

개체명 인식과 이벤트 추출을 통한 판결문 범죄사실 구성요소 및 스토리라인 시각화방안 연구

이유나¹, 박성미², 박노섭³

¹한림대학교 정보법학과

²고려대학교 정보보호대학원

³한림대학교 글로벌학부, 교신저자

yuna_lee@hallym.ac.kr¹, outspark@korea.ac.kr², rspark@hallym.ac.kr³

A Study on Elements of Crime Facts and Visualizing the Storyline through Named Entity Recognition and Event Extraction

Yu-Na Lee¹, Sung-Mi Park², Ro-Seop Park³

¹Legal Informatics and Forensic Science, Hallym University

²School of Cybersecurity, Korea University

³Division of Global Studies, Hallym University

요 약

최근 사법분야에 지능형 법률 서비스를 제공하게 되면서 학습데이터로서 판결문의 중요성이 높아지고 있다. 그중 범죄사실은 수사자료와 유사하여 범죄수사에 귀중한 자료역할을 하고 있지만, 주체가 생략되거나 긴 문장의 형태로 인해 구성요건을 추출하고 사건의 인과관계 파악이 어려울 수 있어 이를 분석하는데 적지 않은 시간과 인력이 소비될 수밖에 없다. 따라서, 본 논문에서는 사전학습모델을 활용한 개체명 인식과 형태소 분석기반 이벤트 추출기법을 범죄사건 재구성에 적용하여 핵심 사건추출을 간편화하고 시각적으로 표현해 전체적인 사건 흐름 이해도를 향상할 수 있는 방법론을 제안하고자 한다.

1. 서론

최근 사법분야에서 법률문서 자동 작성 및 검토, 관련 판례 검색, 예상 형량 측정 등 지능형 법률 서비스 제공을 시작하게 되면서 학습데이터로서 판결문의 중요성도 높아지고 있다. 이는 객관적인 사실관계 파악 및 논증 검증이 무엇보다 우선되는 범죄수사에도 마찬가지로 형사 판결문은 유사범죄검색, 쟁점분석 등 수사지원작업에 귀중한 자료역할을 한다[1]. 그중 형사 판결문의 범죄(공소)사실은 수사문서의 범죄사실에서 차용되는 경우가 많아 비공개가 기본적인 수사자료에서 유례없이 접근이 용이한 데이터라고 볼 수 있다. 또한, 범죄사실은 특정 범죄행위의 구성요건에 해당하는 사실을 6하원칙(범죄의 주체, 일시, 장소, 피해자 또는 객체, 수단·방법, 행위결과)에 따라 작성되어 사건의 전반적인 흐름과 법적 구성요건 충족 여부, 더 나아가 잠재적 쟁점 유추에도 도움이 될 수 있다. 단, 판결문은 주체가 생략되거나 긴 문장의 형태로 인해 구성요건을 추출하고 사건의 인과관계 파악이 어려울 수 있어 이를 일일이 분석하는데 적지

않은 시간과 인력이 소비될 수밖에 없다. 따라서, 본 논문에서는 개체명 인식과 이벤트 추출기법을 범죄사건 재구성에 적합하게 활용하여 보다 더 명확하고 간편하게 스토리라인을 시각적으로 확인할 수 있는 방법론을 제시하고자 한다. 본 논문의 2장에서는 기존 기술인 개체명인식(NER)과 이벤트 추출기법과 관련된 연구에 대해 살펴보고 3장에서 시스템의 흐름도 및 실제 판례를 사용한 예시를 통해 범죄사실 이벤트 추출 및 시각화방안을 보여주고자 한다.

2. 관련 연구

2-1. 개체명 인식(Named Entity Recognition, NER)

개체명 인식이란 텍스트에서 사람, 장소, 기관 등과 같이 명명된 개체를 식별하여 추출하도록 하는 기법으로 질의응답, 정보검색 등의 시스템 구축 시 첫 번째 단계로 많이 사용된다[2]. 딥러닝 모델 기반 개체명 인식은 입력 데이터를 사전 학습된 단어 또는 문자 단위 임베딩, POS 태그 등으로 표현하여 문맥 정보를 CNN, RNN, Transformer 등의 모델을 이용

하여 인코딩 후 태그정보를 Softmax, CRF, RNN, Point network 등의 모델로 디코딩한다[2]. [3]에서는 한국어 사전학습모델인 KoElectra를 활용하여 범죄수사 도메인에 개체명 인식을 적용하였는데, 기존 개체명 표준에 정의된 개체와 더불어 범죄 수법과 범죄 관련 특수한 개체를 별도로 정의함으로써, 형사 판결문과 수사문서에서 추출할 수 있는 정보의 범위를 확장하였다. 단, 새롭게 정의된 개체명을 활용할 경우, 해당 개체가 문서에 나타나는 빈도에 따라 정확도에 큰 차이가 발생하는 문제가 있다[3]. 본 논문에서 다루고자 하는 필수 구성요소인 피고인, 피해자(객체), 범행일시, 범행장소는 시간·장소·인물 등 일반 표준 개체와 큰 언어적 차이를 보이지 않을뿐더러 추후 기술할 구성요소 역할 및 관계 설정 단계를 거치게 되어 기존에 학습된 모델을 충분히 활용할 수 있을 것으로 보인다.

2-2. 이벤트 추출(Event Extraction)

이벤트 추출은 구조화되지 않은 텍스트에서 특정 이벤트 정보를 추출하여 구조화된 형태로 표시하는 것을 목표로 한다[4]. 이벤트 추출 스키마는 일반적으로 1) 이벤트의 발생을 가장 명확하게 표현하는 주요 단어 또는 동사인 Event trigger, 2) 이벤트와 관련된 개체, 시간적 표현 또는 값인 Event argument, 3) Event trigger와 Event argument간의 관계인 Argument role로 구성된다[4]. 기존 연구에서는 워드 임베딩 후 Lexcial 단위 또는 문장 단위에서 특징을 통해 추출하거나[5], Trigger 단어와 Argument를 직접 라벨링하여 추출하는 방법[6]을 사용하였으나, 본 연구에서는 기존 개체명 인식 모델을 활용하여 Event argument를 추출하고 기분석된 범죄행위 사전과 구성요소 매핑표를 통해 Event trigger와 Argument role을 추출하는 방안을 제시한다.

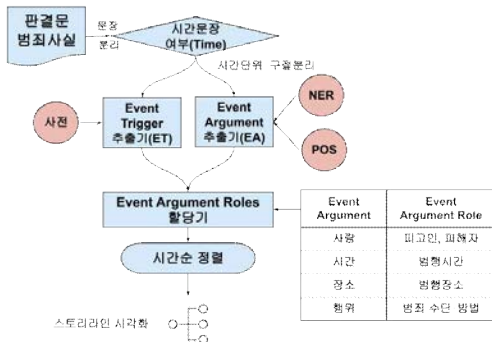
개체명 인식을 활용한 범죄사실 이벤트 추출 흐름도는 (그림1)과 같다. 먼저 판결문 범죄사실을 문장 단위로 분리한 후 (1) 시간 문자열 패턴 기준, (2) 시간 표현 단어(“같은 날 11:17경”, “다음날” 등), (3) 특정 시간을 기준으로 시간을 나타낼 수 있는 단어(“곧바로”, “이후” 등)를 추출하여 이벤트의 시간 데이터로 저장하고, 구절로 분리한다. 이 과정을 통해 일시가 정확히 명시되지 않은 문장도 사건 재구성에 사용할 수 있게 된다. 또한, 형사 판결문의 범죄사실은 시간적 표지를 기준으로 발생 행위 작성을 전제로 하므로 시간 표현 기준으로 문장을 구절 단위로 추가 분리해 범죄사실의 전개를 나타내는 핵심 이벤트 정보의 추출 정확도를 높일 수 있다. 다음 단계에서는 앞서 기술한 개체명 인식을 활용하여 이벤트 요소 중 Argument 요소를 추출한다. 본 연구에서는 한국어 개체명 인식 벤치마크에서 좋은 성능을 보이고 있는 KLUE-RoBERTa-large모델을 KLUE NER 데이터를 사용하여 학습 후 테스트를 진행하였다[7]. Event argument는 인명¹⁾, 장소, 시간 등으로 범죄 특성을 아직 부여하지 않은 기존 개체명과 동일하다. 행위는 한국어 형태소 분석 라이브러리 KoNLPy의 Okt 형태소 분석기를 사용하여 구절 내 동사(Verb)를 추출한다. 그 후, 최종별 범행결과문의 문장을 정규표현으로 추출하고 정제하여 구축한 사전을 통해 해당 범죄사실의 Event trigger를 분류하고 범행결과와 대응하는 구성요소를 정의한 매핑표를 통해 Event argument의 Role을 부여한다. <표1>은 살인 사건의 범죄사실을 사용하여 각 이벤트 요소의 정의와 예시를 보여준다.

이렇게 추출된 이벤트 정보는 시간 데이터에 따라 정렬되어 시각적으로 검증이 가능한 전체적인 스토리라인을 생성한다.

<표 1> 이벤트 정보 정의 및 예시

Event Component	Event Argument Role	예시 (서울남부지방법원 2018고합606)
Trigger	범행결과	- 살해하였다
Argument	사람	피고인, 피해자 A(피고인),B(피해자)
	시간	범행시간 2018. 10. 14. 08:08
	장소	범행장소 서울 양천구 ##병원
	행위	범죄 수단·방법 때리고, 절단시키고

3. 실험 설계

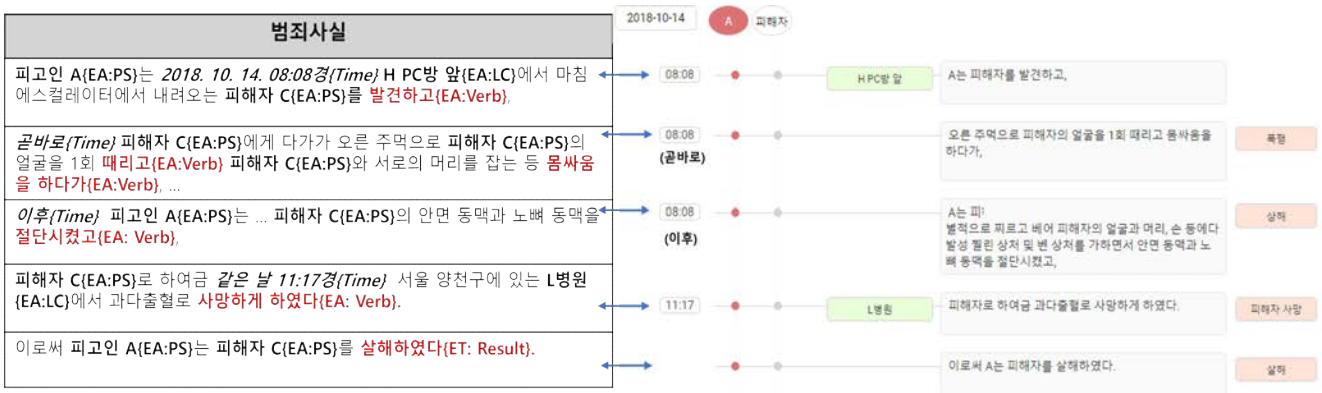


(그림 1) 이벤트 추출 흐름도

3-1. 실험 적용 사건

위 이벤트 추출방안을 실제 사건에 적용한 결과는 (그림 2)와 같다. 사용된 데이터는 유죄가 선고된 살인사건의 범죄사실로 피고인과 피해자의 최초 대면

1) 전처리 단계에서 이름 없이 나오는 대명사·피고인·피해자 경우, 사건 메타정보에서 추출한 이름으로 일괄변경하여 사용한다.



(그림 2) 서울남부지방법원 2018고합606 개체명 인식 및 이벤트 추출을 통한 스토리라인 시각화

· 범행 · 사망 장소 및 시각이 모두 상이하어 예시로 선정하였다. 예시에서 추출된 시간 데이터 중 일반적인 시간 문자열(YYYY.MM.DD. 등)으로 표현된 것은 단 1건으로, 그 외 시간 데이터는 단어 사전에 따라 추출 후 유추 과정이 요구됨을 알 수 있다. 장소 데이터는 범행장소인 ‘H PC방’과 피해자가 사망한 ‘L 병원’의 장소가 추출되었다. 인명은 피해자 ‘C’와 피고인 ‘A’가 추출되었는데 이는 판결문 데이터가 비식별되어 공개되기 때문이다. 비식별화가 진행되지 않은 실제 수사 데이터에 해당 방안을 적용하기 위해 기존 개체명 인식 모델 또는 데이터가 필요불가결한 이유라고 볼 수 있다. 최종적인 범행결과는 마지막 문장에 기술된 ‘살해’로 추출된다. A의 범죄행위는 범죄 구성요소 매핑표에 따라 폭행의 ‘때리고’, 상해의 ‘절단시켰고’, 살해의 ‘사망하게 하였다’가 있고, 그 외 피해자를 발견한 행위 등은 일반 행위로 분류가 된다. (그림2)의 우측 그래프는 위 과정을 통해 추출된 이벤트가 시간 순으로 시각화된 모습을 보여준다. 이 그래프는 범죄 사실의 6하원칙(주체, 일시, 장소, 피해자, 수단·방법, 행위의 결과)을 모두 갖추고 살인의 객관적 구성요건 요소를 모두 충족하며, 원문보다 더 직관적인 이해를 가능케 한다.

4. 결론 및 향후 연구 방향

본 연구에서는 판결문 범죄사실의 이해를 향상하기 위해 자동으로 구성요건을 추출하고 시각화하는 방안을 모색해보았다. 판결문 범죄사실은 긴 문장의 형태로 이루어져 사건의 인과관계를 이해하는데 어려움이 있으며, 최적화된 구성요소 추출을 위해 많은 시간과 인력이 투입되어야 한다. 따라서 본 논문은 제한적인 환경에서 위의 문제를 해결하기 위해 개체명 인식과 이벤트 추출을 통해 형사 판결문 범죄사실을 분석하고 시각적으로 표현하는 방안을 제시하고 있다. 향후 과제로 정보추출 요소를 더 세분화하여 사전학습된 딥러닝 모델들에 적용하여

정확도를 확인하고 높이는 연구가 필요하다.

Acknowledgement

이 논문은 2022년도 정부(경찰청)의 재원으로 지원받아 수행된 연구결과임 [내역사업명: AI 기반 범죄수사 지원 / 연구개발과제번호: PR10-02-000-22]

참고문헌

[1] 박성미, 이유나, 최아리, 안정민, “사법분야 인공지능 발전을 위한 판결문 데이터 개선방안- ‘판결서 인터넷열람 서비스’를 중심으로”, 경찰법연구학회, Vol.19, no.3, p. 3-36, 2021

[2] J. Li, A. Sun, J. Han, C. Li, “A Survey on Deep Learning for Named Entity Recognition”, IEEE Transactions on Knowledge and Engineering, Vol.34, no.1, p. 50 - 70, 2022

[3] 김희두, 임희석, “사전학습 언어모델을 활용한 범죄 수사 도메인 개체명 인식”, 한국융합학회논문지, Vol.13, no.12, p. 13-20, 2022

[4] Y. Chen *et al.*, “Event Extraction via Dynamic Multi-Pooling Convolutional Neural Networks”, Proceedings of the 53rd Annual Meeting of the ACL and the 7th IJCNLP, Beijing, 2015, p. 167-176

[5] S. Yang, D. Feng, L. Qiao, Z. Kan, D. Li, “Exploring pre-trained language models for event extraction and generation”, Proc. of the 57th Conference of the ACL 2019, Florence, 2019, p. 5284 - 5294

[6] Q. Li, Q. Zhang, J. Yao, Y. Zhang, “Event extraction for criminal legal text.”, 2020 IEEE International Conference on Knowledge Graph, IEEE, 2020. p. 573-580

[7] S. Park *et al.*, “KLUE: Korean Language Understanding Evaluation.” arXiv preprint arXiv.2105.09680 (2021).