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

체육학박사 학위논문

머신러닝 기술을 활용한 증강현실 퍼팅 학습에 관한 연구 : 숙련도에 따른 변화 중심으로

서울대학교 대학원

체육교육과

이 동 연

머신러닝 기술을 활용한 증강현실 퍼팅 학습에 관한 연구 : 숙련도에 따른 변화 중심으로

지도교수 김 선 진

이 논문을 이동연 체육학박사 학위논문으로 제출함
2022 년 12 월

서울대학교 대학원
체육교육과
이 동 연

이동연의 박사 학위논문을 인준함
2022 년 12 월

위 원 장 권 성 호

부 위 원 장 박 재 범

위 원 안 주 은

위 원 반 성 범

위 원 김 선 진

국문초록

머신러닝 기술을 활용한 증강현실 퍼팅 학습에 관한 연구 : 숙련도에 따른 변화 중심으로

이 동 연
서울대학교 대학원
체 육 교 육 과

퍼팅 과제는 다양한 패턴의 개인차가 존재하며 올바른 인지-수행 능력에 따라 수행 수준이 결정된다. 개인차는 곧 고유감각 요인이며, 이를 고려하여 어떻게 학습시켜야 성공적인 퍼팅이 가능한지에 관한 연구가 필요하다. 본 연구의 목적은 개인차를 고려한 머신러닝 프로그램을 활용하여 증강현실 피드백을 적용한 집단과 자기조절 피드백(self-controlled feedback)을 활용한 일반 퍼팅 훈련 집단과의 비교를 통해 효율적인 퍼팅 학습법을 제시하는 데 있다. 연구에 참여한 대상은 만 20세에서 40세 사이의 성인 36명으로 숙련자(핸디캡 10 이하, 구력 3년 이상) 18명과 비숙련자(핸디캡 30 이상, 구력 2년 이내) 18명으로 구성하였다. 숙련자 또는 비숙련자에서 9명씩 머신러닝 집단과 자기조절 집단으로 나누었다(4그룹). 연구참여자들은 거리(1m, 2.5m 3.5m)와 방향(홀컵 기준 12가지)에 따라 퍼팅 과제를 수행하였다. 사전검사 데이터를 바탕으로 머신러닝 집단은 개인차를 고려하여 개인별 퍼팅 템포 및 스윙 크기에 대한 시각 및 청각 피드백을 받았으며 자기조절 집단은 성공률과 오차범위에 대한 피드백을 받았다. 3회의 학습 과정 뒤 사후 검사를 실시하였으며, 48시간이 지난 뒤 파지 검사를 시행하였다. 퍼팅 학습 변화를 확인하기 위해 성공률, 오차범위(MRE), 퍼터

헤드의 움직임(임팩트 각도, 속도, 템포, 크기)을 확인하여 평균과 표준편차를 산출하여 비교 분석하였다. 그 결과는 다음과 같다. 첫째, 퍼팅 성공률은 머신러닝을 적용한 숙련자 집단에서 효과적으로 나타났다. 오차범위에서는 머신러닝을 적용한 비숙련자와 숙련자 집단 모두에서 자기조절 집단보다 효과적으로 나타났다. 퍼터 헤드의 움직임에서는 임팩트 각도의 일관성을 살펴본 결과 머신러닝 비숙련자 집단에서 효과적으로 나타났으며, 자기조절 집단은 효과가 나타나지 않았다. 퍼팅 속도의 일관성에서는 자기조절 집단은 효과가 나타나지 않았으며 머신러닝 집단은 숙련자, 비숙련자 모두 향상된 결과가 나타났다. 템포의 일관성에서는 개인별 성공한 퍼팅을 기준으로 템포의 표준편차를 통해 확인한 결과 머신러닝 집단이 크게 향상되었다. 비숙련자의 경우 일관성이 약 20% 향상되었으며, 숙련자는 약 15% 향상되었다. 백스윙과 팔로스루의 스윙크기 일관성에서는 자기조절 집단은 통계적으로 유의하진 않았으나 향상된 경향성을 가져왔고 머신러닝 집단은 숙련자, 비숙련자 모두 일관성이 향상되었다.

종합하면 본 연구는 개인의 고유감각 중 내적템포(internal tempo) 요인을 머신러닝 프로그램을 활용하여 인지-수행 부하가 높은 거리X경사 퍼팅 수행 상황에 적용하였다. 퍼팅 과제의 특성상 개인 고유감각을 고려하여 일관성을 키우는 학습을 통해 학습효과를 확인하였다. 이를 통해 실제 현장에서 연구 결과를 적용하여 퍼팅 학습에 활용할 수 있을 것이며, 숙련도에 따른 결과를 통해 범주화를 하고자 하였다.

주요어 : 퍼팅, 고유감각, 머신러닝, 증강현실, 자기조절 피드백, 퍼팅 템포, 퍼팅 정확성, 퍼팅 숙련도

학번 : 2018-30597

목 차

I. 서 론 ····· 1

1. 연구의 필요성 ····· 1
2. 연구의 목적 ····· 8
3. 연구 가설 ····· 9
4. 용어의 정의 ····· 10

II. 이론적 배경 ····· 13

1. 운동학습의 이해 ····· 13
   1) 운동학습의 개념 ····· 13
   2) 운동학습의 이론 ····· 15
   3) 운동학습의 단계 ····· 16
   4) 운동학습과 파지 ····· 17
2. 피드백에 대한 이해 ····· 19
   1) 피드백의 개념 ····· 19
   2) 피드백의 기능 ····· 20
   3) 외재적 피드백의 이해 ····· 21
   4) 외재적 피드백의 활용 ····· 22
3. 골프퍼팅(golf putting) ····· 23
   1) 골프 퍼팅의 이해 ····· 23
   2) 퍼터 스트로크에 대한 이해 ····· 23

3) 개인 내적 템포 다양성과 퍼팅 템포 ····· 25

4. AR(augmented reality)과 머신러닝(machine learning) ····· 26
1) AR에 대한 이해 ····· 26
2) 머신러닝에 대한 이해 ····· 27
3) 머신러닝 선행연구 ····· 28

Ⅲ. 연구방법 ····· 30

1. 연구대상 ····· 30
2. 실험장비 및 측정방법 ····· 31
3. 실험절차 ····· 39
4. 실험설계 ····· 45
5. 자료분석 ····· 46
6. 통계분석 ····· 50

Ⅳ. 연구결과 ····· 51

1. 수행 정확성 ····· 51
1) 퍼팅 성공률 ····· 51
2) 평균 오차범위(MRE) ····· 54
3) 거리별 홀컵 성공률과 오차범위 ····· 58

2. 수행 수준 ····· 61
1) 퍼터 헤드 움직임 ····· 61

1-1) 임팩트 각도의 변화 ····· 61
1-2) 퍼팅 속도 일관성 ····· 64
2) 템포 일관성 ····· 68
3) 거리별 템포 일관성 ····· 71
4) 스윙 크기 일관성(백스윙) ····· 72
5) 스윙 크기 일관성(팔로스루) ····· 76

Ⅴ. 논의 ····· 80

1. 퍼팅 수행 정확성의 변화 비교 ····· 81
2. 퍼팅 수행 수준의 변화 비교 ····· 83
1) 임펙트 헤드 각도 일관성 ····· 83
2) 퍼팅 템포와 스윙 크기 일관성 ····· 84
3) 퍼팅 수행 수준 변화량 ····· 87
Ⅵ. 결 론 ····· 91
Ⅶ. 제 언 ····· 94

참고문헌 ····· 95

abstact ····· 104

표 목차

표 1. 연구참여자 정보 ····· 31
표 2. 모폴로지 연산 객체 인식 방식 ····· 32
표 3. 객체 인식과 추적 내용 ····· 34
표 4. 머신러닝 분석 내용 ····· 36
표 5. lightGBM 오차행렬 머신러닝 성능지표 ····· 38
표 6. 사전검사 내용 ····· 42
표 7. 자기조절 집단 학습 세부 내용 ····· 44
표 8. 세부 실험 절차 ····· 44
표 9. 실험 설계 ····· 45
표 10. 평균 퍼팅 성공률 ····· 51
표 11. 평균 퍼팅 성공률 혼합분산분석 결과 ····· 53
표 12. 평균 홀컵 오차범위 ····· 54
표 13. 평균 홀컵 오차 범위 혼합분산분석 결과 ····· 56
표 14. 임팩트 헤드 각도 변화 ····· 61
표 15. 임팩트 헤드 각도 변화 혼합분산분석 결과 ····· 63
표 16. 퍼팅 속도 일관성 변화 ····· 65
표 17. 퍼팅 속도 일관성 혼합분산분석 결과 ····· 66
표 18. 퍼팅 템포 오차 ····· 68
표 19. 퍼팅 템포 오차 혼합분산분석 결과 ····· 70
표 20. 퍼팅 백스윙 크기 오차범위 ····· 73
표 21. 백스윙 평균 오차범위 혼합분산분석 결과 ····· 74
표 22. 퍼팅 팔로스루 크기 오차 범위 ····· 76
표 29. 퍼팅 팔로스루 크기 오차범위 혼합분산분석 결과 ····· 78

그림 목차

그림 1. 퍼팅 템포 구분 ····· 25
그림 2. 머신러닝의 분류 ····· 28
그림 3. 카메라와 센서 ····· 31
그림 4. 골프공 객체 인식 및 추적 과정 ····· 33
그림 5. 퍼터 객체 인식 및 추적 과정 ····· 34
그림 6. 머신러닝 프로그램 구조 ····· 36
그림 7. 학습 데이터 습득 및 제공 구조 ····· 37
그림 8. 템포와 스윙 크기 예시 ····· 37
그림 9. 퍼팅 센서와 퍼터 결합 사진 ····· 39
그림 10. 실험 절차 ····· 40
그림 11. 실험 공간 크기와 경사도 ····· 41
그림 12. 거리와 방향에 따른 수행 예시 ····· 42
그림 13. 머신러닝 AR 시각 피드백 예시 ····· 43
그림 14. 비숙련자의 평균 퍼팅 성공률 변화 ····· 53
그림 15. 숙련자의 평균 퍼팅 성공률 변화 ····· 54
그림 16. 비숙련자의 평균 오차범위 변화 ····· 57
그림 17. 숙련자의 평균 오차범위 변화 ····· 57
그림 18. 거리에 따른 퍼팅 성공률 변화 ····· 59
그림 19. 거리에 따른 퍼팅 오차범위 변화 ····· 60
그림 20. 비숙련자의 퍼팅 임팩트 헤드 각도의 변화 ····· 63
그림 21. 숙련자의 퍼팅 임팩트 헤드 각도의 변화 ····· 64
그림 22. 비숙련자의 퍼팅 속도의 일관성 변화 ····· 67
그림 23. 숙련자의 퍼팅 속도의 일관성 변화 ····· 67
그림 24. 비숙련자의 템포 오차 변화 ····· 70

그림 25. 숙련자의 템포 오차 변화 ····· 71
그림 26. 거리별 템포 오차 변화 ····· 72
그림 27. 비숙련자의 백스윙 크기 오차 변화 ····· 75
그림 28. 숙련자의 백스윙 크기 오차 변화 ····· 75
그림 29. 비숙련자의 팔로스루 크기 오차 변화 ····· 78
그림 30. 숙련자의 팔로스루 크기 오차 변화 ····· 79
그림 31. 자기조절 집단 비숙련자의 퍼팅 수행 수준 변화 ····· 88
그림 32. 머신러닝 집단 비숙련자의 퍼팅 수행 수준 변화 ····· 88
그림 33. 자기조절 집단 숙련자의 퍼팅 수행 수준 변화 ····· 89
그림 34. 머신러닝 집단 숙련자의 퍼팅 수행 수준 변화 ····· 89

수식 목차

수식 1. 퍼팅 성공률 ····· 46
수식 2. 홀컵 오차 범위(MAE) ····· 46
수식 3. 퍼팅 템포(tempo) ····· 47
수식 4. 머신러닝 성능 평가(RSR) ····· 48
수식 5. 머신러닝 성능 평가(NSE) ····· 49
수식 6. 머신러닝 성능 평가(MAE) ····· 49

I. 서론

1. 연구의 필요성

스포츠를 즐기기 위해서는 각 종목에 맞는 다양한 운동 기술을 익혀야 한다. 모든 스포츠 종목은 각각의 특성에 맞는 운동 기술이 필요하며 기술 수준에 따라 수행력이 달라진다. 운동 기술 수행 능력은 반복적인 연습과 경험이 필요하다. 반복적인 연습과 경험을 통해 새로운 동작이나 동작의 수행 수준을 비교적 영구적으로 변화시키는 일련의 과정을 운동학습이라 말한다(Schmidt & Lee, 1999). 결국, 운동학습 연구에서 중점을 두고 있는 것은 되도록 짧은 시간에 원하는 운동 기술을 습득하는 것이라고 할 수 있다. 얼마나 효율적이고 체계적으로 연습하느냐에 따라서 운동학습의 성과는 다를 수 있다. 이때 연습의 조건과 학습 환경의 조직을 고려해야 한다(김선진, 2000; Newell, 1991).

체계적이고 효율적인 운동학습을 구성하기 위해서는 단순히 형식적인 체계를 넘어서 Zanone과 Kelso(1997)가 강조한 운동 기술의 학습이 이루어지기 전에 개개인이 가지고 있는 협응 경향에 대한 지식의 중요성 역시 고려되어야 한다. 이들은 운동 기술의 학습은 연속적 과정이며, 개인 차이가 존재한다는 측면에서 학습자의 협응 경향에 대한 사전 규명이 필요하다고 언급하였다. 따라서 효율적이며 체계적인 운동학습 프로그램과 더불어 같은 학습 시간이나 과정에서도 개인차가 존재하기 때문에 환경과 유기체, 그리고 과제 기술의 올바른 조합이 필요하다고 볼 수 있다.

효율적인 운동학습 효과를 얻기 위해서는 과제의 특성에 알맞은 피드백

(feedback)이 제공되어야 한다. 피드백은 운동 기술 학습과 수행에 필수적인 요소로 목표 상태와 수행 간의 차이에 대한 운동수행의 결과나 평가 정보를 제공한다. 즉, 학습자가 인식하지 못하는 유용한 정보 제공이나 잘못 수행하고 있는 오류를 탐지하고 올바른 협응 정보를 제공해준다(Black well & Newell, 1996). 특히, 시각 피드백(visual feedback), 청각 피드백(auditory feedback)의 적절한 제공은 효율적인 운동학습에 필수적이다. 시각 피드백은 인간의 감각 중 가장 많이 의존하는 시각을 활용하는 피드백으로 다양한 운동학습 과제에서 긍정적인 결과가 나타났다(Anderson & Magill, 2001; Wolf et al., 2013; Rhoads et al.,2014). 청각 피드백은 시각 다음으로 많이 의존하는 감각 정보로 신체 고유감각에서 리듬감을 담당하며, 이를 활용하여 긍정적인 리듬이나 템포 학습 효과가 나타났다(Bourdin et al., 2019; Libkuman et al., 2002). 청각 피드백을 통한 자극은 리듬이나 템포를 필요하는 운동 동작에 효과적이다(Repp, 2004). 또한, 생성된 움직임의 정보를 전달하는 피드백을 활용하여 농구 기술 수행 수준에서 효과적인 결과가 나타났으며(Salehi & Orak, 2020) 이를 통해 수행된 동작에 대한 오류를 수정하기 위한 정보를 제공하는 피드백은 운동학습에서 필수적이다. 이때 피드백의 정보 제공 시기나 정보량은 상황에 따라서 다르게 주어져야 한다. 즉, 기술 난이도나 수행자의 수준에 따라 피드백 정보 제공 빈도수나 정보 전달량 조절에 따른 연구(Winstein & Schmidt , 1990; Rice & Hernandez, 2006; Ishikura, 2008; Wulf et al., 2010; Sidaway et al., 2012)를 통해 피드백의 제공 빈도수는 학습이 진행될수록 줄이고 수행자의 기술 수준이 낮을수록 정보 제공을 최소화하며, 기술 난이도에 따라 정보 제공을 달리해야 한다는 결과가 나타났다. Ishikura(2008)에 따르면 시각 피드백을 활용한 결과 지식 피드백 제공 시기 조절에 따라서 골프 퍼팅 학습과제 수행 시 다른 결과가 나타났다. 시도마다 피드백 정보를 제공한 집단과 3회마다 피드백 정보를 제공한 집단과의 학습 효과에서 3회마다 피드

백을 준 집단에서 더 나은 학습효과가 나타난다고 했다. 피드백 제공 횟수 조절과 함께 자기조절(self-controlled)을 적용했을 때 학습 수준이 더 효율적으로 높아지는 연구가 나타나고 있다(Chiviacowsky & Wulf, 2002; Hebert & Coker, 2021). 이에 위를 종합하면 효율적인 운동학습을 위해서는 시각과 청각 피드백의 활용과 적절한 피드백 정보 제공을 자기조절을 활용했을 때 긍정적인 결과가 나타날 수 있음을 알 수 있다.

골프 종목은 회전 운동의 특성과 다양한 감각을 활용해야 하는 높은 수준의 협응 동작이 요구되는 종목으로(Knight, 2004) 체계적이고 효율적인 운동학습 적용이 필요하다. 골프는 크게 티샷, 아이언 샷, 퍼팅으로 구분할 수 있는데 Pelz(2000)에 따르면 그중 퍼팅은 전체 스윙의 약 43%를 차지하는 만큼 가장 중요한 스윙 형태라고 했다. 이에, 골프 실력 향상을 위해서는 정확한 퍼팅 수행 능력이 절대적으로 요구된다. 성공적인 퍼팅을 수행하기 위해서는 퍼터 헤드의 세 가지 요인을 고려해야 한다(Heuler, 1995; Karlsen et al., 2008). 첫째, 임팩트 때 퍼터 헤드의 면(face)이다. 퍼터 헤드의 열리고 닫힘에 따라서 공의 출발 방향에 결정적인 영향을 미칠 수 있다. 둘째, 퍼팅 템포 조절 능력이다. 퍼팅 템포는 거리 조절에 필수적인 요인으로 퍼팅 동작의 특성상 신체 관절의 움직임을 최소화하는 만큼 템포에 따라서 성공적인 퍼팅이 될 수 있다. 셋째, 라이를 정확히 읽어내고 그에 따른 퍼팅 라인을 올바르게 설정해야 한다. 골프 퍼팅 과제는 다양한 경사에서 수행해야 하므로 경사에 따른 높낮이를 확인해야 경사에 따른 효과적인 퍼팅을 수행할 수 있다. 즉, 정확한 경사 확인을 통한 공이 굴러갈 퍼팅 라인을 설정하고 그에 따른 올바른 스윙 템포를 통해 임팩트 때 0°도에 가까운 헤드 조절 능력이 필요하다고 볼 수 있다. 또한, Cochran & Stobbs(1968)에 따르면 성공적인 퍼팅 수행을 위해서는 퍼터 각도 뿐만 아니라 퍼터의 속도와 스윙 크기도 중요하다고 하였다.

이들 요인을 고려하여 성공적인 퍼팅을 위해서는 시각감각의 활용이 중

요하다(Cordo & Flanders, 1990; 하준호 등, 2009). 이들 연구에 따르면 시각 감각은 시각을 통해 들어온 정보 수집과 수집된 근거를 바탕으로 목표 행동 생성을 위한 운동 명령 계획과 수행을 하게 한다. 퍼팅 과제에서 정보 수집은 홀컵과 공과의 거리, 그린의 상태와 경사 파악이다. 정보 수집을 통해 분석 결과를 통해 수행자는 운동 명령 계획과 수행에 따라 퍼팅 출발 방향 설정과 스윙 크기를 결정한다.

Pelz(2000)에 따르면 퍼팅 과제에서 거리에 따라 성공률의 차이가 크게 나타나며, 프로 선수들의 경우 1m에서 90% 성공률, 3.5m에서 75% 그리고 3.5m 이상에서 20%대의 낮은 성공률이 나타났다. 이를 통해 퍼팅 과제에서 한 번에 넣는 성공률을 높이는 것도 중요하지만, 홀컵에 근접하게 붙이는 능력 역시 중요한 요인이기에 키울 필요가 있다(Oh, 2008). 비숙련자는 거리 조절 능력을 키우는 것이 중요하며, 숙련도가 높아질수록 거리 조절 능력이 좋아지는(Tanaka & Iwami, 2018)만큼 홀컵에 가깝게 붙이는 능력은 퍼팅 숙련도를 평가하는 중요한 요인이다. 퍼팅 거리 조절 능력은 스윙 크기와 그에 따른 템포인데 퍼팅 과제는 개인마다 신체 구조적 특징과 습성 그리고 다른 템포를 가지고 있으며, 스윙 패턴도 다양하여 특정한 숙련자를 모방하는 것보다 자신만의 퍼팅 패턴과 템포를 효율적인 반복 훈련을 통해 일관성을 향상시키고 체득시켜 나가는 것이 필요하다(Davids & Hristovski, 2006; Davids et al., 2008).

퍼팅의 성공 여부는 거리 조절과 함께 경사에 따른 방향 요인 역시 중요하다. 특히, 그린의 경사는 공의 진행 궤적을 결정하는데 직접적으로 영향을 미치는 대표적 요인이다. 따라서 그린 위에서 퍼팅을 수행할 때 스트로크의 기술적인 측면 이외에도 홀컵에 따라 기울어진 그린의 미세한 경사에 따라 공의 궤적을 보내는 것은 매우 중요하다. 이렇듯 퍼팅 과제는 그린의 환경적 상태를 고려하여 홀컵까지의 공의 운동 방향이나 거리에 대한 복합적인 인지 능력이 필요하다(Mackenzie & Springs, 2005). 이에 거리와 방

향을 모두 고려해야 하는 퍼팅 과제의 복합적인 특성상 효율적인 학습방법이 요구된다.

퍼팅에 대한 이전 선행연구들을 살펴보면 역학적인 연구(Delay et al., 1997; Craig et al, 2000; Karlsen et al., 2008), 주의 초점 전략에 따른 연구(Wulf, 2010; Rouwen, 2016; Wang et al., 2021), 주의 초점 전략을 사용하여 역학 요인을 분석한 연구(Munzert et al, 2014), 피드백 제공 형태에 따른 연구(Kyle, 2020) 그리고 시각 탐색전략에 따른 연구(하준호, 2009; Lee et al., 2008; Vickers, 2009), 청각 피드백을 활용한 연구(Libkuman et al., 2002) 등으로 다양하게 연구됐다. 이들 연구를 살펴보면 공통으로 숙련자의 데이터를 기준으로 비숙련자와 차이점을 비교-분석하거나 비숙련자에게 주의 초점 학습 전략, 시각이나 청각 피드백을 활용한 연구 등 퍼팅 스트로크의 차이점을 줄이거나 홀컵과의 평균 오차범위를 줄이는데 학습효과를 검증하고 있다. 선행연구를 통해 퍼팅 수행에서 중요 요인 분석이 나타났으나 아직 개개인의 특성에 따라 큰 차이를 보이며 정형화된 신체의 역학적 원리나 기술적 분석에 따른 적용은 다소 어려울 수 있다는 연구에서 지적하는 개인차까지는 고려하지 못하고 있음을 알 수 있다(현승현, 2012; Vickers, 1992). 위를 종합하여 볼 때, Schmidt(1988)가 주장한 연습구조의 다양성(variability of practice structure)에 따라 기술 수준을 높이기 위해서 퍼팅 수행과제에서 거리, 방향 그리고 개인차를 모두 고려한 학습방법의 필요성이 있다.

최근 4차 산업혁명 시대에서 사회, 경제, 기술 등 다양한 분야에서 급격한 변화가 예고되며, 스포츠도 다양한 변화가 나타나고 있다. ICT(information and communication technologies) 기술 기반의 발전으로 정해진 시간이나 장소에서 텍스트 기반으로 소통하는 전통적인 교육의 형태에서, VR(virtual reality), AR(augmented reality) 등을 활용한 실감형, 체험형 학습의 형태로 변화가 나타나고 있다(남기정 & 이종훈, 2017;

Mekni & Lemieux, 2014; Turner et al., 2016). 골프의 경우 스크린 골프나 AR 기반의 골프 프로그램이 등장하였으며, 스윙 궤도 및 패턴에 대한 다양한 분석까지 다양하게 나타나고 있다. 이를 통해 개인의 과거 경험과 지속적인 반복적인 수행에 따른 일차원적인 훈련이 아닌 신기술을 활용한 보다 체계적이며 부상 방지와 단시간에 효율적인 운동학습이 가능해지고 있다(Phu et al., 2019; Lacko, 2020).

AR 기술은 가상 세계와 현실 세계를 혼합하여 제공함으로써, 사용자의 몰입감과 현실감을 향상하는 기술이다(Azuma, 1997). 즉, 눈으로 보이는 실제 환경에 눈으로 보지 못하는 그래픽을 겹쳐서 보여주는 개념이다. VR은 실제와 컴퓨터를 활용하여 가상공간을 만들어 무엇이든 만들거나 경험할 수 있지만 현실 세계의 감각과 차이가 크다는 단점이 있다. 반면, AR은 현실 세계에 없는 유용한 가상의 정보를 다양한 방법으로 제공할 수 있으며, 현실의 공간과 연결되어 쉽게 이해되고 가치가 증대되는 정보를 실감나게 제공할 수 있다(Milgram & Kishino, 1994; Soltani & Morice, 2020). 이를 통해 실제적 환경에서 다양한 기술 수행에 필요한 학습이 가능한 특징이 있다. 이러한 기술을 활용하여 다양한 스포츠 종목에서 활용되고 있다. 가장 대중적으로 알려진 스크린 골프를 시작으로 최근에는 스크린야구, 스크린 테니스, 사격, 양궁 등이 있다.

스포츠 상황에서 AR 기술을 접목하여 다양한 종목의 기술 학습이나 분석 등 폭넓게 적용되며 활용되고 있다. 종목을 살펴보면 다트(Sanchez & Davis, 2018), 크리켓(Hopwood et al., 2011), 테니스(Itoh et al., 2016; Kelly & Connor, 2012;), 클라이밍(Kosmalla et al., 2017), 유도(Witkoski et al., 2016) 그리고 골프(Ikeda et al., 2019) 등 다양한 종목에서 학습 효과가 나타나고 있다. 특히, Sanchez & Davis(2018) 연구에서는 다트 던지기 과제에서 AR을 활용한 학습연구에서 협응 수준의 향상과 더불어 실제 상황에서도 긍정적인 전이가 나타난 것을 확인할 수 있었다. 아울러 다양

한 상황과 경험을 활용하여 기존의 학습법보다 짧은 시간에 효율적인 학습 도구로 활용될 수 있음을 확인하였다.

인공지능 기술 중 하나인 머신러닝(machine learning)은 데이터를 분석하고 해당 데이터를 통해 학습한 후 정보를 바탕으로 결정을 내리기 위해 학습한 내용을 적용하는 알고리즘이다(Mitchell & Jordan, 2015). 대량의 데이터를 알고리즘을 활용하여 학습시킨 뒤 자동으로 여러 데이터의 공통된 특성을 찾아내 특성에 따라 해결법을 제시해준다. 이 기술은 여러 데이터 가운데 공통된 특성을 빠르게 찾아내어 특성에 따라 적합한 해결책을 제시해 줄 수 있다. 즉, 사람이 판단하는 데 오래 걸릴 작업을 빠르게 처리할 수 있으며 기존에 예측하지 못했던 패턴을 찾을 때도 활용할 수 있다. 학습자 개인의 패턴을 분석하여 문제점을 파악하고 다양한 데이터 제시에 따른 개인 맞춤형 운동학습 프로그램을 제시할 수 있게 되어 이를 활용한 운동학습 연구의 필요성이 제시되고 있다(Horvat & Job, 2020; Wilkens, 2021). 이를 통해 사람이나 물체의 움직임 데이터를 바탕으로 증강 피드백을 통해 운동학습의 효율성이 향상하거나 새로운 학습방법을 제시할 수 있다.

머신러닝을 활용한 연구로는 고속으로 댄스를 활용한 새로운 운동학습 접근법 제시(Rivière et al., 2019), 이동하는 야구선수의 위치를 검출하는 연구(Kim.J & T. Choe,2019), IMU를 활용한 골프 스윙 동작 분석과 머신러닝을 활용하여 분석한 연구(Kim, M. S. & S. Y. Park, 2020), 축구 선수의 부상을 방지를 위한 모델링 제공(Teunissen et al., 2020), 그리고 딥러닝을 이용한 3차원 골프 스윙 분석(고경리 & 반성범, 2019) 등 스포츠에 머신러닝을 적용한 다양한 연구들이 진행되고 있다.

오늘날 골프 종목에 관한 다양한 연구와 그에 따른 분석과 학습 프로그램이 나타나고 학습효과가 검증된 가운데, 다수의 퍼팅 과제 연구에서 개인차를 고려하지 않은 반복적이거나 실제 퍼팅 수행 상황과 동떨어진 평지

나 실험실 상황에서 적용되는 비교적 간단한 도구나 형태에 의존하고 있다. 그러나 최근 스포츠 과학과 스포츠 공학의 발전으로 인해 과거 단순한 동작의 분석이나 기록, 오차 측정이 아닌 다양한 상황과 개인별 분석을 토대로 체계적인 훈련 적용의 필요성이 나타나고 있다. 기존 선행 연구의 한계점을 보완하고 머신러닝을 적용한 AR 퍼팅 학습연구를 통해 학습 효과 검증과 더불어 숙련도에 따른 변화를 확인하여 적용 대상에 대한 범주화를 연구할 필요성이 있다.

2. 연구의 목적

본 연구의 목적은 머신러닝을 적용한 AR 피드백 퍼팅 학습 훈련 집단과 자기조절 피드백(self-controlled feedback)을 활용한 일반 퍼팅 훈련 집단과의 비교를 통해 효율적인 퍼팅 학습 프로그램 방법을 제시하는 데 있다. 또한, 숙련도에 따라 비숙련자와 숙련자의 퍼팅 학습 프로그램의 집단 간 효과를 확인하고 기초자료 확보를 통해 적용 대상을 범주화하는데 목표가 있다.

3. 연구 가설

본 연구의 목적을 달성하기 위해 다음과 같은 연구 가설을 설정하였다.

1) 퍼팅 학습과제에서 숙련도에 따라 머신러닝 AR 퍼팅 학습 프로그램을 적용한 집단과 그렇지 않은 집단과의 수행 정확성의 차이가 나타날 것이다.

① 머신러닝 AR 퍼팅 학습 프로그램을 적용한 집단의 성공률이 그렇지 않은 집단보다 높을 것이다.
② 머신러닝 AR 퍼팅 학습 프로그램을 적용한 집단의 오차범위가 그렇지 않은 집단보다 적을 것이다.

2) 퍼팅 학습과제에서 숙련도에 따라 머신러닝 AR 퍼팅 학습 프로그램을 적용한 집단과 그렇지 않은 집단과의 수행 수준의 차이가 나타날 것이다.

① 머신러닝 AR 퍼팅 학습 프로그램을 적용한 집단의 퍼터 헤드의 움직임(임팩트 각도, 속도) 일관성이 그렇지 않은 집단보다 더 나은 형태를 보일 것이다.
② 머신러닝 AR 퍼팅 학습 프로그램을 적용한 집단이 그렇지 않은 집단보다 스윙 템포의 일관성이 높을 것이다.
③ 머신러닝 AR 퍼팅 학습 프로그램을 적용한 집단이 그렇지 않은 집단 보다 스윙 크기 일관성이 더 높을 것이다.

4. 용어의 정의

본 연구에서 주로 사용된 용어에 대한 개념을 정의하면 다음과 같다.

1) 머신러닝(machine learning)

머신러닝은 데이터를 분석하고 해당 데이터를 통해 학습한 후 정보를 바탕으로 결정을 내리기 위해 학습한 내용을 적용하는 알고리즘이다(Mitchell & Jordan, 2015). 퍼팅 데이터는 성공률, 오차범위, 템포 그리고 스윙 크기 분석을 통해 검출 및 학습에 적용하였다.

2) 증강현실(AR)

증강현실은 실시간으로 가상 세계와 현실 세계를 혼합하여 제공함으로써, 사용자의 몰입감과 현실감을 향상할 수 있는 기술을 말한다(Azuma, 1997). 퍼팅 과제 수행시 프로젝션을 통해 증강현실 효과를 적용하였다.

3) 시각 피드백(visual feedback)

시각 피드백은 실내 퍼팅 과제에서 학습 중 빔 프로젝션 레이저를 활용하여 스윙 크기, 퍼팅 속도 그리고 퍼팅 라이에 대한 시각 피드백 정보를 제공하는 것으로 정의하였다.

4) 청각 피드백(auditory feedback)

청각 피드백은 메트로놈을 활용하여 개인별 퍼팅 BPM 템포 정보를 제공해주는 것으로 설정하였다.

5) 운동학습(motor learning)

운동학습은 효율적이고 체계적으로 연습하느냐에 따라서 운동학습의 성과는 다를 수 있다. 이때 연습의 조건과 학습 환경의 조직을 고려해야 한다(김선진, 2009; Newell, 1991). 머신러닝을 적용한 AR 퍼팅 학습 프로그램 집단과 그렇지 않은 집단에게 3회의 학습 훈련을 실시하였다.

6) 파지(retention) 검사

비교적 영구적인 수행 수준의 변화가 목적인 파지는 학습 훈련을 통해 향상된 운동 기술을 유지할 수 있는 것을 말하며, 운동 기능의 파지 정도는 학습 여부를 판단하는 자료가 된다(김선진, 2009). 파지 효과를 확인하기 위해 48시간 뒤 파지검사를 수행하였다(Shafizadeh et al., 2011; Chiviacowsky et al., 2019).

7) 전이(transfer) 효과

전이 효과는 학습을 통해 얻은 수행력이 다른 과제로 어떻게 영향을 미치는 것인가에 초점을 두는 것이다. 전이 효과를 확인하기 위해 학습 과정에는 AR 시각 피드백과 청각 피드백을 받은 후 사후 및 파지 검사에는 시각 및 청각 피드백이 없을 때 수행 결과로 정의하여 살펴보았다.

8) 골프 퍼팅 숙련도

본 연구에서 골프 퍼팅 숙련도는 선행연구를 토대로 핸디캡에 따라 퍼팅 수행 수준을 구분하였다(Paradisis & Rees, 2000; Richardson et al., 2012). 골프 핸디캡은 골프 퍼팅 숙련도를 정의하는 데 있어서 티샷과 아

이언샷 등이 포함되어 명확하지 않을 수 있어 일관성을 위해 골프 구력 요인을 추가하였다. 비숙련자의 경우 핸디캡 30 이상으로 골프 구력은 24개월 이하로 설정하였으며, 숙련자의 경우 핸디캡 10 이하로 골프 구력은 48개월 이상으로 설정하였다.

6) 골프 퍼팅 수행 능력

골프 퍼팅 수행 능력은 퍼팅 기술 수행 능력과 퍼팅 현장 수행 능력을 포함하고 있다. 퍼팅 운동학습 요인에서 수행 정확성을 보는 요인으로는 홀컵 성공률과 오차범위로 설정하였으며, 수행 수준으로 퍼터 헤드의 움직임과 그에 따른 일관성을 요인으로 확인하였다(Keogh et al, 2012).

7) 맥락간섭(contextual interference)

여러 가지 과제를 수행해야 학습되는 연습상황에서 과제 간 혹은 과제 내에서의 간섭이 수행에서는 저조한 결과를 나타내나 파지에서는 효과적인 결과를 가져오는 일종의 기능적 간섭(functional interference)을 말한다. 본 연구에서는 실험 집단과 통제 집단에게 거리와 방향 조절에 따른 맥락간섭 효과를 적용하였다.

8) 자기조절연습(self-regulated practice)

학습의 주체자가 되려고 하는 학습자의 의도적인 노력으로 학습 과정에 자기 주도적으로 참여하려는 의지를 내포하며 궁극적으로 학습 목표의 달성을 위해 자신의 고유한 학습 환경을 창출하는 행동을 말한다. 선행연구를 바탕으로 비숙련자/숙련자 수준을 고려한 맥락간섭 훈련과 피드백 정보 제공량을 조절하여 제공하였다.

8) 퍼팅 라이(putting lie)

본 연구에서는 퍼팅 과제 수행 시 홀컵을 기준으로 3°의 경사를 설정하였다. 홀컵을 기준으로 거리에 따라 평지성 똑바로(straight), 평지성 슬라이스(flat slice), 평지성 훅(flat hook), 내리막 똑바로(down straight), 내리막 슬라이스(down slice), 내리막 훅(down hook), 오르막 슬라이스(up slice), 그리고 오르막 훅(up hook) 라이로 설정하였다.

II. 이론적 배경

본 연구는 퍼팅 과제 시 머신러닝을 적용한 AR 퍼팅 프로그램의 운동학습 효과를 확인하고 숙련도에 따른 변화를 규명하는 데 목적이 있다. 이와 관련하여 운동학습, 피드백, 퍼팅, AI와 머신러닝 그리고 AR에 대하여 살펴볼 것이다.

1. 운동학습의 이해

1) 운동학습의 개념

인간의 학습 능력은 운동 기술적, 지적, 인지적 또는 언어적인 인간의 수행 능력을 통해서 이루어지며, 주어진 환경에 맞게 적용하고, 수많은 경험들을 통해 정보를 획득하는데 중요한 요인으로 간주한다. 이러한 학습을 운동과 관련지어 볼 때, 운동학습은 숙련된 수행에 필요한 역량을 비교적 영속적으로 변화시키는 연습과 경험의 과정으로 정의될 수 있다(Schmidt, 1988).

운동학습은 이론적 관점에 따라 학자들의 주장이 다양하게 정의되고 있다. 따라서 그 개념을 한마디로 정의하기에는 어려움이 있다. 김선진(2000)은 운동학습이란 운동과제를 반복적으로 수행함에 따라 나타나는 일반적인 능력의 변화라 정의하고 있으며, Schmidt(1988)는 연습이나 경험을 통한 비교적 항구적인 행동의 변화라고 하였고, Magill(2001)은 연습이나 경험의 결과로 발생하는 수행의 비교적 영속적인 향상으로부터 추론되어야 하는 기능 수행 능력의 변화라 정의하였다. 이처럼 운동학습은 이론적인 관점에 따라 학자들마다 다양하게 정의되고 있다. 그러나 Magill(1993, 1998)과 Schmidt(1991)는 다양한 운동학습의 정의에 공통으로 적용할 수 있는 세 가지 특성이 있음을 제시하였다.

첫째, 운동학습은 숙련된 운동수행을 위한 개인 능력의 비교적 영구적인 변화를 유도하는 일련의 내적 과정이다. 이러한 특징은 신경학적인 기전에서의 변화와 연관이 있으며, 이러한 중추신경계의 변화는 신경 통로의 구조적인 변화와 신경 자체의 기능적 변화를 포함한다.

둘째, 운동학습은 육안으로 관찰할 수 없다. 학습이 일어나는 현상을 외부적으로 관찰할 수 없으므로 실질적인 학습에 대한 평가는 학습자의 수행을 반복적으로 관찰함으로써 평가를 할 수밖에 없다. 따라서 타당성 있는 학습의 평가 방법을 계획하고 제시하는 것이 중요하다.

셋째, 운동학습은 연습의 결과로서 나타난다. 운동학습에 영향을 미칠 수 있는 행동의 변화는 연습이나 경험과 관련된 변화들이며(정원종, 2005), 성숙이나 동기 또는 훈련에 의한 변화는 포함하지 않는다. 왜냐하면 성숙이나 훈련에 의한 수행력의 변화는 일시적으로 발생하는 경우가 대부분이다. 즉, 훈련으로 기량이 일시적으로 향상된 근육은 훈련을 그만두게 되면 훈련하기 이전의 상태로 되돌아가게 된다. 그러므로 이러한 일시적인 수행의 향상은 학습이라 정의 할 수 없다.

학습의 정의를 종합해 보면 학습자가 주변 환경에 참여하는 과정뿐만 아니라 주변 환경에 적응하면서 학습자의 행동이 변화되는 일종의 과정이라고 할 수 있으며, 그 내용은 훈련이나 경험을 거쳐야 하고, 행동의 변화가 이루어져야 하며, 이는 비교적 항구적인 변화라고 정의 할 수 있다(Schmidt & Walter, 1984; Schmidt, 1988).

2) 운동학습 이론

운동학습에 관한 이론은 크게 세 가지로 볼 수 있다. 첫째, 정보처리 관점으로 운동학습을 주어진 운동과제를 수행하는 데에 필요한 운동 프로그램을 적절히 형성하여 기억 체계를 도식화하고, 운동 기술 수행을 향상시키기 위하여 보다 효율적인 도식으로 재구성해가는 과정이라고 보는 것이

다(Schmidt, 2005). 그는 운동학습을 운동과제를 수행하는 데에 필요한 개인의 능력을 결정하는 내적인 과정의 변화라고 정의하였다.

둘째, 다이나믹 시스템 이론으로 운동학습을 주어진 운동과제를 수행하기 위한 가장 효율적인 협응 구조를 형성하고, 환경과 주어진 과제의 특성적 변화에 대하여 적절하게 대처할 수 있는 적응성을 향상하는 과정이라 정의한다(Newell, 1991).

셋째, 생태학적 관점으로, 연습이나 경험을 통하여 지각-운동 활동 영역(perceptual-motor workspace) 내에서 과제와 환경적 요구에 일치하도록 지각과 동작 간의 협응이 향상하는 과정이라고 보고 있다. 다양한 관점의 운동학습 이론을 정리해보면, 운동학습은 개인적 특성을 바탕으로 연습이나 경험을 통하여 과제와 환경적 변화에 부합하는 가장 효율적인 협응 동작을 형성시켜 나가는 과정이라고 정의할 수 있다(김선진, 2000).

3) 운동학습의 단계

학습이 진행됨에 따라서 나타나는 행동적 변화를 단계별로 구분하는 것은 학습자에게 운동 기술을 학습할 때 필요한 정보를 효과적으로 제공할 수 있는 근거를 제시하여 준다(김선진, 2000).

정보처리 관점에서 인간의 인지적인 처리 과정에 중점을 두었던 Fitts와 Posner(1967)는 운동 기술 학습 과정을 인지 단계(cognitive stage), 연합단계(associative stage), 그리고 자동화 단계(autonomous stage)로 구분하였다. 인지 단계는 대부분 비숙련자에게 해당하며 새로운 기술을 습득하기 위해 과제에 대한 이해와 원리 등에 대해서 인식하는 단계이다. 이러한 인지 단계는 학습자들이 받아들여야 하는 정보의 양이 많으며, 오류를 수정할 수 있는 능력을 갖추지 못했기 때문에 운동수행에 있어 일관성이 부족한 경향을 보인다.

인지 단계를 거치게 되면 연합단계에 들어서게 된다. 이 단계에서는 반

복적인 연습을 통하여 운동 기술에 대한 주의의 요구량이 줄어들게 되며, 학습자 스스로 오류를 발견하여 수정할 수 있게 된다. 연합단계의 특징은 동작의 정확성과 일관성이 관찰되고 협응력 또한 개선된다. 마지막으로 자동화 단계에서는 동작이 거의 자동으로 이루어지기 때문에 움직임 자체에 대한 의식적인 주의가 크게 요구되지 않는다. 상대방의 움직임이나 환경, 물체 등과 같은 이차과제에 주의를 전환할 수 있게 되며, 운동수행의 일관성이 높아진다.

4) 운동학습과 파지

김선진(2000)에 따르면 파지란 연습으로 향상된 운동 기술의 수행력을 오랫동안 유지할 수 있는 능력을 말한다. 따라서 운동 기술의 파지 정도를 검사함으로써 그 운동 기술의 학습 여부를 판단할 수 있다. Bernstein(1967)은 운동 기술을 수행하는 데 필수적 요소(essential elements)의 획득이라는 측면에서 운동 기술의 파지를 설명하였다. 즉, 운동 기술의 습득 과정에서 과제(task)를 구성하고 있는 필수적 기술의 요소에 대한 학습이 이루어지면 시간이 지난 뒤에도 다시 운동과제를 수행할 수 있지만, 그렇지 않으면 시간이 지남에 따라 수행력이 저하되거나 그릇된 움직임으로 나타날 수 있다고 주장하였다. 그리고 운동 기술의 기억을 복잡한 자유도의 문제와 관련하여 과제와 환경 그리고 유기체 간의 상호 관련 속에서 운동 기술의 학습에 필수적인 요소를 파악하고 학습하는 과정이라고 보았다. Newell(1994)은 운동 기술의 파지를 기억 체계의 상실로 인한 망각의 측면보다는 과제, 환경과 유기체가 갖는 요소에 대한 적응과정이라는 측면에서 설명하고 있다. 이는 시간이 지남에 따라서 나타나는 이러한 제한요소의 변화는 곧 운동 기술의 학습에 직접적인 영향을 주게 된다.

운동학습에서 파지는 학습하고자 하는 운동과제의 특성, 유기체(학습

자)(학습자) 그리고 운동 기술의 학습이 이루어지는 환경의 상호작용으로 운동 기술은 학습된다. 먼저 운동 기술의 피지와 학습에 가장 큰 영향을 미치는 운동과제의 특성에 대해 말하자면, 운동과제를 구성하고 있는 요소들이 복잡하거나 운동 기술을 생성하는데 고려해야 할 정보가 많으면 쉽게 학습하지 못할 수도 있다. 하지만 이러한 과제는 반복 학습이 이루어지면 오랫동안 파지 되는 특성이 있다. 그러나 운동과제가 단순하거나 고려해야 할 요소가 적으면 학습은 쉽게 이루어지지만, 너무 단순한 과제의 특성상 파지를 못하게 된다. 운동과제의 특성을 이해하고 파지를 위해서는 환경의 요구와 과제의 특성에 부합하는 신체 분절 간의 상대적 움직임에 대한 학습 또한 같이 이루어져야 한다. 그리고 Newell(1996)은 학습과제에서 상대적 움직임 간의 협응의 형태가 안정적이면 오랫동안 파지가 이루어진다고 하였고, 이 상대적 움직임의 협응은 각기 다른 근육군의 협응 구조의 형성으로 볼 수 있으며 불안정한 협응 구조를 갖는 운동 기술은 시간의 경과에 따라 상실된다고 주장하였다.

운동 기술의 학습 과정에서 환경의 변화는 중요한 변인으로 작용한다. 지각과 동작 시스템 간의 밀접한 상호관련성을 강조하는 Newell(1996)은 환경에서 제시된 정보의 처리 과정을 직접 지각 시스템을 통해 설명하면서 환경의 요소가 운동 기술의 학습과 밀접한 관련이 있다고 주장하였다. 특히 코치나 교사가 제공할 수 있는 학습 환경은 학습자의 운동 기술 학습과정에 많은 영향을 줄 수 있다. 따라서 코치나 교사는 효율적인 운동 기술의 학습과 파지를 위한 적절한 학습 계획 등으로 학습자의 환경을 바꾸어 줄 필요가 있다.

앞에서 설명한 바와 같이 코치나 교사가 과제의 특성에 맞는 올바른 교수 전략을 구사하고 똑같은 양의 연습 기회를 부여해도 몇몇 학생들은 다른 학생에 비해 운동 기술을 빨리 습득하고 일정한 시간 뒤에도 높은 파지 정도를 보이는 경우를 종종 관찰할 수 있다. 이러한 현상은 학습자 개개인

의 신체적 특성, 인지적 수준 등에 따른 협응 능력의 차이에서 오는 것이다. Zanone과 Kelso(1997)는 운동 기술의 학습이 이루어지기 전에 개개인이 가진 협응 경향에 대한 지식의 중요성을 강조하면서, 운동 기술의 학습은 연속적 과정이며, 개인 차이가 존재한다는 측면에서 학습자의 협응 경향에 대한 사전 규명이 필요하다고 언급하였다. 이와 같은 내용들로 보았을 때 파지 검사를 시행하는 전형적인 방법은 학습자에게 이미 연습하였던 기능을 일정 기간이 지난 후에 다시 수행하도록 하는 것이다. 연습의 종료 시점과 평가 시기 사이의 실질적인 시간 간격은 독자적으로 정해진다. 하지만 연습 중에 학습된 것을 확인하려면, 그러한 시간 간격은 수행변수의 영향이 소멸할 수 있을 정도의 시간이어야 한다(Magill, 2001).

2. 피드백에 대한 이론

1) 피드백의 개념

Young & Schmidt(1992)에 의하면 피드백은 교정, 적절성, 또는 학습자의 행동 정확성에 관련하여 학습자에게 제공되는 정보다. 이러한 정보는 세 가지의 구성요소를 가지고 있는데 첫째, 피드백은 학습자가 어떠한 행동의 유형을 나타난 후에 일어나며, 둘째, 피드백은 학습자에 의해 관찰될 수 있으며, 셋째, 피드백은 학습자 행동의 효과를 기술한다고 보고 있다. 즉 이것을 요약하면 피드백은 학습자의 성취에 관한 모든 정보라고 할 수 있다. 김선진(2000)은 운동학습에서 피드백이란 목표 상태와 수행 간의 차이에 대한 정보를 되돌려서 수행자에게 동작 그 자체, 또는 운동수행의 결과나 평가에 대한 정보를 제공하는 것이라고 말한다. 즉, 피드백은 운동 기술을 수행하는 과정에서 나타나는 오류를 탐지하고 수행하고자 하는 운동 행동의 체계를 형성하는 데 필요한 정보를 제공할 뿐만 아니라 운동 동작

이 끝난 후에 동작의 정확성 여부를 판단하기 위한 정보를 제공한다.

따라서 피드백은 운동 기술의 궁극적 목표를 달성하기 위한 효과적인 교수 및 학습의 수단으로서 매우 중요한 의미를 지닌다. 이러한 피드백은 학습자가 수행한 움직임의 과정이나 결과로부터 얻어지는 모든 감각 정보를 포함하기 때문에, 반응 산출 피드백 (response-produced feedback)이라고도 한다. 위에서 살펴본 바와 같이 여러 학자가 내린 피드백의 정의를 종합하여 본 연구에서는 피드백을 "학습자의 성공적인 운동 기술의 수행을 위한 움직임의 과정이나 결과부터 얻어지는 질적, 양적인 모든 교정적 정보"라고 정의를 내린다.

2) 피드백의 기능

Magill(1989)은 피드백의 주된 기능은 첫째, 학습자에게 에러를 수정하도록 도와주는 정보의 기능과 둘째, 수행반응을 강화하며 셋째, 계속 시도하도록 동기를 불어넣는 기능이 있다고 한다. 그리고, Winstein & Schmidt(1990)는 학습자가 정확한 반응을 하도록 계속해서 안내하는 것은 수행과 학습을 증진하는데 아주 중요하다고 했다.

피드백에 관한 기능은 크게 5가지로 나누어질 수 있다. 첫째, 피드백의 강화 기능, 교정적 기능, 정보기능, 동기유발 기능, 마지막으로 안내 기능 등으로 나누고 있다. 따라서 피드백은 학습자의 움직임의 과정이나 결과에 대하여 학습의 적정상태와 동작의 오류에 대한 정보를 제공해줄 뿐만 아니라 동작의 오류를 교정해주며, 학습에 대한 동기를 부여하는 강화인의 역할을 하여 학습의 효과를 증진하는 중요한 기능을 한다고 볼 수 있다.

3) 외재적 피드백

고무적 피드백 (enhanced feedback) 또는 보강적 피드백 (augmented

feedback)이라고도 불리는 외재적 피드백은 학습자가 수행하면서 스스로 감지하여 받아들일 수 있는 자연스러운 정보가 아닌, 교사나 코치, 또는 영상매체 등을 통해 외부로부터 제공되는 정보를 의미한다. 따라서 외재적 피드백의 일반적인 특징은 이용할 수 있는 피드백을 보충 또는 보강해준다. 이러한 외재적 피드백은 세 가지의 중요한 특징을 가진다. 첫째, 외재적 피드백은 언어·비 언어의 형태로 제공된다. 둘째, 움직임이 진행되는 동안이나 완료된 후에 제공된다. 마지막으로, 외재적 피드백은 움직임의 결과나 움직임 유형 자체에 대한 정보를 제공한다 (김선진, 2000).

외재적 피드백이란 개인이나 집단에 제공되는 외적으로 표현되는 피드백의 한 형태로 부가적인 정보나 개인이 쉽게 감지할 수 없는 정보를 제공함으로써 감각 피드백을 보강한다. 외재적 피드백은 결과를 발생시킨 동작의 특성이나 수행 결과와 관련된 오차와 같은 개인 수행의 다른 특성에 근거를 두고, 한 개인의 동작에 대한 일반적인 정보에서부터 매우 구체적인 정보까지 넓은 범위의 정보를 다양한 방법으로 제시한다 (Magill, 1993).

외재적 피드백의 한 형태는 결과지식(knowledge of results)이다. 결과지식이란 동작 수행 결과에 대해 외적으로 제공되는 정보를 말한다. 외재적 피드백의 두 번째 형태는 수행지식 (knowledge of performance)이다. 수행지식은 동작 결과를 유발하는 동작의 특성(movement characteristics)에 관한 정보이다. 수행지식은 가장 일반적으로 언어적 방법으로 제시되나, 자신의 수행을 비디오테이프를 통해 보여주거나 그래프를 통해 제시될 수도 있다. 외재적 피드백의 세 번째 형태는 보강 피드백 (augmented feedback)이다. 보강 피드백은 외적인 장치를 이용하여 감각 피드백을 향상시키고자 한다. 전형적으로 결과지식과 수행지식은 반응을 한 후에, 즉 종말적으로 제공된다. 반면 외재적 감각피드백은 동작진행 중에 동시적으로 제공된다. 그러나 수행지식을 동시적으로 제공할 수도 있으며, 외재적 감각피드백을 종말적으로 제공하는 것도 가능하다. 다양한 형태 속에서 외

재적 피드백은 한 개인의 동작에 대해 매우 일반적인 정보에서부터 매우 구체적인 정보까지 그 범위가 넓으며 제시 방법 또한 다양하다.

4) 외재적 피드백의 활용

운동학습 초기 단계에서 학습자들은 자신의 동작에 대한 정확한 정보를 얻기가 쉽지 않다. 이때 학습자들은 운동기술 향상에 도움이 되는 정보를 주로 지도자에게 의존하게 된다. 그러나, 지도자가 전달하는 정보가 학습자들에게 항상 도움이 되는 것은 아니다. 만약 전달하는 피드백 정보가 학습자에게 너무 어려워 학습자의 주의를 환기하지 못한다면 효율적인 운동기술의 학습이 이루어지지 않을 것이다. 따라서, 학습자의 현재 기술 수준과 정보를 처리할 수 있는 능력을 고려하여 학습자가 이해할 수 있는 정보를 제공해야 한다. 운동기술 수준이 향상되면서 학습자들은 운동수행 중 받게 되는 피드백 정보의 양뿐만 아니라 질도 높아지게 된다. 또한 자신이 수행한 동작과 목표 동작 간의 차이를 파악하고 수정할 수 있는 오류탐지 능력도 향상된다. 그러나 학습자의 기술 수준이 아무리 높아도 운동수행 중에 오류를 스스로 탐지할 수 없는 경우가 많으므로 보강 피드백 정보를 다양하게 제공하는 것이 지속적인 운동학습을 위해 필요하다.

지금까지 운동기술 학습 과정에서 효율적인 운동학습 상황을 유도하기 위한 피드백 정보 활용에 관한 연구들은 정보 제공, 동기유발, 강화 기능 등에 초점을 맞추면서 다양한 형태의 피드백 제공 시기와 빈도수에 관심을 가졌다. 이러한 피드백과 운동학습에 관한 연구들은 운동기술 학습 과정에서 개인에 따라 다양한 능력의 차이가 있으므로 운동기술 유형과 학습자의 특성에 따라서 다양한 형태의 정보를 제공해야 할 필요성이 있다고 언급하고 있다 (김선진, 2000).

3. 골프 퍼팅

1) 골프 퍼팅의 이해

골프 퍼팅 동작은 어드레스(Address), 백스윙(Back Swing), 다운스윙(Downswing), 임팩트(Impact), 팔로우 스루(Follow Through)의 동작들이 운동학적 변인들에 의해 자연스럽게 이루어져야 한다. 퍼팅은 섬세하고 개인차가 많은 만큼 올바른 퍼팅 방법을 찾아 지속적인 훈련으로 퍼팅 성공률을 높여야 한다. 충분한 퍼팅 훈련을 하지 않으면 빈번히 발생하는 미스샷(Miss Shot)에 의한 심리적인 압박으로 경기력에 영향을 미칠 수 있다. 퍼팅도 스윙 훈련과 마찬가지로 끊임없는 자기 연습과 시행착오를 겪어야만 자신만의 퍼팅을 완성할 수 있다(장재훈 & 박동수, 2013).

2) 퍼팅 스트로크에 대한 이해

퍼팅 스트로크에서 가장 중요한 요인은 퍼터의 움직임이다. Heuler(1995)는 좋은 퍼팅의 세 가지 조건은 임팩트 공과 클럽 헤드의 방향이 일치해야 하며, 임팩트 클럽 헤드와 볼이 수직이며, 그리고 임팩트 정타(sweet spot)에 맞아야 한다고 제시하고 있다. Mann(1989)은 골프 퍼팅 스트로크에서 공의 방향에 영향을 주는 중요한 두 가지 요인으로 클럽헤드의 스윙 궤도와 임팩트 클럽페이스의 위치라고 했다. 즉, 올바른 퍼팅 스트로크를 만들기 위해서는 퍼터의 움직임 방향이 퍼팅 선(line of putt)와 일치하는지, 임팩트 클럽 페이스의 수직 벡터(normal vector) 역시 퍼팅 선과 일치해야 한다. Palmer(1993)는 공의 방향에 영향을 주는 것은 약 90%가 임팩트 공과 클럽 페이스의 방향이며 나머지 10%는 스윙 궤도라는 연구결과가 나타났다. 약 2.5m에서 퍼터의 좌우 2도의 오차는 퍼팅의 성공 유무를 결정하는 만큼 임팩트 퍼터 페이스면의 각도는 매우 중요하다(Pelz,

2002). 퍼팅은 퍼터 앞면이 퍼터 헤드의 진행 방향과 수직을 이루고 있지 않을 때 생기며 크게 두 가지 형태로 나누어 볼 수가 있다(임형진,2007).

첫째는 퍼터 헤드의 진행 방향은 원하는 볼의 진행 방향과 일치하지만, 퍼터 앞면이 열리거나(slice putting) 닫혀(hook putting) 퍼터 헤드의 진행 방향과 수직이 되어 있지 않은 경우이다. 이런 경우 골프공은 퍼터 면에 거의 수직 방향으로 출발하여 원래 퍼터 헤드의 진행 방향에서 빗나가게 된다. 둘째, 퍼터면은 원하는 볼의 진행 방향과 수직을 이루나 퍼터 헤드의 진행 방향이 원하는 볼의 진행 방향과 일치하지 않을 경우이다. 이런 경우 골프공은 퍼터 면에 거의 수직 방향으로 원하는 볼의 진행 방향과 같은 방향으로 퍼터 면을 출발하게 된다. 위의 두 가지 경우 골프공은 처음부터 퍼터 면에 거의 수직 방향으로 퍼터 면을 출발하게 되나 골프공과 퍼터 페이스 사이의 마찰력에 의하여 사이드스핀이 생기며 이후에 생기는 탑 스핀과 합성하여 골프공의 방향은 서서히 한쪽으로 변하게 되고 직진 성분의 힘이 현저히 감소하는 홀 근처에서는 경사가 있는 것처럼 심하게 한쪽으로 꺾이는 현상을 보여주게 된다.

퍼팅 과제에서 헤드의 움직임 뿐만 아니라 수행자의 템포 역시 중요하다. 퍼팅 템포는 어드레스에서 백스윙 탑까지 시간과 백스윙 탑에서 공까지 임팩트 까지의 시간을 비율화한다. 이 때 숙련도가 높을수록 템포의 일관성이 높으며 그만큼 템포의 오차가 적다는 것을 의미한다(Delay et al., 1997).

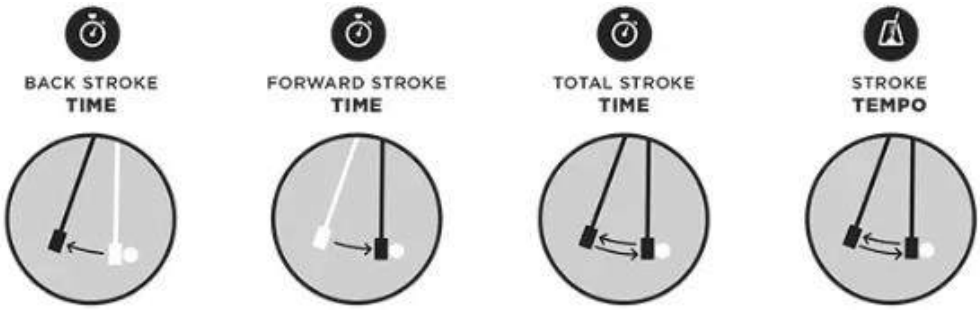

그림 1. 퍼팅 템포 구분 (Delay et al., 1997)

3) 개인 내적 템포 다양성과 퍼팅 템포

모든 사람은 각각의 고유감각의 주기성과 내적 템포를 가지고 있는데 이는 수행 상황에 따라 다양하게 나타난다(Thomas & Chess, 1977). 이러한 고유감각에서 내적 템포는 운동신경 요인으로 인간의 내적 템포에 영향을 주며 이는 사람의 걸음걸이의 리듬, 심장 박동과 상당히 일치하고 있음에 주목하고 있으나 이에 대한 구체적인 증거는 아직 제시되지 않고 있다(Fraisse, 1987). 사람마다 고유 내적 템포를 가진다는 주장은 선행연구로 지지되고 있으며(Drake et al., 2000; Moelants, 2002), 사람의 행동양식에 나타나는 내적 템포는 개인의 움직임의 빈도 등에 의해서도 산출된다. 이러한 내적 템포는 개인마다 다양하게 나타난다(Boltz, 1994).

퍼팅 수행상황에서 다양하게 수행되는 거리, 방향 설정에 따라 과제의 특성이 변해도 운동수행의 결과가 지속적으로 높은 수행 수준을 유지하기 위해서는 템포의 일관성이 중요한 요인이다(Karlsen et al., 2008). 이때 인지된 수행을 정밀하고 일관되게 수행하기 위해서는 신체 내-외 구조별로 운동순서 학습(motor sequence learning)에 따라서 일관된 동작이 나타나야 하는데 템포와 타이밍 일관성 훈련이 요구된다(Ivry, 1996; Meegan et al., 2000). 템포와 타이밍 훈련의 목적은 시간적 오차를 파악하여 동작의 오류를 수정, 신경기전의 메커니즘에 기초를 두고 일관성을 추구하는데 초

점을 두고 메트로놈의 박자 훈련은 개인의 매 동작마다 얼마나 일치성을 가지는지 개인이 확인하기 어려운 문제를 해결하는데 도움을 줄 수 있다(Ericsson, 1996, Lewis 2004). 메트로놈을 통해 지속적인 박자에 맞춘 일련의 점진적인 연습들을 통해 내적 템포의 일관성 동기화를 촉진함으로써 타이밍(Timing), 리듬(Rhythmicity), 집중력(Attention), 운동 계획(Motor Planning), 순차적 처리(Sequencing) 의 동작을 개선할 수 있다(Jantzen, et al.,2008).

4. AR(증강현실)과 머신러닝(machine learning)

1) AR에 대한 이해

마이론 크루거(Myron Kruger)에 의해 1970년대 비디오 플레이스(video place)에 빗댄 '인공현실(artificial reality)'이 탄생했다. 증강현실은 사용자가 보고 있는 현실 세계에 가상 세계를 혼합하여 제시하고 사용자가, 직접 가상 세계를 조작하면서, 컴퓨터와 상호작용할 수 있도록 하는 컴퓨터 인터페이스 기술을 말한다(Billinghurst et al.,2005). 또 증강현실은 현실과 가상이 합쳐진 것이며, 실제 시간과 상호작용하는 것으로 보았다. 따라서 AR은 현실 세계와 가상 세계를 실시간으로 사용자에게 제공하여 사용자보다 향상된 몰입과 현실감을 제공하는 기술로 정의 하였다(Azuma, 1997). AR의 연구는 쉐리단(Sheridan)에 의해 확장됐으며 그는 AR이 컴퓨터 그래픽과 다양한 디스플레이, 자료 입력 테크놀로지들이 하나로 통합돼 일방적인 시각 중심의 구현방식이 아닌 다양한 감각을 사용해 몰입할 수 있도록 유도하는 존재로 파악했다. AR의 특성은 준비된 시나리오나 만들어진 상황 판단 프로그램으로 인해 새로운 자극을 다시 전달하는 피드백 체계를 갖고 있다. AR(증강현실)이란 실제 공간과 가상의 공간을 혼합한 현재의 정보를

증강한 상태를 말한다. 즉, AR은 실제 세계와 가상 세계를 혼합한 기술이라고 정의할 수 있다. 이를 통해 사용자는 더 향상된 몰입의 감정을 느낄 수 있다(Azuma, 1997). AR은 VR 분야에서 파생된 기술이며, 가상으로 생성된 객체를 현실 환경에 접목해 사용자에게 현실감을 느끼게 해준다. 이에 사용자는 다양한 콘텐츠보다 실감이 나는 경험을 할 수 있다. AR과 VR 모두 가상성에 바탕을 두었지만, VR은 컴퓨터가 만들어낸 기술이며, AR은 실제 환경에 가상의 정보를 더 해 실감을 향상하는 기술이다(계보경 & 김영수, 2008). 또한 VR은 오롯이 가상의 세계에서 일어나는 경험을 사용자에게 전달하는 아바타식 기술이 목표라면, AR은 사용자에게 현실감을 부여해 컴퓨터와 상호작용하며 실재감을 되새김질하는 것이 목표라는 차이점을 지니고 있다.

2) 머신러닝에 대한 이해

머신러닝은 예측 분석(Predictive Analytics)이나 통계적 러닝(Statistical Learning)으로도 불리며 통계학과 컴퓨터 과학이 얽힌 인공지능 기술이다. 머신러닝은 대량의 데이터를 알고리즘에 학습시켜주면 자동으로 수많은 데이터의 공통된 특성을 빠르게 찾아내어 데이터의 특성에 따라 높은 성능으로 문제를 분류해낸다(Nasteski 2017). 이들은 운동 기술의 학습은 연속적 과정이며, 개인 차이가 존재한다는 측면에서 학습자의 협응 경향에 대한 사전 규명이 필요하다고 언급하였다. 머신러닝은 지도학습(Supervised Learning)과 비지도학습(Unsupervised Learning)으로 나누어진다<그림2>. 지도학습은 입력 데이터로부터 기대한 출력이 나오도록 알고리즘에 입력과 기대되는 출력을 제공하고 주어진 입력에서 원하는 출력을 만드는 방법을 알고리즘이 스스로 찾게 하는 방식이다. 이렇게 학습된 알고리즘은 새로운 입력 데이터에 적절한 출력을 자동으로 만들어낸다. 지도학습 알고리즘은

입력으로 사용될 데이터셋 구축이 종종 수작업으로 진행된다는 단점을 갖고 있지만 분석과 성능 측정이 간편하다는 장점이 있다.

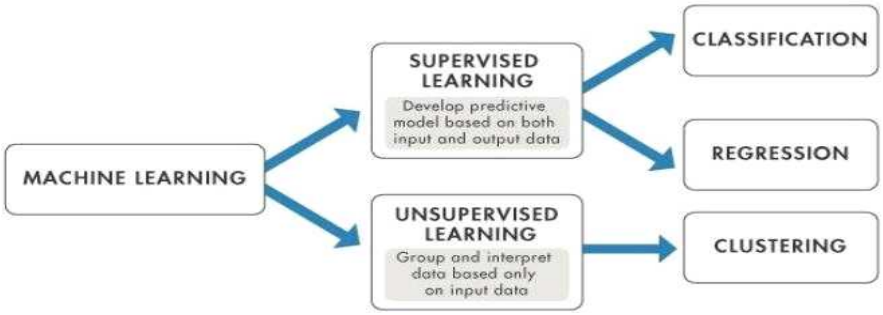

그림 2. 머신러닝 분류 (Nasteski, 2017)

3) 머신러닝 선행연구

스포츠 분야에서도 최근 머신러닝을 활용한 연구들이 진행되고 있다. Zhang & Li(2021)은 머신러닝 알고리즘을 적용하여 걷기나 뛰기에 적합한 운동화 소재를 찾기 위해 다양한 운동화 소재의 신발을 신고 걷기나 뛰기 과제를 수행하여 신체의 일부 각도를 분석하여 효율적인 소재를 찾아 냈다. 또한, 축구 선수들의 부상을 예방하기 위해서 훈련 중 총 움직인 거리, 가속 그리고 감속한 시간과 거리를 통해 개인별 적정 움직임을 제안하는 연구를 통해 선수들의 신체적 부담을 덜어주는 연구가 있었다(Rossi et al., 2018). 그 외 고속으로 이동하는 야구선수의 위치를 검출하려는 방법으로 딥러닝 기반의 CNN 기술을 사용하여 검출하는 시스템을 제안하고 실험 결과를 통해 야구 경기 영상에서 선수의 위치를 효과적으로 검출할 수 있음을 검증한 연구(Kim. J & T. Choe, 2019)가 있었다. 골프 스윙 동작을 분석하기 위해 IMU 센서와 머신러닝을 활용하여 분석한 연구(Kim, M.& Park, S, 2020) 등 스포츠에 머신러닝을 적용하여 분석이나 학습 도구로 활용할 수 있는 다양한 연구가 시도되고 있다. 이처럼 인공지능을 기반으로 한 머신러닝 기술을 활용하면 Zanone과 Kelso(1997)가 강조한 개개인

이 가지고 있는 협응 경향을 고려한 효율적인 운동학습 프로그램을 적용하거나 제시할 수 있을 것이다.

III. 연구방법

본 연구에서는 머신러닝을 적용한 AR 퍼팅 학습 프로그램을 골프 숙련자와 비숙련자에 따라 학습효과 확인과 그에 따른 범주화를 하고자 한다. 연구 대상, 실험 도구 및 측정 방법, 실험 절차, 실험설계, 자료 산출 방법, 그리고 통계 분석을 구체적으로 서술하면 다음과 같다.

1. 연구 대상

본 연구에서는 만 20세에서 40세 사이의 성인 총 40명이 참여하였다. 연구 대상자 모집 및 실험 진행은 서울대학교 생명윤리위원회 허가를 받아 윤리적 기준을 준수하며 진행하였다(IRB No.2211_004-014). 그중 사전검사를 통해 극단적인 수행력 차이를 나타내는 참여자는 실험에서 제외하였으며, 중도 포기자의 제외하고 그룹별 9명 총 36명의 자료를 수집하였다. 연구대상자는 핸디캡에 따른 아마추어 골퍼 집단으로 스마트스코어(Smartscore) 어플리케이션에서 평균 핸디캡과 골프 구력을 기준으로 대상자를 구성하였다. 본 실험에서 설정한 연구참여자의 수는 G Power(ver. 3.1.9.4)를 사용하여 산출하였을 때 필요한 최소 표본 크기가 총 32명으로 산출되어 표본 크기를 만족하였다. 비숙련자는 골프 경력 2년 이내의 핸디캡 30 이상으로 선정하였고, 숙련자는 골프 경력 3년 이상의 핸디캡 10 이하로 선정하였다(Paradisis & Rees, 2000; Richardson et al., 2012).

AR 퍼팅 학습 프로그램을 적용 인원은 총 18명이며 집단별 비숙련자(9명), 숙련자(9명)이며, 자기조절 훈련은 비숙련자(9명), 숙련자(9명)로 구성하였으며 실험 전, 모든 연구참여자로부터 참여 동의서를 받았다<표 1>.

표 1. 연구참여자 정보

집 단			인원(명)	연령(년)	구력(개월)	핸디캡(개)
실험 집단	머신러닝 AR 훈련	비숙련자	9	35.3±5.2	16.5±2.4	34.2±3.3
		숙련자	9	36.7±3.4	56.3±6.6	7.8±1.4
통제 집단	자기조절 훈련	비숙련자	9	34.8±4.2	17.2±3.7	33.7±3.2
		숙련자	9	36.5±4.4	57.4±5.9	8.1±1.3

2. 실험 장비 및 측정 방법

1) 카메라와 센서 구성

본 연구에서는 퍼팅 과제 수행시 정보 취득을 위한 영상 장비는 카메라(FA0615A)와 센서(acA2040-90uc, Basler, Germany)를 사용하였다<그림 3>. 카메라와 센서가 결합 된 형태로, 해상도는 2040 x 2046 px, 프레임은 초당 50fps로 설정하였다. 카메라 센서는 4 x 4m 공간 규격의 정중앙에서 2.5m 높이에 설치한 뒤 왜곡될 수 있는 위치는 소프트웨어 보정을 통해서 공과 퍼터의 움직임 오차를 제거하였다.

그림 3. 카메라와 센서

2) 객체 인식(recognition)과 추적(tracking)

객체 인식 전 데이터 마이닝 과정이 필요하다. 데이터 마이닝은 영상 정보가 들어오면 정보 내에서 객체를 분별할 수 있는 양상, 성질, 그리고 특성을 추출하는 것을 말한다. 이에 특정 형태를 보인 특징점을 정할 때 서로 다른 집단을 구분할 수 있는 성질을 찾아야 한다. 이에 객체 인식 전 색상 데이터 추출을 위한 비전 센서 RGB 데이터 HSV 변환해야 한다. HSV는 빛의 세 가지 속성인 Hue(색조), Saturation(채도), Value(명도)의 성분 조합으로 색을 표현하는 방식으로 사람이 색을 인지할 때와 가장 유사한 방법이기 때문에, 실제로 촬영된 이미지나 영상 속에서 원하는 색상을 추출하기에 적합한 방식이다. 비전 센서 기반으로 골프공 추적, 인식 기술과 프로젝터를 이용한 프로젝션 맵핑 기술 등으로 구분하였다. 골프공 객체 인식(Object recognition) 및 좌표 추출은 HSV 이미지에서 골프공의 색상 범위를 지정하여 Mask-Image(흑백)를 생성하고 이미지프로세싱 라이브러리 OpenCV를 활용한 모폴로지(Morphology)기법으로 열림(opening), 닫힘(closing), 그레이디언트(gradient), 탑햇(tophat) 그리고 블랙햇(blackhat) 방식을 활용하였다<표 2>. 이를 통해 노이즈 제거 및 뚜렷한 형태의 골프공 객체 형태의 이미지로 변환하였다<그림 4>.

표 2. 모폴로지 연산 객체 인식

열림	open = dilate[erode(src)]
닫힘	close = erode[dilate(src)]
그레이디언트	gradient = dilate(src) - erode(src)
탑햇	tophat = src - open(src)
블랙햇	blackhat = close(src) - src

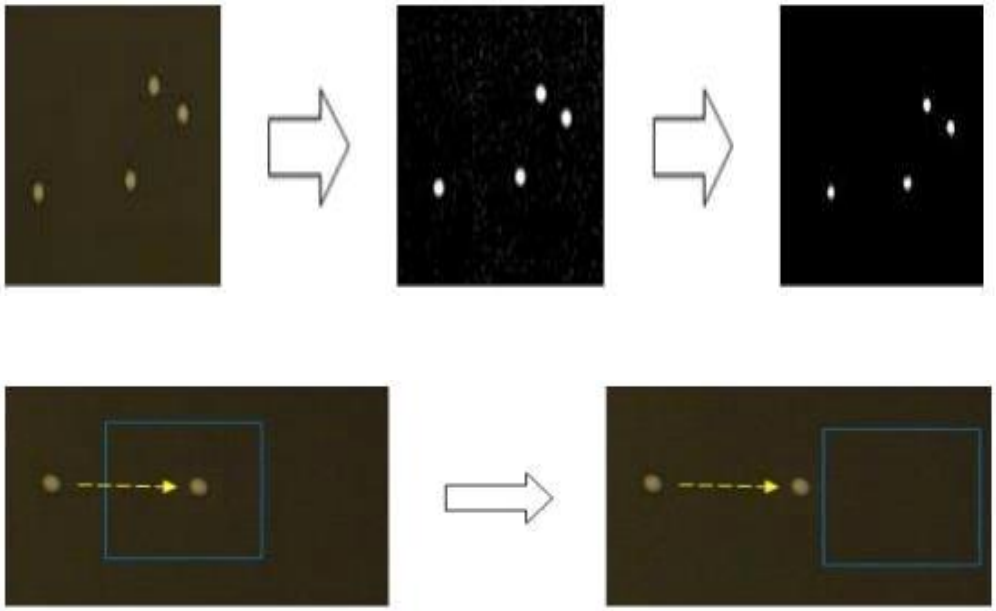

그림 4. 골프공 객체 인식 및 추적

객체 추적은 이전 위치와 현재위치를 분석하여 진행 방향과 이동 크기를 예측하여 추적영역을 지정함으로써 더 정확한 추적을 가능하게 하였다. 공과 퍼터의 실시간 움직임을 초당 50프레임으로 촬영하여 위치를 좌표(x,y)화 하여 dealtaTime을 기록한다. 그 뒤 시작 위치로부터 움직인 거리를 프레임 별로 deltaTime을 속도 공식(속도=거리/시간)으로 계산하여 속도를 측정한다. 이를 시뮬레이션 상에서 동일 조건으로 속도를 측정하여 비교하여 표시한다<그림 4>.

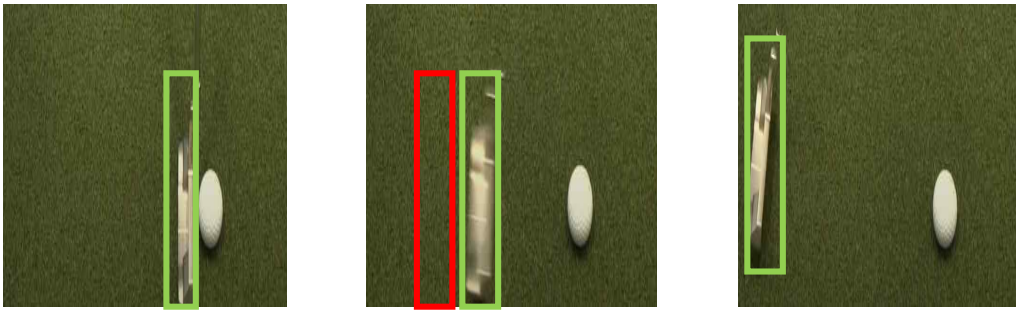

그림 5. 퍼터 객체 인식 및 추적 과정

퍼터 움직임의 경우 지정하는 특정 위치에 공과 퍼터를 놓으면 준비 자세로 인식하며 퍼터의 움직임이 시작되면 초당 50프레임의 사진 속 좌표 값에 따라 1회 걸리면 시간과 임팩트(공이 움직이기 시작하는 시간), 그리고 팔로스루까지 시간을 측정하여 템포를 계산하고, 프레임에 따른 백스윙과 팔로스루 크기를 측정한다. 측정에 대한 구체적인 내용은 <표 3>과 같다.

표 3. 객체 인식과 추적 내용

순서	퍼터	공
어드레스	위치 (x,y) 좌표 기준값 측정	위치 (x,y) 좌표 값
백스윙	위치 (x,y) 좌표, 시간 측정	
백스윙 탑	좌표값 변화에 따른 백스윙 크기와 시간 측정	
임팩트	팔로스루 기준 시간 측정	
팔로스루	좌표값 최종 값에 따른 팔로스루 크기와 시간 측정	

4) 머신러닝 프로그램 시스템

본 연구에서 머신러닝 프로그램은 파이썬(python 버전 3.10.2)를 활용하여 센서를 통해 객체 인식과 추적을 통해 데이터를 획득한 뒤 정확성과 정밀성을 올리는 방법으로 구상하였다. 본 연구는 기준이 명확한 수행과제이므로 지도학습(supervised learning) 방법을 선택했으며, 데이터 세트가 뚜렷할 때 구현이 쉬운 편이면서 정확도가 높은 GBDT(gradient boosting decision tree)를 사용하였다(Freidmand & Jerome, 2001). 지도학습에서 기준으로 사용한 데이터는 성공한 퍼팅의 퍼팅 데이터를 선택하였다. 이때 GBDT의 최적화와 성능 개선이 이루어져 효과적인 lightGBM을 활용하였으며 이는 퍼팅 연구에서 다른 머신러닝 프로그램보다 정확도가 높은 것으로 나타났다(김연호 외, 2022). 특히, XGBoost와 비교하여 학습 소요 시간이 적으며, 메모리 사용량이 적은 장점이 있다. 전체 구조는 퍼팅 수행 시 객체 추적에 따른 데이터들이 수집되고 이를 전처리 작업 후 훈련-시험용 데이터 반복을 통해 필터링을 거친 후 리프 중심 트리 분할 방식을 통해 트리의 균형을 맞추지 않고 최대 손실 값을 가지는 리프 노드를 지속적 분할을 통해 예측 오류 손실 최소화 작업을 수행하였다.

퍼팅 수행에 따른 정보는 성공률(%), 오차 범위(cm), 스윙 템포(bpm) 그리고 스윙 크기(cm)로 수집하였다<표 4>. 연구참여자들이 사전검사에서 수집된 전체 데이터 중 일관된 패턴을 찾아내는 탐색적 분석을 시행하여 분석 기준에 맞는 데이터 전처리를 진행한 후 정확성을 확인한 뒤 모델링을 실시하여 구축한 데이터 세트를 모델에 학습시켰다. 구축된 데이터는 모델 학습을 위한 훈련용 데이터(train data)와 모델 예측 성능검증을 위한 시험용 데이터(test data)로 나누었으며 그 비율은 머신러닝 분야 데이터 세트 분할에 자주 사용되는 7:3 비율로 채택하였다. 주요 변인 적용 및 분석을 통해 거리와 방향에 따른 개인별 성공 퍼팅 정보를 AR을 활용하여

학습 프로그램으로 적용하였으며<그림 6>, 변인 적용 및 분석은 <그림 7>과 같다.

표 4. 머신러닝 분석 내용

분석 항목	내 용
성공률(%)	거리 x 경사(8가지)의 수행상황별 성공률(%) 분석
평균 오차범위(cm)	거리 x 경사(8가지)의 수행상황별 홀컵 평균 오차범위 분석
템 포(bpm)	수행상황별 개인별 템포 분석
스윙 크기(cm)	수행상황별 백스윙 / 팔로스루 크기 분석

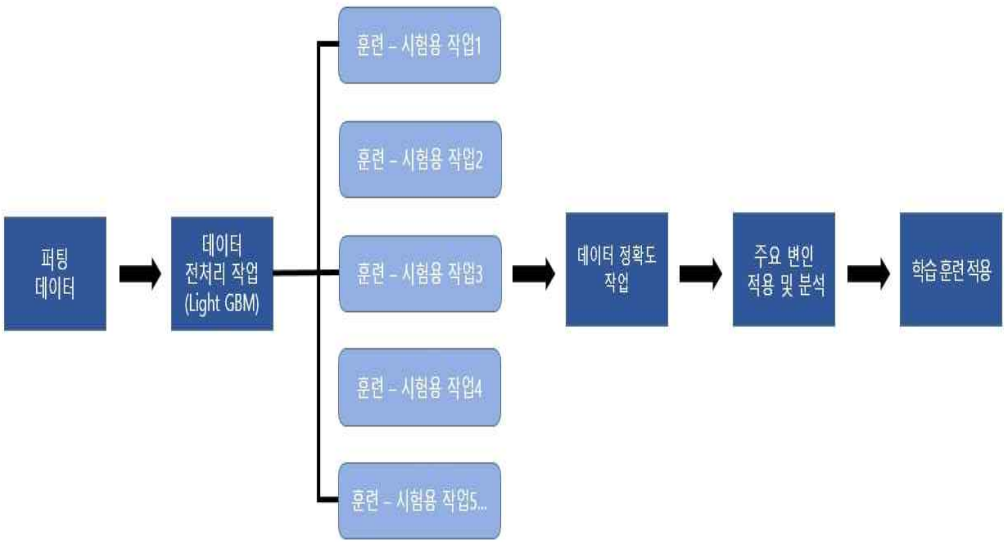

그림 6. 머신러닝 프로그램 구조

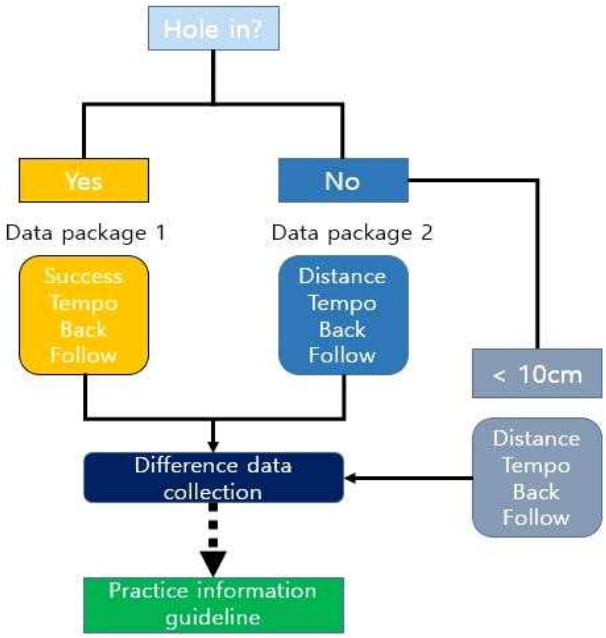

그림 7. 학습 데이터 습득 및 제공 구조

본 연구에서 시각 피드백 제공은 천장에서 제공되는 빔 프로젝터를 통해 스윙 크기(백스윙, 팔로스루) 크기를 제공해주며 이때 퍼터 위치와 공을 놓는 위치는 센서를 통한 정보를 얻기 위해 제시했다<그림 8>.

그림 8. 템포와 스윙 크기 예시

본 연구에서 피험자들을 대상으로 수집된 데이터는 36명의 72회 퍼팅 데이터는 오류가 나거나 화면이 깨진 데이터를 제외하고 학습 데이터는 6745개, 평가데이터 1788개의 평가데이터를 구성했다. 이를 활용하여 오차행렬을 통한 본 머신러닝 데이터의 모델 성능 수준은 <표 5>와 같다. 모든 수치가 0.90을 넘는 만큼 모델의 신뢰도 및 성능이 높은 수준으로 나타났다.

표 5. lightGBM 오차행렬 머신러닝 성능지표

정확도	정밀도	재현율	F1	AUC
0.9175	0.9122	0.9026	0.9046	0.9140

5) 퍼터 헤드 정보 측정 장비

본 연구에서 퍼팅 수행 시 머신러닝 프로그램 정보와 정확도 비교 및 퍼터 헤드 정보를 측정하기 위해 CAPTO사에서 개발한 퍼팅 센서(Captogolf, Italy)를 사용할 것이다<그림 9>. CAPTO 센서는 3축 자이로 센서가 탑재되어 퍼터의 움직임에 관련된 정보와 퍼팅 과제 수행 시 템포를 알려주는 센서이다. 본 연구에서는 초당 200 프레임의 데이터 분석이 가능하면 MSE(mean square error)는 0.1도의 평균제곱오차 범위로 데이터 신뢰도가 높은 센서이다. 이를 통해 어드레스 - 테이크백 - 백스윙 - 다운스윙 - 임팩트 - 팔로우 스루까지 스트로크 전체 과정을 세밀하게 분석할 수 있다. 퍼터의 움직임의 정보로는 헤드면(face), 샤프트(shaft), 라이(lie), 궤적(arc)을 알려주며 백스윙과 다운스윙의 템포를 측정하여 알려준다. 해당 센서는 이탈리아 및 유럽 PGA에서 공인 센서로 활용되고 있다.

그림 9. 퍼터 센서와 결합 사진

3. 실험 절차

본 연구의 실험 절차는 다음과 같다<그림 10>. 실험은 머신러닝 AR 프로그램 훈련 집단(실험 집단)과 자기조절 집단(통제 집단)으로 나뉘며 각 집단 안에서 숙련도에 따라 비숙련자와 숙련자 집단으로 구분한다.

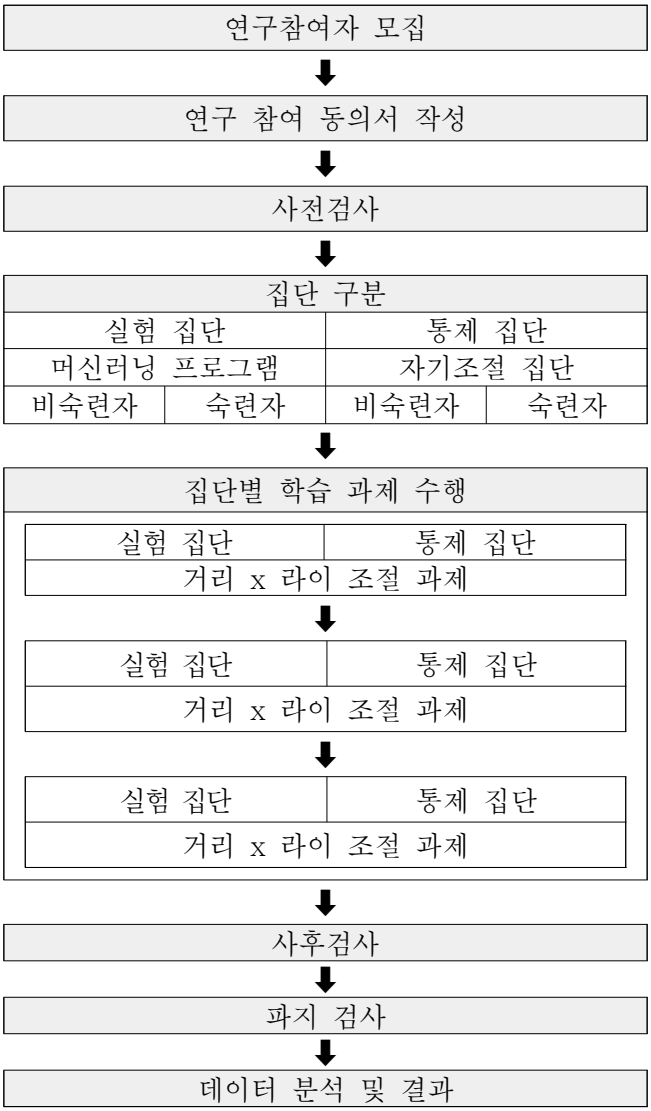

그림 10. 실험 절차

1) 실험 준비

본 연구에 참여하는 참여자들은 연구참여자용 설명서 제공 및 동의서를 작성하게 하였다. 연구의 목적, 실험과정에 대한 설명서와 개인 정보 보호에 관한 동의서 작성한 뒤 궁금하거나 이해하지 못한 부분에 대해서는 구

두로 추가 설명하였다. 실험 공간은 약 3.5m x 3.5m 크기로 본 연구 실험을 위한 충분한 공간을 확보하였다. 실험 공간의 중앙에는 홀컵이 위치하며 홀컵 주변은 3°의 경사도를 지니고 있다<그림 11>. 실험 장소의 그린 빠르기 스팀프미터(stimpmeter) 측정 결과 2.8m로 나타났다.

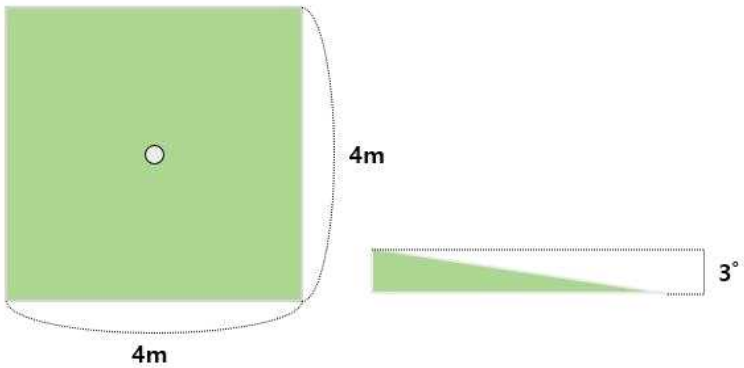

그림 11. 실험 공간 크기와 경사도

2) 사전검사

본 연구의 내용과 목적을 충분히 이해한 뒤 연구참여자는 사전검사를 실시하였다. 참여자는 개인이 사용하는 퍼터로 진행하였으며, 사전검사 전 그린 빠르기 적응을 위한 몸풀기 거리별 3회씩 총 9회의 연습을 수행하였다. 사전검사는 12가지 방향에 따라 거리별(1m, 2.5m 3.5m) 각 24회씩 총 72회 수행하였다<표 6>.

표 6. 사전검사 내용 단위 : 회

거 리	방 향											
	1	2	3	4	5	6	7	8	9	10	11	12
1m	2	2	2	2	2	2	2	2	2	2	2	2
2.5m	2	2	2	2	2	2	2	2	2	2	2	2
3.5m	2	2	2	2	2	2	2	2	2	2	2	2

12 곳의 라이는 평지성 똑바로(straight), 평지성 슬라이스(flat slice), 평지성 훅(flat hook), 내리막 똑바로(down straight), 내리막 슬라이스(down slice), 내리막 훅(down hook), 오르막 슬라이스(up slice), 그리고 오르막 훅(up hook) 라이로, 반복되는 수행에 따른 학습 향상을 방지하기 위해 시도마다 수행하는 위치는 무작위로 나타난다<그림 12>. 시도마다 무작위이지만 모든 참여자가 수행하는 전체 스윙 횟수의 위치는 같다. 스윙 당 제한 시간은 60초를 부여했다. 36회를 실시한 이후 5분의 휴식 시간을 부여했다. 검사 결과는 성공률(%), 실패 시 평균 오차범위(cm), 스윙 템포(bpm), 스윙 크기(cm)를 데이터를 통해 머신러닝 프로그램을 통해 성공한 퍼팅 정보를 바탕으로 학습 정보로 활용하였다.

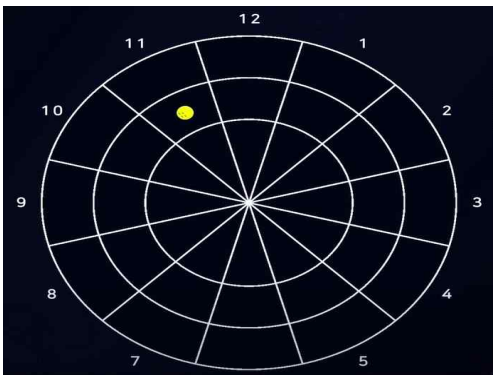

그림 12. 거리와 방향에 따른 수행 예시

3) 집단별 학습 수행

본 연구에서 사전검사 결과를 바탕으로 비숙련자와 숙련자 중 성공률과 오차범위를 기준으로 집단 간 유의한 차이가 나지 않는 집단으로 무작위 배정하였다. 학습은 1주간 3회 진행하였으며 머신러닝 프로그램 집단과 자기조절 집단은 1회 총 90회의 같은 횟수만큼 퍼팅 훈련을 시행하였다. 1회당 3세트로 나누어 세트당 30회 훈련하였으며, 세트 시작 전 5분간 휴식시간을 부여하였다.

머신러닝 집단은 사전검사 결과에 따라 프로그램 분석으로 성공률이 낮거나 오차범위가 상대적으로 높은 곳에서 템포와 퍼팅 스윙 크기 훈련을 추가로 진행하였다. 참여자는 실패율이 높거나 거리 오차 범위가 개인 평균값보다 높은 곳에서 경사도에 따른 최적 경로, 스윙 크기에 대한 시각 피드백 정보를 받으며, 템포에 관한 정보는 메트로놈 청각 피드백을 동시에 받았다<그림 13>.

그림 13. 머신러닝 AR 시각 피드백 예시 (좌) 백스윙 (우) 팔로스루

자기조절 집단의 경우 선행연구들을 통해서 숙련도에 따라서 연습 방법을 다르게 적용했다<표 7>. 비숙련자의 경우 연습 방법은 구획 연습으로 시작하여 파지 검사에서 효과적으로 밝혀진 무선연습으로, 숙련자의 경우 무선연습으로 진행할 것이다. 각 학습 시작 전 사전검사에 따른 위치별 성공률(%)과 오차 범위(cm), 그리고 템포의 정보를 제공해주었다. 세트 별 연습 횟수는 머신러닝 집단과 동일하게 90회로 하였으며, 3세트로 나누어 1세트당 30회, 5분간 휴식 후 2세트 30회, 3세트 30회로 수행하였다<표 8>.

표 7. 자기조절 집단 학습 세부 내용

<table>
<tr><th>회</th><th>세트</th><th>비숙련자</th><th>숙련자</th></tr>
<tr><td rowspan="2">1</td><td>1</td><td rowspan="2">거리 x 방향별 구획연습</td><td rowspan="6">거리 x 방향별 무선연습</td></tr>
<tr><td>2</td></tr>
<tr><td rowspan="2">2</td><td>1</td><td>거리 x 방향별 구획연습</td></tr>
<tr><td>2</td><td>거리 x 방향별 무선연습</td></tr>
<tr><td rowspan="2">3</td><td>1</td><td rowspan="2">거리 x 방향별 무선연습</td></tr>
<tr><td>2</td></tr>
</table>

표 8. 세부 실험 절차

<table>
<tr><th rowspan="3">회</th><th rowspan="3">세트</th><th colspan="2">머신러닝 집단</th><th colspan="2">자기조절 집단</th></tr>
<tr><th colspan="4">근거리 : 1m 중거리: 2.5m 원거리: 3.5m</th></tr>
<tr><th>비숙련자</th><th>숙련자</th><th>비숙련자</th><th>숙련자</th></tr>
<tr><td rowspan="2">1</td><td>1</td><td rowspan="2">피드백 정보
1회당 1번 제공</td><td rowspan="3">피드백 정보
2회당 1번 제공</td><td rowspan="2">구획 연습</td><td rowspan="5">무선 연습</td></tr>
<tr><td>2</td></tr>
<tr><td rowspan="2">2</td><td>1</td><td rowspan="2">피드백 정보
2회당 1번 제공</td><td>구획 연습</td></tr>
<tr><td>2</td><td rowspan="3">피드백 정보
3회당 1번 제공</td><td>무선 연습</td></tr>
<tr><td rowspan="2">3</td><td>1</td><td rowspan="2">피드백 정보
3회당 1번 제공</td><td rowspan="2">무선 연습</td></tr>
<tr><td>2</td></tr>
</table>

※ 세트간 휴식시간은 10분 부여

4) 사후 검사 및 파지 검사

사후 검사는 3회 학습 뒤 24시간이 지난 뒤 실시하였으며, 파지검사는 48시간이 지난 뒤 실시하였다(Shafizadeh et al., 2011; Chiviacowsky et al ., 2019). 연구 참여자들은 사전 검사와 동일하게 거리와 경사에 따른 72회 퍼팅 과제를 실시하였으며 피드백은 없이 진행하였다.

4. 실험설계

본 연구는 평가 시점과 훈련 집단을 독립 변인으로 한 혼합분산분석(mixed anova design)이다. 종속 변인은 크게 수행 정확성과 수행 수준으로 나누었다. 수행 정확성은 퍼트 성공률, 홀컵과의 오차범위 그리고 퍼터 헤드 정보이다. 수행 수준은 임팩트 각도, 스윙 템포의 일관성 그리고 스윙 크기의 일관성으로 설정하였다<표 9>.

표 9. 실험 설계

독립변인		종속변인
실 험	학 습 법	1. 수행 정확성 성공률(%) 가변오차(MRE) 2. 수행 수준 헤드 움직임(각도, 속도) 스윙 템포(bpm) 일관성 스윙 크기(cm) 일관성
	숙련도	
	연습시행	

5. 자료분석

본 연구에서는 퍼팅 과제 시 거리와 경사도에 따라 나타나는 수행 정확성 및 수행 수준을 분석할 것이다. 사전검사부터 학습 3회, 사후검사 그리고 파지 검사까지 전체 퍼팅 수행을 검사할 것이다.

1) 수행의 정확성(성공률, 거리 오차)

▶ 퍼팅 과제 수행 시 나타나는 수행의 정확성 중 성공률은 연구참여자가 검사 및 학습 중 총 시도 횟수 중 홀컵에 들어간 개수를 확률로 나타낸 것이다. 이 값이 크면 클수록 높은 정확도를 의미한다(수식 1).

$$\text{퍼팅성공률}(\%) = \frac{\text{홀컵들어간횟수}}{\text{퍼팅횟수}} X100 \quad \text{(수식 1)}$$

▶ 수행 정확성 중 평균 오차범위의 경우 퍼팅 수행 시 홀컵에 들어가지 않았을 때 홀컵과 공의 최종 위치와의 평균 오차범위를 의미한다(수식 2). 평균 오차범위는 수치가 낮을수록 높은 정확도를 의미한다(Sim & Kim, 2010). 퍼팅 수행 평균 오차범위 즉, target distance error는 홀컵을 기준으로 x축과 y축 값으로 나타낸다.

$$error = \sqrt{(x'-x)^2 + (y'-y)^2} \qquad \text{(수식 2)}$$

홀컵 오차 범위 (Sim & Kim, 2010)

2) 수행 수준(임팩트 각도, 템포, 스윙 크기)

▶ 퍼팅 과제 수행 시 임팩트 각도는 퍼터가 공에 맞는 순간의 각도를 측정하는 것으로 일반적으로 0°에 가까울수록 수행 수준이 높다.

▶ 퍼팅 템포는 어드레스부터 백스윙 시간과 백스윙 탑에서 임팩트까지 시간을 비교하여 비율화한 값을 의미한다(수식 3.) 템포의 일관성은 특정 거리를 위한 퍼팅 수행시 템포 오차가 적에 하는 것이 일관성을 보는 요인으로 그 편차를 확인하여 일관성 지표로 활용하였다.

$$\text{템포}(tempo) = \frac{\text{다운스윙}(downswing)}{\text{백스윙}(backswing)} \quad (\text{ 수식 } 3 \text{ })$$

▶ 스윙 크기는 어드레스부터 백스윙 탑까지 스윙 크기와 임팩트 이후 팔로스루까지 크기를 cm 단위로 측정하였다. 템포와 동일하게 거리에 따라서 스윙 크기는 편차가 적을수록 일관된 것으로 백스윙과 팔로스루의 크기를 편차를 측정하여 일관성 지표로 활용하였다.

3) 머신러닝 모형 성능 평가

카메라와 센서를 통해 들어오는 수많은 영상 정보를 머신러닝을 활용하여 정확한 데이터 분석과 처리가 필요하다. 또한, 검사와 학습 과정에서 허용 가능한 error 값과 이를 넘어섰을 때 boundary를 설정하기 위해서 Python 머신러닝 알고리즘 퍼팅 데이터를 학습해 적절한 퍼팅 템포와 크기 데이터를 제시하는 머신러닝 모델을 고안하는 것이다. 머신러닝 모델은 의사결정 과정의 설명가능성이 높은 gradient boosting decision tree (GBDT)를 채택하였다(Friedman 2001). Decision tree (DT)는 지도학습의

일종으로 높은 설명가능성을 요하는 회귀 및 분석 문제에서 널리 사용된다. DT의 중간 노드 (non-leaf node)는 입력 변수에 대해 특정 조건을 만족하는지 검사하고, 결과에 따라 서로 다른 branch로 입력 데이터를 분류한다. DT의 끝 노드 (leaf node)는 decision의 결과 (회귀 문제에서는 값, 분류 문제에서는 레이블)를 나타낸다. 입력 데이터는 모두 루트 노드에서 시작해서 서로 다른 경로를 통해 끝 노드에 도달한다. 그러므로 중간 노드를 분석해 DT의 의사 결정 과정을 이해할 수 있다. DT의 학습에서 가장 중요한 것은 적절한 조건(규칙)과 분기점을 찾는 것이다.

Gradient boosting decision tree (GBDT)은 predictive error를 최소화하는 방향으로 학습된 decision tree의 ensemble이다. 회귀 문제에서 GBDT는 노드의 최종 값을 얻기 위해 ensemble한 여러 decision tree의 leaf node 값을 종합한다. GBDT의 최적화와 성능 개선을 위해 많은 연구들이 이루어졌고, 본 서비스에서 우리는 그 중 가장 최신의 모델인 LightGBM을 사용하였다(Goulin et al., 2017). 오류를 최소화하는 방식으로 성공률과 평균 오차범위, 그리고 임팩트 퍼트 헤드 정보를 바탕으로 설정하였다.

▶ 본 연구에서 사용된 머신러닝 모형 성능 평가는 Root mean squared error-obervation standard deviation ration(RSR), Nash-Sutcliffe of Efficiency(NSE), Mean absolute error(MAE)의 3가지 평가지수를 이용하였다(수식4,5,6).

$$RSR = \frac{\sqrt{\sum_{t=1}^{n}(M_{t,obs} - M_{t,m})^2}}{\sqrt{\sum_{t=1}^{n}(M_{t,obs} - \overline{M_{t,obs}})^2}} \qquad \text{(수식 4)}$$

$M_{i,obs}$: $Observed\,value\,at\,time\,t$, $M_{i,\mathrm{model}}$: $\mathrm{Predcted}\,value\,at\,time\,t$

$$NSE = 1 - \frac{\sum_{t=1}^{n}(M_{t,m} - M_{t,obs})^2}{\sum_{t=1}^{n}(M_{t,obs} - \overline{M_{obs}})^2} \qquad \text{(수식 5)}$$

$M_{i,obs}$: Observed value at time t, $M_{t,m}$: Predicted value at time t

$\overline{M}_{obs}$: Average of observed values

$$MAE = \frac{1}{n}\sum_{t=1}^{n}\left| M_{t,m} - M_{t,obs} \right| \qquad \text{(수식 6)}$$

n : Total ∋mber of observed valus

$M_{t,m}$: Predicted value at time t

$M_{t,obs}$: Observed value at time t

6. 통계 분석

본 연구에서는 SPSS 27.0 프로그램을 사용하여 다음과 같은 분석을 시행할 것이다. 가설 검증을 위한 통계적 유의수준은 $p < 0.05$로 설정할 것이다(SPSS Inc, Chicago, USA).

▶ 비숙련자의 평가 시점에 따른 수행 정확성과 수행 수준의 차이를 분석하기 위해 평균과 표준편차를 활용한 독립표본 t 검정(independent sample t-test)을 통해 유의 수준을 확인하였다.

▶ 숙련자의 평가 시점에 따른 수행 정확성과 수행 수준의 차이를 분석하기 위해 평균과 표준편차를 활용한 독립표본 t 검정(independent sample t-test)을 통해 유의 수준을 확인하였다.

▶ 집단별 학습방법(자기조절 집단, 머신러닝 집단)과 숙련도(비숙련자, 숙련자) 그리고 평가 시기(사전, 사후, 파지)에 따른 수행정확성과 수행수준의 차이를 알아보기 위해 혼합분산분석(3-way mixed ANOVA)을 실시하였다. 유의한 차이가 나타나는 결과에 대해서는 사후검정(Bonferroni correction)을 실시하였다.

IV. 연구 결과

본 연구에서는 머신러닝과 증강현실(AR) 기술을 적용한 퍼팅 학습 훈련의 효과를 알아보고 숙련도에 따른 효과의 차이점을 살펴보기 위해 거리와 경사에 따른 퍼팅 수행 정확성과 수행 수준을 살펴보았다. 수행 정확성의 변인은 퍼팅 성공률(%)과 오차 범위(cm)로 설정하였다. 그리고 퍼팅 수행 수준의 변화를 살펴보기 위해 퍼팅 시 퍼터 헤드의 움직임(임팩트 각도 일관성, 퍼팅 헤드 속도 일관성), 템포 일관성(bpm) 그리고 스윙 크기의 일관성(백스윙, 팔로스루)을 확인하였다.

1. 수행 정확성(Performance accuracy)

1) 퍼팅 성공률(putting success rate)

본 연구에서 평균 퍼팅 성공률은 3가지 거리에서 방향(12곳)에 따라 2회씩 총 72회 홀컵에 퍼팅을 시도하여 들어간 것을 바탕으로 분석하였다. 평가 시기에 따른 평균 퍼팅 성공률의 평균 및 표준편차는 <표 10>와 같다.

표 10. 평균 퍼팅 성공률 (단위:%)

집 단		사 전	사 후	파 지
머신러닝 AR 집단	비숙련자	44±5	48±5	50±4
	숙련자	66±4	74±4	75±4
자기조절 집단	비숙련자	44±5	46±3	47±3
	숙련자	65±6	67±5	67±7

비숙련자 집단의 평가 시점 퍼팅 성공률 차이를 분석하기 위해 독립표본 t검정(independent sample t-test)을 분석한 결과 사전, 사후 그리고 파

지에서 모두 유의하지 않은 결과가 나타났다. 그러나 자기조절 집단은 사전(44.14%), 사후(46.45%), 파지(47.07%)으로 약 3%의 향상하였으며, 머신러닝 집단은 사전(43.52%), 사후(48.30%), 파지(50%)로 약 7%의 향상된 경향성을 나타냈다. 숙련자 집단의 평가 시점 퍼팅 성공률 차이를 분석하기 위해 독립표본 t검정을 분석한 결과 사후 그리고 파지에서 유의한 결과가 나타났다. 자기조절 집단은 사전(65.28%), 사후(67.28%), 파지(66.51%)로 별다른 차이가 나타나지 않았으며, 머신러닝 집단은 사전(66.05%), 사후(73.61%), 파지(75.46%)로 약 10%의 높은 학습 효과가 나타났다.

집단, 시점, 숙련여부에 따른 평균차이를 검증하기 위하여 혼합분산분석(3-way mixed anova)를 사용하였다. Mauchly의 단위행렬 검정값의 유의확률이 .088으로 .05이상으로 구형성 가정을 만족하는 것으로 나타났다. 따라서 구형성 가정의 유의확률을 확인하였다. 시점의 경우 유의미한 차이가 나타났다[F=25.718, p<.001]. 시점*집단의 경우 유의미한 차이가 나타났다[F=8.018, p<0.001]. 시점*숙련여부의 경우 유의미한 차이가 나타나지 않았다[F=0.34, p=0.713]. 시점*집단*숙련여부의 경우 유의미한 차이가 나타나지 않았다[F=1.239, p=0.296]. 집단의 경우 유의미한 차이가 나타났다[F=6.976, p=.013]. 숙련여부의 경우 유의미한 차이가 나타났다[F=309.809, p<.001]. 집단 * 숙련여부의 경우 유의미한 차이가 나타나지 않았다[F=2.410, p=.130]. Bonferroni 사후검정을 통해 구체적인 차이를 검정하였다. 자기조절 집단에서는 유의미한 평균 차이가 나타나지 않았다. 구체적으로, 자기조절 집단보다 머신러닝 집단의 평균이 유의미하게 높았다. 비숙련자보다 숙련자의 평균이 유의미하게 높았다. 시점에 대해서 사전보다 사후의 평균이 유의미하게 높았으며. 사후와 파지에는 유의미한 차이가 나타나지 않았다. 머신러닝 집단에서는 사전에 비해 사후의 값이 유의미하게 높았다. 머신러닝 집단에서는 사전에 비해 파지의 값이 유의미하게 높았다. 머신러닝 집단에서는 사후와 파지의 값의 차이가 나타나지 않았다.

표 11. 퍼팅 성공률 혼합분산분석 결과

	유형 III 제곱합	자유도	평균제곱	F	유의확률
(집단 내)					
시점	.052	2.000	.026	25.718	.000***
시점 * 집단	.016	2.000	.008	8.018	.001***
시점 * 숙련여부	.001	2.000	.000	.340	.713
시점 * 집단 * 숙련여부	.003	2.000	.001	1.239	.296
오류(시점)	.065	64.000	.001		
(집단 간)					
집단	.031	1.000	.031	6.976	.013*
숙련여부	1.361	1.000	1.361	309.809	.000***
집단 * 숙련여부	.011	1.000	.011	2.410	.130
오류	.141	32.000	.004		

*p<.05, **p<.01, ***p<.001

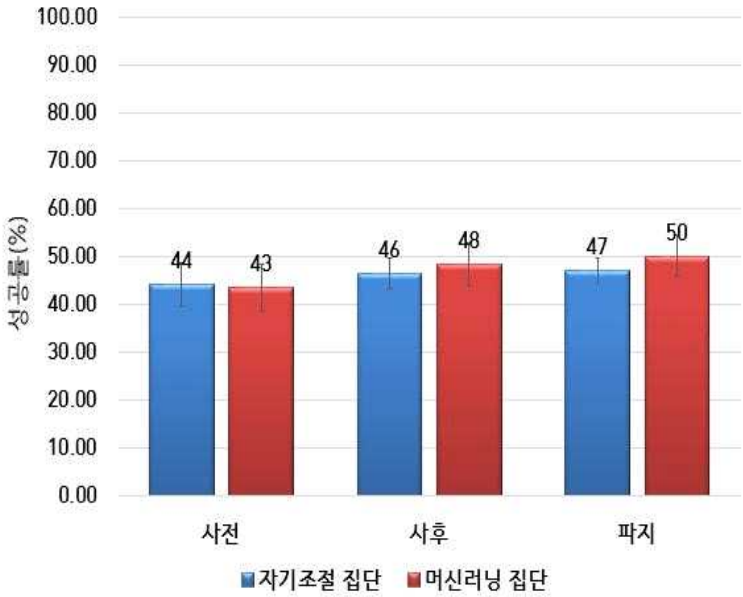

그림 14. 비숙련자의 퍼팅 성공률 변화

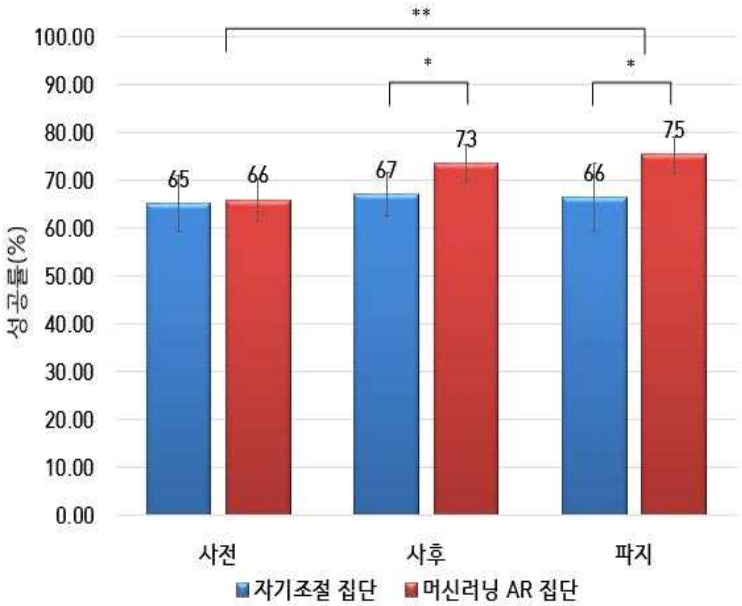

그림 15. 숙련자의 퍼팅 성공률 변화

2) 평균 오차범위(MRE)

본 연구에서 평균 오차범위는 검사 시 전체 퍼팅 수행(72회)에서 실패한 퍼팅의 홀컵과의 절대오차 거리(cm) 정보를 수집하여 분석하였다. 평가 시기에 따른 평균 오차범위에 대한 평균 및 표준편차는 <표 12>와 같다.

표 12. 평균 홀컵 오차범위 (단위:cm)

집 단		사 전	사 후	파 지
머신러닝 AR 집단	비숙련자	77.09±8.96	62.15±10.24	55.62±9.04
	숙련자	52.04±2.52	39.78±3.39	35.45±3.68
자기조절 집단	비숙련자	75.83±4.89	75.38±8.77	74.56±8.39
	숙련자	53.63±7.37	51.74±11.99	46.14±5.9

비숙련자 집단의 평가 시점 평균 홀컵 평균 오차범위의 차이를 분석하기 위해 독립표본 t검정을 분석한 결과 사후 및 파지 검사에서 통계적으로 유의하게 나타났다. 자기조절 집단은 사전(75.83cm), 사후(75.38cm), 파지(74.56cm)로 차이가 나타나지 않았으며, 머신러닝 집단은 사전(77.09cm), 사후(62.15cm), 파지(55.62cm)으로 약 20cm 홀컵에 근접한 결과가 나타났다. 숙련자 집단의 평가 시점 평균 홀컵 평균 오차범위의 차이를 분석하기 위해 독립표본 t검정을 분석한 결과 통계적으로 유의하게 나타났다. 자기조절 집단은 사전(53.63cm), 사후(51.74cm), 파지(46.14cm)로 약 8cm의 향상된 결과가 나타났으며, 머신러닝 집단은 사전(52.04cm), 사후(39.78cm), 파지(35.45cm)으로 약 17cm로 자기조절 집단보다 더 큰 학습 효과가 나타났다.

집단, 시점, 숙련여부에 따른 평균차이를 검증하기 위하여 혼합분산분석를 사용하였다. Mauchly의 단위행렬 검정값의 유의확률이 .002으로 .05미만으로 구형성 가정을 만족하지 못하는 것으로 나타났다. 따라서, Greenhouse-Geisser의 값을 확인하였다. 시점의 경우 유의미한 차이가 나타났다[F=31.214, p<.001]. 시점*집단의 경우 유의미한 차이가 나타났다[F=13.14, p<.001]. 시점*숙련도의 경우 유의미한 차이가 나타나지 않았다[F=0.579, p=0.518]. 시점*집단*숙련도의 경우 유의미한 차이가 나타났다[F=6.355, p=.007]. 집단의 경우 유의미한 차이가 나타났다[F=14.515, p<.001]. 숙련도의 경우 유의미한 차이가 나타났다[F=117.059, p<.001]. 집단*숙련도의 경우 유의미한 차이가 나타나지 않았다[F=1.411, p=.244]. 사후검정을 통해 구체적인 차이를 검정하였다. 구체적으로, 자기조절 집단보다 머신러닝 집단의 평균이 유의미하게 높았다. 비숙련자보다 숙련자의 평균이 유의미하게 낮았다. 사전보다 사후의 평균이 유의미하게 낮았다. 사전보다 파지의 평균이 유의미하게 낮았다. 사후보다 파지의 평균이 유의미하게 낮았다. 자기조절 집단에서는 사후보다 파지 값이 유의미하게 낮았다.

머신러닝 집단에서는 사전보다 사후, 파지 값이 유의미하게 낮았으나 사후와 파지에서 차이가 나타나지 않았다. 자기조절 집단이면서 비숙련자일 때 시점 간의 유의미한 차이가 나타나지 않았다. 자기조절 집단이면서 숙련자일 때 사전과 사후에는 유의미한 차이가 없었지만, 사전보다 파지의 값이 유의미하게 낮으며 사후도 파지 값이 유의미하게 작았다. 머신러닝 집단이면서 비숙련자의 경우 사전보다 사후, 파지의 값이 유의미하게 낮으며, 사후보다 파지의 값이 유의미하게 낮았다. 머신러닝 집단이면서 숙련자의 경우 사전보다 사후, 파지의 값이 유의미하게 낮게 나타났다.

표 13. 평균 오차 범위 혼합분산분석 결과

	유형 III 제곱합	자유도	평균제곱	F	유의확률
[집단 내]					
시점	1899.592	1.512	1256.475	31.214	.000***
시점 * 집단	799.659	1.512	528.930	13.140	.000***
시점 * 숙련도	35.259	1.512	23.322	.579	.518
시점 * 집단 * 숙련도	386.760	1.512	255.820	6.355	.007**
오류[시점]	1947.408	48.379	40.253		
[집단 간]					
집단	1665.456	1.000	1665.456	14.515	.001***
숙련도	13431.513	1.000	13431.513	117.059	.000***
집단 * 숙련도	161.945	1.000	161.945	1.411	.244
오류	3671.737	32.000	114.742		

*p<.05, **p<.01, ***p<.001

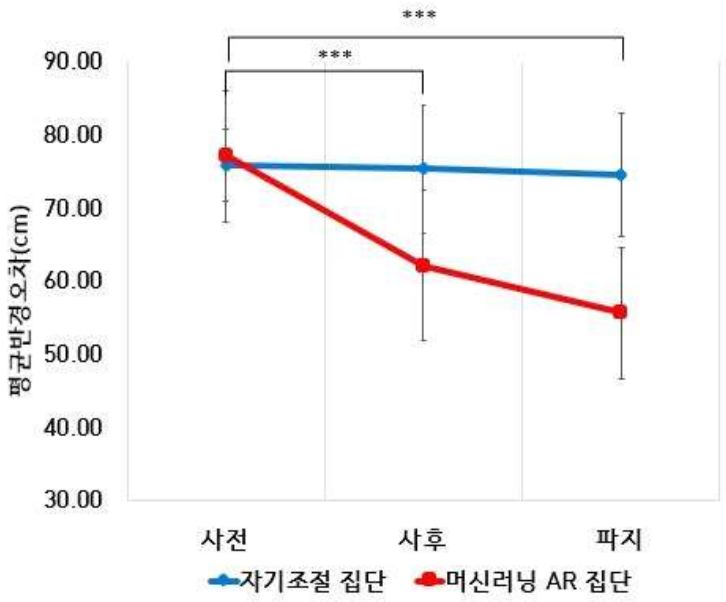

그림 16. 비숙련자의 평균 오차범위 변화

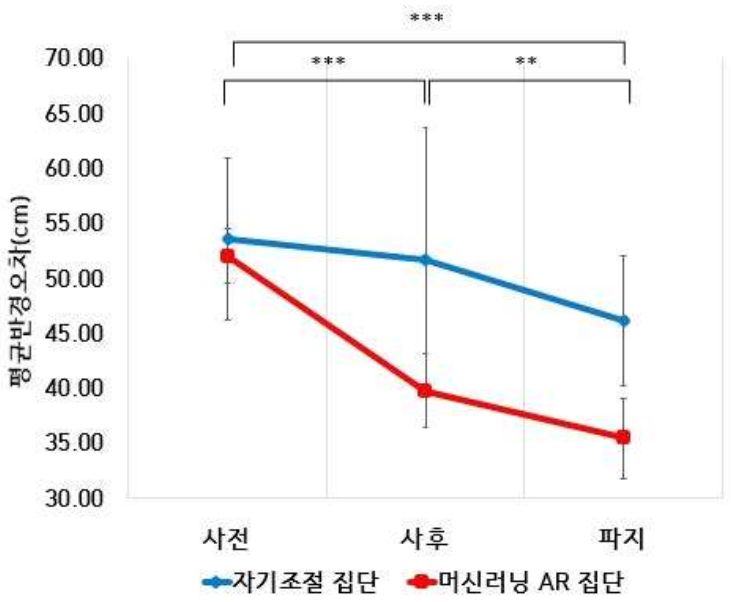

그림 17. 숙련자의 평균 오차범위 변화

3) 거리별 홀컵 성공률과 오차범위

본 연구에서 거리(1m, 2.5m, 3,5m)에 따른 성공률을 살펴보았을 때 다음과 같다<그림 18>. 거리에 따른 성공률 변화를 살펴보면 자기조절 집단의 경우 모든 거리에서 비숙련자와 숙련자 모두 사전, 사후, 파지에서 유의한 차이가 나타나지 않았다. 머신러닝 집단의 경우 비숙련자 집단의 1m 거리에서 성공률은 약 10% 향상되었으며, 숙련자 집단의 경우 1m에서는 차이가 나타나지 않았으나 2.5m는 약 10%, 3.5m는 약 15%의 향상된 결과가 나타났다. 퍼팅 과제의 경우 거리가 멀어질수록 과제 수행의 난도가 높아지고 그에 따라 퍼팅 성공률은 급격하게 낮아진다. 본 연구에서도 거리가 늘어남에 따라 수행자의 성공률은 급격하게 낮아졌으며 숙련자의 경우 사전검사에서 1m와 3.5m의 성공률은 2배 가까운 차이가 나타났다. 선수들의 경우 약 1m 거리는 95%, 4m는 54%로 거리 증가에 따른 성공률은 급감하는 것을 알 수 있다(2022 PGA). 이에 본연구에서 숙련자의 경우 거리 증가에 따라 성공률 향상이 나타난 만큼 개인의 내적 템포와 수행 크기 일관성 향상 훈련이 숙련자에게 퍼팅 성공률 향상에 큰 도움을 주는 것을 알 수 있다.

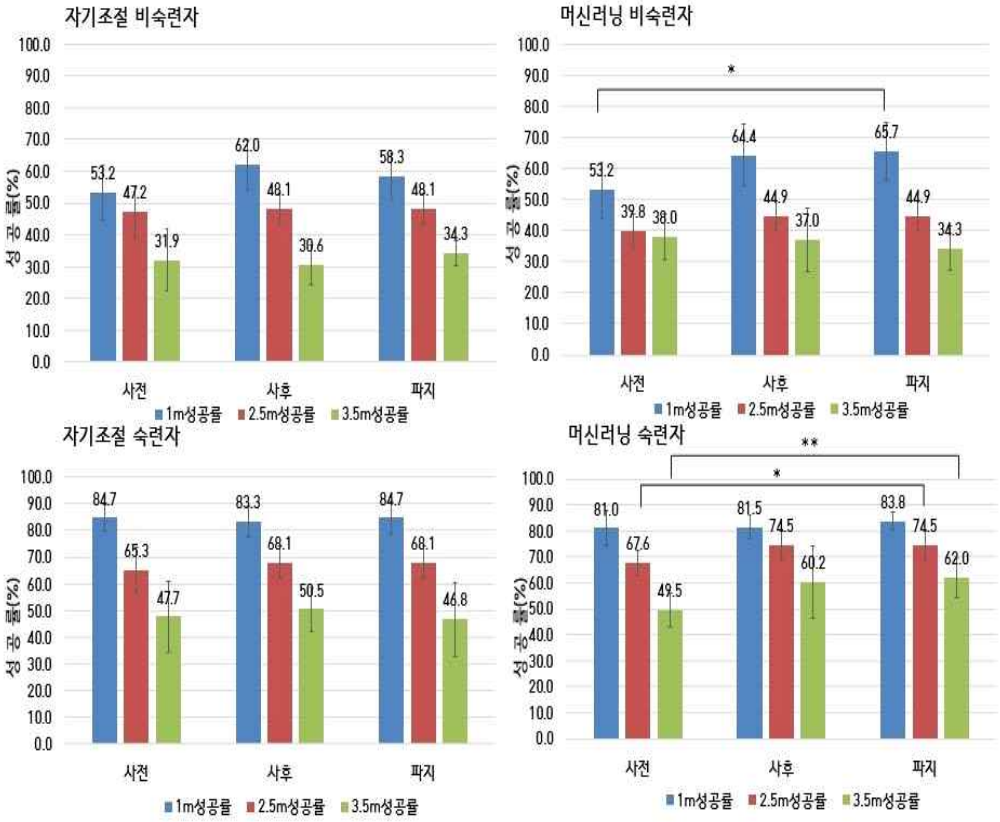

그림 18. 거리에 따른 퍼팅 성공률 변화

퍼팅 성공률과 함께 거리에 따른 오차범위를 살펴보면 다음과 같다<그림 19>. 홀컵과의 오차범위는 퍼팅 정확도에서 성공률과 함께 고려해야 하는 중요한 요인이다. 유의한 결과가 나타난 부분을 살펴보면 비숙련자의 경우 자기조절 집단에서는 3.5m 거리에서 약 10cm 향상, 머신러닝 집단은 2.5m 약 13cm, 3.5m 약 22cm의 향상된 결과가 나타났다. 숙련자의 경우 자기조절 집단은 3.5m 약 12cm, 머신러닝 집단은 2.5m 약 9cm, 3.5m 약 15cm 향상된 결과가 나타났다. 모든 집단에서 향상된 경향이 나타나거나 3.5m 에서는 모두 향상된 만큼 선행연구의 퍼팅 학습 결과와 일부 일치하는 결과가 나타났다. 이와 함께 머신러닝을 적용하여 고유 템포와 스윙 크

기 일관성 향상 학습 훈련이 홀컵 오차범위에서 숙련도와 무관하게 모두 효과적인 것을 확인할 수 있었다.

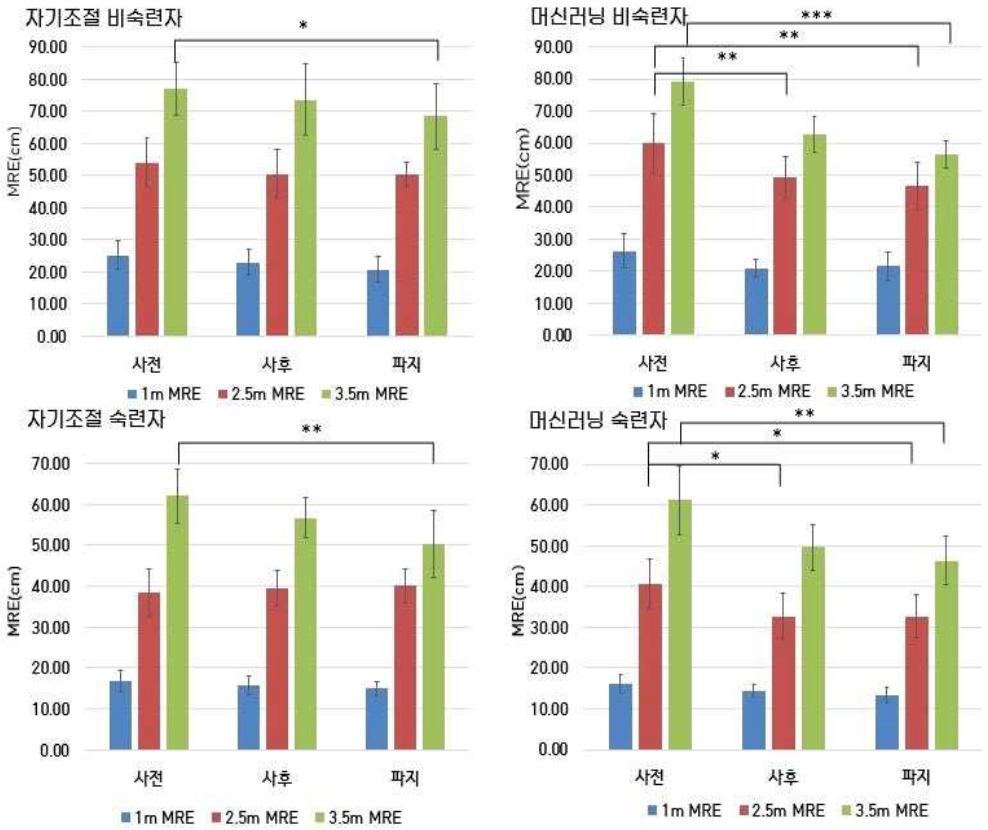

그림 19. 거리에 따른 퍼팅 오차범위 변화

2. 수행 수준

퍼팅 수행 수준은 퍼터 헤드 움직임(임팩트 각도, 퍼팅 속도), 템포 그리고 퍼팅 크기의 일관성을 확인하였다. 이들 요인을 통해 거리와 방향에 따른 다양한 퍼팅 과제에서 수행자의 실제 퍼팅 수준의 변화를 확인하였다.

1) 퍼터 헤드 움직임(Movement of putter head)

1-1) 임팩트 각도의 변화(Impact head degree)

퍼팅 과제 수행 시 임팩트 때 헤드 각도에 따라서 공의 출발 방향이 결정되는 만큼 임팩트 각도는 공을 기준으로 0°에 가까울수록 수행자가 원하는 방향으로 출발할 수 있다(Cochran & Stobbs, 1968). 수행자마다 임팩트 시 헤드의 열림(+°)과 닫힘(-°)의 성향이 다르며, 임팩트 순간 열리고 닫힘는 방향은 퍼팅 성공률에 동일한 영향을 주기 때문에 0°를 기준으로 오차의 절대값을 통해 평균과 표준편차를 반영하였다. 시점에 따른 각 집단별 임팩트 각도 변화의 평균과 표준편차는 <표 14>와 같다.

표 14. 임팩트 헤드 각도 변화 (단위 : °)

집 단		사 전	사 후	파 지
머신러닝 AR 집단	비숙련자	2.35±0.37	2.17±0.51	1.88±0.4
	숙련자	1.65±0.21	1.39±0.29	1.31±0.09
자기조절 집단	비숙련자	2.27±0.29	2.33±0.32	2.33±0.32
	숙련자	1.58±0.24	1.54±0.22	1.43±0.17

비숙련자 집단의 평가 시점 임팩트 헤드 각도의 변화 차이를 분석하기 위해 독립표본 t검정(independent sample t-test)을 분석한 결과 파지 평가 시기에서 통계적으로 유의하게 나타났다. 자기조절 집단은 사전(2.27°), 사후(2.33°), 파지(2.33°)로 변화가 나타나지 않았으며, 머신러닝 집단은 사전(2.35°), 사후(2.17°), 파지(1.88°)로 약 0.5°도 향상된 결과가 나타났다. 숙련자 집단의 평가 시점 임팩트 헤드 각도의 변화 차이를 분석하기 위해 독립표본 t검정(independent sample t-test)을 분석한 결과 사전, 사후, 파지 평가 시기 모두 유의하지 않은 결과를 나타냈다. 자기조절 집단은 사전(1.58°), 사후(1.54°), 파지(1.43°)의 감소하는 경향을 보였으며, 머신러닝 집단은 사전(1.65°), 사후(1.39°), 파지(1.31°)으로 감소함을 나타내었다.

집단, 시점, 숙련여부에 따른 평균차이를 검증하기 위하여 혼합분산분석를 사용하였다. Mauchly의 단위행렬 검정값의 유의확률이 .666으로 .05이상으로 구형성 가정을 만족하는 것으로 나타났다. 따라서 구형성 가정의 유의확률을 확인하였다. 시점의 경우 유의미한 차이가 나타났다[F=15.83, p<.001]. 시점*집단의 경우 유의미한 차이가 나타났다[F=10.208, p<.001]. 시점*숙련여부의 경우 유의미한 차이가 나타나지 않았다[F=0.691, p=.505]. 시점*집단*숙련여부의 경우 유의미한 차이가 나타나지 않았다[F=2.895, p=.063]. 집단의 경우 유의미한 차이가 나타나지 않았다[F=1.804, p=.189]. 숙련여부의 경우 유의미한 차이가 나타났다[F=65.787, p<.001]. 집단*숙련여부의 경우 유의미한 차이가 나타나지 않았다[F=0.355, p=.555]. 사후검정을 통해 구체적인 차이를 검정하였다. 비숙련자보다 숙련자의 평균이 유의미하게 낮았다. 사전보다 사후, 파지의 값이 유의미하게 낮으며, 사후보다 파지의 값이 유의미하게 낮았다. 자기조절 집단에서는 시점에 따른 유의미한 차이가 없었다. 그러나 머신러닝 집단의 경우 사전보다 사후, 파지의 값이 유의미하게 낮으며, 사후보다 파지의 값이 유의미하게 낮게 나타났다.

표 15. 임팩트 헤드 각도 변화 혼합분산분석 결과

	유형 III 제곱합	자유도	평균제곱	F	유의확률
[집단 내]					
시점	.897	2.000	.448	15.830	.000***
시점 * 집단	.578	2.000	.289	10.208	.000***
시점 * 숙련여부	.039	2.000	.020	.691	.505
시점 * 집단 * 숙련여부	.164	2.000	.082	2.895	.063
오류[시점]	1.813	64.000	.028		
[집단 간]					
집단	.401	1.000	.401	1.804	.189
숙련여부	14.623	1.000	14.623	65.787	.000***
집단 * 숙련여부	.079	1.000	.079	.355	.555
오류	7.113	32.000	.222		

*p<.05, **p<.01, ***p<.001

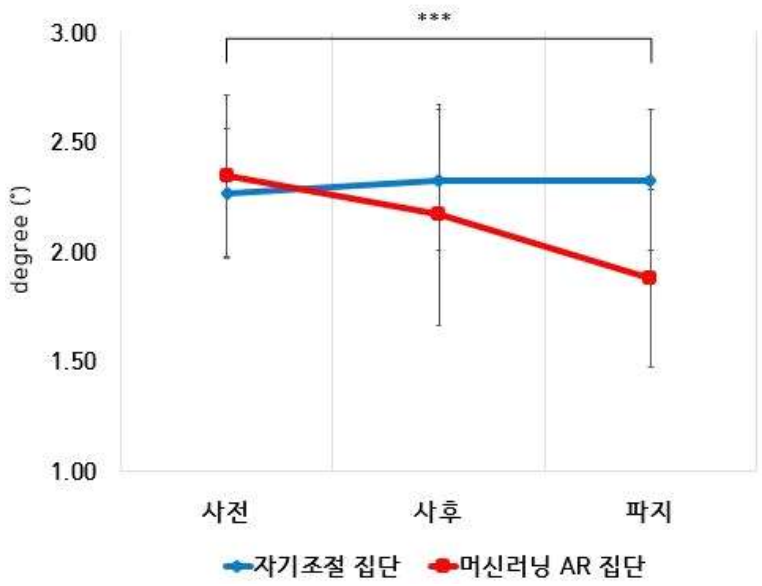

그림 20. 비숙련자의 임팩트 헤드 각도의 변화

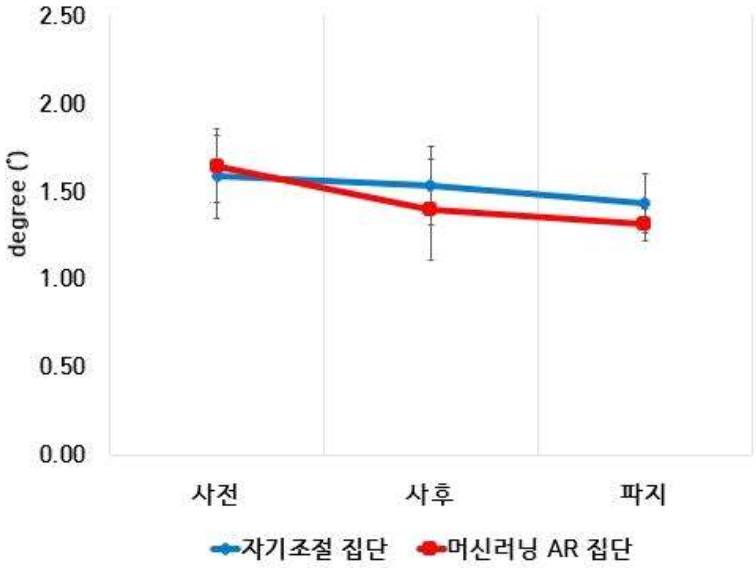

그림 21. 숙련자의 임팩트 헤드 각도의 변화

1-2) 퍼팅 속도 일관성(putting speed consistency)

퍼터 헤드의 움직임에서 공의 출발 방향을 결정하는 것은 임팩트 각도이며 공의 이동 거리 요인은 퍼팅 과제 수행 시 퍼팅 속도이다(Cochran & Stobbs, 1968). 퍼팅 속도는 특정 거리에 원하는 만큼 공을 보내기 위한 수행자의 목적에 따라 일정한 속도를 가져가는 것이 성공적인 퍼팅 수행요인으로 볼 수 있다. 본 실험에서 활용된 2.8m 그린 빠르기에서 퍼터 헤드 속도 0.1m/s당 공은 약 28cm 이동한다. 그에 따라 홀컵을 기준으로 퍼터 헤드 속도 ±0.1m/s 범위 안에 들어온 것을 퍼팅 속도의 일관성 성공 요인 범주로 설정하였다(Pope et al., 2014). 시점에 따른 집단별 퍼팅 헤드 속도 변화의 평균과 표준편차는 <표 16>와 같다.

표 16. 퍼팅 속도 일관성 변화 (단위:%)

집 단		사 전	사 후	파 지
머신러닝 AR 집단	비숙련자	0.45±0.06	0.52±0.06	0.56±0.05
	숙련자	0.58±0.05	0.61±0.03	0.62±0.04
자기조절 집단	비숙련자	0.48±0.08	0.47±0.06	0.47±0.06
	숙련자	0.59±0.06	0.59±0.05	0.59±0.05

비숙련자 집단의 평가 시점 퍼팅 속도 일관성의 차이를 분석하기 위해 독립표본 t검정(independent sample t-test)을 분석한 결과 파지 검사시점에서 통계적으로 유의하게 나타났다. 자기조절 집단은 사전(0.48), 사후(0.47), 파지(0.47)로 학습 효과가 나타나지 않았으며, 머신러닝 집단은 사전(0.45), 사후(0.52), 파지(0.56)로 10% 정도 일관성이 향상되었다. 숙련자 집단의 평가 시점 퍼팅 속도 일관성의 차이를 분석하기 위해 독립표본 t검정(independent sample t-test)을 분석한 결과 파지 검사시점에서 통계적으로 유의하게 나타났다. 자기조절 집단은 사전(0.59), 사후(0.59), 파지(0.59)로 학습효과가 나타나지 않았으며, 머신러닝 집단은 사전(0.58), 사후(0.61), 파지(0.62)로 지속적인 향상된 결과가 나타났다.

집단, 시점, 숙련여부에 따른 평균차이를 검증하기 위하여 혼합분산분석를 사용하였다. Mauchly의 단위행렬 검정값의 유의확률이 .001 미만으로 .05 미만으로 구형성 가정을 만족하지 못하는 것으로 나타났다. 따라서, Greenhouse- Geisser의 값을 확인하였다. 시점의 경우 유의미한 차이가 나타났다[F=18.519, p<.001]. 시점*집단의 경우 유의미한 차이가 나타났다[F=23.679, p<.001]. 시점*숙련여부의 경우 유의미한 차이가 나타나지 않았다[F=2.001, p=0.160]. 시점*집단*숙련여부의 경우 유의미한 차이가 나타났다[F=4.905, p=0.023]. 집단의 경우 유의미한 차이가 나타나지 않았다

[F=2.294, p=0.14]. 숙련여부의 경우 유의미한 차이가 나타났다[F=38.023, p<.001]. 집단*숙련여부의 경우 유의미한 차이가 나타나지 않았다[F=0.367, p=0.549]. 사후검정을 통해 구체적인 차이를 검정하였다. 비숙련자보다 숙련자의 평균이 유의미하게 높았다[p<.001]. 사전보다 사후, 파지의 값이 유의미하게 높으며, 사후보다 파지의 값이 유의미하게 높았다. 자기조절 집단에서는 시점의 차이가 나타나지 않았다. 그러나 머신러닝 집단의 경우 사전보다 사후, 파지의 값이 유의미하게 높으며, 사후보다 파지의 값이 유의미하게 높았다. 자기조절 집단의 경우 숙련여부, 시점에 따른 차이가 나타나지 않았다. 머신러닝 집단 중에서 비숙련자의 사전보다 사후, 파지의 값이 유의미하게 높으며, 사후보다 파지의 값이 유의미하게 높았다. 머신러닝 집단 중에서 숙련자의 사전보다 사후, 파지의 값이 유의미하게 높게 나타났다.

표 17. 퍼팅 속도 일관성 혼합분산분석 결과

	유형 III 제곱합	자유도	평균제곱	F	유의확률
(집단 내)					
시점	.023	1.336	.017	18.519	.000***
시점 * 집단	.030	1.336	.022	23.679	.000***
시점 * 숙련여부	.003	1.336	.002	2.001	.160
시점 * 집단 * 숙련여부	.006	1.336	.005	4.905	.023*
오류(시점)	.040	42.736	.001		
(집단 간)					
집단	.018	1.000	.018	2.294	.140
숙련여부	.301	1.000	.301	38.023	.000***
집단 * 숙련여부	.003	1.000	.003	.367	.549
오류	.253	32.000	.008		

*p<.05, **p<.01, ***p<.001

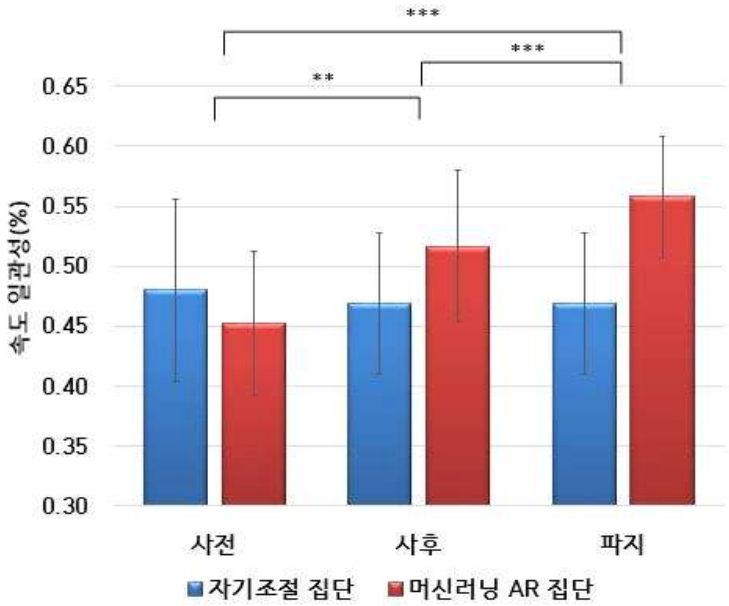

그림 22. 비숙련자의 퍼팅 속도 일관성 변화

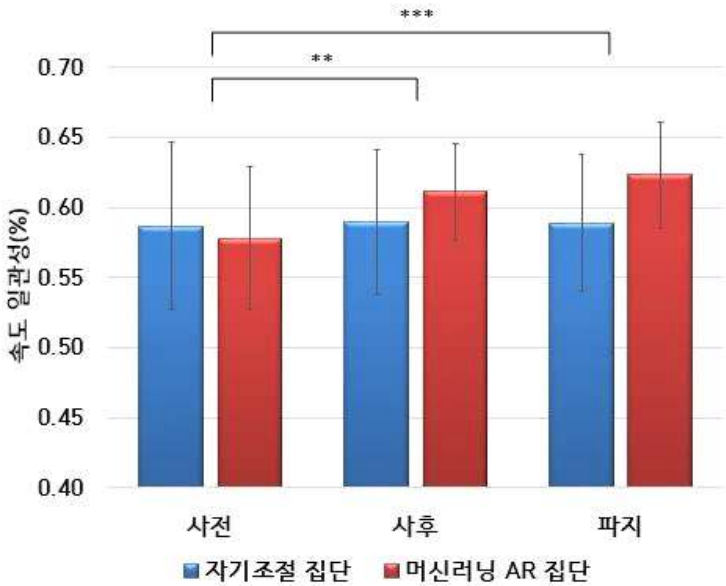

그림 23. 숙련자의 퍼팅 속도 일관성 변화

2) 템포 일관성 (Tempo consistency)

퍼팅 과제에서 템포는 개인 고유감각 차이로 인해 선수들도 차이가 나타나므로, 특정 템포의 기준을 두는 것 보다 템포의 일관성이 숙련도를 확인하는데 더 바람직한 요인으로 볼 수 있다(Heuler, 1995; Karlsen et al., 2008). 템포는 거리와 방향에 무관하게 일정해야 하며, 템포는 성공적인 퍼팅 수행을 위한 중요한 요인이다. 즉, 퍼팅 수행 수준이 높을수록 템포의 오차 범위가 작아야 한다. 두 집단의 숙련도에 따른 3가지 거리에 따른 템포의 오차 평균과 표준편차는 <표 18>와 같다.

표 18. 퍼팅 템포 오차 평균과 표준편차 (단위 : bpm)

집 단		사 전	사 후	파 지
머신러닝 AR 집단	비숙련자	8.91±1.06	7.31±0.62	6.83±0.73
	숙련자	6.61±0.45	5.35±0.49	5.25±0.41
자기조절 집단	비숙련자	9.21±1.03	8.6±0.51	8.88±0.66
	숙련자	6.51±0.6	6.32±0.51	6.48±0.26

비숙련자 집단의 평가 시기 퍼팅 템포 오차의 차이를 분석하기 위해 독립표본 t검정(independent sample t-test)을 분석한 결과 사후, 파지 평가 시기에서 통계적으로 유의하게 나타났다. 자기조절 집단은 사전(9.21bpm), 사후(8.6bpm), 파지(8.88bpm)의 감소하는 경향을 보였으며, 머신러닝 집단은 사전(8.91bpm), 사후(7.31bpm), 파지(6.83bpm)으로 자기조절 집단보다 더욱 감소함에 따라 일관성이 향상된 것을 알 수 있다. 숙련자 집단의 평가 시점 평균 템포오차의 차이를 분석하기 위해 독립표본 t검정(independent sample t-test)을 분석한 결과 사후, 파지 평가 시기에서 통

계적으로 유의하게 나타났다. 자기조절 집단은 사전(6.51bpm), 사후(6.32bpm), 파지(6.48bpm)으로 차이가 나타나지 않았으며, 머신러닝 집단은 사전(6.61bpm), 사후(5.35bpm), 파지(5.25bpm)으로 자기조절 집단보다 일관성이 향상되었다.

집단, 시점, 숙련여부에 따른 평균차이를 검증하기 위하여 혼합분산분석를 사용하였다. Mauchly의 단위행렬 검정값의 유의확률이 .05으로 .05이상으로 구형성 가정을 만족하는 것으로 나타났다. 따라서 구형성 가정의 유의확률을 확인하였다. 시점의 경우 유의미한 차이가 나타났다[F=43.263, p<.001]. 시점*집단의 경우 유의미한 차이가 나타났다[F=22.964, p<.001]. 시점*숙련여부의 경우 유의미한 차이가 나타나지 않았다[F=2.637, p=0.079]. 시점*집단*숙련여부의 경우 유의미한 차이가 나타나지 않았다[F=0.679, p=0.511]. 집단의 경우 유의미한 차이가 나타났다[F=30.945, p<.001]. 숙련여부의 경우 유의미한 차이가 나타났다[F=164.041, p<.001]. 집단*숙련여부의 경우 유의미한 차이가 나타나지 않았다[F=2.205, p=0.147]. 사후검정을 통해 구체적인 차이를 검정하였다. 자기조절 집단보다 머신러닝 집단의 값이 유의미하게 낮았다[p<.001]. 비숙련자보다 숙련자의 평균이 유의미하게 낮았다[p<.001]. 사전보다 사후[p<.001], 파지[p<.001]의 값이 유의미하게 낮으며, 사후보다 파지의 값은 유의미한 차이가 나타나지 않았다. 자기조절 집단에서는 시점 간의 값의 차이는 유의미하지 않았다. 머신러닝 집단에서는 사전보다 사후, 파지의 값이 유의미하게 낮으며, 사후보다 파지의 값은 유의미한 차이가 나타나지 않았다.

표 19. 퍼팅 템포 오차 혼합분산분석 결과

	유형 III 제곱합	자유도	평균제곱	F	유의확률
[집단 내]					
시점	20.786	2	10.393	43.263	0.001***
시점 * 집단	11.033	2	5.517	22.964	0.001***
시점 * 숙련여부	1.267	2	0.634	2.637	0.079
시점 * 집단 * 숙련여부	0.326	2	0.163	0.679	0.511
오류[시점]	15.374	64	0.240		
[집단 간]					
집단	24.759	1	24.759	30.945	0.001***
숙련여부	131.245	1	131.245	164.041	0.001***
집단 * 숙련여부	1.764	1	1.764	2.205	0.147
오류	25.602	32	0.800		

*p<.05, **p<.01, ***p<.001

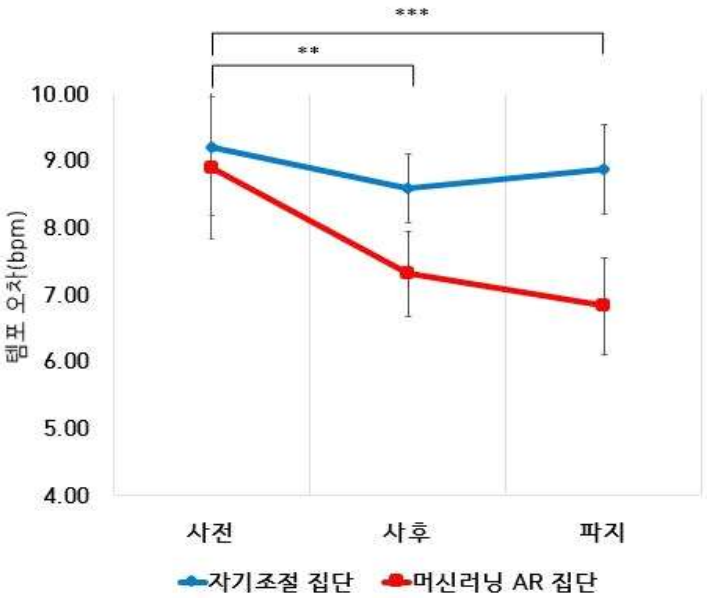

그림 24. 비숙련자의 템포 오차 변화

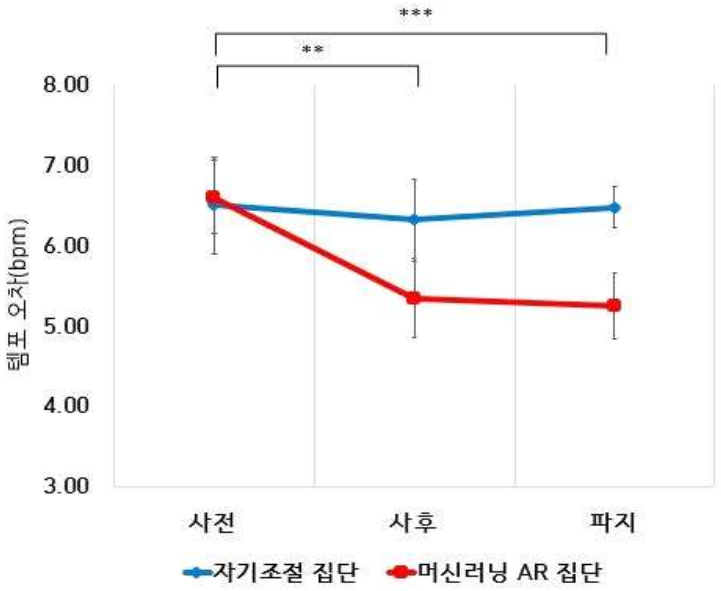

그림 25. 숙련자의 템포 오차 변화

3) 거리별 템포 일관성

본 연구에서 거리(1m, 2.5m, 3,5m)에 따른 템포의 일관성을 오차범위를 통해 살펴보았을 때 다음과 같다<그림 27>. 거리에 따른 템포 오차를 살펴보면 자기조절 집단의 경우 비숙련자의 2.5m에서 10%의 향상을 제외하고 모든 부분에서 일관성 향상은 나타나지 않았다. 그에 반해 머신러닝 집단의 경우 1m 거리를 제외하고 비숙련자와 숙련자 모두 2.5m, 3.5m에서 향상이 나타났다. 1m 거리에서 템포 오차의 경우 머신러닝 집단은 일관성이 향상된 결과가 나타났지만, 사전검사에서 템포 오차 범위가 높지 않아 통계적 유의수준까지 나타나지 않았다. 특히 3.5m의 템포의 일관성이 크게 향상되었다. 사전검사를 통해 템포 오차범위 역시 집단과 숙련도와 무관하게 거리가 늘어날수록 커지는 것을 확인하였다. 거리가 늘어남에 따라 템포의 오차범위가 커지게 되는데, 파지검사에서 오차범위가 줄어드는 템포

일관성이 향상 정도가 커짐에 따라 본 연구의 학습 훈련이 숙련도와 무관하게 학습 효과가 있음을 확인하였다.

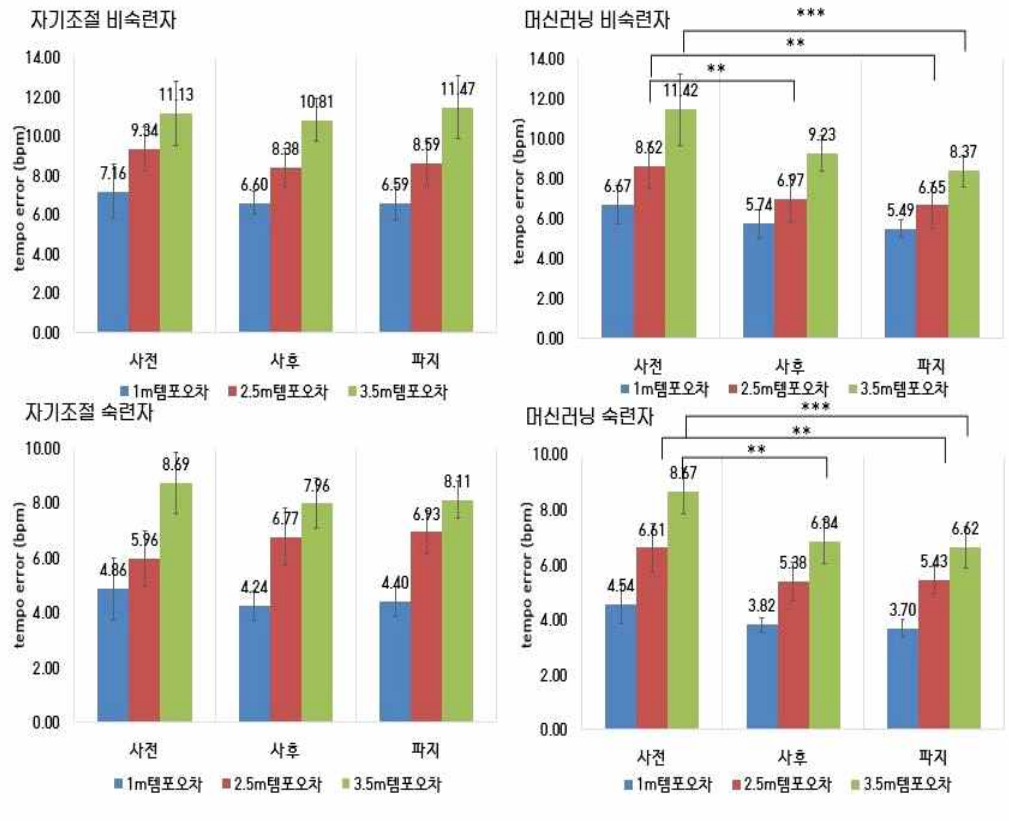

그림 26 거리별 템포 오차 변화

4) 스윙 크기 일관성 - 백스윙(back swing)

퍼팅 과제에서 스윙 크기의 일관성은 템포와 함께 수행자가 인지적으로 생각한 크기만큼을 수행하려는 목적에 맞는 일관성을 확인하는 것으로 퍼팅 과제의 경우 스윙 크기는 숙련도에 따라 일관성이 높으며, 템포와 함께 거리 조절에서 중요한 요인이다(Tanaka & Iwami, 2018). 이에 백스윙(BS-back swing) 크기의 평균 오차를 평균과 표준편차로 구하였다. 이때 편차를 기준으로 수치가 낮을수록 일관된 스윙 크기를 가져갔다고 볼 수

있다. 두 집단의 숙련도에 따른 BS 오차 평균과 표준편차는 <표 20>와 같다.

표 20. 퍼팅 백스윙 크기 오차 범위 (단위 : cm)

집 단		사 전	사 후	파 지
머신러닝 AR 집단	비숙련자	4.05±0.45	3.31±0.16	3.2±0.19
	숙련자	3.24±0.22	2.71±0.2	2.59±0.21
자기조절 집단	비숙련자	4.09±0.36	3.96±0.28	3.92±0.26
	숙련자	3.31±0.21	3.24±0.18	3.1±0.11

비숙련자의 평가 시점별 백스윙 편차의 차이를 분석하기 위해 독립표본 t검정(independent sample t-test)을 분석한 결과 사후, 파지 검사시점에서 유의한 결과를 나타냈다. 자기조절 집단은 사전(4.09cm), 사후(3.96cm), 파지(3.92cm)의 향상된 경향성이 나타났으며, 머신러닝 집단은 사전(4.05cm), 사후(3.31cm), 파지(3.2cm)으로 약 1cm로 자기조저 집단보다 학습 효과가 더 크게 나타났다. 숙련자의 평가 시점별 백스윙 편차의 차이를 분석하기 위해 독립표본 t검정(independent sample t-test)을 분석한 결과 사후, 파지 검사시점에서 유의한 결과를 나타냈다. 자기조절 집단은 사전(3.31cm), 사후(3.24cm), 파지(3.1cm)로 감소되었으며, 머신러닝 집단은 사전(3.24cm), 사후(2.71cm), 파지(2.59cm)의 감소를 나타내었다.

집단, 시점, 숙련여부에 따른 평균차이를 검증하기 위하여 혼합분산분석를 사용하였다. Mauchly의 단위행렬 검정값의 유의확률이 .434으로 .05이상으로 구형성 가정을 만족하는 것으로 나타났다. 따라서 구형성 가정의 유의확률을 확인하였다. 시점의 경우 유의미한 차이가 나타났다[F=48.716, p<.001]. 시점*집단의 경우 유의미한 차이가 나타났다[F=19.529, p<.001].

시점*숙련여부의 경우 유의미한 차이가 나타나지 않았다[F=0.894, p=0.414]. 시점*집단*숙련여부의 경우 유의미한 차이가 나타나지 않았다[F=0.751, p=0.476]. 집단의 경우 유의미한 차이가 나타났다[F=48.217, p<.001]. 숙련여부의 경우 유의미한 차이가 나타났다[F=143.347, p<.001]. 집단*숙련여부의 경우 유의미한 차이가 나타나지 않았다[F=0.699, p=0.409]. 사후검정을 통해 구체적인 차이를 검정하였다. 자기조절 집단보다 머신러닝 집단의 값이 유의미하게 낮았다[p<.001]. 비숙련자보다 숙련자의 평균이 유의미하게 낮았다[p<.001]. 사전보다 사후, 파지의 값이 유의미하게 낮으며, 사후보다 파지의 값은 유의미한 차이가 나타나지 않았다. 자기조절 집단의 경우 사전보다 파지의 값이 유의미하게 낮았다. 나머지 시점의 차이는 유의미하지 못하였다. 머신러닝 집단의 경우 사전보다 사후[p<.001], 파지[p<.001]의 값이 유의미하게 낮으며, 사후보다 파지의 값은 유의미한 차이가 나타나지 않았다.

표 21. 백스윙 크기 오차범위 혼합분산분석 결과

	유형 III 제곱합	자유도	평균제곱	F	유의확률
[집단 내]					
시점	4.411	2	2.206	48.716	0.001
시점 * 집단	1.768	2	0.884	19.529	0.001
시점 * 숙련여부	0.081	2	0.040	0.894	0.414
시점 * 집단 * 숙련여부	0.068	2	0.034	0.751	0.476
오류[시점]	2.897	64	0.045		
[집단 간]					
집단	4.787	1	4.787	48.217	0.001
숙련여부	14.231	1	14.231	143.347	0.001
집단 * 숙련여부	0.069	1	0.069	0.699	0.409
오류	3.177	32	0.099		

*p<.05, **p<.01, ***p<.001

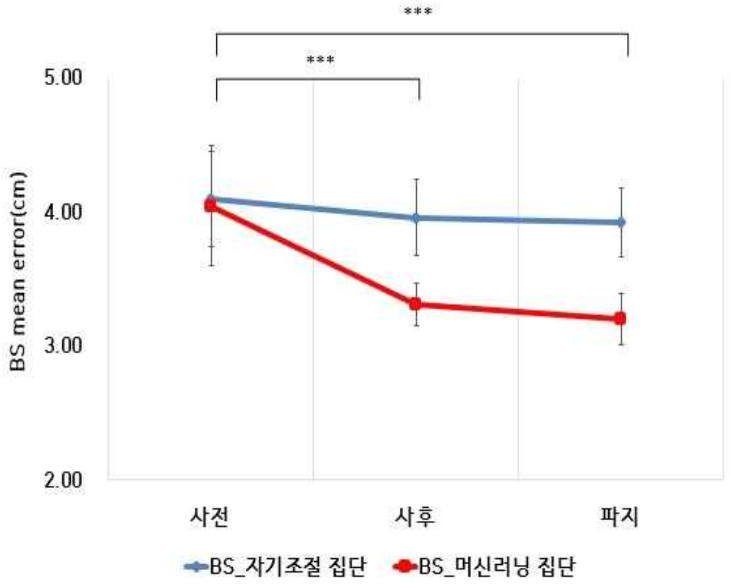

그림 27. 비숙련자의 백스윙 오차 변화

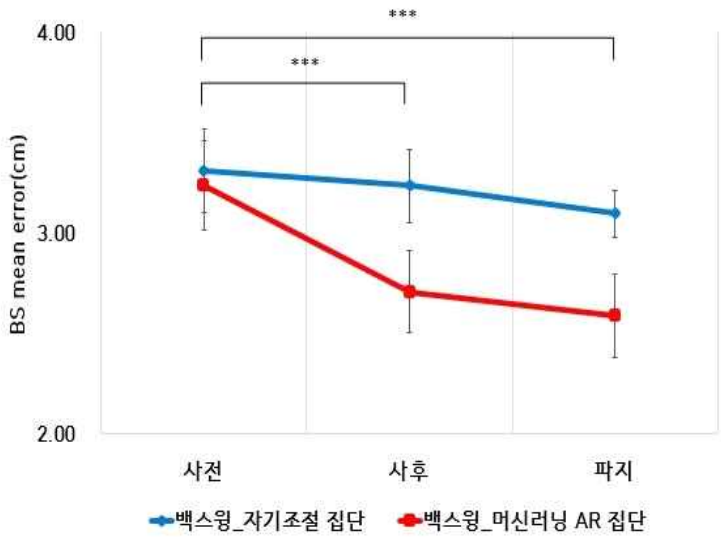

그림 28. 숙련자의 백스윙 오차 변화

4) 스윙 크기 일관성 - 팔로스루(follow-through)

스윙 크기 일관성의 팔로스루는 백스윙과 동일한 요인으로 동일한 방식으로 구하였다. 거리와 방향에 따라 팔로스루 크기의 오차를 평균과 표준편차로 구하였다. 이때 편차를 기준으로 수치가 낮을수록 일관된 스윙 크기를 가져갔다고 볼 수 있다. 두 집단의 숙련도에 따른 팔로스루 오차 평균과 표준편차는 <표 22>와 같다.

표 22. 퍼팅 팔로스루 크기 오차 범위 (단위 : cm)

집 단		사 전	사 후	파 지
머신러닝 AR 집단	비숙련자	4.39±0.3	3.51±0.27	3.26±0.25
	숙련자	3.39±0.28	2.79±0.14	2.85±0.21
자기조절 집단	비숙련자	4.4±0.32	4.26±0.32	4.17±0.3
	숙련자	3.45±0.31	3.34±0.25	3.31±0.23

비숙련자의 평가 시점 팔로스루 편차의 차이를 분석하기 위해 독립표본 t검정(independent sample t-test)을 분석한 결과 사후, 파지 검사시점에서 유의한 결과를 나타냈다. 자기조절 집단은 사전(4.4cm), 사후(4.26cm), 파지(4.17cm)의 약간의 감소를 나타냈으며, 머신러닝 집단은 사전(4.39cm), 사후(3.51cm), 파지(3.26cm)의 학습 효과가 나타났다. 숙련자의 평가 시점별 팔로스루 편차의 차이를 분석하기 위해 독립표본 t검정(independent sample t-test)을 분석한 결과 사후, 파지 검사시점에서 유의한 결과를 나타냈다. 자기조절 집단은 사전(3.45cm), 사후(3.34cm), 파지(3.31cm) 차이가 나타나지 않았으며, 머신러닝 집단은 사전(3.39cm), 사후(2.79cm), 파지(2.85cm) 약 0.5cm 의 일관성 향상이 나타났다.

집단, 시점, 숙련여부에 따른 평균차이를 검증하기 위하여 혼합분산분석를 사용하였다. Mauchly의 단위행렬 검정값의 유의확률이 .035로 .05미만으로 구형성 가정을 만족하지 못하는 것으로 나타났다. 따라서, Greenhouse-Geisser의 값을 확인하였다. 시점의 경우 유의미한 차이가 나타났다[F=61.848, p<.001]. 시점*집단의 경우 유의미한 차이가 나타났다[F=27.32, p<.001]. 시점*숙련여부의 경우 유의미한 차이가 나타났다[F=5.865, p=0.008]. 시점*집단*숙련여부의 경우 유의미한 차이가 나타나지 않았다[F=3.043, p=0.065]. 집단의 경우 유의미한 차이가 나타났다[F=42.449, p<.001]. 숙련여부의 경우 유의미한 차이가 나타났다[F=133.847, p<.001]. 집단*숙련여부의 경우 유의미한 차이가 나타나지 않았다[F=1.984, p=0.169]. 자기조절 집단보다 머신러닝 집단의 값이 유의미하게 낮았다[p<.001]. 비숙련자보다 숙련자의 값이 유의미하게 낮았다[p<.001]. 사전보다 사후, 파지의 값이 유의미하게 낮으며, 사후보다 파지의 값은 유의미한 차이가 나타나지 않았다. 자기조절 집단의 경우 시점의 차이가 나타나지 않았다. 머신러닝 집단의 경우 사전보다 사후, 파지의 값이 유의미하게 낮으며, 사후보다 파지의 값은 유의미한 차이가 나타나지 않았다. 비숙련자의 경우 사전보다 사후, 파지의 값이 유의미하게 낮으며, 사후보다 파지의 값도 유의미하게 낮았다. 숙련자의경우 사전보다 사후, 파지의 값이 유의미하게 낮으며, 사후보다 파지의 값은 유의미한 차이가 나타나지 않았다.

표 23. 퍼팅 팔로스루 크기 오차 범위 혼합분산분석 결과

	유형 III 제곱합	자유도	평균제곱	F	유의확률
[집단 내]					
시점	5.435	1.674	3.247	61.848	0.001***
시점 * 집단	2.401	1.674	1.434	27.320	0.001***
시점 * 숙련여부	0.515	1.674	0.308	5.865	0.008**
시점 * 집단 * 숙련여부	0.267	1.674	0.160	3.043	0.065
오류[시점]	2.812	53.571	0.052		
[집단 간]					
집단	5.594	1	5.594	42.449	0.001***
숙련여부	17.639	1	17.639	133.847	0.001***
집단 * 숙련여부	0.261	1	0.261	1.984	0.169
오류	4.217	32	0.132		

*p<.05, **p<.01, ***p<.001

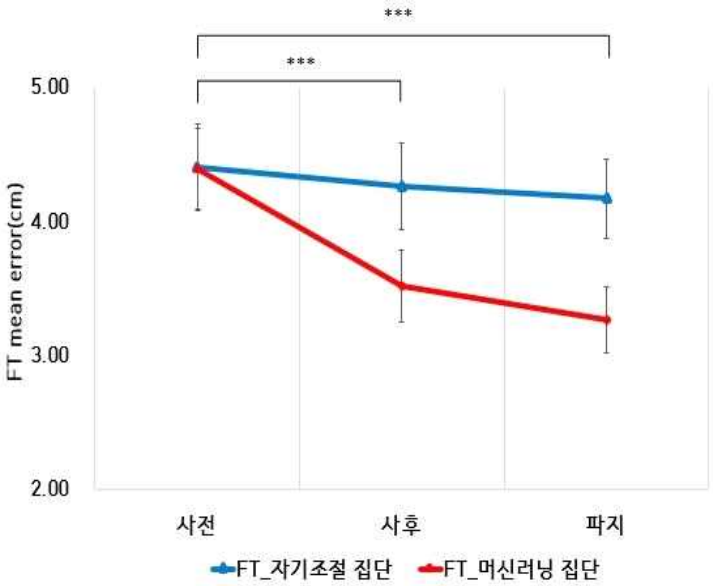

그림 29. 비숙련자의 팔로스루 오차 변화

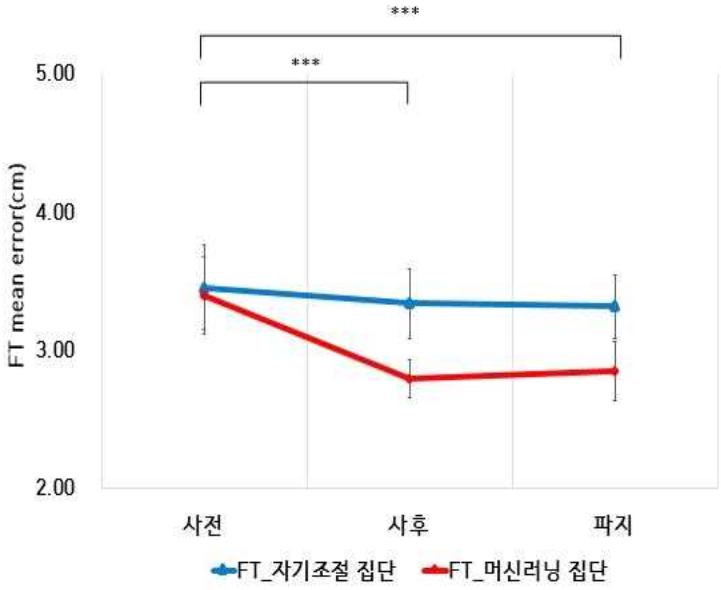

그림 30. 숙련자의 팔로스루 오차 변화

V. 논의

운동학습은 짧은 시간에 가장 효율적인 학습효과를 보기 위함에 있다. 가장 효율적인 학습효과는 다이나믹 이론(dynamic theory)에 따라 수많은 자유도를 고려하여 적용해야 하며, 이때 개개인의 신체 내적 요인과 외적 요인을 모두 고려해야 하는데 이는 현실적으로 분석하여 적용하는 데 어려움이 있다. 특히, 퍼팅 과제에서는 학습을 위해 요구되는 힘의 조절이나 고유감각의 패턴이 다양하므로 이를 고려해야 한다(Jonassen & Grabowski, 1993; Davis et al., 2008). 인간은 개인마다 선호하는 템포가 있는데 이러한 내적 템포(internal tempo)를 고려한 연구들이 나타나고 있다(Drake et al, 2000; Lewis, 2004). 본 연구에서는 퍼팅 과제에서 이를 활용하기 위해 본 연구에서는 머신러닝 알고리즘을 적용한 증강현실 시각 및 청각 피드백을 활용하였다.

본 연구는 숙련도에 따라 비숙련자와 숙련자로 나누었으며 머신러닝 알고리즘을 적용한 집단과 자기조절 피드백을 적용한 집단으로 2주간 사전검사, 3회의 학습 훈련, 사후 검사 그리고 파지 검사를 하였다. 머신러닝 알고리즘 적용 집단은 학습자의 퍼팅 과제 수행 시 나타나는 개인별 템포와 퍼팅 크기, 그리고 궤적을 시각 피드백 및 청각 피드백을 활용하여 제시하였으며, 자기조절 피드백 집단은 오차범위와 궤적에 대한 정보를 제공하였다. 이를 통해 개인별 퍼팅 템포와 스윙 크기 조절 능력 일관성 향상 훈련에 따른 퍼팅 성공률, 오차범위, 헤드 조절 능력과 일관성을 변인으로 두고 변화를 살펴보고자 하였다. 본 장에서는 이러한 세부적인 목적을 규명하기 위해 이루어진 실험 결과를 선행연구의 이론적 배경과 연결하여 논의하고자 한다.

1. 퍼팅 수행 정확성의 변화 비교

본 연구에서 머신러닝을 적용한 증강현실 퍼팅 학습 집단과 자기조절 피드백을 활용한 집단과 숙련도에 따라 어떠한 차이가 나타나지는지에 대한 퍼팅 수행 정확성은 성공률과 오차범위 결과를 기반으로 해석하였다.

전체 거리에서 퍼팅 성공률을 살펴보면 학습에 따른 효과를 살펴보는 파지검사에서 숙련도에 따른 차이가 나타났다. 비숙련자의 경우 머신러닝 집단은 사전(44%)에서 파지(50%)로 약 6% 향상, 자기조절 집단은 사전(44%)에서 파지(47%)로 약 3% 두 그룹 모두 통계적으로 유의하진 않았지만 향상된 경향성이 나타났다. 숙련자의 경우 사전(66%)에서 파지(75%)로 약 9% 향상, 자기조절 집단은 사전(65%)에서 파지(67%)로 머신러닝 숙련자 집단이 높은 학습효과를 나타냈다. 이러한 결과를 통해 모든 그룹에서 학습효과의 크기는 있지만 효과가 나타난 것은 퍼팅 과제에서 피드백에 따른 선행연구(Anderson & Magil, 2001; Wolf et al., 2013; Bourdin et al, 2019)의 결과와 일치한다고 볼 수 있다. 그러나 자기조절 집단에서 학습효과가 선행연구와 유사하게 나타나지 않은 점은 Mackenzie과 Springs(2005) 연구처럼 본 연구에서는 거리와 경사에 따른 복합적인 인지수행 능력이 요구되어 과제 난이도 상승에 따른 것으로 유추해 볼 수 있다. 결국 별도의 신체적인 수정 전략이 부여되지 않는 자기조절 피드백 학습의 경우 실제 퍼팅 수행상황에서 경험할 경사에 따른 성공률 향상은 나타나지 않을 수 있음을 알 수 있다.

그에 반해 개인의 고유 템포를 피드백으로 적용한 머신러닝 집단의 경우 자기조절 피드백 집단보다 비숙련자와 숙련자 모두 더 향상된 결과가 나타났다. 특히, 숙련자에서는 높은 수준의 성공률 향상이 나타났는데, Heuler(1995)의 연구에서 나타난 비숙련자보다 퍼팅 타이밍이 높아 고유 템포의 일관성 향상 요인만으로도 성공률이 높아질 수 있음을 유추할 수

있다.

거리에 따른 성공 개수의 차이를 살펴보면 비숙련자의 경우 머신러닝 집단은 1m 사전(12.78개)에서 파지(15.78개), 2.5m 사전(9.56개)에서 파지(12개) 그리고 3.5m 사전(9.11개)에서 파지(8.22개)로 나타났으며 자기조절 집단은 1m 사전(12.78개)에서 파지(14개), 2.5m 사전(11개)에서 파지(11.67개), 3.5m 사전(7.67개)에서 파지(8.22개)로 나타났다. 자기조절 집단의 경우 1m 거리를 제외하고 향상이 나타나지 않았으며, 머신러닝 집단의 경우 1m 와 2.5m에서 자기조절 집단보다 더 나은 학습효과가 나타났다. 그러나 3.5m 거리에서 두 집단 모두 성공률 향상이 나타나지 않은 것을 보아 거리가 멀어질수록 본 연구에서 성공률의 향상이 나타나진 않을 수 있음을 알 수 있다. 숙련자의 변화를 살펴보면 머신러닝 집단은 1m 사전(19.44개)에서 파지(20.11개), 2.5m 사전(16.22개)에서 파지(19.33개), 3.5m 사전(11.89개)에서 파지(14.89개)로 나타났으며 자기조절 집단은 1m 사전(20.33개)에서 파지(20.33개), 2.5m 사전(15.67개)에서 파지(16.33개), 3.5m 사전(11.44개)에서 파지(11.22개)로 나타났다. 통계적으로 유의하게 나타난 건 머신러닝 집단에서 2.5m와 3.5m 거리에서 나타났으며, 자기조절 집단에서는 유의한 향상이 나타나지 않았다. 자기조절 숙련자 집단의 결과는 핸디캡 10의 참여자를 대상으로 평지에서 퍼팅 학습 시 거리가 늘어남에 따라 자기조절 연습 방법에 따라 학습 효과가 나타났으나, 경사가 주어지면 거리에 따른 학습 효과가 나타나지 않은 연구(Dias et al., 2014)와 일치하고 있다. 그러나 머신러닝을 적용한 본 연구에서는 거리가 멀어짐에 따라서 머신러닝 숙련자 집단은 성공률이 높아지는 것을 확인할 수 있으며, 이를 통해 과제 난이도가 높아짐에 따라 고유 템포와 스윙 크기 일관성 훈련이 퍼팅 성공률에서 효과적인 것을 유추해 볼 수 있다.

퍼팅 수행 정확성에서 홀컵 오차범위(MRE)는 홀컵을 기준으로 벗어난 절대오차를 분석하는 방법(Dias et al., 2014; Sim & Kim. 2010)을 바탕으

로 분석하였다. 오차범위는 머신러닝 집단이 자기조절 집단보다 학습효과가 크게 향상된 결과가 나타났다. 세부적으로 살펴보면 비숙련자의 경우 사전(77.09cm)에서 파지(55.62cm)로 약 22cm 크게 향상된 결과가 나타났다. 숙련자의 경우 사전(52.04cm)에서 파지(42.36cm)로 약 10cm 향상된 결과가 나타났다. 자기조절 집단은 비숙련자는 사전(75.83cm)에서 파지(74.56cm)로 변화가 나타나지 않았으며, 숙련자는 사전(53.63cm)에서 파지(46.14cm)로 약 7cm 향상된 결과가 나타났다. 비숙련자의 경우 숙련도가 낮은 만큼 퍼팅 성공률이 낮으므로 홀컵과의 오차범위가 중요한 요인이다. 홀컵 오차범위를 줄이는 것이 비숙련자의 숙련도 향상에 중요한 척도이며 숙련도가 높아지고 있다는 것임을 선행연구의 결과를 지지하고 있다(Tanaka & Iwami, 2018).

2. 퍼팅 수행 수준의 변화와 비교

본 연구에서 퍼팅 수행 수준은 퍼터 헤드의 움직임의 조절 능력이다. 퍼팅 과제 수행 시 퍼터 헤드의 움직임은 수행자의 신체 협응 패턴과 함께 퍼팅 수행 수준을 판단하는 중요한 척도이다(Cochran & Stobbs, 1968; Delay et al., 1997; Sim & Kim, 2010). 퍼터 헤드의 움직임 조절 능력에는 임팩트 헤드 각도와 템포 그리고 스윙 크기가 있다. 본 연구에서는 이들의 일관성을 살펴보기 위해 이상적인 기준이나 개인별 성공 퍼팅 기준에서 절대오차를 기준으로 살펴보았다.

1) 임팩트 헤드 각도 일관성

성공적인 퍼팅을 위해서는 임팩트시 헤드 각도의 조절 능력이 매우 중요하다. 임팩트 순간 헤드 각도는 0°에 가까울수록 성공적인 퍼팅이다

(Heuler, 1995). 경사가 있는 퍼팅 상황에서 임팩트 시 공의 출발 방향은 성공률에서 가장 중요한 요인이며, 출발 방향이 올바를수록 경사가 있는 상황에서 거리에 따른 오차범위가 줄어든다. 결국 임팩트 헤드 각도의 0°를 유지하는 것과 일관성을 키우는 학습 훈련을 할 필요가 있다. 본 연구에서는 임팩트 각도를 0°를 기준으로 닫혀맞거나(-) 열려맞는(+) 각도를 절대오차를 통해 일관성으로 분석하였다. 머신러닝 집단에서 비숙련자는 사전(2.35°)에서 파지(1.88°)로 약 0.5° 향상되었다. 숙련자는 사전(1.65°)에서 파지(1.31°)로 약 0.3°도 향상되었다. 그에 반해 자기조절 집단은 비숙련자 사전(2.27°)에서 파지(2.33°)로 변화가 나타나지 않았으며, 숙련자는 사전(1.58°)에서 파지(1.43°)로 약 0.1°도 향상되었다. 통계적으로 머신러닝 집단에서만 사전에서 파지로 유의한 결과가 나타났다. 이를 통해 본 연구에서 고유 템포 학습 훈련이 임팩트 시 헤드각도 조절 능력의 향상을 가져올 수 있음을 알수 있었다. 이러한 결과는 퍼팅 수준이 향상 되었음을 알 수 있는 요인으로 임팩트 헤드 각도가 0°라는 선행연구과 일치하고 있다(Cochran & Stobbs, 1968). 아울러 퍼터와 신체의 협응 패턴이나 헤드의 조절에 대한 피드백이 주어지지 않았음에도 템포와 스윙 크기의 일관성 향상 학습 훈련이 임팩트 시 헤드 조절 능력 향상에도 효과가 있음을 판단할 수 있다.

2) 퍼팅 템포와 스윙 크기의 일관성

퍼팅 과제에서 템포는 일정하게 반복되는 필수적인 요인이다(Mann,1989). 그러나 템포는 개인마다 내적인 요인마다 다양하게 나타날 수 있다. Boltz(1994)는 개인마다 내적 템포는 손이나 발 또는 도구를 사용할 때 내적템포로 인해 다양한 템포 차이가 나타난다고 했다. 퍼팅 과제를 정밀하게 수행하기 위해서는 순차적 처리능력이 요구된다. 거리 요인과 경

사에 따른 출발 방향 요인을 인지해야 하며, 그에 따른 퍼터 움직임을 가져가야 한다. 본 연구에서는 머신러닝 집단에게 이러한 개인의 고유 템포와 그에 따른 퍼터의 스윙 크기를 개인마다 사전검사를 통해 성공한 퍼팅 정보를 바탕으로 머신러닝 알고리즘을 활용하여 시각(스윙 크기) 그리고 청각(템포) 정보를 제공하였다. 템포와 스윙 크기의 일관성은 개인의 성공 퍼팅을 기준으로 절대오차를 통해 일관성을 구하였다. 그 결과 자기조절 집단은 사전에 비해 파지에서 효과가 나타나지 않았으나, 머신러닝 집단은 사후 및 파지에서 크게 향상된 결과가 나타났다. 퍼팅 템포에서 비숙련자의 경우 사전(8.91)에서 파지(6.83)으로 약 2bpm 이상 오차가 줄었으며, 숙련자는 사전(6.61)에서 파지(5.25)로 약 1.5bpm 정도 오차가 줄어들어 일관성이 통계적으로 유의하게 향상되었다. 자기조절 집단의 경우 비숙련자는 사전(9.21)에서 파지(8.88)로 변화가 거의 나타나지 않았으며, 숙련자는 사전(6.51)에서 파지(6.48)로 비숙련자와 동일하게 차이가 나타나지 않았다. 스윙 크기의 일관성 역시 머신러닝 집단이 비숙련자와 숙련자에서 크게 향상되었다. 자기조절 집단의 경우 템포와 동일하게 숙련도에 상관없이 효과가 나타나지 않았다.

스윙 크기는 백스윙과 팔로스루로 구분하였으며, 스윙 크기는 템포와 함께 공이 임팩트 후 움직이는 절대거리에 중요한 요인이다(Tanaka & Iwami, 2018). 스윙 크기의 일관성에서 두 집단에서는 머신러닝 집단이 숙련도와 상관없이 향상된 결과가 나타났다. 세부적으로 살펴보면 머신러닝 집단에서 비숙련자의 백스윙 오차는 사전(4.05cm)에서 파지(3.2cm)로 약 0.9cm 향상되었으며 팔로스루 오차는 사전(4.39cm)에서 파지(3.26cm)로 약 1.1cm 향상되었다. 그에 반해 자기조절 집단의 비숙련자는 백스윙 사전(4.09cm)에서 파지(3.92cm), 팔로스루 사전(4.4cm)에서 파지(4.17cm)로 두 가지 모두 차이가 거의 나타나지 않았다. 숙련자의 경우 머신러닝 집단은 백스윙 사전(3.24cm)에서 파지(2.59cm)로, 팔로스루 사전(3.39cm)에서 파지

(2.85cm)로 약 0.6~0.7cm 오차범위가 향상된 결과가 나타났다. 자기조절 집단은 백스윙 사전(3.31cm)에서 파지(3.1cm)로, 팔로스루 사전(3.45cm)에서 파지(3.31cm)로 비숙련자와 같이 차이가 거의 나타나지 않았다. 이를 통해 자기조절 피드백은 퍼팅 과제에서 스윙 템포나 스윙 크기의 일관성 향상에는 숙련도와 무관하게 효과가 나타나지 않음을 확인했다. 그에 반해 고유템포 훈련 결과 스윙 템포와 스윙 크기 일관성 향상에 효과적임을 확인했다.

이러한 결과는 템포의 일관성 향상을 위해서는 청각 피드백을 활용해야 한다는 연구(Elliot et al., 2010; Repp et al., 2004), 퍼팅 과제에서 청각 피드백을 활용하여 특정 템포(2:1)를 따라하게 한 결과 퍼팅 수준을 향상시킨 연구(Kooyman et al, 2013)를 지지하는 연구 결과가 나타났다. 특정 템포를 따라 하기 위해서는 개인의 내적 템포와 차이가 있을 때 이를 다시 수정하기 위한 과정이 요구된다. 결국 1차적으로 특정 템포와 본인의 템포를 일치시키기 위한 수정 과정을 거친 후 다시 일관성 향상을 위한 노력을 해야 한다. 그러나 본 연구에서는 개인의 내적 템포의 일관성을 향상을 위한 노력만으로도 향상된 결과가 나타난 것을 통해 개인 내적템포 향상이 운동수행에 긍정적인 영향을 가져올 수 있는 연구를 지지하고 있다(Marius et al, 2014). 즉, 지속적인 박자에 맞춘 일련의 점진적인 연습을 통해 운동 계획(motor planning) 및 순차적 처리(sequencing)의 향상에 따른 타이밍(timing), 템포(tempo)로 동작이 개선되었다고 볼 수 있다(Jantzen et al., 2008).

3. 퍼팅 수행 수준 변화량(putting performance variability)

성공적인 퍼팅을 위해서 다양한 요인을 확인한 본 연구에서 도출된 결과를 바탕으로 학습방법에 따른 학습시기별 퍼팅 수행 수준의 변화량(Karlsen et al., 2008; Richardson et al., 2018)을 살펴보기 위해 숙련도에 따른 산점도를 통해 살펴보았다 <그림 29, 30>. 퍼팅 수행 수준 변화량은 퍼팅 과제 수행 시 퍼터의 움직임 요인(임팩트 각도)과 공 속도를 종합하여 거리와 방향에 따른 퍼팅 수행 수준을 복합적으로 알아보는 것으로 퍼팅 수준 숙련도가 높을수록 수치가 낮게 나온다. 선행연구를 통해 퍼팅 숙련도가 매우 높은 선수들의 경우 약 0.2에서 0.4 사이로 나타나고 있다.

결과를 살펴보면 머신러닝 집단과 자기조절 집단 모두 사전검사에 비해 파지검사에서 퍼팅 학습의 효과가 나타나고 있다. 비숙련자와 숙련자 모두 효과가 나타나고 있음을 통해 선행연구들의 결과를 지지하고 있다. 학습에 따르는 과정을 살펴보았을 때 머신러닝 집단의 경우 비숙련자와 숙련자에서 학습에 따른 효과가 크게 나타나고 있음을 알 수 있다. 또한, 자기조절 집단과는 다르게 학습이나 사후 과정보다 파지검사에서 더 나은 결과가 나온 인원들이 다수로 확인되어 본 연구의 실험 집단의 효과가 크게 나타나고 있음을 알 수 있다.

특이점으로 숙련자의 경우 자기조절 집단의 경우 머신러닝 집단보다 9명이 사전보다 대체로 고루 나은 결과가 나타났는데 머신러닝 집단에서는 자기조절 집단보다 큰 효과가 나타난 7명이 있었으나 2명의 경우 작지만, 사전보다 수행력이 감소하는 결과가 나타났다. 자기조절 집단의 경우 수행자가 스스로 수행을 통해 동기부여와 피드백 정보를 통해 능동적으로 학습했지만, 머신러닝 집단의 경우 템포와 스윙 크기 정보의 지속적인 제공을 통해 자기조절 집단보다 수동적인 요인이 개입되었다. 숙련자의 경우 숙련도가 높은 만큼 퍼팅 과제 수행 시 이러한 피드백 요인이 수행력 향상에 역

효과를 불러올 수 있음을 유추해 볼 수 있다. 즉, 이러한 학습을 숙련자에게 적용할 때는 고려해야 함을 알 수 있다.

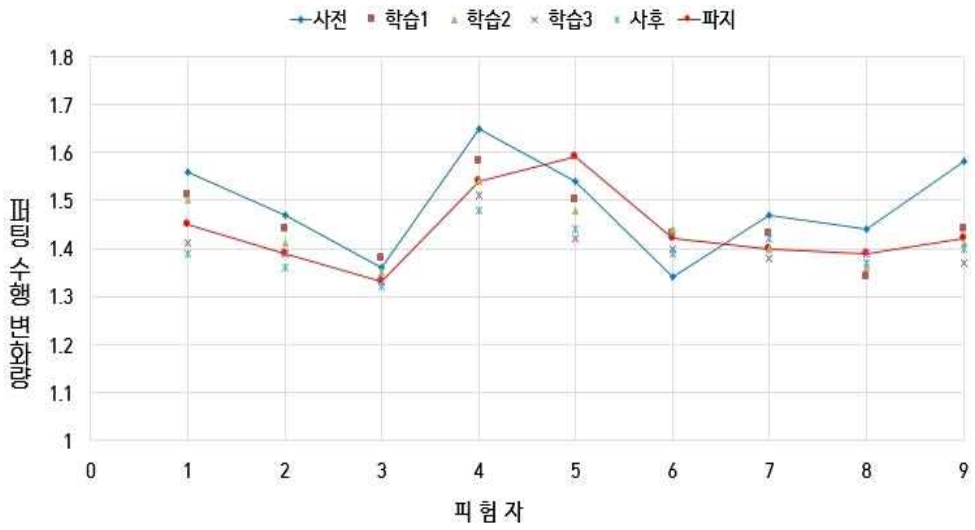

그림 31. 자기조절 집단 비숙련자 퍼팅 수행 수준 변화

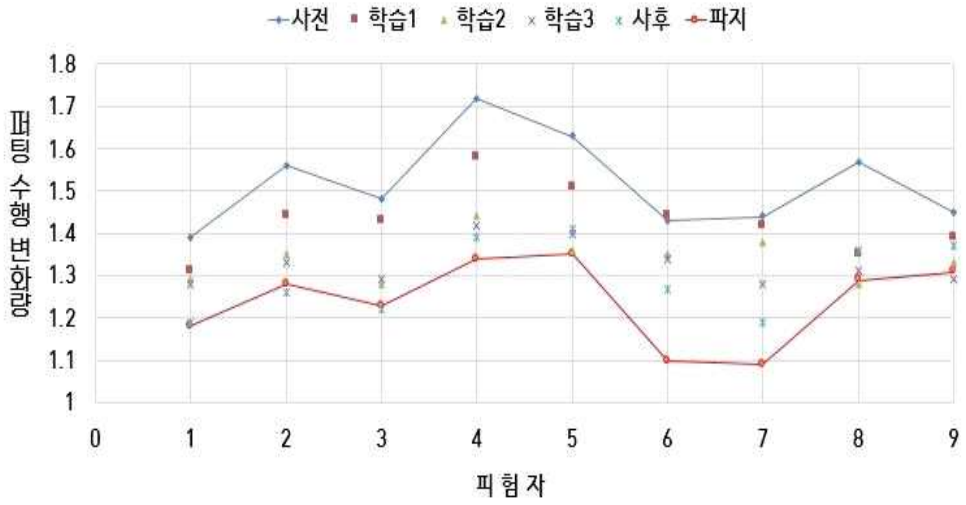

그림 32. 머신러닝 집단 비숙련자 퍼팅 수행 수준 변화

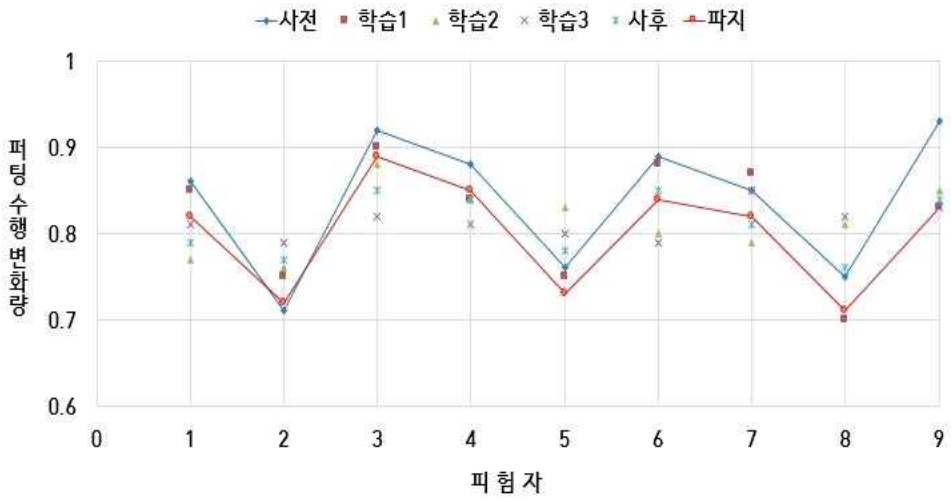

그림 33. 자기조절 집단 숙련자 퍼팅 수행 수준 변화

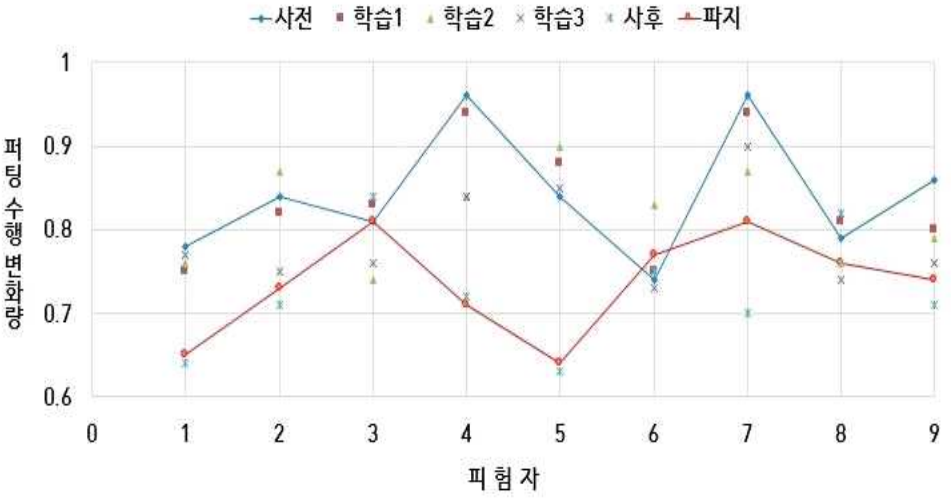

그림 34. 머신러닝 집단 숙련자 퍼팅 수행 수준 변화

논의를 종합하면, 본 연구에서는 개인차를 고려한 퍼팅 학습 훈련의 숙련도에 따른 차이를 검증하였다. 기술의 개발에 따른 머신러닝 알고리즘을 활용하여 퍼팅 과제 수행 시 다양한 정보를 분석하고 통합하여 퍼팅 학습에 적용한 결과 기존 학습법보다 다양한 퍼팅 상황에서 효과적으로 나타났

다. 증강현실을 활용하여 수행자들에게 몰입감과 현실감을 높였으며, 유용한 가상 정보를 시각과 청각 피드백을 활용하여 퍼팅 학습 수준을 효과적으로 높였다. 또한, 머신러닝을 활용하여 눈으로 보지 못하거나 적용하기 어려운 수많은 데이터를 빠르게 분석하고 패턴을 파악하여 개인차를 고려하여 효율적인 퍼팅 학습방법을 확인할 수 있었다. 본 연구 결과를 통해 퍼팅 학습뿐만 아니라 고유감각 일관성 향상을 통한 운동학습 연구에 활용될 수 있을 것으로 기대한다.

VI. 결론

골프 퍼팅 과제는 다양한 근육과 관절을 활용하는 아이언이나 드라이버 스윙과는 다르게 고유감각 요인인 템포와 스윙 패턴, 경사와 거리에 따른 계산까지 필요한 신체-감각-인지 능력이 요구되는 복합적인 과제이다. 즉, 개인의 신체 구조와 고유수용감각을 고려해야 하는 만큼 획일화된 퍼팅 학습 도구나 방법만으로는 운동학습의 궁극적 목표인 체계적이며 효율적인 목적을 달성하기 어려울 수 있다. 최근 머신러닝의 발전에 따라 운동수행 과제에서 복합적인 요인을 고려한 운동학습이 가능해진 만큼 이를 퍼팅 과제에 접목하여 본 연구의 결론은 다음과 같다.

1. 퍼팅 성공률은 머신러닝 AR 프로그램을 적용한 숙련자 집단에서 효과적으로 나타났다. 비숙련자의 경우 사전 성공률이 숙련자보다 낮았음에도 불구하고 숙련자의 학습 효과가 높게 나타났다. 이를 통해 본 연구에서 활용된 실제와 유사한 상황을 통해 퍼팅 수행에 인지적인 부하가 추가된 경우 비숙련자는 성공률을 높일 정도로 퍼팅 수행 수준이 향상되지는 않은 것으로 유추해 볼 수 있다.

2. 평균 오차범위에서는 머신러닝 AR 프로그램을 적용한 집단(비숙련자, 숙련자)에서 매우 효과적으로 나타났다. 숙련도와 무관하게 두 그룹 모두 홀컵 오차 범위가 약 20cm 근접하게 나타난 만큼 개인의 고유감각을 강화하는 학습 훈련이 효과적이었음을 알 수 있다. 본 연구에서 활용된 개인별 고유감각 요인 중 하나인 템포와 스윙 크기 일관성 학습 훈련이 선행연구의 특정 템포에 따라가는 것이 아닌 개인의 고유감각의 일관성을 향상하는 것으로도 수행력이 향상되는 것을 확인할 수 있었다. 평균 오차범위는 홀컵 성공률에 영향을 미치는 요인은 아니지만, 홀컵에 근접하게 실패할수록

다음 퍼팅의 부담을 줄여주는 것으로 3퍼트 확률 감소에 따른 퍼팅 수행력 향상에서 중요한 요인인 만큼 아마추어 골퍼들에게 더욱 효과적인 학습방법이 될 수 있음을 결론 내릴 수 있다.

3. 퍼터 헤드의 움직임에서 임팩트 각도는 일관성을 확인하였다. 머신러닝 AR 프로그램을 적용한 집단에서 임팩트 각도의 변화는 비숙련자에게서 가장 큰 효과가 나타났으며 숙련자 역시 사전에 비해 파지에서 유의한 수준으로 향상되었다. 자기조절 집단은 비숙련자는 사전에 비해 파지에서 오히려 감소 된 일관성이 나타났으며 숙련자는 차이가 나타나지 않았다. 이를 통해 퍼터 헤드 각도에 대한 정보를 주지 않았음에도 템포와 스윙 크기 훈련이 퍼터 헤드의 움직임 조절에 간접적인 학습 효과를 가져올 수 있음을 추론해볼 수 있다.

4. 퍼터 헤드 움직임의 퍼팅 속도 일관성에서는 자기조절 집단은 효과가 나타나지 않았으며, 머신러닝 집단은 비숙련자, 숙련자 모두 향상된 결과가 나타났다.

5. 템포의 일관성 변화는 머신러닝 AR 프로그램을 적용한 집단이 자기조절 집단보다 비숙련자, 숙련자 모두 매우 효과적으로 나타났다. 비숙련자의 경우 20% 이상 향상되었으며 숙련자는 15% 향상되었다. 자기조절 집단에서는 변화가 나타나지 않았다.

6. 스윙 크기의 일관성(BS, FT)의 경우 머신러닝 집단은 사후 및 파지에서 모두 크기 일관성이 향상되었다. 템포의 일관성과 함께 스윙 크기의 일관성이 복합적으로 향상된 것으로 유추해 볼 수 있다. 자기조절 집단은 향상되는 경향성은 나타났으나 향상 정도가 미비하였다.

7. 퍼팅 수행 변화량을 통해 자기조절 집단과 머신러닝 집단에서 비숙련자와 숙련자 모두 크기와 인원의 차이는 있지만 학습 효과는 선행연구와 같이 향상된 것을 확인했다. 그중 머신러닝 AR 프로그램을 적용한 집단은 그렇지 않은 집단보다 학습 효과가 더 크게 나타났으며, 본 연구의 숙련도에 따른 적용 범위에서 숙련도와 무관하게 모두 효과가 나타날 수 있음을 확인했다.

VII. 제언

본 연구를 통해 후속 연구를 진행을 위해 고려해야 하는 주요 사항과 제한점을 제시하면 다음과 같다.

첫째, 거리와 경사에 따른 퍼팅 학습과제에서 복합적인 경사 상황 또는 다양한 거리에 따른 변화를 확인할 필요가 있다. 본 연구에서는 경사도가 오르막, 내리막, 옆 라이만 형성되어 있었는데 2가지 경사가 복합적으로 나타날 때 수행자에게 추가적인 경사에 대한 인지 부하 상황에 대한 학습 변화를 확인해야 할 것이다. 또한, 5m 또는 10m 이상의 긴 거리에 대한 퍼팅 과제 수행 시 본 연구의 훈련법이 적용 가능한지를 확인할 필요성이 있다.

둘째, 고유감각 요인에서 내적 템포 요인의 일관성 향상을 활용한 훈련의 원리를 여러 운동과제에서 적용할 필요성이 있다. 본 연구에서는 퍼팅 과제에서 거리와 경사에 따른 인지-수행상황에서 개인의 템포 및 스윙 크기 요인을 분석한 머신러닝 프로그램과 증강현실을 활용하여 학습 훈련에 적용하였다. 그 결과 숙련자와 비숙련자 모두 긍정적인 결과가 나온 만큼 다양한 운동과제와 학습자 특성에 알맞은 접근을 통해 학습 효과를 다양한 곳에서 확인할 수 있는 사례가 필요할 것이다.

셋째, 퍼팅 과제는 어드레스, 백스윙, 다운스윙, 임팩트, 팔로스루 형태로 순서별 운동학적 및 운동 역학적 원리가 있다. 본 연구에서는 이들 협응 패턴의 학습 정보와 변화는 확인하지 않았다. 이에 추후 연구에서 본 연구의 원리를 접목하여 신체 관절이나 협응 패턴의 변화를 확인할 필요성이 있다.

참고문헌

고경리, & 반성범. **(2019)**. 딥러닝을 이용한 스윙 시퀀스 영상 기반 3 차원 골프 스윙 분석. **전자공학회논문지, 56(10), 49-55.**

김연호 & 이기광 **(2022).** 머신러닝 기반 골프 퍼팅 방향 예측 모델을 활용한 중요 변수 분석 방법론. **한국운동역학회지, 32(1), 1-8.**

김선진. **(2000). 운동학습과 제어(개정판).** 서울: 대한미디어.

계보경, & 김영수. (2008). 증강현실 기반 학습에서 매체특성, 현존감, 학습몰입, 학습효과의 관계 규명. **교육공학연구, 24(4), 193-224.**

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

임형진. **(2008).** 퍼터의 라이각과 로프트각이 퍼팅한 공의 방향성에 미치는 영향. **대한기계학회 춘추학술대회, 1496-1500.**

장재훈, & 박동수. (2013). 골프의 개념과 학문적 가치. **골프연구, 7(2), 88-97.**

Alexander, D. L., & Kern, W. (2005). Drive for show and putt for dough? An analysis of the earnings of PGA Tour golfers. *Journal of sports Economics, 6(1),* 46-60.

Anderson, D. I., Magill, R. A., & Sekiya, H. (2001). Motor learning as a function of KR schedule and characteristics of task-intrinsic feedback. *Journal of motor behavior, 33*(1), 59-66.

Azuma, R. T. (1997). A survey of augmented reality. *Presence: teleoperators & virtual environments, 6*(4), 355-385.

Bernstein, L. A. (1967). The concept of materiality. *The accounting review, 42*(1), 86-95.

Billinghurst, M. (2002). Augmented reality in education. *New horizons for learning, 12*(5), 1-5.

Blackwell, J. R., & Newell, K. M. (1996). The informational role of knowledge

of results in motor learning. *Acta Psychologica, 92*(2), 119-129.

Chiviacowsky, S., & Wulf, G. (2002). Self-controlled feedback: Does it enhance learning because performers get feedback when they need it?. *Research quarterly for exercise and sport, 73*(4), 408-415.

Chiviacowsky, S., Wulf, G., Wally, R., & Borges, T. (2009). Knowledge of results after good trials enhances learning in older adults. *Research quarterly for exercise and sport, 80*(3), 663-668.

Chiviacowsky, S., Harter, N. M., Gonçalves, G. S., & Cardozo, P. L. (2019). Temporal-comparative feedback facilitates golf putting. *Frontiers in Psychology*, 2691.

Couceiro, M. S., Portugal, D., Gonçalves, N., Rocha, R., Luz, J. M. A., Figueiredo, C. M., & Dias, G. (2013). A methodology for detection and estimation in the analysis of golf putting. *Pattern Analysis and Applications, 16*(3), 459-474.

Craig, C. M., Delay, D., Grealy, M. A., & Lee, D. N. (2000). Guiding the swing in golf putting. *Nature, 405*(6784), 295-296.

Delay, D., Nougier, V., Orliaguet, J. P., & Coello, Y. (1997). Movement control in golf putting. *Human Movement Science, 16(5)*, 597-619.

Dias, G., Couceiro, M. S., Barreiros, J., Clemente, F. M., Mendes, R., & Martins, F. M. (2014). Distance and slope constraints: adaptation and variability in golf putting. *Motor Control, 18*(3), 221-243.

Drake, C., Jones, M. R., & Baruch, C. (2000). The development of rhythmic attending in auditory sequences: attunement, referent period, focal attending. *Cognition, 77*(3), 251-288.

Filipczak, B. (1995). Putting the learning into distance learning. *Training, 32*(10), 111-12.

Friedman, J. H. (2001). Greedy function approximation: a gradient boosting

machine. *Annals of statistics*, 1189-1232.

Golf Society of Great Britain (England), COCHRAN, A., Noble, D., & STOBBS, J. L. N. (1968). T**he Search for the Perfect Swing**. By Alastair Cochran and John Stobbs. With Assistance from David Noble and Others, Etc.(An Account of the Golf Society of Great Britain Scientific Study.)[With Illustrations.]. Heinemann.

Hebert, E. P., & Coker, C. (2021). Optimizing feedback frequency in motor learning: self-Controlled and moderate frequency KR enhance skill acquisition. *Perceptual and Motor Skills, 128*(5), 2381-2397.

Heuler, O. (1995). *Perfecting your golf swing: New ways to lower your score*. Sterling Publishing Company Incorporated.

Hopwood, M. J., Mann, D. L., Farrow, D., & Nielsen, T. (2011). Does visual-perceptual training augment the fielding performance of expert cricketers?. *International Journal of Sports Science & Coaching, 6*(4), 523-535.

Ikeda, A., Hwang, D. H., & Koike, H. (2019, March). *A real-time projection system for golf training using virtual shadow*. In 2019 IEEE Conference on Virtual Reality and 3D User Interfaces (VR) (pp. 1527-1528). IEEE.

Ishikura, T. (2008). Reduced relative frequency of knowledge of results without visual feedback in learning a golf-putting task. *Perceptual and motor skills, 106*(1), 225-233.

Itoh, Y., Orlosky, J., Kiyokawa, K., & Klinker, G. (2016, February). *Laplacian vision: Augmenting motion prediction via optical see-through head-mounted displays*. In Proceedings of the 7th Augmented Human International Conference 2016 (pp. 1-8).

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

Karlsen, J., & Nilsson, J. (2008). Distance variability in golf putting among highly expert players: *The role of green reading. International Journal of Sports Science & Coaching, 3*(1_suppl), 71-80.

Karlsen, J., Smith, G., & Nilsson, J. (2008). The stroke has only a minor influence on direction consistency in golf putting among elite players. *Journal of Sports Sciences, 26(3)*, 243-250.

Keogh, J. W., & Hume, P. A. (2012). Evidence for biomechanics and motor learning research improving golf performance. *Sports Biomechanics, 11(2*), 288-309.

Kim, M., & Park, S. (2020). Golf swing segmentation from a single IMU using machine learning. *Sensors, 20*(16), 4466.

Kelly, P., & O'Connor, N. E. (2012, May). *Visualisation of tennis swings for coaching*. In 2012 13th International Workshop on Image Analysis for Multimedia Interactive Services (pp. 1-4). IEEE.

Knight, C. A. (2004). Neuromotor issues in the learning and control of golf skill. *Research Quarterly for Exercise and Sport, 75*(1), 9-15.

Kosmalla, F., Daiber, F., Wiehr, F., & Krüger, A. (2017, October). *Climbvis: Investigating in-situ visualizations for understanding climbing movements by demonstration*. In Proceedings of the 2017 ACM International Conference on Interactive Surfaces and Spaces (pp. 270-279).

Lacko, J. (2020, January). Health safety training for industry in virtual reality. *In 2020 Cybernetics & Informatics (K&I) (pp. 1-5)*. IEEE.

Lee, A. M., Keh, N. C., & Magill, R. A. (1993). Instructional effects of teacher feedback in physical education. *Journal of Teaching in Physical Education, 12*(3), 228-243.

MacKenzie, S. J., & Sprigings, E. J. (2009). Understanding the role of shaft stiffness in the golf swing. *Sports engineering, 12*(1), 13-19.

Magill, R. A., & Schoenfelder-Zohdi, B. R. I. T. T. A. (1996). A visual model and knowledge of performance as sources of information for learning a rhythmic gymnastics skill. I*nternational Journal of Sport Psychology, 27*(1), 7-22.

McLaughlin, P., Best, R., & Carlson, J. (2008). Movement of the centre of pressure (COP) in the putting stroke. *In Science and golf V: Proceedings of the World Scientific Congress of Golf*. Mesa, Arizona: Energy in Motion (pp. 239-244).

Mekni, M., & Lemieux, A. (2014). Augmented reality: Applications, challenges and future trends. *Applied computational science, 20*, 205-214.

Milgram, P., & Kishino, F. (1994). A taxonomy of mixed reality visual displays. *IEICE TRANSACTIONS on Information and Systems, 77*(12), 1321-1329.

Mills, R., & Paul, R. (1993). *Putting the student first: Management for quality in distance education*. Reforming open and distance education: Critical reflections from practice, 113-129.

Munzert, J., Maurer, H., & Reiser, M. (2014). Verbal-motor attention-focusing instructions influence kinematics and performance on a golf-putting task. *Journal of motor behavior, 46*(5), 309-318.

Nasteski, V. (2017). An overview of the supervised machine learning methods. *Horizons. b, 4,* 51-62.

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

Paradisis, G., & Rees, J. (2000). Kinematic analysis of golf putting for expert and novice golfers. In *ISBS-Conference Proceedings Archive*.

Pelz, D. (2000). *Dave Pelz's putting bible: the complete guide to mastering the green* (Vol. 2). Doubleday Books.

Phu, S., Vogrin, S., Al Saedi, A., & Duque, G. (2019). Balance training using virtual reality improves balance and physical performance in older adults at high risk of falls. *Clinical interventions in aging, 14*, 1567.

Rhoads, M. C., Da Matta, G. B., Larson, N., & Pulos, S. (2014). A meta-analysis of visual feedback for motor learning. *Athletic Insight, 6*(1), 17.

Rice, M. S., & Hernandez, H. G. (2006). Frequency of knowledge of results and motor learning in persons with developmental delay. *Occupational therapy international, 13*(1), 35-48.

Richardson, A., Hughes, G., & Mitchell, A. (2012). Center of Pressure Excursion During the Golf Putting Stroke in Low, Mid and High Handicap Golfers. *International Journal of Golf Science*.

Richardson, A. K., Mitchell, A. C., & Hughes, G. (2018). The effect of movement variability on putting proficiency during the golf putting stroke. *International Journal of Sports Science & Coaching, 13(4)*, 590-597.

Rivière, J. P., Alaoui, S. F., Caramiaux, B., & Mackay, W. E. (2019). *Capturing movement decomposition to support learning and teaching in contemporary dance*. Proceedings of the ACM on Human-Computer Interaction, 3(CSCW), 1-22.

Rommers, N., Rössler, R., Verhagen, E., Vandecasteele, F., Verstockt, S., Vaeyens, R., ... & Witvrouw, E. (2020). A machine learning approach to assess injury risk in elite youth football players. *Medicine and science in sports and exercise, 52*(8), 1745-1751.

Rossi, A., Pappalardo, L., Cintia, P., Iaia, F. M., Fernández, J., & Medina, D. (2018). Effective injury forecasting in soccer with GPS training data and machine learning. *PloS one, 13*(7), e0201264.

Salehi, S. K., & Orak, L. L. (2020). The effect of knowledge of performance

feedback and task difficulty on performance and learning of baske tball chess pass: challenge based learning approach. *European Journal of Physical Education and Sport Science*. *7*(20)

Salmoni, A. W., Schmidt, R. A., & Walter, C. B. (1984). Knowledge of results and motor learning: a review and critical reappraisal. *Psychological bulletin, 95*(3), 355.

Schmidt, R. A., Lee, T. D., Winstein, C., Wulf, G., & Zelaznik, H. N. (1999). *Motor control and learning: A behavioral emphasis*. Human kinetics.

Shafizadeh, M., McMorri, T., & Sproule, J. (2011). Effect of different external attention of focus instruction on learning of golf putting skill. *Perceptual and motor skills, 113*(2), 662-670.

Sidaway, B., Bates, J., Occhiogrosso, B., Schlagenhaufer, J., & Wilkes, D. (2012). Interaction of feedback frequency and task difficulty in children's motor skill learning. *Physical therapy, 92*(7), 948-957.

Sim, M., & Kim, J. U. (2010). Differences between experts and novices in kinematics and accuracy of golf putting. *Human movement science, 29*(6), 932-946.

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.

Soltani, P., & Morice, A. H. (2020). *Augmented reality tools for sports education and training*. Computers & Education, 155, 103923.

Tanaka, H., & Iwami, M. (2018). Estimating putting outcomes in golf: Experts have a better sense of distance. *Perceptual and motor skills, 125*(2), 313-328.

Teunissen, J. W., Rommers, N., Pion, J., Cumming, S. P., Rössler, R., D'Hondt, E., ... & Malina, R. M. (2020). Accuracy of maturity prediction

equations in individual elite male football players. *Annals of Human Biology, 47*(4), 409-416.

Turner, C. J., Hutabarat, W., Oyekan, J., & Tiwari, A. (2016). Discrete event simulation and virtual reality use in industry: new opportunities and future trends. *IEEE Transactions on Human-Machine Systems, 46*(6), 882-894.

Vatanpour, F. A. M., & Khosravi, S. B. M. Investigating the process of upgrading hand skills in dart throwing using augmented reality.

Wang, H., Lei, Z., Zhang, X., Zhou, B., & Peng, J. (2016). *Machine learning basics*. Deep learning, 98-164.

Winstein, C. J., & Schmidt, R. A. (1990). Reduced frequency of knowledge of results enhances motor skill learning. *Journal of Experimental Psychology: Learning, Memory, and Cognition, 16*(4), 677.

Wiren, G. Golf, *building a solid game*. Englewood Cliffs, NJ: Prentice-Hall, 1992.

Witkowski, K., Sobecki, J., Maslinski, J., Cieslinski, W., Rokita, A., & Kalina, R. M. (2016). *The use of augmented-reality technology to improve judo techniques. Premises, assumptions, methodology, research tools, preliminary scenarios-the first stage of the study*. Archives of Budo, 12, 355-367.

Wulf, G., Chiviacowsky, S., & Lewthwaite, R. (2010). Normative feedback effects on learning a timing task. *Research quarterly for exercise and sport, 81*(4), 425-431.

Young, D. E., & Schmidt, R. A. (1992). Augmented kinematic feedback for motor learning. *Journal of motor behavior, 24*(3), 261-273.

Zanone, P. G., & Kelso, J. S. (1997). Coordination dynamics of learning and transfer: collective and component levels. *Journal of Experimental Psychology: Human Perception and Performance, 23*(5), 1454.

Zhang, L., & Li, N. (2021). *Material analysis and big data monitoring of sports*

training equipment based on machine learning algorithm. Neural Computing and Applications, 1-15.

Abstract

A Study on Augmented Reality Putting Training Using Machine Learning Technology : Focusing on Changes According to Skill Level

Lee, Dong Youn
Department of Physical Education
The Graduate School
Seoul National University

There are various patterns of individual differences in the putting task, and the performance level is determined according to the correct cognitive ability and performance ability. Individual difference is a proprioceptive factor, and it is necessary to study how to learn how to putt successfully. The purpose of this study is to suggest an efficient putting learning method through comparison between a group applying augmented reality feedback using a machine learning program considering individual differences and a general putting training group using self-controlled feedback. The subjects who

participated in the study were 36 adults between the ages of 20 and 40, 18 expert (handicap less than 10, experience more than 3 years) and 18 novice (handicap more than 30, experience less than 2 years). 9 participants were divided into a machine learning group and a self-controlled group (4 groups). Participants performed putting tasks according to the distance (1m, 2.5m, 3.5m) and direction (12 hole cup standards). Based on the pretest data, the machine learning group received visual and auditory feedback on individual putting tempo and swing size in consideration of individual differences, and the self-adjustment group received feedback on the success rate and mean radial error. A post-test was conducted after the learning process three times, and a gripping test was conducted after 48 hours. To confirm the change in putting learning, the success rate, mean radial error (MRE), and putter head movement (impact angle, speed, tempo) were checked, and the average and standard deviation were calculated and analyzed for comparison. The results are as follow. First, the putting success rate was effectively shown in the expert group to which machine learning was applied. In the mean radial error, both the novice and expert groups to which machine learning was applied appeared more effective than the self-controlled group. As a result of examining the consistency of the impact angle in the movement of the putter head, it appeared effective in the machine learning novice group, but did not appear in the self-adjustment group. Regarding the consistency of putting speed, the self-controlled group showed no effect, and the machine learning group showed improved results for both expert and novice. In the consistency of tempo, the machine learning group improved significantly as a result of checking the standard deviation of tempo based on individual successful putting. Consistency

improved by about 20% for the novice, and about 15% for the expert. Regarding the consistency of the swing size of the backswing and follow-through, the self-controlled group showed an improved tendency, although it was not statistically significant, and the machine learning group showed improved consistency for both the expert and novice. In summary, this study applied the proprioceptive (internal tempo) factor considering individual differences to the distance x incline putting performance situation with high cognitive-performance load using a machine learning program. Due to the nature of the putting task, the learning effect was confirmed through learning to develop consistency in consideration of individual unique senses. Through this, it will be possible to apply the research results in the actual field and use them for putting learning, and we tried to categorize them through the results according to the level of proficiency.

Key words : Putting, proprioception, machine learning, augmented reality, self-controlled feedback, putting accuracy, putting level, putting proficiency

Student Number : 2018 - 30597