

SDA 시니어 논문세션

Game State and Spatio-temporal Action Detection in Soccer
using Graph Neural Networks and 3D Convolutional Networks

2026년 5월 23일(토)

Index


- 1. Introduction
- 2. Methodology
- 3. Evaluation
- 4. Critic
- 5. Future work

Introduction

- 축구 데이터 분석의 진화: 1950년대 수동 분석에서 현대의 카메라·AI 기반 자동 분석으로 발전
- 현재의 한계: 선수 추적(Tracking)은 자동화되었으나, 정밀한 이벤트 주석(Annotation)은 여전히 작업자의 수동 작업에 의존하여 비용과 시간이 많이 소요됨
- 기술적 난제: 기존 시공간 액션 탐지 모델은 개별 선수의 시각 정보에만 의존하여, 축구 특유의 복잡한 선수 간 상호작용 및 전술적 맥락을 파악하지 못함


Introduction

- Spatio-temporal Action Detection(시공간적 액션 탐지)
- 축구 선수의 행동은 서로 유기적으로 연결되어 있음. 따라서 주변 선수의 위치, 속도, 팀 정보를 추가하면 순수 시각 모델보다 더 정확한 예측이 가능할 것이라는 가설로 시작
→ 3D-CNN + GNN
- 시각적 특징과 게임 상태(Game state) 정보를 결합하는 하이브리드 모델 제안
- 실제 현장에서 사용 가능하도록 단일 GPU(RTX A6000)에서 학습 가능한 효율적인 시스템 구축, computational cost(계산 비용) 제한




Video Understanding (3D CNN)

-





GNN (Graph Neural Network)

-




Graph Neural Networks






Aggregate(Message passing)



Combine(Update)



Methodology

- 기존 데이터셋(MultiSports)의 한계: 선수 추적 데이터 및 카메라 보정 모델 부재로 게임 상태 연구가 불가능함

		# classes	# inst.	Max #inst.	Min #inst.	# act. bbox	#non-act. bbox	Position & Velocity
Multisports	Aerobic gym.	21	8703	-	-	325k	0	X
Multisports	Volleyball	12	7645	-	-	139k	0	X
Multisports	Basketball	18	9099	-	-	213k	0	X
Multisports	Football	15	12254	-	-	225k	0	X
Multisports	Total	66	37701	3477	3	902k	0	X
Footovision	Football	8	19969	2500	2500	620k	19,9M	✓

Figure 2: Comparison of the characteristics of the MultiSports and Footovision datasets

Methodology

- 기존 데이터셋(MultiSports)의 한계: 선수 추적 데이터 및 카메라 보정 모델 부재로 게임 상태 연구가 불가능함
- Footovision 데이터셋 구축
 - 규모: 997개 경기, 20,000개 비디오 클립 (각 3초)
 - 8개 클래스: 드리블, 패스, 크로스, 헤더, 스로인, 슛, 태클, 블락
 - 포함 정보: 선수/심판 바운딩 박스, 트랙 ID, 팀 정보, 경기장 내 실제 위치(x,y) 및 속도

Methodology

After applying TAAD to our clip of T frames, with N players, we obtain a feature tensor $\Phi_{X3D} \in \mathbb{R}^{N \times T \times 192}$, and we note $\Phi_{X3D}^{(i,t)}$ the visual feature vector of the player i and time t :

시각적 특징 추출

$$\Phi_{X3D}^{(i,t)} = \mathbf{ROI}(\mathbf{X3D}(\text{sequence}), \text{bbox}^{(i,t)}) \quad (1)$$

- 베이스라인 모델: 카메라 움직임에 강한 TAAD* 채택
- 백본 네트워크: 기존의 무거운 SlowFast 대신 경량화된 X3D 사용
 - 장점: 파라미터 수는 훨씬 적으면서 성능은 유사하여 과적합 방지 및 계산 효율성 높음
- 처리 방식: ROI Align**을 통해 선수의 경로를 따라 192차원의 특징 벡터 추출

* *Track-aware action detector*, 행위자를 먼저 찾고 그 경로(*Track*)를 따라 액션을 분석

** 샘플링 연산, 선수들의 바운딩 박스(*Bounding Box*) 데이터를 기반으로 X3D 백본의 결과물에서 각 선수의 시각적 특징 벡터($D=192$)를 추출




Figure 1. **X3D** networks progressively **expand** a 2D network across the following axes: Temporal duration γ_t , frame rate γ_τ , spatial resolution γ_s , width γ_w , bottleneck width γ_b , and depth γ_d .

Methodology

- its normalized position $(p_x^{(i,t)}, p_y^{(i,t)})$ at time t ,
- its normalized velocity $(v_x^{(i,t)}, v_y^{(i,t)})$ at time t ,
- its team membership, either 0 or 1,
- a projection of its visual feature vector $\Phi_{X3D}^{(i,t)}$ in a space of lower dimension ($D'=64$), noted $\phi_{X3D}^{(i,t)}$.

$$h_u^{(k+1)} = \text{MAX} \left(\text{MLP} \left(h_u^{(k)} \parallel h_v^{(k)} - h_u^{(k)} \right) \right) \quad (3)$$


Where MLP is a shallow Multi-layer Perceptron and MAX a channel-wise max pooling operation.

로컬 게임 상태 인코딩(GNN)

$$\mathbf{x}_t^i = \left(p_x^{(i,t)}, p_y^{(i,t)}, v_x^{(i,t)}, v_y^{(i,t)}, 0|1, \phi_{X3D}^{(i,t)} \right) \quad (2)$$

- 노드 구성: 각 타임스텝의 선수를 노드로 설정 ($\mathbf{x}_i^t = \text{위치} + \text{속도} + \text{팀} + \text{시각 특징 투영값}$)
- 그래프 구축: 동일 선수의 시간적 연결 + 가장 가까운 6명의 선수와 공간적 연결
- 에지 컨볼루션(Edge Conv): 노드의 전역 정보와 이웃과의 상대적 정보(상대 위치, 상대 속도 등)를 동시에 학습
- 3~4개 레이어만 사용하여 오버 스무딩(Over-smoothing) 방지

<주의> Over-Smoothing Issue



○ GCN에서 Layer 개수별 정확도





Figure 1: Accuracy of GCN on Cora w.r.t. # of convolution layers.

Evaluation

성능 비교 결과

Method	mAP	
	0,2	0,5
TAAD (X3D + FPN + TCN)	59,58	46,4
TAAD + GNN (ours) (X3D + FPN + Local Game State GNN)	64,48	49,7



- 평가 지표: mAP(IoU 임계값 0.2 및 0.5)
- TAAD 단독 모델보다 GNN 결합 모델의 성능이 모든 지표에서 우수함
 - mAP@0.2 59.58% -> 64.48%
 - mAP@0.5 46.4% -> 49.7%
- 구조화된 게임 상태 정보 통합이 탐지 정확도 향상에 기여함을 증명

Evaluation

실무적 유용성 분석

Actions	Increase in number of True Positives	Decrease in number of False Positives
Ball-Drive	0,0%	23,0%
Pass	-0,5%	13,1%
Cross	-7,9%	39,9%
Throw	-0,4%	31,0%
Shot	3,9%	23,3%
Header	0,9%	29,0%
Tackle	13,8%	47,8%
Ball-Block	1,3%	36,0%
Overall	0,4%	29,0%

- 고재현율 모드: 데이터 분석 현장에서는 이벤트를 놓치지 않는 것이 중요함
- 오탐지(False Positives) 감소: 재현율 80% 수준에서 GNN 결합 모델은 기존 대비 오탐지를 약 29% 감소
- 태클: 오탐지 48% 감소, 정탐지 14% 증가 (가장 큰 개선)
- 크로스: 골문 근처에서 슈트와 혼동되어 약 8% 하락

Evaluation

True label	background	0	1538	485	133	229	150	324	548	788
	drive	62	1109	24	5	0	3	1	9	7
	pass	123	41	394	15	0	4	2	14	12
	cross	19	7	6	253	0	14	1	1	2
	throw	11	0	0	0	244	0	0	0	0
	shot	37	5	4	12	0	233	2	2	5
	header	31	9	2	0	1	1	231	0	3
	tackle	23	53	7	0	1	0	1	152	13
	block	42	3	13	3	1	4	3	22	226
	Predicted labels - TAAD	background	drive	pass	cross	throw	shot	header	tackle	block

True label	background	0	1181	411	70	156	108	225	266	504
	drive	67	1109	23	4	1	3	4	6	3
	pass	126	45	392	15	1	3	2	12	9
	cross	36	4	9	233	0	20	1	0	0
	throw	10	2	0	0	243	0	0	0	0
	shot	34	9	3	9	0	242	1	1	1
	header	30	5	7	0	1	1	233	0	1
	tackle	34	25	4	0	1	0	0	173	13
	block	38	4	13	3	0	0	4	26	229
	Predicted labels - TAAD + GNN	background	drive	pass	cross	throw	shot	header	tackle	block

Critic

(+)

- 비논리적 탐지 제거: 시각 모델은 단순 제스처만으로 스로인을 오탐지할 수 있으나, GNN은 "이미 다른 선수가 공을 몰고 있다"는 맥락을 파악해 이를 차단함
- 실제 접촉 판단: 헛발질 상황에서 주변 선수들의 반응 (가속도 등)을 통해 실제 접촉 여부를 더 정교하게 판단함

Critic

(-)

- 밀집 상황 및 Occlusion: 선수들이 매우 가까이 붙어 있거나 겹쳐 있는 경우(공중볼 경합), 시각적 특징이 거의 동일해져 모델이 혼동함
- 의도 파악의 어려움: 크로스과 슛처럼 선수 위치와 동작이 유사한 액션은 여전히 구분하기 까다로움

Future work

향후 연구 방향

- 시간적 시야 확장: 현재의 2초(50프레임) 제한을 넘어선 장기 맥락 파악 필요
- Seq2Seq 모델 도입: 긴 이벤트 시퀀스를 통해 경기의 전체적인 논리와 역학을 학습
- 사후 정제 시스템: 전체 경기 지식을 바탕으로 탐지된 시퀀스의 노이즈를 제거하거나 사후 예측 수행
- 추가특징 결합: 미래 예측에 사용되는 다양한 게임 상태 특징들을 추가로 도입하여 모델 고도화