복잡한 운동 기술 중 하나인 야구 치기 기술을 영상 분석을 통해 빅데이터로 수집하고, 머신러닝을 통해 숙련도를 분류 모델을 검증하고, 초보자를 대상으로 실행한 인공지능 피드백의 학습효과를 살펴보는 것이다. 연구과제는 배팅티 위에 올려진 공을 타구하는 것으로 머신러닝의 검증에서는 숙련자와 초보자 모델의 기계학습을 진행하여 신뢰도를 검증하였고, 운동학습 실험에서는 인공지능 피드백과 일반 피드백의 학습효과를 운동 수행 결과와 운동 수행 폼으로 나누어 비교하였다.

1. 머신러닝의 검증

야구 치기 기술의 숙련도를 분류하는 머신러닝은 관절 데이터로 PCA를 실행한 후, PC의 분산이 90%를 초과하는 PC 수의 score(주성분 점수)를 통해 SVM의 기계학습을 진행했다. 머신러닝의 신뢰도 검증은 머신러닝을 평가하는 지표로 혼동행렬에서 찾을 수 있는 정확도와 ROC 커브의 아래쪽 면적인 AUC로 검증했다.

먼저 정확도는 신뢰도 검정을 위해 사용된 전체 데이터 세트 중에 올바르게 분류된 값의 비율로 해당 연구에서는 약 97.1%의 높은 값이 도출됐다. 이는 복잡한 운동 기술 중 하나인 야구 치기 기술을 수행하는 영상을 통해 숙련자인지 초보자인지 약 97.1%의 정확도로 분류할 수 있다는 머신러닝 프로그램이 구성됐음을 의미한다(Beauxis-Aussalet, & Hardman, 2014).

둘째로, AUC는 ROC 커브의 x, y축의 평면상에서 아래쪽의 면적으로, 이것이 1에 가까우면 민감도와 특이도가 모두 높은 것으로 머신러닝의 알고리즘 성능이 좋은 분류라고 할 수 있다. 본 연구에서는 실제 숙련자 중에 숙련자로 예측한 비율인 민감도가 99.2%, 실제 초보자 중에 초보자로 예측한 비율인 특이도가 76.4%가 나왔으며 이들을 통해 만들

어진 ROC 커브의 AUC는 0.9809이 나왔다. 이는 1에 가까운 값으로 성능이 우수한 머신러닝 분류 모델이 생성됐다고 확인했다. 이는 이원분류 모델이기에 정확도의 값보다 더욱 일관적이고 더욱 구분을 잘 할 수 있는 신뢰도 검증 방법으로 알려져 있기에(Huang, & Ling, 2005), 야구 치기 기술의 숙련도 분류 모델로 받아들일 수 있다.

머신러닝의 검증을 완료한 후 숙련자와 초보자의 야구 치기 수행 시에 나타나는 복합관절의 협응구조를 추가로 살펴보았다. 이는 PCA를 통해 나타나는 주성분의 개수, 주성분의 분산, 적재값을 통해 확인했다. 먼저, 주성분으로 설명되는 분산(latent)이 90%를 초과하는 PC의 개수는 숙련자의 경우 최빈값이 4개였고, 초보자의 경우 최빈값은 5개였다. 비모수 통계 결과 초보자의 PC 개수가 유의하게 컸다. 이는 dynamical system 관점에서 초보자가 야구 치기를 수행할 때에 갖는 협응군이 숙련자보다 많음을 의미한다. 이는 숙련자가 신체 분절의 움직임을 커플링하여, 더 적은 dynamical degrees of freedom을 통해 움직임을 제어한다고 해석할 수 있다(Eubank and Farmer 1997; Li 2006; Newell and Vaillancourt 2001; Ko et al., 2013).

둘째로, 주성분으로 설명되는 분산은 PC1과 PC2에서는 숙련자가 초보자보다 분산이 유의하게 컸고, PC3과 PC4, PC5에서는 숙련자가 초보자보다 분산이 유의하게 작았다. 이는 주성분의 개수에서 해석한 것과 같이 숙련자의 주성분 개수가 적기 때문에 가장 큰 분산으로 설명을 하는 PC1과 두 번째로 큰 분산인 PC2에서의 분산이 초보자의 분산보다 크게 나온 것이다. 이에 따라 나머지 설명을 갖게 되는 분산인 PC3 이하의 PC들은 숙련자가 초보자보다 적은 것이다. 즉 숙련자는 초보자에 비해서 적은 수의 그룹화된 협응군으로 야구의 치기 기술을 수행할 수 있다는 것이다.

셋째로, 적재값(loading data)은 가장 큰 값을 나타내는 5개의 관절에서 살펴본 결과, PC1에서 숙련자는 왼쪽 어깨의 좌우면-오른쪽 어깨의 수평면-오른쪽 손목의 좌우면-골반의 회전-오른쪽 발목의 시상면 움직임에서 가장 높은 기여도를 나타냈으나, 초보자의 경우 오른쪽 어깨의

좌우면-왼쪽 어깨의 수평면-오른쪽 팔꿈치의 시상면-골반의 회전-왼쪽 무릎의 시상면 움직임에서 가장 높은 기여도를 나타냈다. 이때 숙련자에게 나타나는 오른쪽 손목의 좌우면에서의 움직임은 초보자의 경우 90% 설명력을 갖는 PC들(PC1~PC5)의 적재값에서도 발견되지 않는 움직으로 숙련성을 비교하는데 중요한 지표가 될 것으로 유추할 수 있다. 이는 초보자의 경우 가장 원위에 있는 관절인 손목의 움직임이 협응군으로 포함되지 않은 것으로, 순차적 패턴이 잘 수행되지 않았고(Putnam, 1983), 초보자이기에 이러한 패턴이 일관적이지 않았을 수 있기 때문으로 여겨진다(Vereijken et al., 1992). PC2의 경우 숙련자는 왼쪽 엉덩관절의 시상면-오른쪽 엉덩관절의 수평면-양쪽 엉덩관절의 좌우면-왼쪽 무릎의 시상면 움직임에서 높은 기여도를 나타냈고, 초보자는 양쪽 팔꿈치의 시상면-왼쪽 엉덩관절의 시상면-골반의 회전-왼쪽 무릎의 시상면 움직임에서 높은 기여도를 나타냈다. 이는 초보자의 경우 두 번째로 높은 주성분의 분산에서 숙련자에게는 나타나지 않는 팔꿈치의 굴곡-신전 움직임으로 협응군을 생성한다고 해석할 수 있다. PC3의 경우 숙련자는 양쪽 어깨의 시상면-왼쪽 어깨의 수평면-오른쪽 엉덩관절의 좌우면-왼쪽 발의 내외측 움직임에서 높은 기여도를 나타낸 반면, 초보자의 경우 양쪽 팔꿈치의 시상면, 왼쪽 엉덩관절의 시상면, 골반의 회전, 왼쪽 무릎의 시상면 움직임에서 높은 기여도를 나타냈다. 이는 백스윙과 스윙구간에서 나타나는 왼쪽 발의 이동이 숙련자에게서만 높은 기여도로 나타내는 모습이라고 해석할 수 있다.

2. 운동학습 실험

본 연구에서는 초보자를 대상으로 인공지능 피드백의 야구 치기 기술 학습효과를 살펴보기 위해서, 통제집단, 인공지능 피드백 집단(AIfb), 일반 피드백 집단(Gfb)에게 적합한 피드백을 제공하고 종속 변인을 운동 수행 결과와 운동 수행 폼으로 나누어 살펴보았다.

1) 운동 수행 결과

운동 수행 결과는 목표한 타구 각도의 정확성, 타구 각도의 일관성, 타구 속도로 살펴보았다. 먼저 목표한 타구 각도의 정확성은 집단간의 유의한 차이는 없었고, 검사 시점에서 차이가 있었다. 통제집단과 AIfb집단의 경우 파지 검사에서 정확성의 지표인 절대오차가 유의하게 가장 작았으나, Gfb집단의 경우 사후 검사에서 절대오차가 유의하게 가장 작았다. 이는 피드백을 받지 않은 집단이나, AIfb의 경우 시간이 지남에 따라 정확성이 향상됐지만, Gfb의 연습이 끝나고 48시간이 지난 파지 기간에는 정확성이 다시 저하됐다고 해석할 수 있다. 즉 Gfb집단은 타구 각도의 정확성에 있어서 운동 수행의 향상은 있었지만 운동 학습의 향상은 없었고, AIfb집단의 경우 타구 각도의 정확성에 있어서 운동 학습의 향상이 나타났다고 해석하였다.

둘째로 타구 각도의 일관성인 가변오차는 파지 검사 시점에서 AIfb집단과 Gfb집단이 통제집단에 비해 각각 유의하게 증가했다. 이는 피드백을 받은 집단이 목표한 타구 각도를 의식하고, 운동 수행 폼에 대한 시간적, 공간적 정보를 처리하고 있기에 그 가변성이 증가했다고 해석할 수 있다. 이는 파지 검사 시점에서 타구 속도가 피드백 집단에서 증가하고, 주성분 개수가 감소하는 것과 관련 있을 수 있다. 이는 운동속도가 증가할 때, 공간가변성이 증가한다는 선행연구와 같은 맥락이다(Kim et al., 1999). 주성분 개수의 감소는 dynamical degrees of freedom이 감소한 것이며, 그룹화된 협응군의 감소를 의미한다.

다이내믹 시스템 이론 관점에서 보면 하위 움직임 수의 감소는 그룹화된 협응군의 감소로 생각할 수 있고, 이는 운동학습 과정에서 나타나는 현상이다(Mitra et al., 1998). 본 실험은 단순한 도달 과제와는 다르게, 치기 과제로 연구 참여자로 하여금 타격되는 물체에 부딪히는 속도와 각도를 인지하게 된다. 따라서 그룹화된 협응군의 감소는 운동학습의 과정에서 나타나며 이것이 타구 각도의 일관성을 저하(가변오차를 증가)시키는 원인일 수 있다.

셋째로 타구 속도는 사후 검사(post-test)시점과 파지 검사(retention-test) 시점에서 각각 AIfb집단이 통제집단과 Gfb집단보다 유의하게 증가했다. 이는 AIfb이 타구 속도를 향상시키는데 크게 기여하였다고 해석할 수 있다. 이는 운동 수행 폼 중에 관절의 최대 각속도 순서 발현 비율이 AIfb에서 가장 높게 나타난 것과 함께 생각해볼 수 있다. 즉 골반의 회전 상체의 회전, 그리고 왼쪽 팔꿈치 움직임이 AIfb집단에서 근위-원위 협응 패턴(PDS)을 더 많이 발현되면서 순차적 가속이 나타나 타구 속도의 증가를 불러 일으켰다고 볼 수 있을 것이다(Tinmark et al., 2010).

2) 운동 수행 폼

운동 수행 폼은 관절의 최대 각속도 순서 발현 비율, 주성분 개수, 주성분으로 설명되는 분산, 적재값으로 살펴봤다. 먼저 사후 검사(post-test) 시점에서는 AIfb집단이 통제집단이나 Gfb집단에 비해 관절의 최대 각속도 순서 발현 비율이 유의하게 증가했고, 파지 검사(retention-test) 시점에서는 AIfb집단이 통제집단에 비해 관절의 최대 각속도 순서 발현 비율이 유의하게 증가했다. 이는 야구의 치기 기술이 연습을 통해 AIfb이 Gfb보다 순차적 가속에 있어서 수행의 향상이 있었지만, 파지 검사 시점에서는 AIfb이 Gfb보다 우수한 경향이 있었다고 해석할 수 있다. 이는 주성분 개수의 감소와 함께 생각해 볼 수 있다. 숙련자의 주성분 개수 즉 그룹화된 협응군이 4개인 것을 고려해보면, AIfb의 dynamical degrees of freedom 변화가 Gfb의 그 변화보다 숙련자와

가깝기에, 효율적인 치기 기술이 나타나는 순차적 가속이 AIfb에서 더 많이 나타났을 수 있다. 이들의 관계는 어떤 관절의 기여도가 있었는지에 따라 더욱 구체적으로 해석이 가능할 것이다.

두 번째로 주성분의 분산이 90%를 초과하는 주성분의 개수가 사후 검사(post-test) 시점과 파지 검사(retention-test) 시점에서 각각 AIfb집단과 Gfb집단이 통제집단에 비해 유의하게 감소했다. 사전 검사에서는 모든 집단의 주성분 개수의 최빈값이 5개였는데, AIfb집단의 경우 사후 검사와 파지 검사 시점에서 3개로, Gfb집단의 경우 사후 검사와 파지 검사 시점에서 2개로 감소하였다. 이는 숙련자의 주성분 개수가 4개인 것으로 볼 때, AIfb집단의 주성분 개수의 감소가 Gfb집단의 감소보다 숙련자와 가깝게 dynamical degrees of freedom의 변화가 나타난 경향이 있었다고 해석할 수 있다. 이는 AIfb의 경우 야구의 치기 기술을 설명하는 그룹화된 협응군이 5개에서 3개로 줄었고, Gfb의 경우 5개에서 2개로 줄었다고 해석할 수 있다는 것이다(Ko & Newell, 2015; Santos et al., 2010; Song et al., 2022). AIfb과 Gfb는 야구의 치기 기술을 잘 설명하는 움직임에 대하여 네 가지 분류로 나누어 피드백을 제공했다는 공통점이 있지만, 각 분류의 운동학적 기준에 대한 판별은 기계화된 알고리즘이 실행하는지, 전문화된 코치가 판별하는지의 차이가 있다. 인간이 진행하는 피드백은 움직임 기술을 시행할 때에 반복적인 동작에 의한 예측 등으로 심리적인 요소가 판별에 영향을 미칠 수 밖에 없다. 즉 Gfb의 그룹화된 협응군이 2개로 AIfb집단보다 더 줄게 된 것은 위와 같은 차이가 있었기 때문이며 구체적으로는 적재값(loading data)을 통해 움직임에 기여하는 관절을 살펴볼 필요가 있다.

셋째로 주성분으로 설명되는 분산은 PC1의 경우 사후 검사 시점과 파지 검사 시점에서 Gfb집단이 AIfb집단과 통제집단에 비해 유의하게 증가했고, PC2, PC3, PC4 그리고 PC5의 경우 반대로 사후 검사와 파지 검사 시점에서 Gfb집단이 AIfb집단과 통제집단에 비해 유의하게 감소했다. 이는 주성분의 분산이 90%를 초과하는 주성분 개수가 감소한

것에 영향을 받아, Gfb집단이 PC1에서는 AIfb집단보다 더 큰 분산을, 그리고 그 외의 나머지 PC에서는 더 작은 분산을 나타내게 된 것이라 할 수 있다.

넷째로 적재값은 파지 검사 시점에서 피드백을 받은 집단의 가장 큰 적재값을 나타내는 5개의 관절에서 살펴본 결과, PC1에서 AIfb집단은 양쪽 어깨의 좌우면-오른쪽 팔꿈치의 시상면-골반의 회전-왼쪽 무릎의 시상면 움직임에서 높은 기여도를 나타냈고, Gfb집단은 오른쪽 어깨의 좌우면-왼쪽 어깨의 수평면-오른쪽 팔꿈치의 시상면-상체의 회전-골반의 회전 움직임에서 높은 기여도를 나타냈다. PC2에서 AIfb집단은 오른쪽 팔꿈치의 시상면-상체의 회전-왼쪽 엉덩 관절의 시상면-골반의 회전-왼쪽 무릎의 시상면 움직임에서 높은 기여도를 나타냈고, Gfb집단은 오른쪽 어깨의 시상면-왼쪽 어깨의 좌우면-오른쪽 어깨의 수평면-양쪽 팔꿈치의 시상면 움직임에서 높은 기여도를 나타냈다. 이는 Gfb집단의 경우, 상체의 회전과 골반의 회전을 모두 PC1이라는 협응군에서 사용하면서 PC2의 협응군에서는 어깨와 팔꿈치만의 움직임만으로 협응구조를 생성하는 모습을 나타냈다고 볼 수 있다. 반면 AIfb은 PC3에서 오른쪽 어깨의 좌우면-왼쪽 팔꿈치의 시상면-왼쪽 엉덩관절의 시상면-골반의 회전- 왼쪽 무릎의 시상면 움직임에서 높은 기여도를 나타냈다. 이는 PC1에서는 양쪽 어깨의 좌우면 움직임과 골반의 회전을 협응군으로 사용하게 되는 점, PC2에서는 골반의 회전과 함께, 상체의 회전, 그리고 왼쪽 엉덩관절의 굴곡-신전을 협응군으로 사용하게 되는 점을 확인할 수 있고, PC3에서는 오른쪽 어깨의 좌우면 움직임과 왼쪽 팔꿈치의 굴곡-신전을 협응군으로 사용하는 모습을 확인할 수 있다고 해석했다. 이들을 숙련자와 비교해본다면 피드백을 받은 두 집단 모두 왼쪽 발의 뻗는 동작이나 손목의 움직임을 협응군으로 사용하지는 못했지만, AIfb집단은 PC1에서 골반의 회전을, PC2에서 골반과 상체의 회전을 협응군으로 포함하는 반면, Gfb집단은 PC1에서 골반의 회전과 상체의 회전을 협응군으로, 그리고 PC2에서는 어깨와 팔꿈치만의 움직임만으로 협응군을 생성하는 변화가 나타났다고

해석할 수 있다. 이는 Gfb이 AIfb에 비해서 상대적으로 근위에 있는 골반과 상체의 회전을, 상대적으로 원위에 있는 상지의 움직임과 다소 분리하여 협응군을 이루는 모습을 보이면서 그룹화된 협응군의 개수를 더욱 줄였다고 해석될 수 있다. 이러한 현상으로 인해 Gfb집단에서 순차적 가속의 비율이 AIfb집단보다 작게 나타났을 수 있고, 이것이 Gfb집단의 타구 속도도 AIfb집단에 비해 유의하게 작게 나타나게 된 원인일 수 있다. 즉 이러한 점이 운동 수행의 결과 중 타구 속도에도 영향을 미쳤을 수 있다는 것이다.

Ⅵ. 결론 및 제언

1. 결론

인간의 삶의 질을 향상시키는 인간의 움직임은 교육을 통해 효율적으로 변화할 수 있고, 이는 일상에서 운동기능의 향상, 운동 재활 치료로 이어진다. 컴퓨터 과학의 발전으로 인간의 움직임 교육은 빅데이터화 되어 머신러닝 알고리즘을 통해 움직임의 숙련도가 분류될 수 있었고, 이를 바탕으로 만들어진 인공지능 피드백의 효과도 확인할 수 있었다. 본 연구는 다음과 같은 결론에 도달했다.

첫째, 숙련성에 따른 복잡한 운동 기술인 야구 치기 기술의 운동 수행 폼을 머신러닝 기반 운동기술 측정 프로그램으로 분류할 수 있다.

둘째, 빅데이터 기반 인공지능 피드백이 일반 피드백에 비해 치기 기술의 운동 수행 결과인 타구 각도의 정확성과 일관성의 향상에는 효과가 없었으나, 타구 속도의 향상에는 효과적이다.

셋째, 빅데이터 기반 인공지능 피드백이 일반 피드백에 비해 치기 기술의 운동 수행 폼인 근위-원위 협응 패턴의 향상과 주성분으로 설명되는 분산의 변화에 효과적이었으며, 주성분 개수의 변화에는 긍정적인 경향성을 보였다.

종합하면 머신러닝을 통해 만들어진 인공지능 피드백이 운동 수행의 결과보다는 운동 수행 폼의 향상에 긍정적으로 기여하고 있으며, 이는 실제 현장에서 적용되고 있는 코칭에 큰 도움을 줄 수 있을 것으로 보인다.

2. 제언

본 연구에서 정리된 결과 및 논의를 바탕으로 추후 진행될 연구에서 고려되어야 할 점은 다음과 같다.

첫째, 본 연구에서는 치기 기술 학습 프로그램 이외의 연구참여자 개개인이 가지고 있는 생리적 특성 및 심리적 특성을 완전하게 통제하지 못한다. 따라서 다음과 같은 제한점을 보완하기 위해서, 실험에 참여하기 전과 후에 골반이나 상체의 유연성과 피드백을 주는 대상과의 관계에 의한 심리를 보고받는 추가적인 절차가 이루어질 것을 제언한다.

둘째, 인공지능이 판별하는 운동학적 데이터들은 변인에 따라 상호관련성이 존재하더라도 그 관련성이 배제되어 독립적으로 분류된다. 인간의 신체 분절은 생체역학적으로 연결되어 있기 때문에 한 관절의 움직임은 다른 관절에 영향을 줄 수 밖에 없지만, 각각의 관절의 자유도를 보존하기 위해 그 관련성이 배제된 상태로 독립적으로 분류됐다. 추후 연구에서는 해당 관절의 움직임 근처에서 나타나는 근처 분절의 움직임의 관련성을 파악하여 하나의 협응구조로 해석하여 표현한다면 인간 움직임의 협응을 더욱 명확하게 규명할 수 있을 것이다.

셋째, 일반 피드백의 경우 인공지능 피드백과의 동등성을 위해 야구 전문 코치의 언어적 피드백만 네 가지의 큰 범주에서 제공되는 것으로 제한되었다. 현장에서의 피드백은 대부분의 다양한 종류의 피드백을 포괄하고 있으며, 여기에는 언어적 피드백 뿐만 아니라, 시범을 통한 시각 피드백, 촉각 피드백 등이 존재한다. 또한 심리적 특성에 따라 동기를 향상시켜 운동학습을 향상시키기도 하는 등 다양한 피드백이 존재한다. 인공지능 피드백이 실제 현장에서의 피드백 만큼 효과가

있는지 밝히기 위해서는 위와 같이 다양한 감각 피드백이 함께 고려되어야 하며, 학습자의 동기나 과제 성향을 파악하여 운동학습에 긍정적인 심리변화를 이끌어낼 수 있는 피드백도 함께 구축되어야 할 것이다.

참고 문헌

권정선. (2021). 인공지능시대, 데이터 기반 맞춤형 교육에 대한 비판적 고찰: 존 듀이의 경험철학적 사고 개념을 중심으로. **교육철학연구, 43**(2), 51-76.

김선진. (2015). **운동학습과 제어 개정판**. 서울: 대한미디어.

김선진. (2003). **운동발달의 이해**.서울: 서울대학교출판부.

남수미, 서동휘, & 김민주. (2022). 아동 운동발달 평가도구 (MABC-2)의 평가역량 교육의 효과 검증. **한국여성체육학회지, 36**(2), 77-90.

박동진, 한동욱, & 김용운. (2011). 결과지식 수준과 신체 및 관찰연습이 타이밍 학습에 미치는 영향. **한국스포츠심리학회지, 22**(3), 141-152.

박수범, & 홍승분. (2019). 내. 외적 주의초점 피드백에 따른 태권도 앞차기 동작기술의 학습 효과. **국기원태권도연구, 10**(3), 335-354.

서동휘. (2019). **시각 피드백 형태에 따른 배드민턴 초보자의 포핸드 언더 클리어 학습 효과.** 서울대학교. 미간행 석사학위논문.

서동휘, 남수미, 엄혜성, & 김민주. (2022). 코로나바이러스 감염증-19 (COVID-19) 확산을 경험하는 청소년의 신체활동과 심리상태. **한국발육발달학회지, 30**(2), 207-218.

서형준. (2019). 4 차 산업혁명시대 인공지능 정책의사결정에 대한 탐색적 논의. **정보화정책, 26**(3), 3-35.

이동연, 서동휘, & 김선진. (2022). 가상현실 (Virtual Reality) 기기 훈련이 야구 배트 스윙의 정확도에 미치는 영향. **한국체육교육학회지, 27**(1), 223-233.

이용준, & 김태영. (2021). 딥러닝 기반 포즈 인식 및 교정을 통한 효율적인 홈 트레이닝 시스템 개발. **한국차세대컴퓨팅학회**

논문지, 17(6), 89-99.

이의재, 제성준, & 윤현수. (2020). 코로나 19 펜데믹 (pandemic) 상황에서 고등학교 경력 체육 교사가 겪는 온라인 수업 실천의 어려움과 극복 전략 탐색. **학습자중심교과교육연구, 20**(14), 339-362.

이한우, & 육동원. (2004). 언어적 진술로 구성된 내, 외부적 주의초점 피드백이 볼링투구과제에 미치는 영향. **한국스포츠심리학회지, 15**(2), 1-16.

한국통계청. (2018). **2018년 기준 국민생활체육조사 통계결과표 [데이터 세트]**. 국가도서관통계시스템. https://kosis.kr/statHtml/statHtml.do?orgId=113&tblId=DT_113_STBL_1028576

Ae, K., Koike, S., Fujii, N., Ae, M., & Kawamura, T. (2017). Kinetic analysis of the lower limbs in baseball tee batting. *Sports biomechanics, 16*(3), 283-296.

Beauxis-Aussalet, E., & Hardman, L. (2014). ***Visualization of confusion matrix for non-expert users.*** In IEEE Conference on Visual Analytics Science and Technology (VAST)-Poster Proceedings.

Begg, R., & Kamruzzaman, J. (2005). A machine learning approach for automated recognition of movement patterns using basic, kinetic and kinematic gait data. *Journal of biomechanics*, *38*(3), 401-408.

Beilock, S. L., Bertenthal, B. I., McCoy, A. M., & Carr, T. H. (2004). Haste does not always make waste: Expertise, direction of attention, and speed versus accuracy in performing sensorimotor skills. *Psychonomic bulletin & review, 11*(2), 373-379.

Bernstein, N. (1966). ***The coordination and regulation of movements.*** The coordination and regulation of movements.

Bonaccorso, G. (2017). *Machine learning algorithms*. Packt Publishing Ltd.

Burton, A. W., & Rodgerson, R. W. (2001). New Perspectives on the Assessment of Movement Skills and Motor Abilities. *Adapted Physical Activity Quarterly*, *18*(4).

Chiviacowsky, S., & Wulf, G. (2007). Feedback after good trials enhances learning. *Research quarterly for exercise and sport, 78(2)*, 40-47.

Christina, R. W., & Shea, J. B. (1993). More on assessing the retention of motor learning based on restricted information. *Research Quarterly for Exercise and Sport, 64*(2), 217-222.

Conforti, I., Mileti, I., Del Prete, Z., & Palermo, E. (2020). Measuring biomechanical risk in lifting load tasks through wearable system and machine-learning approach. *Sensors, 20*(6), 1557.

Eubank, S. G., & Farmer, J. D. (1997). Probability, random processes, and the statistical description of dynamics. *Introduction to nonlinear physics*, 106-178.

Faul, F., Erdfelder, E., Buchner, A., & Lang, A. G. (2009). Statistical power analyses using G* Power 3.1: Tests for correlation and regression analyses. *Behavior research methods, 41*(4), 1149-1160.

Frankel, F., & Reid, R. (2008). Big data: Distilling meaning from data. *Nature, 455*(7209), 30-30.

Gentile, A. M. (1972). A working model of skill acquisition with application to teaching. *Quest, 17*(1), 3-23.

Gentile, A. M., & Nacson, J. (1976). Organizational processes in motor control. *Exercise and sport sciences reviews, 4*(1), 1-34.

Glover, S. (2002). Visual illusions affect planning but not control. *Trends in cognitive sciences, 6*(7), 288-292.

Hirashima, M., Kudo, K., Watarai, K., & Ohtsuki, T. (2007). Control of 3D limb dynamics in unconstrained overarm throws of different speeds performed by skilled baseball players. *Journal of neurophysiology*, *97*(1), 680-691.

Hong, S. L., & Newell, K. M. (2006). Change in the organization of degrees of freedom with learning. *Journal of Motor Behavior*, *38*(2), 88-100.

Huang, J., & Ling, C. X. (2005). Using AUC and accuracy in evaluating learning algorithms. *IEEE Transactions on knowledge and Data Engineering*, *17*(3), 299-310.

Hubbard, A. W., & Seng, C. N. (1954). Visual movements of batters. *Research Quarterly. American Association for Health, Physical Education and Recreation*, *25*(1), 42-57.

Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: *Trends, perspectives, and prospects. Science, 349*(6245), 255-260.

Kagan, D. (2010). What is the best launch angle to hit a home run?. *The Physics Teacher*, *48*(4), 250-250.

Kaiser, H. F. (1960). The application of electronic computers to factor analysis. *Educational and psychological measurement, 20*(1), 141-151.

Katsumata, H., Himi, K., Ino, T., Ogawa, K., & Matsumoto, T. (2017). Coordination of hitting movement revealed in baseball tee-batting. *Journal of Sports Sciences, 35*(24), 2468-2480.

Kernodle, M. W., & Carlton, L. G. (1992). Information feedback and the learning of multiple-degree-of-freedom activities. *Journal of motor behavior, 24*(2), 187-195.

Kim, S., Carlton, L. G., Liu, Y. T., & Newell, K. M. (1999). Impulse and movement space—time variability. *Journal of motor behavior*, *31*(4), 341-357.

Ko, J. H., Challis, J. H., & Newell, K. M. (2013). Postural coordination patterns as a function of rhythmical dynamics of the surface of support. *Experimental brain research*, *226*(2), 183-191.

Ko, J. H., & Newell, K. M. (2015). Organization of postural coordination patterns as a function of scaling the surface of support dynamics. *Journal of Motor Behavior, 47*(5), 415-426.

Kugler, P. N., Kelso, J. S., & Turvey, M. T. (1980). 1 on the concept of coordinative structures as dissipative structures: I. theoretical lines of convergence. In *Advances in psychology* (Vol. 1, pp. 3-47). North-Holland.

Lanshammar, H. (1982). On practical evaluation of differentiation techniques for human gait analysis. *Journal of Biomechanics*, *15*(2), 99-105.

Larivière, C., Arsenault, A. B., Gravel, D., Gagnon, D., & Loisel, P. (2001). Median frequency of the electromyographic signal: effect of time-window location on brief step contractions. *Journal of Electromyography and Kinesiology*, *11*(1), 65-71.

Lawrence, G. P., Gottwald, V. M., Hardy, J., & Khan, M. A. (2011). Internal and external focus of attention in a novice form sport. *Research Quarterly for Exercise and Sport*, *82*(3), 431-441.

Lee, T. D., Ishikura, T., Kegel, S., Gonzalez, D., & Passmore, S. (2008). Head-putter coordination patterns in expert and less skilled golfers. *Journal of Motor Behavior, 40*(4), 267-272.

Lee, H. S., & Lee, J. (2021). Applying artificial intelligence in physical education and future perspectives. *Sustainability, 13*(1), 351.

Li, Z. M. (2006). Functional degrees of freedom. *Motor control*, *10*(4), 301-310.

Magill, R., & Anderson, D. (2010). *Motor learning and control*. New

York: McGraw-Hill Publishing.

Maier, M., Ballester, B. R., & Verschure, P. F. (2019). Principles of neurorehabilitation after stroke based on motor learning and brain plasticity mechanisms. *Frontiers in systems neuroscience, 13*, 74.

McErlain-Naylor, S. A., King, M. A., & Felton, P. J. (2021). A review of forward-dynamics simulation models for predicting optimal technique in maximal effort sporting movements. *Applied Sciences, 11*(4), 1450.

Mitra, S., Amazeen, P. G., & Turvey, M. T. (1998). Intermediate motor learning as decreasing active (dynamical) degrees of freedom. *Human movement science*, *17*(1), 17-65.

Nakata, H., Miura, A., Yoshie, M., Higuchi, T., & Kudo, K. (2014). Differences in trunk rotation during baseball batting between skilled players and unskilled novices. *The Journal of Physical Fitness and Sports Medicine, 3*(4), 457-466.

Newell, K. M. (1985). Coordination, control and skill. *In Advances in psychology*(Vol. 27, pp. 295-317). North-Holland.

Newell, K. M. (1991). Motor skill acquisition. *Annual review of psychology, 42*(1), 213-237.

Newell, K. M. (1996). Change in movement and skill: Learning, retention, and transfer. *Dexterity and its development*, 393-429.

Newell, K. M., & Vaillancourt, D. E. (2001). Dimensional change in motor learning. *Human movement science*, *20*(4-5), 695-715.

Noble, W. S. (2006). What is a support vector machine?. *Nature biotechnology, 24*(12), 1565-1567.

Oppici, L., Dix, A., & Narciss, S. (2021). When is knowledge of performance (KP) superior to knowledge of results (KR) in

promoting motor skill learning? A systematic review. *International Review of Sport and Exercise Psychology*, 1-25.

Perkins-Ceccato, N., Passmore, S. R., & Lee, T. D. (2003). Effects of focus of attention depend on golfers' skill. *Journal of Sports Sciences*, *21*(8), 593-600.

Post, P. G., Aiken, C. A., Laughlin, D. D., & Fairbrother, J. T. (2016). Self-control over combined video feedback and modeling facilitates motor learning. *Human movement science, 47*, 49-59.

Power, D. J. (2014). Using 'Big Data'for analytics and decision support. *Journal of Decision Systems, 23*(2), 222-228.

Putnam, C. A. (1993). Sequential motions of body segments in striking and throwing skills: descriptions and explanations. *Journal of biomechanics*, *26*, 125-135.

Roh, J., Park, H. J., Lee, K. J., Hyeong, J., Kim, S., & Lee, B. (2018). Sitting posture monitoring system based on a low-cost load cell using machine learning. *Sensors, 18*(1), 208.

Salmanpour, M. R., Shamsaei, M., Saberi, A., Klyuzhin, I. S., Tang, J., Sossi, V., & Rahmim, A. (2020). Machine learning methods for optimal prediction of motor outcome in Parkinson's disease. *Physica Medica, 69*, 233-240.

Santos, M. J., Kanekar, N., & Aruin, A. S. (2010). The role of anticipatory postural adjustments in compensatory control of posture: 2. Biomechanical analysis. *Journal of Electromyography and Kinesiology*, *20*(3), 398-405.

Schmidt, R. A. (1991).***Motor learning & performance: From principles to practice.*** Human Kinetics Books.

Schoenfeld, B. J., Vigotsky, A., Contreras, B., Golden, S., Alto, A., Larson, R., ... & Paoli, A. (2018). Differential effects of

attentional focus strategies during long-term resistance training. *European Journal of Sport Science*, *18*(5), 705-712.

Serrien, B., & Baeyens, J.-P. (2017). The proximal-to-distal sequence in upper-limb motions on multiple levels and time scales. *Human Movement Science, 55*, 156-171.

Shea, C. H., & Wulf, G. (1999). Enhancing motor learning through external-focus instructions and feedback. *Human Movement Science*, *18*(4), 553-571.

Sigrist, R. (2011). Visual and auditory augmented concurrent feedback in a complex motor task. *Presence, 20*(1), 15-32.

Sigrist, R., Rauter, G., Riener, R., & Wolf, P. (2013). Augmented visual, auditory, haptic, and multimodal feedback in motor learning: a review. *Psychonomic bulletin & review*, *20*(1), 21-53.

Song, Y. H., Cho, S. N., & Nam, S. M. (2022). Asymmetric Influence of Dual-Task Interference on Anticipatory Postural Adjustments in One-Leg Stance. *International Journal of Environmental Research and Public Health*, *19*(18), 11289.

Tallet, J., Kostrubiec, V., & Zanone, P. G. (2008). The role of stability in the dynamics of learning, memorizing, and forgetting new coordination patterns. *Journal of Motor Behavior, 40*(2), 103-116.

Tinmark, F., Hellström, J., Halvorsen, K., & Thorstensson, A. (2010). Elite golfers' kinematic sequence in full-swing and partial-swing shots. *Sports Biomechanics*, *9*(4), 236-244.

Toole, A. J., & Fogt, N. (2021). Head and Eye Movements and Gaze *Tracking in Baseball Batting. Optometry and Vision Science, 98*(7), 750-758.

Totsika, V., & Wulf, G. (2003). The influence of external and internal foci of attention on transfer to novel situations and

skills. *Research Quarterly for Exercise and Sport*, *74*(2), 220-232.

Triano, J. J., Descarreaux, M., & Dugas, C. (2012). Biomechanics-review of approaches for performance training in spinal manipulation. *Journal of Electromyography and Kinesiology, 22*(5), 732-739.

Ulrich, D. A. (2013). The test of gross motor development-3 (TGMD-3): Administration, scoring, and international norms. *Spor Bilimleri Dergisi*, *24*(2), 27-33.

Vandevoorde, K., Vollenkemper, L., Schwan, C., Kohlhase, M., & Schenck, W. (2022). Using Artificial Intelligence for Assistance Systems to Bring Motor Learning Principles into Real World Motor Tasks. *Sensors, 22*(7), 2481.

Van Vliet, P. M., & Wulf, G. (2006). Extrinsic feedback for motor learning after stroke: what is the evidence?. *Disability and rehabilitation, 28*(13-14), 831-840.

Varea, V., & Gonzalez-Calvo, G. (2021). Touchless classes and absent bodies: teaching physical education in times of Covid-19.*Sport, Education and Society, 26*(8), 831-845.

Vereijken, B., Emmerik, R. E. V., Whiting, H. T. A., & Newell, K. M. (1992). Free (z) ing degrees of freedom in skill acquisition. *Journal of motor behavior*, *24*(1), 133-142.

Weeks, D. L., & Kordus, R. N. (1998). Relative frequency of knowledge of performance and motor skill learning. *Research Quarterly for Exercise and Sport*, *69*(3), 224-230.

Welch, C. M., Banks, S. A., Cook, F. F., & Draovitch, P. (1995). Hitting a baseball: A biomechanical description. *Journal of orthopaedic & sports physical therapy*, *22*(5), 193-201.

Winstein, C. J. (1991). Knowledge of results and motor learning—

implications for physical therapy. *Physical therapy*, *71*(2), 140-149.

Wulf, G., Höß, M., & Prinz, W. (1998). Instructions for motor learning: Differential effects of internal versus external focus of attention. *Journal of Motor Behavior, 30*(2), 169-179.

Wulf, G. (2013). Attentional focus and motor learning: a review of 15 years. *International Review of sport and Exercise psychology, 6*(1), 77-104.

Yuan, X. (2021, August). The Application Prospects of Artificial Intelligence in the Field of Physical Education. *In 2021 World Automation Congress (WAC)*(pp. 283-286). IEEE.

Abstract

Learning effect of baseball hitting technique using artificial intelligence feedback

Suh, Dong Hwi

Department of Physical Education

The Graduate School

Seoul National University

In In this study, we observed if machine learning techniques were able to classify proficiency in complex movement such as striking skills. We then observed if artificial intelligence based feedback(Alfb) had an effect on improving the form of the strike. In order to verify the reliability of AI based feedback, 440 adolescent male novices (age: 14.9±0.8) and 48 adolescent male experts (age: 16.9±0.8) performed a task of striking a ball placed on a batting tee, which was recorded from the front. The captured data was expressed as joint data using video analysis, which was subjected to machine learning through Principal Component Analysis (PCA) and a Support Vector Machine (SVM). In the motor learning experiment, 42 male adolescent novices (age: 15.0±0) who did not participate in the above machine learning verification experiment were classified into a control group, an AIfb group, and a Gfb group, and they performed a pre-test, a test post practice test, and a retention-test. All tests consisted of 10 strikes, and in the practice stage, 5 blocks of 10 strikes were conducted for 5 days, resulting in a total of 250 strikes that were performed while receiving feedback.

As a result, in the machine learning verification experiment, the machine learning program was concluded to have excellent performance with high accuracy and high AUC. At this time, the number of principal components of the expert obtained the mode at 4, and the number of principal components of the novices obtained the mode at 5, so it can be seen that fewer dynamical degrees of freedom appeared in the striking skills of the expert.

In the motor learning experiment, there was no significant difference among the groups that received feedback in the absolute error representing the

accuracy of the striking angle, and the variable error, which expresses the consistency of the striking angle, showed an increase in the group that received the feedback than the control group. However, the ball speed was significantly improved in the AIfb group than in the Gfb group. In the case of the form of motor performance, the maximum angular velocity ratio in the order of pelvis-trunk-left elbow showed a significant improvement in the AIfb group compared to the Gfb and control groups, and the number of principal components decreased to 3 in the AIfb group and to 2 in the Gfb group. Accordingly, the variance of the principal components was significantly greater in the Gfb group than in the AIfb group in PC1, but significantly smaller in the Gfb group than in the AIfb group below PC2. It can be seen that AIfb contributed to the improvement of form of motor performance because the AIfb group changed close to that of the experts In the case of loading data, the AIfb group uses the upper extremity, pelvis, and knee in PC1, the upper extremity, upper body, pelvis, and lower extremity in PC2, and the upper extremity, pelvis, and lower extremity in PC3 as the coordination group. On the other side, it was confirmed that the Gfb group used the upper limbs, upper body and pelvis in PC1 and only the upper limbs in PC2 as the coordination group.

This study tried to verify the reliability of classifying the proficiency of the striking skills, which is a complex motor skill, through machine learning of big data, and confirm the effect of AIfb. The study was able to classify proficiency in complex motor skills that are difficult to observe, and confirmed that it could contribute to the improvement of motor performance form through artificial intelligence feedback that automatically provides appropriate kinematic feedback for insufficient parts. We also confirmed that artificial intelligence feedback can effectively change the dynamical degrees of freedom. It is expected that artificial intelligence feedback using big data will help provide necessary feedback to instructors and learners in the field of motor learning, and will be meaningful as a scientific basis for deep understanding of the coordination structure of human movements.

Keywords : Artificial intelligence, Motor learning, Striking task, Coordination, Machine learning, Feedback

Student Number : 2019-37841