



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](#)

국제학 석사 학위논문

자연어처리 기술을 활용한 국내 형사 판결문
검색 모델 비교 연구

- 범행 동기를 중심으로 -

(A Comparative Study on Criminal Judgement Search
Models Using Natural Language Processing
- Focusing on the motive for the crime -)

최 아 리(Choi, A Ri)

국제학과(Department of International Studies)
정보법과학전공(Major in Legal Informatics and Forensic
Science)

한림대학교 대학원
(Graduate School, Hallym University)

국제학 석사 학위논문

자연어처리 기술을 활용한 국내 형사
판결문 검색 모델 비교 연구

- 범행 동기를 중심으로 -

(A Comparative Study on Criminal Judgement Search
Models Using Natural Language Processing
- Focusing on the motive for the crime -)

최 아 리(Choi, A Ri)

국제학과(Department of International Studies)

정보법과학전공(Major in Legal Informatics and Forensic
Science)

한림대학교 대학원

(Graduate School, Hallym University)

장 윤 식, 김 선 정 교수지도

국 제 학 석 사 학 위 논 문

최 아 리의 석사 학위논문을 합격으로 판정함

2022년 12월 20일

심위심사위원장 박 노 섭

심사위원 장 윤 식

심사위원 김 선 정

심사위원 안 정 민

목차

제 1 장 서 론	1
제 1 절 연구배경 및 목적	1
제 2 장 이론적 배경	4
제 1 절 유사 사건 도출과 관련된 선행 연구	4
제 2 절 유사 사건 도출 기능을 제공하는 국내 판결문 검색 서비스.....	8
1. 종합법률정보 대국민 시스템	9
2. 판결서 인터넷열람	14
3. 엘박스 (LBox)	16
4. 빅 케이스	17
제 3 절 검색 엔진의 적용 가능한 자연어 처리 (NLP) 기술	18
1. 단어 표현 (Word Representation)	20
2. 임베딩 (Embedding).....	22
가. Word2Vec 과 WMD	22
나. GloVe	25
다. 트랜스포머 계열 모델인 BERT 와 KoBERT.....	27
3. 유사도 측정 방법	29
가. Cosine Similarity	29
나. Soft Cosine Similarity.....	30
4. 문서 분류 모델	32
가. 전통적인 머신러닝 모델.....	32
1) Decision Tree	32
2) Random Forest.....	33
3) SVM.....	34

나. 트랜스포머 모델, KoBERT 와 KLUE	3 5
5. 분류 모델 성능 측정 방법.....	3 8
제 3 장 유사 사건 검색 기능의 실태 분석 및 형사 판결문을 기반으로 한 유사 사건 기준 도출 실험.....	4 0
제 1 절 판결서 열람 서비스 내 유사사건 검색 기능 실태 분석	4 1
1. 엘박스	4 1
2. 빅케이스	4 7
제 2 절 판결문 데이터 수집, 정제, 전처리	5 3
1. 데이터 선정 및 수집.....	5 3
2. 데이터 정제	5 4
3. 데이터 전처리	5 7
제 3 절 유사 사건 기준 수립을 위한 선행 연구.....	5 9
1. 유사 사건 기준 파악을 위한 실험 설계 및 결과.....	5 9
2. 작업자 평가 및 결과.....	6 2
제 4 절 의미론적(semantic) 유사 사건 도출에 대한 소결론.....	6 7
제 4 장 범행 동기를 기준으로 판결문 분류 데이터셋 구축 방법	6 8
제 1 절 동기의 중요성 및 연구 방법.....	6 8
제 2 절 범죄사실 내 동기 분류 기준 수립	7 1
1. 기존 연구에서 분류하는 동기의 기준.....	7 1
2. 범죄 사실 내 동기를 활용한 데이터 셋 구축 방안	7 3
3. 범죄 사실 내 동기를 포함하고 있는 문장 분리 기준 수립	7 3
4. 동기 포함 문장 내 분류 별 키워드 추출 기준 수립	7 7
5. 동기 분류 데이터셋 구축.....	8 5

제 5 장 동기 분류 데이터셋을 중심으로 한 분류 모델 구축 및 검증	8 9
제 1 절 동기 분류 모델 구축 방안.....	8 9
1. 베이스 라인 모델 설계.....	9 0
2. 전통적인 머신러닝 모델 설계.....	9 2
3. 트랜스포머 모델 설계	9 4
제 2 절 모델이 분류한 동기 데이터 평가	9 7
1. 데이터셋 1 내 검증 데이터를 통한 모델 평가 결과	9 7
2. 데이터셋 2 내 검증 데이터를 통한 모델 평가 결과	1 0 0
3. 데이터셋 3 내 검증 데이터를 통한 모델 평가 결과	1 0 2
4. 동기 분류 데이터셋을 통한 모델 검증의 소결론.....	1 0 5
제 6 장 결론	1 0 7
참고 문헌	1 0 9
부록	III

표 목차

표 1 외국 유사 사건 도출과 관련된 선행 연구 및 데이터셋 정리.....	5
표 2 종합법률정보시스템에서 제공하는 판결문 종류 및 출처.....	1 0
표 3 엘박스 기능 요약.....	1 6
표 4 GLOVE에서 사용하는 동시등장확률의 예시	2 6
표 5 KLUE에서 제공하는 태스크 및 상세 설명과 각 사용된 데이터	3 7
표 6 오차행렬 (CONFUSION MATRIX).....	3 8
표 7 엘박스 유사 사건 검색 기준 사건인 수원지방법원 안산지원 2016 고합 3의 범죄사실 요약 .	4 1
표 8 유사 판례 검색 기능을 통해 비교 대상으로 선출된 사건 목록.....	4 3
표 9 엘박스 유사 사건 검색 내 1 순위 사건인 부산지방법원 2011 고합 503 사건의 범죄사실 요약....	4 3
.....	
표 10 엘박스 유사 사건 검색 내 2 순위 사건인 춘천지방법원 2020 고합 154, 2021 전고 2 사건의 범죄사실 요약.....	4 4
표 11 엘박스 유사 사건 검색 내 3 순위 사건인 의정부지방법원 2019 고합 347 사건의 범죄사실 요약	4 4
표 12 엘박스를 통해 도출한 유사 사건 세부 내역 비교표.....	4 5
표 13 빅케이스를 통해 도출한 유사 사건.....	4 8
표 14 빅케이스로 도출된 유사 사건 1 위 대구지방법원 2013 고합 221 사건의 범죄사실 요약	4 8
표 15 빅케이스로 도출된 유사 사건 2 위 수원지방법원 평택지원 2019 고합 167 사건의 범죄사실 요약	4 9
표 16 빅케이스로 도출된 유사 사건 3 위 대구지방법원 포항지원 2013 고합 104 사건의 범죄사실 요약	5 0
표 17 빅케이스를 통해 도출한 유사 사건 세부 내역 비교표	5 1
표 18 '판결서 인터넷열람사이트' 검색 조건에 적용한 세부내역.....	5 4
표 19 형태소 분석기별 성능 비교표	5 7
표 20 유사 사건 도출을 위한 기준 사건 목록	5 9
표 21 기준 사건 1 번 (광주지방법원 목포지원 2016 고합 105)사건에 대한 모델들이 도출한 유사 사건	6 1

표 22 기준 사건 2 번 (대전지방법원 서산지원 2012 고합 170) 에 대한 모델이 도출한 유사 사건	6 1
표 23 기준 사건 3 번 (수원지방법원 안산지원 2019 고합 33) 에 대한 모델이 도출한 유사 사건 ..	6 1
표 24 기준 사건 4 번 (부산지방법원 2016 고합 736)에 대한 모델이 도출한 유사 사건	6 2
표 25 작업자들이 평가한 유사 사건 도출 데이터셋 평가	6 4
표 26 작업자들이 작성한 이유 범주화 결과	6 5
표 27 유사 사건 기준 분류 차트	6 6
표 28 범죄 사실 내 동기를 나타내는 패턴 및 정규 표현식	7 4
표 29 데이터셋 1,2,3 내 세부 내역	8 5
표 30 데이터셋 별 동기 분포 변화	8 6
그림 37 베이스라인 모델 구축 도안표 31 데이터셋 별 동기 분포 변화	8 6
표 32 데이터셋 별로 동기 문장 글자 수 평균	8 6
표 33 각 데이터셋 내 동기 분류 분포 비율	8 7
표 34 데이터셋 별 학습 및 검증 데이터 크기와 분류 별 분포	9 0
표 35 KOBERT 모델 구축에 사용한 세부 파라미터와 값	9 5
표 36 KLUE 모델 구축에 사용한 세부 파라미터와 값	9 6
표 37 데이터셋별 가장 높은 정확도를 도출한 모델과 모델에 사용된 입력 데이터의 형태	9 7
표 38 데이터셋 1 을 통한 각 모델의 정확도 및 검증 데이터 내 맞춘 개수와 틀린 개수	9 8
표 39 데이터셋 1 내 검증용 데이터 라벨에 따른 모델 별 F1 스코어	9 9
표 40 데이터셋 2 을 통한 각 모델의 정확도 및 검증 데이터 내 맞춘 개수와 틀린 개수	1 0 0
표 41 데이터셋 2 내 검증용 데이터 라벨에 따른 모델 별 F1 스코어	1 0 1
표 42 데이터셋 3 을 통한 각 모델의 정확도 및 검증 데이터 내 맞춘 개수와 틀린 개수	1 0 2
표 43 데이터셋 3 내 검증용 데이터 라벨에 따른 모델 별 F1 스코어	1 0 4
표 44 중복으로 등장하는 키워드 개수	1 0 6

그림 목차

그림 1 판결문이 개인에게 공개되는 과정 도식화	9
그림 2 종합법률정보에서 제공하는 단순 검색 기능	1 1
그림 3 종합법률정보 내 상세 검색 기능	1 2
그림 4 종합법률정보 디렉토리 검색을 통해 형법 제 250 조를 검색한 결과	1 3
그림 5 판결서 인터넷 열람 사이트에서 제공하는 판결문 검색 기능	1 4
그림 6 유사 사건 도출과 문서 분류를 위한 자연어 처리 흐름도	1 9
그림 7 국소 표현과 분산 표현을 통해 구축한 각 문서별 벡터 예시.....	2 1
그림 8 WORD2VEC 에서 단어를 이용해 벡터를 생성 및 단어끼리 연산 방법 도식화.....	2 3
그림 9 WORD2VEC 의 학습 방식인 CBOW 방식과 SKIP-GRAM 방식 도식화.....	2 4
그림 10 WMD 에서 사용하는 문서 간 거리 측정 방안 도식화.....	2 5
그림 11 BERT 의 사전 훈련(PRE-TRAINING)과 추가 학습(FINE-TUNING) 과정 도식화 [14]	2 8
그림 12 두 벡터 사이의 각도로 보는 COSINE SIMILARITY 값 변화	3 0
그림 13 COSINE SIMILARITY 와 SOFT COSINE SIMILARITY 비교 그래프	3 1
그림 14 DECISION TREE 과정 도식화	3 3
그림 15 RANDOM FOREST 과정 도식화	3 4
그림 16 RANDOM FOREST 과정 도식화	3 4
그림 17 SVM 내 핵심 기능 (SUPPORT VECTOR, MARGIN, HYPERPLANE) 그래프	3 5
그림 18 BERT 를 이용한 LABEL 분류 방법 도식화	3 6
그림 19 엘박스 유사 판례 검색 기능 통해 도출한 결과	4 2
그림 20 AI 유사판례 기능을 통해 도출한 유사 사건 화면	4 7
그림 21 판결문 선정 및 수집부터 전처리까지의 흐름도.....	5 3
그림 22 텍스트 형태의 판결문을 JSON 형태로 구조화한 예시.....	5 6
그림 23 기준 사건을 중심으로 한 유사 사건 도출 데이터셋 구축 구조화	6 0
그림 24 유사 사건 평가에 사용된 설문지.....	6 3
그림 25 작업자들이 작성한 1 위 사건에 대한 이유	6 5
그림 26 부산지방법원 2018 고합 511 범죄사실 내 관계, 동기, 도구.....	6 9
그림 27 해당 논문에 맞춰 수정한 동기 분류 도출 방식 도식화.....	7 2
그림 28 동기 분류 데이터셋 구축 흐름도.....	7 3

그림 29 동기 분류 데이터셋 구축 흐름도.....	7 3
그림 30 광주지방법원 목포지원 2020 고합 91 판결의 범죄사실.....	7 6
그림 31 광주지방법원 목포지원 2012 고합 181 판결을 이용한 지정 키워드 추출 예시.....	7 8
그림 32 서울중앙지방법원 2015 고합 856 판결을 이용한 정신 키워드 추출 예시.....	8 0
그림 33 춘천지방법원 2013 고합 136 판결을 이용한 금품 키워드 추출 예시.....	8 2
그림 34 청주지방법원 2018 고합 171 사건을 이용한 원한 키워드 추출 예시.....	8 3
그림 35 청주지방법원 2018 고합 171 사건을 이용한 원한 키워드 추출 예시.....	8 3
그림 36 청주지방법원 2018 고합 171 판결을 이용한 원한 키워드 추출 예시.....	8 4
그림 37 베이스라인 모델 구축 도안표 31 데이터셋 별 동기 분포 변화.....	8 6
그림 38 베이스라인 모델 구축 도안.....	9 1
그림 39 머신러닝을 활용한 동기 분류 도식화.....	9 2
그림 40 키워드 빈도수를 기반으로 생성한 사건별 벡터.....	9 3
그림 41 트랜스포머 계열을 활용한 동기 분류 모델 작동 원리.....	9 4
그림 42 동기 분류 데이터 셋 1 검증용 데이터를 기반으로 KLUE(BERT-BASE) 모델이 도출한 오차행렬.....	9 9
그림 43 동기 분류 데이터셋 2 검증용 데이터를 기반으로 RANDOM FOREST 모델이 도출한 오차행렬	1 0 1
그림 44 동기 분류 데이터셋 3 검증용 데이터를 기반으로 RANDOM FOREST 모델이 도출한 오차행렬	1 0 4

제1장 서론

제 1절 연구배경 및 목적

4차 산업혁명의 도래로 발전된 인공지능 기술을 활용하면서 처리해야 할 데이터가 기하급수적으로 증가하였다. 많은 데이터를 단시간에 처리하기 위해서는 효율적인 검색 서비스가 필요로 한다. 이는 대량의 법률 문서를 활용하는 리걸테크 분야에서도 큰 부분을 차지하고 있다. 리걸테크는 법률 분야(Legal)에 기술(Tech)을 적용시킨 분야로 [1], 크게 검색, 분석, 작성으로 나뉘고 세부적으로는 사용자가 원하는 목적에 따라 ①변호사 검색, ②법령 또는 판례 검색, ③ 증인 또는 증거 검색, ④ 행정절차, 소송절차 등 안내, ⑤ 사무자동화로 나뉜다[2]. 법령 또는 판례 검색의 경우, 기술의 발전으로 단순 검색(키워드 검색)을 넘어 기존 사건과 비슷한 사건을 도출해주는 유사 사건 검색까지 가능해지고 있다.

이러한 유사 사건 검색 서비스는 기업이 아닌 공공기관에서도 활발히 개발되고 있다. 싱가포르에서는 싱가포르 사법부와 난양기술대학교(Nanyang Technological University)의 통합 기술 스마트 플랫폼 인프라 연구(Smart Platform Infrastructure Research on Integrative Technology) 소속 스마트 국가 연구 센터와 함께 인공지능을 활용한 지능형 사건 검색 시스템(Intelligent Case Retrieval System, ICRS)를 개발하여 판례 데이터베이스 내에서 가장 관련도가 높은 판례를 검색하고 다양한 분야에 해당하는 판례의 선례를 검색함으로써 결과에 대한 예측을 단시간에 정확하게 검색할 수 있게 되었다[3]. 해당 시스템을 통해 검색을 진행하는 모든 사용자는 자신의 사건의 강점과 약점을 파악할 수 있을 뿐만 아니라 유사 사건을 통해 질적 향상된 문서 제출로 판사의 의사 결정 과정에 도움을 주어 판결문의 질을 높이고 궁극적으로 사법부에 대한 신뢰를 강화한다[4]. 호주에서는 국가법률구조(National Legal Aid)와 남호주 법률서비스 위원회(Legal Service Commission of South Australia)가 인공지능을 활용한 아미카(amica) 프로그램을 개발하여, 이혼 당사자들에게 과거 가정법원의 결정 뿐만

아니라 당사자들의 개별 자산 및 상황을 분석 및 평가하고 당사자들의 사건과 유사한 사건을 제시 및 해당 합의안을 검토하여 법원이 유사한 분쟁을 다루는 방식을 분석한 뒤, 당사자들에게 재산 분할 결정을 제안한다[5].

이렇듯, 유사 사건 검색은 사건을 기반으로 사용자들에게 빠르고 정확한 유사 사건을 도출하여 효율적인 검색 기능을 제공하는 데 그치는 것이 아니라 유사 사건 검색 결과로 사건 당사자들의 의사결정에 큰 도움이 될 수 있다. 이와 비슷하게 국내에서는 인공지능을 활용하여 수사 문서를 단시간 내 분석, 검토 및 보완하는 ‘과학적 범죄수사 고도화 기술 개발’ 연구과제가 진행중에 있다[6]. 해당 과제의 세부 목표 중 하나인 유사 사건 추천은 수사관이 담당하고 있는 사건과 비슷한 사건의 진행 과정을 파악할 수 있고, 이전 사건을 통해 담당 사건을 보완할 수 있는 기회를 마련하여 궁극적으로 수사의 질을 높이는데 목적을 두고 있다. 특징적으로는 기존 국내 판결문 검색 연구가 대법원 판례 중심이던 것에 비해 본 과제는 형사 하급심 판결문을 주 데이터로 다루고 있다.

우리나라에 운용되는 3 심 구조에 따라 하급심인 원심과 항소심에서는 피고인의 범죄사실을 기반으로 사실관계를 판단하고 인정되는 사실관계에 대한 법리판단을, 최종심에서는 법적 판단을 대상으로 진행한다. 리걸테크의 목적인 사법 분야에 인공지능을 활용하기 위해서는 하급심 데이터를 활용하여 사실관계에 대한 분쟁 분석부터 시작하여야 한다[7]. 따라서, 사실 관계를 직접적으로 다루는 하급심 데이터는 리걸테크 분야에 있어 필수적이다. 또한, 법률 전문가들은 인공지능을 활용해 판결문을 분석하고 그 결과를 기반으로 유사 사건 검색이나 다른 태스크들을 진행하기 위해서는 직접적 사실관계를 다루는 하급심이 필요하다고 하급심의 중요성을 강조하였다[8].

따라서, 본 연구에서는 하급심 데이터인 형사 1 심 판결문을 중심으로 국내에서 제공하고 있는 유사 사건 검색 기능의 실태를 분석하고 자연어 처리 기술을 활용해 정확한 유사 사건 도출을 위한 방법에 대해 연구하는 것을 목적으로 한다. 먼저 유사 사건과 관련된 선행연구를 먼저 살펴보고, 국내에서 제공되고 있는 판결서 열람 서비스들과 해당 서비스에서 제공하는 판결서 검색 및 유사 사건 검색 기능을 살펴본다. 단, 유사 사건에서 유사성은 사람마다 기준이 다른 주관적인 용어로, 가장 유사한 수법에 대한 판단은

사람마다 달라진다[9]. 따라서 본 연구에서는 자연어 처리 기술을 활용해 유사 사건을 도출하고 작업자 평가를 통한 유사 사건의 기준을 파악한다. 도출된 유사 사건 기준을 토대로 판결문을 분류하여 분류 근거로 키워드 또는 문장으로 구성된 데이터셋을 구축하여 해당 데이터셋을 기반으로 분류 모델의 성능을 평가한다.

본 논문의 구성은 다음과 같다. 제 2 장에서는 판결문 검색 엔진 발전 과정과 국가에서 운영하는 종합법률정보 대국민 시스템과 판결서 인터넷 열람 사이트 그리고 민간에서 운영하는 엘박스과 빅케이스에 대해 알아보고, 각 사이트에서 제공하는 판결문 검색 및 열람 방식을 알아본다. 또한, 판결문 검색 및 열람 기능의 근간이 되는 자연어 처리 기법의 정의와 흐름을 살펴보고, 각 흐름에서 사용되는 세부 기법들을 살펴본다. 이후, 제 3 장에서는 엘박스과 빅케이스에서 제공하는 유사 사건 기능의 실태를 파악하고, 제 2 장에서 언급된 자연어 처리 기법을 사용해 판결문 데이터를 수집 및 정제를 거쳐 전처리 후 유사 사건 도출 실험을 진행하고 진행된 결과를 통해 유사 사건 판별 기준을 수립한다. 제 3 장에서 수립된 유사 사건 판단 기준인 '범행동기'를 중심으로 판결문을 분류하기 위해, 제 4 장에서는 범죄사실 내 서술되어 있는 동기를 문장과 키워드 단위로 추출해 데이터셋을 구축한다. 제 5 장에서는 제 4 장에서 구축한 데이터셋을 기반으로 다양한 모델을 통해 판결문 분류 작업을 진행하고 각 모델의 성능을 파악한다. 마지막 제 6 장에서 결론을 내린다.

제2장 이론적 배경

제 1절 유사 사건 도출과 관련된 선행 연구

형사 판결문 내 범죄사실을 대상으로 적합한 유사 사건을 도출하기 위해 국내외로 유사 사건에 관한 선행 연구들을 조사하였다. 먼저, 국내의 경우, [10] 연구에서 종합법률정보사이트에서 교통사고법과 관련된 대법원 판례 2,264 건을 수집하여 전처리 후 Doc2Vec 과 SBERT 로 임베딩하여 코사인 유사도 값을 비교해 유사 사건 여부를 판단하였다. 모델마다 유사도가 높은 상위 5 개의 사건을 추출하였는데, Doc2Vec 은 상위 1 개를 제외하고 의미상으로 유사한 판례를 찾지 못하였고, SBERT 는 상위 3 개까지 유의미한 것으로 보았다. 단, 해당 논문에서는 결과를 분석하며 의미적 유사를 기준으로 유의미함을 판별했으나, 그 판단하는 기준을 밝히지 않았다. 수집한 데이터가 ‘교통사고법’이라는 특정 범주 내 판례였다는 점을 고려하면 그 상세한 판단 기준이 핵심적인 정보로 보여 다소 아쉬운 부분이다. 또한, 코사인 유사도가 높아도 실제 유사하지 않은 판례의 분석이 없어 논문에서 말하는 의미적 유사성과 코사인 값의 관계를 파악할 수 없었다.

이외에도 국내에서 유사 사건을 연구한 논문 중 수사 데이터에서 범죄사실을 추출하여 침입절도 사건의 유사성을 검토한 연구가 있는데[9], 수사자료의 범죄사실은 하급심 판결문에 기재되는 범죄사실과 동일한 경우가 많아 동일 맥락의 연구라고 볼 수 있다. [9]는 침입절도에 초점을 맞춰 2011 년부터 2015 년 사이 발생한 침입절도 사건 수사 보고서를 수집하여 동일범의 사건들과 비동일범의 사건들 사이의 주요 수법의 유사도를 비교하였다. 하지만, 해당 연구에서는 수사 자료 데이터를 사용했기 때문에, 데이터 생성을 위한 세부적인 데이터 전처리 과정이나 활용하는 데이터에 대해 상세하게 알 수 없었고, 추출한 데이터를 기반으로 진행한 상이 지수에 대한 구체적인 정보를 얻을 수 없었다.

앞서 본 바와 같이 국내의 경우, 판결문을 기반으로 한 선행 연구를 찾기 어렵다. [10]의 경우, 판결문을 활용했으나, 형사 판결문이 아닌 교통사고 법과 관련된 대법원 판결문이라는 점에서 형사 판결문을 위한 유사 사건 선행 연구는 국내에 없는 것으로 보인다. 또한, 유사 사건을 도출하는 과정에서 사용한 기준으로 코사인 유사도와 의미적 판단을 사용했으나, 의미적 판단에 대한 설명이 없기 때문에 기준 판결문과 실제 판결문 사이에 의미적인 유사성을 파악하기 어렵다. 또한, [9]의 경우, 판결문 내 범죄사실에 기재되는 내용과 동일한 수사 문서 데이터를 사용하였으나, 본 연구와 같은 자연어 처리 기법을 사용한 것이 아닌 단순 키워드 추출을 이용한 유사도 추천 알고리즘을 개발하였다는 점에서 본 연구와의 차별점을 가진다.

국외의 경우, 유사 사건 도출 분야에서는 대표적으로 CAIL 와 COLIEE 워크숍이 유명하다. CAIL 와 COLIEE 에서는 매년 참가자들에게 훈련용과 검증용으로 구축된 데이터를 제공하고, 해당 데이터셋을 기반으로 참가자들을 각자 모델을 구축해 최종적으로는 검증용 데이터셋으로 도출한 정확도(accuracy)나 정밀도(precision)과 재현율(recall)을 기반으로 한 F1-Score 로 참가자들의 모델을 순위를 매긴다. 따라서, 각 모델들의 성능을 평가하고 궁극적으로 참가자들 사이의 순위를 매기기 위해, 정답을 포함한 데이터셋을 제공하고 있다. 세부적으로 CAIL 와 COLIEE 에 대해 정리한 내용은 아래 표 1 과 같다.

표 1 외국 유사 사건 도출과 관련된 선행 연구 및 데이터셋 정리

논문명	연도	태스크	데이터셋 명	데이터 량
CAIL2019-SCM: A Dataset of Similar Case Matching in Legal Domain[11]	2019	<ul style="list-style-type: none"> ○ 법률 QA (Legal Question-Answering) ○ 법률 케이스 요소 예측 (Legal Case Element Prediction) ○ 유사 사건 도출 (Similar Case Matching) 	Chinese AI and Law Challenge (CAIL)2019-Similar Case Matching (SCM)	3 개의 판결문을 하나로 묶어 총 8,964 건의 판결문. 모든 판결문은 사채(private lending)과 관련된 판결문.

<p>Overview and Discussion of the Competition on Legal Information Extraction/Entailment (COLIEE) 2021[12]</p>	<p>2022</p>	<ul style="list-style-type: none"> ○ Task 1 : The Legal Case Retrieval Task ○ Task 2 : The Legal Case Entailment Task ○ Task 3 : The Statute Law Retrieval Task ○ Task 4 : The Legal Textual Entailment Data Corpus 	<p>COLIEE - 2022 (Competition on Legal Information Extraction / Entailment)</p>	<p>Task 1, 2) 캐나다 연방 법원 판례법(case law)의 4,415 건의 데이터. Task 3,4) 일본 법률 시험 데이터와 일본 민법 데이터.</p>
--	-------------	---	---	---

CAIL(Chinese AI and Law Challenge)는 2018 년부터 시작하여 3 가지 태스크를 목표로 하고 있다. 법률 데이터를 기반으로 질의응답을 진행하는 법률 QA(Legal Question-Answering), 법률 케이스 내 요소를 예측하는 법률 케이스 요소 예측 (Legal Case Element Prediction), 유사 사건 도출(Similar Case Matching)이다. CAIL 에서는 매년 태스크와 관련된 데이터를 참가자들에게 제공하고, 참가자들은 해당 데이터셋을 기반으로 각자의 모델을 구축해 결과를 제출한다. [11]은 유사 사건 도출과 관련하여 사채와 관련된 중국 판결문 8,964 건 중 기준 판결문인 A 가 있다면 비교 대상 판결문 B 와 C 중 기준 판결문 A 와의 유사도를 측정하는 것을 목표로 한다.

COLIEE(Competition on Legal Information Extraction / Entailment)에서는 4 가지의 태스크를 목표로 하고 있으며, Task 1 과 2 는 캐나다 연방 법원 판례법(case law)의 4,415 건의 데이터를 기반으로 진행하고, Task 3,4 는 일본 법률 시험과 일본 민법 데이터를 영어로 번역한 데이터를 기반으로 진행한다[12]. Task 1 (The Legal Case Retrieval Task)은 새로운 사건 Q 가 주어졌을 때, Q 를 법적으로 지지하는 사건 R 를 찾아내는 것을 목표로 하고 있으며[13], Task 2 (The Legal Case Entailment Task)는 Task 1 과 비슷하게 새로운 사건 Q 가 주어졌을 때, 해당 Q 를 지지하는 사건 R 내 문단 S 중 가장 많이 지지하는 내용을 담고 있는 문단 S 를 찾는 것을 목표로 한다[14]. Task 3 (The Statute Law Retrieval Task)은 일본 법률 시험의 문제를 기반으로 일본 민법 중 관련 있는 조항을 추출한다[15]. Task 4 (The Legal Textual Entailment Data Corpus)는

Task 3의 후속 태스크로 일본 법률 시험 문제와 일본 민법으로 이루어진 데이터 쌍의 유사성을 유사하다(Yes)와 유사하지 않다(No)의 답을 제출하게 된다[15].

이렇듯, 외국에서는 유사 사건 검색을 위한 다양한 데이터를 제공하고 있다. 하지만, 국내에서는 [10]을 제외하고는 유사 사건을 위한 별도의 데이터셋이 존재하지 않고, 유사 사건 도출과 관련된 연구 진행도 미미한 편이다. 2022년 COLIEE 워크숍 내 Task1과 2에는 각각 6개의 팀이 결과를 제출하였고 Task 3과 4에는 8개의 팀이 참가하였으며[12], 2019년에 개최된 CAIL2019-SCM에는 총 247개의 팀이 참가하였다는 점[11]에 비해 국내에서 유사 사건과 관련된 연구 진행은 상당히 적은 수로 보인다.

제 2절 유사 사건 도출 기능을 제공하는 국내 판결문 검색 서비스

앞서 국내외에서 판결문의 유사함을 판단하는 학문적 연구를 살펴보았다면, 현장에서 실제로 사용되고 있는 정부 또는 민간기업 판례 검색 서비스의 기능도 자세히 알아볼 필요가 있다. 판결문은 공공데이터로 개방되어야 하는 데이터이나[16], 그간 판결문을 접근하는 방법은 법원이나 검찰 등 법률 직종에 종사하거나, 법원도서관장의 승인을 얻은 일반인만을 대상으로 접근 가능했으며, 2 시간이라는 제한적인 시간 내에 원하는 판결문을 검색 및 열람할 수 있었고, 원하는 판결문이 있을 경우, 별도의 신청 절차를 거쳐 교부 받게 되는 등 상당한 제약이 있었다[17]. 이에 대법원은 2010 년 03 월에 「사법제도 개선안」을 발표하였고 민사소송법 및 형사소송법의 개정을 통해 민사 판결문은 2015 년 01 월 01 일부터, 형사 판결문은 2013 년 01 월 01 일부터 모든 판결문을 공개하게 되었다[18]. 특히 법원에서는 2019 년에 인터넷 열람 제도를 시행하며 법원명-사건번호-사건당사자명을 모두 입력해야 했던 기존 시스템과 다르게 키워드 검색이 가능한 판결서 열람 검색 서비스를 실시하고 있다. 법원에서 생성된 판결문이 비식별화 과정을 거친 후 정부의 서비스를 통해 사용자에게 제공되는 과정은 다음 그림과 같다[7].

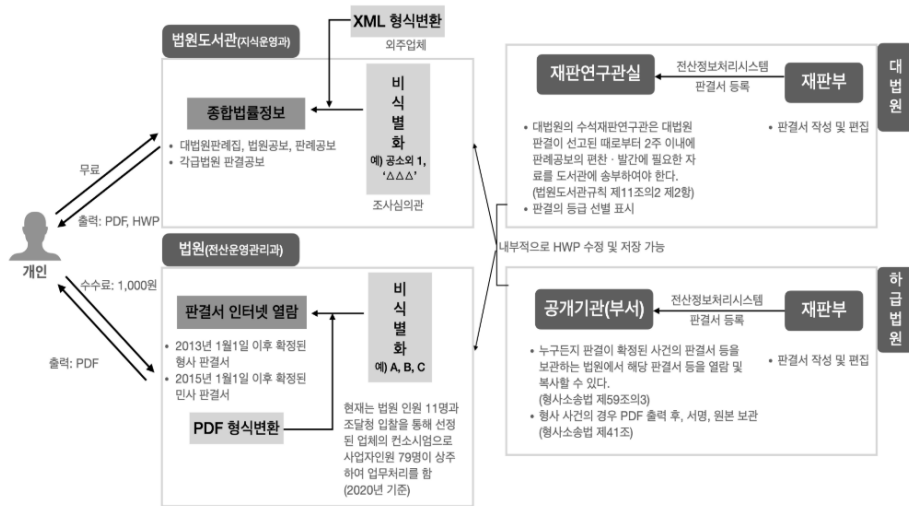


그림 1 판결문이 개인에게 공개되는 과정 도식화

위 그림에서 보는 것과 같이 공공기관 측 대표적인 판례 검색 및 제공 사이트는 종합법률정보서비스와 판결문 인터넷 열람 사이트가 있다. 법원에서 작성한 판결문을 개인정보를 보호하기 위해 비식별화 조치를 취한 다음 종합법률정보와 판결문 인터넷 열람사이트를 통해 개인에게 공개하는 것이다. 따라서, 해당 사이트에서 제공하고 있는 판결문과 검색 기능에 대해 알아본다.

1. 종합법률정보 대국민 시스템

종합법률정보 대국민 시스템은 1998년부터 시작한 서비스로 법원 직원이 판례나 법령, 조약 등 법률 정보를 신속하고 정확하게 검색 및 조회할 수 있도록 만들어진 검색 시스템이다. 해당 시스템에서는 판례, 법령, 조약, 법률 문헌, 대법원 규칙·예규·선례 등 다양한 자료를 무료로 제공하고 있으나, 본 연구에서는 판례 검색에 초점을 맞춰 알아보았다. 2022년 12월 15일 기준으로 종합법률정보에 등록되어 있는 판례는 총

85,716 건이다¹. 종합법률정보에서 제공하는 대법원 판례의 경우 간행 판결과 미간행 판결로 나눠 등록하고 있다. 간행 판결의 경우, 대법원 판례집과 법원공보, 판례공보에 실린 판결문을 소지하고 있다. 미간행 판결의 경우, 1948 년 이후 선고된 미간행 판결 중에 참고판례로서 의미가 있는 판결문을 선별하여 등록하고 있다.

하급심의 경우, 고등법원 판례집과 하급심 판례집 그리고 각급 법원에서 제공하는 판결공보에 실린 판결이 등록되어 있다. 각 판례집의 연도를 통해, 1961 년부터 2022 년 4 월 10 일자까지 실린 판결들을 등록하고 있다. 하지만, 모든 판결문이 등록된 것이 아닌, 해당 판례집에 등록된 판결들만 제공하고 있다. 판례집이나 공보에 실리지 않은 판결문의 경우, 종합법률정보 시스템에서는 제공하고 있지 않다.

표 2 종합법률정보시스템에서 제공하는 판결문 종류 및 출처

심급 분류	판결 분류	제목	세부 내역
대법원	간행 판결	대법원판례집	제 1 권(1953 년 간행) ~ 제 56 권(2009 년 간행)
		법원공보	제 471 호(1973. 9. 1.) ~ 제 1006 호(1995. 12. 15.)
		판례공보	제 1 호(1996. 1. 1.) ~ 제 633 호(2022. 5. 1.)
	미간행 판결	1948 년 이후 선고된 미간행 판결 중 참고판례로서 의미 있는 것을 선별하여 등록	
하급심		고등법원판례집	1961 ~ 1983 년
		하급심판결집	1984 ~ 2003 년

¹ 대한민국 법원 종합법률정보 사이트 첫 화면에 '자료등록현황' 부분을 참고하였다.

	각급법원 판결공보	판결공보 제 1 호 (2009. 9. 10) ~ 제 224 호(2022. 4. 10)
	기타	대법원 판결의 원심판결 또는 제 1 심 판결 중 일부



그림 2 종합법률정보에서 제공하는 단순 검색 기능

종합법률정보에서 제공하고 있는 판결문 검색 방법은 3 가지이다. 첫번째로 단순 검색이 있다. 단순 검색에서는 사용자가 원하는 키워드를 입력하여 이에 해당하는 판결문을 제공해주는 방식이다 (그림 2). 사용자가 넣은 키워드를 판결문의 내용과 매칭시켜, 가장 적합한 판결문을 보여주는 방식으로 사용된다. 단순 검색의 경우, 검색어로 어떤 단어를 입력해도 결과는 도출되나, 사용자가 원하는 결과를 검색하기 위해서는 사용자 스스로 여러 번의 검색어를 넣고 결과를 도출해보아야 한다. 해당 검색 기능의 경우, 단순 키워드 검색이므로, 유사 사건을 도출하기 매우 어려운 것으로 보인다.

그림 3 종합법률정보 내 상세 검색 기능

두번째 검색 방법으로는 상세 검색이 있다 (그림 3). 상세 검색은 단순 검색에 비해 더 많은 검색 필터를 제공함으로써, 사용자가 원하는 판례를 찾을 수 있도록 대상을 좁혀주는 기능이다. 상세 조건 필터로는 사건번호, 사건명, 참조 조문, 항목 범위, 사건 종류, 선고일자, 판례등급, 법원명이 있고 상세 검색 기능에서는 '쉬운 연산자 입력'이라는 기능도 지원하고 있다. '쉬운 연산자 입력'은 연산자 입력이 힘든 일반인들을 위해 만들어진 기능이다. 여기서 제공하는 '제외할 단어', '완전히 일치시킬 단어', '앞부분이 일치할 단어', '뒷부분이 일치할 단어' 그리고 '인접한 단어' 기능들을 검색하기 쉽게 말로 풀어 두었다. '쉬운 연산자 입력' 기능으로 연산자에 넣을 내용을 완성시킨 뒤, '검색창에 적용하기' 버튼을 통해 사용자가 넣은 키워드 뒤에 해당 연산자 내용을 넣어 상세 검색을 진행할 수 있다. 상세 검색 또한 앞서 본 단순 검색과 크게 다르지 않기 때문에 유사 사건을 검색하기는 어려운 것으로 파악된다.

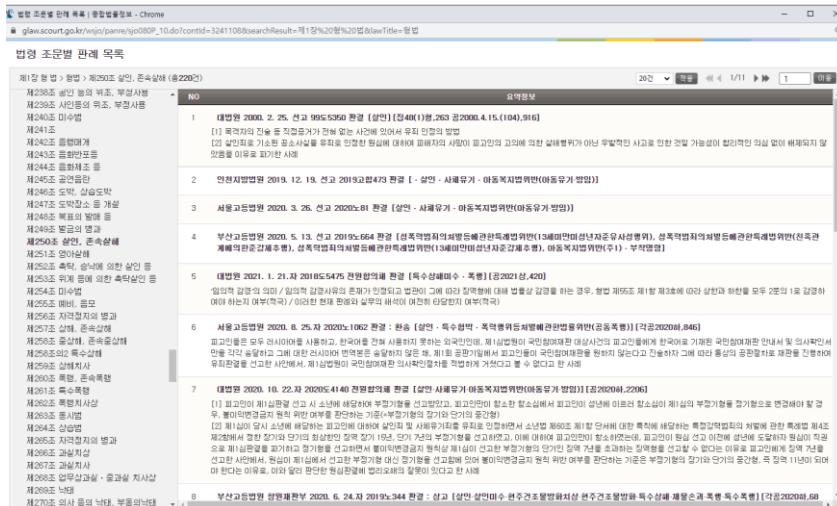


그림 4 종합법률정보 디렉토리 검색을 통해 형법 제 250 조를 검색한 결과

마지막으로 판례 검색에서는 ‘디렉토리 검색’을 지원한다(그림 4). ‘디렉토리 검색’은 법조문별 검색과 법률용어별 검색으로 나뉘진다. 법조문별 검색은 각 법률의 세부 조문을 기준으로 판례를 검색하는 기능이고, 법률용어별 검색은 종합법률정보에서 제공하는 법률용어 중 일부를 추출해서 검색어로 활용하는 기능이다. 해당 검색 기능은 종합법률에서 제공하는 검색 기능들 중에서 가장 유사 사건에 흡사한 기능이다. 예시로 ‘형법 제 250 조(살인, 존속살해)’를 검색하면, 아래와 같이 결과가 도출된다. 먼저, 법조문 분류에서 형법을 찾고, 형법 조문 중 제 250 조를 검색하였다. 하지만, 각 사건끼리 관계와 5 가지 사건의 등수가 내포하고 있는 의미를 파악할 수 없었다. 이후에는 정부에서 제공하는 또다른 판결문 열람 사이트인 ‘판결서 인터넷열람 사이트’에 대해 알아본다.

2. 판결서 인터넷열람

국가에서 제공하는 판결문 검색 및 열람 서비스로는 ‘판결서 열람 사이트’가 있다. 해당 사이트는 2013년 01월 01일부터 확정된 형사사건을 유료로 열람할 수 있다. 2014년 01월 01일부터 형사사건의 판결문 뿐만 아니라 증거 목록과 기록 목록 등 판결에서 사용한 전자 문서들도 같이 제공되고 있으며, 제공하는 판결서 및 기타 서류들은 모두 비식별화 조치가 된 판결서로, 보안상의 이유로 이미지 형태의 PDF 파일로 제공한다. 판결문 검색을 위해서는 본인인증 절차를 거친 뒤, 최대 2년까지의 선고 일자를 선택하고, 법원명, 사건번호, 관련 법령과 검색어 등을 통해 검색을 진행할 수 있다 (그림 5). 검색 결과 내에서 필요한 판결문을 선택하고 1건당 1,000원의 수수료를 내면 해당 판결서를 조회 및 다운로드 할 수 있다. 해당 기능을 제외하고는 판결문 인터넷 열람사이트에서는 유사 사건과 관련된 기능을 제공하고 있지 않다.

그림 5 판결서 인터넷 열람 사이트에서 제공하는 판결문 검색 기능

정부에서 제공하는 판결문 열람 서비스로는 ‘종합법률정보 시스템’과 ‘판결문 인터넷 열람 사이트’가 있다. 종합법률정보 시스템 내 판결문은 모두 무료로 제공받을 수 있으나, 사실 관계를 담고 있는 하급심 보다는 법리 판단을 주로 하는 3심 판결문을 위주로 제공하고 있다. 검색 기능으로는 키워드 중심인 단순 검색과 상세 검색 그리고 법령 중심인 디렉토리 검색이 있으나, 본 연구에서 중점으로 두는 사실 관계를 기반으로 한 유사 사건 검색 기능은 없었다. 또 다른 서비스인 ‘판결서 인터넷 열람사이트’는 종합법률정보 시스템과는 달리 판결문 1건당 1,000 원의 수수료를 부과하고 있고, 1,2,3심의 다양한 판결문을 제공받을 수 있다. 하지만, 종합법률정보 시스템과 마찬가지로 단순한 키워드 검색만 제공하고 있으며, 하급심 내 범죄사실을 기반으로 하는 유사 사건 검색 기능은 없었다.

이러한 공공 서비스 부문에 발맞춰, 민간 서비스에서도 판결문 검색 및 열람을 위한 서비스가 개진되었다. 먼저, 2001년 법무법인 태평양에서 종합 법률포털서비스인 ‘로앤비’를 출범하였다. 로앤비는 법무법인 태평양이 20년 넘게 쌓아온 기업법무 DB와 법률 관련 콘텐츠를 기반으로 법령, 판례, 법률 서식 정보를 제공하고 일반인들도 쉽게 검색할 수 있도록 자연어 검색을 기본으로 사용하고 있다[19]. 로앤비에서 사용한 자연어 검색을 기반으로 민간에서도 다양한 기술을 접목한 판결문 검색 및 열람 서비스가 생겨났다. 이후, 2020년 03월에는 인공지능 기술을 활용해 판결문 검색 및 열람 서비스를 제공하는 ‘엘박스’가[20], 2022년 01월에는 로앤컴퍼니에서 ‘빅케이스’가 출범되었다[21]. 앞서 언급한 판결문 검색 및 제공 사이트 중, 민간에서 운영하는 ‘엘박스’와 ‘빅케이스’에서 사용자들을 위해 제공하는 ‘유사 사건 검색 기능’을 중심으로 자세히 알아본다.

3. 엘박스 (LBox)

엘박스(LBox)는 2020년부터 출범한 서비스로 2022년 12월 07일을 기준으로 총 1,750,888건의 판결문을 보유하고 있다². 엘박스는 회원 가입을 한 사람들에 한하여 하루에 3건을 무료로 열람할 수 있으나, 이후 초과되는 건수는 멤버십에 가입하여 일정 금액을 지불하는 유료 회원에게만 공개하고 있다. 엘박스에서는 회원에게 판결문 열람과 관련한 다양한 서비스를 제공하고 있다. 크게 검색 기능과 알람 기능 그리고 판례 기능으로 나눌 수 있다 (표 3). 먼저 **검색 기능**은 사용자가 판결문을 검색할 때, 특정 법조문을 검색어로 사용함으로써, 해당 법조문을 포함하고 있는 판례를 모아볼 수 있는 기능이 있다. 그리고 **판례지도 뷰 기능**을 통해, 판례가 상급 법원에 올라가는 단계나 참조 및 인용한 판례를 보여준다. 판례를 열람 중에 특정 쟁점으로 유사한 사건을 검색할 수 있는 **유사판례 검색 기능**도 제공하고 있다.

표 3 엘박스 기능 요약

기능 분류	세부 기능	설명 요약
검색 기능	법조문으로 검색 가능	특정 법조문으로 포함하는 판례 검색
	판례지도 뷰 검색	검색된 판례 중 영향력이 높은 판례와 그 판례의 참조 및 따름 판례 파악
	유사판례 검색	특정 쟁점으로 유사 판례 검색
알림 기능	판례 구독 신청	자주 사용하는 검색 조건을 저장하여, 해당하는 판례 등록 여부 알람
	미등록 판례 요청	미등록 판례 요청
	사건 캘린더	원하는 사건과 관련된 일정 알람
판례 기능	판례 보관함	원하는 판례를 따로 보관하여 관리
	하이라이트 표시	판례 중 하이라이트 표시

² 엘박스 사이트 첫 화면에 기입되어 있는 판례 보유 수를 참조하였다.

	하이라이트 포함 인쇄 및 공유	하이라이트 표시 부분과 함께 판례 인쇄 및 공유
	메모	판례 내 메모 작성 및 저장

4. 빅 케이스

빅케이스는 로앤컴퍼니에서 2022 년에 출범한 서비스이다. 로앤컴퍼니에서는 이전에 ‘로톡(LAWTALK)’이라는 서비스를 통해 변호사 중개 서비스 및 인공지능(AI)을 기반으로 형량 예측 서비스를 제공했었다.³ 하지만, 로톡에서는 판결문을 공개하지 않고 중개 서비스 및 인공지능(AI)을 기반으로 형량 예측 서비스만을 제공했다. 이에, 보유중인 판결문을 공개하고, 유사 사건을 검색할 수 있는 빅케이스 서비스를 제공하게 되었다. 2022 년 12 월 07 일을 기준으로 빅케이스에서 수집하여 전문을 공개한 판결문의 개수는 3,289,660 개이다.⁴ 비회원의 경우, 수집된 판결문 중 빅케이스에서 공개하는 15 만건 내외의 판결문을 열람할 수 있다. 비공개 판결문을 열람하고 싶을 경우 일정 금액을 지불하는 유료 회원으로 전환해야 한다. 빅케이스가 회원에게 제공하는 서비스는 크게 3 가지가 있다. 첫번째는 **AI 요약 보기 기능**으로 인공지능이 열람하고 있는 판결문의 요점을 판결문에서 찾아서 하이라이트 해주는 기능이다. 해당 기능을 통해 사용자가 판결문의 전문이 아닌 요점을 간략하게 읽고 판결문을 빠르게 파악할 수 있도록 돕는다. 두번째는 **서면으로 검색 기능**으로 변호사인 사용자를 위한 서비스로서, 변호사 업무 중에 사용되는 서면, 소장, 의뢰인과의 상담 문서의 내용을 복사하여 검색 창에 넣으면, 관련된 판례와 법령을 찾아주는 서비스이다. 마지막으로 **유사판례 검색** 기능을 제공하고 있다. 해당

³ 형량 예측 서비스는 2021 년 09 월 30 일을 기점으로 종료되었다.

⁴ 빅케이스 사이트 내 전문 판례 수를 참조하였다.

기능을 통해, 사용자가 열람하고 있는 판결문과 유사한 판결문을 인공지능이 찾아 주는 것을 확인할 수 있었다.

제 3절 검색 엔진의 적용 가능한 자연어 처리 (NLP) 기술

앞서 2 절에서는 국내 판결문 검색 및 열람 서비스를 제공하는 사이트를 파악하고, 해당 사이트에서 제공하는 검색 기능들에 대해 알아보았다. 특히, 유사 사건 검색 기능은 정부에서 제공하는 서비스에서는 찾을 수 없었고, 민간에서 제공하는 엘박스와 빅케이스에서 제공하고 있음을 확인하였다. 이러한 유사 사건 검색 기능은 자연어 처리 기술이 필수적이다. 엘박스는 사실 관계가 잘 반영되어 있는 1 심 과 2 심 데이터의 부족 문제를 해결하기 위해 인공지능을 접목한 기술을 개발하였다고 언급하였고[22], 빅케이스는 한국어 판례 데이터를 학습한 AI 언어 모델을 적용하고, 유사도 측정을 위해 고도의 자연어 처리 기술을 적용하였다고 밝혔다[23]. 따라서, 엘박스와 빅케이스에서 유사 사건 도출에 사용한 자연어 처리 기술에 대해 알아본다.

먼저 자연어(Natural Language)란 사람들이 일상에서 자연스럽게 사용하는 언어를 말하고, 자연어에는 한국어나 영어처럼 다양한 국가나 민족에서 사용되는 언어들이 포함되어 있다. 자연어 처리 (Natural Language Processing)는 사람들이 사용하는 자연어를 컴퓨터가 이해하고 분석할 수 있도록 처리하는 기법을 말한다. 자연어 처리 기법으로 문서 내 단어에 특정 기준을 값을 부여하고 벡터 공간에 임베딩 한다. 이렇게 임베딩된 벡터를 기반으로 특정 문서를 기준으로 유사한 문서를 도출하는 문서 유사도 도출, 문서를 주제에 맞춰 분류하는 문서 분류, 문서 내에서 질문에 해당하는 답을 찾는 질의응답(Question-Answering)등 다양한 태스크를 수행할 수 있게 해준다. 특히, 본 연구에서 사용할 유사 사건 도출과 문서 분류에 대한 자연어 처리의 흐름도는 아래 그림 6 과 같다[24].

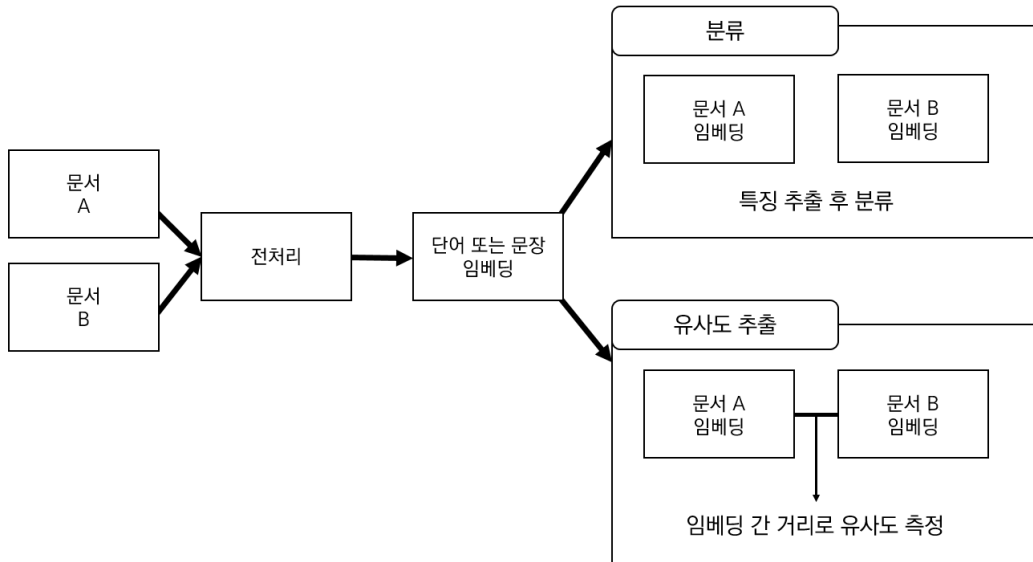


그림 6 유사 사건 도출과 문서 분류를 위한 자연어 처리 흐름도

자연어 처리 단계는 전처리와 임베딩을 통해 얻은 임베딩 값으로 문서 분류 및 유사도 추출과 같은 태스크를 진행한다. 먼저, 전처리 단계에서는 문서 내 문장 또는 단어를 기준으로 토큰으로 분리하고, 각 토큰에 품사 태깅한 뒤, 불용어를 제거한다. 이때 전처리에 사용되는 기준은 각 연구별 목적에 따라 다르게 사용된다. 본 연구에서 사용하는 전처리 방식은 이후 3장에서 다룬다. 두번째 단계는 전처리를 통해 분리된 토큰을 기반으로 해당 단어의 의미를 컴퓨터가 이해할 수 있도록 값을 매겨주는 임베딩 과정을 거친다. 마지막으로, 이렇게 도출된 값을 기반으로 유사도 추출 태스크에서는 임베딩 값 사이의 비교를 통해 유사도를 추출하여 사용하고, 문서 분류 태스크에는 임베딩 값을 모델에 넣고 특징에 추출하여 분리한다. 이후에는 1) 단어의 값을 부여하는 다양한 임베딩 모델과 2) 문서 간 유사도를 측정하기 위한 방법들, 3) 문서 분류를 위해 사용되는 알고리즘들, 4) 분류 모델의 성능을 측정하는 방안에 대해 살펴본다.

1. 단어 표현 (Word Representation)

단어 표현은 단어를 벡터 공간에 단어의 값을 넣어주는 (embedding) 것으로 두 가지 방안이 있다. 첫번째는 국소 표현(Local Representation)으로 각 단어와 유니크한 값을 맵핑(mapping)하는 방법이다. 국소 표현의 예시로는 원 핫 인코딩(one-hot-encoding), Bag of Words 이 있다. 해당 기법은 사용자의 기준에 따라, 중요한 단어를 1 또는 1 이상의 값으로 아닌 단어를 0 으로 임베딩하는 방안이다. 예를 들어, Bag of Words 방식의 경우, 벡터 공간에 나타내고자 하는 목표 단어(Word)를 사전(Bag)에 넣는다. 각 문서 별로 사전에 해당하는 단어일 경우, 벡터에 단어에 배정된 키 값으로 나타낸다. 국소 표현의 단점으로는 첫번째로는 Bag of Words 방식의 경우, 사전에 등록되지 않은 단어일 경우 처리할 수 없다는 단점이 있다. 두번째로는 문서 내 들어가는 단어는 한정적이고, 모든 단어를 다 포함하고 있지 않기 때문에 대부분의 값이 0 으로 채워지고 모든 단어의 수를 고려한 고차원의 희소 행렬 (Sparse Matrix)이 형성된다. 이러한 행렬을 처리하는데 있어 0 으로 채워지는 값이 매우 많아 컴퓨터 연산량을 늘어나는 단점도 가지고 있다.

두번째는 분산 표현(Distributed Representation)으로 0 과 1 로만 임베딩 하는 국소 표현 방안과는 달리 0 부터 1 사이에 있는 실수로 임베딩을 한다. 앞서 설명한 국소 표현의 단점인 사전에 등록되지 않은 단어를 처리할 수 없다는 점과 희소 행렬로 인한 연산량 증가를 해결하기 위해 실수 임베딩을 진행한다. 분산 표현의 예시로는 TF-IDF 가 있다. 문서 내 등장하는 단어의 빈도수인 Term Frequency (TF)에 해당 단어가 등장하는 문서의 수인 Document Frequency 에 전체 문서 수로 나눠 준 뒤 로그 값을 곱해준 Inverse Document Frequency (IDF)를 통해 단어를 처리한다. 해당 TF-IDF 를 통해 다양한 문서에 자주 등장하는 단어인 '은, 는, 이, 가'와 같은 조사의 가중치 값을 줄여준다. 특정 문서 내에서만 자주 등장하는 단어들을 해당 문서의 주제로 파악하여 가중치를 높여준다.

	단어 1	단어 2	단어 3
문서 A	0	1	1
문서 B	1	0	1
문서 C	1	1	0

〈국소 표현 방식의 예시〉

	단어 1	단어 2	단어 3
문서 A	0	0.493	0.572
문서 B	0.721	0	0.361
문서 C	0.611	0.216	0

〈분산 표현 방식의 예시〉

그림 7 국소 표현과 분산 표현을 통해 구축한 각 문서별 벡터 예시

위 그림 7은 국소 표현과 분산 표현을 통해 구성된 문서별 벡터 예시이다. 아래 그림을 통해, 국소 표현은 각 문서내 단어들을 0과 1로만 표현하고 있다는 것을 알 수 있다. 또한, 분산 표현 방식의 경우, 0부터 1사이의 값을 기반으로 국소 표현 방식과는 달리 다양한 값으로 단어를 표현하고 있음을 확인할 수 있다. 국소 표현의 방식을 통해서만 문서 A는 단어 1보다 단어 2와 3이 더 중요한 것을 알 수 있다. 하지만, 단어 2와 3 중에 어떤 단어가 더 중요한지 파악할 수 없다. 하지만, 분산 표현의 경우, 문서 A에서는 단어 2보다 단어 3이 더 중요한 역할을 하는 것을 알 수 있다. 단어의 가중치를 나타낼 수 있는 분산 표현 방식을 사용하되, 단어가 내포하고 있는 의미를 벡터에 제대로 담기 위해 후에 나오는 임베딩 방안들이 고안되었다. 이후부터는 임베딩의 다양한 방식들에 대해 알아보겠다.

2. 임베딩 (Embedding)

머신 러닝 기법의 등장으로, 자연어처리분야에서도 비지도 학습(Unsupervised Learning)을 통한 워드 임베딩과 같은 방식이 등장하였다[25]. 워드 임베딩은 모델이 머신 러닝의 다양한 기법으로 대량의 코퍼스를 학습하여, 각 단어의 의미를 파악해 수치화 하여 사용한다. 이러한 워드 임베딩 기법은 앞서 국소 표현에서 문제점으로 지적되었던 고차원의 희소 벡터가 아닌 저차원의 벡터에 단어의 의미를 더 풍부하게 담을 수 있다. 또한, 국소 표현에 비해 단어의 내포된 의미를 더 잘 담고 있어 단어끼리 유사도 비교가 가능하게 한다. 워드 임베딩 방식의 예시로는 신경망 기반의 **Feed-Forward Neural Net Language Model(NNLM) 모델**이 있다. 해당 모델의 가장 큰 문제점은 Non-linear 은닉층으로 인한 계산도가 복잡하고 학습하고자 하는 단어의 이전 단어만을 고려하여 의미를 수치화 한다는 점이다. 해당 방식으로 학습을 진행할 경우, 다음 단어는 전혀 고려하지 못하여 단어의 내포된 의미를 제대로 담았다고 보기 어렵다. 또한, 계산이 복잡하고 느리다는 단점도 존재하였다.

가. Word2Vec 과 WMD

앞서 알아본 NNLM 모델을 보완하기 위해 **Word2Vec 모델**이 등장하였다. Word2Vec 은 가장 큰 목적은 Non-linear hidden layer 로 인해 높아지는 계산 복잡도를 줄이고 더 깊은 단어의 의미를 표현하는 것이다[26]. Word2Vec 방식의 전제 조건은 ‘비슷한 단어는 비슷한 벡터 공간 내에 위치한다’이다. 아래 그림 8 을 보면, 강아지와 고양이는 동물이라는 비슷한 성격을 가진 단어들로, Word2Vec 이 이러한 성격을 반영해 강아지와 고양이를 비슷한 벡터 공간 내 위치하도록 하는 것을 볼 수 있다. 이와 비슷하게, 강아지들과 고양이들도 강아지-고양이 관계처럼 비슷한 관계를 띤다. 위와 같이 성격이 비슷한 단어끼리 비슷한 공간의 위치한 점을 이용해 단어끼리 연산을 가능하게 한다.

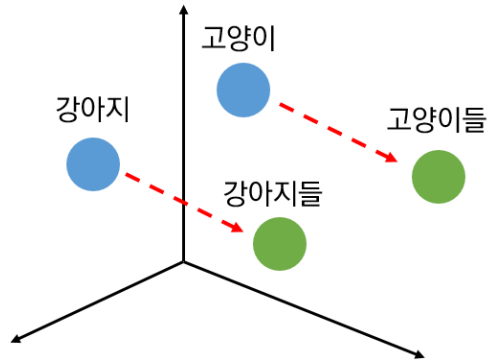


그림 8 Word2Vec 에서 단어를 이용해 벡터를 생성 및 단어끼리 연산 방법 도식화

단어와 단어 사이의 관계를 연산할 수 있게 하기 위해서 Word2Vec 은 두가지의 학습 방식을 사용한다. 첫번째는 Continuous Bag-of-Words (CBOW) 방식이다. 해당 방식은 단어의 앞과 뒤의 단어를 고려하여 단어를 예측할 수 있도록 학습한다. CBOW 방식은 비선형의 hidden layer 를 없애고, projection layer 가 모든 input 을 공유함으로써, 계산 복잡도를 낮췄다. CBOW 방식의 계산 복잡도를 hierarchical softmax 방식을 사용해 낮춘 방식은 아래와 같다.

$$Q = N \times D + D \times \log_2(V)$$

두번째는 skip-gram 방식이다. 해당 방식은 한 단어를 기점으로 주위의 등장하는 단어의 등장 여부를 유추하는 방식이다. Skip-gram 방식도 CBOW 방식과 비슷하게 hierarchical softmax 를 통해 계산 복잡도를 낮춘 방식은 아래와 같다. 아래 그림 9 는 CBOW 방식과 Skip-gram 의 방식을 도식화한 것이다. 이러한 학습 방식으로 Word2Vec 은 단어를 벡터를 표현할 때, 유사한 단어는 유사한 공간에 위치하고, 해당 벡터를 통해 단어 간의 연산을 가능하게 한다.

$$Q = C \times (D + D \times \log_2(V))$$

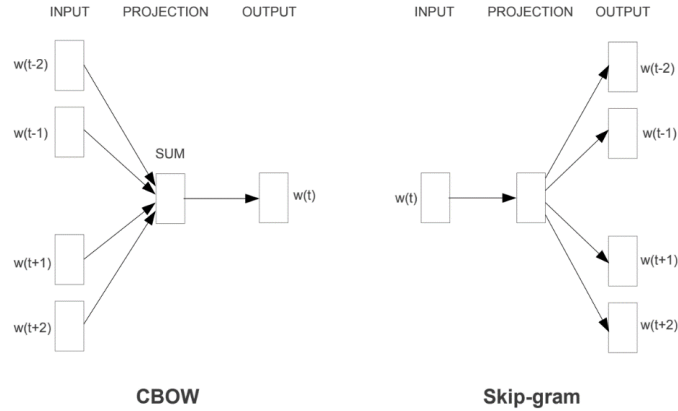


그림 9 Word2Vec 의 학습 방식인 CBOW 방식과 Skip-gram 방식 도식화

Word Mover Distance (WMD)은 Word2Vec 의 임베딩 방식을 사용함으로써, Word2Vec 의 장점인 유사한 단어는 유사한 공간에 위치한다는 점과 단어와 단어 사이의 연산이 가능하다는 점을 활용한다. WMD 는 Word2Vec 의 임베딩 값을 사용하여 비교하고자 하는 문서들 사이의 단어들을 추출하여 단어끼리 거리를 측정하여 문서 사이의 유사도로 사용한다. 아래 그림 10 을 보면, 기준 문서인 D_0 와 비교하고자 하는 문서인 D_1 , D_2 사이의 거리를 계산한다. D_1 와 D_2 내 단어와 D_0 의 단어 사이의 거리를 기반으로 D_1 와 D_2 그리고 D_0 사이의 유사도로 사용한다. 만약, 비교하고자 하는 문서와 기준 문서의 단어 수가 다른 경우에는 모든 단어 대비 가장 짧은 거리를 유사도로 사용한다.

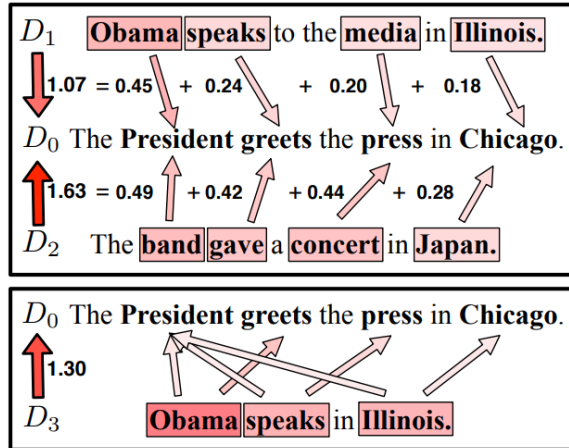


그림 10 WMD 에서 사용하는 문서 간 거리 측정 방안 도식화

나. GloVe

GloVe (Global Vectors for Word Representation)은 2014 년 미국 스탠포드 대학교에서 개발한 단어 임베딩 방법론이다. GloVe 는 예측 기반 방식의 Word2Vec 과 카운트 기반 방식의 LSA 의 한계를 넘어선 것에 의의를 갖고 있다. Word2Vec 의 경우, 학습하는 단어의 주변 단어로만 학습을 하기 때문에, 말뭉치 전체에 대한 통계량을 활용하지 못한다는 단점이 있다. LSA 의 경우, 말뭉치의 전체적인 통계 정보를 고려하지만, 단어 유추 문제에 약하다는 단점을 갖고 있다. 이에, GloVe 는 말뭉치 전체에 대한 통계량을 고려하면서 단어 유추를 할 수 있게 하여, Word2Vec 과 LSA 의 한계를 보완한다[27].

표 4 GloVe 에서 사용하는 동시등장확률의 예시

	k = 커피	k = 강아지	k = 바지
P(k/맛있는)	0.89	0.1	0.3
P(k/멋있는)	0.14	0.74	0.89
P(k/맛있는)/P(k/멋있는)	6.3571	0.1351	0.3370

GloVe 에서는 단어의 의미를 계산하면서 문서 전체의 통계를 반영하기 위해 동시 발생 확률 (Co-Occurrence)를 활용한다. 동시 발생 확률은 동시에 등장한 단어의 빈도수를 전체 말뭉치 단어 개수를 나눈 값을 활용한다. 위 표 4 를 예시로 들어보면, k 는 중심 단어로 ‘커피’, ‘강아지’, ‘바지’를 기준으로 잡았다. 먼저, 한 문서 내에 기준 단어인 ‘커피’가 등장하면서 ‘맛있는’ 이라는 단어가 등장할 확률과 ‘멋있는’이라는 단어가 등장하는 확률을 구한다. 상식적으로 ‘멋있는 커피’ 라는 말보단 ‘맛있는 커피’라는 말이 더 자연스럽게 때문에, 커피라는 단어가 맛있는 이란 단어와 함께 등장할 확률 (P(커피/맛있는))이 더 높은 것을 확인할 수 있다. 이렇게 계산된 맛있는 커피의 확률과 멋있는 커피의 확률을 나눠 상호 간의 비율 정보 또한 단어의 의미로 이해하여 임베딩하는 방식으로 진행된다. GloVe 를 발표한 논문[27]에서는 [28]의 데이터셋을 이용하여 Word2Vec (Skip-gram 방식과 CBOW 방식)을 포함한 다양한 모델의 단어 유추 성능을 비교한 결과, GloVe 가 대체적으로 우수했으며, CoNLL-2003 벤치마크 데이터셋을 기반으로 개체명인식(Named Entity Recognition) 태스크의 성능을 F1 스코어로 비교해본 결과 대부분의 데이터 셋에서 좋은 성능을 보여주었다고 밝혔다.

다. 트랜스포머 계열 모델인 BERT 와 KoBERT

Word2Vec 과 GloVe 의 모델을 통해 이전 모델인 국소 표현 모델 보다 더 좋은 품질의 임베딩을 진행할 수 있었으나, 더 높은 임베딩 수준을 충족시키기 위해 ELMO 모델이 공개되었다. ELMO[29]는 Embedding from Language Model 의 약자로 해당 모델의 목표는 언어의 구문 분석이나 의미 유사적 관점에서 복합적인 언어의 성격을 잘 담아내는 것이다. 한국어의 경우, 동음이의어가 대표적인 예시이다. 예를 들어, ‘말’이라는 단어는 동물로 해석될 수 있고, 사람의 생각을 전달하는 매개체로 이해될 수 있다. 사람의 경우, ‘말’이라는 단어의 뜻을 해당 단어가 등장하는 문맥에 따라 이해할 수 있지만, Word2Vec 과 GloVe 의 경우, 동음이의어를 구분할 수 없어서 같은 값으로 처리한다. 따라서 ELMO 에서는 단어를 임베딩할 때, 문맥을 반영한 임베딩 (Contextualized Word Embedding)을 진행하는 것을 목표로 한다.

기존의 LSTM 모델을 활용한 ELMO 의 경우, 모델의 입력 값을 순차적으로 트랜스포머를 활용한 모델들이 등장하면서 좋은 성능을 보여주고 있다. 트랜스포머를 활용한 모델로는 Bidirectional Encoder Representations from Transformers (BERT), Generative Pre-Training (GPT) 등이 있다. 이중에서, BERT 와 KoBERT 에 대해서 알아보겠다. BERT[30]는 2018 년 구글에서 공개한 사전 훈련된 모델이다. BERT 는 트랜스포머의 인코더를 쌓아 올린 구조로 셀프 어텐션(Self-Attention)을 활용해 문맥을 반영한 임베딩 (Contextual Embedding)을 사용하고 있다. Attention 기법[31]이란 입력 값으로 들어온 단어와 모델이 예측 해야할 단어에 집중하여(Attention) 보는 기법이다. 따라서, 입력 값으로 받은 데이터를 학습하는 과정에서 Encoder 에서 누적한 데이터의 특징을 바로 Decoder 에 넘기지 않고, Decoder 가 출력을 예측할 때마다 학습할 때 사용한 Encoder 를 참고한다.

아래 그림 11 에 따라, BERT 는 대량의 데이터를 통해 사전 훈련(pre-training)한다. 하지만, 사전 훈련 과정에서 사용되는 데이터는 위키피디아 같은 일반적인 문서이다. 따라서, 사용자의 목적에 따라, 새로운 데이터를 기반으로 추가 학습(fine-tuning)을 진행해야 하고, 추가 학습을 진행한 BERT 모델은 그렇지 않은 모델에 비해 상당히 좋은

성능을 보여준다[32]. BERT 는 사전 훈련 과정에서 2 가지 학습 방안을 사용하는데, 첫번째는 입력 값의 15%의 단어를 무작위로 마스킹(masking)한 뒤, 마스킹한 단어를 마스킹 된 주위 단어를 양방향으로 파악하여 예측하는 방안이다. 두번째 방안은 입력 값으로 두 문장을 제공한 뒤, 해당 문장이 이어지는 문장인지 이어지지 않는 문장인지를 예측하는 방안이다. 두번째 학습 방안을 위해 학습 데이터 중 실제로 이어지는 문장 50%와 나머지 실제로 이어지지 않는 문장 50%을 무작위로 섞어 학습한다. BERT 는 이 두가지 방안으로 사전 학습을 진행하면서 BERT 는 문장 간의 관계 등 언어적 의미를 더욱 더 잘 파악할 수 있게 된다[33].

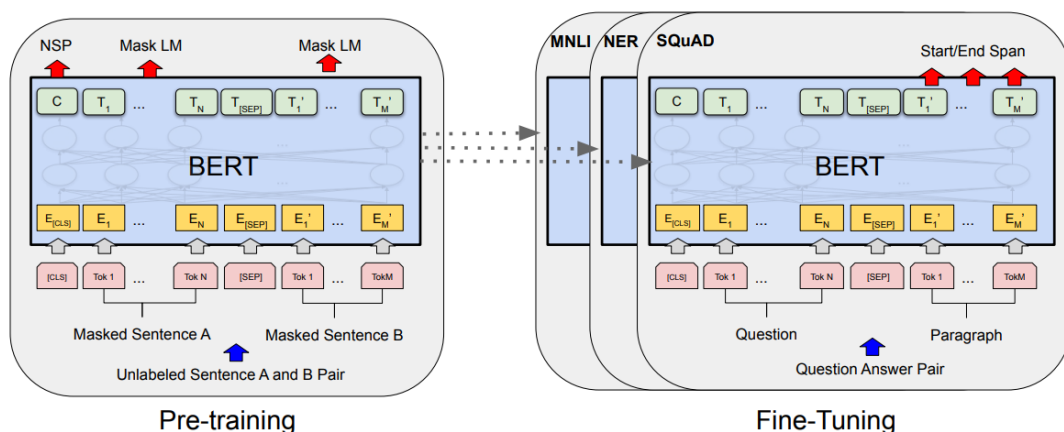


그림 11 BERT 의 사전 훈련(Pre-training)과 추가 학습(Fine-Tuning) 과정 도식화 [14]

BERT(huggingface)에서는 층의 개수나 셀프 어텐션 헤드의 수 등을 기반으로 Base 모델과 Large 모델을 공개하고 있고, 영어 데이터로 사전 훈련한 모델과 다양한 언어 데이터를 기반으로 훈련한 bert-base multilingual 모델도 공개하고 있다[34]. 하지만, SKTBrain 에서는 다국어를 지원하는 bert-base multilingual 모델이 한국어 성능의 한계를 갖고 있음을 지적하며, 한국어 위키피디아와 한국어 뉴스 등의 자료로 총 500 만개의 문장을 기반으로 학습한 KoBERT 를 공개하였다[35]. 네이버 감성 영화 말뭉치 (Naver Sentiment Movie Corpus, NSMC)를 기반으로 LSTM, BiLSTM, CNN,

BERT(Multilingul-cased)와 KoBERT(SKTBrain) 모델을 비교해본 결과, BERT(Multilingul-cased) 모델 보다 한국어 데이터로 학습시킨 KoBERT(SKTBrain)의 성능이 더 뛰어난 것을 확인할 수 있었다[36].

3. 유사도 측정 방법

분석할 데이터를 단어 단위로 나누고 특정 값을 부여하여 만든 벡터를 만들었다. 유사도 측정은 해당 벡터에서 특정 단어를 기준으로 유사도를 측정하여 기준 단어와 가장 비슷한 단어를 도출해 내는 방법을 말한다. WMD 와 같이 모델에서 자체적으로 유사도 방안을 제공하는 경우를 제외하고, 대부분 임베딩 모델을 이용해 만든 벡터 간 유사도를 측정하는 방법에는 주로 Cosine 을 이용한 방식을 주로 사용한다[37]. 따라서, 본 연구에서는 Cosine Similarity 와 해당 방식을 기반으로 변화를 준 Soft Cosine Similarity 를 사용하였고, 각 방식에 대해 알아보겠다.

가. Cosine Similarity

Cosine Similarity 는 두 벡터 A 와 B 사이의 코사인 각도를 측정해 유사도를 판별한다. 벡터의 각도를 측정할 때, 두 벡터의 방향이 가장 중요하다. Cosine Similarity 는 -1 이상 1 이하의 값으로 도출된다. 만약 두 벡터의 방향이 정반대일 경우, Cosine Similarity 는 -1 을 도출한다. 두 벡터의 방향이 같다면 1 의 값을 도출한다. 따라서 Cosine Similarity 의 값이 1 과 가까울수록 두 벡터는 상당히 유사하다고 볼 수 있다.




그림 12 두 벡터 사이의 각도로 보는 Cosine Similarity 값 변화

분석하고자 하는 문서의 내용을 기반으로 만들어진 벡터들을 유사도를 측정할 때 Cosine Similarity가 많이 사용된다[37]. 각 문서마다 길이가 다르기 때문에 벡터화를 진행했을 때 각 문서를 나타내는 벡터의 크기가 다를 수 있다. Cosine Similarity는 측정하고자 하는 대상 벡터의 크기나 각도가 달라도 유사도 측정의 영향을 주지 않기 때문에 문서 간의 유사도 측정에 Cosine Similarity를 많이 활용한다. Cosine Similarity를 구하는 수식은 아래와 같다.

$$\text{similarity} = \cos(\theta) = \frac{X \cdot Y}{\|X\| \|Y\|}$$

나. Soft Cosine Similarity

Cosine Similarity의 경우, 비교하고자 하는 두 벡터 간의 방향만 고려해 유사도를 측정하기 때문에, 벡터 사이의 공통되는 단어가 없을 경우, Cosine Similarity는 매우 낮은 값을 반환한다. 하지만, 각각의 문서의 유사도를 측정함에 있어, 단순 문서 벡터 뿐만 아니라 벡터를 구성하는 단어의 유사도 또한 고려할 필요가 있다. Soft Cosine Similarity[38]는 문서 벡터 내 단어 간의 유사도를 고려하여 최종적으로 문서 간의 유사도를 측정하는 방식이다. 기존의 사용하던 Cosine Similarity를 구하는 식에 ' s_{ij} '를 추가한 형식이다. 이를 통해, 유사도를 측정하고자 하는 두 벡터가 담고 있는 문장 내 단어의 유사도 또한

고려하여 최종적인 벡터 유사도를 측정할 수 있게 된다. 아래 그림은 Cosine Similarity 와 Soft Cosine Similarity 를 비교한 그림이다[39].

문서 1 — Hi, World!

문서 2 — Hello, World!

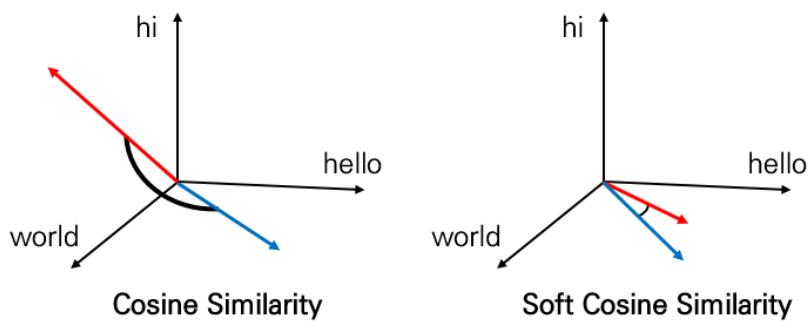


그림 13 Cosine Similarity 와 Soft Cosine Similarity 비교 그래프

$$\text{soft_cosine}(a, b) = \frac{\sum \sum_{i,j}^N s_{i,j} a_i b_i}{\sqrt{\sum \sum_{i,j}^N s_{ij} a_i a_j} \sqrt{\sum \sum_{i,j}^N s_{ij} b_i b_j}}$$

$$s_{ij} = \text{sim}(f_i, f_j)$$

4. 문서 분류 모델

자연어를 컴퓨터가 이해하게 하기 위해, 자연어 처리 기법이라는 것을 활용하여 자연어인 단어와 문장을 수치화 하였다. 이렇게 자연어 처리를 통해 얻은 단어별 임베딩 값을 이용해 문장과 문장 사이 유사도 도출, 문장 분류, 감성 분석 등 다양한 태스크에 활용할 수 있다. 이후부터는 해당 논문에서 활용할 문서 분류를 위한 모델을 알아본다. 문서 분류를 위한 모델은 크게 전통적인 머신 러닝 모델과 트랜스포머 계열 모델이 있다. 전통적인 머신 러닝 모델에는 Decision Tree, Random Forest, SVM 이 있고, 트랜스포머 계열 모델에는 KoBERT 와 KLUE bert-base 가 있다.

가. 전통적인 머신러닝 모델

머신러닝은 기존 사용자가 직접 코드를 통해 해결했던 문제를 기계가 데이터와 정답을 보고 직접 학습하는 방식이다. 머신러닝을 통해 회귀와 분류 문제를 해결할 수 있다. 회귀는 연속적인 값을 도출하고 분류는 0,1,2 와 같은 라벨을 도출한다. 분류는 0 과 1 로 분류하는 이진 분류 (Binary Classification)와 2 개 이상의 라벨로 분류하는 다중 클래스 분류 (Multi-Class Classification) 그리고 한 데이터에 2 개 이상의 라벨을 부여하는 멀티 라벨 분류 (Multi-label Classification)로 나뉜다. 본 연구에서는 범죄 사실 내 서술된 동기를 기반으로 분류 작업을 진행하므로 각 데이터에 1 개의 라벨만 부여하고, 2 가지 이상의 라벨을 사용하므로 멀티 클래스 분류 방식들을 살펴본다.

1) Decision Tree

Decision Tree는 의사 결정 규칙을 나무 구조로 시각화하여 분류와 예측을 수행하는 알고리즘이다[40]. Decision Tree는 뿌리 노드(Root Node)에서 중간 노드 (Intermediate Node)를 지나 끝 노드 (Terminal Node)로 가는 과정을 시각화 하여 확인할 수 있다 (그림 12). 이때 뿌리 노드에서 끝 노드까지 진행되는 과정에서는 변수 하나씩만 사용하며 움직이고, 해당 변수는 한번 선택되면 모형에서 제거되지 않는다[41]. Decision Tree에서 중간 노드와 끝 노드를 분류하는 변수로는 엔트로피(Entropy), 지니 계수 (Gini Index), 카이제곱통계량(chi-squared statistic)값을 사용한다[42]. 다양한 변수로 분류하

는 영역의 순도(homogeneity)를 높이고, 불순도(impurity)를 줄이는 방안으로 학습을 진행한다. Decision Tree는 경계가 불연속적이라 설명 변수가 적은 선형 모형에서 결과가 좋지 않다는 단점을 갖고 있다[43].

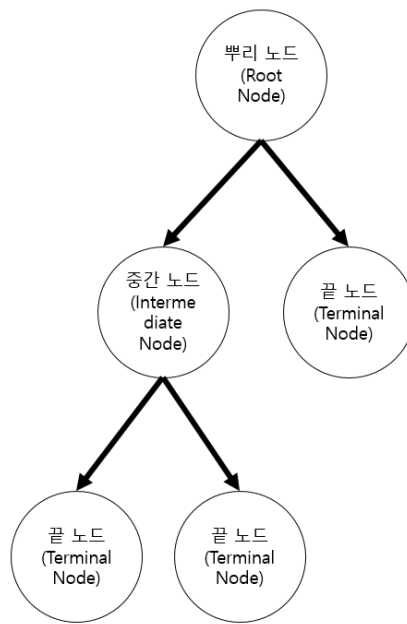


그림 14 Decision Tree 과정 도식화

2) Random Forest

Decision Tree는 모델이 안정적이지 않고, 예측력이 낮다는 단점을 갖고 있다[42]. 따라서 위 문제를 개선하기 위해 제안된 앙상블 모델이 Random Forest[44]이다. Random Forest는 배깅(Bagging) 방식을 통해 동일한 데이터를 무작위로 부분 집합으로 나눠 각 집합에 대한 Decision Tree를 형성한다(그림 13). 각 Decision Tree를 통해 도출된 결과는 과반수 이상의 찬성 또는 전체 평균으로 최종 결과를 도출하게 된다. 이때, 각 트리의 가지를 치지 않고 데이터가 전부 분류될 때 까지 크기를 증가시키기 때문에 각 트리에서는 과적합이 날 가능성이 있으나, 전체적으로 분산이 낮아서 Random Forest 관점에서는 과적합이 나지 않는다[44]. Random Forest는 설명 변수가 다수일 때 예측력이 매우 높고 안정

적인 모형을 제공한다[43]. Random Forest 모델의 단점으로는 Random Forest 작동 방식에서 기인된다. 전체 데이터를 여러 개로 분할하여 각각의 Decision Tree를 구성하고 전체적으로 Forest를 구축하기 때문에 Decision Tree처럼 모델의 결과를 시각화하여 결과를 확인할 수 없다. 따라서, Random Forest는 블랙박스 모형이라고 지칭되며 높은 예측력에 비해 해석력이 낮다는 단점을 가지고 있다[42].

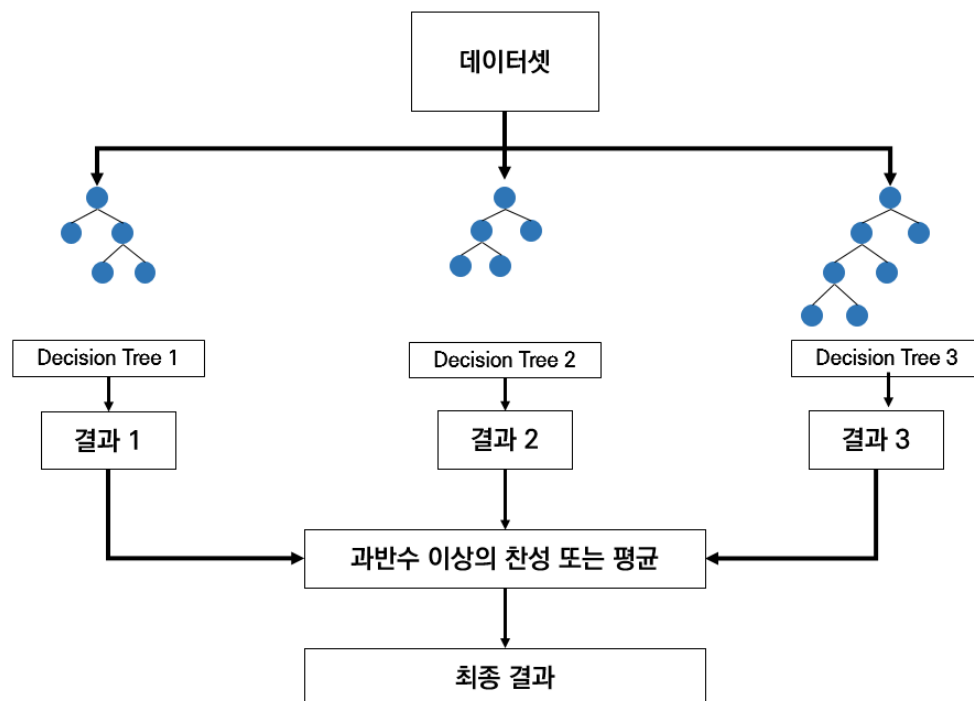


그림 15 Random Forest 과정 도식화

3) SVM

Support Vector Machine (SVM)은 분류(classification)와 회귀(regression)에 응용할 수 있는 지도 학습을 기반으로 한 머신 러닝 모델이다[45]. SVM은 서로 다른 두 집합을 한 개 이상의 초평면(hyperplane)으로 동질적인 데이터로 분류 또는 예측할 수 있는 알고리즘이다[46]. 서포트 벡터 (Support Vector)는 데이터를 분류할 수 있는 기준점이

되는 초평면을 정하는 최대 마진 거리 측정에 이용되는 벡터를 지칭한다(그림 12). 이때 마진은 초평면과 Support Vector 사이의 거리를 의미한다. 실제 데이터 수 보다 초평면을 구할 때 사용되는 Support Vector 의 수가 훨씬 적기 때문에 높은 성능을 도출할 수 있다. SVM 의 장점은 구조를 이해하기 쉽고, 높은 정확도를 가진다는 점이다[47]. 또한, 적은 데이터를 사용해 SVM 을 구축해도 과적합이 될 가능성이 낮고[48], 다른 머신 러닝 모델에 비해 사용자가 조정해줘야 할 파라미터 수가 적다는 점을 포함한다[49].

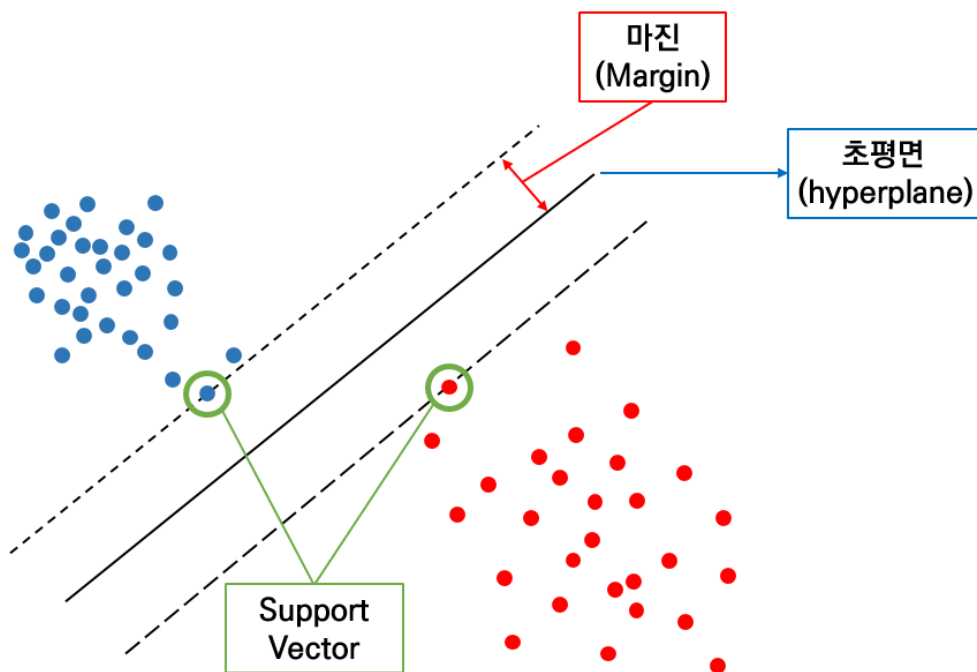


그림 17 SVM 내 핵심 기능 (Support Vector, Margin, hyperplane) 그래프

나. 트랜스포머 모델, KoBERT 와 KLUE

전통적인 머신러닝 기법 외에도 트랜스포머 계열 모델을 활용한 문서 분류 태스크가 가능하다. 특히 BERT에서는 'BERTClassifier'라는 함수를 통해 BERT를 활용한 분류를 지원하고 있다. BERTClassifier는 아래 그림 27과 같이 입력 값을 받아들이고 임베딩 하는

과정은 같다. 하지만, 마지막에 도출하는 결과가 임베딩 값을 도출하는 BERT와는 달리, 입력 값과 정답으로 부여한 라벨 사이의 학습을 통한 라벨 결과값을 도출하게 된다. 단순 BERT 모델의 학습양으로는 사용자의 목적에 맞춰진 분류 문제를 해결하기 어렵다. 따라서, BERT를 이용한 분류 문제 해결에는 목적에 맞춰진 입력 데이터와 해당 데이터의 부여하는 정답 라벨을 통해 BERT모델의 추가 학습 (fine-tuning)이 필수적이다.

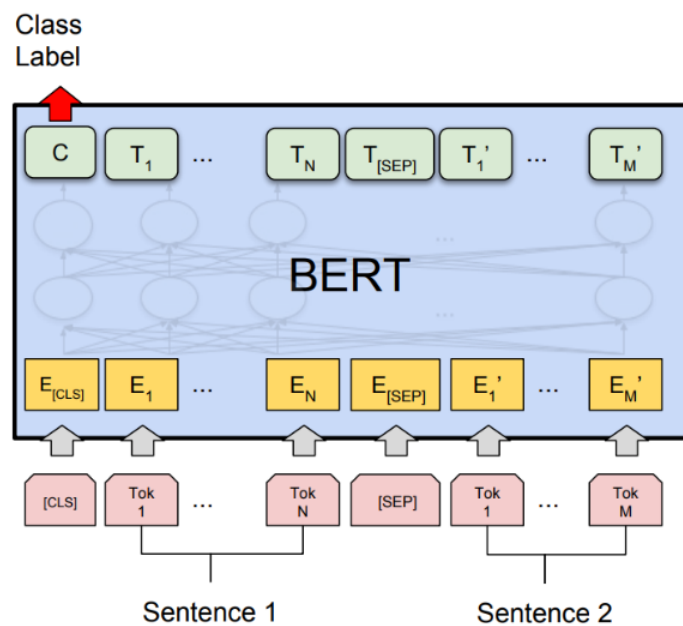


그림 18 BERT 를 이용한 Label 분류 방법 도식화

본 연구에서 분류 문제에 활용하는 트랜스포머 모델은 KoBERT 와 KLUE(bert-base)이다. KoBERT 는 앞서 임베딩 단계에서 언급되었기 때문에 해당 부분에서는 KLUE(bert-base) 모델에 초점을 맞춰 진행한다. KLUE 모델[50]은 KLUE 벤치마크 데이터셋을 기반으로 BERT-base 모델을 학습시킨 모델이다. KLUE 벤치마크 데이터셋은 한국어 데이터의 자연어 처리 성능 평가를 위한 데이터셋이다. 영어 데이터셋의 경우, 자연어 처리를 평가하기 위한 GLUE 데이터셋[51]이 존재하고, 각 언어별로 중국어 버전의 GLUE(CLUE[52]), 불어 버전의 GLUE(FLUE[53])가 존재하나, 한국어 데이터를 위한

자연어 처리 평가 데이터셋 없었다. 이에, 2021 년 KLUE 데이터셋이 공개되었고, KLUE 에서 평가하는 8 가지 세부 태스크는 아래 표 7 과 같다.

표 5 KLUE 에서 제공하는 태스크 및 상세 설명과 각 사용된 데이터

태스크 분류	태스크 설명	데이터
주제 분류 (Topic Classification)	- 뉴스 헤드라인을 기준으로 정치, 경제, 사회, 생활문화, 세계, IT 과학, 스포츠의 카테고리 분류	연합뉴스 (헤드라인)
의미 유사도 (Semantic Textual Similarity)	- 두 문장 간의 의미 유사도를 0 부터 5 사이의 소수점 두 자리까지 허용한 점수로 나타냄	- 정부에서 배포한 기사 (POLICY) - 발화 데이터 세트 (PARAKQC)
자연어 추론 (Natural Language Inference)	- 전제와 가설 사이 관계를 참, 거짓, 중립으로 분류	- WIKITREE - POLICY - WIKINEWS - WIKIPEDIA - Airbnb 리뷰 - 네이버 영화 말뭉치 (NSMC)
개체명 인식 (Named Entity Recognition)	- 하나의 문장을 사람(PS), 위치(LC), 기관(OG), 날짜(DT), 시간(TI), 수량(QT)로 나눠 분석	- WIKITREE - NSMC
관계 추출 (Relation Extraction)	- 문장 내 단어들 간의 의미론적 관계 식별하여 30 개의 관계 레이블링으로 표현	- WIKIPEDIA - WIKITREE - POLICY
의존 구문 분석 (Dependency Parsing)	- 문장 내 단어 간의 관계 정보를 찾아냄	- WIKITREE - Airbnb 리뷰
기계 독해 (Machine Reading Comprehension)	- 문맥을 이해하고 질문의 답을 문맥에서 찾아냄	- WIKIPEDIA - 한국 경제신문 기사 - ACROFAN 의 기사
대화 상태 추적 (Dialogue State Tracking)	- 사람과 컴퓨터 대화에서 사람의 말의 문맥을 파악하여 대화 상태 예측	- 태스크에 맞춰진 대화록 (Task Oriented Dialogue)

5. 분류 모델 성능 측정 방법

각 모델이 분류한 결과에 대한 성능을 비교하기 위해 정확도(accuracy), 정밀도(precision), 재현율(recall) 그리고 정밀도와 재현율의 조화평균인 F1-score 를 측정하여 평가한다. 또한, 모델이 분류한 각 라벨별 정확도, 정밀도, 재현율을 계산하기 위해 오차행렬(confusion matrix) 개념을 활용한다. 오차행렬을 통해, 실제 라벨 값이 참(True)인지 거짓(False)인지에 따라, 모델이 예측한 값이 긍정(Positive)인지 부정(Negative)인지 각 경우 별로 값을 도출한다. 오차행렬을 통해 나온 True Positive(TP), True Negative(TN), False Positive(FP), False Negative(FN)의 값을 활용해 정확도, 정밀도, 재현율, F1-Score 을 계산한다.

표 6 오차행렬 (Confusion Matrix)

		Actual Label	
		True	False
Predicted Label	Positive	True Positive (TP)	False Positive (FP)
	Negative	True Negative (TN)	False Negative (FN)

오차행렬에 따라, 머신러닝 모델과 트랜스포머 계열 모델이 실제 값과 정확하게 예측하였을 경우, TP 값으로, 실제 값과 다른 값으로 예측하였을 경우, FN 값으로 측정한다. 정밀도, 재현율, 정확도, F1-Score 를 구하는 수식은 아래 식들과 같다. 정밀도(precision)는 모델이 긍정으로 평가한 라벨 중 실제 정답의 개수를 통해 비율을 파악한다. 재현율(recall)는 모델이 정답과 비교하였을 때 실제로 정답을 맞춘 경우와 틀린 경우 중 맞힌 경우의 비율을 활용한다. 정확도(accuracy)는 모델이 도출한 모든 결과에 대해 모델이 긍정의 값을 도출한 결과에 대한 비율을 활용한다. F1-Score 는 정밀도와 재현율의 조화평균을 사용함으로써, 정밀도와 재현율의 편차가 크지 않을수록 높은 F1-Score 의 값을 도출한다.

$$\text{정밀도 (precision)} = \frac{TP}{TP + FP}$$

$$\text{재현율 (recall)} = \frac{TP}{TP + FN}$$

$$\text{정확도 (accuracy)} = \frac{TP + TN}{TP + FP + TN + FN}$$

$$\text{F1 - Score} = 2 \cdot \frac{\text{precision} \cdot \text{recall}}{\text{precision} + \text{recall}}$$

제3장 유사 사건 검색 기능의 실태 분석 및 형사 판결문을 기반으로 한 유사 사건 기준 도출 실험

판결서 열람을 제공하는 서비스는 크게 정부에서 제공하는 서비스와 민간에서 제공하는 서비스로 나눌 수 있다. 정부에서 제공하는 서비스로는 종합법률정보 대국민 시스템과 판결서 인터넷열람 사이트가 있다. 해당 서비스들의 경우, 판결문 열람과 열람에 필요한 다양한 검색 기능을 제공하고 있으나, 키워드나 법령을 중심으로 해당하는 판결문을 검색을 위한 기능만을 제공하고 유사 사건 검색과 관련된 기능은 제공하고 있지 않는 것으로 확인되었다. 민간에서 제공하는 서비스인 엘박스과 빅케이스의 경우, 정부에서 제공하고 있는 검색 기능과 판결문 전체 또는 범죄사실을 기준으로 유사 사건 검색 기능을 제공하고 있는 것으로 파악되었다.

이후에는 ‘엘박스’와 ‘빅케이스’에서 제공하는 유사 사건 검색 기능의 실태를 분석하였다. 하지만, 유사 사건의 기준이 명확하지 않아 유사 사건 판별에 어려움을 겪었고, 기준 사건과 유사 사건을 비교하기 위해 다양한 기준으로 평가하였다. 이후, 더 적합한 유사 사건 도출을 위해 형사 하급심 판결문 데이터를 수집, 정제 및 전처리하여 자연어 처리 기술을 활용한 모델을 이용해 유사 사건을 도출하였다. 하지만, 모델에서 각자 다른 사건을 도출하여 모델 간의 일치율을 이끌어낼 수 없었다. 따라서, 분석자들을 통해 모델이 도출한 유사 사건을 분석을 진행하였으나 분석자 간에 가장 유사한 사건을 도출하기는 어려웠다. 이는 분석자들마다 생각하는 유사 사건의 기준이 다르기 때문에 모두가 동의하는 유사 사건을 도출하는데 어려움을 겪은 것으로 파악되었다. 유사한 사건을 도출하기 위해서는 사람들이 다양한 사건 중에서 유사 사건으로 분류하는 과정에서 사용되는 각자의 기준을 파악할 필요가 있다. 따라서, 작업자들이 작성한 1 위 선정 결과를 분류하여 순위를 매긴 결과, 가장 많이 언급된 유사 사건의 기준으로 동기가 도출되었다.

제 1절 판결서 열람 서비스 내 유사사건 검색 기능 실태 분석

1. 엘박스

엘박스에서 제공하는 검색 기능 중 ‘유사 판례 검색’의 성능을 알아보고자, 살인죄와 관련된 키워드를 통해 얻은 결과 중 해당 판례의 범죄 사실 부분과 유사한 사건을 찾아 해당 판례와 유사 판례를 분석을 진행하였다. 먼저, ‘살인’을 검색어로 넣고 검색 결과로 나온 ‘수원지방법원 안산지원 2016 고합 3 판결문’을 기준 사건으로 선정하였다. 해당 사건의 경우, 피해자가 2 명이므로 각 피해자 별로 정리한 범죄 사실 내용은 아래 표 9와 같다.

표 7 엘박스 유사 사건 검색 기준 사건인 수원지방법원 안산지원 2016 고합 3의 범죄사실 요약

항목	요약
피해자 A에 대한 범행	<ul style="list-style-type: none"> • 피고인과 피해자 A의 관계는 재혼한 부부 • 범행 전부터 피고인이 피해자 A에게 지속적으로 폭력을 휘둘러 피해자 A와 별거 중 • 피해자 A가 피고인이 거주 중인 빌라를 팔아 딸에게 금전적 지원을 해주자는 제안에 말다툼 중 격분함 • 피고인은 파이프 렌치를 내리쳐 피해자를 살해함
피해자 C에 대한 범행	<ul style="list-style-type: none"> • 피고인과 B는 교제 중이었고, B와 피해자 C도 교제 중 • 피해자 B와 피해자 C가 교제 중이라는 것을 알게 되어 피해자 C에게 헤어질 것을 요구하였으나 피해자의 태도 변화가 없어 죽이기로 마음먹음 • 피해자 C를 만나면 죽이겠다는 마음으로 차량에 약초 팽이를 소지하고 다님 • E의 집에서 고스톱을 치는 피해자 C를 발견하여 피고인이 약초 팽이를 휘두름 • 피해자 C의 저항으로 미수에 그침

형량 결정	<ul style="list-style-type: none"> • 피고인이 피해자 C 의 살인미수 후 자수, 피고인 전과 없음, 피해자 C와 합의한 점으로 감형 • 하지만, 피해자 A 가 사망 직전까지 가정 폭력에 시달렸다는 점과 피해자 A 의 사망으로 인해 가중 처벌됨 • 피고인은 위와 같은 범죄사실로 징역 20 년을 선고받음
-------	---

여러 개의 죄가 결합된 판결문의 경우, 범죄사실에서 각 죄 별로 나눠서 범죄 사실을 서술한다. 피해자가 여러 명일 경우에는 각 피해자 별로 나눠 서술한다. 엘박스에서는 범죄사실 내 나눠진 단락을 기준으로 유사 사건을 검색할 수 있는 기능을 제공하고 있다. 하지만, 기준 사건과 가장 유사한 사건을 도출하기 위해 전체 범죄사실을 선택하여 유사 사건을 검색하였다. 아래 그림 15 를 통해, 엘박스를 통해 제공되는 유사 판례 검색 기능에서는 유사한 판결문의 목록과 각 판결문의 요약을 보여주는 것을 확인할 수 있었다. 하지만, 유사 판례의 기준이나, 기준 사건과 유사 판례 사건들 사이의 유사한 부분을 보여주는 기능이 없어, 각 판결문을 읽고 유사한 부분과 유사 정도를 파악해 분석해보기로 한다. 엘박스에서 도출한 유사 사건의 결과는 아래 그림 15 와 표 10 과 같다.

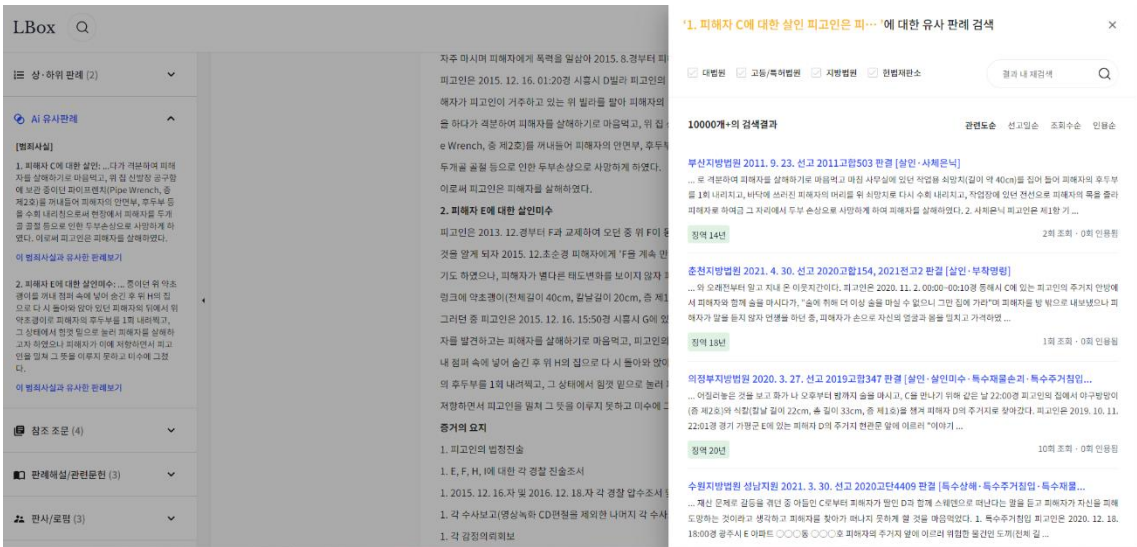


그림 19 엘박스 유사 판례 검색 기능 통해 도출한 결과

표 8 유사 판례 검색 기능을 통해 비교 대상으로 선출된 사건 목록

순위 (관련도 순)	사건명
1	부산지방법원 2011 고합 503 판결
2	춘천지방법원 2020 고합 154, 2021 전고 2 판결
3	의정부지방법원 2019 고합 347 판결

표 9 엘박스 유사 사건 검색 내 1 순위 사건인 부산지방법원 2011 고합 503 사건의 범죄사실 요약

항목	요약
살인	<ul style="list-style-type: none"> 피고인과 사채업자인 피해자 A 에게 금전적 채무가 있는 상황 피해자가 피고인에게 변제를 독촉하며 목검으로 휘두르고 욕설을 하자 피고인은 피해자를 살해하기로 마음먹음
사체 은닉	<ul style="list-style-type: none"> 피고인은 피해자를 쇠파망치로 때려 살해하고 피해자의 사체를 가방에 넣고 매장하여 사체를 은닉함
형량 결정	<ul style="list-style-type: none"> 사체 은닉으로 인한 가중 요소로 징역 14 년 선고

기준 사건과 1 번 사건 사이의 공통적인 부분은 피고인의 행위 결과가 살인이라는 점과 피고인이 사용한 흉기가 파이프 렌치나 쇠파망치처럼 작업에 자주 쓰이는 도구라는 점이다. 하지만, 1) 기준 사건의 경우, 피해자가 2 명이었고, 1 번 사건은 피해자가 1 명으로 피해자의 수가 다르다는 점, 2) 부부 사이나 연인의 바람난 상대였던 기준 사건과 달리 1 번 사건은 채무가 있던 사채업자인 점, 3) 기준 사건은 살인과 살인 미수로 이루어져 있는 반면, 1 번 사건은 살인 이후 사체 은닉까지 저지른 점, 4) 징역 20 년을 받은 기준 사건과 달리 1 번 사건은 징역 14 년을 선고받았다는 점에서 다른 양상을 보여준다.

표 10 엘박스 유사 사건 검색 내 2 순위 사건인 춘천지방법원 2020 고평 154, 2021 전고 2 사건의
범죄사실 요약

항목	요약
살인	<ul style="list-style-type: none"> 피고인과 피해자는 이웃 지간 피고인과 피해자가 같이 술을 마시던 중, 피해자에게 귀가를 권유했으나 피해자의 거부로 말싸움 피고인과 피해자의 말싸움 도중 피해자의 폭력으로 화가 나 피해자를 살해할 마음을 먹음 피고인은 도끼로 피해자를 살해함
형량 결정	<ul style="list-style-type: none"> 피고인의 재범 가능성이 높다고 판단되어 10 년의 위치추적 전자장치 부착 명령과 징역 18 년을 선고받음

기준 사건과 2 번 사건의 공통점으로는 1) 피고인이 사용한 흉기가 파이프 렌치나 도끼와 같은 공구 도구라는 점, 2) 피고인의 행위로 피해자가 사망했다는 점, 3) 피고인이 피해자를 살해하게 된 경위가 말다툼 중이었다는 점이 있었다. 하지만, 1) 기준 사건의 경우, 피고인과 피해자의 관계가 부부 사이와 연인과 관련된 사이였으나, 2 번 사건의 경우, 지인이라는 점, 2) 피해자가 2 명인 기준 사건과는 달리, 2 번 사건은 피해자가 1 명이라는 점, 3) 기준 사건과 2 번 사건의 형량이 다르고, 2 번 사건은 징역 뿐만 아니라 부착명령 10 년도 같이 판결 받았다는 점에서 다른 모습을 보여주었다.

표 11 엘박스 유사 사건 검색 내 3 순위 사건인 의정부지방법원 2019 고평 347 사건의 범죄사실 요약

항목	요약
피해자 D 에 대한 범행 (폭행)	<ul style="list-style-type: none"> 피고인은 피해자 C 와 동거 중, 피해자 C 가 가출 피해자 C 와 피해자 D 가 함께 술을 마시는 것을 목격한 피고인은 피해자 C 와 피해자 D 가 연인 관계라고 생각함 피고인은 피해자 D 의 집에서 피해자 D 와 피해자 C 가 같이 있는 것을 보고 격분하여 피해자 D 를 폭행함

피해자 D 에 대한 범행 (특수재물손괴, 특수주거침입)	<ul style="list-style-type: none"> • 다른 날, 피해자 D 의 집 앞에서 피해자 D 에게 문 개방을 요구했으나 피해자 D 가 거부하여 야구방망이로 유리창을 깨뜨려 손괴하고 피해자 D 집의 주거침입
피해자 C 와 D 에 대한 범행 (살인미수)	<ul style="list-style-type: none"> • 피해자 D 집의 주거침입 이후, 피해자 C 와 피해자 D 가 연인 관계라는 사실에 격분하여 피해자 C 와 D 를 살해하기로 마음먹음 • 피고인은 피해자 C 와 D 를 칼로 찔러 살해하고 하였으나 살인미수에 그쳤음
공용건물손상	<ul style="list-style-type: none"> • 피고인은 체포된 이후, 유치장에서 대변기 커버를 뜯어 던지는 등 공용 건물 내 물건을 손상시켰다.
피고인의 주장 및 형량 결정	<ul style="list-style-type: none"> • 피고인은 범행 당시 피고인이 만취 상태였기 때문에 심신미약을 주장함 • 법원은 피고인이 미리 흉기를 준비해 간 점을 근거로 심신미약 상태 인정하지 않음 • 피고인은 징역 20 년 선고받음

기준 사건과 3 번 사건의 경우, 1) 피해자가 각각 살인 1 건과 살인미수 1 건이라는 점, 2) 피고인과 피해자가 애정으로 연관된 관계라는 점, 3) 피해자가 2 명이라는 점, 4) 두 사건 모두 징역 20 년형을 선고받았다는 점에서 공통점을 지닌다. 하지만, 1) 파이프 렌치를 사용한 기준 사건과는 달리, 3 번 사건의 경우, 식칼을 사용했다는 점, 2) 기준 사건에 비해 3 번 사건은 살인과 살인미수 외에도 폭행, 특수재물손괴, 특수주거침입과 같은 추가 범행들이 더 있는 점들이 기준 사건과 3 번 사건이 다른 양상을 보여주고 있다.

표 12 엘박스를 통해 도출한 유사 사건 세부 내역 비교표

비교 요소	사건명			
	(기준 사건)	(사건 1 번)	(사건 2 번)	(사건 3 번)
	수원지방법원 안산지원 2016 고택 3	부산지방법원 2011 고택 503	춘천지방법원 2020 고택 154, 2021 전고 2	의정부지방법원 2019 고택 347

피고인과 피해자 관계	1. 부부 연인과 바람 난 사람	채무관계	이웃 지간	1. 동거하는 사이 2. 피해자와 친한 사이
피해자 수	2	1	1	2
동기	1. 말싸움 도중 격분 2. 이전부터 원한 있었음	피해자의 폭력과 욕설	피해자의 폭력	피해자 외도 의심
사용한 흉기	1. 파이프 렌치 2. 약초 괄이	쇠망치	도끼	식칼
피고인 행위의 결과	살인 1 건 살인미수 1 건	살인 1 건, 사체 은닉 1 건	살인	살인 1 건, 살인미수 1 건, 폭행, 특수재물손괴, 특수주거침입, 공용 건물 손상 1 건
사체 은닉 여부	X	O	X	X
형량	징역 20 년	징역 14 년	위치추적 전자장치 부착 명령 10 년 징역 18 년	징역 20 년

엘박스를 통해 살펴본 기준 사건과 유사 사건 3 건을 비교를 해보면, 유사 사건으로 도출된 사건들이 기준 사건과 다른 양상을 보여주고 있어, 가장 유사한 사건을 판별하기에 어려움을 겪었다. 이후에는, 민간에서 제공하는 다른 판결문 열람 서비스인 빅케이스의 유사 사건 비교 기능을 살펴보겠다.

2. 빅케이스

민간에서 제공하는 판결문 열람 서비스 중 다른 한 곳인 빅케이스에서 유사 사건 검색 기능과 해당 기능의 성능을 파악해보겠다. 엘박스에서 사용한 기준 판결문인 ‘수원지방법원 안산지원 2016 고합 3 판결문’을 기준으로 Ai 유사판례 기능을 통해 가장 유사한 3 건의 판례를 비교 분석해보았다. 해당 사이트를 통해 제공되는 Ai 유사판례 기능에서는 유사한 판결문의 목록과 각 판결문의 초반 부분을 보여주고 있다. 하지만, 유사 판례의 기준이나, 기준 사건과 유사 판례 사건들 사이의 유사한 부분을 보여주는 기능이 없어, 각 판결문을 읽고 유사한 부분과 유사 정도를 파악해 분석해보기로 한다.

The screenshot shows a web interface for searching court judgments. At the top, there are icons for download and share, and a toggle switch labeled 'Ai 요청보기'. Below this, the search results are displayed. The main result is a judgment from the Suwon District Court, dated March 16, 2016, regarding murder and attempted murder. To the right, there is a section titled '부가정보' (Additional Information) which lists three similar cases found by the AI system, each with a brief summary of the facts and the court's decision.

그림 20 Ai 유사판례 기능을 통해 도출한 유사 사건 화면

이후, Ai 유사판례 기능을 통해, 기준 사건인 제주지방법원 2018 고합 205 판결과 유사하다고 도출된 3 건의 사건을 분석하여 유사한 부분을 파악하고 유사 정도를

확인해본다. 도출된 사건은 아래 표 15 와 같고 각 사건들을 1 위, 2 위, 3 위 사건으로 지칭한다.

표 13 빅케이스를 통해 도출한 유사 사건

순위 (관련도 순)	사건명
1	대구지방법원 2013 고평합 221 판결
2	수원지방법원 평택지원 2019 고평합 167 판결
3	대구지방법원 포항지원 2013 고평합 104 판결

표 14 빅케이스로 도출된 유사 사건 1 위 대구지방법원 2013 고평합 221 사건의 범죄사실 요약

항목	요약
피해자 A 에 대한 범행 (살인)	<ul style="list-style-type: none"> 피고인과 도박하는 사이 피고인이 도박으로 모든 돈을 잃고 피해자 A 에게 돌려 달라 요구함 피해자 A 가 피고인에게 만원을 주며 욱하자 피고인은 피해자 A 를 살해하기로 마음먹음 피고인은 주방에 있는 칼을 가져와 피해자 오른쪽 겨드랑이를 찔러 살해함
피해자 B 에 대한 범행 (살인 미수)	<ul style="list-style-type: none"> 피고인과 도박하는 사이 피해자 A 를 찾으러 집 안으로 들어간 피해자 B 는 피해자 A 에 대한 범행 현장을 목격함 피고인은 목격자인 피해자 B 도 살해하고자 칼로 찔렀으나 미수에 그침
절도	<ul style="list-style-type: none"> 피고인은 피해자 A 를 살해한 이후, 피해자 A 가 소지하고 있던 현금을 절취함
피고인의 주장 및 형량 결정	<ul style="list-style-type: none"> 피고인은 피해자 B 를 살해하려는 고의가 없었다고 주장하나, 법원에서는 피해자 B 에 대한 미필적 고의를 인정함

	<ul style="list-style-type: none"> 피고인은 위와 같은 범죄사실로 징역 12 년은 선고받았고, 절취한 금액은 피해자 A 의 상속인들에게 환부되었음
--	---

기준 사건과 1 위 사건 사이에 공통적인 부분으로는 살인 사건 1 건과 살인 미수 사건 1 건이 일어난 사건이라는 점을 제외하고는 찾기 어려웠다. 다른 점으로는 기준 사건의 경우 파이프 렌치와 약초 팽이를 사용하였으나 1 위 사건은 식칼을 사용하였고, 기준 사건의 피해자들이 피고인의 애정 관계로 이루어진 사람이었으나 (피해자 A 는 피고인과 재혼하였으나 별거 중인 사람, 피해자 B 와 피고인은 교제 중, 피해자 B 와 피해자 C 는 교제 중이었음) 1 위 사건은 피고인과 도박하던 사이였다는 점이였다.

표 15 빅케이스로 도출된 유사 사건 2 위 수원지방법원 평택지원 2019 고평 167 사건의 범죄사실 요약

항목	요약
피고인과 피해자 A, B 의 관계 및 범행 전 상황	<ul style="list-style-type: none"> 피고인과 피해자 A 는 직장 동료 사이임 피고인은 피해자 A 와 B 에게 본인의 휴대전화를 본 사실에 대해 물었으나 피해자들의 기분 나쁜 대답을 들음 피해자들의 대답에 피고인은 피해자들이 숨긴 것으로 생각하고 피해자들을 살해하기로 마음먹음
피해자 A 에 대한 범행 (살인)	<ul style="list-style-type: none"> 피고인이 평소 소지하고 있던 중식도를 들고 식당에 앉아 있던 피해자 A 에게 내리쳐 살해함
피해자 B 에 대한 범행 (살인 미수)	<ul style="list-style-type: none"> 피고인이 피해자 A 를 중식도로 내리치는 것을 본 피해자 B 가 피고인을 저지함 피고인은 피해자 B 에게 중식도를 휘둘러 살해하려 하였으나, 피해자가 도주하고 다른 동료들이 방에서 나오는 바람에 미수에 그침
피고인의 주장 및 형량 결정	<ul style="list-style-type: none"> 피고인의 전과가 없는 사실을 기반으로 위와 같은 범죄사실로 징역 12 년을 선고받음

기준 사건과 2 위 사건의 공통적인 부분으로는 살인 미수 1 건과 살인 1 건이라는 점을 제외하고는 찾을 수 없었다. 기준 사건과 2 위 사건은 각 범행의 동기, 피고인과 피해자의 관계, 범행 도구 등 다양하게 다른 모습을 보여주고 있다.

표 16 빅케이스로 도출된 유사 사건 3 위 대구지방법원 포항지원 2013 고탕 104 사건의 범죄사실 요약

항목	요약
피고인의 전과	<ul style="list-style-type: none"> 피고인은 준강간죄로 집행유예 3 년을 선고받고 집행유예 중에 범죄를 저지름
피해자 B 에 대한 범행 (살인 미수)	<ul style="list-style-type: none"> 피고인은 A 와 교제하면서 피해자 B 를 알게 됨 피고인은 A 와 피해자 B 사이의 특별한 관계가 형성되는 바람에 피고인과 A 가 결별하였다고 생각하고 피해자 B 에게 위해를 가할 마음먹음 피고인은 과도와 망치를 소지한 채 피해자 B 를 만나 말다툼 도중 피해자로부터 얼굴을 가격당하자 살해하기로 마음먹음 피고인은 과도로 피해자의 뒷머리를 찔러 살해하려 하였으나 피해자의 저항으로 미수에 그침
형량 결정	<ul style="list-style-type: none"> 피고인은 피해자에 대한 살인의 고의는 없었다고 주장하나 법원은 피고인에게 미필적으로나마 고의를 인정함 피고인은 위 범행으로 징역 3 년을 선고받음

기준 사건과 3 위 사건 사이의 공통점으로는 피고인과 연인 관계였던 사람으로 인한 사건이라는 점이다. 하지만, 이외에 기준 사건과 달리 3 위 사건에서는 피고인이 전과가 있는 점, 파이프 렌치와 약초 팽이를 사용한 기준 사건과 달리 3 위 사건에서는 과도와 망치를 사용하였다는 점에서 다른 점을 보여준다.

빅케이스를 통해 살펴본 기준 사건과 유사하다고 도출한 사건을 비교한 결과는 아래 표 18 과 같다. 먼저, 기준 사건과 1 위, 2 위 사건은 피해자수가 같고, 피고인의 행동의

결과가 살인 1 건과 살인미수 1 건이라는 점에서 비슷하였다. 또한, 3 위 사건은 기준 사건과 피고인과 피해자의 관계와 동기의 일부가 비슷하였다. 하지만, 해당 내용을 제외하고 기준 사건과 각 1 위, 2 위, 3 위 사건 사이의 공통점을 찾을 수 없었다.

표 17 빅케이스를 통해 도출한 유사 사건 세부 내역 비교표

비교 요소	사건명			
	기준 사건	1 위 사건	2 위 사건	3 위 사건
비교 요소	수원지방법원 안산지원 2016 고합 3 판결문	대구지방법원 2013 고합 221	수원지방법원 평택지원 2019 고합 167	대구지방법원 포항지원 2013 고합 104
피해자 수	2	2	2	1
피고인과 피해자의 관계	1. 부부 2. 연인과 바람 난 사람	피고인과 도박하는 사이	직장 동료	피고인 전 애인의 지인
동기	1. 말싸움 도중 격분 2. 이전부터 원한 있었음	도박으로 잃은 금품을 돌려받기 위해 말다툼 도중 화가 남	피고인의 휴대전화를 숨겼다고 생각하여 화가 남	피고인과 전 애인의 결별 원인이 피해자라고 생각함
사용한 흉기	1. 파이프 렌치 2. 약초 괄이	칼	중식도	과도, 망치
피고인 행동의 결과	살인 1 건 살인미수 1 건	살인 1 건 살인미수 1 건 절도 1 건	살인 1 건 살인 미수 1 건	살인미수 1 건
형량	징역 20 년	징역 12 년	징역 12 년	징역 3 년

민간에서 제공하는 ‘엘박스’와 ‘빅케이스’에서는 다양한 판결문을 제공하고 있으며, 사용자의 편의를 위해 사용자가 보고 있는 사건과 유사한 사건을 추천해 보여주는 기능도 제공하고 있다. 하지만, 앞서 살펴본 것과 같이 1) 기준 사건과 유사 사건으로 도출된 사건이 실제로 유사하다고 판단하기 매우 어렵고, 2) 유사 사건의 기준이 전혀 명시되어 있지 않아 사용자들이 사용하기 어려운 것으로 보인다. 따라서, 범죄사실 내용을 가장 잘 담고 있는

형사 1심 판결문 데이터 내 범죄사실을 기반으로 문서 간의 유사도를 도출하는 모델인 Word Mover Distance (WMD), Global of Vector for Word Representation (GloVE), Korean Bidirectional Encoder Representations from Transformers (KoBERT)을 이용하여 유사 사건을 추출한다. 이후, 모델이 도출한 유사 사건과 기준 사건을 작업자들이 평가하여 좋은 유사 사건을 도출하는 모델을 선정하고 작업자들이 작성한 선정 기준을 통해 유사 사건 판별의 기준을 파악한다.

제 2절 판결문 데이터 수집, 정제, 전처리

제 2절을 통해 엘박스과 빅케이스의 유사 사건 도출 기능의 실태를 파악해보았다. 하지만, 유사 사건을 위한 기준의 부재로 해당 서비스들을 통해 도출된 유사 사건이 기준 사건과 실제로 유사한 사건인지 파악할 수 없었고, 비교분석을 위해 본 연구에서는 피고인과 피해자의 관계, 동기 등 다양한 기준으로 각 사건을 분석하였으나 기준 사건과 유사 사건으로 도출된 사건 사이의 간극이 있는 것으로 파악되었다. 따라서, 제 3절에서는 자연어 처리 기술을 활용한 다양한 모델을 통해 유사 사건을 도출하는 실험을 진행하기 위한 형사 1심 데이터를 수집하고 정제하는 과정에 대해 알아본다.

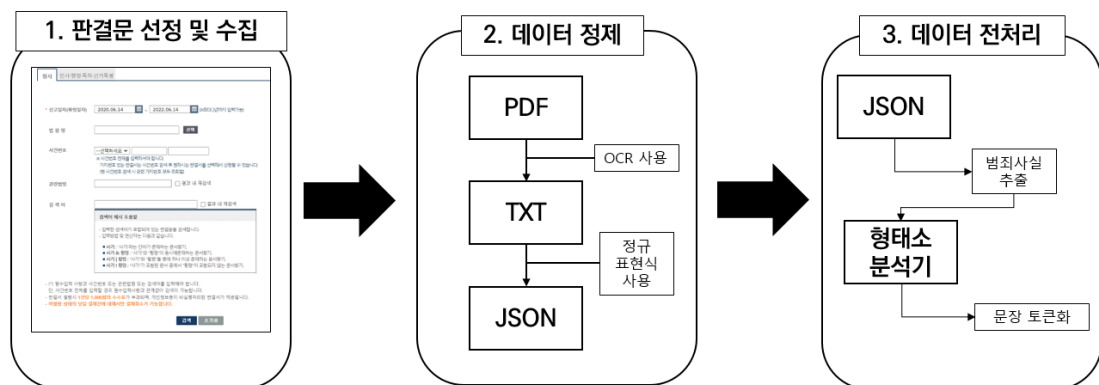


그림 21 판결문 선정 및 수집부터 전처리까지의 흐름도

1. 데이터 선정 및 수집

형사 판결문 수집을 위해, 죄종과 관련 법령 그리고 법원을 선정하였다. 세부 선정 기준을 아래 표와 같다. 형사 사건에 해당하는 여러 죄종 중에서 살인죄를 선정하였다. 살인죄는 강력 범죄 중에서 가장 정형화되어 있어 유사 사건을 위한 사건을 분석을 진행하기에 비교적 명확하다. 살인죄가 명시되어 있는 형법 제 250조를 검색 키워드로 사용하였고, 사실 판단을 담고 있는 1심 사건들을 수집하기 위해, 지방법원과 지원급 법원을 선정하였다. 형사 1심 데이터 수집을 위해 대한민국 법원에서 제공하는 ‘판결서 열람 사이트’를 이

용하였고 검색 필터(그림 5)를 통해 필요한 판결서 수집을 진행하였다. 최종적으로 적용된 검색 필터는 표 19와 같고, 판결서 인터넷 열람 사이트를 통해 수집한 판결문은 총 4,042건을 수집하였다.

표 18 '판결서 인터넷열람사이트' 검색 조건에 적용한 세부내역

선고일자 (확정일자)	2013.01.01 ~ 2021.12.31
법원명	지방법원 및 지원급 법원
관련법령	형법 제250조
검색어	살인

2. 데이터 정제

판결서 열람 사이트를 통해 제공되는 판결문 PDF는 보안상의 이유로 이미지 형식의 PDF로 제공된다. 개정된 「전자우편 등을 통한 판결문제공에 관한 예규」를 통해, 2021년 7월 5일 이후 게시되는 민·형사 판결문은 텍스트 검색이 가능한 파일로 제공된다 [7]. 이전 판결문의 경우, 여전히 텍스트 검색이 불가능한 이미지 형식의 PDF로 제공되고 있기 때문에, OCR 작업을 통해 판결문의 내용을 추출하였다. OCR(Optical Character Recognition)은 광학 문자 인식 기술로, 이미지 형식의 PDF를 기계가 판독할 수 있는 TXT 형태로 변환해주는 기술이다. 한국어 OCR을 위한 여러 모델이 있으나, OCR 하고자 하는 데이터의 특성을 잘 고려하여 추출 하는 모델을 선택해야 한다[7]. 따라서, NAVER CLOVA OCR의 API를 사용하여, 판결문 형태에 맞는 OCR 처리 프로그램을 사용하였다.

한국어 판결문을 OCR 진행할 시, 문자 인식 오류가 발생하지만 OCR 내에는 해당 오류를 수정해주는 과정이 없다. OCR 중에 생긴 인식 오류는 정제 과정을 통해 교정해준다. OCR을 통해 추출한 결과에는 띄어쓰기 오류를 포함하고 있다. OCR 과정에서 발생한 띄어쓰기 오류는 자동 줄 바꿈 (soft return)과 강제 줄 바꿈(hard return)에서 발생한다 [54]. 해당 오류가 나는 부분에 특수문자를 포함한 문자열로 변환하여, 추후 한스펠(hanspell) 맞춤법 검사기를 통해 수정해주었다.


```

{
  "case_meta": {
    "id": "CASE0005112012075000257",
    "court_name": "광주지방법원 목포지원",
    "case_name_num": "2012 고평 257",
    "case_name_type": [
      "살인미수"
    ],
    "case_name_raw": "2012 고평 257 살인미수 ",
    "court_num": "제 1 형사부",
    "defendant": "A ",
    "prosecutor": "박향철(기소), 임아람(공판) ",
    "attorney": "변호사 B ",
    "case_date": "2013. 1. 24. ",
    "judicial_decision": "피고인을 징역 3 년에 처한다. 압수된 과도갈날 1 개를 피고인으로부터 몰수한다. ",
    "judge": "판사 문방진 판사 박종환 판사 전경호 "
  },
  "case_main": "이 유 \n 범죄사실 … \n 다만, 피고인이 초범인 점, 자신의 범행을 반성하고 뉘우치고 있는 점, 피해자와 원만하게 합의된 점, 이 사건 범행에 이르게 된 경위 그 밖에 기록과 공판과정에 나타난 제반 양형조건을 참작하여 보면 피고인에 대한 형을 양형기준이 정한 권고형의 하한보다 낮게 정함이 상당하여 주문과 같은 형을 정한다. \n",
  "footnote": "",
  "case_main_parasplit": {
    "crime_fact": "범죄사실 \n 피고인은 2012. 5.경 만나 서로 호감을 느껴 2012. 6. 16.경부터 함께 동거생활을 하여 오던 중 피해자 C(여. 35 세)이 2012. 10.경부터 자신에게 소홀하게 대하고, 늦은 시간까지 다른 남자와 통화를 하거나 문자메세지 등을 주고 받는 것을 보고 피해자가 다른 남자를 만나고 있다고 의심을 하게 되었다. … \n 이로써 피고인은 피해자를 살해하려 하였으나 그 뜻을 이루지 못하고 미수에 그쳤다. ",
    "evidence_summary": "증거의 요지 \n1. 피고인의 범정진술 \n1. C, D 에 대한 경찰진술조서 \n1. 압수조서 등 \n1. 각 사진(수사기록 51, 58 면), CCTV 사진 \n1. 수사보고(피해자 담당의사의 소견서 및 진료기록 첨부 보고) \n1. 수사보고(병원진단서 및 구급활동일지 첨부) ",
    "application_law": "법령의 적용 \n1. 범죄사실에 대한 해당법조 및 형의 선택 \n 형법 제 254 조, 제 250 조 제 1 항(유기징역형 선택) \n1. 적량감경 \n 형법 제 53 조, 제 55 조 제 1 항 제 3 호 \n1. 몰수 \n 형법 제 48 조 제 1 항 제 1 호 ",
    "ground_sentence": "양형의 이유 \n1. 처단형의 범위 : 징역 2 년 6 월 ~ 15 년 … 다만, 피고인이 초범인 점, 자신의 범행을 반성하고 뉘우치고 있는 점, 피해자와 원만하게 합의된 점, 이 사건 범행에 이르게 된 경위 그 밖에 기록과 공판과정에 나타난 제반 양형조건을 참작하여 보면 피고인에 대한 형을 양형기준이 정한 권고형의 하한보다 낮게 정함이 상당하여 주문과 같은 형을 정한다. ",
    "judgment": "null"
  }
}

```

그림 22 텍스트 형태의 판결문을 JSON 형태로 구조화한 예시

3. 데이터 전처리

엘박스와 빅케이스에서 유사 사건을 도출하는데 사용한 범죄사실을 부분을 추출해 유사 사건 도출 모델의 입력 데이터로 활용한다. 하지만 활용하고자 하는 WMD와 GloVe 모델의 경우, 문장 그대로 처리할 수 없기 때문에 범죄사실을 잘 나타내는 단어를 선별하여 사용한다. 먼저, 범죄사실을 문장 별로 나누고, 문장 내 각각의 단어에 형태소 분석(Morphological analysis)을 통해 필요한 단어만 선별하였다. 형태소 분석은 파이썬 라이브러리 중 Konlpy(Korean NLP in Python) 라이브러리[55]를 사용하였다. Konlpy 라이브러리는 C나 Java 등 다양한 언어로 개발된 오픈소스 한국어 형태소 분석기를 파이썬에서 사용할 수 있도록 제공하고 있다. 현재, Konlpy 라이브러리에서 제공하고 있는 형태소 분석기는 총 5개로, 한나눔(Hannanum), 꼬꼬마(Kkma), 꼬모란(Komorán), 메깅(Mecab), Okt가 있다. 본 연구에서는 Konlpy 라이브러리 내 Mecab 클래스를 사용하여 품사 태깅을 진행하였다.

Mecab 형태소 분석기는 ‘은전한닢 프로젝트’를 통해 개발된 분석기로, 기존에 일본어 형태소 분석기 Mecab을 한국어 형태소 분석에도 사용할 수 있도록 변환한 메깅(Mecab-ko) 형태소 분석기로 변형한 것에서 시작되었다. Mecab 형태소에 장점은 단시간에 세부적으로 형태소를 잘 분리한다. ‘아버지가방에들어가신다’라는 문장을 넣었을 때, KoNLpy 내 각 클래스가 품사 태깅을 진행한 결과, 입력데이터에 대해 띄어쓰기 보정을 진행하지 않고 바로 형태소 분석을 진행한 한나눔, 꼬모란과는 달리, 꼬꼬마와 Mecab, Okt는 보정 한 결과에 대해 형태소 분석을 진행했다는 것을 알 수 있다(표 20). 입력 데이터를 올바르게 고칠 경우, ‘아버지가 방에 들어가신다’라는 문장 구조로 이루어져 있어 ‘아버지’와 ‘가방’으로 분리하는 꼬꼬마와 Okt 보다는 ‘아버지가’와 ‘방에’로 분리하는 Mecab의 성능이 더 뛰어난 것임을 확인할 수 있다[55].

표 19 형태소 분석기별 성능 비교표

Hannanum		Kkma		Komoran		Mecab		Okt	
어절	형태소	어절	형태소	어절	형태소	어절	형태소	어절	형태소
아버지	N	아버지	NNG	아버지	NNP	아버지	NNG	아버지	Noun

가방에 들어가				가방에 들어가 신다					
이	J	가방	NNG			가	JKS	가방	Noun
시니다	E	에	JKM			방	NNG	에	Josa
		들어가	VV			에	JKB	들어가 신	Verb
		시	EPH			들어가	VV	다	Eomi
		니다	EFN			신다	EP + EC		

또한, 분석하고자 하는 문자의 개수를 최소 0개부터 최대 10만개까지 늘려가면서 각 형태소 분석기에서 품사 태깅에 걸리는 시간을 확인해본 결과 Mecab이 가장 빠른 시간내 모든 문서를 처리한 것을 확인할 수 있었다. 따라서, 본 연구에서는 단시간에 띄어쓰기 보정을 하며 형태소를 잘 분석해내는 Mecab 형태소 분석기를 사용하였다[55].

제 3절 유사 사건 기준 수립을 위한 선행 연구

1. 유사 사건 기준 파악을 위한 실험 설계 및 결과

수집한 형사 1심 데이터 중 유사 사건의 평가 기준으로 총 4건의 사건을 결정하였다. 비교 대상을 명확히 하기 위해, 여러 범죄가 섞이지 않은 살인미수죄나 살인죄만 해당하는 사건 중에서 랜덤으로 살인미수 2건과 살인 2건을 선정하였다. 기준 사건은 아래 표 21과 같다.

표 20 유사 사건 도출을 위한 기준 사건 목록

기준	번호	사건명
살인미수	1	광주지방법원 (목포지원) 2016고합105
	2	대전지방법원 서산지원 2012고합170
살인	3	수원지방법원 안산지원 2019고합331
	4	부산지방법원 2016고합736

해당 기준 사건을 쿼리로 사용하고 전체 사건을 대상으로 WMD, GloVe, KoBERT를 이용해 유사 사건을 찾는 실험을 진행하였다. 워드 임베딩 방식을 사용하는 WMD와 GloVe에는 범죄사실을 전처리 후, Mecab 형태소 분석기를 통해 명사만 추출한 데이터셋을 사용해 유사 판결문을 도출하였고, 문장을 입력으로 받아 문맥을 파악할 수 있는 트랜스포머 계열인 KoBERT는 범죄사실에 별다른 전처리를 거치지 않고 문장 데이터 그대로 사용하였다.

WMD는 전처리한 판결문을 Word2Vec 방식으로 임베딩한 뒤, 기준 판결문 내 단어들과 비교할 판결문의 단어들을 이용해서 최소의 거리를 계산하였고, 가장 가까운 판결문을 유사 사건으로 도출하였다. GloVe는 전처리한 판결문을 기반으로 기준 사건과 미리 임

베딩된 GloVe 모델⁵을 가져와 파이썬 모듈인 gensim[39]에서 제공하는 Soft Cosine Similarity로 계산한 값이 가장 큰 판결문을 유사한 사건들을 도출하였다. KoBERT는 KoBERT가 사전 학습한 데이터를 통해 구축된 임베딩 값을 이용하였으며, 유사도 평가에는 Cosine Similarity를 사용하였다. 유사 사건 데이터셋 구축 도식화는 아래 그림 23과 같다.

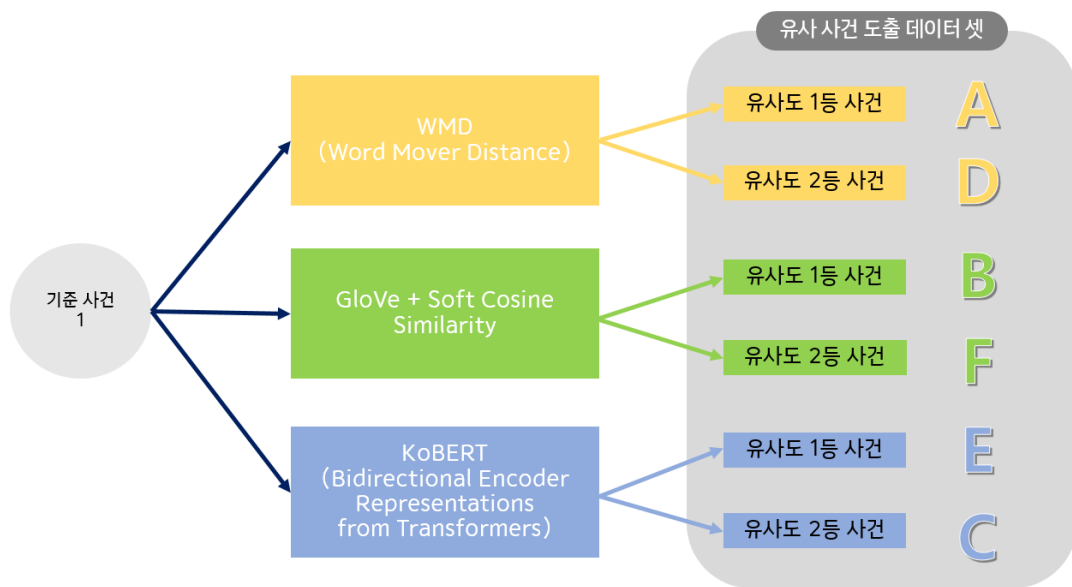


그림 23 기준 사건을 중심으로 한 유사 사건 도출 데이터셋 구축 구조화

각 기준 사건에 대한 WMD, GloVe, KoBERT가 유사하다고 판단하여 도출한 사건 중 1,2위만 모아서 임의로 A부터 F까지의 인덱스를 부여하였다. 최종적으로 구축된 유사 사건 도출 데이터셋은 아래 표 23부터 26과 같다. GloVe와 KoBERT의 경우, 유사도 측정 방법으로 Cosine Similarity를 사용하기 때문에 가장 가까운 사건이 1의 값을 도출하고, 가

⁵ 한국어 임베딩 도서 저자인 이기창은 Word2Vec, GloVe 등의 임베딩된 파일을 무료로 배포하고 있어, 해당 데이터를 가져와서 사용하였다. (<https://ratsgo.github.io/embedding/downloaddata.html>)

장 가깝지 않은 사건이 0의 값을 도출한다. 반면, WMD는 WMD 자체적으로 거리를 재는 방식을 사용하기 때문에 가장 가까운 사건이 0의 값을 도출하고 가깝지 않은 사건은 무한대의 값을 반환하였다. 각 모델들이 도출한 사건을 통해, 공통적으로 도출되는 사건은 없었으며, 모델마다 각기 다른 사건을 도출하고 있음을 파악하였다.

표 21 기준 사건 1 번 (광주지방법원 목포지원 2016 고합 105)사건에 대한 모델들이 도출한 유사 사건

인덱스	사건명	도출한 모델
A	청주지방법원 2015고합90	KoBERT
B	대전지방법원 2017고합117	KoBERT
C	대전지방법원 서산지원 2017고합40	GloVe
D	청주지방법원 2016고합136	WMD
E	인천지방법원 2017고합527	WMD
F	수원지방법원 2016고합761	GloVe

표 22 기준 사건 2 번 (대전지방법원 서산지원 2012 고합 170) 에 대한 모델이 도출한 유사 사건

인덱스	사건명	도출한 모델
A	창원지방법원 통영지원 2019고합7	WMD
B	광주지방법원 2016고합136	KoBERT
C	대구지방법원 2014고합39	KoBERT
D	부산지방법원 동부지원 2018고합21	GloVe
E	서울중앙지방법원 2016고합327	GloVe
F	대전지방법원 서산지원 2013고합32	WMD

표 23 기준 사건 3 번 (수원지방법원 안산지원 2019 고합 33) 에 대한 모델이 도출한 유사 사건

인덱스	사건명	도출한 모델
A	수원지방법원 2015고합510	KoBERT
B	수원지방법원 여주지원 2013고합91	WMD
C	인천지방법원 2015고합562	KoBERT

D	서울남부지방법원 2018고합479	GloVe
E	서울중앙지방법원 2020고합143	WMD
F	부산지방법원 2013고합649, 710 (병합)	GloVe

표 24 기준 사건 4 번 (부산지방법원 2016 고합 736)에 대한 모델이 도출한 유사 사건

인덱스	사건명	도출한 모델
A	대전지방법원 천안지원 2013 고합 262	KoBERT
B	서울중앙지방법원 2014 고합 50	GloVe
C	부산지방법원 동부지원 2016 고합 97, 190(병합), 191(병합)	GloVe
D	의정부지방법원 2014 고합 186	KoBERT
E	전주지방법원 군산지원 2019 고합 145	WMD
F	부산지방법원 2015 고합 180	WMD

2. 작업자 평가 및 결과

자연어 처리 기술을 활용한 임베딩 모델로 유사 사건을 도출한 결과, 각 모델에서 도출하는 사건이 전부 달랐다. 따라서 작업자들을 통해 기준 사건과 유사 사건을 비교 분석하기로 한다. 법률 지식을 가지고 있는 작업자들에게 평가받고자 설문지를 만들었고, 작업자들은 기준 사건의 범죄사실을 읽고 추후 나오는 인덱스 별로 적힌 범죄사실을 읽고 난 뒤, 맨 뒤에 위치한 평가표에 따라 유사 사건으로 도출된 사건들을 순위를 매기고 이유를 적도록 하였다(그림 24). 해당 설문지에서는 유사 사건을 가려내는 태스크만 전달하고, 유사 사건의 기준이 될 만한 사항에 대해서는 전혀 전달하지 않았다. 유사 사건을 위한 명확한 기준이 존재하지 않기 때문에, 작업자들이 다양한 요소를 고려하고 유사 사건을 선정할 수 있도록 설계하였다.

작업자들로서는 일반인 보다 법률 지식을 갖고 있으며, 평소 작업으로 인해 다양한 판결문을 접하는 한림대학교 정보법과학 전공을 이수한 연구원들과 경찰대학교 치안정책연구소 내 연구원들 총 11명을 선정하였다. 작업자들이 유사 사건을 평가하면서 1위부터 6위

까지 해당하는 이유를 적도록 하는 것은 어려운 작업으로 평가되어, 1위와 6위는 의무적으로 적고, 그 외 순위에 대해서는 자율적으로 적도록 하였다.

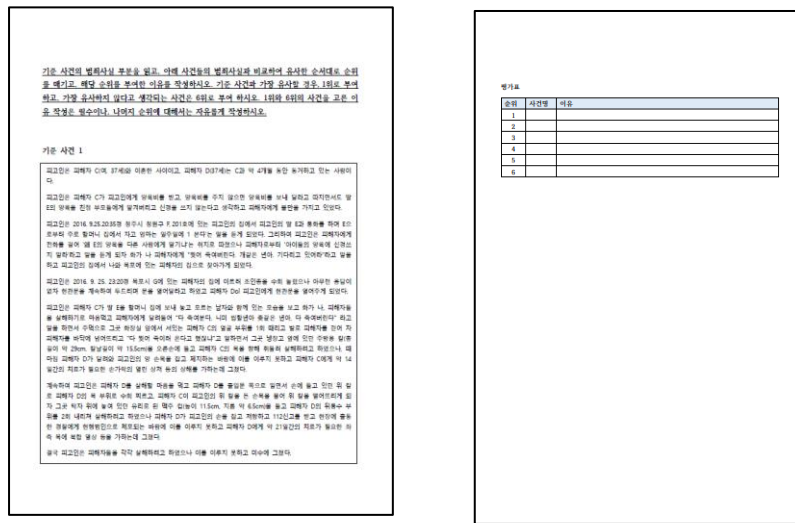


그림 24 유사 사건 평가에 사용된 설문지

작업자들이 유사한 순서대로 매긴 순위를 취합하여, 득표율 순으로 기준사건별로 1 등과 6 등을 도출하였고 해당 결과는 아래 표 26 과 같다. 4 천여건 중에 다양한 모델로 유사 사건을 추려서 접했음에도 불구하고, 작업자들에 의하면, 1 위 사건을 선정하는 것보다 6 위 사건을 선정하는 것이 더 쉬웠다는 응답이 많았다. 이는 후보 사건 중에서 기준 사건과 뚜렷하게 유사한 사건을 도출하는 것이 어려웠음을 의미한다. 세부 결과를 살펴보면, 대부분의 1 위와 6 위로 선정된 사건들이 작업자 11 명 중에 6 명 이상의 표를 받은 것으로 보인다. 하지만, 그 중에서 기준 사건 3 번의 1 위 사건과 기준 사건 4 번의 1 위 사건이 5 표로 과반수의 동의를 얻어내지 못한 것을 확인하였다. 이 중 가장 많은 득표율을 기록하는 사건은 기준 사건 2 번의 6 위로 선정된 서울중앙지방법원 2016 고평합 327 사건이었다. 해당 사건은 GloVe 를 통해서 도출된 사건이었으며, 작업자 11 명 중 10 명에게 6 위로 선정되었다.

표 25 작업자들이 평가한 유사 사건 도출 데이터셋 평가

기준	번호	기준 사건명	순위	라벨	모델	사건명	표 수	비율
살인 미수	1	광주지방법원 (목포지원) 2016 고합 105	1 위	E	WMD	인천지방법원 2017 고합 527	6	54%
			6 위	C	GloVe	대전지방법원 서산지원 2017 고합 40	6	54%
	2	대전지방법원 서산지원 2012 고합 170	1 위	F	WMD	대전지방법원 서산지원 2013 고합 32	6	54%
			6 위	E	GloVe	서울중앙지방법원 2016 고합 327	10	90%
살인	3	수원지방법원 안산지원 2019 고합 331	1 위	B	WMD	수원지방법원 여주지원 2013 고합 91	5	45%
			6 위	A	KoBE RT	수원지방법원 2015 고합 510	6	54%
	4	부산지방법원 2016 고합 736	1 위	B	GloVe	서울중앙지방법원 2014 고합 50	5	45%
			6 위	D	KoBE RT	의정부지방법원 2014 고합 186	7	63%

작업자들의 득표율을 기반으로 형사 판결문 대상 좋은 유사 사건을 도출하는 모델을 파악하고자 하였으나, 기준 사건 4 건 중 2 건의 사건이 작업자들의 과반수의 동의를 얻어 내지 못한 것을 확인하였다(표 26). 위와 같은 결과는 단순하게 임베딩 모델을 활용한 유사 사건 도출을 실제 사용자들이 유사 사건으로 활용하기에 무리가 있는 것을 파악하였다. 따라서, 작업자들이 유사 사건을 평가할 때 사용한 기준에 대해 알아보고 해당 기준을 활용하여 유사 사건을 도출할 경우, 사용자들에게 보다 더 적합한 유사 사건을 도출할 수 있을 것으로 보인다. 따라서, 작업자들이 유사 사건 도출할 때 사용한 이유에 대해 파악해본다.

작업자들은 별도의 기준을 가지지 않고, 본인만의 기준으로 이유를 서술해 두었기 때문에, 각각 읽고 범주화해주는 작업을 필요로 한다. 예를 들어, ‘피고인과 부부/연인 관계에 있는 사람과 연관이 있는 피해자’ 라는 내용은 사실상 ‘피고인과 피해자의 관계’를

의미하는 말로 생각할 수 있다. 또한 한 문장에 여러 요소를 언급하는 방식은 문장 내 각각 요소로 분리하여 범주화하였다. 아래 그림 15 는 작업자들이 실제 작성한 이유와 해당 부분을 근거로 범주화 한 일부이다.

태스크번	순위	이유	범주
1	1	1 피고인과 부부/연인 관계에 있는 사람과 연관이 있는 피해자, 살인미수, 우발적	피고인-피해자 관계, 결과, 우발적
1	1	1 피해자에게 화가 나서 범행을 저지른 것이 동일하다고 판단(남자와 있는 것에 화가 남)	동기
1	1	1 관계, 사용용기가 가장 유사	관계, 흥기
1	1	1 피해자 수, 범행도구, 미수 여부, 미수 사유, 상해 부위, 공격부위 등이 같거나 비슷함	피해자 수, 범행도구, 결과와 결과 사유, 상해 및 공격 부위
1	1	1 범행도구(칼)	도구
1	1	1 피고인과 피해자들의 관계, 범행 동기, 범행 도구가 유사함	피고인-피해자 관계, 동기, 도구
1	1	1 평소에 피해자에게 불만을 가지고 있다가 피해자와 같이 지내는 남자로 인해 살해의 의도를 가짐	동기
1	1	1 동기가 부부관계이며, 범죄사실이 상해, 살인미수인 점에서 가장 유사	동기, 결과
1	1	1 흥기를 사용한 경위와 사건에 개입된 사람의 수 등이 기준판결과와 유사함	흥기, 피해자 수
1	1	1 연인사이로 타통과 협박이 있었음, 피해자가 저항함	동기, 피해자의 저항
1	1	1 내용없음	
2	1	1 아는 사이, 다름의 장소가 유사함, 다름의 원인이 유사함	피고인-피해자 관계, 장소, 동기
2	1	1 범행동기와 범행전상황이 유사함	동기
2	1	1 발생장소, 사용용기 유사	장소, 흥기
2	1	1 피해자 수, 범행도구, 미수여부, 공격부위, 동기 등이 같거나 비슷함	피해자 수, 흥기, 결과, 공격 부위, 동기
2	1	1 피고인 상태 (소주를 마신 뒤), 범행동기 (자신을 무시한다는 이유로 화가 나)	피고인 상태, 동기
2	1	1 피고인이 흉주상태였고, 피고인과 피해자의 관계와 범행의 동기가 유사하며, 범행 도구 부엌칼로 동일함.	피고인 상태, 동기, 흥기
2	1	1 문제 발생 당사자들이 아닌 제3자가 갑자기 피해자가 됨	동기
2	1	1 동기가 질투심이며, 피해자가 모두 업소 직원이라는 점, 도구로 칼을 이용한 살인미수 범죄라는 점에서 유사함	동기, 피해자 직업, 흥기, 결과

그림 25 작업자들이 작성한 1 위 사건에 대한 이유


작업자들이 작성한 이유를 기반으로 범주화 한 항목으로는 총 15 개였으나, 사람들이 평균적으로 생각하는 유사 사건의 기준을 파악하고자 빈도수가 1 개인 항목은 제외하였다. 총 113 건의 결과를 도출했고, 해당 목록을 빈도수로 나타낸 표는 아래 표 와 같다. 가장 많이 언급된 것은 ‘동기’ 였고, 이후 ‘범행 도구’와 ‘피고인 - 피해자 관계’가 뒤를 이었다. 해당 범주들을 전체 대비 비율로 확인해본 결과는 아래 표 28 과 같다. 동기가 31% 가장 많은 득표율을 보였고, 이후, 범행 도구가 19%, 피고인-피해자 관계가 15% 였다. 동기, 범행 도구, 피고인-피해자 관계를 제외한 나머지는 10%도 넘지 못하는 결과를 보여주었다.

표 26 작업자들이 작성한 이유 범주화 결과

범주	상세 설명	빈도수
동기	피고인이 범행을 저지르게 된 이유	35

범행 도구	피고인이 범행 당시 사용한 흉기	21
피고인-피해자 관계	피고인과 피해자의 관계	17
결과	피고인 행동으로 인한 피해자의 결과 (사망, 미수)	10
살해 방법	피고인이 피해자를 살인 또는 살인미수 했던 방법	9
피해자 수	사건 내 피해자의 수	5
피고인 상태	범행 전 피고인의 음주 여부	5
계획적 또는 우발적	피고인의 행위가 계획적이었는지 우발적이었는지 여부	4
상해 및 공격 부위	피고인의 행위로 피해자가 공격받거나 상해 입은 부위	4
장소	범행이 일어난 장소	3
총합		113

표 27 유사 사건 기준 분류 차트



제 4절 의미론적(semantic) 유사 사건 도출에 대한 소결론

형사 판결문을 기준으로 유사 사건을 도출하기 위해 국내에서 제공하고 있는 판결문 열람 사이트 내 유사 사건 검색 기준의 실태를 파악해보았다. 하지만, 해당 사이트들에서는 유사 사건을 위한 별다른 기준을 제공하고 있지 않았고, 기준 사건과 유사 사건으로 도출된 사건을 평가하기 위해 다양한 기준으로 평가하였으나 유사한 판결문으로 판별하기 어려움이 있었다. 따라서 다양한 임베딩 모델을 활용하여 형사 1 심 판결문을 기준으로 유사 사건을 도출하는 실험을 진행하였다. 하지만, 다양한 모델을 활용했음에도 불구하고 모델마다 도출하는 사건이 다르기 때문에 실제 작업자들을 통한 유사 사건 평가가 불가피했다. 작업자들을 통해 모델이 도출한 유사 사건을 평가를 진행하였으나, 전체 사건에 대한 작업자들의 절반 이상의 합의를 도출하지 못하였다. 이러한 결과를 통해, 별도의 기준 없이 단순 의미적 유사도의 기반한 유사 사건 도출은 형사 판결문에 적합하지 않는 것을 파악할 수 있었다. 분석자가 모델이 도출한 유사 사건을 평가하면서 작성한 근거를 기반으로 사람이 형사 판결문 내 범죄사실을 기준으로 유사 사건을 판별할 때 동기를 가장 많이 고려하는 것을 알 수 있었다. 따라서, 이후 제 5 장에서는 범죄사실 내 서술되어 있는 동기를 기반으로 분류하여 유사 사건 검색 시 전체 사건을 대상으로 진행하는 방안이 아닌 기준 사건과 같은 동기 분류의 사건을 기반으로 검색할 수 있는 기반을 마련한다.

제4장 범행 동기를 기준으로 판결문 분류 데이터셋 구축 방법

제 1절 동기의 중요성 및 연구 방법

앞서 진행된 유사 사건 도출 실험 결과를 통해, 유사 사건을 판별할 때 가장 중요한 요소로는 ‘동기’, ‘범행 도구’, ‘피고인과 피해자의 관계’로 나타났다. 이에, 본 연구에서는 유사 사건을 결정하는 가장 중요한 기준으로 ‘동기’로 여기고, 실제 판결문과 선행 연구들을 통해 ‘동기’에 집중해야 하고자 하는 이유에 대해 알아본다. 판결문 내 범죄사실은 먼저 피고인과 피해자의 관계에 대해 짧으면 ‘부부’와 같은 한 단어나 길면 최대 1~2 문장으로 서술한다. 이후 피고인이 피해자를 살해하고자 하는 동기를 범행 전 상황과 평소 피고인이 피해자에 원한 또는 불만 여부와 함께 여러 줄에 걸쳐서 설명을 하고 있다. 피고인의 동기 부분 및 범행 전 상황의 서술이 종료되고, 범행 중 상황에 대해 서술하며 피고인이 사용한 범행 도구에 대해 서술하는 형식을 보인다. 실제 판결문인 부산지방법원 2018 고합 511 판결을 통해 해당 패턴을 확인해보았다.

아래 그림 26은 부산지방법원 2018 고합 511 판결의 범죄사실 부분이다. 그림 16 내 녹색 박스 부분을 통해, 피고인과 피해자가 연인 관계였다는 점을 파악할 수 있다. 또한, 파란색 박스 부분을 통해, 피고인이 장도리를 이용해 피해자를 살해하고자 하였음을 파악할 수 있었다. 동기의 경우, 주황색 박스 부분을 통해, 1) 피해자에게 다른 남자가 생겼다는 점, 2) 이후, 피해자가 피고인에게 다정하게 대하지 않았다는 점, 3) 피해자가 피고인과의 성관계를 거부하였다는 점으로 배신감을 느끼고 있었으며, 4) 범행 당일 피해자가 또 다시 성관계를 거부하자 피해자와의 말다툼 도중 피고인이 격분하여 피해자를 살해하였다는 것을 알 수 있다. 1번부터 3번까지는 범행 당일에 일어난 사건들이 아니며, 범행 전부터 피고인이 피해자에 대해 일련의 사건들로 인해 배신감을 느끼고 있었던 것으로 보인다. 이렇듯, 동기는 범행 도구나 피고인과 피해자의 관계와는 달리 피고인이 범행 전부터

느껴왔던 불만을 근거로 범행 직전에 해당 불만에서 피해자를 살해하는 행위까지 연결하는 트리거로 이루어져 있다. 따라서, 정교하고 정확한 유사 사건 도출을 위해서는 동기 부분을 명확히 분류할 필요가 있다.

예시) 부산지방법원 2018고합511 살인미수 범죄사실

피고인은 2017. 6. 8. 전처와 이혼한 후 혼자 생활하여 오다가 2018. 4. 경 다방종업원으로 일하던 피해자 B(여, 50세)을 만나 사귀면서 생활비와 자녀 학원비 등 물질적 도움을 주고, 주로 성관계를 하면서 피해자와 원만한 관계를 유지하던 중 2018. 10. 경 다른 남자가 생겼다는 이유로 피해자가 자신을 다정하게 대하지 아니하고 집에 오더라도 자신과의 성관계를 무조건 거부만 하는 모습을 보이자 피해자에게 심한 배신감을 느끼게 되었다. 피고인은 2018. 11. 25. 09:00경 부산 금정구 C아파트 D호 자신의 주거지에서 반찬을 가지고 온 피해자가 또 다시 성관계를 거부하자 피해자에게 "내가 너에게 준 반지, 귀걸이 등은 달라고 안 할 테니 둘째 딸 학원비와 결혼비용은 당장 내놔라"고 말하였으나 피해자로부터 "돈 없다, 연락도 하지 마라, 오빠하고는 끝났다." 라는 말을 듣고 격분하여 피해자를 살해하기로 마음먹고 주먹으로 피해자의 얼굴을 수 회 때리고, 발로 피해자의 배를 수 회 걸어찬 후 그곳 신발장에 있던 장도리(길이 약 32cm)를 들고 피해자의 머리 부위를 수 회 내리치고, 그곳 옷장에 있는 넥타이 2개를 들고 바닥에 엎드린 피해자의 목에 감아 조른 다음 피해자가 의식을 잃자, 계속하여 그곳 신발장에 있던 다른 장도리(길이 약 23.5cm)를 들고 피해자의 머리를 내리쳐 피해자를 살해하려고 하였으나, 이웃 주민의 신고를 받고 경찰관이 출동하는 바람에 피해자에게 약 12주간의 치료를 요하는 외상성 거미막막 출혈 등의 상해를 가하고, 그 뜻을 이루지 못하고 미수에 그쳤다.




그림 26 부산지방법원 2018 고합 511 범죄사실 내 관계, 동기, 도구

해당 판결문 뿐만 아니라, 다양한 논문에서도 ‘동기’, ‘범행 도구’, ‘피고인과 피해자의 관계’에 대한 서술을 알아 볼 수 있다. 피고인이 사용한 범행 도구의 경우, 살인죄에서 사용하는 범행 도구는 상당히 한정적이다. [56]에서는 69.9%의 사건이 범행 도구를 사용했으며, 35.6%의 사건이 예기나 둔기 등 도구를 사용한 사건이라고 밝혔다.

과학적범죄분석시스템(Scientific Crime Analysis System, SCAS)는 경찰청 내 과학수사요원에 의해 작성되는 서류를 통합하여 관리하는 시스템이다[57]. 해당 시스템의 강력범죄분석항목 내 범행 도구에서는 1) 없음, 2) 예기, 3) 둔기, 4) 신체, 5) 끈 종류(테이프 포함), 6) 독극물-약물, 7)기타로 분류하고 있다. 해당 분류들을 통해 도출될 수 있는 범행 도구는 칼과 같은 예기, 장도리와 같은 둔기, 전선줄과 같은 끈 종류, 농약과 같은 독극물-약물 종류가 해당된다. 따라서, 범행 도구들은 범죄 사실 내 단순한 명사형으로 서술되는 경우가 많기 때문에, 단순 추출 작업으로도 충분히 데이터를 확보할 수 있음을 확인하였다.

피고인과 피해자의 관계의 경우, [56]에서는 1) 연인, 2) 가족친척, 3) 지인친구 등, 4) 처음보는 사람, 5) 기타로 분류하였고, SCAS 에서는 피의자를 기준으로 1) 비면식, 2) 편면식, 3) 일면식으로 분류하고 있었다. SCAS 에서 분류하는 항목이 더 포괄적인 관계로 논문에서 분류한 방식을 살펴보면, 대부분 명사형으로 도출될 수 있는 ‘연인’, ‘부부’, ‘친형’, ‘지인’ 등의 형식으로 서술되며, 범행 도구와 같이 단순 추출 작업으로도 충분히 데이터를 확보할 수 있음을 확인하였다.

동기의 경우, SCAS 에서는 범행 동기를 1) 금품, 2)원한-복수, 3) 성욕, 4) 치정, 5) 정신질환, 6) 개인적 스트레스, 7) 종교적 신념, 8) 개인적 신념, 9) 기타로 분류하고 있고, 논문에서는 1) 경제적 이유, 2) 분노/보복/우발 등, 3) 치정, 4) 정신병 등, 5) 가정불화, 6) 기타(불상)으로 분류하고 있다. 하지만, 동기의 경우, 범죄 사실 내에서 여러 줄에 걸쳐서 다양한 언어로 표현되고 있으며, 크게 1 차적인 원인과 2 차적인 원인으로 나뉘는 등, 앞서 언급된 ‘범행 도구’와 ‘피고인과 피해자의 관계’와는 다르게 취급되어야 한다. 따라서, 본 연구에서는 유사 사건 도출을 위한 ‘동기’부분에 초점을 맞춰 판결문을 분류하는 작업을 진행한다.

앞서 진행된 실험들을 통해, 판결문 내 동기 서술 방식을 파악했다. 단순 명사형이나 길어도 1~2 줄 정도로 서술되는 범행 도구와 피고인과 피해자의 관계와는 달리, 서술 방식이 매우 길기 때문에, 유사 사건 도출을 위해서는 판결문 내 동기 부분을 분류할 필요가 있다. 따라서, 제 2 절에서는 본 연구에서 사용한 동기 분류 기준과, 판결문 내 동기를 포함하고 있는 문장 분리 기준 그리고 동기를 포함하는 문장 내 주요 키워드를 추출하는 기준에 대해서 서술하고, 기준에 따라 구축된 데이터셋에 대해 알아본다.

제 2절 범죄사실 내 동기 분류 기준 수립

1. 기존 연구에서 분류하는 동기의 기준

본 연구에서 활용한 동기의 분류 기준을 결정하기 전에, 기존 연구에 분류하는 동기 기준을 파악해보았다. 먼저, 과학적범죄분석시스템 (Scientific Crime Analysis System, SCAS) 내 강력범죄 분석 항목에 따르면, 범행 동기를 1) 금품, 2)원한-복수, 3) 성욕, 4) 치정, 5) 정신질환, 6) 개인적 스트레스, 7) 종교적 신념, 8) 개인적 신념으로 분류하고 있다. 대상 시스템에서 제공하는 분류는 살인죄 뿐만 아니라 강간죄, 절도죄 등 강력범죄를 대상으로 적용되기 때문에 광범위 하다. 예를 들어, 사용한 분류 중 하나인 ‘성욕’은 살인죄를 대상으로 분류하기 어렵고, 주로 강간죄와 관련되어 있다. 살인죄를 대상으로 진행되는 본 연구에서는 주요 쟁점으로 활용할 수 없다. 따라서, 본 연구의 대상 범죄인 살인죄에 적합한 동기의 분류 기준을 파악한다.

[56]은 SCAS 시스템 내 2015 년부터 2019 년까지 서울지방경찰청 관할 내에서 발생한 살인 및 치사 사건 총 216 건의 데이터를 분석해 살인혐의 사건 가해자의 특성을 파악하는 연구를 진행하였다. 해당 연구의 동기는 다음과 같은 분류를 1) 경제적 이유, 2) 분노/보복/우발 등, 3) 치정, 4) 정신병 등, 5) 가정불화, 6) 기타(불상)을 사용하였다. 본 연구에서는 나타난 빈도를 기반으로 분노/보복/우발(30.6%), 정신병 등(18.5%), 치정(18.1%) 순으로 자주 발생하는 것으로 분석됐다. 해당 기준으로 본 연구에서 사용하는 살인죄 판결문 200 건을 분석해본 결과, 가정불화의 출현 횟수가 많지 않아, 가정 불화의 내용은 크게 분노/보복/우발로 묶어서 분석한다.

본 연구에서는 과학적범죄분석 시스템과 논문에서 사용된 동기 분류를 혼합하여 살인죄 판결문 데이터에 적합한 동기 분류를 사용한다. 기본적인 틀은 SCAS 에서 제공하는 틀을 사용하되, 논문과 SCAS 내 분류 큰 범주로 묶어서 사용하고 이를 도식화 한 그림은 아래 그림 27 과 같다. 예를 들어, 논문에서는 치정과 가정불화로 나눠 분류를 진행하였으나, 해당 기준 중에서 가정 불화의 경우 피고인과 피해자가 부부인 관계일 때 성립하는 경우로

한정해, 치정과 비슷한 성격을 지닌다고 판단하여 치정으로 분류하였다. 또한, SCAS에서는 치정과 성욕으로 나눠서 분류를 진행하고 있다. 하지만, 살인, 강간, 강도 등 강력범죄를 대상으로 하는 시스템 특성 상, 살인죄 내 동기를 분류하기에는 적합하지 않다고 판단되어, 치정에 성욕을 포함하여 진행하였다. 최종적으로 본 연구에서 사용되는 치정의 기준은 1) 피고인과 피해자의 사이의 사랑 다툼, 2) 피고인의 성욕으로 인해, 3) 피고인과 피해자가 부부 관계이며 가정 내 불화로 인한 다툼으로 정의한다.

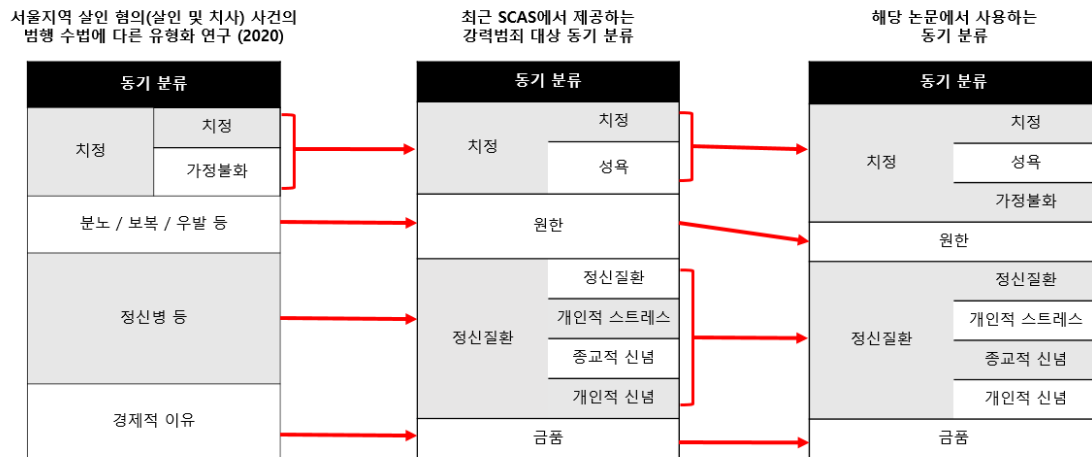


그림 27 해당 논문에 맞춰 수정한 동기 분류 도출 방식 도식화

원한의 경우, 논문에서 분류한 분노/보복/우발 등을 포함하여 크게 원한으로 분류하였다. 본 연구에서 사용하는 분류 기준인 정신질환의 경우, 논문에서 분류한 정신병 등과 SCAS 에서 제공하는 정신질환을 포함하였고, 본 연구에서 다루는 주 데이터인 살인죄의 경우, 개인적 스트레스와 종교적 신념, 개인적 신념으로 인한 사건의 빈도수가 낮을 것으로 예상하여 정신질환에 포함하여 분류하였다. SCAS 에서 분류하는 금품에 논문에서 분류한 경제적 이유를 포함하여 금품이라는 명칭을 유지하며 분류하였다.

2. 범죄 사실 내 동기를 활용한 데이터 셋 구축 방안

형사 1 심 판결문을 대상으로 동기를 분류하기 위해 동기의 분류 기준을 치정, 원한, 정신, 금품으로 지정하였다. 이후 과정에서는 동기를 활용한 데이터셋을 구축하기 위한 작업을 진행한다(그림 28). 먼저, 범죄사실에서 동기를 담고 있는 문장의 패턴을 파악하고 문장을 추출한다. 트랜스포머 계열 모델의 경우 해당 문장을 입력 값으로 사용할 수 있으나, 머신러닝 계열 모델은 문장을 입력으로 받을 수 없기 때문에 형태소 분석기를 통해 키워드를 추출해 주는 과정을 진행한다. 최종적으로 사건별로 동기를 포함하고 있는 문장과 키워드를 추출해 데이터셋을 구축한다.

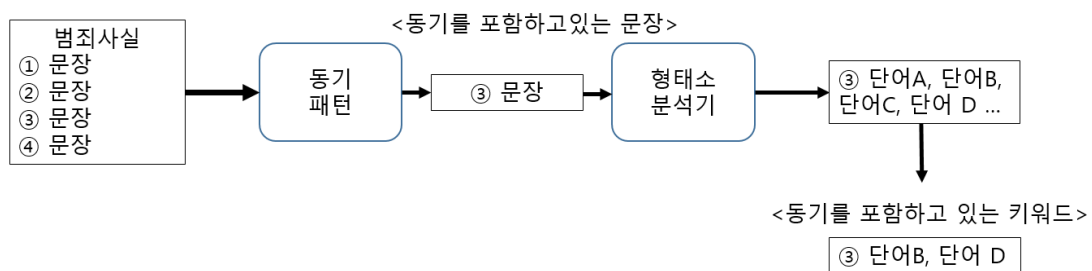


그림 28 동기 분류 데이터셋 구축 흐름도

3. 범죄 사실 내 동기를 포함하고 있는 문장 분리 기준 수립

살인죄에서 동기는 치정, 원한, 정신, 금품과 같은 단순하게 이루어져 있는 경우도 있고, 앞서 제 3장 제 4 절 내 4. 유사 사건 기준의 동기와 동기 분류의 중요성에서 언급했던 부산지방법원 2018 고합 511 판결처럼 평소 피고인이 피해자에 대해 좋지 않은 감정을 가지고 있었고, 범행 당일의 다툼이 살인의 동기가 되는 경우도 있다. 이에, 본 연구에서는 평소 피고인이 피해자에 대해 좋지 않은 감정을 가지고 있었던 것을 '1 차 동기'로, 범행 당일 다툼이 살인으로 이어지는 것을 '2 차 동기'로 분리하였다. 근본적인 원인을 서술하는 1 차 원인 보다는 살인 또는 살인미수로 이어지는 직접적인 동기인 2 차 동기를 추출하기 위해 특정 패턴과 작업을 통해 동기를 서술하고 있는 문장을 추출하였다. 한 문장에 동기를

서술하고 있다면, 해당 문장을 추출하였고, 한 문장만으로 부족한 경우, 추가적으로 앞뒤 문장을 고려하여 추출하였다.

살인죄에서 동기를 서술하는 방식은 크게 6가지로 나눌 수 있다. 각 패턴과 해당 패턴을 잡아내기 위한 정규표현식은 아래 그림 18 과 같다. 첫번째는 ‘마음먹고’라는 구절이다. 아래 그림 18은 마음먹고 라는 문장을 담고 있는 판결문 예시이다. 가장 먼저 ‘마음먹고’라는 패턴을 잡아낸 이유는 피고인이 범행을 저지르기 전 마지막으로 언급되는 동기 부분이기 때문이다. ‘화가 나’ 또는 ‘양심을 품고’ 라는 문구는 1차 동기 뿐만 아니라 2차 동기에도 해당 하는 문구이기 때문에, 2차 동기를 가장 정확히 뽑아낼 수 있는 ‘마음먹고’를 먼저 추출하였다. 다음 패턴인 ‘결심을 하고’와 ‘결의하고’는 ‘마음먹고’에 또 다른 표현으로, ‘마음먹고’처럼 2차 동기를 중점적으로 나타낸다. 따라서, ‘마음먹고’로 잡아내지 못한 사건 내 패턴을 잡아내었다. 앞선 패턴들로 2차 동기를 잡아 냈기 때문에, ‘화를 참지’, ‘화가 나’, ‘양심을 품고’와 같은 1차 동기 서술에도 사용되는 방식으로 동기를 잡아주었다. 그럼에도 불구하고, 패턴으로 잡히지 않는 동기 서술 방식들과 동기 자체가 존재하지 않는 경우도 있었다. 위와 같은 패턴들에 대한 설명과 예시는 부록 A에 서술해 두었다.

판결문을 분석하면서 파악된 패턴을 정규 표현식을 사용해 동기 문장을 추출하였다 (표 29). 정규 표현식을 사용하는 이유는 패턴과 완벽히 일치하는 문장이나 패턴 사이에 띄어쓰기 있거나 없는 경우, 그리고 ‘마음먹고’, ‘마음을 먹고’, ‘마음 먹었다’, ‘마음을 먹게’, ‘마음을 먹었다’ 처럼 다양한 형식으로 등장하는 패턴을 잡아낼 수 있기 때문이다.

표 28 범죄 사실 내 동기를 나타내는 패턴 및 정규 표현식

순서	패턴	정규 표현식
1	마음 먹고	마음은?을?\s?먹[은 고 였 게]
2	결심을 하고	결심을?\s?하
3	결의하고	결의\s?하[였 고 의]
4	격분하여	격분[하 한]
5	화를 참지	화를\s?[내 참]

6	화가 나	화가\s?[내 난 풀]
7	양심을 품고	[불만 양심]을\s?품[고 은 였]
8	패턴이 없는 경우	-
9	동기가 없는 경우	-

패턴을 통해, 범죄 사실 내 동기를 포함하고 있는 문장을 추출하였다. 특정 기준에 따라 사람이 직접 손으로 동기를 포함하고 있는 문장을 추출해야 하는 경우도 있었다. 1) 앞서 본 패턴 중, 패턴이 없는 경우와 동기가 없는 경우, 동기 패턴을 잘 잡아 냈으나 2) 해당 문장이 아닌 앞 문장에서 동기를 상세히 설명하고 그 다음 문장에서 동기 문장 패턴을 가지고 있는 경우, 3) 정신으로 분류되는 사건인 경우로 나뉘진다.

동기 패턴을 통해, 동기를 서술하는 문장을 잡아 냈으나, 앞 문장에서 동기를 서술하고 뒤 문장에서 앞 문장을 정리하며 동기 패턴을 가지고 있을 경우, 위와 같은 패턴으로는 뒤 문장을 동기 문장으로 반환한다. 아래 그림 30 광주지방법원 목포지원 2020 고합 91 판결의 범죄 사실을 예시로 설명해보겠다. 앞서 동기 패턴을 사용해 동기 문장을 추출할 경우, 그림 18 내 ④ 문장을 추출하게 된다. 하지만, ④ 문장의 경우, ③ 문장을 짧게 서술하고 이후 피고인의 범행 과정과 피고인의 행위로 인한 피해자의 결과에 대한 부분을 서술하고 있다. 오히려 ③ 문장에서 피고인과 피해자가 다투게 되었으며, 위 과정 속에서 피고인 피해자에게 맞아 넘어졌고, ④ 문장인 살해하기로 마음먹었다고 보는 것이 합당하다. 따라서 해당 사건의 경우, 동기 문장으로 ④이 아닌 ③ 문장으로 수정하였다.

① 범죄사실

② 피고인과 피해자 B(남, 61 세)는 전남 신안군 임자면 선적의 근해자망어선인 C(14 톤)의 선원으로서, 피고인은 평소 피해자가 피고인을 포함한 동료 선원들에게 지속적으로 폭언을 하는 문제로 피해자에게 앙심을 품고 있었다.

③ 피고인은 2020. 8.21. 06:50 경 전남 신안군 임자도 북서방 인근 해상에서 조업 중인 위 어선의 선수갑판에서 어획물 정리 작업을 하면서 **피해자와 다투게 되었고, 피해자로부터 손으로 얼굴을 3 회 맞아 그곳 바닥에 넘어지게 되었다.**

④ 이에 피고인은 격분하여 피해자를 살해하기로 **마음먹고**, 그곳 선수갑판에 보관 중이던 작업용 칼(칼날 길이 20cm. 전체 길이 33cm)을 오른손으로 뽑아 든 다음 위 칼로 피해자의 좌측 가슴 부위를 2 회 찔렀으나, 피해자가 왼팔로 이를 막으며 반항하고 주변에 있던 동료 선원이 피고인을 제지하여 피해자에게 치료일수를 알 수 없는 좌측 가슴 부위 자상 및 좌측 팔꿈치 열상을 가하는데 그쳤다.

⑤ 이로써 피고인은 피해자를 살해하려고 하였으나 그 뜻을 이루지 못하고 미수에 그쳤다.

그림 30 광주지방법원 목포지원 2020 고택 91 판결의 범죄사실

또한, 분류가 정신에 해당하는 경우, 동기 패턴으로 잡아내는 문장이 피고인이 피해자를 살해하게 된 주요 원인이 맞으나 피고인의 의사결정 과정에 있어서는 정신과 관련된 문제가 가장 큰 원인으로 작용되었기 때문에, 피고인의 정신 질환 문제를 잘 나타내는 문장을 추출하였다. 예시로 광주지방법원 2019 고택 312 판결의 범죄사실을 사용하여 해당 예시는 부록 B 에 있다. 피고인은 A 와 사이에서 피해자를 출산하고 양육하던 중, C 와 다툼이 있었다. 위 과정 중 피해자가 칭얼거리자 피고인은 피해자를 창문 밖으로 던져 살해할 마음을 먹게 되었다. 하지만, 당시 피고인 중등도의 지적장애 등으로 인하여

사물을 변별할 능력이나 의사를 결정할 능력이 미약한 상태에서 해당 범죄를 저질렀기 때문에, 부록 B 내 8 번 문장이 아닌 9 번 문장을 추출한다. 그리고 해당 사건은 피해자의 청얼거림으로 인한 피고인의 원한으로 분류하지 않고, 피고인의 정신 질환으로 인한 사건으로 분류하였다.

4. 동기 포함 문장 내 분류 별 키워드 추출 기준 수립

동기 분류를 치정, 원한, 정신, 금품으로 지정하였고, 범죄 사실 내에서 동기를 담고 있는 문장을 추출하였다. 트랜스포머 계열 모델의 경우, 앞서 추출한 문장으로도 동기 분류가 가능하다. 하지만, 머신 러닝 계열의 모델은 아직 문장을 통해 문맥을 파악하는 기능까지 지원하지 않기 때문에, 문장 내에서 주요 키워드를 추출해 데이터셋을 구축한다. 키워드 추출 기준으로는 1) 동기 문장 내 분류에 해당할 만한 주요 키워드를 추출하고, 2) 키워드는 문장 내 출현 빈도에 따라 추출한다. 같은 분류에 해당하더라도 사건마다 특성이 다르기 때문에, 해당 특성을 살려주기 위해서 키워드는 출현 빈도에 따라 넣어준다. 또한, 머신 러닝 기법의 모델의 경우, 단어 빈도 수를 기반으로 각 사건별로 벡터를 만들어주기 때문에, 단어의 빈도수도 고려해야 한다. 각 사건마다 일정한 키워드를 추출하기 위해, 동기 문장을 형태소 분석기 중 Mecab을 사용하여 형태소 별로 분리하고 그 중에서 키워드를 추출한다. ‘불륜’과 같이 치정에서는 매우 중요하게 사용되나, Mecab 형태소 분석기는 ‘불,륜’으로 분리하기 때문에, 특정 단어들은 한 단어로 합쳐 키워드로 추출한다. 이후 각 분류에서 사용되는 세부 기준과 추출 방안 그리고 결과에 대해서 알아본다.

치정은 다른 분류와 달리 피고인과 피해자의 관계가 두드러지는 분류이다. 대개, 치정의 경우, 피고인과 피해자가 부부 관계이거나 연인 관계이며, 관계가 틀어지는 것을 염려한 피고인이 피해자와 다투던 중 범행이 일어난다. 따라서, 치정에 해당하는 사건에서는 문장 내에서 1) 피고인과 피해자의 관계를 알 수 있는 단어, 2) 피고인이 피해자와의 관계를 지속 또는 우려하는 단어, 3) 피고인과 피해자 사이의 관계로 인해 단어들을 위주로 추출한다. 아래는 치정으로 분류된 광주지방법원 목포지원 2012고합 181 판결서 내 동기 추출 문장이다. 피고인은 피해자와 부부 사이이며, 피해자에 계속되는 이혼 요구와 피해자의 잦은

외출로 피고인은 피해자의 외도를 의심하여 살인 미수 사건이 벌어졌다. 따라서, 키워드로 피고인과 피해자의 관계를 나타내는 ‘처’, 그리고 피고인이 피해자의 관계로 인해 일어나는 ‘경제적, 무능력, 이혼, 요구, 부부, 관계, 남자, 의심’와 같은 단어들을 추출하였다. 예시에 서는 ‘이혼’이라는 단어가 동기 문장 내 총 3번 등장하였기 때문에, 키워드로 ‘이혼’을 3번 넣어주었다.

예시) 광주지방법원 목포지원 2012고합181

<동기 문장>

피고인은 처인 피해자 C(여, 36세)이 피고인의 경제적 무능력을 문제 삼으며, 2011.말 경부터 피고인에게 반복적으로 이혼을 요구하고, 부부관계에도 응하지 않으며, 주말에 도 일을 한다면서 외출을 하는 경우가 잦아지자, 피해자에게 다른 남자가 생겼다는 의심을 하게 되었고, 피고인이 피해자에게 내년이 되면 이혼을 해주겠다고 약속을 하였는데도 최근 피해자가 피고인에게 계속해서 이혼을 요구하자, 피해자를 살해할 마음을 먹게 되었다.

<형태소 분석기 결과>

피고인|은|처|인|피해자|C|(여|,|36|세)|이|피고인|의|경제적|무능력|을|문제|삼|으며|,|2011|.말|경|부|터|피고|인|에|게|반|복|적|으|로|이|혼|을|요|구|하|고|,|부|부|관|계|에|도|응|하|지|않|으|며|,|주|말|에|도|일|을|한|다|면|서|외|출|을|하|는|경|우|가|잦|아|지|자|,|피|해|자|에|게|다|른|남|자|가|생|겼|다|는|의|심|을|하|게|되|었|고|,|피|고|인|이|피|해|자|에|게|내|년|이|되|면|이|혼|을|해|주|겠|다|고|약|속|을|하|였|는|데|도|최|근|피|해|자|가|피|고|인|에|게|계|속|해|서|이|혼|을|요|구|하|자|,|피|해|자|를|살|해|할|마|음|을|먹|게|되|었|다|.

<키워드 추출 결과>

처, 경제적, 무능력, 이혼, 요구, 부부, 관계, 다른, 남자, 의심, 이혼, 이혼, 요구

그림 31 광주지방법원 목포지원 2012 고합 181 판결을 이용한 치정 키워드 추출 예시

정신은 피고인의 정신상태로 일어나는 사건을 분류한 사건들로, 피고인의 정신 상태 또는 피고인이 앓고 있는 정신 질환과 관련된 키워드를 추출한다. 예시로, 서울중앙지방법원 2015고합856 판결은 피고인이 기질성 인격장애로 사물 변별 능력이나 의사 결정 능력이 미약한 상태에서 피해자와 화단 내 돌무더기 처리 문제로 싸움 중 피해자에게 의견이 묵살되었다고 생각되어 과도를 피해자를 살해한 사건이다. 피고인과 피해자의 다툼 과정으로 인해 피해자가 살해되었으나, 근본적으로는 피고인의 정신 질환으로 인한 사건이므로, 피고인의 정신 질환이나 피고인이 범행 당시 겪고 있었던 상태에 대한 키워드를 추출하였다. 먼저, 피고인의 정신 질환을 나타내는 키워드인 ‘기질성, 인격장애’와 피고인이 범행 당시 겪고 있었던 상태인 ‘사물, 변별, 능력, 의사, 결정, 능력, 미약, 상태’를 추출하였다.

예시) 서울중앙지방법원 2015고합856 판결

<동기 문장>

피고인은 기질성 인격장애로 아래 범행 당시 사물을 변별할 능력이나 의사를 결정할 능력이 미약한 상태에 있었다. 피고인은 서울 강남구 C 아파트 102 동 107 호 거주하면서 102 동 뒤편 화단 관리를 하여 왔는데, 다른 주민이 화단 관리를 방해한다고 느껴지면 그 주민들과 싸움을 벌이는 등 마찰을 빚곤 하였다.

<형태소 분석 결과>

피고인은기질성인격장애로아래범행당시사물을변별할능력이나의사를결정할능력이미약한상태에있었다.피고인은서울강남구C아파트102동107호에거주하면서102동뒤편화단관리를하여왔는데,다른주민들이화단관리를방해한다고느껴지면그주민들과싸움을벌이는등마찰을빚곤하였다.

<키워드 추출 결과>

기질성, 인격, 장애, 사물, 변별, 능력, 의사, 결정, 능력, 미약, 상태

그림 32 서울중앙지방법원 2015 고합 856 판결을 이용한 정신 키워드 추출 예시

금품은 피고인과 피해자의 채무 관계 또는 피해자와의 지속적인 금전 문제로 벌어지는 경우에 해당한다. 따라서, 금품에 해당하는 사건의 키워드 추출 기준은 피고인과 피해자 사이의 금품 문제를 나타내는 단어들을 키워드로 선정하였다. 예를 들어, 춘천지방법원 2013 고합 136 사건의 경우, 강간과 관련된 전과를 가지고 있는 피고인이 재활용품 수거장에서 만난 피해자와 친해져, 피해자로부터 돈을 빌려달라는 부탁을 받고 현금 5 만원을 빌려주었다. 이후, 피고인은 피해자와 함께 술을 마시던 중, 피해자에게 빌려줬던 돈을 갚으라고 하였으나, 피해자는 빌린 적 없다며 반항하자 과도로 피해자를 살해한 사건이다. 피고인이 피해자에게 빌려준 돈으로 인해 피해자가 사망하는 사건까지 발생하였으므로, 피고인과 피해자 사이의 금품 거래를 설명할 수 있는 키워드를 추출한다. 아래 동기 문장에서 ‘빌려,만원,갚,요구,돈,빌렸’를 키워드로 추출해 사용하였다.

예시) 춘천지방법원 2013고합136 판결

<동기 문장>

피고인은 2013. 10. 6. 20:00 경 위 아파트 부근에서 피해자를 만난 후, 피해자와 함께 춘천시 H에 있는 원룸 건물 2층 2호에 있는 피고인의 주거지로 와서 술을 마시던 중, 같은 날 23:0 경 피해자에게 위와 같이 빌려준 5 만 원을 갚으라고 요구하였으나 피해자가 \"내가 돈을 언제 빌렸느냐\"라고 억지를 부리며 거세게 반항하자, 이에 격분하여 오른손으로 피해자의 목을 잡고 왼손으로 그 옆에 있던 과도(총길이 21cm. 날길이 10cm)로 피해자의 목 부위를 총 5 회(왼쪽 2 회, 오른쪽 1 회, 뒷목덜미 2 회) 찔러 피해자로 하여금 그 무렵 경부자창상으로 사망하게 하였다.

<형태소 분석 결과>

피고인|은|2013|.10|.6|.20:|00|경|위|아파트|부근|에서|피해자|를|만난|후|,|피해자|와|함께|춘천시|H|에|있는|원룸|건물|2층|2호|에|있는|피고인|의|주거지|로|와서|술|을|마시던|중|,|같은|날|23:|00|경|피해자|에게|위와|같이|빌려준|5만|원을|갚으|라고|요구|하였으나|피해자|가|\"내가|돈을|언제|빌렸|느냐|\"라고|억지|를|부리며|거세|게|반항|하자|,|이에|격분|하여|오른손|으로|피해자|의|목|을|잡고|왼손|으로|그|옆|에|있던|과도|(총길이|21|cm|.날길이|10|cm)|로|피해자|의|목|부위|를|총|5회|(왼쪽|2회|,|오른쪽|1회|,|뒷목|덜미|2회)|찔러|피해자|로|하여금|그|무렵|경부|자창상|으로|사망|하게|하였다|.

<키워드 추출 결과>

빌려,만원,갚,요구,돈,빌렸

그림 33 춘천지방법원 2013 고합 136 판결을 이용한 금품 키워드 추출 예시

원한은 피고인과 피해자 사이의 말다툼이나 몸싸움으로 인해 사건이 벌어지는 경우에 해당하므로, 원한을 나타내는 키워드로는 피고인과 피해자의 다툼 원인과 다툼 과정부터 범행 직전까지의 다툼을 담고 있는 키워드를 추출하였다. 특히, 범행 전부터의 싸움이 범행 중까지도 이어지는 경우가 많아, 원한 키워드를 추출할 때는 동기 패턴을 기준으로 이전까지의 문장 내에서만 추출한다. 예시로, 청주지방법원 2018 고합 171 사건은 피고인과 피해자는 동거하는 사이인데, 피고인은 평소 피해자가 피고인에게 반말과 욕설을 하고 피해자의 개 3 마리를 관리하지 않아 피해자에게 불만이 쌓여 있었다. 범행 당일, 피고인은 피해자에게 반말과 욕설을 듣자 화가 나 칼로 피해자를 찔렀으나 미수에 그쳤다. 따라서, 피고인과 피해자가 다투게 된 경위를 나타내는 단어인 ‘때리, 반말, 욕설’을 키워드로 추출해 사용하였다.

살인죄 판결문의 범죄사실에 서술되어 있는 다양한 동기를 지정, 원한, 정신, 금품으로 분류하고, 범죄 사실 내에서 동기 부분을 서술하고 있는 문장을 추출하는 기준을 수립해 추출하였고, 해당 문장에서 각 분류에 해당하는 키워드를 추출하였다. 추후, 동기를 포함하고 있는 문장은 문장을 입력 값으로 받고, 문맥을 이해할 수 있는 트랜스포머 계열 모델에 활용하고, 문장을 받아들이기 어려운 머신 러닝 계열 모델에는 추출한 키워드를 활용한다.

예시) 청주지방법원 2018고합171

<동기 문장>

피고인은 2018. 8. 17. 22:30 경 위 피고인의 주거지 방 안에서, 피해자가 술을 마시고 있던 피고인에게 "왜 개를 때리느냐"고 하면서 또 반말을 하고 욕설을 하자 격분하여 피해자를 살해할 것을 마음먹고, 그곳 밥상의 냄비 안에 들어 있던 칼(총 길이 약 33cm 칼날 길이 약 22cm)을 꺼내어 들고 "너 이 새끼, 죽여 버린다"라고 말하면서 피해자의 등 부위를 깊숙이 찌르고, 이어 피해자의 목과 어깨 부위를 찌르는 등 피해자를 8 회 정도 찔러 살해하려 하였으나, 피해자가 그 자리에서 도망가는 바람에 그 뜻을 이루지 못하고 미수에 그쳤다.

<형태소 분석 결과>

피고인은|2018|.18|.17|.22:30|경|위|피고인|의|주거지|방|안|에서|.피해자|가|술|을|마시고|있던|피고인|에게|"왜|개|를|때리|느냐|"고|하|면서|또|반말|을|하|고|욕설|을|하|자|격분|하|여|피해자|를|살해|할|것|을|마음|먹|고|.그|곳|밥상|의|냄비|안|에|들|어|있|던|칼|(총|길이|약|33|cm|칼날|길이|약|22|cm)|을|꺼내|어|들|고|"너|이|새끼|.죽|여|버|린다|"라|고|말|하|면서|피해자|의|등|부위|를|깊|숙|이|찌|르|고|.이|어|피해자|의|목|과|어깨|부위|를|찌|르|는|등|피해자|를|8|회|정|도|찔|러|살|해|하|려|하|였|으나|.피해자|가|그|자|리|에서|도|망|가|는|바|람|에|그|뜻|을|이|루|지|못|하|고|미수|에|그|쳤|다|.

<키워드 추출 결과>

때리, 반말, 욕설

그림 36 청주지방법원 2018 고합 171 판결을 이용한 원한 키워드 추출 예시

5. 동기 분류 데이터셋 구축

범죄 사실 내 다양한 방식으로 서술되어 있는 동기를 분류하기 위해, 동기를 포함한 문장을 추출하고, 해당 문장을 기반으로 사건의 동기 분류를 잘 나타내는 키워드들을 추출하였다. 살인 판결문 중 단일 범죄로 이루어진 2,589건 중 1,012건을 작업을 통해 동기 데이터셋을 구축하였다. 데이터 크기 별 각 모델이 도출하는 결과 값을 확인하고자 1,2,3차로 분리하였다. 1차 데이터셋은 총 365건의 데이터를 포함하고 있고, 2차 데이터셋은 1차 데이터셋에 324건을 추가해 총 689건의 데이터를 포함하고 있다. 1,2차 데이터는 모두 동기 문장이 패턴으로 분리가 되는 케이스들만 포함한 데이터셋이다. 3차 데이터셋은 총 1,012건으로, 데이터의 다양성을 위해 패턴으로 분리되지 않은 사건 323건을 추가해 구축하였다. 각 데이터셋 별로 분포된 분류는 표 30와 표31을 통해 확인할 수 있고, 전반적으로 원한으로 분류되는 사건들이 많은 것을 확인할 수 있었다. 또한, 표 33을 통해, 데이터셋 별로 동기 분장 내 글자 수의 평균을 확인해본 결과, 패턴으로 잡아낸 동기 문장으로만 구성된 데이터셋 2번과 패턴으로 잡지 못한 동기 문장 데이터가 섞인 3번 데이터의 차이가 크지 않다는 것을 발견하였다. 이는 패턴으로 잡지 않은 동기 문장도 패턴으로 잡아낸 동기 문장의 길이와 비슷하다는 것을 알 수 있었다.

표 29 데이터셋 1,2,3 내 세부 내역

데이터셋	치정	원한	정신	금품	합계
1	84	189	57	35	365
2	146	355	100	88	689
3	185	540	166	121	1,012

표 30 데이터셋 별 동기 분포 변화




표 32 데이터셋 별로 동기 문장 글자 수 평균

데이터셋	평균 단어 수
1	313.93
2	318.96
3	320.55

각 데이터셋 내 동기 분포를 살펴보겠다. 데이터셋 1 을 기반으로 데이터셋 2 에 324 건의 사건이 추가되었고, 데이터 2 를 기반으로 데이터셋 3 에는 323 건의 사건이 추가되었다. 데이터의 크기가 늘어남에 따라, 동기 분류 분포의 변화를 통해, 데이터 내 분포가 일정한 지 아니면 특정 분포가 늘어나는지를 확인해보겠다. 아래 표 23 을 통해, 데이터셋 1 내 동기 분포 비율을 기준으로 각 데이터셋의 동기 분포 비율을 확인해보겠다. 데이터셋 1 에서 가장 많이 도출된 사건은 원한이고 총 데이터 중에서 52%의 비율을

차지하였다. 이후, 치정, 정신, 금품 순으로 많이 도출되는 것을 확인할 수 있었다. 이러한 상황의 까닭으로는 관계에 영향을 많이 받는 치정, 피고인의 정신 상태에 따른 정신, 피고인과 피해자 사이의 금품 거래로 인한 금품의 경우, 각 데이터 별로 요구하는 사항으로 인해 데이터의 특색이 강하기 때문에 전체 사건 대비 원한에 비해 출현 빈도가 낮은 것으로 파악된다.

데이터셋 2와 3의 경우에도 약간의 비율 변화는 있으나, 대개 데이터셋 1과 같은 맥락을 보여주고 있음을 파악하였다. 원한의 경우, 데이터셋 1,2,3을 통해 52~53%를 유지하고 있었고, 치정의 경우, 데이터셋이 늘어남에 따라 비율이 23%에서 18% 정도까지 낮아짐을 확인하였다. 하지만, 정신과 금품의 경우 데이터셋 3에서 초기 기준인 데이터셋 1과 같은 비율을 유지하거나 오히려 증가한 추세를 보여주었다. 정신의 경우, 데이터셋 2에서는 1% 감소하였고, 데이터셋 3에서는 1% 증가함을 알 수 있었다. 이는, 피고인의 정신 질환으로 인해 분류되는 정신의 경우, 동기 패턴으로 잡아낼 수 없었던 사건들에서 많이 드러났던 것으로 보인다. 또한, 금품의 경우, 동기 패턴으로 잡아낸 사건 중에서 많이 나타났기 때문에 데이터셋 1에서 데이터셋 2까지의 증가를 나타내고, 이후, 동기를 나타내는 패턴이 잡히지 않은 사건의 데이터를 섞음으로 약간의 감소를 일으킨 것으로 보인다.

표 33 각 데이터셋 내 동기 분류 분포 비율

(단위: %)

데이터셋	치정	원한	정신	금품	합계
1	23	52	16	10	100
2	21	52	15	13	100
3	18	53	16	12	100

위 과정들을 통해, 형사 1심 판결문 데이터에 적합한 동기 분류의 기준을 선정하였고, 범죄 사실 내에서 해당 기준에 따른 동기를 서술하고 있는 문장과 키워드를 추출하였다. 추출한 문장과 키워드를 기반으로 데이터셋 1,2,3을 구축하였다. 데이터셋 1,2,3은 데이터셋 1을 기반으로 사건을 더 추가한 형태를 띄고 있으며, 데이터셋 1과 2의 경우는 동기를 나타내는 패턴이 뚜렷한 사건을 중심으로 구축되었고, 데이터셋 3에 추가된 데이터는 동기를 나타내는 패턴이 없는 사건들이 추가되었다. 이후에는 데이터셋 1,2,3을 기반으로 머신러닝 모델과 트랜스포머 계열 모델을 학습시키고 각 모델 별 성능을 도출한다.

제5장 동기 분류 데이터셋을 중심으로 한 분류 모델 구축 및 검증

제 1절 동기 분류 모델 구축 방안

범죄 사실 내에서 동기를 포함한 동기 문장과 동기 분류의 성격을 띄고 있는 동기 키워드들을 추출한 데이터셋 1,2,3 을 구축하였다. 해당 데이터셋의 구성 요소인 키워드를 기반으로 베이스라인(baseline)을 구축하고, 키워드와 문장을 입력 값으로 사용하는 머신러닝 계열 모델과 문장만 입력 값으로 사용하는 트랜스포머 계열 모델로 나눠 구축한다. 머신러닝 계열 모델로는 Decision Tree, Random Forest, SVM 을 선정하였고, 트랜스포머 계열 모델로는 KoBERT(SKTBrain)과 KLUE bert-base(huggingface)를 선정하였다. 각 모델에 동일한 학습 데이터와 검증 데이터를 사용하기 위해 동기 분류 데이터셋을 8 대 2 비율로 나눠 80%의 데이터로 모델을 학습시키고, 20% 데이터로 모델의 성능을 검증하였다. 아래 표 35 는 데이터셋 별 학습 및 검증 데이터의 크기와 각각 들어있는 분류 별 분포를 나타낸 표이다. 전체 데이터셋을 학습용과 검증용으로 나누기 위해 파이썬 모듈 중 scikit-learn 모듈⁶을 사용해 전체 데이터셋을 랜덤으로 섞은 뒤 8 대 2 비율에 맞춰 분리하였다.

⁶ 1.0.2 버전의 Scikit-learn 모듈을 사용하였다.

표 34 데이터셋 별 학습 및 검증 데이터 크기와 분류 별 분포

데이터셋	목적	분류			
		치정	원한	정신	금품
1 차	학습	66	151	45	30
	검증	18	38	12	5
	전체	84	189	57	35
2 차	학습	122	276	74	79
	검증	24	79	26	9
	전체	146	355	100	88
3 차	학습	161	421	128	99
	검증	24	119	38	22
	전체	185	540	166	121

1. 베이스 라인 모델 설계

선행 실험을 통해, 유사 사건을 판별하는 가장 중요한 기준은 동기로 드러났다. 이에, 범죄 사실 내 동기를 포함하고 있는 문장의 패턴을 찾아내 해당 문장과 동기 분류 별 문장에서 중요하게 여겨지는 키워드를 추출하여 데이터셋을 구축하였다. 빈도수를 기반으로 기본이 되는 베이스라인 모델을 구축하여 머신러닝 계열과 트랜스포머 계열 모델들 사이의 성능을 비교해본다. 먼저, 베이스라인 모델은 키워드 빈도수를 기반으로 분류를 도출하였다. 학습용 데이터셋 내 사건의 분류와 키워드를 모두 취합하여, 분류별 키워드를 정리하였다. 이때, 같은 분류에서 중복으로 등장하는 키워드는 1개만 남기고 제거해주었고, 여러 분류에 등장하는 키워드는 제거해주지 않았다. 여러 분류에 등장하는 키워드는 도출된 분류에 성격을 반영하고 있기 때문에 별도로 제거해주지 않았다. 예를 들어, 치정 분류 내에서 ‘이혼’이라는 단어가 10번이 나왔을 경우, 1 단어만 남기고 모두 제거하였다. 하지만, 치정과 원한 분류 모두 ‘술’이라는 단어가 나왔을 경우, 해당 단어는 어느 분류에서도 삭제해주

지 않았다.

검증용 데이터셋 내 동기 문장을 해당 키워드셋으로 각 분류별 빈도수를 파악한 뒤, 가장 많은 빈도수를 도출한 분류를 베이스라인에서 도출한 분류 결과로 파악하였다. 이때, 베이스라인에서 도출한 분류와 실제 분류 라벨이 일치할 경우, 정답으로 판정하였고, 실제 분류 라벨과 일치하지 않는 경우 오답으로 판정하였다. 베이스라인이 검증용 데이터셋을 분류하는 중, 그림 38내 사건 C와 같이 특정 분류들의 빈도수가 같은 경우가 발생하는 것을 확인하였다. 하지만, 위와 같은 상황은 단순 키워드 빈도수를 기반으로 분류를 진행하기 베이스라인의 한계점으로 보고 ‘판단 불가’라벨을 부여하였고, 해당 라벨은 모두 오답으로 처리하였다.

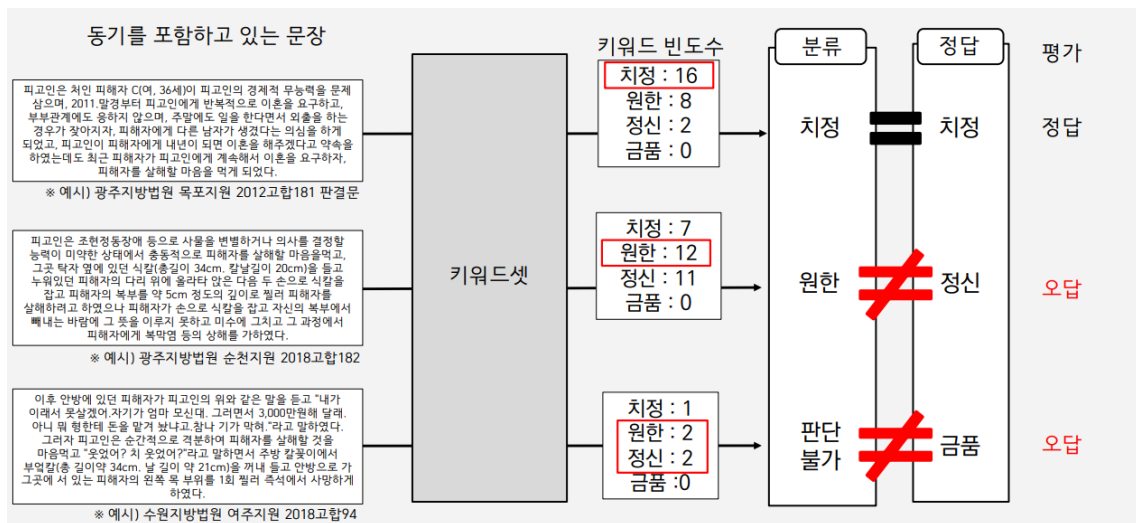


그림 38 베이스라인 모델 구축 도안

2. 전통적인 머신러닝 모델 설계

베이스라인을 기준으로, 머신러닝 모델인 Decision Tree, Random Forest, SVM 과 트랜스포머 계열 모델인 KoBERT 와 KLUE(bert-base) 모델 사이의 성능 값을 비교해보기 위해 각 모델을 구축하였다. 머신러닝 모델을 이용한 범행동기 분류 방식은 아래 그림 과 같다. 동기를 포함하고 있는 문장을 기반으로 사람이 직접 추출한 키워드 결과와 형태소 분석기를 통해 명사만 도출한 결과 내 단어 빈도수를 기반으로 벡터를 구축한다. 해당 벡터를 머신러닝 기법인 Decision Tree, Random Forest 와 SVM 에 입력 값으로 사용하였다. 단어 빈도수를 기반으로 구축한 벡터 생성과 Decision Tree, Random Forest, SVM 모델의 학습 및 범행 동기 분류 예측 값 추출에는 파이썬 모듈 중 sklearn⁷을 사용하였다.

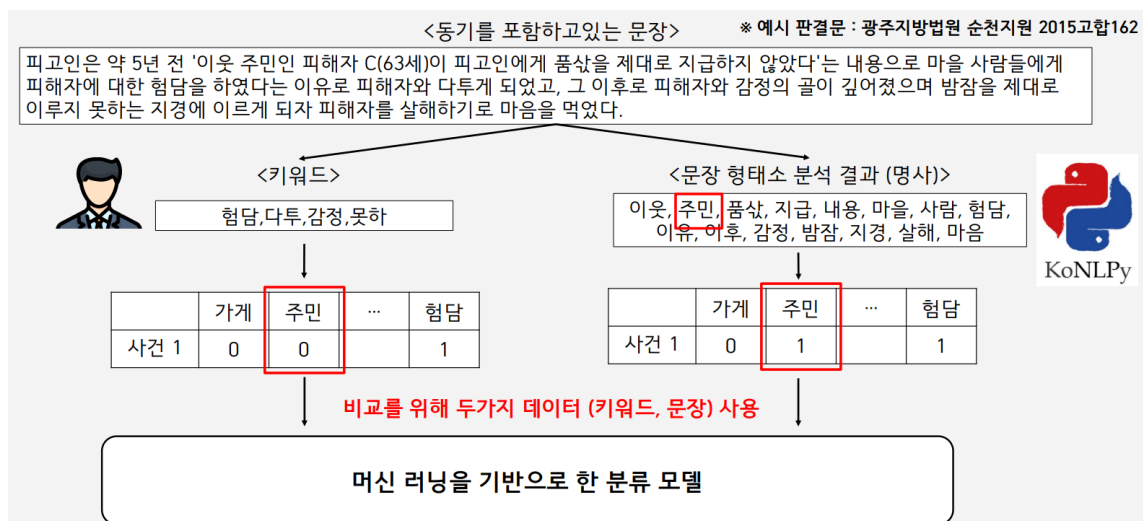


그림 39 머신러닝을 활용한 동기 분류 도식화

⁷ 1.0.2 버전의 scikit-learn 모듈을 사용하였다.

case_name	가격	가게	가로채	가정	가출	간병	간섭	갈등	감당	감정	...	혼내	혼인	올대	확신	환각	환청	회피	혼계	취두르	흡입
광주지법(목포)_2012고합181	0	0	0	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0
광주지법(목포)_2012고합247	0	0	0	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0
광주지법(목포)_2012고합257	0	0	0	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0
광주지법(목포)_2013고합25	0	0	0	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0
광주지법(목포)_2014고합133	0	0	0	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0
...
의정부지법(고양)_2013고합93	0	0	0	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0
인천지법_2014고합264	0	0	0	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0
인천지법_2020고합387	1	0	0	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0
창원지법(통영)_2020고합19	0	0	0	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0
창원지법_2015고합251	0	0	0	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0

그림 40 키워드 빈도수를 기반으로 생성한 사건별 벡터

앞서 나눈 학습용 데이터 셋과 검증용 데이터셋으로 각각 벡터를 구성하고 모델에 넣어줄 경우, 키워드를 입력값으로 받는 머신러닝 모델의 특성으로 인해 처음 접하는 키워드에 대한 처리를 해줄 수 없다. 또한, 학습용 데이터 셋과 검증용 데이터셋 각각 구성된 벡터의 차원이 다르기 때문에 모델에서 이를 받아들일 수 없다. 벡터 차원을 맞춰주기 위해 특정 벡터의 길이를 제한하고 0 으로 채워주는 패딩(padding)을 진행할 수도 있지만, 모델은 단어를 입력값으로 판단하는 것이 아닌 단어의 빈도수를 기반으로 구성된 벡터로 판단하기 때문에 그림 30 과 같이 전체 동기 분류의 키워드와 문장에서 명사만 추출해 빈도수를 기반으로 한 벡터를 생성하여 활용한다. 이후 학습용 데이터셋과 검증용 데이터셋의 사건명을 기반으로 그림 42 에서 해당 사건들에 대한 벡터를 추출하여 각 모델에서 제공하는 fit 을 통해 학습용 데이터를 학습하고, predict 기능을 통해 검증 데이터에 대한 라벨 결과를 확인하였다.

3. 트랜스포머 모델 설계

키워드를 입력값으로 받는 머신러닝 계열 모델과는 달리 트랜스포머 계열의 모델은 문장을 입력값으로 받는다. 하지만, 단순 문장을 입력값으로 사용하는 게 아닌 BERT 모델에 맞춰진 형태로 입력값으로 변환해 주어야 한다. KoBERT와 KLUE(bert-base) 모델 둘 다 BERT 모델을 기반으로 사용하기 때문에, 아래 그림 43과 같이 BERT에 맞춰진 방식으로 임베딩을 진행해주어야 한다. 동기를 서술하고 있는 문장 앞과 뒤에 [CLS] 토큰과 [SEP] 토큰을 추가하여 문장의 시작과 끝이라는 것을 BERT에게 알려주고 데이터셋을 통해 분류된 동기를 라벨로 알려주는 추가 학습(fine-tuning) 과정을 통해 해당 문장이 치정으로 분류된다는 것을 학습시켜줘야 한다. 따라서, 앞서 구축한 동기 분류 데이터셋 내 학습용 데이터를 통해 모델을 추가학습한 뒤, 검증용 데이터로 해당 모델의 성능을 평가하였다.

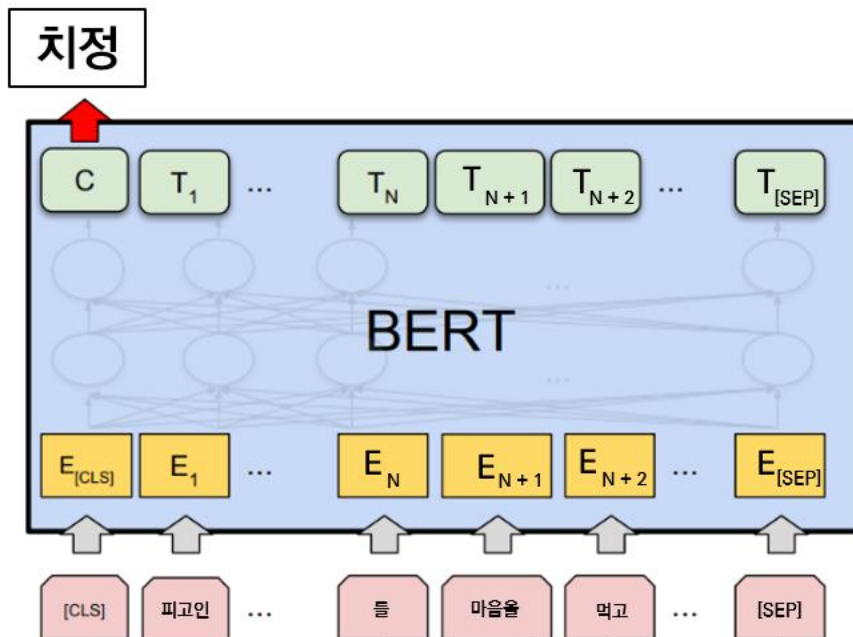


그림 41 트랜스포머 계열을 활용한 동기 분류 모델 작동 원리

KoBERT 와 KLUE 모델의 세부적인 파라미터를 살펴 보자면, 먼저 KoBERT 는 파이썬 모듈 중 자연어처리 태스크에 효율적인 glounnlp 모듈⁸[58]을 이용해서 앞서 구축한 동기 분류 데이터셋을 가져온다. KoBERT 는 한국어 형식에 맞춰진 토큰나이저를 제공하고 있어, 해당 토큰나이저를 통해 데이터셋 내 동기를 서술하고 있는 문장을 분할한 뒤, 정수 인코딩과 패딩을 진행하였다. 모델을 학습시킬 때는 Adam 를 사용해 optimizer 를 해주었다. 이후, SKTBrain 에서 대량의 한국어 데이터를 학습시킨 KoBERT 모델을 가져와 사용하였고, KoBERT 모델에 대한 세부 파라미터는 아래 표 36 과 같다.

표 35 KoBERT 모델 구축에 사용한 세부 파라미터와 값

세부 파라미터	값
Max_length	128
batch_size	32
num_epochs	10
learning_rate	5e-5
Optimizer	Adam

KLUE 모델을 사용하기 위해, 동기를 서술하고 있는 문장을 BERT 형식에 맞춰 임베딩한 후, 파이썬 모듈 중 transformer⁹를 사용하여 huggingface 내 KLUE (bert-base)모델을 가져와 사용하였다. 또한, 앞서 사용한 KoBERT 와 같은 모델을 기반으로

⁸ 0.10.0 버전을 사용하였다.

⁹ 4.25.1 버전을 사용하였다.

KLUE 모델을 비교하기 위해, KLUE 데이터로 학습한 BERT(base)모델을 가져와 사용하였다. KLUE 모델에 사용된 세부 파라미터와 가 값은 아래 표 37 과 같다.

표 36 KLUE 모델 구축에 사용한 세부 파라미터와 값

세부 파라 미터	값
Max_ length	128
Learning rate	3e-5
epsilon	1e-08
clipnorm	1.0
Epochs	10
Optimizer	Adam

제 2절 모델이 분류한 동기 데이터 평가

각 데이터셋 별로 가장 좋은 정확도를 보여준 모델을 확인해본 결과(표 38), 데이터셋 1에서는 문장을 입력 값으로 사용한 KLUE 모델이 가장 좋았고, 데이터셋 2와 3에서는 키워드를 입력 값으로 사용한 Random Forest 모델의 성능이 가장 높은 것을 확인할 수 있었다. 이러한 결과를 통해, 단순 문장을 입력 값으로 사용했을 때보다 직접 추출한 키워드로 모델을 학습시켰을 때가 가장 좋은 결과를 도출함을 알 수 있었다. 이후에는 각 데이터셋 별로 모델의 성능을 평가한다.

표 37 데이터셋별 가장 높은 정확도를 도출한 모델과 모델에 사용된 입력 데이터의 형태

데이터셋	모델명	입력 데이터 형태	정확도
1	KLUE(bert-base)	문장	0.90
2	Random Forest	키워드	0.92
3	Random Forest	키워드	0.95

1. 데이터셋 1 내 검증 데이터를 통한 모델 평가 결과

데이터셋 1은 동기 패턴으로 잡아낸 문장과 해당 문장을 기반으로 추출한 키워드로 이루어져 있다. 해당 데이터셋의 크기는 총 365 건으로 이 중 292 건은 모델 학습에 활용하였고, 73 건을 학습한 모델을 검증하는 데 사용하였다. 아래 표 39는 각 모델이 도출한 정확도와 모델이 검증 데이터로 맞춘 사건과 틀린 사건 개수를 나타낸 것이다. 정확도의 경우, 소수점 세 자리에서 반올림하였다. 이를 통해, 문장 데이터를 입력 값으로 사용한 KLUE(bert-base) 모델이 가장 좋은 성능을 보여준 것을 확인할 수 있었다. KLUE(bert-base)는 검증용 데이터 73 건 중에 66 건을 정답 라벨과 같은 라벨을 부여하였고, 7 건을 다른 라벨로 분류하였다. 비교 대상 모델 중에서 가장 낮은 정확도를

보인 모델은 KoBERT 로 0.74 의 정확도와 정답 라벨과 비교했을 때, 54 개의 라벨을 맞추고 19 개의 라벨을 틀린 것으로 드러났다.

표 38 데이터셋 1 을 통한 각 모델의 정확도 및 검증 데이터 내 맞춘 개수와 틀린 개수

입력 데이터	모델	정확도	정답 셋과 비교 시	
			맞춘 개수	틀린 개수
키워드	Baseline	0.82	60	13
	Decision Tree	0.86	63	10
	Random Forest	0.79	58	15
	SVM	0.86	63	10
문장	Decision Tree	0.79	58	15
	Random Forest	0.64	47	28
	SVM	0.52	38	35
	KoBERT (SKTBrain)	0.74	54	19
	KLUE(bert- base)	0.90	66	7

가장 좋은 결과를 도출한 KLUE(bert-base) 모델이 동기 분류 데이터셋 1 의 검증 데이터를 기반으로 도출한 결과를 오차 행렬로 나타낸 결과는 아래 그림 44 에 나타나 있다. 실제 정답은 Y 축인 Actual 로 나타내고, 모델이 평가한 결과는 X 축인 Predicted 로 나타내 각 라벨별 도출 결과를 개수가 높을수록 밝은 색으로 표시하였다. 각 라벨 별로 살펴보면, 치정(0)의 경우, 전체 18 건 중에서 15 건을 맞추고 3 건을 원한(1)으로 분류하였다. 원한(1)의 경우, 38 건 중 36 건을 올바르게 분류하였고, 2 건을 치정(0)으로 분류한 것을 파악할 수 있었다. 정신(2)의 경우, 12 건 전부 올바르게 분류한 것을 알 수 있다. 금품(3)은 총 5 건 중에 3 건을 맞추고 2 건을 폭력으로 분류한 것으로 드러났다. KLUE 모델이 오답으로 분류한 경우는 대부분 원한(1)으로 분류한 것을 알 수 있다. 이러한 이유로는 데이터셋 1 내 원한으로 분류된 데이터의 비율이 매우 높기 때문으로 보인다(표 34 참조).




그림 42 동기 분류 데이터 셋 1 검증용 데이터를 기반으로 KLUE(bert-base) 모델이 도출한 오차행렬

표 39 데이터셋 1 내 검증용 데이터 라벨에 따른 모델 별 F1 스코어

라벨	Decision Tree	Random Forest	SVM	KoBERT	KLUE(bert-base)
치정	0.67	0.86	0.86	0.62	0.86
원한	0.84	0.89	0.89	0.73	0.81
정신	0.90	0.96	0.96	0.64	1
금품	0.54	0	0	0	0.75

2. 데이터셋 2 내 검증 데이터를 통한 모델 평가 결과

데이터셋 2는 데이터셋 1과 동기 패턴으로 분류가 가능한 데이터 324건이 합쳐져 총 689건으로 구성되어 있다. 해당 데이터셋은 551건의 학습용 데이터와 138건의 검증용 데이터로 나뉘어 각 모델에 입력 값으로 사용되었다. 아래 표 41을 통해 가장 좋은 성능을 보여주는 모델은 데이터셋 내 동기 키워드를 기반으로 분류한 Random Forest였다. Random Forest는 정확도 0.92를 보여주며 검증용 데이터 138건 중에 127건을 올바르게 분류한 것으로 나타났다. 또한, 가장 성능이 낮은 모델로는 KoBERT가 도출되었으며, KoBERT는 총 138건 중에 114건을 맞추고 24을 틀린 것으로 드러났다.

표 40 데이터셋 2 을 통한 각 모델의 정확도 및 검증 데이터 내 맞춘 개수와 틀린 개수

입력 데이터	모델	정확도	정답 셋과 비교 시	
			맞춘 개수	틀린 개수
키워드	Baseline	0.79	110	28
	Decision Tree	0.89	123	15
	Random Forest	0.92	127	11
	SVM	0.88	122	16
문장	Decision Tree	0.77	107	31
	Random Forest	0.73	101	37
	SVM	0.58	81	57
	KoBERT (SKTBrain)	0.83	114	24
	KLUE(bert- base)	0.90	125	13

동기 분류 데이터셋2의 검증용 데이터를 기반으로 가장 좋은 정확도를 도출한 모델은 키워드를 입력 값으로 사용한 Random Forest임이 밝혀졌다. 하지만, 데이터 내 라벨

분포가 균등하지 않기 때문에 Random Forest가 검증용 데이터를 기반으로 오차 행렬을 도출하고 Random Forest가 분류한 각 결과들에 대해 살펴본다. Random Forest가 도출한 오차행렬은 아래 그림 45와 같다. 먼저 치정(0)의 경우, 검증용 데이터 총 24건 중에 21건을 올바르게 분류하였으나 3건을 원한(1)으로 분류하였다. 원한(1) 데이터 79건 중 78건을 올바르게 분류하고 1건을 치정으로 분류하였다. 정신(2)의 경우, 총 26건 중에서 22건의 데이터를 정답으로 맞추고 4건을 원한(1)으로 분류하였다. 금품(3) 데이터 9건 중에서는 6건을 올바르게 분류하고 3건을 원한(1)로 분류하였다.




그림 43 동기 분류 데이터셋 2 검증용 데이터를 기반으로 Random Forest 모델이 도출한 오차행렬

표 41 데이터셋 2 내 검증용 데이터 라벨에 따른 모델 별 F1 스코어

라벨	Decision Tree	Random Forest	SVM	KoBERT	KLUE(bert-base)

치정	0.89	0.91	0.94	0.79	0.84
월한	0.90	0.93	0.91	0.86	0.93
정신	0.94	0.92	0.83	0.86	0.94
금품	0.63	0.80	0.67	0.61	0.84

3. 데이터셋 3 내 검증 데이터를 통한 모델 평가 결과

데이터셋 3은 앞서 진행된 데이터 1, 2 모두를 포함하고 추가로 동기 패턴으로 잡히지 않은 사건 323건을 추가하여 총 1,012건으로 이루어진 데이터셋으로서, 데이터셋 중에 가장 크기가 크고 다양한 데이터로 구성되어 있다. 해당 데이터셋은 809건의 학습용 데이터와 203건의 검증용 데이터셋으로 구성되어 있고, 아래 표 43는 각 모델 별 검증용 데이터셋에 대한 정확도와 그 결과이다. 데이터셋 3을 가장 잘 분리하는 모델로는 키워드를 입력값으로 사용한 Random Forest가 뽑혔으며, 정확도 0.95와 해당 모델은 총 203건 중에 192건을 맞추고 11건을 틀린 것으로 나타났다. 가장 낮은 성능을 보여준 모델로는 KoBERT가 도출되었는데, 정확도 0.82와 158건을 맞추고 45을 틀린 것을 알 수 있었다.

표 42 데이터셋 3을 통한 각 모델의 정확도 및 검증 데이터 내 맞춘 개수와 틀린 개수

입력 데이터	모델	정확도	정답 셋과 비교 시	
			맞춘 개수	틀린 개수
키워드	Baseline	0.74	152	51
	Decision Tree	0.90	183	20
	Random Forest	0.95	192	11
	SVM	0.91	185	18
문장	Decision Tree	0.73	149	54
	Random Forest	0.75	154	49
	SVM	0.61	124	79
	KoBERT (SKTBrain)	0.82	158	45

	KLUE(bert-base)	0.87	176	27
--	-----------------	------	-----	----

동기 분류 데이터셋 3의 검증용 데이터를 통해 각 모델이 도출한 정확도 중 가장 높은 성능을 보여준 것은 Random Forest 로 드러났다. 하지만, 전체 검증용 데이터 중 원한으로 분류된 사건이 총 119건으로 전체 데이터 대비 약 58% 정도를 차지하며 (표 35 참고) 검증용 데이터 내 라벨 간 불균형이 있는 것으로 드러났다. 따라서, 가장 높은 정확도를 도출한 Random Forest 의 오차행렬 값을 통해 각 라벨별 분포를 파악한다. 치정(0)의 경우, 전체 24건 중 21건을 맞추고 남은 3건 중 2건을 원한(1)으로, 1건을 금품(3)으로 분류하였다. 원한(1)의 경우, 총 119건 중 117건을 올바르게 분류하였고 1건을 치정(0)으로, 1건을 금품(3)으로 분류하였다. 정신(2)의 경우, 38건 중에서 36건을 올바르게 분류하였고, 남은 2건을 각각 치정(0)과 금품(3)으로 분류하였다. 금품(3)의 경우, 전체 22건 중 18건을 정답으로 분류하고 나머지 4건을 원한(2)으로 분류하였다.




그림 44 동기 분류 데이터셋 3 검증용 데이터를 기반으로 Random Forest 모델이 도출한 오차행렬

표 43 데이터셋 3 내 검증용 데이터 라벨에 따른 모델 별 F1 스코어

라벨	Decision Tree	Random Forest	SVM	KoBERT	KLUE(bert-base)
치정	0.86	0.89	0.93	0.79	0.82
원한	0.94	0.97	0.93	0.86	0.90
정신	0.96	0.97	0.93	0.86	0.93
금품	0.70	0.84	0.72	0.60	0.70

4. 동기 분류 데이터셋을 통한 모델 검증의 소결론

형사 판결문의 범죄사실 내 서술되어 있는 범행 동기를 분류하기 위해, 앞서 정의한 동기 분류의 기준을 기반으로 동기 분류 데이터셋을 구축하였다. 이러한 동기 분류 데이터셋을 학습용과 검증용으로 나눠 머신러닝 모델인 Decision Tree, Random Forest, SVM과 트랜스포머 모델인 KoBERT와 KLUE(bert-base)에 학습시킨 뒤, 검증용 데이터를 기반으로 모델 검증을 진행하였다. 키워드를 입력 값으로 사용한 모델 중에서는 Random Forest의 정확도가 가장 높았다. Random Forest는 데이터가 증가함에 따라 키워드를 기반으로 한 정확도가 올라가는 것을 확인할 수 있었다. 문장을 입력 값으로 사용한 모델 중에는 KLUE(bert-base) 모델의 정확도가 가장 높았다. 특히, 문장을 사용한 모델 중에서는 머신러닝 계열보다 트랜스포머 계열의 모델의 정확도가 더 높았다. 트랜스포머 계열 모델 중 KLUE 모델이 가장 적은 데이터로 구성된 데이터셋 1에서 가장 좋은 성능을 보여주었는데, 이러한 원인은 데이터셋 1을 구성하고 있는 데이터가 동기를 추출하는 패턴으로 가장 잘 분리되는 데이터를 담고 있기 때문인 것으로 보인다. 위 결과를 통해, 동기 분류 데이터셋 내 키워드는 사람이 직접 추출한 데이터로, 사람이 직접 분류하는 것만큼 좋은 성능을 내려면 사전 학습된 트랜스포머 계열의 모델을 사용해야 한다는 것을 알 수 있었다.

각 데이터셋에서 오분류된 데이터를 살펴보았다. 먼저, 데이터셋 1을 통한 모델 검증에서는 KLUE 모델이 높은 성능을 보여주었으나, 대부분의 오답을 원한으로 분류한 것을 알 수 있었다. 이러한 오분류의 원인으로서는 데이터셋 1 내 원한으로 분류된 데이터의 비율이 절반 이상을 차지하기 때문으로 보인다(표 34 참조). 또한 데이터셋 2와 3을 통해 정확도가 높은 모델이 도출한 오차행렬을 통해, 대다수의 모델이 치정과 원한의 분류를 어려워하는 것으로 나타났다. 해당 문제는 입력 값으로 활용된 키워드로 인한 것으로 파악된다. 모든 단어들이 특정 분류에만 적용되는 것은 아니고, 다른 분류에도 중복적으로 사용될 수 있다. 예를 들어 원한에서 가장 많이 도출된 ‘술’에 경우, 다른 분류에서도 ‘술’을 마시던 중 사건이 일어날 수 있다. 하지만, 두 사건 모두 키워드인 ‘술’이 중요하게 사용될

수 있기 때문에 제거하지는 않았기 때문에 중복적으로 사용된 키워드로 인해 모델이 분류하는 데 어려움을 겪은 것으로 파악되었다.

표 44 중복으로 등장하는 키워드 개수

데이터셋 중복 분류 수	1	2	3
2개	29	60	92
3개	7	10	15
4개	1	1	1
총합	37	71	108

제6장 결론

본 연구는 형사 판결문 내 범죄 사실을 기반으로 유사 사건을 도출하기 위한 실험을 진행하였다. 이를 통해, 사람들이 유사 사건을 결정함에 있어서 다양한 요소들이 고려되어야 하지만, 이 중 ‘동기’가 가장 중요한 것으로 보인다. 하지만, 범죄 사실 내 동기는 범행 도구나 피고인과 피해자의 관계와는 달리 여러 줄에 걸쳐 다양하게 서술되기 때문에 단순 키워드 매칭 방식의 검색이나 단어의 임베딩 값을 이용해 유사 사건을 찾는 방식으로는 잡기 어렵다. 따라서, 동기에 더 특화된 유사 사건 도출을 위한, 살인죄에 특화된 동기 분류를 정의하고 해당 분류를 기준으로 동기를 분류한 데이터셋을 구축하여 동기 분류를 잘하는 모델을 찾는 것을 목적으로 두었다.

살인죄에 특화된 동기로는 치정, 원한, 정신, 금품으로 규정하였고, 동기가 서술되는 패턴을 파악하여 범죄 사실 내에서 동기 패턴을 이용해 동기를 서술하는 문장을 추출하였다. 앞서 진행된 선행 실험으로 트랜스포머 계열 모델과 아님 모델을 비교했을 시, 트랜스포머 계열 모델이 무조건적으로 좋은 성능을 도출하는 것은 아니었기에, 동기 문장과 동기 키워드를 분류하는 모델을 머신 러닝 모델 중 Decision Tree, Random Forest, SVM과 트랜스포머 계열인 KoBERT와 KLUE(bert-base) 모델을 비교하였다. 문장을 입력으로 받아들이고 문맥을 이해할 수 있는 트랜스포머 계열과는 달리 머신 러닝 모델의 경우, 문장을 입력으로 받아들일 수 없기에, 동기 문장에서 분류의 성격을 잘 나타내는 키워드를 추출하여 활용하였다.

동기 분류 데이터셋을 데이터셋의 크기에 따라 1,2,3으로 나눠 진행하였고, 데이터셋 1에서 가장 좋은 성능을 보여준 것은 KLUE(bert-base) 모델이었고, 데이터셋 2와 3에서 가장 좋은 성능을 보인 모델은 Random Forest였다. Random Forest가 좋은 성능을 보여준 까닭으로는 Random Forest의 입력 값인 동기 키워드의 경우, 동기 문장에 비해 많은 전처리 과정을 통해 동기 분류의 성격을 띄고 있는 키워드로만 구성되어 있기 때문으로 보인다.

본 연구의 한계로는 살인죄에서의 동기는 크게 2가지로 나눌 수 있다. 1차 원인으로

는 피고인이 피해자에게 범행 전부터 지닌 원한을 의미하고, 2차 원인으로는 피고인이 피해자를 살해하게 된 직접적인 원인이다. 본 연구에서 사용한 동기의 분류 기준 중 정신질환을 제외한 나머지 기준의 경우 동기를 서술하는 패턴을 근거로 동기를 추출하였기 때문에 1차 원인 보다는 2차 원인에 집중하고 있다는 점에서 한계를 지니고 있다. 또한, 본 연구에서는 동기를 중심으로 판결문을 분류하여 동기 분류 데이터셋을 구축하였으나 해당 데이터셋의 크기가 작고, 대부분의 동기 분류가 원한으로 치우쳐져 있다는 점에서 한계를 가지고 있다.

따라서, 추후 연구 과제로는 1) 선행 실험의 결과로 유사 사건 판별에 가장 중요한 요소로 추출된 원인은 동기, 범행 도구, 피고인과 피해자의 관계였으며, 추후에는 범행 도구와 피고인과 피해자의 관계 또한 고려하는 유사 사건 검색 모델을 구축할 예정이다. 2) 단순 살인죄 뿐만 아니라 다양한 죄종을 대상으로 유사 사건을 도출할 수 있도록 고려해야 한다. 앞으로는 단순 단어 임베딩에 중점을 둔 유사 사건 도출이 아닌 판결문의 특징을 고려한 유사 사건 검색 엔진이 개발되어야 할 것이다.

참고 문헌

- [1] 장완규, “리걸테크(Legal Tech) 시대의 도래와 당면과제,” *Leg. Tech*, pp. 229-257, 2021, doi: 10.5771/9783748922834.
- [2] 이종주, “법률산업의 디지털 전환에 따른 동향과 이슈,” *월간 SW 중심사회*, vol. 53, pp. 21-31, 2018.
- [3] “Access to justice,” *Singapore Governemt Court.*, p. 30, 2021, [Online]. Available: <https://www.lawsociety.org.uk/policy-campaigns/campaigns/access-to-justice/#>
- [4] L. K. Yan and C. Wilson, “Developing AI for law enforcement in Singapore and Australia,” *Commun. ACM*, vol. 63, no. 4, pp. 62-62, 2020, doi: 10.1145/3378418.
- [5] L. S. C. of S. Australia, “42nd Annual Report 2019-2020,” no. ecrement, p. 33, 2020.
- [6] 치안정책연구소, “「과학적 범죄수사 고도화 기술 개발」 사업 공고.” https://www.psi.go.kr/police/board/view.do?bbsId=BBSMSTR_000000000161&pageIndex=1&nttId=158644&menuNo=117002000000 (accessed Feb. 07, 2022).
- [7] 박성미, 이유나, 최아리, and 안정민, 사법분야 인공지능 발전을 위한 판결문 데이터 개선방안, vol. 19, no. 3. 2021.
- [8] 홍수정, “ 주목받는 리걸테크 산업,” *법률신문뉴스*, 2021. <https://www.lawtimes.co.kr/Legal-News/Legal-News-View?serial=169586> (accessed Dec. 07, 2022).
- [9] M. J. Kang, I. G. Kang, M. J. Kim, S. H. Cho, K. E. Lee, and M. H. Lee, “Research on Developing a Similarity Measure among Break-in Burglary Crimes and its Applications,” *korean Assoc. Police Sci. Rev.*, vol. 20, no. 6, pp. 57-82, Dec. 2018, doi: 10.24055/kaps.20.6.3.

- [10] Y. K. O, H. Kang, S. Park, Y. Jang, and H. Kim, “딥러닝 알고리즘을 이용한 유사 판례 매칭 데이터셋 구축 방안 연구 A Study on the building Dataset of Similar Case Matching in Legal Domain using Deep Learning Algorithm,” 한글 및 한국어 정보처리 학술대회 논문집, pp. 72-76, 2021.
- [11] C. Xiao *et al.*, “CAIL2019-SCM: A Dataset of Similar Case Matching in Legal Domain,” 2019, [Online]. Available: <http://arxiv.org/abs/1911.08962>
- [12] J. Rabelo, R. Goebel, M.-Y. Kim, Y. Kano, M. Yoshioka, and K. Satoh, “Overview and Discussion of the Competition on Legal Information Extraction/Entailment (COLIEE) 2021,” *Rev. Socionetwork Strateg.*, vol. 16, no. 1, pp. 111-133, 2022, doi: 10.1007/s12626-022-00105-z.
- [13] A. Askari, G. Peikos, G. Pasi, and S. Verberne, “LeiBi@COLIEE 2022: Aggregating Tuned Lexical Models with a Cluster-driven BERT-based Model for Case Law Retrieval,” pp. 1-14, 2022, [Online]. Available: <http://arxiv.org/abs/2205.13351>
- [14] S. K. Nigam and N. Goel, “nigam@COLIEE-22: Legal Case Retrieval and Entailment using Cascading of Lexical and Semantic-based models,” 2022, [Online]. Available: <http://arxiv.org/abs/2204.07853>
- [15] U. of Alberta, “COLIEE-2022,” 2022.
- [16] 남혜현, “‘리걸테크 키우려면 '판례'부터 공개하라,’” 바이라인네트워크, 2020. <https://byline.network/2020/11/6-63/> (accessed Dec. 11, 2022).
- [17] 최선, “판결문 공개제도와 사법부의 책무성,” *헌법학연구*, vol. 28, no. 1, pp. 421-452, 2022.
- [18] 손현수, “미확정 판결서 공개... 어디까지 왔나,” *법률신문*, 2020. <https://m.lawtimes.co.kr/Content/Article?serial=166111> (accessed Feb. 11, 2022).

- [19] 박재범, “[뉴스] 대형 법률정보사이트 ‘로앤비’ 오픈,” 머니투데이.
<https://n.news.naver.com/mnews/article/008/0000048663?sid=101>
- [20] 홍수정, “[주목 이사람] ‘풍부한 법률 정보, 데이터 구축 ... 법조인들의 “구글로,”” 법조단체, 2020.
- [21] 편도욱, “로앤컴퍼니, 국내 최다 판례 보유한 ‘빅케이스’ 서비스 출시,” 로이슈, 2022.
https://ccnews.lawissue.co.kr/view.php?ud=202201250806308391204ead0791_12
- [22] 신종철, “한국인공지능법학회 세미나...로톡, 엘박스, 법틀 등 리걸테크 참여,” 로리더, 2022.
<http://www.lawleader.co.kr/news/articleView.html?idxno=8733> (accessed Feb. 11, 2022).
- [23] 신서경, “로앤컴퍼니, 판례 AI 검색 서비스 ‘빅케이스’ 출시 ... 53 만 건 판례 데이터 제공,” 스타트업투데이, 2022.
- [24] 송애린 and 박영호, “WV-BTM: SNS 단문의 주제 분석을 위한 토픽 모델 정확도 개선 기법,” *디지털콘텐츠학회논문지 J. Digit. Contents Soc.*, vol. 19, no. 1, pp. 51-58, 2018, [Online]. Available:
<http://dx.doi.org/10.9728/dcs.2018.19.1.51>
- [25] U. Naseem, I. Razzak, S. K. Khan, and M. Prasad, “A Comprehensive Survey on Word Representation Models: From Classical to State-of-the-Art Word Representation Language Models,” *ACM Trans. Asian Low-Resource Lang. Inf. Process.*, vol. 20, no. 5, pp. 1-46, 2021, doi: 10.1145/3434237.
- [26] T. Mikolov, K. Chen, G. Corrado, and J. Dean, “Efficient estimation of word representations in vector space,” *1st Int. Conf. Learn. Represent. ICLR 2013 - Work. Track Proc.*, pp. 1-12, 2013.

- [27] J. Pennington, R. Socher, and C. D. Manning, “GloVe: Global Vectors for Word Representation,” *Br. J. Neurosurg.*, vol. 31, no. 6, pp. 682–687, 2017, doi: 10.1080/02688697.2017.1354122.
- [28] T. Mikolov, W. Yih, and G. Zweig, “Linguistic Regularities in Continuous Space Word Representations,” *Proc. of NAACL-HLT 2013*, pp. 746–751, 2013.
- [29] M. E. Peters *et al.*, “Deep contextualized word representations,” *NAACL HLT 2018 - 2018 Conf. North Am. Chapter Assoc. Comput. Linguist. Hum. Lang. Technol. - Proc. Conf.*, vol. 1, pp. 2227–2237, 2018, doi: 10.18653/v1/n18-1202.
- [30] J. Devlin, M. W. Chang, K. Lee, and K. Toutanova, “BERT: Pre-training of deep bidirectional transformers for language understanding,” *NAACL HLT 2019 - 2019 Conf. North Am. Chapter Assoc. Comput. Linguist. Hum. Lang. Technol. - Proc. Conf.*, vol. 1, no. M1m, pp. 4171–4186, 2019.
- [31] A. Vaswani *et al.*, “Attention is all you need,” *Adv. Neural Inf. Process. Syst.*, vol. 2017-Decem, no. Nips, pp. 5999–6009, 2017.
- [32] S. Wehnert, V. Sudhi, S. Dureja, L. Kutty, S. Shahania, and E. W. De Luca, “Legal norm retrieval with variations of the bert model combined with TF-IDF vectorization,” *Proc. 18th Int. Conf. Artif. Intell. Law, ICAIL 2021*, pp. 285–294, 2021, doi: 10.1145/3462757.3466104.
- [33] J. Hyeon, J. Lee, and H. Cho, “Sentiment Analysis of News on Corporation Using KoBERT,” *Korean Account. Rev.*, vol. 47, no. 4, pp. 33–54, 2022, doi: 10.24056/KAR.2022.08.002.
- [34] S. Yoo and O. Jeong, “Korean Contextual Information Extraction System using BERT and Knowledge Graph,” *한국인터넷정보학회*, vol. 21, no. 3, pp. 123–131, 2020.

- [35] SKTBrain, “KoBERT”, [Online]. Available:
<https://github.com/SKTBrain/KoBERT#tokenizer>
- [36] J. Park, “Comparison of Korean Embedding Performance using Pre-trained Model,” *J. Korean Inst. Def. Technol.*, vol. 2, no. 3, pp. 001-004, 2020, doi: 10.52682/jkiddt.2020.2.3.001.
- [37] P. Sunilkumar and A. P. Shaji, “A Survey on Semantic Similarity,” *2019 6th IEEE Int. Conf. Adv. Comput. Commun. Control. ICAC3 2019*, 2019, doi: 10.1109/ICAC347590.2019.9036843.
- [38] G. Sidorov, A. Gelbukh, H. Gómez-Adorno, and D. Pinto, “Soft similarity and soft cosine measure: Similarity of features in vector space model,” *Comput. y Sist.*, vol. 18, no. 3, pp. 491-504, 2014, doi: 10.13053/CyS-18-3-2043.
- [39] R. Rehurek and P. Sojka, “Gensim--python framework for vector space modelling,” *NLP Centre, Fac. Informatics, Masaryk Univ. Brno, Czech Repub.*, vol. 3, no. 2, 2011.
- [40] 이영섭, 오현정, and 김미경, “데이터 마이닝에서 배깅,부스팅,SVM 분류 알고리즘 비교 분석,” *응용통계연구*, vol. 18, no. 2, pp. 343-354, 2005.
- [41] 유진은, “랜덤 포레스트: 의사결정나무의 대안으로서의 데이터 마이닝 기법,” *교육평가연구*, vol. 28, no. 2, pp. 427-448, 2015.
- [42] 박정, “머신러닝을 활용한 서울시 중학생 진로성숙도 예측 요인 탐색,” *한국빅데이터학회지*, vol. 5, no. 2, pp. 155-170, 2020, doi:
<https://doi.org/10.36498/kbigdt.2020.5.2.155>.
- [43] D. S. Siroky, “Navigating random forests and related advances in algorithmic modeling,” *Stat. Surv.*, vol. 3, pp. 147-163, 2009, doi: 10.1214/07-SS033.

- [44] Tin Kam Ho, "Random Decision Forests," *Proc. 3rd Int. Conf. Doc. Anal. Recognit.*, pp. 278-282, 1995, [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/598994/>
- [45] Y. Choi, S. Hyun, and Y. Shin, "SNS (트위터) 를 활용한 재난 및 위기상황 인식에 관한 연구," *한국어정보처리학회 학술대회논문집*, vol. 28, no. 2, pp. 483-486, 2021.
- [46] C. Cortes and V. Vapnik, "Support-vector networks," *Mach. Learn.*, vol. 20, no. 3, pp. 273-297, Sep. 1995, doi: 10.1007/BF00994018.
- [47] 김경재 and 안현철, "재무예측을 위한 Support Vector Machine 의 최적화," *지능정보연구*, vol. 17, no. 4, pp. 241-254, 2011, [Online]. Available: <http://scholar.google.com/scholar?hl=en&btnG=Search&q=intitle:Support+Vector+Machine?+????+??+????#0>
- [48] C. K. Ahn and D. Kim, "Efficient variable selection method using conditional mutual information," *J. Korean Data Inf. Sci. Soc.*, vol. 25, no. 5, pp. 1079-1094, Sep. 2014, doi: 10.7465/jkdi.2014.25.5.1079.
- [49] 양수연, 이채록, 원종관, and 홍태호, "증권신고서의 TF-IDF 텍스트 분석과 기계학습을 이용한 공모주의 상장 이후 주가 등락 예측 *," *J Intell Inf. Syst*, vol. 28, no. 2, pp. 237-262, 2022, doi: <http://dx.doi.org/10.13088/jiis.2022.28.2.237>.
- [50] S. Park *et al.*, "KLUE: Korean Language Understanding Evaluation," May 2021, [Online]. Available: <http://arxiv.org/abs/2105.09680>
- [51] A. Wang, A. Singh, J. Michael, F. Hill, O. Levy, and S. R. Bowman, "GLUE: A Multi-Task Benchmark and Analysis Platform for Natural Language Understanding," *EMNLP 2018 - 2018 EMNLP Work. BlackboxNLP Anal. Interpret. Neural Networks NLP, Proc. 1st Work.*, pp. 353-355, 2018, doi: 10.18653/v1/w18-5446.

- [52] J. Xu, J. Wen, X. Sun, and Q. Su, “A Discourse-Level Named Entity Recognition and Relation Extraction Dataset for Chinese Literature Text,” 2017, [Online]. Available: <http://arxiv.org/abs/1711.07010>
- [53] H. Le *et al.*, “FlauBERT: Unsupervised language model pre-training for French,” *Lr. 2020 - 12th Int. Conf. Lang. Resour. Eval. Conf. Proc.*, pp. 2479-2490, 2020.
- [54] 박호민, 김창현, 노경목, 천민아, and 김재훈, “동적 프로그래밍을 이용한 Ocr 에서의 띄어쓰기 교정,” *제 28 회 한글 및 한국어 정보처리 학술대회 논문집*, pp. 243-245, 2016.
- [55] 박은정 and 조성준, “KoNLPy: 쉽고 간결한 한국어 정보처리 파이썬 패키지(KoNLPy : Korean natural language processing in Python),” *제 26 회 한글 및 한국어 정보처리 학술대회 논문집*, pp. 4-7, 2014.
- [56] L. C. Analysis, “서울지역 살인 혐의 (살인 및 치사) 사건의 범행 수법에 따른 유형화 연구 - SCAS 자료에 대한 잠재계층분석의 적용 -,” pp. 87-112, 2020.
- [57] G.-J. Yu, A.-K. Kim, J.-H. Lee, and J. Jung, “Problems and Improvement of Scientific Crime Analysis System (SCAS) through Analysis of Unnatural Death,” *Korean Acad. Sci. Crim. Investig.*, vol. 13, no. 3, pp. 173-179, 2019, doi: 10.20297/jsci.2019.13.3.173.
- [58] “glounnlp.” <https://github.com/dmlc/gluon-nlp>

자연어처리 기술을 활용한 국내 형사 판결문 검색 모델 비교 연구 - 범행 동기를 중심으로 -

2022.

석사학위논문

최아리

국제학과

지도교수: 장윤식, 김선정

4차 산업 혁명의 도래로 인공지능 기술이 발전하였고, 처리해야 할 데이터가 기하급수적으로 늘었다. 많은 데이터를 단시간에 처리하기 위해 효율적인 검색을 필요로 한다. 이는 대량의 법률 문서를 대상으로 진행되는 리걸테크 분야에서도 필요로 하고 있다. 리걸테크는 법률 분야에 기술을 적용시킨 분야로서 크게 검색, 분석, 작성과 관련된 서비스를 제공하고 있다. 특정 사건을 기준으로 유사한 사건을 검색하는 유사 사건 검색의 경우, 싱가포르나 호주 등 다양한 국가에서 연구되고 있으나 국내에서는 아직 미미한 수준이다. 이러한 판결문 검색에는 텍스트인 판결문 데이터를 기반으로 자연어 처리 (Natural Language Processing) 기술을 통해 텍스트 데이터를 수치화하여 자연어를 컴퓨터가 이해하고 분석할 수 있도록 한다. 현재, 유사 사건 검색의 경우, 민간에서 제공하는 서비스인 엘박스나 빅 케이스 등에서 제공하고 있으나, 해당 검색 엔진의 성능이 사용자가 요구하는 수준을 만족시키기는 어려워 보이며, 국내에서 진행된 다양한 연구에서도 법률 분야에서의 유사 사건의 의미를 명시하고 있지 않다.

본 연구에서는 형사 판결문을 대상으로 다양한 임베딩 모델과 유사도 측정 방안들을 활용하여 유사 사건 도출 실험을 진행하였다. 하지만, 다양한 모델을 이용했음에도 불구하고, 모델마다 도출하는 유사 사건이 다르다는 것을 확인할 수 있었다. 이에, 사람이 직접 개입하여, 기준 사건을 토대로 유사 사건 사이의 순위를 매겨 유사 사건 결과를 평가를 진행

하였다. 하지만, 사람을 통해 유사사건을 평가하였으나, 여러 기준 사건 중 절반이 사람들의 과반수의 동의를 이끌어내지 못하는 것을 확인하였다. 이를 통해, 단순히 임베딩 모델을 기반으로 유사 사건 도출하는 것은 형사 판결문에 적합하지 않다는 것을 파악하였다. 따라서, 사람들이 유사 사건을 평가할 때 작성한 이유를 근거를 통계내 본 결과, 다양한 유사 사건 선별 기준 중 '동기'를 가장 많이 고려한다는 것을 알 수 있었다. 이후에는 유사 사건 도출을 위해 범죄 사실 내 서술된 동기를 기준으로 판결문을 분류하는 것을 목적으로 판결문 분류를 진행하였다. 이후, 해당 동기를 키워드와 문장으로 구성된 데이터셋을 구축하였다. 해당 데이터셋을 기반으로 머신러닝 계열인 Decision Tree, Random Forest, SVM 모델과 트랜스포머 계열인 KoBERT, KLUE/bert 모델을 학습하였다. 그 결과 키워드 기반 데이터셋으로 Random Forest, 문장 기반 데이터셋으로는 KLUE/bert의 성능이 가장 좋았다.

주제어 : 형사 판결문, 자연어 처리, 유사 사건 검색, 판결문 분류

A Comparative Study on Criminal Judgement Search Models Using Natural Language Processing - Focusing on the motive for the crime -

2022.

Master's Degree

Choi, A Ri

Department of International Studies

Advisor Prof. Jang, Yun Sik, Kim, Seung Jung

With the advent of the Fourth Industrial Revolution, artificial intelligence technology has developed, and the data to be processed has increased exponentially. Efficient search is required to process a lot of data in a short time. This is also required in the legal tech field, which targets a large number of legal documents. Legal Tech is a field that applies technology to the legal field and provides services related to search, analysis, and writing. In the case of search for similar cases based on specific cases, it is being studied in various countries such as Singapore and Australia, but it is still insignificant in Korea. In searching for such judgments, text data is digitized through Natural Language Processing technology based on text judgment data, allowing computers to understand and analyze natural languages. Currently, similar case searches are provided by private services such as Lbox and Big Case, but it seems difficult for the performance of the search engine to meet the level required by users, and various studies conducted in Korea do not specify the meaning of similar cases in the legal field.

In this study, a similar case derivation experiment was conducted using various embedding models and similarity measurement methods for criminal judgments.

However, despite using various models, it was confirmed that the similar events derived from each model were different. Accordingly, humans directly intervened, and the results of similar events were evaluated by ranking between similar events based on the reference event. However, similar cases were evaluated through people, but it was confirmed that half of the various reference cases did not obtain the consent of the majority of people. Through this, we found that simply deriving similar cases based on the embedding model is not suitable for criminal rulings. Therefore, as a result of statistical analysis of the reasons people wrote when evaluating similar events, it was found that 'motivation' was considered the most among the various criteria for screening similar events. After that, to derive similar cases, the judgment was classified by the motives described in the crime facts. Thereafter, a dataset consisting of keywords and sentences with the corresponding motive was constructed. Based on the corresponding dataset, we learned the machine learning family Decision Tree, Random Forest, SVM model, and the transformer model, KoBERT and KLUE/bert model. As a result, Random Forest as a keyword-based dataset and KLUE/bert as a sentence-based dataset performed the best.

Keywords: Judgement in a Criminal Case, Natural Language Processing, Similar Case Matching, Judgement Classification

부록

부록 A. 범죄 사실 내 동기 패턴 예시

<마음먹고> - 대구지방법원 김천지원 2016 고합 112 판결

피고인은 위 식당에서 피해자가 가스레인지에 물을 담은 냄비만 올려놓은 채 빨리 라면을 끓이지 않는다는 이유로 화가 나 피해자를 살해할 **마음을 먹고** ...

<결심을 하고> - 서울중앙지방법원 2018 고합 151 판결

만약 피해자가 그날도 돈을 변제하지 않으면 칼로 피해자를 제압하여 위해를 가하기로 **결심을 하고**, ...

<격분하여> - 광주지방법원 2012 고합 1314 판결

피고인은 2012. 11. 15. 14:30 경 광주 서구 C 건물 305 호에 있는 피고인의 집 안방에서, 내연녀인 피해자 D(여, 51 세)와 함께 누워 있던 중 피해자가 다른 남자를 만난다는 이유로 말다툼을 하다가 순간적으로 **격분하여**, ...

<화를 참지 > - 광주지방법원 순천지원 2016 고합 97 판결

피고인은 집으로 돌아온 후에도 그 **화를 참지** 못하고 그곳 마당에 있던 회칼(칼날길이 약 12cm)을 가지고

<화가 나> - 광주지방법원 순천지원 2013 고합 52 판결

이에 피해자가 위 선박 우현 현측에 기대어 보드후크(갈고리가 부착된 장대)를 이용하여 이를 수거하려 하자, 피고인은 순간적으로 **화가 나** 심야시간에 추운 날씨로 인해 피해자가 바다에 빠져 사망할 수도 있을 것이라고 생각하면서도 피해자에게 다가가 뒤에서 피해자의 다리를 들어 올려 바다로 밀어버려 피해자를 바다에 떨어지게 하였다.

<불만/양심을 품고> - 서울서부지방법원 2013 고합 392

피해자가 이에 호응하지 않고 피고인을 피하려 한다는 등의 이유로 **양심을 품고**, 미리 준비하여 간과도(총 길이 20cm, 칼날길이 10cm, 증 제 1 호)로 의자에 앉아 있는 피해자의 뒷머리와 등 오른쪽 어깨 등을 힘껏 찔러 피해자를 살해하려 하였으나,

<패턴이 없는 경우>

1. 정신질환으로 인한 패턴 없음 - 광주지방법원 목포지원 2013 고향 107

피고인은 2013. 9. 17.경 목포시 E, 비(B)동 403 호(F 아파트)에 있는 자신의 집에서, 피해망상, 과대망상, 환청, 환시, 현실 판단력의 장애, 충동조절능력의 저하 등의 정신증세를 보이는 양극성 정동장애, 정신병적 조증 증상이 있는 등 심신장애로 인하여 사물을 변별할 능력이나 의사를 결정할 능력이 미약한 상태로, **함께 거주하는 피고인의 어머니 피해자 G(85 세)이 피고인의 친어머니가 아닌 북한의 스파이라고 생각하고** 주먹과 발, 무릎, 지팡이 등으로 피해자의 얼굴, 턱, 등, 가슴 등 온몸을 수회 때리고 짓밟아 그 자리에서 피해자로 하여금 경부압박에 의한 질식으로 사망에 이르게 하여 자기의 직계존속인 피해자를 살해하였다.

2. 분류가 정신이 아니나 패턴이 없음 - 광주지방법원 순천지원 2019 고향 167

피고인 겸 피부착명령청구자(이하 '피고인'이라고만 한다)는 마을이장과 어촌계장을 겸직하고 있는 피해자 B(남, 61 세)이 약 6 년 전 어촌계 규칙을 이유로 자신을 마을 어촌계원에서 제명시킨 것에 대해 양금이 남아 있었고, 2019. 10. 14. 14:00 경 C 보상을 받으려면 맨손 어업신고서(바지락, 굴, 해초류 채취)를 작성해 제출하라는 피해자의 마을 방송을 듣고 이를 제출하기 위해 어업신고서를 작성하였다. 피고인은 2019. 10. 14. 16:50 경 여수시 D 에 있는 피해자의 집으로 가 그의 집 마당에서 위와 같이 작성한 어업신고서를 **피해자에게 제출하며 어촌계원으로 등록해 줄 것을 요구하였으나 거절당하자**, 미리 상의 안주머니에 넣어 준비한 다용도 칼(증 제 4 호, 손잡이 약 11cm, 칼날 길이 약 13.5cm)을 꺼내 들고 "야! 새끼야, 니 그럴 수가 있어, 죽고 싶어"라고 말하며 피해자의 가슴 부위를 1 회 찌르고, 피해자가 반항하자 계속하여 피해자를 향해 칼을 휘둘러 목 부위와 아랫 입술 부위를 그었다.

<동기가 없는 경우>

1. 이유 없이 - 부산지방법원 동부지법 2019고합56

피고인은 같은 날 23:50경 피고인의 주거지에서, 피해자의 부축을 받아 화장실에서 소변을 보고 나오던 중, 갑자기 아무런 **이유 없이** 주먹으로 피해자의 머리 부위를 수회 때리고, 1) 피해자가 이에 저항을 하자 주방 싱크대 밑에 있던 부엌칼(칼날길이 20cm)을 가지고 와서 피해자의 왼쪽 턱 밑 부위를 힘껏 찔러 피해자를 살해하려고 하였으나, 피고인과 피해자가 다투는 소리를 듣고 찾아 온 K과 J에 의하여 피해자가 병원으로 후송되어 응급 수술을 받는 바람에 피해자에게 치료일수를 알 수 없는 경부 열상 4cm. 깊이 8cm)2)을 가하는데 그침으로써 그 뜻을 이루지 못하고 미수에 그쳤다.

2. 알 수 없는 이유로 - 서울중앙지방법원 2016고합980

피고인은 2016. 9. 7. 13:00경부터 18:00경까지 사이에 피해자의 집에서 **알 수 없는 이유로** 1 그 곳 주방 싱크대 위에 있던 부엌칼(전체길이 30cm, 칼날길이 18cm)로 피해자의 오른쪽 가슴부위를 1회 찔러 피해자를 그 자리에서 흉부자창으로 사망하게 하였다.

3. 불상의 이유로 - 전주지방법원 정읍지원 2020고합22

피고인은 2020. 5. 10. 18:59경 정읍시 B아파트 C호에 있는 피고인의 주거지 거실에서 같은 동네에 거주하는 지인인 피해자 D(남, 69세)과 함께 술을 마시던 중, **불상의 이유로** 화가 나 위 주거지 주방 칼꽂이에 꽂혀 있던 식칼(총 길이 : 32cm. 칼날 길이 : 19.5cm. 증제 1호)을 집어 들고 와 피해자의 우측 쇄골 아래 부위를 1회 찌르고, 다시 목 부위를 1회 그어 피해자를 살해하고자 하였으나 피해자에게 치료일수를 알 수 없는 우측 흉부 열상 및 목의 전면부 열상(길이 : 15cm, 깊이 : 2.5cm)를 가하는 데 그쳐 그 뜻을 이루지 못하고 미수에 그쳤다.

4. 환청이 들리자 - 수원지방법원 평택지원 2014고합86

피고인은 2014. 4. 22. 19:10경 평택시 E에 있는 피고인의 돌아가신 어머니가 농사짓던 텃

밭에서 이웃에 살고 있는 피해자 F(여, 72세)가 밭일을 하고 있는 것을 보고, 피해자를 쳐야 피고인에게 이득이 생긴다는 **환청이 들리자** 피해자의 뒤로 다가가 피해자가 밭일을 하기 위해 바닥에 놓아 둔 피해자 소유의 망치(길이 약 30cm)를 손에 집어 드 후 피해자의 머리를 향해 수회 내리쳐 피해자를 살해하려고 하였으나, 피해자가 소리를 지르며 도망가는 바람에 피해자에게 약 6주간의 치료를 요하는 외상성 경막 하혈증 두개 함몰 골절 등의 상해를 가한 채 그 뜻을 이루지 못하고 미수에 그쳤다.

5. 충동을 억제하지 못하고 - 대구지방법원 2012고합1472

이에 피고인은 만성형 외상후 스트레스 장애로 인하여 의사를 결정할 능력이 미약한 상태에서 **충동을 억제하지 못하고**, 피해자를 죽이고 자신도 따라 죽으면 F이 E와 잘 살게 될 것이라는 생각을 한 나머지 한 손으로 피해자의 코와 입을 막고 다른 한 쪽 손으로는 피해자의 목 부위를 눌러, 그 자리에서 피해자를 경부압박에 의한 질식으로 사망하게 하여 피해자를 살해하였다.

6. 갑자기 - 대전지방법원 홍성지원 2015고합53

피고인은 2015. 6. 13. 04:16경 보령시 C에 있는 D초등학교 정문 앞 도로에서 개인택시 콜센터에 전화하여 부른 피해자 E(56세)이 운행하는 F 택시의 조수석에 승차하여 같은 날 04:22경 위 택시가 보령시 G에 있는 보령시 H 작업장 전방 300m 앞 농로에 이르렀을 무렵 **갑자기** 오른손으로 바지 뒷주머니에서 회칼(총길이 29cm, 칼날길이 20cm)을 꺼내어 회칼의 칼날 부분으로 운전 중이던 피해자의 오른손목 부위를 3회 내리치며 피해자에게 \"내가 오늘 살인을 저지르려고 한다. 내 얼굴을 잘 기억하고 있으라, 내일 신문에 나올 것이다.\" 라고 말한 다음 위 회칼로 피해자의 오른쪽 옆구리 부위를 칼날이 오른쪽 횡경막과 간에 들어갈 정도로 힘껏 찌르고, 칼에 찔린 피해자가 택시에서 하차하여 도망가려고 하자 택시에서 내려 피해자에게 달려들어 위 회칼로 재차 찔러 살해하려고 하였으나, 피해자가 격렬히 저항하며 피고인을 땅에 넘어뜨리고, 그 과정에서 땅에 떨어진 위 회칼을 인근 논으로 집어 던진 다음 위 택시를 타고 도망가는 바람에 그 뜻을 이루지 못하고 미수에 그쳤다.

부록 B. 정신으로 분류되는 판결문의 동기 추출 방식

[광주지방법원 2019 고합 312]

① 범죄사실

② 피고인 겸 피부작명령청구자(이하 '피고인'이라 한다)는 B 경 C 와의 사이에서 피해자 D 출산하고 광주 광산구에 있는 피고인의 집에서 피해자, C 와 함께 거주하던 중 2019. 4. 29. 경 C 의 호적에 피해자 D 를 등재하고 나서 C, 피해자와 함께 C 의 주거인 광주 서구 E 아파트로 이동하여 함께 거주하게 되었다.

③ 피고인은 2019. 7. 16.경 위 E 아파트에서 C 와 말다툼을 하던 중 화가 나 피고인 이전에 살던 광산구 집으로 가버렸고, C 도 화가 나 자신의 주거지 현관 번호 키 비밀번호를 피고인이 모르는 번호로 바꾸어버렸다.

④ 다음날인 2019. 7. 17.경 광주 광산구청에서 피고인에게 피해자의 양육수당 지급 문제로 방문하라고 하자 피고인은 피해자, C 를 만나 함께 광산구청에 방문하였다가 C 의 집으로 귀가하였고, 같은 날 밤 무렵 피고인, C, 피해자와 함께 피고인이 평소 알고 지내던 언니의 식당에 방문하였다가 2019. 7. 18. 03:43 경 재차 C 의 집으로 귀가하였다.

⑤ 피고인은 2019. 7. 18. 04:26 경 위 C 의 주거지에서 피해자와 함께 작은 방에서 잠을 자려던 중 피해자가 모기에 물리는 등 몸에 붉은 발진이 생겨 잠을 자지 않고 보채고 청얼거리자 119 에 신고를 하게 되었다.

⑥ 피고인은 피해자를 데리고 집 밖으로 나와 5 층에서 119 구급대원을 만나 함께 로비층으로 이동하여 대화를 하던 중 평소 C 가 병원에 가는 것을 싫어하던 것이 생각 나 119 구급대원에게 병원에 가지 않겠다고 말을 한 후 피해자와 함께 주거지가 있는 5 층으로 올라왔다.

⑦ 피고인은 피해자를 안고 있는 상태에서 집에 들어가기 위하여 현관문 번호 키에 평소 알고 있던 비밀번호를 눌렀으나 C가 비밀번호를 바꾸어버려 문이 열리지 않았고, 피고인이 문을 발로 차고, 손으로 두드리고, 초인종을 수회 눌렀음에도 청각장애가 있던 C는 그 소리를 듣지 못하고 문을 열어주지 않아 집에 들어가지 못하게 되었다.

⑧ 이에 피고인은 집에 인터폰을 하기 위하여 피해자를 안은 상태에서 엘리베이터를 타고 내려가 경비실에 가서 인터폰을 해보았지만 C가 받지 않자 재차 피해자를 안고 엘리베이터를 탄 후 5층으로 올라가 문을 두드리고 초인종을 눌렀으나 여전히 C는 문을 열어주지 않았고, 재차 피해자를 안고 엘리베이터를 타고 내려갔다 올라와 문을 두드리는 행위를 3회 가량 반복하였음에도 C가 현관문을 열어주지 않았고, 모기에 피고인과 피해자 몸이 물리고, 피해자는 울고 칭얼거리려 힘이 들자 피해자를 창문 밖으로 던져 **살해할 것을 마음먹었다.**

⑨ 이에 피고인은 **중등도의 지적장애 등으로 인하여 사물을 변별할 능력이나 의사를 결정할 능력이 미약한 상태에서** 2019. 7. 18. 05:57 경부터 06:00 경 사이 위 E아파트 5층 복도에서 피고인이 안고 있던 피해자를 바닥에 내려놓고 닫혀있던 창문을 연 후 피해자를 두 손으로 잡고 창문 밖으로 힘껏 던져 피해자가 5층에서 1층 바닥으로 떨어지게 하여 피해자로 하여금 추락에 의한 다발성 손상으로 사망에 이르게 하였다.

⑩ 이로써 피고인은 피해자를 살해하였다.

국제학석사학위논문	
자연어처리 기술을 활용한 국내 형사 판결문 검색 모델 비교 연구	
2022	
12	
최아리	

국제학석사학위논문	
A Comparative Study on Criminal Judgement Search Models Using Natural Language Processing	
2022	
12	
최아리	