

SDA 시니어 논문세션

Precise Event Spotting in Sports Videos: Solving
Long-Range Dependency and Class Imbalance
2026년 3월 29일(일)

Contents.

01 Introduction

02 Method

03 Experiment

04 Conclusion

01


Introduction

1.1 Precise Event Spotting (PES)

정의

긴 스포츠 영상에서 이벤트의 클래스와 정확한 발생 시점을 찾는 것
하이라이트 생성, 자동 이벤트 태깅, 경기 영상 검색, 스포츠 영상 분석 자동화

Video Frames



1.1 Precise Event Spotting (PES)

Action Recognition

| 영상 구간이 어떤 행동인지 분류

Temporal Localization

| 행동이 발생한 구간을 찾음

Precise Event Spotting

| 이벤트가 발생한 정확한 frame을 찾음


1.2 기존 방법의 한계

1. Long-range temporal dependancy

| 현재 프레임만 보서는 이벤트 판별이 어려움, 과거/미래 프레임 정보 필요

2. Class imbalance

| 자주 발생하는 이벤트와 드문 이벤트의 수 차이가 큼



1.2 기존 방법의 한계

기존 방법들: E2E-Spot, T-Deed, ASTRA, COMEDIAN, SpotFormer

- 큰 pre-trained feature extractor 사용
- transformer 기반 temporal modeling 사용

E2E-Spot	end-to-end spotting	어려운 데이터셋에서 제한적
ASTRA	transformer + augmentation	rare class 대응 부족
COMEDIAN	distillation + transformer	고비용, 대형 모델
기존 transformer 계열	global context	긴 시퀀스에서 비효율 가능

1.3 해결하려는 문제

목표

1. Long-range dependency 해결
2. class imbalance 해결
3. 효율적이면서도 정확한 PES 모델 제안

아이디어

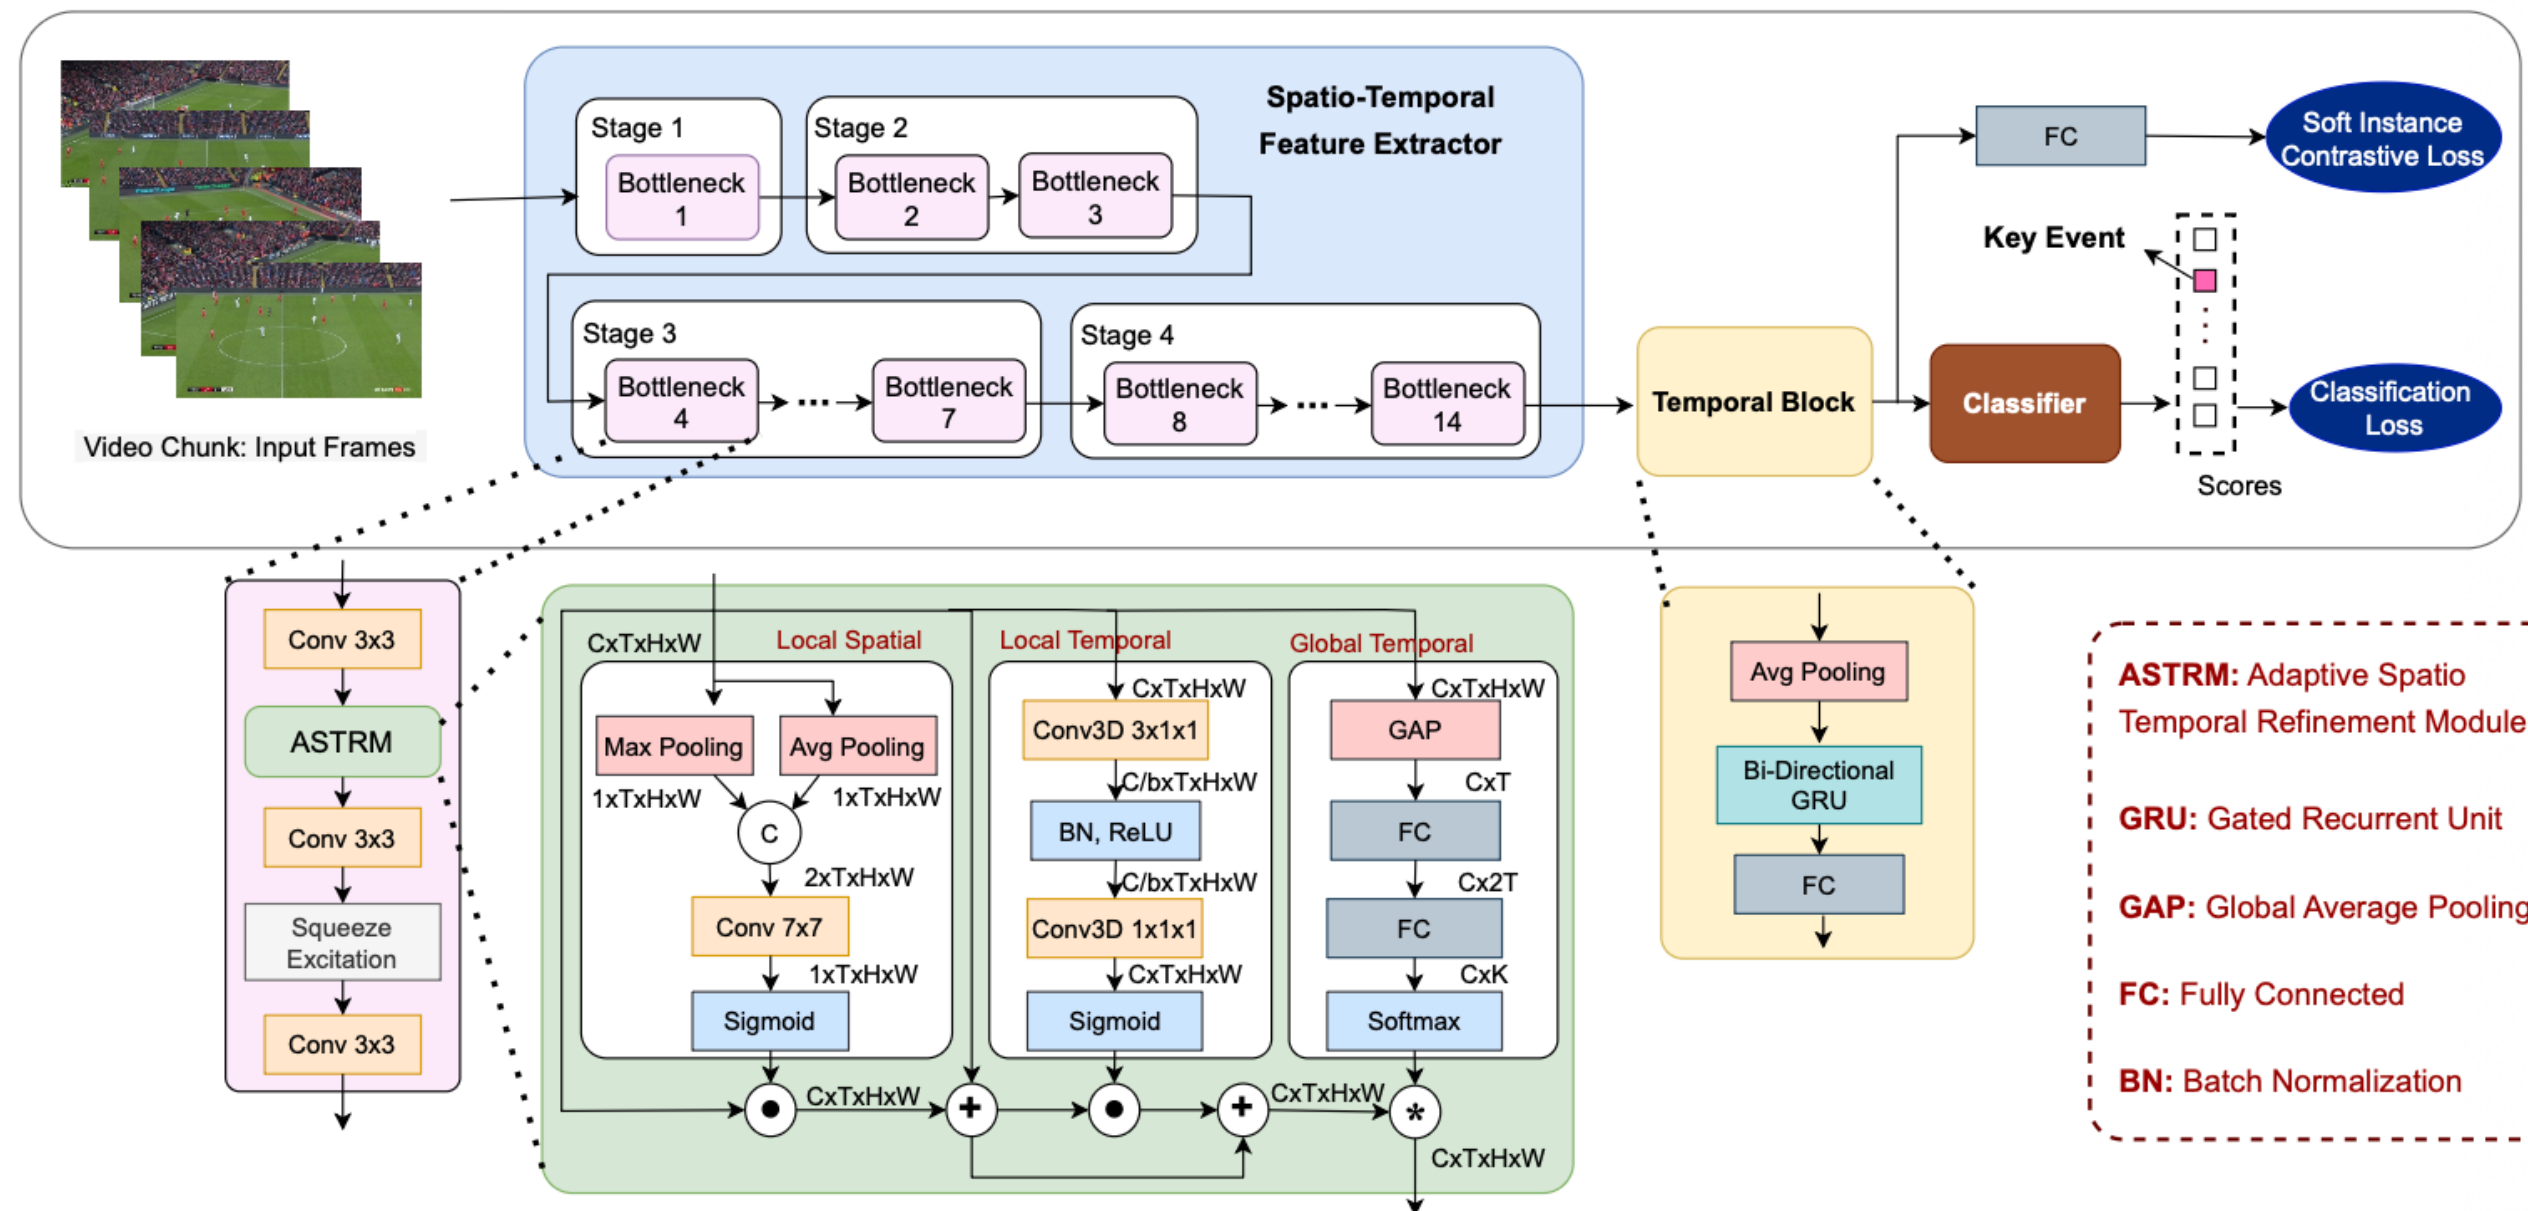
1. ASTRM: spatial + temporal feature refinement
2. Bi-GRU temporal block: 장기 시간 문맥 모델링
3. Soft-IC loss: rare class를 위한 feature compactness / separability 강화

02


Method

2.1 전체 모델 구조

입력: Video Clip
 Backbone: RegNetY
 각 Bottleneck에 ASTRM 삽입
 temporal block: Bi-GRU
 classifier: frame-wise classification
 loss: BCE+ Soft-IC



2.2 Backbone: RegNetY



Backbone



| 입력 영상에서 기본적인 시각 feature를 뽑아내는 기본 신경망

RegNet

CNN 계열 backbone 중 하나

성능 대비 연산량이 우수



구조가 안정적이라서 영상 feature extractor로 쓰기 좋음



2.3 Bottleneck에 ASTRM 삽입

Bottleneck



| CNN 안에서 feature를 효율적으로 처리하는 작은 기본 블록



2.3 Bottleneck에 ASTRM 삽입

Squeeze Excitation


| 채널 별로 어떤 feature가 중요한지 다시 가중치를 주는 모듈



2.3.1 ASTRM

Adaptive Spatio-Temporal Refinement Module



backbone이 뽑은 feature를 공간 정보와 시간 정보를 함께 반영해 더 정교하게 다듬는 모듈



2.3.1 ASTRM

1. Local Spatial block



| 현재 프레임 안에서 어떤 공간 영역이 중요한지 강조하는 부분



2.3.1 ASTRM

2. Local Temporal block


| 가까운 프레임들 사이의 시간 변화를 반영하는 부분



2.3.1 ASTRM

3. Global Temporal block


| 더 멀리 떨어진 프레임까지 고려해 현재 feature를 보정하는 부분



2.4 Temporal Block: Bi-GRU

Temporal block



ASTRM이 feature를 더 잘 만들게 해주더라도, 긴 시퀀스 전체의 흐름을 이해하려면 별도의 temporal block 필요



2.4 Temporal Block: Bi-GRU

Bi-GRU (Bidirectional Gated Recurrent Unit)

앞뒤 시간 정보를 모두 보면서 시퀀스를 이해하는 순환신경망



2.4 Temporal Block: Bi-GRU

Why not Transformer?

1. 영상 길이


self-attention이 긴 시퀀스에서 계산량, 학습 난이도 커짐

2. 데이터 규모가 무한히 크지 않음

데이터가 충분하지 않으면 불안정하거나 오버피팅

3. PES는 frame-level precision이 중요

너무 복잡한 global modeling보다 안정적인 sequence modeling이 더 유리



2.5 BCE Loss


| Binary Cross Entropy loss 예측 확률과 정답의 차이를 계산하는 손실함수

$$\text{BCE} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(p_i) + (1 - y_i) \log(1 - p_i)]$$

class imbalance 문제로 BCE는 기본 분류 오차만 보고,
rare class를 위해 다른 Loss 추가

2.6 Soft-IC Loss

Soft Instance Contrastive loss는 soft label이 생기는 상황에서도 같은 클래스 feature는 더 compact하게 모으고 다른 클래스와는 더 잘 분리 되도록 만드는 손실함수



03

Experiment

3.1 사용 데이터셋

SoccerNet V2

Tennis

Figure Skating (FS-Comp / FS-Perf)

FineGym

3.2 입력 및 실험 세팅

Backbone: RegNetY200

Clip length: 128

Optimizer: AdamW + ASAM

Framework: PyTorch

Hardware: 4xA100 GPU

3.3 평가 지표

SoccerNet V2: tight-mAP / loose-mAP

Tennis, FS, FineGym: mAP at $\delta=0,1,2$

04

Conclusion

4.1 SoccerNet V2 결과

Model	Params (M)	GFLOPs	Tight	Loose
Baidu (TF) [35]	—	—	47.05*	73.77*
SpotFormer [2]	—	—	60.90	76.10
E2E-Spot (RegNet-Y 200MF) [14]	4.46	39.61	61.19	73.25
E2E-Spot (RegNet-Y 800MF) [14]	12.64	151.40	61.82	74.05
Spivak [23]	17.46	461.89	65.10	<u>78.50</u>
ASTRA [29]	44.33	8.83**	66.63	78.14
T-DEED (RegNet-Y 200MF) [30]	16.36	21.96	39.43 [‡]	52.93 [‡]
T-DEED (RegNet-Y 800MF) [30]	46.22	60.25	21.57 [‡]	30.49 [‡]
UGLF [27]	4.46	39.61	63.51	73.98 [‡]
COMEDIAN (ViSwin-T) [6]	70.12	222.76	<u>71.33</u> [†]	77.07 [†]
Proposed	6.46	60.25	73.74	79.11

4.2 다른 스포츠 데이터셋 결과

Model	Tennis			FS-Comp			FS-Perf			FineGym		
	$\delta = 0$	$\delta = 1$	$\delta = 2$	$\delta = 0$	$\delta = 1$	$\delta = 2$	$\delta = 0$	$\delta = 1$	$\delta = 2$	$\delta = 0$	$\delta = 1$	$\delta = 2$
TSP [1] + MS-TCN [8]	—	90.90	95.10	—	72.40	87.80	—	76.80	89.90	—	40.50	58.50
TSP [1] + ASFormer [32]	—	89.80	95.50	—	77.70	94.10	—	80.20	94.50	—	38.80	57.60
2D-VDP [12] + MS-TCN [8]	—	—	—	—	83.50	96.20	—	85.20	<u>96.40</u>	—	—	—
VC-Spot (RegNet-Y 200MF) [14]	—	92.40	96.00	—	61.80	75.50	—	56.20	75.30	—	18.70	28.60
E2E-Spot (RegNet-Y 200MF) [14]	<u>45.34</u> *	<u>96.10</u>	97.70	22.08*	81.00	93.50	22.33*	85.10	95.70	10.01*	47.90	65.20
E2E-Spot (RegNet-Y 800MF) [14]	44.64*	95.16*	<u>97.72</u> *	23.95*	83.40	94.90	22.17*	83.30	96.00	10.15*	50.11*	67.23*
T-DEED (RegNet-Y 200MF) [30]	43.49	96.17	97.95	<u>28.92</u> *	<u>85.15</u>	91.70	<u>31.87</u> *	86.79	96.05	<u>13.54</u> *	<u>53.73</u> *	66.43*
T-DEED (RegNet-Y 800MF) [30]	44.08	96.42	97.05	27.59*	84.77	92.86	31.25*	<u>88.17</u>	95.87	12.42*	54.00 *	<u>66.70</u> *
UGLF [27]	—	—	—	—	—	—	—	—	—	—	50.20	67.80
Proposed	61.01	96.21	97.75	37.54	86.67	<u>95.53</u>	40.36	89.57	97.38	15.24	52.31	66.57

4.3 Ablation Study

Method	Tight	Loose
Analysis on proposed modules		
Baseline: E2E-Spot (RegNet-Y 200MF + GSM)	61.19	73.25
RegNet-Y 200MF + ASTRM	68.63	75.57
RegNet-Y 200MF + ASTRM + SAM	71.89	77.50
RegNet-Y 200MF + ASTRM + ASAM	72.65	78.58
RegNet-Y 200MF + ASTRM + ASAM + Focal Loss	70.36	76.86
RegNet-Y 200MF + ASTRM + ASAM + IC Loss	72.05	78.30
RegNet-Y 200MF + ASTRM + ASAM + Soft-IC loss	73.74	79.11
Analysis on proposed ASTRM module		
With local spatial only	69.91	76.39
With local temporal only	70.41	76.79
With global temporal only	71.65	77.06
With local spatial + local temporal	71.06	77.10
With local spatial + global temporal	71.82	77.85
With local temporal + global temporal	71.55	76.93
Proposed ASTRM module	73.74	79.11

Analysis on Different Temporal networks		
Baseline with Bi-GRU	61.19	73.25
Proposed with Bi-GRU	73.74	79.11
with Deformable Attention	67.43	72.15
with Bi-GRU 2 Layers	67.85	73.03
with Transformer (L1H8)	65.89	70.76
with Transformer (L2H8)	67.60	72.35
with Bi-LSTM	68.15	73.35
with MSTCN	68.75	73.50

Analysis on Clip Length		
Clip length = 64	43.82	52.09
Clip length = 100 (Used in baseline E2E-Spot)	71.20	76.73
Clip length = 128 (proposed)	73.74	79.11
Clip length = 192	71.74	77.02

Thank you