

LSTM을 이용한 태권도 경기의 변칙 발차기 탐지 연구

조단비*, 이현영*, 강승식*

*국민대학교 컴퓨터공학과

{daanv319, hyunyoung2, sskang}@kookmin.ac.kr

A Study on the Detection of Anomalous Kicks in Taekwondo games by using LSTM

Dan-Bi Cho*, Hyun-Young Lee*, Seung-Shik Kang*

*Dept. of Computer Science, Kookmin University

요 약

태권도 경기와 같이 동작의 정확한 기술을 판별하여 유효득점화하는 시스템에서는 점수 체계의 정확성과 전문성이 필요하다. 기존에 시행되었던 심판 판정은 객관성과 신뢰성의 결여 문제가 존재하여 이를 대체하기 위한 방법으로 전자호구가 도입되었다. 하지만 전자호구는 타격 강도에 따라 분류되는 문제로 인해 태권도 기술이 아닌 변칙 발차기 기술에서도 유효득점이 처리되는 문제가 발생하였다. 본 논문에서는 변칙 발차기와 일반 발차기를 분류하여 변칙 발차기에서의 유효득점을 무효 득점화 시키기 위한 분류 모델을 제안하였다. 순환 신경망 모델인 LSTM을 이용하여 변칙 발차기와 일반 발차기를 분류하였으며 94.90%의 정확도를 보였다.

1. 서론

태권도 경기는 기술 동작의 행위가 발생함과 동시에 판정이 선언되며 이를 점수화하여 최종적으로 누적된 유효득점을 통해 승패를 결정한다. 실시간으로 점수화되는 경기에서 정확한 기술을 판별해야 하지만 심판 판정의 경우 주관적 개입 혹은 정확한 점수 체계가 이루어지지 않아 객관성과 신뢰성의 문제가 존재한다 [1]. 경기의 득점 판정을 객관적으로 평가하기 위해 세계태권도연맹에서는 ‘전자호구’를 도입하였으며 센서를 이용하여 타격 강도에 따른 유효득점 판정이 이루어졌다[2].

조은형(2007)은 통계적 접근 방법으로 전자호구를 이용한 득점 판정의 현장 타당성을 연구하였다. 전자호구를 이용한 득점 판정은 타격 강도, 연속 타격 인식 등의 기계적 타당도 측면에서 검증된다. 하지만 경기 중에 나타나는 변칙 기술을 판별하지 못하는 단점이 있으며 팔꿈치, 겨안기 등에 의한 무효 타격에서도 센서 감지를 통해 점수화되는 문제가 나타났다 [2].

양대승(2009)은 전자호구 도입 전과 후의 체급별 평균 득점과 감점, 금지행위에 의한 점수화 문제

에 대하여 분석하였다 [3]. 조은형(2009)은 심판의 판정에 따라 점수화되는 기존의 방식과 객관적인 지표를 위한 전자호구 방식의 차이를 비교하고 심판의 객관성과 신뢰성 문제, 전자호구의 전문성 문제를 지적하였으며 득점 판정의 오차를 줄임으로써 전문성과 객관성을 증가시키는 전자호구 도입의 필요성에 대하여 분석하였다 [4].

정확한 태권도 기술이 아닌 변칙 발차기를 분별하지 못해 유효 득점화되는 전자호구의 문제점을 보완하기 위해 딥러닝을 이용하여 변칙 발차기를 탐지하는 분류 모델을 제안한다. 변칙 발차기는 제기차기 형식으로 상대와 가까운 거리에 대치되어있는 상황에서 발을 몸통에 맞대는 몽키킥이 대표적이며 이러한 변칙 기술의 득점 판정을 해결하여 태권도 전자호구의 점수 체계 시스템을 보완하고자 한다.

센서가 부착된 전자호구를 통해 선수들의 겨루기 경기를 시연하여 시계열 데이터를 구축하였으며 이를 딥러닝에 적용하여 일반 발차기와 변칙 발차기를 분류하는 모델을 제안한다. 일반 발차기와 변칙 발차기를 분류하여 변칙 발차기로 인한 유효득점을 최소화하는 것을 목적으로 하며 전자호구 시스템의 객관성과 전문성이 향상될 것으로 예상된다.

<표 1> 데이터 구축을 위해 실행한 발차기 유형 별 발차기 동작

발차기 유형		발차기 동작
변칙 발차기		몽키킥, 몽키킥(상단)
일반 발차기	밀어차기류	밀어차기(수비형 하단), 밀어차기(공격형 하단), 깡 밀어차기(공격형 하단)
	옆밀어차기류	깡 옆 밀어차기(공격형 하단), 커트 옆 밀어차기(공격형), 커트 옆 밀어차기(수비형)
	돌려차기류	택견식 돌려차기(하단), 붙은 후 돌려차기(접어서), 빠른발 돌려차기(하단)

2. 센서 데이터를 이용한 변칙 발차기 분류 모델

2.1 데이터 구축 및 데이터 증폭

전자호수에 IMU(Inertia Measurement Unit) 센서를 부착하여 근진도(Electromyogram), 각속도(Gyroscope), 가속도(Accelerometer), 지자계(Magnetometer)의 특징값을 기록하였다. IMU 센서는 총 11개(머리, 가슴, 단진, 양쪽 팔, 양쪽 허벅지, 양쪽 발목, 양쪽 발)를 부착하였으며 관성 센서의 흔들림과 이동을 최소화하도록 고정하였다.

IMU 센서를 부착하여 총 11가지의 발차기 동작을 실행하였으며 유형 별 발차기 동작은 표 1과 같다. 11개의 발차기에 대한 IMU 센서에서 기록된 4가지 특징값을 4d motion program¹⁾을 이용하여 총 33개의 특징에 대한 248프레임²⁾의 시계열 데이터로 변환하였다.

구축된 데이터는 하나의 발차기 동작 $x_i = (248 \times 33)$ 을 11개의 발차기에 대하여 실행한 $X = \{x_1, x_2, \dots, x_{11}\}$ 와 같이 구성하였다. 구축한 데이터는 11개의 동작에 대한 한 명의 데이터이기 때문에 데이터의 양이 부족하여 변칙 발차기를 분류하기 위한 모델을 학습하기에 부적합하다. 이를 해결하기 위해 본 논문에서는 데이터 증폭을 이용하여 학습 데이터를 확장하였다.

데이터 증폭은 식 (1)과 같이 248프레임 값을 갖는 33개의 특징(f)에서 0.5에서 1.5 사이의 실수 값을 무작위로 추출하여 더한 값으로 데이터를 변환하였다. 데이터의 등분산성을 유지하기 위해 무작위로 추출된 값을 더하였으며 하나의 특징이 나타내는 248프레임에는 동일한 값을 더하여 시계열 특성이 변형되지 않도록 하였다.

$$k_{i(248 \times f)} = x_{i(248 \times f)} + random(0.5, 1.5) \quad (1)$$

$$k_i = (k_{i(248 \times 1)}, k_{i(248 \times 2)}, \dots, k_{i(248 \times 33)})$$

데이터 증폭 기법을 이용하여 구성된 i 번째 발차기 k_i 를 총 11개의 발차기에 대하여 변형한 데이터 $K_1 = \{k_1, k_2, \dots, k_{11}\}$ 를 1만 명의 데이터로 확장하여 학습 데이터 $Aug = (K_1, K_2, \dots, K_{10k})$ 를 구축하였다. Aug 는 1만 명이 11개의 발차기 동작에 대하여 한 번씩 실행한 데이터이기 때문에 11개 발차기 동작 별 데이터의 수는 1만 개로 동일하다.

2.2 LSTM 모델

순환 신경망 모델은 데이터의 순차 정보를 포함하여 학습한다. 시계열이나 텍스트와 같이 연속된 데이터를 처리하며 하나의 연속된 데이터 $S = (s_1, s_2, \dots, s_n)$ 에서 i 번째 순차 정보 s_i 는 이전 순차 정보(s_1, s_2, \dots, s_{i-1})의 값을 포함하여 요약된 값으로 학습된다. 이전 순차의 학습 정보를 포함하여 학습된다는 장점이 있지만 시간이 지남에 따라 점진적으로 정보가 손실되는 문제가 존재한다. 이러한 문제를 완화시키는 모델로 LSTM(Long-Short Term Memory)이 소개되었으며 이는 이전 순차 정보 중 중요한 정보를 선별하여 저장하는 게이트 메커니즘을 포함하고 있다. 게이트 메커니즘은 이전 순차 정보 중 중요한 정보만을 저장하도록 하여 중요한 정보의 손실을 최소화하도록 한다 [5, 6, 7].

LSTM을 이용한 분류 모델 학습 시 학습 데이터를 8:2로 분할하여 검증한 최적화 모델로 분류 실험을 진행하였다. 최적화 모델의 파라미터로 학습률 0.001의 확률적 경사하강법(Stochastic Gradient Descent) 최적화 함수를 사용하였으며 교차 엔트로피(cross entropy)를 통해 모델의 손실을 최소화하도록 하였다. 또한 모델은 64개의 히든 유닛을 가지며 batch size 32, epochs 20의 반복 학습으로 설계하였다.

1) IMU 센서 기반 스포츠 코칭 어플이며 센서로 감지된 값을 위치 별 앞뒤 혹은 좌우 기울기 값, 회전 값, 관절각도의 속도, 좌우 가속도 합성 값 등 33개의 특징 값을 계산한다. (<https://4dmotionsports.com/>)
 2) 0.02초를 1프레임으로 하여 총 4.96초 동안의 시계열 값으로 나타난다.

<표 2> 발차기 분류 실험 정확도(%)

	2 class	4 class	11 class
Accuracy	94.90	33.97	27.27

3. 실험 및 결과

태권도 전자호구를 이용하여 득점하는 체계에서 변칙 발차기를 무효득점으로 처리하는 것은 태권도 경기에서 중요한 문제이다. IMU 센서가 부착된 전자호구를 착용하여 11개의 발차기 동작에 대한 데이터를 구축하였으며, 4d motion program을 통해 변환된 데이터를 학습 데이터로 사용하였다. 분류 모델을 위해 데이터 증폭 기법을 이용하여 1만 개의 데이터로 확장하였다. 248프레임에 대하여 시계열 형태로 구성된 증폭 데이터 Aug를 모델에 입력하기 위해 연속된 벡터 차원의 형태로 표현하였다. 하나의 발차기 동작 데이터는 하나의 특징이 248프레임을 구성하는 33차원의 벡터이며 1만 개의 학습 데이터로 구성되어 있기 때문에 증폭 데이터 Aug는 (1만, 248, 33) 형태의 벡터로 표현된다.

본 연구에서는 변칙 발차기를 분별하여 무효득점화하는 것이 연구의 목적이다. 이를 위해 변칙 발차기와 일반 발차기를 분류하는 이진 분류 실험을 진행하였으며 동일한 모델에 대하여 4가지 유형(변칙 발차기, 밀어차기류, 옆밀어차기류, 돌려차기류)과 11가지 발차기 별 분류 실험을 진행하였다.

두 가지 발차기 동작으로 실행된 변칙 발차기의 데이터 크기는 20k이기 때문에 데이터의 균형을 맞추기 위해 일반 발차기 90k 중 무작위로 20k의 데이터를 추출하여 총 40k 데이터로 분류 실험을 진행하였다. 각 유형 별 데이터를 8:2로 분할하여 학습 데이터와 평가 데이터를 유형 별 동일한 데이터 크기로 구성하도록 하였다.

4개의 발차기 유형 분류에서는 변칙 발차기가 20k개의 데이터로 구성되어 있는 것을 고려하여 각 유형 별 20k개의 데이터를 추출하여 총 80k개의 데이터로 실험을 진행하였다. 11개의 발차기 유형 분류에서는 10k개의 데이터를 구성하는 11개의 발차기 동작을 분류하는 실험으로, 110k 데이터를 사용하여 실험하였다. 이진 분류 실험과 동일하게 데이터를 8:2로 분할하여 LSTM에 적용하였다. 표 2는 분류 유형 별 정확도이며 본 논문에서 제안한 LSTM을 이용한 변칙 발차기와 일반 발차기의 이진 분류 실험에서 94.90%로 가장 높은 성능을 보였다.

4. 결론 및 향후 연구

변칙 발차기를 유효득점으로 처리하는 전자호구의 문제를 해결하기 위해 변칙 발차기 분류 모델을 제안한다. 데이터 증폭 기법을 통해 학습 데이터를 구축하고 시계열의 순차 정보를 효율적으로 처리하기 위해 LSTM을 적용하여 변칙 발차기와 일반 발차기를 분류한 결과, 94.90%의 정확도를 보였다. 변칙 발차기 분류 모델을 통해 태권도 경기에서 점수체계의 객관성과 정확성을 향상시킬 수 있을 것이라 예상된다. 추후 데이터 증폭이 아닌 선수들의 시연된 데이터를 이용하여 변칙 발차기 분류 모델에 적용할 예정이며 다중 분류를 위한 모델에서 성능 개선이 필요할 것으로 보인다.

Acknowledgments

위 논문은 문화체육관광부의 스포츠서비스사업화지원사업에 의거 국민체육진흥공단의 국민체육진흥기금을 지원받아 연구되었습니다.

참고문헌

- [1] 전인기, “태권도 경기의 공정성 확보를 위한 전자호구 도입에 관한 연구,” 한국체육과학회지, Vol.15(1), pp.423-432, 2006.
- [2] 조은형, 엄한주, “태권도 전자호구에 의한 득점 방식의 타당성 연구,” 한국체육측정평가학회지, Vol.9(2), pp.93-104, 2007.
- [3] 양대승, 박금숙, “태권도 경기의 전자호구 사용에 따른 득점 및 감점 분석,” 한국체육과학회지, Vol.18(4), pp.273-280, 2009.
- [4] 조은형, 정미미, 강성기, 김중현, 광태용, “유목내 상관을 이용한 태권도 경기의 득점인정 결과분석: 전자호구 득점 vs 심판에 의한 득점,” 대한무도학회지, Vol.10(1), pp.165-176, 2009.
- [5] Karim, F., S. Majumdar, H. Drabi, and S. Chem, “LSTM fully convolutional networks for time series classification,” in IEEE access, Vol.6, pp.1662-1669, 2017.
- [6] Zhou, X., X. Wan, and J. Xiao, “Attention-based LSTM network for cross-lingual sentiment classification,” In Proceedings of the 2016 conference on empirical methods in natural language processing, pp.247-256, 2016.
- [7] Dai, C., X. Liu, and J. Lai, “Human action recognition using two-stream attention based LSTM networks,” In Journal of applied soft computing, Vol.86(105820), 2020.