



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](#)

공 학 박 사 학 위 논 문

기계학습의 산업안전 적용에 관한 연구

A Study on Application of Machine Learning for
Occupational Safety

울 산 대 학 교 일 반 대 학 원
안 전 보 건 전 문 학 과
최 승 주

기계학습의 산업안전 적용에 관한 연구

지도교수 정 기 효

이 논문을 공학박사학위 논문으로 제출함

2021년 8월

울 산 대 학 교 일 반 대 학 원
안 전 보 건 전 문 학 과
최 승 주

최승주의 공학박사학위 논문을 인준함

심사위원 박창권



심사위원 이수동



심사위원 황규선



심사위원 신성우



심사위원 정기효



울산대학교대학원

2021년 8월

국문 요약

기계학습의 산업안전 적용에 관한 연구

울산대학교 일반대학원
안전보건전문학과
최 승 주

1960년 5% 대에 이르던 산업재해율은 2020년 0.57%까지 감소하였으나, 2020년도 산업재해로 인해 882명의 노동자가 목숨을 잃었다. 이에 따라 정부는 국민생명 지키기 3대 프로젝트, 산업안전보건법 전면개정, 중대재해처벌법 제정 등 산재 사망 사고를 감소시키고 산업안전을 향상시키기 위한 다양한 정책을 추진하고 있다. 산업안전의 강화를 위해서는 고용노동부, 한국산업안전보건공단, 민간 재해예방기관, 사업주, 노동자가 각자의 역할을 하는 것이 중요하다. 정부는 산업안전 정책 중 가장 강력한 수단인 감독과 안전점검을 사업장별 위험성 분석을 통해 효율적으로 집행하고, 사업장은 잠재된 유해·위험요인을 파악하고 위험성을 추정·결정하는 위험성평가를 실시하여야 한다.

기계학습은 많은 데이터를 분석하여 특징을 찾아낼 수 있어 미래를 예측할 수 있다는 장점을 가지고 있다. 기계학습이 최근 다양한 분야에서 성공적인 결과를 보이면서 산업 전반에 걸쳐 효율성을 높이기 위해 그 활용이 확대되고 있다. 따라서 본 연구는 정부의 산업안전 정책의 효율성 및 사업장의 안전관리 수준을 높이고자 산업안전 분야에 예측 모델 및 물체 탐지 모델의 기계학습 적용 방안을 제시하였다. 기계학습의 예측 모델은 산재통계 외의 사전적 정보 등 다양한 자료를 수집함으로써 사고사망 발생 등의 사업장의 위험성을 더욱 정확하게 예측할 수 있다. 또한 딥러닝을 통한 물체 탐지 모델은 이미지나 영상으로부터 불안정한 행동 등을 실시간으로 파악하는데 큰 도움을 줄 수 있다.

기계학습의 물체 탐지와 예측 모델을 실제 문제에 적용하여 성능을 검증함으로써 현장 적용에 대한 가능성을 확인하였다. 이동식사다리는 산업 현장에서 널리 활용되는 만큼 사망사고가 가장 많이 발생하는 기인물이다. 이동식사다리에 대한 산재통계 분석결과, 매년 약 30명의 사망사고가 발생하는데 소규모 건설현장에서 가장 많이 발생하는 것으로 나타났다. 이동식사다리 사용이 많은 건설공사의 초기와 종료 시점에 사망사고가 집중되고 있다. 이동식사다리에서의 사망사고는 떨어짐에 의해 머리가 손상되어 발생하고 있다. 이에 따라 이동식사다리의 작업자는 안전모를 착용하도록 관리해야 한다. 이에 따라 기계학습을 적용하여 이동식사다리 작업 시

안전모 착용을 탐지하는 모델을 개발하였다. 이동식사다리와 안전모의 착용 여부에 대하여 CCTV를 이용한 실시간 탐지를 위해 속도가 빠른 YOLO 알고리즘을 적용하였다. 모델의 성능은 F1-score 0.795, mAP 0.843으로 나타났으며, 동영상에 대한 탐지 속도가 25 FPS 이상으로 나타나, 기계학습을 이용한 이동식사다리, 안전모 착용 탐지 모델이 CCTV에서 충분히 적용할 수 있음을 확인하였다.

건설 현장의 사망사고 위험도를 예측하기 위해 공사기간, 지상층수 등 공사 사전정보를 활용하여 기계학습 모델을 구축하였다. SVM, Random Forest, XGBoost, LightGBM, AutoML 등의 알고리즘을 적용하여 성능을 비교 평가하였다. 자료의 불균형 문제를 처리하기 위해 SMOTE, ADASYN의 과대표본화 기법을 적용한 결과 모든 알고리즘에서 F1-score가 0.88 이상으로 나타났다. SMOTE를 적용한 알고리즘보다 ADASYN을 적용한 경우의 F1-score가 평균 0.011 높았다. 사용한 모든 알고리즘이 크게 차이가 나지는 않았으나 특히 ADASYN을 적용한 LightGBM이 F1-score, ROC-AUC가 각각 0.941로 가장 높은 예측 성능을 나타냈다. 공사 사전정보 중 사망사고에 가장 영향을 미치는 요인은 Random Forest, LightGBM 모두 지상층수로 나타났다. 공사기간, 굴착깊이, 최고높이도 두 알고리즘에서 공통적인 중요 요인으로 나타났다.

본 연구는 산업안전 분야에 기계학습의 적용을 위한 방향을 제시하고 실증을 위한 기계학습 모델을 구축하였다는 점에서 의의가 있다. 기계학습의 산업안전 적용 방향은 필요성과 활용성을 고려할 때, 물체 탐지를 이용한 불안정한 상태 모니터링 및 데이터를 이용한 사업장의 위험성 예측이 적합하다. 이에 따라 이동식사다리 작업에서 안전모 착용 여부의 실시간 탐지 모델 및 공사 사전정보를 활용한 사고위험도 예측 모델을 기계학습을 이용하여 구축하였다. 이러한 방법을 더욱 발전시켜 나간다면 보다 효율적이고 효과적인 산업안전관리를 가능케 하여 산업재해를 감소시키는 데 기여할 것으로 기대된다.

Key word : 산업안전, 기계학습, 딥러닝, 물체 탐지, 예측 모델

목 차

국문요약	i
표 목차	v
그림 목차	vi
1. 서론	
1.1 연구배경 및 목적	1
1.2 연구의 내용 및 방법	4
1.3 연구 의의	5
2. 이론적 고찰 및 선행연구	
2.1 기계학습	6
2.2 기계학습 절차	7
2.3 기계학습 알고리즘	9
2.3.1 Support Vector Machine(SVM)	10
2.3.2 Random Forest	12
2.3.3 XGBoost	13
2.3.4 LightGBM	15
2.3.5 AutoML	17
2.3.6 Convolutional Neural Network	18
2.3.7 물체 탐지	21
2.4 성능평가	23
2.4.1 회귀 모델의 성능평가	23
2.4.2 분류 모델의 성능평가	24
2.4.3 물체 탐지 모델의 성능평가	26
2.4.4 성능평가 방법	27
2.5 과대표본화	28
3. 산업안전 분야의 기계학습 적용 방안	
3.1 산업안전 관리 방법	31
3.2 기계학습 적용 사례 및 선행연구	33
3.3 기계학습 적용 방향	36
4. 이동식사다리 사고예방을 위한 물체 탐지 모델	
4.1 배경	39
4.2 연구방법	40
4.2.1 재해통계 분석	40

4.2.2 기계학습을 이용한 이동식사다리 및 안전모 탐지	40
4.2.3 데이터셋(Dataset)	41
4.3 연구결과	43
4.3.1 이동식사다리 관련 사망재해 분석	43
4.3.2 기계학습을 활용한 이동식사다리 및 안전모 착용 탐지	47
4.4 소결	51
5. 건설현장의 사망사고 위험도 예측 모델	
5.1 배경	52
5.2 연구방법	52
5.2.1 데이터 수집 및 전처리	53
5.2.2 기계학습 모델 개발	57
5.3 연구결과	57
5.3.1 예측 모델의 성능 비교	57
5.3.2 공사사전정보의 중요도 분석	60
5.4 소결	61
6. 결론 및 향후 연구방향	
6.1 결론	63
6.2 향후 연구방향	64
참고문헌	66
Abstract	76

표 목차

<표 1-1> 고용노동부 감독대상 (근로감독관 집무규정 제10조)	2
<표 2-1> 분류에 사용되는 알고리즘 비교	8
<표 2-2> 혼동 행렬	24
<표 4-1> 업종별 사망재해 현황	44
<표 4-2> 건설업 공사금액별 사망재해 현황	44
<표 4-3> 사업장 규모별 사망재해 현황	45
<표 4-4> 공정률별, 공사금액별 사망재해 현황	46
<표 4-5> 학습용 데이터셋에 대한 모델의 성능평가	47
<표 4-6> 평가용 데이터셋에 대한 모델의 성능평가	49
<표 4-7> 영상에 대한 물체 탐지 속도	50
<표 5-1> 입력 데이터의 설명 및 형태	54
<표 5-2> 과대표본화 사용여부 및 알고리즘 별 F1-score	58
<표 5-3> 구축된 AutoML 모델 결과 예시	59
<표 5-4> ADASYN을 적용한 2개 알고리즘의 특성 중요도	61

그림 목차

[그림 1-1] 연도별 산재 사고사망 현황	1
[그림 1-2] 연구수행 과정	5
[그림 2-1] 인공지능과 기계학습의 관계	6
[그림 2-2] 기계학습 절차	7
[그림 2-3] 기계학습 알고리즘의 종류	10
[그림 2-4] 선형 SVM 개념	11
[그림 2-5] 비선형 SVM 개념	11
[그림 2-6] 의사결정나무	12
[그림 2-7] Random Forest 절차	13
[그림 2-8] AdaBoost의 학습방법	14
[그림 2-9] 편향-분산 트레이드오프 예시	15
[그림 2-10] 균형 트리분할 및 리프중심 트리분할	16
[그림 2-11] AutoML의 적용 범위	17
[그림 2-12] 완전연결층을 적용한 인공신경망	19
[그림 2-13] 합성곱 신경망의 기본 구조	19
[그림 2-14] 합성곱 및 최대 풀링의 예시	20
[그림 2-15] CNN 적용을 통한 특징 추출 예시	21
[그림 2-16] 물체 탐지의 종류	21


[그림 2-17] R-CNN의 구조	22
[그림 2-18] YOLO 모델 구조	23
[그림 2-19] ROC 그래프 예시	25
[그림 2-20] 실제 이미지와 분류 결과.....	26
[그림 2-21] IoU 계산 방법.....	27
[그림 2-22] 학습, 평가를 위한 데이터셋의 분리	28
[그림 2-23] k-겹 교차검증 예시.....	28
[그림 2-24] SMOTE의 표본 생성 방법	29
[그림 2-25] 과대표본화 기법의 차이 예시	30
[그림 3-1] 위험성평가 절차	32
[그림 3-2] 기계학습 적용 사례	34
[그림 3-3] 물체 탐지를 이용한 안전 및 규제준수 관리 프레임워크	37
[그림 4-1] YOLO 모델의 물체 탐지 예시	41
[그림 4-2] 데이터셋의 예시	42
[그림 4-3] 연도별 이동식 사다리 사망재해	43
[그림 4-4] 상병별 사망재해 현황	47
[그림 4-5] 탐지 성공 예시	48
[그림 4-6] 탐지 실패 예시	49
[그림 4-7] 영상에 대한 탐지 예시	50
[그림 5-1] 사망사고 발생별 데이터 분포	55

[그림 5-2] ADASYN을 적용한 알고리즘별 ROC 곡선 60

1. 서론

1.1 연구배경 및 목적

산업재해보상보험이 시작된 1964년 이래, 1960년 5% 대에 이르렀던 산업재해율은 지속적인 노력으로 2020년 0.57%까지 감소하였다 그러나 산업재해로 인한 경제적 손실 추정액은 최근 5년간 증가추세로 2019년 27조를 넘어섰으며, 산업재해로 인한 사망자수는 2천명에 이른다. 특히, [그림 1-1]과 같이 사업장에서 산재 사고로 인하여 목숨을 잃는 노동자가 2020년 882명이 발생하여, 노동자 만 명당 사고사망자수는 0.46‰로 일본, 독일 등 선진국의 2~3배 수준에 달하고 있다(고용노동부, 2021).



[그림 1-1] 연도별 산재 사고사망 현황

대형 사고로 인해 안전에 대한 국민의 관심이 높아지고 최근 산업 현장뿐만 아니라 공공기관에서도 지속적으로 발생하는 사망사고로 인하여 산업안전에 대한 우려가 커짐에 따라, 2018년 정부는 ‘국민생명 지키기 3대 프로젝트’를 추진하여 교통, 자살과 함께 산업재해 분야에서 사망자를 2022년까지 절반으로 줄이는 것을 국정목표로 설정하였다. 또한, 1981년에 제정된 「산업안전보건법」을 38년 만에 전면 개정하였으며, 2021년 1월 「중대재해 처벌 등에 관한 법률」을 제정하였다.

산업안전보건법이 제정될 당시, 우리나라는 경공업에서 중화학공업으로 산업의 구조조정이 진행되던 시기였으며, 고용구조도 종신고용이 일반적이었다. 그러나 현재는 반도체산업, IT 산업, 서비스업 등이 주력 산업이 되었으며, 아웃소싱(Out

sourcing)이 전 산업으로 확대되었다. 또한, 비정규직 노동자 및 노동자이면서 사업주인 특수고용형태종사자가 증가하였을 뿐만 아니라, 온라인 플랫폼을 매개로 하는 깃(Gig) 노동이 새로운 고용형태로 대두되었다. 개정 산업안전보건법은 이러한 문제점을 극복하기 위해 법의 적용대상을 ‘노무를 제공하는 자’로 확대하고 발주자, 도급인 등의 산업안전보건에 대한 책임을 강화하였다. 아울러 2000년 초반, 시민단체를 중심으로 기업의 사회적 책임 강화를 위해 해외 사례를 참고하여 ‘기업살인법’의 제정이 제기되어왔다. 이후 대형 인명사고로 이어진 사회적 재난이 일어날 때마다 여러 차례 있었던 입법발의는 국회를 통과하지 못하였다. 그러나 최근 안전에 대한 국민적 관심이 크게 높아지고 국민동의청원에 10만 명이 넘게 참여하면서 2021년에 이르러 중대재해처벌법이 제정되었다. 중대재해처벌법의 제정은 그간 산업안전보건법 위반에 대한 벌칙의 강화에도 불구하고 처벌이 낮았던 현실을 반영한 결과이다. 이처럼 산업안전을 둘러싼 국민적 요구와 기준은 더욱 엄격해지고 있다.

정부의 산재예방 대책은 위험기계·기구의 안전인증·검사, 화학공장에 대한 공정안전보고서, 위험 업종 및 건설현장에 대한 유해위험방지계획서 등의 법적 근거에 기반을 둔 인·허가와 고위험 사업장에 대한 감독, 안전점검, 재정지원 등의 기술지원으로 이루어져 있다. 기술지도 관련 업무는 고위험 사업장에 고용노동부 감독관 등 안전보건 관계자가 방문하여, 법적 위반사항에 대한 행정 조치 또는 위험요인에 대한 기술적 지원을 하여 개선토록 하고 있다. 이러한 업무에서 중요한 것은 고위험 사업장을 선별하고 적절한 안전조치를 하도록 하는 것이다.

<표 1-1> 고용노동부 감독대상 (근로감독관 집무규정 제10조)

구분	대상사업장
정기 감독	<ul style="list-style-type: none"> - 중대재해 또는 중대산업사고가 발생한 사업장 - 최근 1년간 사고성 휴업재해가 2명 이상 발생한 사업장(건설현장은 제외)으로서 재해율이 전년도 동종업종 규모별 평균 재해율을 초과하는 사업장 - 최근 1년간 직업병에 걸린 자가 있는 사업장 - 최근 1년간 산업재해 발생 사실을 은폐하여 처벌을 받은 사업장 - 공정안전보고서 이행상태 평가등급이 낮은 사업장 - 그 밖에 장관이 산업재해 발생 위험이 높다고 판단하여 정하는 사업장
기획 감독	<ul style="list-style-type: none"> - 산업재해가 다수 발생하는 유해·위험요인이 있거나 산업재해가 다수 발생하는 유해·위험작업을 하고 있는 사업장 - 특정 취약 시기에 산업재해 발생 우려가 높은 사업장 - 산업재해 발생 취약 업종에 해당하는 사업장 - 작업환경 또는 안전보건관리상태가 불량하여 산업재해 발생 우려가 높은 사업장 - 대형사고 발생 등으로 사회적 물의를 일으키거나 그 밖에 산업재해예방을 위하여 필요하다고 판단한 사업장
특별 감독	<ul style="list-style-type: none"> - 안전·보건관리가 매우 불량하거나, 대형사고 발생 또는 중대재해 다발 등으로 사회적 물의를 일으켰거나 일으킬 우려가 있어 필요하다고 판단한 사업장

고용노동부의 사업장 감독은 <표 1-1>의 근로감독관 직무규정 제10조에 따라 정기감독, 기획감독, 특별감독으로 이루어져 있다. 정기감독은 중대재해가 발생한 사업장에 대하여 감독계획을 수립하여 실시하고 있으며, 기획감독은 산업재해가 발생한 업종, 작업을 대상으로 하고 있다. 특별감독 역시 대형사고 발생, 중대재해 등으로 사회적 물의를 일으킨 사업장에 대하여 실시한다. 이와 같이 사업장 감독은 산업재해 발생 이후에 하고 있어, 산업재해를 예방하는 측면보다는 처벌 및 재발방지에 중점을 두고 있다. 이러한 점을 보완하기 위해 최근에 산업재해의 사전 예방을 위한 기획감독을 강화하고, 한국산업안전보건공단의 안점점검과 연계하는 등의 노력을 하고 있으나, 여전히 산업재해 통계를 분석하여 실시하는 감독 및 점검의 대상을 선정하는 것은 효율성이 다소 부족하다.

최근 산업계 전체에서 효율성을 높이는 수단으로 빅데이터와 인공지능을 활용한 분석이 사용되고 있다. 빅데이터란 데이터의 규모(Volume), 형태(Variety), 속도(Velocity) 등이 방대하여 기존의 방법으로 처리할 수 없는 정도의 데이터를 말한다. 그간 기술의 발달로 디지털화된 데이터가 축적되었고, 컴퓨터 성능 증가에 따라 이러한 데이터를 기존의 방법과는 다른 방식으로 분석이 가능하게 되었다. 인공지능은 사람의 지능을 컴퓨터로 구현하기 위한 기술이다. 인공지능에 대한 개념은 1950년대부터 시작되었으나, 기술이 낮은 수준에 머물러 있으면서 현실적 응용에 요구되는 수준에 미치지 못하였기 때문에 최근까지 주목할 만한 변화를 일으키지 못하였다. 그러나 최근 인공지능 기술이 놀라운 속도로 발전하면서 현실적으로 적용하지 못했던 분야에서 성공적인 결과를 보이면서 기대를 높이고 있다. 전통적으로 인공지능 방법론은 크게 두 가지로 분류된다. 첫째는 지식에 기반하는 방법이고, 둘째는 데이터에 기반하는 방법이다. 지식기반 인공지능은 사람이 가진 지식을 컴퓨터로 표현하고 이를 활용해 현상의 분석, 문제해결에 사용된다. 반면, 데이터 기반 인공지능은 지식을 직접 제공하기 보다는 데이터를 제공하고 컴퓨터가 필요한 정보를 스스로 학습하게 한다. 데이터에서 정보를 효과적으로 추출하고 추상화할 수 있도록 학습을 시키는 것인데, 이러한 분야를 기계학습이라 한다. 기계학습은 학습데이터가 많을수록 좋은 성능을 얻을 수 있는 장점이 있는데, 최근 빅데이터와 연계하여 분석을 함으로써 산업에 시너지(Synergy) 효과를 일으키고 있다. 최근에 기계학습 분야에서 각광을 받고 있는 딥러닝(Deep learning)은 데이터 분석 및 예측, 이미지 인식, 음성인식, 자연어처리 등 다양한 분야의 기술 수준을 크게 향상시켰다.

이러한 기술들에 힘입어 사고 예측 등에 기계학습을 활용하려는 연구가 추진되고 있는데, 특히 교통사고 분야에서 가장 많이 적용되고 있으며(Yannis et al., 2010; Nishimoto et al., 2017), 산업안전 분야에도 최근 적용이 되고 있으나(Tixier et al., 2016; Sarkar et al., 2019) 관련 분야에 대한 데이터의 부족과 인공지능 기술에 대한 잠재력의 이해 부족으로 아직 활용도는 낮은 편이다.

급격한 산업화와 기술발전은 작업환경의 복잡성을 증대시켰으며, 이에 따라 사망사고와 같은 산업재해의 원인도 복합적으로 발생하고 있다. 이러한 산업재해를 감소시키기 위해서는 사업장 안전관리를 강화하는 것이 필요하다. 이에 따라 산업안

전보건법, 중대재해처벌법 등 안전기준은 지속적으로 강화되고 있으며, 정부의 산재 예방정책 수립, 집행 및 현장 안전관리자 등의 노력의 중요성이 더욱 커지고 있다. 그러나 전체 사업장수, 근로자수 등에 비해 안전관리 인력은 부족하며, 여전히 사업장에서는 안전이 최우선 순위가 아닌 것이 현실이다. 특히 산업재해의 다수를 차지하는 소규모 사업장의 경우 위험성평가 등을 통한 자율적 안전관리에 대해서는 취약할 수밖에 없다. 이에 따라 사업장의 안전관리 수준 향상을 위해, 보다 효율적인 산재예방 대책이 필요하다.

따라서 본 연구는 기존의 샘플링 데이터에 대한 통계적 분석에서 찾아내기 어려웠던 새로운 통찰을 찾아낼 수 있는 기계학습을 통해, 한정된 자원을 활용하여 효율적, 효과적인 안전관리를 위해 산업안전 분야에 적용할 수 있는 방안을 제시하고자 한다.

1.2 연구의 내용 및 방법

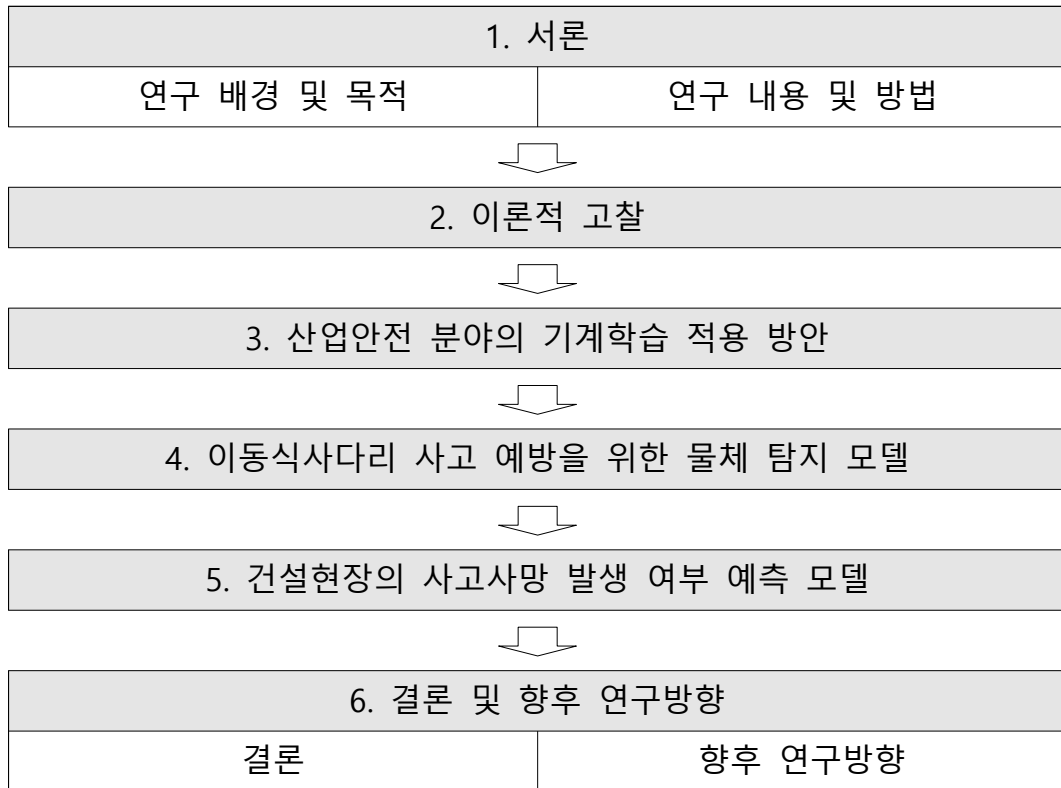
본 연구는 산업현장에서 발생하는 사망사고 등 산업재해를 줄이기 위해서 기계학습에 기반한 산업안전관리 방안을 개발하는 것을 목적으로 하고 있다.

첫째, 기계학습에 대한 이론적 배경과 기계학습을 적용한 선행 연구 등 문헌을 고찰하고 분석하였다.

둘째, 기계학습의 산업안전 분야 적용을 위해 현재 우리나라의 산업안전 관리 방향을 검토하였다. 그리고 기계학습의 적용 사례 및 선행연구를 분석을 통해 산업안전 관리의 향상을 위한 기계학습 기술의 적용 방안을 제안하였다.

셋째, 기계학습의 적용 방안에 따른 실증 결과를 제시함으로써 적용 가능성을 분석하였다. 기계학습의 대표적인 분야 중 비정형 데이터인 이미지 및 영상을 활용한 물체 탐지 모델과 정형 데이터인 사업장 정보를 사용하여 사고사망 발생 예측모델을 구축하였다.

본 연구를 수행하기 위한 구성 도표는 [그림 1-2]와 같다. 본 연구는 크게 6장으로, 제1장은 연구의 배경 및 목적, 연구내용 등에 대한 서론, 제2장은 이론적 배경 및 선행연구를 고찰하였다. 제3장은 산업안전 분야의 기계학습 적용 방안을 제안하였다. 제4장은 산업안전에 활용할 수 있는 물체 탐지 모델 개발, 제5장은 건설현장의 사전정보를 활용한 사망재해 예측모델 개발로 기계학습의 산업안전 분야에 실증한 결과를 제시하였다. 마지막으로 제6장은 결론으로 연구 결과와 연구의 한계점 및 향후 연구 방향을 제시하였다.



[그림 1-2] 연구수행 과정

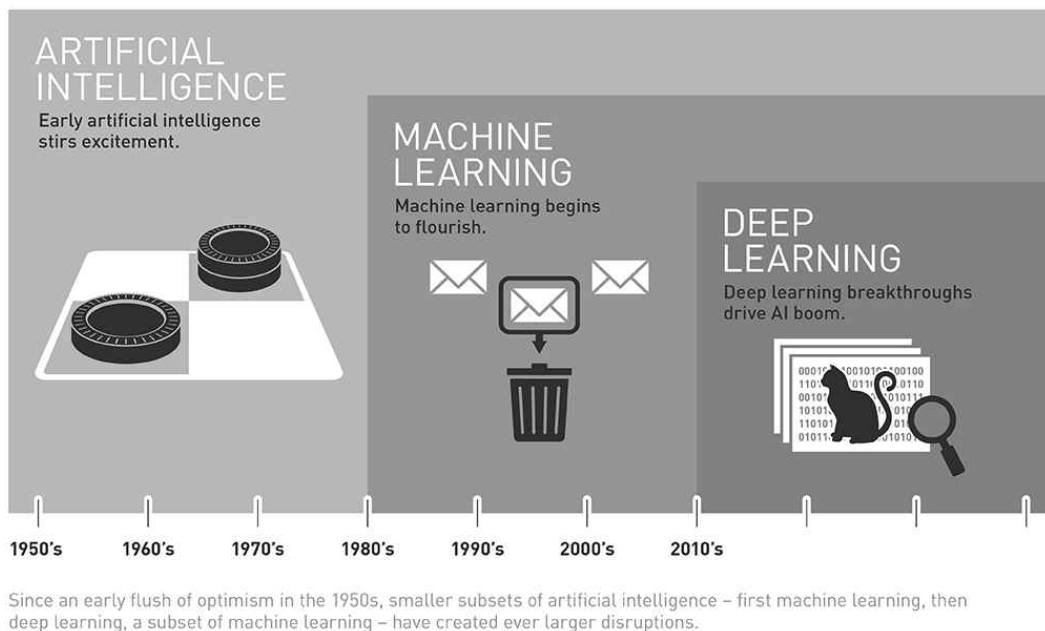
1.3 연구 의의

본 연구는 학술적, 실무적, 그리고 정책적 측면에 의의가 있다. 첫째, 본 연구는 기계학습의 산업안전 분야 적용을 위해 우리나라의 산업안전 관리 방향과 기계학습 적용 사례 및 선행연구 등을 검토하여 산업안전 분야에 기계학습 적용 방안을 제시하였다. 둘째, 본 연구에서 제시한 적용 방안에 따라 기계학습의 이미지 인식, 분류 예측을 사용하여 산업안전 관리를 위한 실증을 통해 적용 가능성을 모색한 측면에서 실무적 의의가 있다. 마지막으로, 본 연구는 사업장의 안전관리를 위해 사업장에서 위험 상황을 실시간으로 파악하고, 사고사망 발생 여부를 예측함으로써 산재예방 정책 수립 및 안전투자를 위한 기초자료로 활용될 수 있다는 측면에서 정책적 의의가 있다고 사료된다.

2. 이론적 고찰

2.1 기계학습

기계학습은 [그림 2-1]과 같이 인공지능의 한 분야로, 인공지능이 인간의 지능을 기계로 구현하는 모든 형태를 말한다면, 기계학습이란 인공지능을 만들기 위해 기존의 프로그램과는 달리 코드로 정의하지 않고 컴퓨터에게 학습하는 능력을 부여하는 것을 연구하는 것이다(Samuel, 1959). 어떤 작업이 있고, 이에 대한 성능이 경험으로 향상이 된다면 프로그램은 경험으로부터 학습한다고 할 수 있을 것이다. 일반적으로 주어진 데이터를 분석하고 그 결과에서 규칙이나 새로운 지식을 자동으로 추출하도록 함으로써, 기계가 인간과 같이 학습하는 것과 같은 효과를 얻도록 한다. 한편, 기계학습은 데이터를 분석하고, 그로부터 어떤 값을 도출하는 것을 목표로 한다는 점에서 데이터마이닝과 비슷하나, 데이터마이닝이 데이터를 분석하기 위해 데이터의 구조, 특징 등을 발견하는 것에 초점을 맞춘다면, 기계학습은 데이터를 통해 새로운 현상을 예측하는 것을 목적으로 한다.




[그림 2-1] 인공지능과 기계학습의 관계 (<https://developer.nvidia.com/deep-learning>)

기계학습은 지도학습(Supervised learning), 비지도학습(Unsupervised learning), 강화학습(Reinforcement learning)의 3가지로 크게 분류할 수 있다. 지도학습은 입력 데이터와 출력 데이터를 모두 제공하면서 기계를 학습시키는 방법으로, 입력 데이터의 속성과 출력 데이터의 속성의 관계를 설정하고 이 관계를 사용하여 새로운 데이터에 대한 출력을 예측한다. 대표적인 지도학습으로 분류(Classification)와 회귀(Regression)가 있다. 지도학습은 신뢰성 높은 모델을 구축할 수 있으나, 많은 학습

데이터가 필요하고 이를 만드는 데 큰 비용이 든다는 단점이 있다. 비지도학습은 지도학습과 달리 특정한 의미(좋다/나쁘다, 산다/안산다)를 갖는 출력 데이터가 없이 데이터 자체에서 어떤 패턴을 찾는 학습방법이다. 비지도학습에는 대표적으로 군집화(Clustering)와 차원축소(Dimensionality reduction)가 있다. 기계가 사람의 개입 없이 자동적으로 데이터 속의 패턴을 찾아내고 의미를 추론해야 하므로 오류가 많을 수 있으며, 기대한 결과를 얻지 못할 수 있다. 마지막으로, 강화학습은 경험과 시행착오를 통해서 얻어진 데이터를 기반으로 모델을 지속적으로 개선하는 방식이다. 모델이 어떤 결과를 냈을 때 획득한 성과에 따라 보상을 부여함으로써, 어떤 행동이 보상을 받는 것에 유리하지를 알아내고 이를 최대화 하는 데에 초점을 맞춘다. 이는 매우 새로운 방법을 찾아낼 수 있다는 장점이 있으나, 적용이 힘들고 개발자의 전문성이 높아야 한다.

2.2 기계학습 절차

일반적인 기계학습의 절차는 [그림 2-2]와 같이 이루어진다.



[그림 2-2] 기계학습 절차

기계학습은 데이터에 매우 의존적이다. 기계학습을 위한 데이터셋을 구축하기 위해서는 해결하려는 문제에 데이터가 적합해야 한다. 이에 따라 데이터 수집 단계에서는 분석 데이터를 정리하고 수집 대상과 범위를 명확히 해야 한다. 문제 해결을 위해서는 충분한 양의 데이터가 필요하기 때문에 직접 생성하거나, 데이터를 수집할 수 있는 별도의 환경 구축 또는 필요한 데이터를 보유하고 있는 곳이 있는지 확인해야 한다. 데이터 수집에 있어 데이터의 품질은 중요한 고려사항이다. 우수한 모델이라 하더라도 저품질의 데이터를 사용한다면 결과의 신뢰성을 담보할 수 없다.

데이터 분석은 수집한 데이터를 분석하고 기계학습에 활용이 가능하도록 데이터를 정제하는 것이다. 탐색적 데이터 분석(Exploratory data analysis)을 통해 시각적, 정량적 방법을 사용하여 데이터셋을 이해하고 요약한다. 이는 문제에 대한 적절한 모델을 개발하고, 결과를 올바르게 해석하는 데 도움을 준다. 데이터에 결측치, 이상치 등의 존재, 데이터의 불균형 등은 학습 과정에서 문제가 있으므로 이를 적절하게 처리해야 한다. 그리고 표준화, 정규화, 원-핫 인코딩(One-hot encoding) 등 데이터를 변환하여 기계학습이 잘 되도록 데이터셋을 구축한다.

학습 및 평가 단계에서 가장 중요한 것은 학습에 사용할 알고리즘을 선택하는 것이다. 많은 기계학습 알고리즘이 있으므로 해결할 문제와 데이터셋에 적합한 것을 선정해야 한다. 주로 숫자들로 이루어진 정형 데이터(Structured data)로 이루어진 데이터셋에 대한 분류 및 회귀 문제는 SVM, 의사결정나무, Random Forest,

LightGBM 등을 사용한다. 이미지, 오디오, 텍스트 등으로 이루어진 비정형 데이터 (Unstructured data)의 경우는 CNN 등의 인공신경망 기반의 딥러닝 알고리즘이 효과적으로 알려져 있다. 분석 목적 및 보유 데이터에 대한 적합성, 학습/추론에 소요되는 시간과 비용 등을 고려해서 알고리즘을 선택해야 한다. <표 2-1>와 같이 알고리즘별로 장단점이 있으므로 다양한 알고리즘을 적용해 보는 것도 고려할 수 있다.

<표 2-1> 분류에 사용되는 알고리즘 비교 (Bhavsar & Ganatra, 2012)

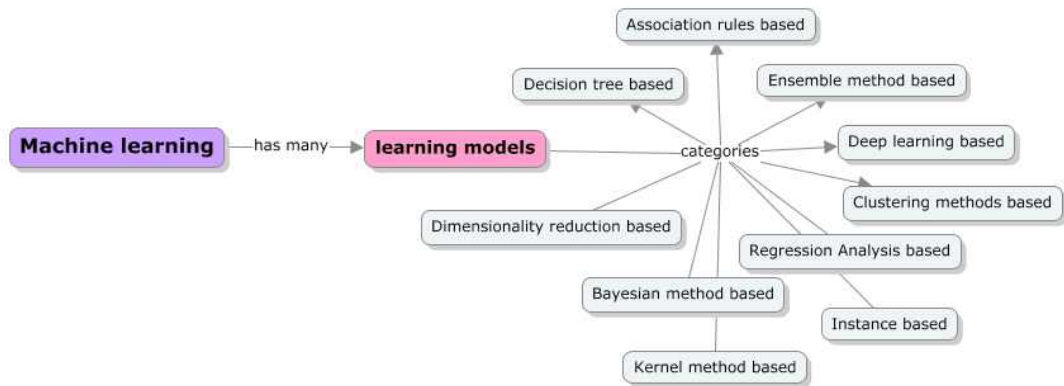
구분	의사결정 나무	신경망	나이브 베이스	K 최근접 이웃	SVM
Accuracy in general	좋음	매우 좋음	보통	좋음	훌륭함
Speed of learning	매우 좋음	보통	훌륭함	훌륭함	보통
Speed of classification	훌륭함	훌륭함	훌륭함	보통	훌륭함
Tolerance to missing values	매우 좋음	보통	훌륭함	보통	좋음
Tolerance to irrelevant attributes	매우 좋음	보통	좋음	좋음	훌륭함
Tolerance to redundant attributes	좋음	좋음	보통	좋음	매우 좋음
Tolerance to highly interdependent attributes	좋음	매우 좋음	보통	보통	매우 좋음
Dealing with discrete/binary/continuous attributes	모두 가능	이산은 불가능	연속은 불가능	모두 가능	이산은 불가능
Tolerance to noise	좋음	좋음	매우 좋음	보통	좋음
Dealing with danger of overfitting	좋음	보통	매우 좋음	매우 좋음	좋음
Attempts for incremental learning	좋음	매우 좋음	훌륭함	훌륭함	좋음
Explanation ability/transparency of knowledge/classification	훌륭함	보통	훌륭함	좋음	보통
Support Multiclassification	훌륭함	기본적으로 확장	기본적으로 확장	훌륭함	이진 분류

마지막으로 검증 및 활용 단계는 개발된 기계학습 모델을 실제 현장에 적용하여 효과를 검증하고 활용하는 것이다. 또한 활용하면서 발생하는 결과를 분석하여 기계학습 모델의 개선에 사용해야 한다.

2.3 기계학습 알고리즘

기계학습을 위한 수많은 종류의 알고리즘이 있으며, 최근에도 계속 새로운 알고리즘이 개발되고 있다. 문제의 종류, 데이터의 크기, 품질 등에 따라 적합한 알고리즘을 사용해야 원하는 결과를 얻을 수 있다.

기계학습 알고리즘을 특성에 따라 분류하면 [그림 2-3]과 같이 나타낼 수 있다. 커널(Kernel) 방법의 대표적인 알고리즘은 Support vector machine(SVM)이다. 입력 데이터를 커널 기법을 사용하여 고차원으로 매핑함으로써 분류 문제를 간단하게 만들어 주는 방법이다. 의사결정나무(Decision tree)는 트리 구조를 사용하여 데이터를 이산형으로 구분하고 이를 반복적 또는 재귀적으로 모델을 구성하여 분류 문제나 회귀 문제를 해결한다. 의사결정나무는 해석이 용이하고, 다양한 형식의 입력 데이터를 사용할 수 있으며 전처리가 적은 편이어서 널리 사용되고 있다. 의사결정나무를 기반으로 하는 다양한 알고리즘이 있는데 대표적으로 Classification and regression tree(CART), C5.0, Gradient boosting machine(GBM), Random Forest 등이 있다. 앙상블(Ensemble) 방법은 집단지성을 알고리즘으로 구현한 것으로, 여러 개의 알고리즘을 사용하여 예측을 실시한 후 각 예측들을 결합함으로써 보다 효율적이고 정확한 결과를 도출하는 방법이다. 앙상블 방법에는 각각의 결과에 대해 투표를 통해 최종 결과를 예측하는 보팅(Voting), 데이터를 샘플링 하여 나누어 학습하는 배깅(Bagging), 학습을 순차적으로 진행하면서 이전에 생성된 모델의 결과를 토대로 개선해나가는 부스팅(Boosting), 개별 알고리즘으로 예측한 데이터를 별도의 알고리즘을 통해 예측하는 스택킹(Stacking)이 있다. 배깅 방식을 사용하는 Random Forest와 부스팅 방식을 사용하는 AdaBoost, XGBoost, LightGBM 등이 대표적인 앙상블 알고리즘이다. 딥러닝(Deep learning)은 인공신경망(Artificial neural network)을 기반으로 하는 알고리즘이다. 인간의 뇌에 존재하는 신경세포인 뉴런이 패턴을 인식하는 방식을 모방하여 만들어졌다. 인공신경망은 입력층과 출력층이 있고, 사이에 여러 개의 은닉층(Hidden layer)이 있는 계층 구조를 가진다. 은닉층이 증가할수록 연산의 양이 기하급수적으로 늘어나는데, 최근 컴퓨터 성능의 발전과 병렬처리가 개발되어 많은 층을 쌓은 심층신경망(Deep neural network)을 만들 수 있게 되면서 다양한 분야에 적용되고 있다. 딥러닝 알고리즘에는 합성곱신경망(Convolutional Neural Network; CNN), 순환신경망(Recurrent Neural Network, RNN), 제한된 볼츠만 머신(Restricted Boltzmann Machine, RBM) 등이 있다.



[그림 2-3] 기계학습 알고리즘의 종류 (Gollapudi, 2016)

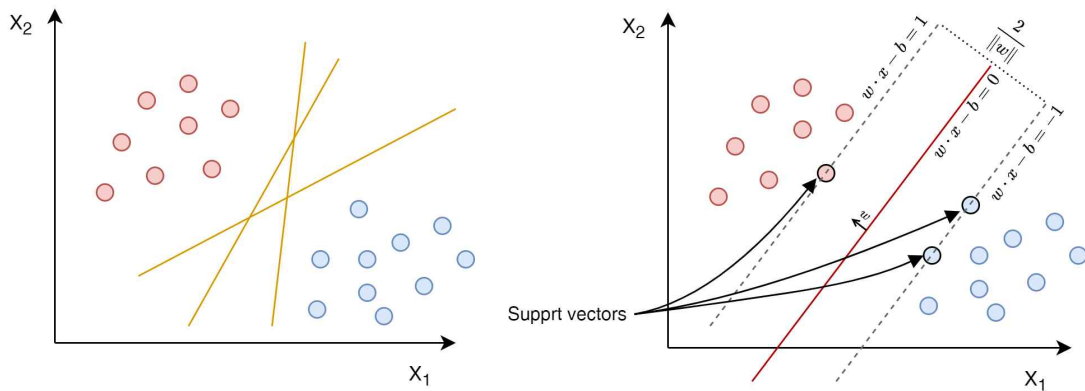
2.3.1 Support Vector Machine(SVM)

SVM은 기존의 통계적 이론에서 이용되는 경험적 위험 최소화 원칙(Empirical risk minimization)이 아닌 구조적 위험 최소화 원칙(Structural risk minimization)을 이용하여 일반화 오류를 줄이기 때문에 패턴 인식 등에서 우수한 성능을 보여주고 있다 (Vapnik, 1999; Burges, 1998). 이에 따라 SVM은 현재까지도 분류를 위한 기계학습 알고리즘으로 보편적으로 사용되고 있다. SVM은 선형적으로 분리할 수 있는 학습 집단에 대해서 최대 마진(Margin) 분류기를 구축하는 선형 SVM과 선형적으로 분리할 수 없는 경우에 커널 함수에 의해 만들어지는 비선형 결정함수를 이용하여 최적의 초평면(Hyper plane)을 구축하는 비선형 SVM으로 분류된다.

선형 SVM은 두 개의 범주로 구성된 객체가 [그림 2-4]와 같이 2차원 공간에 있을 경우, 이를 하나의 초평면으로 구분할 때 수많은 분리경계면이 있을 수 있다. 이때, 두 범주를 구분할 수 있고 가능한 최대 멀리 떨어지게 하는 최적의 초평면을 찾아야 한다. 초평면은 다음과 같은 식으로 표현될 수 있다.

$$w \cdot x - b = 0 \tag{2-1}$$

여기에서 w 는 초평면의 법선 벡터(Normal vector)이다. 식 (2-1)과 평행이고 가장 가까운 빨간 점과 파란 점(Support vector)을 지나고 평면은 식 (2-2)와 같이 각각 나타낼 수 있다.



[그림 2-4] 선형 SVM 개념


$$w \cdot x - b = 1$$

(2-2)

$$w \cdot x - b = -1$$

초평면의 마진은 식 (2-2)의 두 평면 사이의 거리인 $\frac{2}{\|w\|}$ 이며, 선형 SVM은 이 마진을 최대화 하는 최적화 문제로 풀 수 있다.

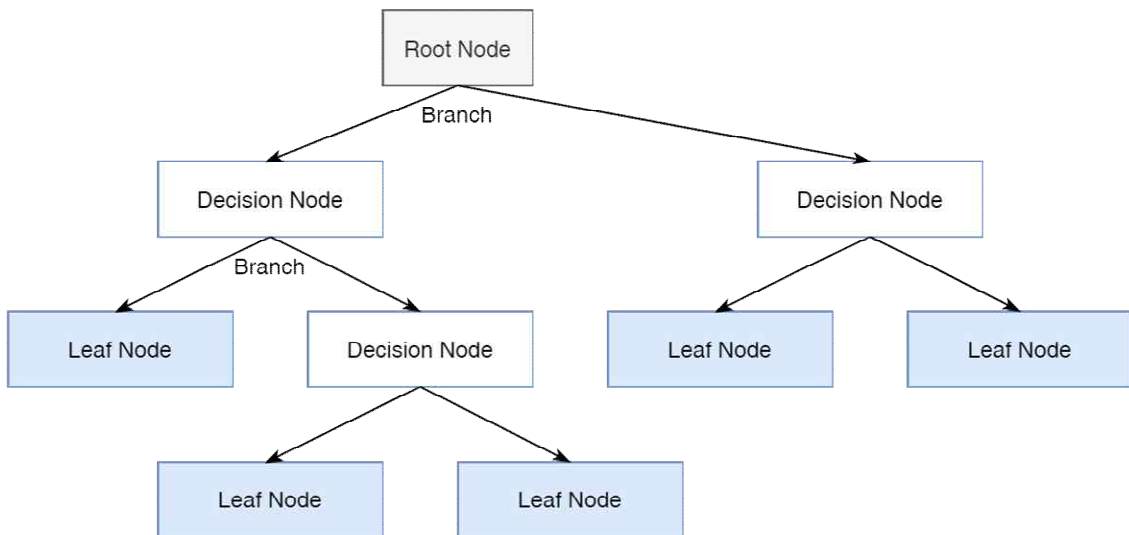
비선형 SVM은 선형 분리가 불가능할 경우 입력 데이터를 분리할 수 있는 비선형 결정 경계(Non-linear decision boundaries)를 이용하게 되는데, SVM은 이를 위해서 커널 함수(ϕ)를 이용하여 [그림 2-5]와 같이 입력 데이터를 고차원 공간으로 매핑하여 선형으로 분리할 수 있게 한다. 즉, 낮은 차원의 비선형 함수를 고차원에서 선형 함수로 근사화하는 것이다. 대표적인 커널 함수는 다항식(Polynomial), 방사기저함수(Radial basis function), 쌍곡탄젠트(Hyperbolic tangent) 등이 있다.



[그림 2-5] 비선형 SVM 개념

2.3.2 Random Forest

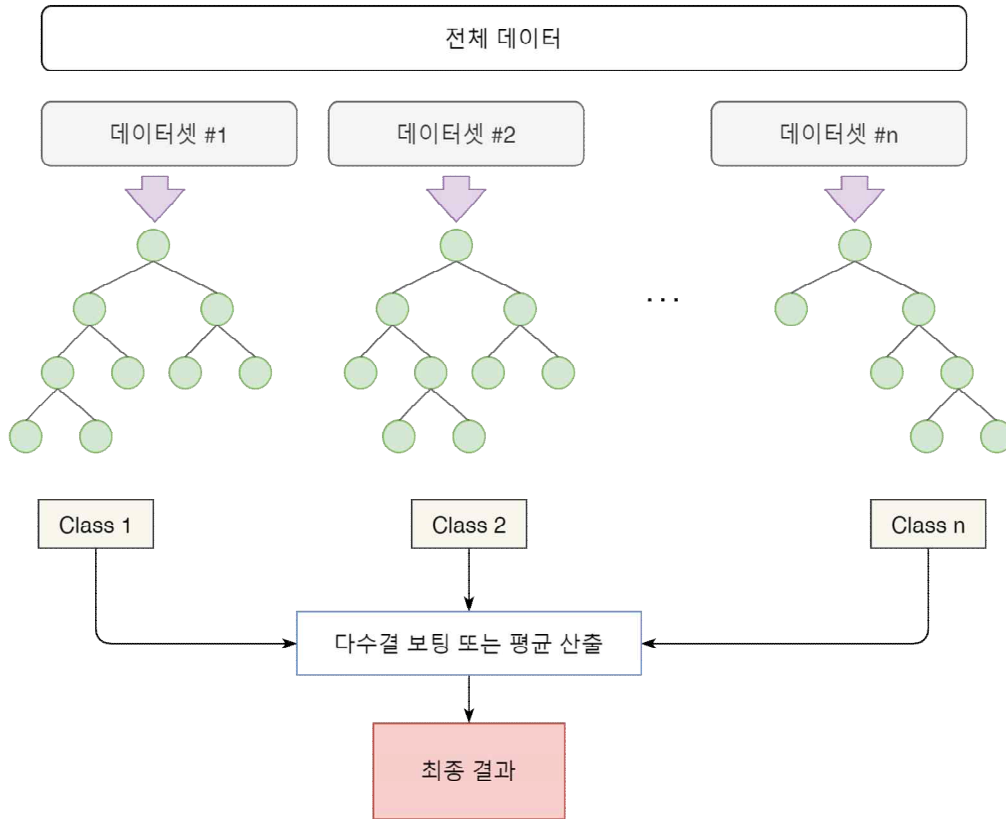
의사결정나무는 스무고개 게임과 유사하게 하나씩 조건에 따라 분류하여 최종 예측결과를 제공하는 알고리즘이다. 의사결정나무는 [그림 2-6]과 같이 표현된다. 규칙 노드(Decision node)는 분할하는 조건을, 리프 노드(Leaf node)는 결정된 값을 나타낸다. 조건에 따라 규칙 노드가 만들어지고 그 조건에 따른 결과를 리프 노드로 표시하거나 새로운 조건으로 연결되어 분류하게 된다.



[그림 2-6] 의사결정나무

Random Forest는 이러한 의사결정나무를 기반으로 하는 알고리즘으로, 다른 구조와 성능을 갖는 다수의 의사결정나무에서 각각 학습을 수행한 후, 결합하는 배경 방식을 사용한 앙상블 모델이다. 이에 따라 Random Forest는 의사결정나무의 직관성을 가지고 있으며, 앙상블 모델 중에서 비교적 빠르고 성능이 우수하다. Random Forest의 가장 큰 특징은 입력 데이터를 생성할 때와 의사결정나무의 규칙 노드를 생성할 때 무작위성(Randomness)을 부여하는 것이다. 이에 따라 각 의사결정나무 간의 상관관계를 낮추어 예측오차를 줄이고 일반화된 모델을 만들 수 있다.

Random Forest의 절차는 [그림 2-7]과 같다. 먼저 전체 입력 데이터의 일부를 샘플링 하여 데이터셋(Dataset)을 생성한다. 각 데이터셋은 일부가 중첩이 되도록 부트스트랩(Bootstrap) 방법을 사용하여 만들어진다. 부트스트랩은 통계학에서 표본 분포(Sampling distribution)를 추정하기 위해서 데이터를 여러 번 복원 추출하는 것을 의미한다. Random Forest에서는 이러한 방법으로 입력 데이터를 임의로 만들게 된다. 다음으로 표본의 특성(Feature) 중에서 무작위로 일부를 선택하여 하나의 의사결정나무를 만든다. 이러한 과정을 반복해서 여러 개의 의사결정나무를 만들고 각 결과 값을 분류 모델의 경우는 보팅, 회귀 모델의 경우는 평균을 구하여 최종 결과를 도출한다.

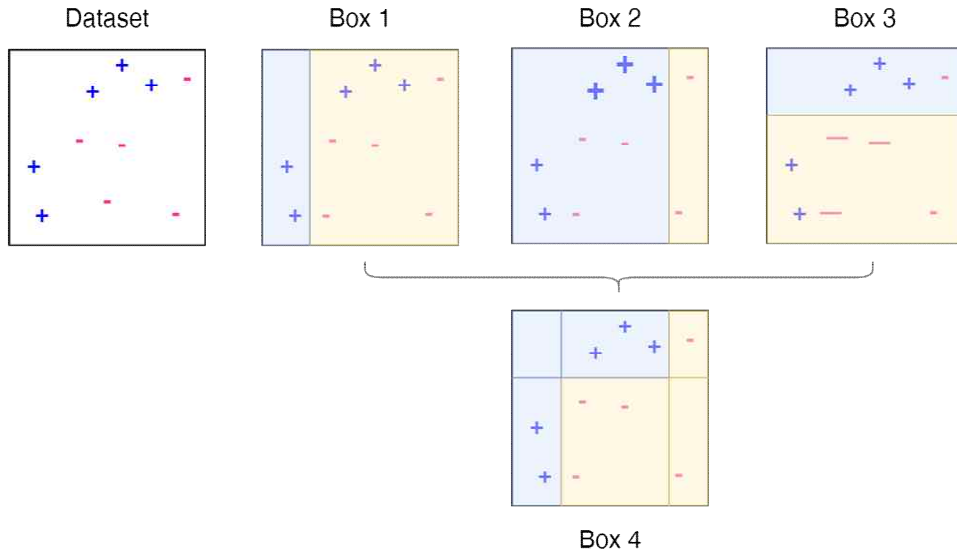


[그림 2-7] Random Forest의 절차

Random Forest는 임의성을 가지고 있어, 손실 데이터(Missing value)가 있거나 이상치(Outlier)가 포함되어 있어도 작동에 문제가 없을 만큼 유연성이 높다. 대용량의 데이터에 적합하며, 범주형, 비선형 구조를 가진 데이터에도 충분한 성능을 보인다 (Olden et al., 2008).

2.3.3 XGBoost

부스팅 기법은 여러 개의 약한 학습기(Weak learner)를 순차적으로 학습시키고 이를 결합하여 강한 학습기(Strong learner)를 만드는 방법이다. 각 분류기에서 사용하는 데이터는 이전의 분류기의 결과에 기반을 두어 가중치를 부여하고 학습을 진행함으로써 성능을 향상시킨다. 이진 분류를 위해 구현된 최초의 성공적인 부스팅 방식 알고리즘인 AdaBoost(Adaptive boosting)의 학습 진행 방법은 [그림 2-8]과 같다. 첫 번째 약한 분류기가 Box 1과 같이 분류한다. 잘못 분류된 데이터(+)에 대해서 가중치를 부여하면, 두 번째 약한 분류기는 Box 2와 같이 다른 분류 기준을 만들게 된다. 다음으로 잘못 분류된 데이터(-)에 대해서 더 큰 가중치를 부여하고 다시 학습을 하면 Box 3과 같이 분류한다. 최종적으로 각 약한 학습기의 분류 기준을 모두 결합시켜 Box 4와 같이 개별적인 약한 분류기보다 성능이 우수한 강한 학습기를 만들 수 있다.



[그림 2-8] AdaBoost의 학습방법

다른 부스팅 방법인 Gradient boosting은 AdaBoost와 비슷한 메커니즘을 가지고 있으나, 가중치를 부여할 때 경사하강법(Gradient descent)을 사용하여 손실함수의 최적해를 찾는 방식으로 수행한다(Friedman, 2001). 예측 값에 대한 잔차(Residual)를 계산하고 이를 새로운 모델에 업데이트하여 합산해 가는 방식을 사용한다. 그러나 이러한 부스팅 기법은 순차적으로 진행되므로 우수한 성능을 위해서는 학습시간이 길어진다는 단점이 있다.

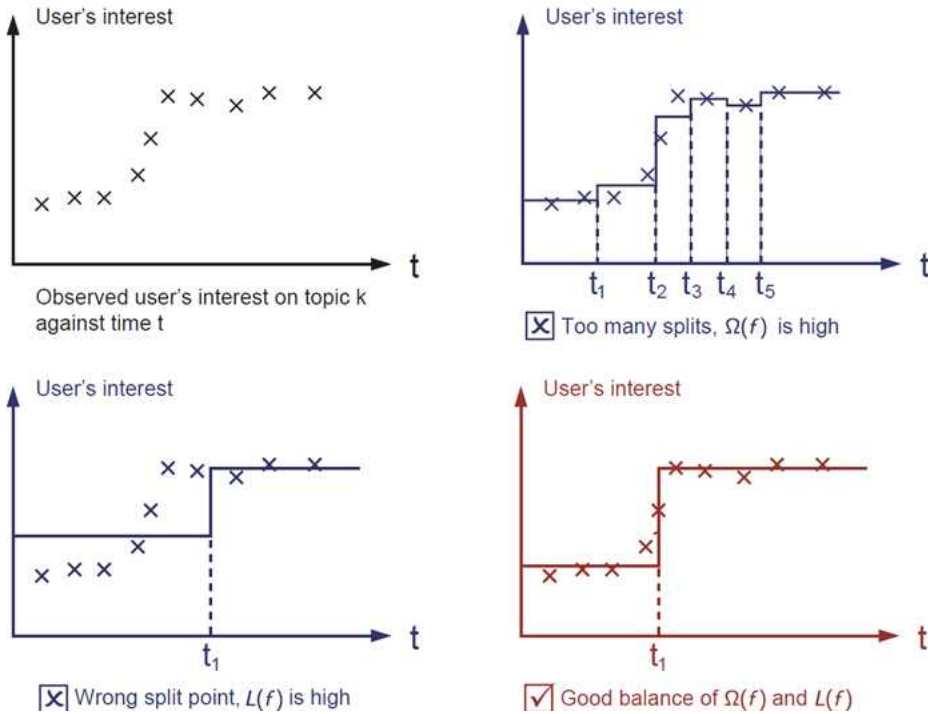
XGBoost는 eXtreme Gradient Boosting의 약자로 병렬화를 통해 Gradient boosting 기법의 속도를 향상시켰다(Chen & Guestrin, 2016). 또한 과적합 문제 해결을 위해 정규항(Regularization term)을 제공하여 좀 더 일반화된 모델을 만들 수 있다. XGBoost는 분류와 회귀의 예측 성능이 뛰어나고, Gradient Boosting 대비 빠른 수행 시간, 과적합 규제로 강한 내구성, 이득이 없는 노드를 잘라내는 나무 가지치기(Tree pruning), 교차검증 및 결측치 자체 처리 등의 장점을 가지고 있다. XGBoost의 모델과 목적함수는 다음과 같다.

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i) \quad (2-3)$$

$$obj = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (2-4)$$

K 는 의사결정나무의 개수이고, f_k 는 k 번째 의사결정나무이다. l 은 손실함수를 나타내며 일반적으로 평균제곱오차(Mean squared error)나 로지스틱 손실함수를 사용한다. Ω 는 정규항을 의미하는데, 식 (2-5)와 같다. 리프의 개수(T)와 리프 스코어의 L2 Norm으로 구성되어 있어 의사결정나무의 복잡도를 나타내며, 편향-분산을 맞추는(Bias-variance tradeoff) 수 있도록 한다. [그림 2-9]는 이러한 예시를 나타낸다.

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \quad (2-5)$$




[그림 2-9] 편향-분산 트레이드오프 예시 (<https://xgboost.readthedocs.io/en/latest/tutorials/model.html>)

주어진 목적함수를 전개함으로써 각 트리 구조에 대한 점수를 측정할 수 있는데, 이를 이용하여 트리에서 가지를 분할할 때의 이득값(Gain)을 계산하고 이득값이 최대가 되도록 트리를 생성한다. 그리고 이를 부스팅하여 최종적인 모델을 만들게 된다.

2.3.4 LightGBM

LightGBM은 XGBoost와 같이 의사결정나무를 기반으로 하는 부스팅 기법을 사용한 알고리즘이다. XGBoost는 부스팅 기법 중에서는 수행시간이 빠르다고 하지만 여전히 학습에 오랜 시간이 걸리므로 초매개변수(Hyperparameter) 최적화뿐만 아니라 빅데이터와 같은 대용량 데이터에서 사용하기는 어려운 점이 있다. LightGBM은 이러한 점을 개선하기 위해 Microsoft에서 개발된 알고리즘이다(Ke et al., 2017). LightGBM은 XGBoost의 병렬화, 정규화 등의 장점은 계승하면서 단점을 보완하고자 하였다. LightGBM의 가장 큰 특징으로 [그림 2-10]과 같이 리프 중심 트리분할(Leaf wise) 방법을 사용하는 것이다. 의사결정나무를 기반으로 하는 기존의 알고리즘은

강건한 모델을 만들기 위해 트리의 깊이를 줄이고자 균형 트리분할(Level wise) 방법을 사용한다. 최대한 균형 잡힌 트리를 유지하면서 분할하기 때문에 트리의 깊이를 최소화 할 수 있으나 균형을 맞추기 위한 시간이 필요하다는 단점이 있다. 이에 반해, 리프 중심 트리분할은 트리의 균형을 맞추기보다 최대 손실값(Max delta loss)을 가지고 있는 리프 노드를 우선적으로 분할하여 성장한다. 트리의 깊이가 깊어지고 비대칭적으로 만들어질 수 있지만 이러한 방법이 균형 트리분할 방법보다 오차를 더 줄일 수 있다.



[그림 2-10] 균형 트리분할 및 리프중심 트리분할 (<https://lightgbm.readthedocs.io/en/latest/Features.html>)

LightGBM은 학습속도를 높이기 위해서 히스토그램 방식(Histogram-based), GOSS(Gradient-based One-Side Sampling), EFB(Exclusive Feature Bundle) 등의 방법을 사용한다. 기존의 Gradient boosting 모델은 사전 정렬 방식(Pre-sort-based)을 사용하여 최적 분할점을 찾아내 의사결정나무를 학습한다. 이는 간단하지만 최적화에 어려운 점이 있으며 학습속도와 메모리 사용에 불리하다. LightGBM은 히스토그램 방식을 사용하여 연속적인 변수 값을 개별 구간으로 나누고 이 구간을 사용하여 최적 분할점을 찾도록 하였다. 히스토그램 방식은 메모리, 학습 속도에 보다 효율적일 수 있지만, 희소한(Sparse) 데이터셋에는 오히려 불리할 수 있다.

AdaBoost에서 가중치는 데이터의 중요도를 알려주는 좋은 지표이다. Gradient boosting에서는 Gradient가 그런 역할을 할 수 있다. 기울기가 작다는 것은 오차가 작다는 것을 의미하므로 학습이 잘 되었다는 것이다. 그래서 모델을 간단하게 하기 위해 기울기가 작은 데이터를 제거할 수도 있지만, 이럴 경우 데이터 분포가 변하는 문제가 있다. GOSS는 기울기가 큰 데이터는 모두 남겨두고, 기울기가 작은 데이터는 무작위 샘플링을 진행함으로써 원래의 데이터 분포를 크게 변경하지 않으면서도 기울기가 큰 데이터의 학습에 집중할 수 있게 한다.

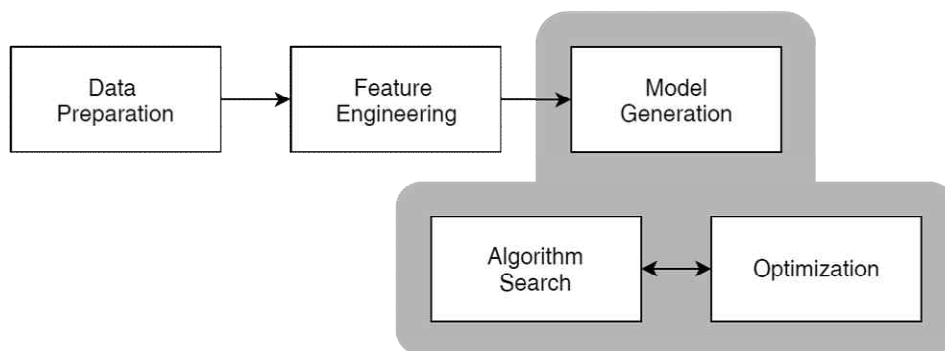
실제로 사용하는 많은 데이터들은 대부분 0 값이고, 0이 아닌 값을 드물게 가지

는 희소한 경우가 많다. 또한 이런 경우 다수의 변수가 0이 아닌 값을 동시에 갖지 않는 상호 배타적이다(예, 원-핫 인코딩). 이에 따라 배타적 변수를 단일 변수로 묶는 방법이 EFB이다. EFB를 적용함으로써 연산량을 줄이고 히스토그램 방식을 효율적으로 사용할 수 있다.

2.3.5 AutoML

기계학습의 여러 성공사례와 오픈소스로 제공되는 다양한 알고리즘 등으로 인하여 이전보다 쉽게 데이터 분석을 할 수 있게 되었으며, 이에 대한 관심이 높아졌다. 그러나 실제 문제를 해결하기 위해서는 데이터의 특성을 파악하고 적합한 알고리즘을 선택하여 최적화 등을 수행해야 하는데, 이를 위해서는 해당 도메인에 전문적인 경험과 지식이 필요한 것은 물론이고 많은 시간이 필요하다. 일반적으로 기계학습에 대한 개발과정은 학습 및 검증 데이터를 준비하고(Data preparation), 학습 목적에 맞도록 데이터의 전처리 및 분석을 수행한다. 그리고 문제에 적합한 기계학습 알고리즘을 선택하고, 알고리즘에 따라 사전에 정의해야 하는 초매개변수를 충분한 성능이 나오도록 최적화하여 예측 모델을 구축하고 검증 데이터를 통해서 예측을 한다. 이러한 전문지식과 장시간의 반복 수행이 필요한 문제를 개선하기 위하여 AutoML(Automated machine learning)에 대한 연구가 진행되고 있다.

AutoML은 하나의 기계학습 알고리즘이 아니라 기계학습 과정에서의 일련의 작업을 자동화하여 더욱 빠른 훈련과 분석을 가능하게 해주는 것이다. AutoML의 분야는 기계학습 과정에 따라 [그림 2-11]과 같이 데이터 준비, 특징 공학, 모델 생성으로 구성되어 있으며, 모델 생성은 다시 알고리즘 탐색과 최적화 단계로 나눌 수 있다. 알고리즘 선택은 SVM, Random Forest 등을 선택하는 것이며, 최적화는 초매개변수의 최적화와 딥러닝의 구조(Architecture)의 최적화를 포함한다. 딥러닝의 경우 알고리즘, 구조 등을 포괄하여 신경망 구조 탐색(Neural architecture search; NAS)이라고도 한다. 최근 딥러닝에 대한 관심이 높고 딥러닝의 구조가 갈수록 복잡해지고 연산량이 기하급수적으로 증가하면서 신경망 구조 탐색에 대한 연구가 활발히 이루어지고 있다.



[그림 2-11] AutoML의 적용 범위


AutoML 모델마다 범위와 방법에 차이가 있지만 각 단계마다 최적화를 위해서 시행착오(Trial and error) 자동화, 베이지안 최적화(Bayesian optimization), 위상구조(Topology), 유전자 알고리즘 등의 기법들을 사용하고 있다. 예를 들어 Auto-Sklearn은 파이썬(Python)의 기계학습 라이브러리인 사이킷런(Scikit-learn)에 기반으로 두는 AutoML 모델이다(Feurer et al., 2015). Auto-Sklearn은 15개의 분류기와 14개의 특징 공학 방법, 4개의 데이터 전처리 방법을 포함하고 베이지안 최적화를 사용하여 앙상블 모델을 만들어 낸다. Auto-Sklearn외에도 TPOT, Auto-Weka 등의 오픈소스 뿐만 아니라 글로벌 기업에서도 솔루션(IBM AutoAI, Microsoft AzureML, Google AutoML, Amazon SageMaker)들이 지속적으로 개발되고 있다.

다만, AutoML은 사람이 쉽게 생각하기 어려운 구성을 만들어 효율성을 높이기도 하지만 단점도 존재한다. 성능을 높이기 위해 모델이 복잡해지면서 모델에 대한 과학적인 해석이 어려워지고, 재현성, 강건성 등이 부족하다(He et al., 2021).

2.3.6 Convolutional Neural Network

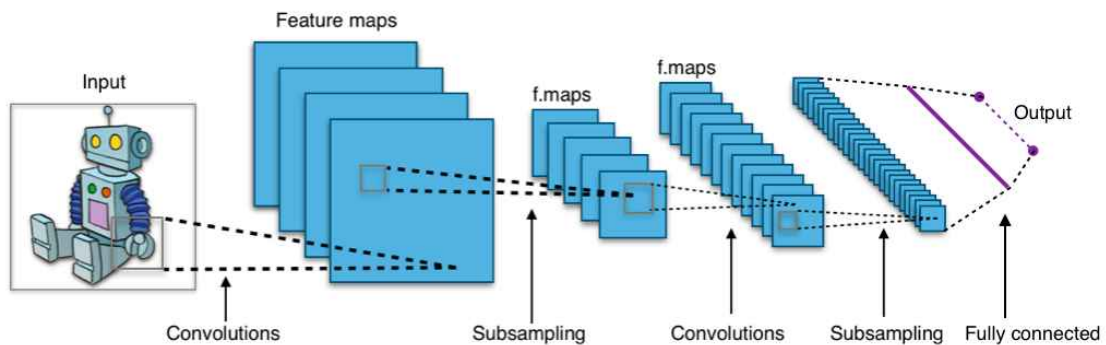
합성곱 신경망(Convolutional neural network; CNN)은 인공신경망의 한 종류로 다층 퍼셉트론(Multi layer perceptron)이다. 그러나 한 층의 뉴런이 다음 층의 모든 뉴런에 완전히 연결된 네트워크와 달리 데이터에서 계층적 패턴을 활용함으로써 복잡성을 낮추게 된다. 이에 따라 비정형 데이터인 이미지 인식, 자연어처리 등에 널리 사용되고 있다. 2012년 개최된 ILSVRC(ImageNet large scale visual recognition competition)에서 CNN을 활용한 AlexNet이 기존 SVM 등을 이용한 다른 팀을 압도하면서 본격적으로 주목을 받기 시작했고, 이후 대부분의 상위권 팀이 CNN을 활용한 딥러닝을 사용하였다.

CNN은 동물의 시각 피질의 연구로부터 아이디어를 얻은 것으로 가장 중요한 특성은 필터를 사용하여 입력 데이터의 특징을 추출하는 것이다. 인공신경망은 입력 데이터를 받아 1개 이상의 은닉층을 거쳐 출력 값을 내보내는데, 이전 층에서 나온 출력 값이 부여된 가중치와 계산하여 다음 층의 입력 값으로 보내진다. 기존의 인공신경망은 [그림 2-12]와 같이 완전연결층(Fully connected layer)을 사용하는데, 완전연결층은 이미지인 2차원 데이터를 1차원 벡터로 변환하여 입력으로 받기 때문에 이미지의 공간적인 구조(Spatial structure) 정보와 이미지의 색을 나타내는 RGB 정보의 손실을 가져온다. 따라서 이미지의 일부가 섞여도 성능이 변하지 않게 된다. 그러나 합성곱층(Convolution layer)은 형상을 유지하면서 전달하기 위해 공간 필터를 사용함으로써 정확한 정보의 전달을 가능케 한다.



[그림 2-12] 완전연결층을 적용한 인공신경망 (<https://stanford.edu/~shervine/teaching/cs-230/cheatsheet-convolutional-neural-networks>)

CNN의 기본 구조는 [그림 2-13]과 같으며, 주요 구성 계층은 합성곱층과 풀링층(Pooling layer)이다. 합성곱층은 입력에 대하여 공간 필터를 사용한 합성곱 연산을 수행하여 공간 정보의 특징을 요약하는 특징 맵(Feature map)을 생성한다. 그런데 특징 맵은 정확한 위치를 기록하기 때문에 공간 정보가 조금만 바뀌어도 완전히 다른 패턴으로 인식하게 될 수도 있다. 이 문제를 해결하기 위해서 다운 샘플링 등이 사용되는데, CNN에서는 풀링층으로 처리한다. 풀링층은 특징을 강화하고 출력을 간소화하여 학습할 매개변수의 개수를 감소시킨다. 대표적인 풀링 방법으로는 최대 풀링(Max pooling)과 평균 풀링(Average pooling)이 있다.



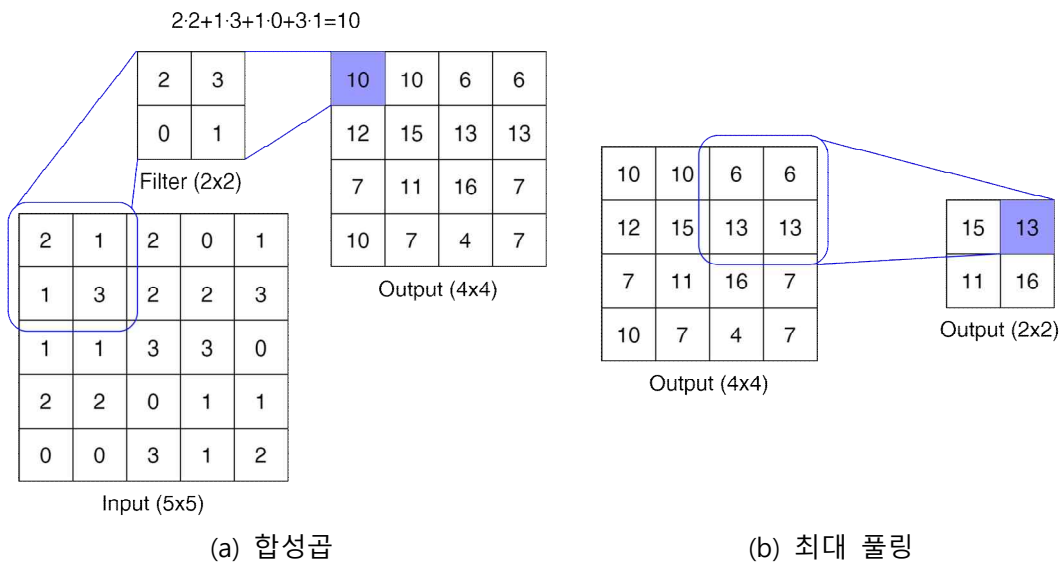
[그림 2-13] 합성곱 신경망의 기본 구조 (https://en.wikipedia.org/wiki/Convolutional_neural_network)

합성곱의 연산은 2차원 입력 이미지의 위치 (i, j) 의 픽셀(Pixel) 값을 $f(i, j)$, 필터를 $h(a, b)$ 라고 하면 식 (2-6)과 같이 계산된다. k 는 필터의 크기이다.

$$g(i, j) = \sum_{a=0}^{k-1} \sum_{b=0}^{k-1} f(i+a, j+b)h(a, b) \quad (2-6)$$

[그림 2-14]는 합성곱과 최대 풀링의 예시이다. 5×5 의 입력에 대해서 2×2 의 필

터를 이용하여 일정한 간격(Stride)만큼 움직이면서 입력 이미지의 전 영역에서 각각 합성곱을 수행하여 특징 맵을 생성한다. [그림 2-14]에서는 간격이 1이므로 특징 맵의 크기는 4×4가 된다. 이러한 필터가 CNN에서 가중치에 해당하며, 학습을 통해 필터의 값이 결정되게 된다. 최대 풀링은 특징맵에서 정해진 크기의 영역에서 최대값만을 추출한다. 보통 풀링은 2×2의 영역을 사용하고 간격도 2로 하는 경우가 많은데, [그림 2-14]에서는 최대 풀링에 따라 4×4의 특징 맵이 2×2로 축소되었음을 알 수 있다.



[그림 2-14] 합성곱 및 최대 풀링의 예시 (McClure, 2017)

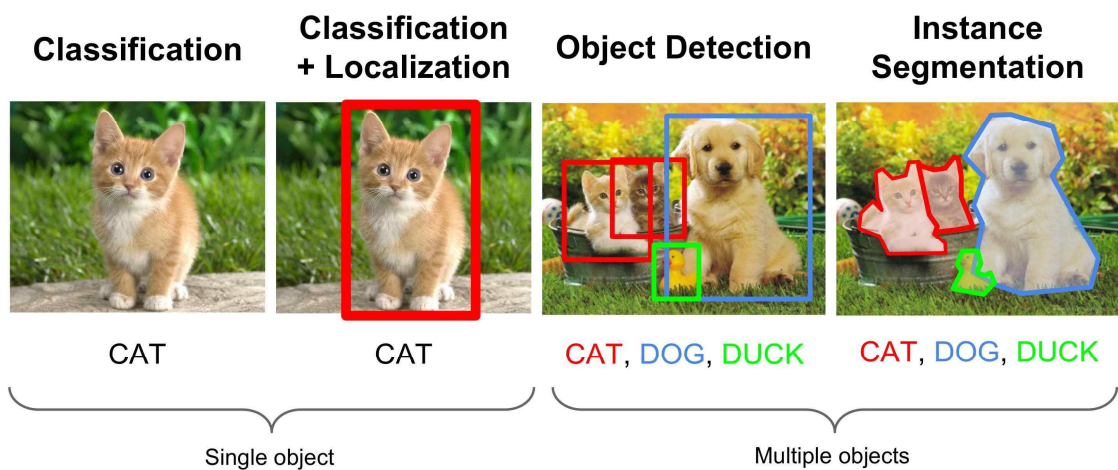
CNN은 [그림 2-13]과 같은 합성곱층과 풀링층을 여러 개를 쌓음으로써 이미지의 특징을 추출하고, 최종적으로 분류를 위해 완전연결층을 사용한다. 앞에서 얘기한 AlexNet은 총 11개의 층(합성곱층 5개, 풀링층 3개, 완전연결층 3개)으로 이루어져 있다(Krizhevsky et al., 2012). [그림 2-15]는 CNN을 통해 이미지로부터 추출된 특징 맵을 시각화 한 것이다. 우측 그림을 CNN을 통해 추상한 결과, 좌측의 특징 맵은 문자나 사물의 윤곽을 두드러지게 표현하여 나타내는 것을 알 수 있다.



[그림 2-15] CNN 적용을 통한 특징 추출 예시 (Zeiler & Fergus, 2013)

2.3.7 물체 탐지

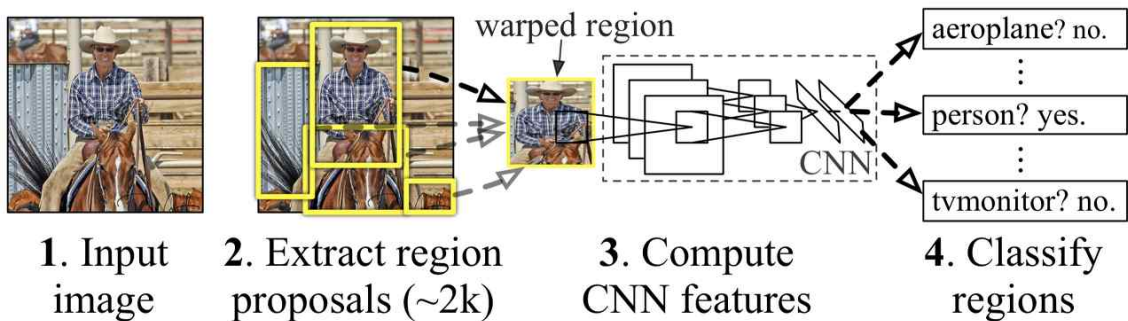
물체 탐지는 이미지 인식의 한 분야로 이미지 또는 영상으로부터 물체(객체)를 찾아내어 분류하는 작업이다. 물체 탐지는 [그림 2-16]과 같이 분류된다. [그림 2-16]의 맨 좌측은 이미지에 하나의 물체만 존재하고 그 물체의 종류를 분류하는 것이다. 좌측에서 두 번째는 이미지에서 사물의 위치와 분류를 동시에 하는 것이다. 세 번째는 이미지 안의 여러 물체의 위치와 종류를 각각 찾아내는 것이다. 맨 우측은 사물을 배경과 분리하는 개체 분리이다. 일반적으로 물체 탐지는 세 번째를 의미한다.



[그림 2-16] 물체 탐지의 종류 (<https://medium.com/comet-app/review-of-deep-learning-algorithms-for-object-detection-c1f3d437b852>)

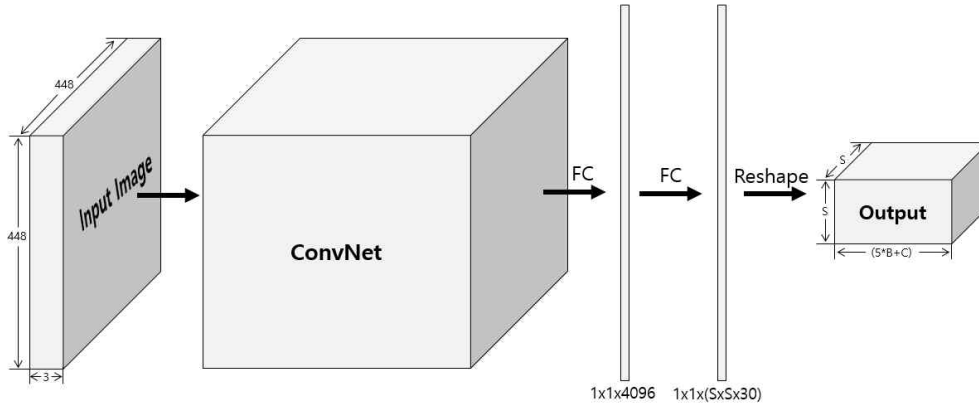
CNN 알고리즘이 소개된 이후, 이미지 분류([그림 2-16]의 첫 번째)에서는 인간보다도 더 높은 정확성을 얻는 등 상당한 효과를 거두었으나, 물체 탐지 분야에서는 물체의 위치를 찾아내기 어려워 적용이 쉽게 되지 못하였다. 이를 해결하는 방법으로 제안된 알고리즘이 R-CNN이다. R-CNN은 기존의 컴퓨터 비전에서 사용해왔던 지역 제안(Region proposals)을 사용하여 물체의 덩어리를 먼저 찾아낸 다음, 각 물체를 CNN을 이용하여 물체의 특징을 찾아내고 SVM을 이용하여 물체의 종류를 분류하였다(Girshick et al., 2014). R-CNN의 절차는 [그림 2-17]과 같이 우선 입력된 이미지에 대해서 분류와 관계없이, 인접한 픽셀 간의 차이를 통해서 비슷한 이미지를 하나의 경계상자를 만드는 선택적 탐색(Selective Search)을 사용하여 약 2,000개 이하의 독립된 이미지를 추출한다. 그리고 추출한 모든 이미지를 하나씩 CNN 모델에 넣고 SVM을 적용하여 각각 이미지 분류 문제로 해석하였다.

R-CNN: *Regions with CNN features*



[그림 2-17] R-CNN의 구조 (Girshick et al., 2014)

R-CNN은 기존 방법보다 30%의 정확도 향상이 있었으며, 이 방법을 발전시켜 Fast R-CNN, Faster R-CNN 등의 알고리즘이 개발되었다. R-CNN은 지역 제안과 분류가 순차적으로 진행된다는 의미로 2단계 탐지기(2-stage detector)라고 불린다. 2단계 탐지기는 정확성은 높으나, 지역 제안도 시간이 걸리고 제안된 모든 이미지를 분류하는 데도 시간이 소요되므로 느리다는 단점이 있다. 따라서 최근에는 이미지의 위치 파악과 분류를 동시에 진행하는 1단계 탐지기(1-stage detector)인 YOLO, SSD 등의 알고리즘이 개발되고 있다. 1단계 탐지기는 [그림 2-18]과 같이 입력 이미지를 하나의 CNN 아키텍처에 넣고 물체의 종류와 사물의 위치를 동시에 계산하여 물체를 탐지한다.



[그림 2-18] YOLO 모델 구조 (이한솔, 2018)

2.4 성능평가

기계학습을 통해 만들어진 모델의 성능평가는 학습된 모델이 얼마나 정확하게 예측했는지를 보여주는 것으로 매우 중요하다. 예측 모델이 잘 작동하는 지를 나타내기 위해 적절한 성능평가 방법을 선택해야 한다. 특히 불균형 데이터의 경우 반드시 적절한 방법으로 평가해야 원하는 성능을 확인할 수 있다. 기계학습의 예측 모델은 분류 모델과 회귀 모델로 나누어진다. 분류 모델은 얼마나 잘 분류하였는지로 성능을 평가하지만, 회귀 모델의 성능평가는 일반적으로 오류를 측정함으로써 성능을 평가한다.

2.4.1 회귀 모델의 성능평가

회귀 모델의 성능평가를 위해 일반적으로 사용되는 것은 평균제곱오차, 평균제곱근오차(Root mean squared error), 평균절대오차(Mean absolute error)이며 각각 다음과 같은 식으로 표현된다.

$$MSE(y, \hat{y}) = \frac{1}{N} \sum_{i=0}^{N-1} (y_i - \hat{y}_i)^2 \quad (2-7)$$

$$RMSE(y, \hat{y}) = \sqrt{MSE(y, \hat{y})} \quad (2-8)$$

$$MAE(y, \hat{y}) = \frac{1}{N} \sum_{i=0}^{N-1} |y_i - \hat{y}_i| \quad (2-9)$$

여기에서 \hat{y}_i 는 예측값, y_i 는 실제값을 의미한다. 이 외에 MSLE(Mean squared logarithmic error), MAPE(Mean absolute percentage error)등이 회귀 모델의 성능평가를 위해서 사용된다.

2.4.2 분류 모델의 성능평가

혼동 행렬(Confusion matrix)은 분류 모델의 성능을 평가하는데 가장 널리 사용되는 방법이다. 실제 값과 예측 모델에 의해 분류된 예측 값의 발생 빈도를 보여주는 것으로 오류행렬(Error matrix)이라고도 한다.(Stehman, S.V., 1997). 혼동 행렬은 <표 2-2>와 같이 나타낼 수 있다.

<표 2-2> 혼동 행렬

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

혼동 행렬의 TP와 TN은 정확히 분류(정분류)한 것을 나타내고, FP, FN는 잘못 분류(오분류)한 것을 나타낸다. 이 혼동 행렬의 각 값을 사용하여 분류 모델의 성능을 평가하는데, 대표적인 척도는 정확도(Accuracy), 정밀도(Precision), 재현율(Recall)이다. 정확도는 전체 분류 중 정분류한 비율이며, 정밀도는 예측이 참이라고 예측한 것 중 정분류한 비율로 긍정 예측도(Positive predictive value; PPV)라고도 한다. 재현율은 실제로 참인 것 중 정분류한 비율이며, 사실-긍정율(True-positive rate; TPR) 또는 민감도(Sensitivity)라고도 불린다.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2-10)$$

$$Precision = \frac{TP}{TP + FP} \quad (2-11)$$

$$Recall = \frac{TP}{TP + FN} \quad (2-12)$$

일반적으로 정밀도와 재현율은 반비례의 관계를 가지기 때문에, 하나의 값으로 나타내기 위하여 F_β 척도를 사용한다(van Rijsbergen, 1979). F_β 척도는 식 (2-13)과 같이 표현되는데, 여기에서 P 는 정밀도, R 은 재현율이며, α 는 가중치를 의미한다. 즉, F_β 는 가중치(α)가 있는 정밀도와 재현율의 조화평균을 의미한다.

$$F_\beta = \frac{1}{\alpha \frac{1}{P} + (1-\alpha) \frac{1}{R}} = \frac{(\beta^2 + 1)PR}{\beta^2 P + R} \quad (2-13)$$

$$\text{여기에서 } \alpha = \frac{1}{1+\beta^2}$$

정밀도와 재현율에 동일하게 가중치 0.5를 부여하는 경우, β 가 1이 된다. 이를 F1-score라고 부르며 가장 많이 사용하고 있다.


$$F1\text{-score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (2-14)$$

그 외에 특이도(Specificity), 긍정오류율(False positive rate; FPR) 등이 있으며 식 (2-15)와 같다.

$$\begin{aligned} \text{Specificity} &= \frac{TN}{TN+FP} \\ \text{FPR} &= \frac{FP}{TN+FP} = 1 - \text{Specificity} \end{aligned} \quad (2-15)$$

민감도와 긍정오류율의 상호관계를 보여줌으로써 다양한 부분을 한 눈에 볼 수 있는 방법으로 [그림 2-19]와 같은 ROC(Receiver operation characteristic) 곡선이 있다. 각 상황에 따른 민감도와 긍정오류율을 계산하여 그래프 상에 그림으로써 만들어진다. 임계값(Threshold)을 기준으로 왼쪽 상단에(민감도=1, 긍정오류율=0) 가까울수록 성능이 높고, 임계값에 가까울수록 성능이 낮다(Fawcett, 2006). ROC 곡선을 하나의 값으로 나타내기 위해 그래프 아래의 면적인 AUC(Area under curve)를 계산하여 정량화하여 사용한다. 이 외에도 매튜 상관계수(Matthews correlation coefficient; MCC)도 많이 사용되고 있다.

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP+FP)(TP+FN)(TN+FP)(TN+FN)}} \quad (2-16)$$




[그림 2-19] ROC 그래프 예시

2.4.3 물체 탐지 모델의 성능평가

물체 탐지는 2.2.6절에서 언급한 ILSVRC 외에도 PASCAL VOC(Visual object challenge), MS COCO 등 다양한 대회를 통해 이미지에서 물체를 탐지하고 분류하는 성능을 개선해 왔다. 이런 대회에서 평가지표로 주로 사용하는 것이 mAP(Mean average precision)인데, 2007년 PASCAL VOC에서 최초로 사용되었다(Everingham et al., 2010).

여러 개의 물체가 있는 이미지에서 물체를 탐지하는 모델의 성능을 평가하기 위해서는 물체의 위치와 분류의 두 가지 모두 잘 되었는지를 평가해야 하기 때문에, 기존의 분류와는 다른 추가적인 방법이 필요하다. [그림 2-20]의 (a)와 같이 분류해야 할 실제(Ground truth) 정보는 이미지에 포함된 개체의 범주(Class)와 개체의 위치를 나타내는 경계상자(Boundary box)의 정보이다.

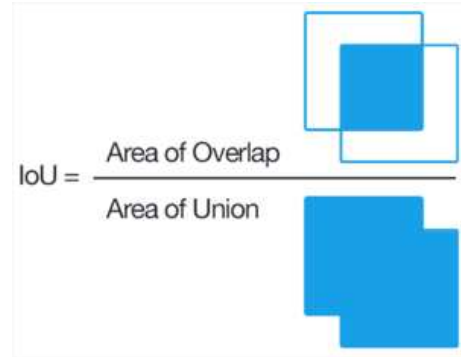
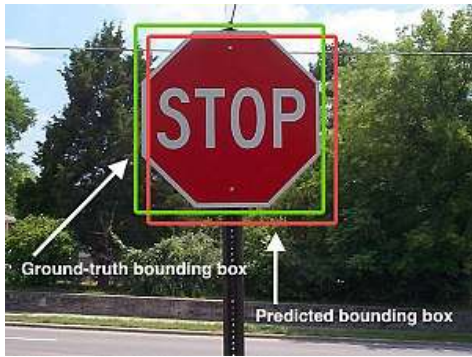


(a) 분류해야 할 실제 정보

(b) 물체 탐지 결과

[그림 2-20] 실제 이미지와 탐지 결과

물체 탐지 모델이 [그림 2-20] (b)와 같은 결과를 얻었을 때, 정확도를 정량화하기 위하여 IoU(Intersection over Union)을 구한다. IoU는 예측한 경계 상자와 실제 경계 상자가 겹치는 정도를 나타낸다(Jaccard, 1912). IoU는 도식적으로 [그림 2-21]과 같이 계산할 수 있다.



[그림 2-21] IoU 계산 방법 (Wikipedia)

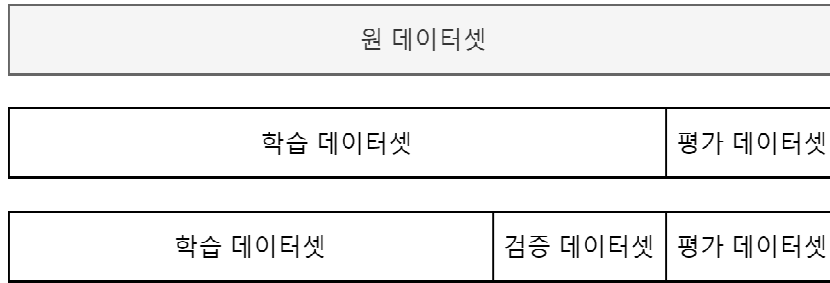
일반적으로 IoU의 값이 0.5보다 크면 맞게 탐지한 것으로, 그렇지 않으면 잘 못 탐지한 것으로 판단한다. 이와 같은 방법으로 이미지에서 물체를 탐지하고 분류한 결과를 판별하여 2.3.2절과 같이 각 범주별로 정밀도, 재현율 등을 계산할 수 있다. 정밀도와 재현율을 이용하여 정밀도-재현율 곡선을 그릴 수 있는데, 이를 이용하여 AP(Average precision)를 다음과 같은 식으로 계산할 수 있다. 여기에서 n 은 탐지할 물체의 전체 숫자이고, P_i 는 i 번째 탐지에 대한 최대 정밀도이며, R_i 는 해당 재현율이다. AP는 정밀도-재현율 곡선 아랫부분의 면적(AUC)이다.

$$AP = \sum_{i=1}^n P_i \Delta R_i \quad (2-18)$$

이 AP를 각 범주에 대해서 계산하여 합하고 범주의 개수로 나눠주는 값이 mAP이다(Nath et al., 2020). 이 외에도 앞 절과 동일하게 F1-score, ROC-AUC를 사용하기도 한다.

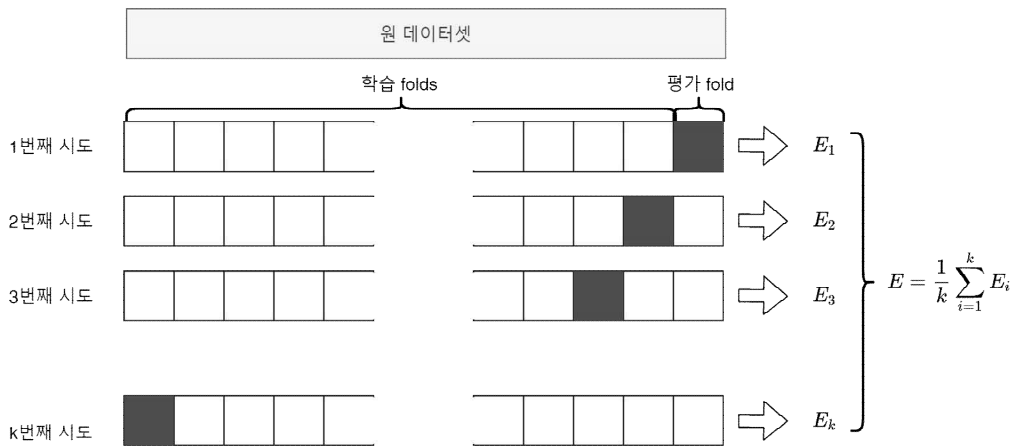
2.4.4 성능평가 방법

모델의 일반화된 성능을 보기 위해서, [그림 2-22]와 같이 원래의 데이터셋을 학습에 사용할 데이터와 평가에 사용할 데이터로 분리가 필요하다. 학습에 사용하지 않은 새로운 데이터로 검증함으로써 실제 모델의 성능을 검증할 수 있다. 일반적으로 데이터셋의 분리 비율은 80/20 또는 70/30을 사용하지만 데이터셋의 크기에 따라 좌우될 수 있다. 데이터가 충분히 많다면, 평가용 데이터가 클 필요는 없다. 알고리즘에 따라 학습 모델의 수정 또는 조정에 검증데이터를 사용하는 경우도 있다. 검증 데이터는 모델에 직접 사용하여 과적합을 방지하기 위해서 사용된다. 이런 경우 [그림 2-22]의 맨 아래와 같이 분리한다.



[그림 2-22] 학습, 평가를 위한 데이터셋의 분리

다른 평가 방법으로는 k-겹 교차검증(k-Fold cross validation)이 있다. k-겹 교차검증은 모든 데이터를 학습과 평가에 사용함으로써 데이터 양이 적을 때 정확도를 향상시킬 수 있으며, 데이터를 한번 나눌 때보다 더 일반화된 결과를 얻을 수 있다 (Arlot & Celisse, 2010). k-겹 교차검증은 [그림 2-23]과 같이 데이터셋을 k개로 나눈 후, k-1개는 학습에 사용하고 1개는 평가에 사용한다. 이를 번갈아 반복하여 학습 및 평가를 하고 각 모델의 성능을 평균하여 최종 성능으로 산출한다.



[그림 2-23] k-겹 교차검증 예시

2.5 과대표본화

분류 문제에서 이상적인 데이터는 분류하고자 하는 범주의 분포가 균일해야 한다. 일반적인 기계학습 알고리즘은 각 범주의 비율이 비슷한 상황을 가정하기 때문에 분포가 불균형한 경우 제대로 학습하지 못하고 다수를 차지하는 범주에 편향이 발생한다(손민재 등, 2019). 사고 발생을 예측하기 위한 분류 모델의 경우, 사고가 발생하지 않은 사업장의 수가 사고가 발생한 사업장의 수에 비해 훨씬 많기 때문에, 기계학습을 하는 경우 사고가 발생하지 않은 사업장 중심으로 편향이 발생하여 사고 발생 사업장에 대한 특징을 학습하지 못하게 된다. 질병 진단, 금융사기 탐지 등 현실에서 분류가 필요한 많은 문제에서 이런 문제가 발생한다.


불균형 데이터를 해결하기 위해 주로 사용되는 방법은 샘플링(Sampling) 방법이

다. 다수 범주 또는 소수 범주의 표본의 수를 조정하여 균형을 가지도록 한다. 어떤 범주의 개수를 조정하는지에 따라서 과소표본화(Under-sampling)와 과대표본화(Over-sampling)로 나뉜다. 과소표본화는 다수 범주의 수를 소수 범주의 수에 맞도록 샘플을 제거하여 조정한다. 임의의 표본을 제거하는 무작위 과소표본화(Random under-sampling), 다수 범주에서 독립적인 부분 집합을 만들어 소수 범주와 학습 시키는 EasyEnsembler 등의 기법이 있다. 그러나 과소표본화는 정보의 손실을 초래하므로, 데이터의 수가 적은 경우 많이 사용되지 않는다.

과대표본화는 소수 범주의 표본을 새로 생성하여 다수 범주의 개수와 맞추는 방식이다. 임의로 표본을 생성하는 무작위 과대표본화(Random over-sampling), k-최근접 이웃(k-nearest neighbors) 알고리즘을 활용하여 기존의 표본들 사이에 새로운 데이터를 합성하여 생성하는 SMOTE(Synthetic minority over-sampling technique), ADASYN 등이 있다.

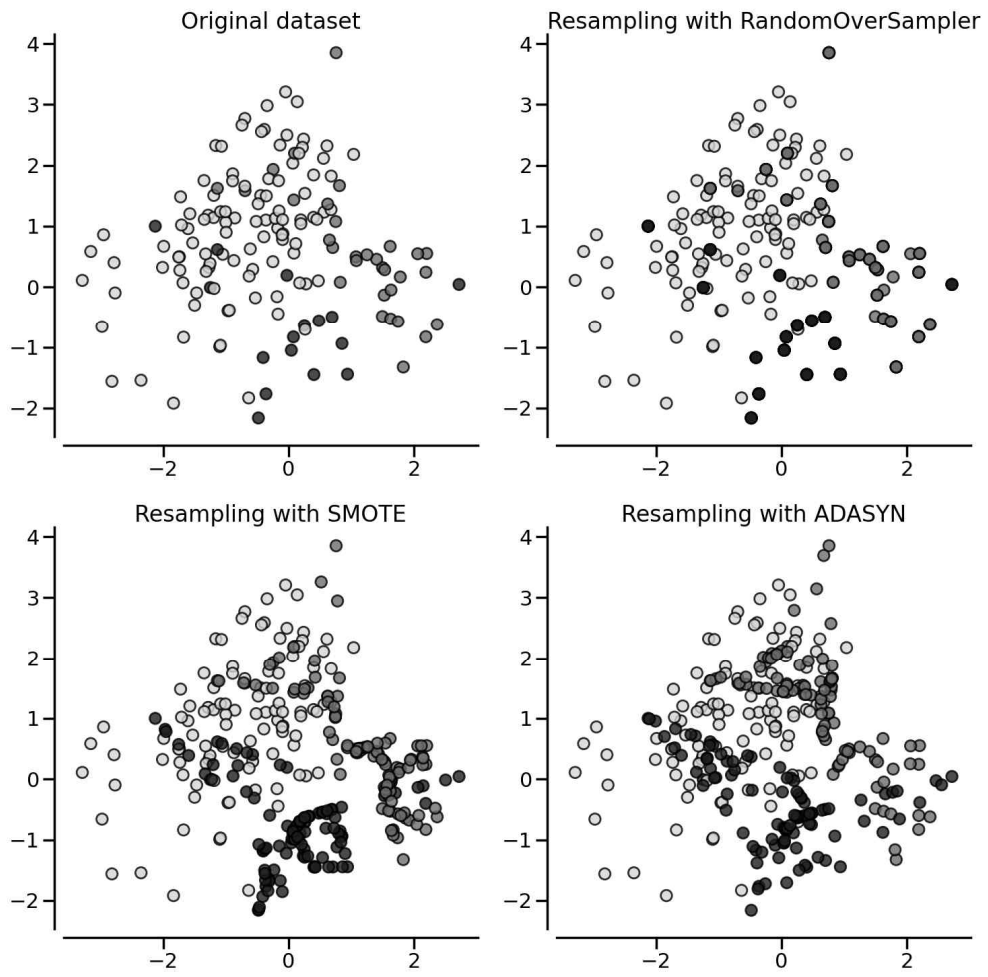
SMOTE의 절차는 [그림 2-24]와 같이 소수 범주에 속하는 표본 x_i 에 대해서 k-최근접 이웃을 계산하고, 최근접 이웃(\hat{x}_j)과 x_i 와의 유클리디안 거리(Euclidean distance)를 계산한다. 그리고 계산한 유클리디안 거리에 [0, 1]사이의 임의의 값을 곱하여 식 (2-19)와 같이 새로운 표본을 만들어 표본에 추가한다.

$$x_{new} = x_i + (\hat{x}_j - x_i) \times \delta, \quad \delta \in [0, 1] \quad (2-19)$$



[그림 2-24] SMOTE의 표본 생성 방법 (He & Garcia, 2009)

ADASYN은 SMOTE에서 발생하는 과도한 일반화 문제를 해결하기 위해서 주위 데이터의 분포에 따라 새로운 데이터의 생성을 보다 체계적으로 조절하는 방법이다. [그림 2-25]는 과대표본화 기법에 따라 생성되는 데이터 분포의 차이를 보여준다.



[그림 2-25] 과대표본화 기법의 차이 예시 (<https://www.imbalance-learn.org>)

3. 산업안전 분야의 기계학습 적용 방안

3.1 산업안전 관리 방법

산업안전보건법 제2조 정의에 따르면 ‘산업재해’란 노무를 제공하는 사람이 업무에 관계되는 건설물·설비·원재료·가스·증기·분진 등에 의하거나 작업 또는 그 밖의 업무로 인하여 사망 또는 부상하거나 질병에 걸리는 것을 의미한다. 이에 따라 산업안전은 산업재해 중 사고로 인하여 사망 또는 부상으로부터 노동자를 보호하는 것을 말한다고 할 수 있다.

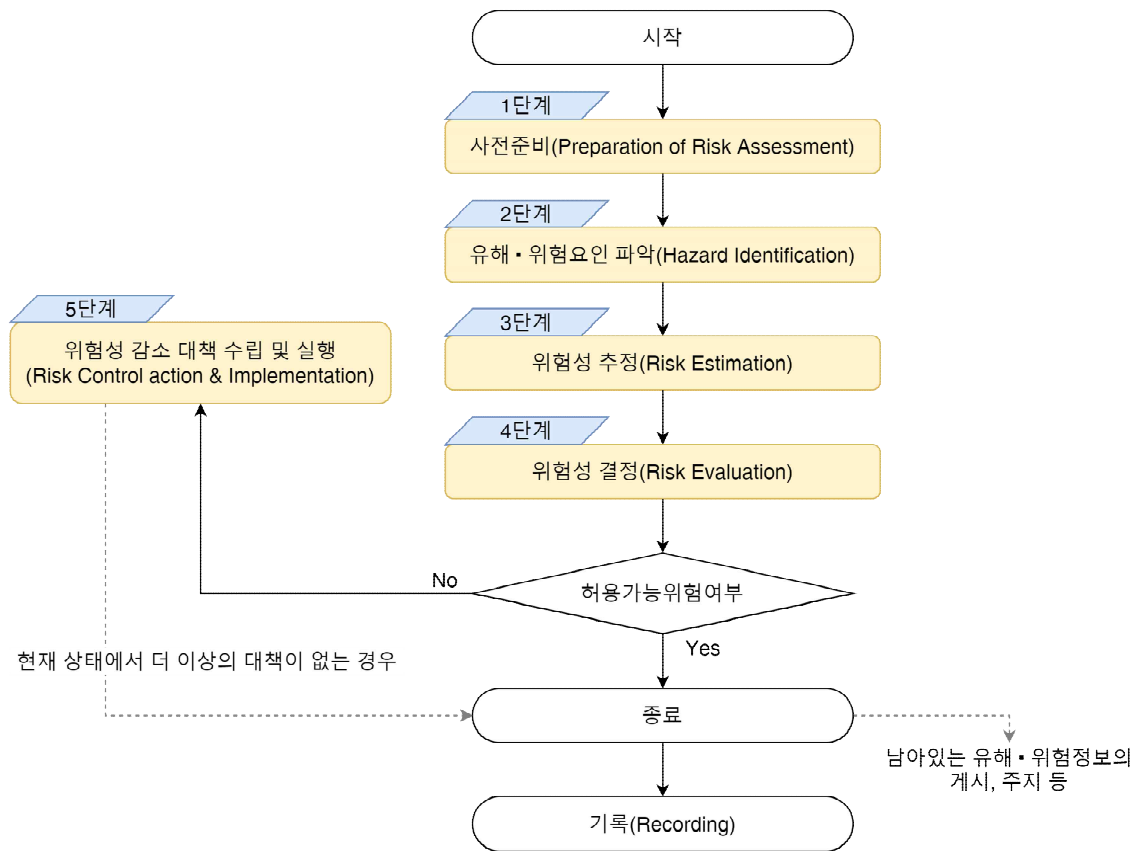
우리나라의 산업안전 관리에 대해 주체별로 보면, 정책은 크게 고용노동부, 한국산업안전보건공단, 민간 재해예방기관을 통해 이행된다. 고용노동부는 법 및 기준의 수립, 사업장 감독 집행을 수행하고, 한국산업안전보건공단은 산업재해 예방을 위해 안전점검, 기술지원, 재정지원, 안전인증, 자료개발, 홍보, 통계생산, 교육, 연구 등의 사업을 한다. 민간 재해예방기관은 안전관리 위탁, 컨설팅 등의 역할을 하고 있다. 사업주는 사업장의 산업안전의 책무를 다하기 위해 재해 방지를 위한 안전조치, 안전보건관리책임자, 안전관리자 선임 등 안전관리 체계의 구축, 안전보건 교육 실시, 사업장의 안전에 관한 정보 제공 등을 해야 한다. 특히 위험성평가를 실시하여 사업장의 유해·위험요인을 파악, 위험성을 결정한 후, 해당 위험에 대한 감소대책을 수립하고 실행해야 한다. 노동자는 법, 기준을 잘 준수하고, 사업주 및 정부 관계자가 실시하는 산업재해 예방에 관한 조치에 따라야 한다.

정부의 산업안전 정책의 가장 강력한 수단은 감독, 안전점검이다. 안전점검은 산업재해의 감소와 법 준수에 영향이 있으며(Andersen et al., 2019), 고용노동부 감독이 이루어진 사업장은 산업재해율이 감소추세에 있는 것으로 보고되었다(김영선 등, 2016). 산재 사망사고를 감축하기 위해서 2019년 하반기부터 한국산업안전보건공단의 안전점검과 고용노동부의 산업안전 감독을 연계하는 패트룰 점검을 건설업을 중심으로 집중 시행하고 있는데, 이러한 패트룰 점검은 2019년 사망자수를 27명 감소한 것으로 추정되고 있다(정재휘 등, 2020). 그러나 산업안전 규제기관의 감독, 안전점검 등의 효과는 수행자, 점검방법 등에 따라 차이가 있다(Soriano-Serrano et al., 2020). 그중 중요한 것은 점검 대상을 잘 선정하는 것이다. 점검 대상을 선정하는 방법으로 가장 간단한 방법은 모든 사업장을 대상으로 하거나 무작위로 사업장을 추출하는 방법이다. 경제적인 측면을 고려했을 때, 이러한 방법은 효과가 없는 것으로 나타났다(Blanc, 2013). 따라서 대부분의 감독기관은 위험 수준을 기준으로 사업장을 선택하는 방식을 사용한다(Dahl, 2019).

영국의 산업안전보건법을 포함한 산업안전 체계를 만든 로벤스 보고서는 산재사고 통계나 기업의 정보 등 관련된 모든 데이터를 분석하여 위험성이 높은 사업장에 대해서 점검 대상 선정의 우선순위를 높이라고 권고하고 있다(Robens, 1972). 그리고 OECD는 규제 정책을 위한 감독 대상의 선정을 위해서는 위험성 분석과 평가가 기본적으로 실행되어야 한다고 발표하였다(OECD, 2014). 이러한 방법을 사용하려면

데이터 분석이 필요한데, 대부분의 국가에서는 산업재해의 통계자료를 바탕으로 위험성을 분석하여 점검 대상을 결정하고 있다. 미국의 Cal/OSHA는 산재통계 자료에 근거하여 재해율이 높은 산업에서 10인 이상의 사업장을 무작위 추출하여 감독한 결과, 연간 재해자수를 9.4% 감소시켰으며, 낮은 재해율이 몇 년간 지속된 것으로 나타났다(Levine et al., 2012). 우리나라의 패트를 점검도 이와 유사하게 사고사망만 인율이 높은 중소기업 건설현장을 중심으로 무작위 점검을 진행하였다. 그러나 위험 수준을 기준으로 하는 접근 방식의 적용을 위해 만들어진 정밀한 위험분석 방법론은 여전히 부족한 실정이다(Mischke et al., 2013).

사업장에서 실시하는 위험성평가는 정부의 획일적인 규제 방식이 아닌 사업장의 자율적인 안전관리 체계로 전환하기 위해 2012년에 국내에 도입되었다. 위험성평가의 절차는 [그림 3-1]과 같다.



[그림 3-1] 위험성평가 절차 (사업장 위험성평가에 관한 지침[고용노동부고시 제2020-53호])

사전준비는 위험성평가 실시계획서를 작성하고, 자료를 수집하는 것이다. 다음으로 자체 점검 등을 통해 사업장 내에 잠재되어 있는 유해요인과 위험요인을 파악한다. 그리고 해당 요인별로 사고 발생 가능성, 중대성 등을 추정하여 위험성을 결정하고, 그 결과에 따라 사업장별로 설정한 허용가능 기준과 비교하여 추정된 위험성의 크기가 허용 가능한지를 판단한다. 허용이 불가능한 위험성은 합리적으로 실천

가능한 범위 내에서 가능한 낮은 수준으로 감소시키기 위한 대책을 수립하고 실행하여야 한다. 마지막으로 남아있는 위험성에 대해서 작업자에게 위험정보를 알려야 한다.

위험성평가에서 사업장에 있는 모든 유해·위험요인을 찾아내는 것이 가장 중요하다. 모든 유해·위험요인을 찾기 위해서는 현장의 유해·위험요인과 관련한 자료를 최대한 수집하여 활용하여야 한다. 유해·위험요인을 파악하는 방법으로는 관리자가 작업을 잘 관찰하거나, 작업자와 면담을 통해 조사하는 방법 등이 있다. 또한, 위험하다고 알려진 작업환경(기계설비, 사용 화학물질, 작업방법, 작업장소 등)이나 사고 발생형태 등으로부터 위험성을 파악하여 유해·위험요인을 찾아가는 방법도 있다. 이를 위해서는 충분한 자료의 분석과 정보가 필요하다. 한편, 정부에서 집행하는 감독, 안전점검 역시 사업장의 유해·위험요인을 파악하는 것이다. 위험성이 높은 사업장에 대해 감독, 안전점검을 통해서 사업장의 유해·위험요인을 확인하고 이에 대한 필요한 조치(처벌, 계도 등)를 하게 된다.

위험성평가는 위험성을 감소시키는데 효과적인 수단으로 주요 선진국에서는 필수적으로 사용되고 있으나, 수많은 위험성을 찾고 위험성을 추정·결정하기 위해서는 복잡하고 많은 정보를 분석해야 하므로 상당한 노력과 비용이 수반된다(Guzman et al., 2016).


3.2 기계학습 적용 사례 및 선행연구

기계학습은 데이터를 분석하여 맞춤형 서비스를 제공하거나 예측예방 시스템을 구축하는 데 널리 사용되고 있다. 특히 딥러닝은 방대한 데이터를 분석하여 고수준 특징(High-level feature)을 학습하여 차이점을 찾고 유사점을 분류해야 하는 이미지 및 영상, 언어 처리에서 강점을 보이고 있다.

국내외에서 다양한 산업에 기계학습이 적용되고 있으며 공공영역에도 확대되고 있다. 기계학습을 통한 맞춤형 서비스는 데이터를 분석하여 마케팅, 금융, 교육 분야에서 많이 활용되고 있다. 넷플릭스(Netflix), 유튜브(YouTube)는 사용자가 관심이 있을 만한 영상을 추천해주고, 아마존(Amazon)은 고객 맞춤형 책 추천서비스를 통해 매출의 상당부분을 올리고 있다. 예측예방 시스템은 앞으로 일어날 일을 예측하거나 비정상 상황을 예방하는 것으로, 보건복지부에서는 사회보장 데이터와 전기·가스 데이터 등을 연계하여 기계학습을 통해 복지 사각지대의 발굴에 활용하였다. 미국 네바다주에서는 식중독 예방을 위한 위생검사 대상 선정에 인공지능을 도입하여 문제 식당의 발견 비율을 9%에서 15%로 향상하기도 하였다(이상길, 2018). 미국 뉴욕시 소방청은 건축물의 화재·부상사고 데이터, 건축물의 위치와 인접한 건물의 수, 세금·보건위생 관련법 위반 내역 등의 자료를 활용하여 건축물 화재 위험도 예측 모델을 구축하였으며 2017년 분석결과 화재 위험이 높은 건축물 예측의 정확도를 20% 이상 높였다(행정안전부, 2020). 일본 히타치에서는 범죄통계, 소셜 미디어, 순찰기록 등으로 범죄를 예측하는 분석 플랫폼을 만들었다.



(a) 위생검사 대상 식당 선정



(b) 일본 범죄 예측 플랫폼

[그림 3-2] 기계학습 적용 사례

산업안전을 포함하여 위험성평가를 지원하기 위해 기계학습을 활용하여 위험성을 분석하고 평가하기 위한 연구는 지속적으로 증가하고 있다. Guzman et al.(2016)은 중요 인프라에 대한 위험성평가에 기존의 전문가 시스템(Expert system), 인공신경망 등을 적용하여 비교한 결과, 인공신경망을 결합한 방법이 위험성의 추정에 가장 좋은 선택이라고 하였다. Hegde et al.(2020)은 다양한 분야에서 위험성평가를 위해 기계학습을 적용한 연구논문 124편을 분석하였다. 연구결과에 따르면, 자동차 산업에서 위험성평가에 기계학습을 적용한 사례가 가장 많았으며, 인공신경망이 가장 많이 사용한 알고리즘이고 다음으로는 SVM이 선택되었다. 그리고 위험성평가의 단계 중에서는 유해·위험요인의 파악을 지원하기 위한 연구가 가장 많이 수행되었다.

산업안전 분야에서는 기계학습을 적용하여, 사고를 분석하여 위험을 예측하려는 연구와 딥러닝 등을 사용하여 이미지, 영상을 통해 위험요인을 찾아 안전관리를 향상하려는 연구가 많이 수행되었다.

사고를 분석한 연구는 안전관리를 위해 통계 자료, 사업장 정보 등을 활용하여 피해 규모, 사고 유형을 예측하거나 위험요인을 파악하는 것이다.

Tixier et al.(2016)은 470여 개소의 건설 현장에서 수집한 4,398건의 사고 리포트에 있는 78개 항목의 구조화된 데이터셋을 이용하여, Random Forest와 Stochastic Gradient Tree Boosting(SGTB)을 이용하여 사고의 발생확률을 예측하고자 하였다. 사용한 항목은 사고 장소, 작업, 불안정한 행위 등의 정보이며, 사고의 에너지원, 발생형태, 부상부위, 사고 심각도를 결과 값으로 사용하였다. 예측 모델의 평가는 Rank Probability Skill Score (RPSS)를 사용하였다.

Sarkar et al.(2019)은 사고 데이터를 SVM과 인공신경망에 적용하여 부상, 아차사고, 재산상 손실을 예측하고자 하였다. 사고 데이터는 2010년부터 2013년까지의 인도의 철강회사에서 수집된 1,500여개를 사용하였다. 데이터셋은 사고일자, 사고발생월, 사고형태, 기계상태 등의 범주형 데이터 위주의 16개로 구성되어 있다. 카이제곱 검정으로 도출한 중요도는 발생형태, 종사자지위 등이 가장 중요한 변수로 나타났다. 예측결과로부터 사고 등의 핵심 원인 식별을 위한 9가지 규칙을 제안하였다.

Poh et al.(2018)은 기계학습을 적용하여 건설현장의 위험을 분류할 수 있는 안전

선행지표를 개발하고자 하였다. 2010년부터 2016년까지의 27개 건설 현장으로부터 785개의 안전점검 결과, 418개 사고사례 등을 수집하였다. 항목은 공사유형, 공사금액, 건설기계 상태, 비계, 떨어짐 위험/개구부 등이며, 결과값은 사고 없음, 경미한 사고, 중대사고 등을 사용하였다. 기계학습 알고리즘은 의사결정나무, Random Forest, SVM 등의 5가지를 사용하였고, 정확도, 정밀도, 재현율로 모델의 성능을 평가하였다. 불균형 데이터 문제는 SMOTE를 사용하였다. 학습 및 평가 결과 Random Forest가 정확도 0.78로 가장 높은 것으로 나타났다.

Choi et al.(2020)은 2011년부터 2016년까지의 건설 산업재해자 140,169명의 데이터를 로지스틱 회귀분석, 클러스터 분석, 의사결정나무, Random Forest, AdaBoost를 사용하여 부상과 사망 발생을 예측하고자 하였다. 데이터셋은 재해자 연령, 성별, 근속연수, 공사유형, 고용규모 등의 항목으로 구성되어 있다. 부상자와 사망자의 데이터 불균형 문제 해결을 위해 무작위 과대표본화를 적용하였다. 예측모델의 평가는 ROC-AUC를 사용하였다. 로지스틱 회귀분석 결과 중대재해와 성별, 고용규모, 근속연수, 발생월, 발생요일이 유의미한 요소로 도출되었다. 예측모델 중 Random Forest를 적용하였을 때, ROC-AUC가 0.920으로 가장 높게 나타났다.

Zhu et al.(2021)은 건설사고의 심각도 예측을 위해 기계학습 기법을 사용하였다. 데이터는 571개의 건설사고를 수집하였다. 이전 연구로부터 사고원인으로 분류된 안전부서, 안전전문가, 위험관리, 안전문화 등 16개의 항목을 사용하였다. 결과는 사고의 크기(사망자 수)를 사용하였다. 기계학습 알고리즘은 로지스틱 회귀분석, 의사결정나무, SVM, Naive-Bayes, Random Forest, MLP, AutoML 등 8가지를 사용하였다. SMOTE를 적용하였으며, 10겹 교차검증과 F1-score를 사용하여 모델을 평가하였다. 로지스틱 회귀분석과 AutoML의 F1-score가 0.8, 0.844로 가장 높게 나타났다. Random Forest로부터 도출한 중요도는 사고 유형, 안전감독, 계약 순으로 나타났다.

딥러닝을 사용한 연구는 이미지, 영상으로부터 물체 탐지를 통해 안전 기준을 준수하는지, 안전에 문제가 있는 결함이 존재하는지에 대한 연구가 많이 수행되었다.

Fang et al.(2018)은 고소작업자의 추락방지를 위해 SSD 알고리즘을 사용하여 안전모, 안전대 등 개인보호구 착용을 감지하였다. 다양한 상황을 고려하여 2만 여장의 이미지를 학습하여, 0.9 이상의 평균 정밀도와 재현율의 성능을 보였다.

박상윤 등(2019)은 건설현장의 안전모 착용 감지를 위해, R-FCN의 알고리즘과 전이학습기법을 적용하여 딥러닝 모델을 제안하였다. ImageNet에서 수집한 사람과 안전모가 포함된 1,089장의 이미지를 사용하여 학습을 진행하였다. 사람과 안전모의 mAP는 각각 0.86, 0.83으로 측정되었다.

Zhao et al.(2019)은 YOLO v3 알고리즘을 사용하여 안전모, 안전조끼의 착용여부를 탐지하고, Kalman filter 등을 사용하여 보행자의 궤적을 추적하였다. mAP는 0.89의 성능을 보였으며, FPS는 18로 나타났다.

김명호 등(2019)은 Inception-v2와 ResNet-101 네트워크를 적용한 Faster R-CNN의 알고리즘을 사용하여 안전모 착용 상태 인식모델을 제안하였다. 직접 및 ImageNet에서 수집한 이미지 2,260장을 데이터셋으로 구축하여 학습 및 평가에 사

용하였다. mAP는 0.930, 0.936으로 나타났으며 FPS는 각각 6.3, 2.3으로 나타났다.

Perez et al.(2019)은 CNN 기반의 VGG-16 네트워크와 2,622장의 데이터셋을 사용하여 건물 벽의 습기에 의한 결함을 0.84 이상의 F1-score로 검출하였다.

Nath et al.(2020)은 건설현장의 사망사고예방을 위해 개인보호구(안전모, 조끼)의 착용여부를 인식하고자 하였다. 이를 위해 YOLO 아키텍처를 기반으로 작업자, 안전모, 조끼를 인식하고, 분류기를 통해 착용여부를 검증하였다. 첫 번째는 신경망, 의사결정나무 등의 분류기를 적용하였고, 두 번째는 단일 아키텍처만을 사용하였다. 세 번째는 작업자만을 감지한 후 잘라서 CNN 기반 분류기(VGG-16, ResNet-50 등)를 적용하여 분류하였다. 학습에는 약 1,500개의 이미지를 사용하였으며, 그 결과 단일 아키텍처를 사용한 경우가 mAP 72.3의 최고 성능으로, 초당 11 프레임을 처리할 수 있는 것으로 나타났다. 첫 번째 방법은 mAP 63.1에 초당 13 프레임으로 가장 빠르고, 세 번째 방법은 mAP가 67.93으로 나타났다.

3.3 기계학습 적용 방향

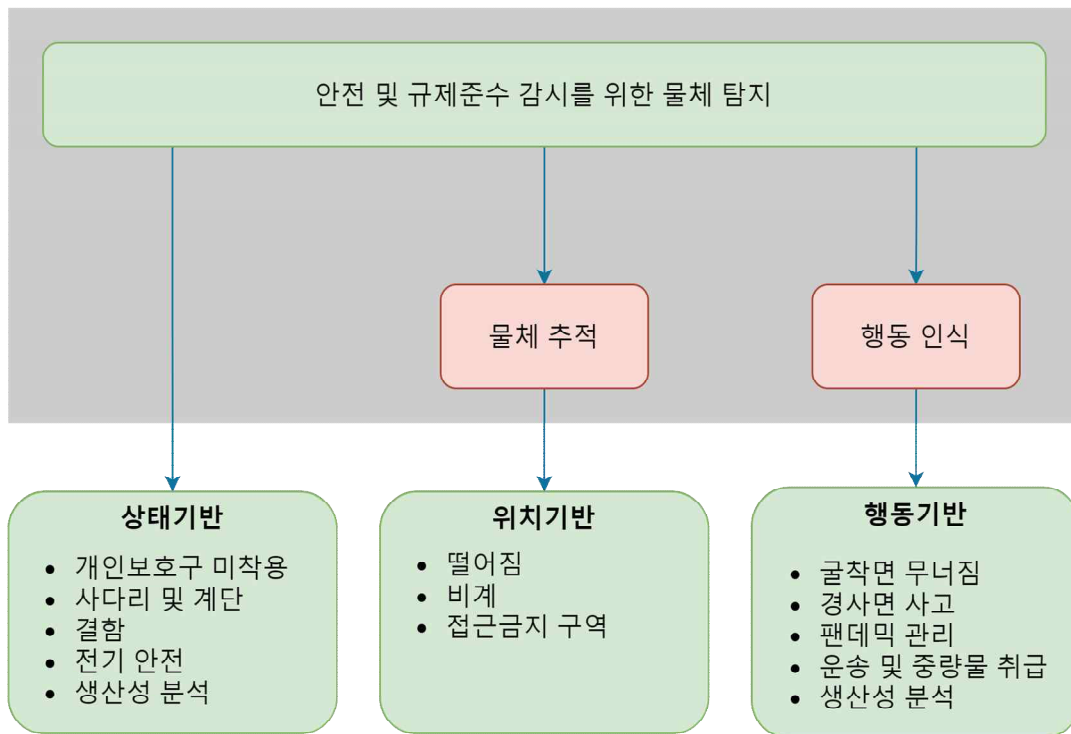
수백만 개의 사업장 중에서 위험성이 높은 사업장을 찾아내는 것은 매우 어려운 일이다. 또한 사업장에서 실시하는 위험성평가에서 잠재되어 있는 위험요인을 파악하고 위험성을 추정·결정하는 것은 대부분 평가자의 경험과 지식에 의존하여 정성적으로 이루어진다. 이에 따라 위험성을 분석하고 예측할 수 있는 체계적인 방법이 필요하다. 이렇게 많은 데이터에서 특징을 찾아내고 관계를 파악해야 하는 문제를 해결하는 것은 기계학습이 효과적으로 능력을 발휘할 수 있는 분야이다.

노르웨이 노동감독청(Norwegian Labour Inspection Authority; NLIA)은 사업장 감독을 위한 예측도구 RGPT(Risk Group Prediction)를 구축하였다(Dahl et al., 2018). RGPT는 이항 로지스틱 회귀분석(Binary logistic regression analysis) 알고리즘을 사용하여 사업장별로 위험성에 대한 확률을 예측하고, 사업장을 위험성에 따라 4개의 그룹으로 분류하였다. RGPT는 35,000건의 감독을 통해 도출된 기업 규모, 업종, 감독 횟수, 감독 내용, 산업재해 내용 등으로 구성되어 있다. RGPT의 적용 결과 위험성이 높은 그룹에 속하는 사업장을 비교적 정확히 예측하는 것으로 나타났다. 이와 유사한 접근 방법으로 여러 유럽 국가에서도 시험 운용되고 있다(Ridemar, 2018; Jacobusse & Veenman, 2016).

3.2절의 선행연구나 사례 등을 볼 때, 대부분 기존의 방법과 동일한 산재통계와 같은 사후적(Reactive) 정보 중심으로 데이터를 구성하여 기계학습에 사용하는 경우가 많다. 물론 과거의 사고는 미래 사고를 예방하기 위한 기반이라고 하였다(Goh & Ubeynarayana, 2017). 사후적 정보는 사고의 결과인 발생형태, 근로손실일수, 발생일 등의 세부적인 자료를 제공한다. 사고 결과는 후속 조치, 보상처리 등으로 인하여 사후적 정보는 관심이 매우 높아 비교적 자세하게 수집되어 왔다. 그리고 사고에 따라 원인을 찾기 위한 분석 보고서 등을 통해 더욱 상세한 자료를 수집할 수도 있으나 근본적인 원인을 찾는 데에는 한계가 있다(Sarkar et al., 2020). 반면에 사고가 발생하기 이전에 얻을 수 있는 정보인 사전적(Proactive) 정보는 사업장의 일반

적인 현황부터 점검보고서, 안전 감사 결과, 교육 보고서 등 다양하다. 사전적 정보는 사고 발생 위험에 대해 효과적으로 인지할 수 있고, 의사결정권자들에게 사고를 예방하는 방안을 찾는 데 도움을 주는 선행지표로 활용될 수 있는 것으로 알려져 있다(Li et al., 2015). 또한 사업장의 경영 활동들을 포함한 다양한 사전적 정보는 내재된 위험성을 드러나게 할 수도 있을 것이다. 그러나 그동안 사전적 정보는 사후적 정보에 비해 수집이 어렵고 데이터의 양도 적어서 실태조사 등을 통해 제한적으로 분석되어 왔다. 기계학습의 발달은 다각적인 방법으로 분석하여 이전에는 발견하지 못했던 새로운 인사이트(Insight)를 찾을 수 있는 사례를 만들어왔다. 사전적 정보를 적극적으로 폭넓게 수집하여 분석한다면, 사고와 연관성이 높은 중요한 변수를 찾아내고 사업장의 위험성 파악 및 결정을 더욱 정확하게 예측할 수 있을 것이다.

산업안전 분야에 딥러닝은 이미지나 영상으로부터 위험 상황을 탐색하는 연구가 진행되고 있다. 이미지나 영상을 활용하여 사업장의 안전을 관리하는 것에 대하여 Nain et al.(2021)은 [그림 3-3]과 같은 프레임워크를 제안하였다.



[그림 3-3] 물체 탐지를 이용한 안전과 규제준수 관리 프레임워크 (Nain et al., 2021)

이미지 및 영상에 딥러닝을 적용한 연구는 크게 물체 탐지, 물체 추적, 행동 인식으로 나눌 수 있다. 상태를 확인하는 물체 탐지를 기본으로, 물체의 이동을 파악하거나 물체의 행동을 인식하여 불안정한 행동이나 기준을 지키고 있는지를 확인하는 것이다. 물체 추적이나 행동 인식은 물체 탐지의 다음 단계 기술로서, 현재 산업안전 분야에 딥러닝을 적용한 연구는 대부분 개인보호구 착용을 탐지하는 상태기반

연구가 대부분이며, 위치기반은 관련 일부 연구가 진행되어 있다. 행동 인식은 근골격계 질환에 대한 산업보건 분야에서도 시도가 되고 있다. 위치기반과 행동기반의 활용이 많지 않은 이유는 간단한 카메라를 이용해서는 물체의 깊이 등의 정확한 3차원적인 위치 파악이 어렵기 때문이다. 이에 따라 3D 카메라나 2대 이상의 카메라를 이용하는 기술이 관련 분야에서는 사용된다. 자동차 회사인 테슬라(Tesla)는 다른 회사와 달리 레이더, 라이다(LiDAR) 등을 사용하지 않고 8개의 카메라를 이용하여 3차원 형상을 구현하는 방식을 사용하고 있다. 그러나 딥러닝을 이용하여 2D 영상을 3D로 전환하는 기술도 지속적으로 개발되고 있으며, 이미지와 자연어처리를 결합한 이미지 캡셔닝(Image captioning), VQA(Visual Question Answering) 등의 새로운 기술은 산업안전 분야에도 활용 가능성이 높다. 이미지, 영상 등에 딥러닝을 적용하는 것은 작업 중 위험성을 실시간으로 모니터링 하여 산업안전 관리에 큰 도움을 줄 수 있을 것이다.

4. 이동식사다리 사고예방을 위한 물체 탐지 모델

4.1 배경

2019년 우리나라의 산업재해로 인한 사고사망자는 855명이 발생하였다. 발생형태별 현황을 보면 떨어짐 347명(40.58%), 끼임 106명(12.40%), 부딪힘 84명(9.82%) 순으로 발생하고 있다. 세부 기인물을 보면 이동식사다리 41명(4.80%), 슬레이트 지붕 35명(4.09%), 단부 32명(3.74%), 백호 30명(3.51%) 순으로 나타나고 있다. 따라서 단일 기인물 중에서는 이동식사다리가 가장 주요한 산업재해 사망사고의 원인임을 알 수 있다.

이동식사다리는 「산업안전보건기준에 관한 규칙」에 따라 통로로 사용되어야 타당하나, 간편성과 저렴한 가격으로 고정 사다리가 없거나 작업발판의 설치가 곤란한 좁은 장소에서 활용되고 있다. 건설업, 제조업, 서비스업 등 다양한 업종에서 통로로의 사용뿐만 아니라 설비의 설치·수리·점검 등 다양한 작업을 목적으로 작업발판 대신 널리 사용되고 있다.

고용노동부에서는 사망사고 감축 대책의 일환으로 2018년 말 이동식사다리를 작업발판으로 사용하는 것을 금지하고자 하였다. 이동식사다리 안전 사용 방법 등 관련 자료를 정비하고 현장 기술지도 및 산업안전 감독을 강화할 계획을 수립하고 사업장에 홍보 및 계도하였으나, 대체품이 부족하거나 비용이 많이 소요되는 등 현장에서 혼란이 커지고 비현실적 대책이라는 반발이 컸다. 이에 따라 결국 사용금지 조치를 완화하여 안전모 착용, 작업높이별 안전기준 준수, 경작업 또는 협소한 장소 등에서만 사용 등을 담은 개선방안을 시행하였다.

이와 같이 이동식사다리는 사망사고의 위험성에도 불구하고 산업현장에서 사용할 수밖에 없다. 2014년 산업재해원인조사에 따르면 ‘계단, 사다리에서의 떨어짐’에서 31명의 사망사고가 발생하였는데, 그 중 25명(80.64%)은 안전모를 착용했다면 재해를 예방할 수 있는 것으로 조사되었다. 이동식사다리를 활용하는 작업의 작업높이가 높지 않음에도(예, 3m 이하) 추락으로 인해 사망사고의 빈도가 높은 것을 감안한다면, 이동식사다리 사용 시 노동자의 사망사고의 위험을 경감시키기 위해서는 안전모 착용이 매우 중요하다는 것을 알 수 있다. 이에 따라 이동식사다리 작업 시 노동자에게 안전모를 쓰도록 안전관리자 등이 점검을 하고 있지만, 소수 인력으로 넓은 현장을 확인하기에는 어려움이 있다. 그간 건설현장 등의 안전관리를 위해 무선통신 기술인 RFID, 지그비(Zigbee) 등을 활용하여 안전모 착용 여부를 모니터링하는 연구(장원석 등, 2009)가 진행되었으나 높은 비용, 사용상의 불편, 관리의 어려움 등으로 널리 활용되지는 않고 있다.

본 연구에서는 이동식사다리에 의한 사망사고를 줄이기 위해 이동식사다리와 관련한 중대재해 통계 분석을 통해 예방방안을 모색하고 이동식사다리 사용 노동자의 안전모 착용 여부를 자동으로 식별하는 기계학습 모형을 개발하고자 한다. 이동식사다리 관련 사망사고의 분석은 최근 10년간의 산업재해 사고사망자 중 이동식사다

리에서 발생한 재해를 대상으로 하였다. 그리고 CCTV를 이용한 이동식사다리과 안전모 착용 여부를 탐지하고자 정확성과 추론 속도를 고려하여 CNN 기반의 딥러닝 알고리즘을 사용하였다. 이동식사다리 등이 포함된 이미지 데이터를 수집하고 지도 학습을 위한 라벨링(Labeling)을 통해 데이터셋을 구축하였다. 데이터셋으로 기계학습 모형을 학습시킨 후 성능을 평가하여 현장 적용성을 확인하였다. 본 연구의 결과는 기계학습을 이용한 물체 탐지를 사용하여 현장에서 이동식사다리 작업 중 안전모 착용 여부를 쉽게 모니터링 할 수 있도록 함으로써, 산업안전 분야에 기계학습을 활용한 물체 탐지 기술의 사용 가능성의 확인과 관련 사망사고를 감소시키는 데 이바지할 수 있을 것으로 기대된다.

4.2 연구방법

4.2.1 재해통계 분석

최근 10년간(2010년~2019년)의 업무상 재해로 승인된 사고사망자 통계 자료를 바탕으로 이동식사다리에서 발생한 294명을 대상으로 사고사망 재해의 특성을 분석하였다(한국산업안전보건공단, 2010~2019). 재해 발생의 주요 특징을 분석하기 위해 업종별, 건설현장의 규모별, 공사 규모에 따른 공정률별, 사고 상병명을 분석하였다. 분석 방법은 도수분포표와 χ^2 검정을 사용하였다.

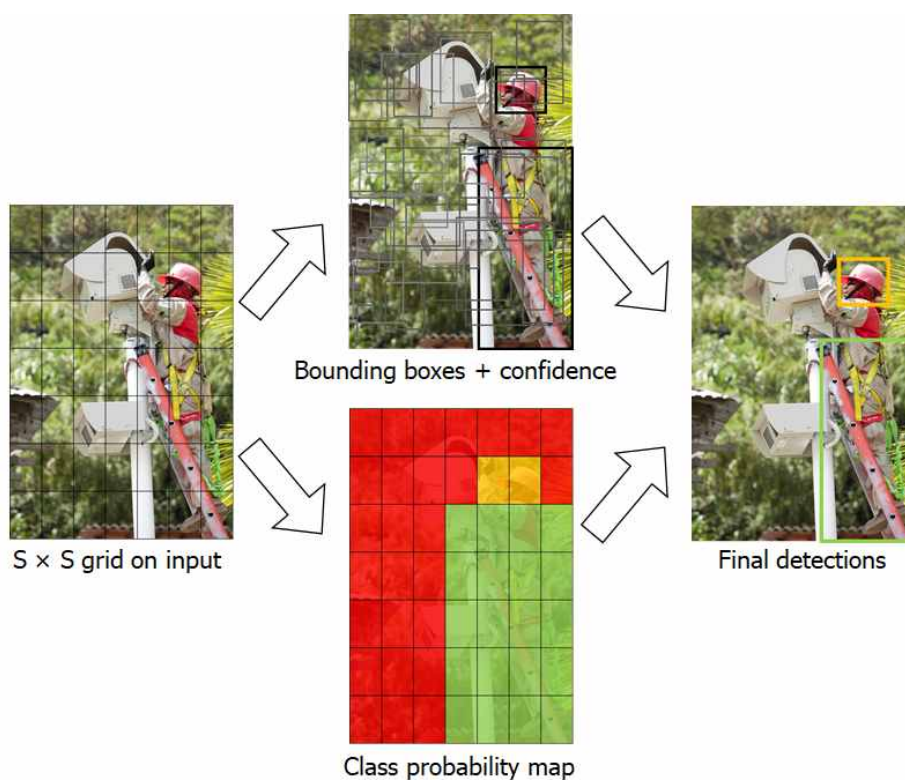
4.2.2 기계학습을 이용한 이동식사다리 및 안전모 탐지

2장에서 설명한 바와 같이 기계학습을 이용한 물체 탐지는 CNN을 기반으로 여러 알고리즘이 지속적으로 개발되었다. 본 연구에서는 물체 탐지 알고리즘 중에서 YOLO(You Only Look Once)를 사용하였다(Redmon et al., 2016). YOLO는 1단계 탐지기로 실시간에 가까운 탐지 속도를 보유하고 있어, CCTV에서 촬영된 영상에서 이동식사다리와 안전모를 실시간으로 탐지하려는 본 연구에 적합할 것으로 판단하였다. YOLO는 현재 v1~3의 버전이 있으며, 점진적으로 속도 및 정확성에서 개선되고 있다(Redmon & Farhadi, 2017). 본 연구에서는 YOLO v3를 사용하였다.

YOLO는 하나의 네트워크를 이용하여 물체의 위치와 종류를 동시에 예측하는 회귀(Regression) 문제로 물체 탐지를 한다. YOLO v1의 기본적인 작동방법은 [그림 4-1]과 같이 입력 이미지를 $S \times S$ 개의 그리드(Grid)로 분할한 후, 각 그리드에 대해 2개의 경계상자를 예측한다. 각 예측 경계상자는 물체의 위치를 표시하기 위한 위치정보(중심좌표, 크기), 경계상자 내에 물체의 존재 가능성을 나타내는 신뢰값(Confidence) $Pr(Object) * IoU$ 를 가지며, 각 그리드는 클래스에 대한 확률 $Pr(Class_i | Object)$ 을 가진다. 이를 곱하여 각 경계상자의 클래스 값을 계산한다.

$$Pr(Class_i | Object) * Pr(Object) * IoU = Pr(Class_i) * IoU \quad (4-1)$$

이를 이용하여 일정 이상의 신뢰값을 가지는 경계상자를 합하여 결과를 표시한다. YOLO v1은 실시간 탐지기로서 매우 빠른 속도를 보여주었으나, 정확도는 다른 실시간 탐지기에 비해서는 높지만 기존의 2단계 탐지기보다는 다소 부족하였다. YOLO v3는 성능을 높이기 위해 기존의 알고리즘에 여러 가지 추가적인 기법을 적용하였다. Faster R-CNN에 적용된 앵커 상자(Anchor box)의 사용, 큰 물체부터 작은 물체까지 탐지하기 위하여 3개의 다른 크기의 특징맵에 대해서 예측 수행 등을 통해 개선하였다. YOLO v1의 GoogleNet을 기반으로 하여 24개의 합성곱층과 2개의 완전연결층을 사용한 백본 네트워크(Backbone network)는 v3에 이르러서는 합성곱층을 53개로 확장하였다.



[그림 4-1] YOLO 모델의 물체 탐지 예시 (최승주 & 정기효, 2021)

4.2.3 데이터셋(Dataset)

기계학습 모델이 충분한 성능을 내기 위해서는 학습에 필요한 양질의 많은 데이터가 필요하다. 이런 데이터셋을 직접 모으기에는 시간이 매우 많이 걸리게 된다. 최근 딥러닝 기술의 급속한 발전요인에는 GPU 등의 하드웨어의 발달, 적극적인 지식의 공유와 더불어 대규모 학습 데이터의 구축 및 공개도 있다. 컴퓨터 비전 기술 연구에 활용되고 있는 대규모 공개 이미지 데이터셋은 ImageNet, Open Image, MS COCO, LVIS 등이 있다. 각 데이터셋은 물체 탐지, 의미 분할, 자세 추정(Pose estimation) 등의 다양한 문제 해결에 활용하기 위한 라벨(Label) 정보도 제공하고

있다.

본 연구에서는 이동식사다리와 안전모 착용 여부를 탐지하기 위해 해당 이미지를 분류하고 경계상자가 라벨링 되어 있는 데이터셋이 필요하다. 공개 이미지 데이터셋 중 두 가지 이미지를 정확히 제공하는 것은 없었다. Open Image의 경우, 이동식사다리는 아니더라도 사다리(Ladder)를 분류해 제공하고 있으나, 헬멧(Helmet)은 안전모보다 자전거용, 오토바이용 등이 상당부분을 차지하고 있다(Krasin et al., 2017). 이에 따라 안전모 착용 여부는 다른 연구 등에서 사용되었거나 인터넷에서 무료로 제공하고 있는 자료를 수집하여 데이터셋으로 사용하였다(Nath et al., 2020; Xie & Liangbin, 2019). 구축된 데이터셋을 나누어 학습용으로 6,023장, 모델 검증용으로 839장의 이미지를 각각 사용하였다.



[그림 4-2] 데이터셋의 예시 (Krasin et al., 2017; Xie & Liangbin 2019)


물체 탐지 모델의 성능평가 방법으로는 F1-score와 mAP를 사용하였으며, 실시간 탐지 가능성 검토를 위해서 FPS(Frames per second)로 탐지 속도를 평가하였다.

4.3 연구결과

4.3.1 이동식사다리 관련 사망재해 분석

가. 연도별 사망재해 발생 현황

연도별 이동식사다리에서의 사고사망자 발생 현황은 [그림 4-3]과 같다. 최근 10년간 294명의 사고사망자가 발생하여, 매년 약 30명이 이동식사다리에서 사고로 인해 사망하는 것으로 나타났다. 또한 최근 산재 사망사고가 지속적으로 감소하는 추세에도 불구하고 이동식사다리에서 발생한 사고사망자는 줄지 않고 있으며, 최근 2년간은 40명 이상으로 증가하였다.



[그림 4-3] 연도별 이동식사다리 사망재해 현황

나. 업종별 사망재해 발생 현황

지난 10년간 이동식사다리에서 발생한 전체 사망재해 중 63.95%가 <표 4-1>과 같이 건설업에서 발생하였다. 그 다음으로 서비스업 등 기타의 사업에서 19.05%, 제조업에서 14.29%로 나타났다. 업종에 대한 적합도 검정 결과 유의하게 나타났다 ($\chi^2(3) = 59.24, p < 0.001$). 이동식사다리의 사용이 빈번한 설치·해체, 전기공사, 조경공사 등의 건설현장과 시설관리, 도소매 등의 서비스업에서 많이 발생하고 있는 것으로 나타났다.

<표 4-1> 업종별 사망재해 현황

업종	사고사망자수 (%)
건설업	188 (63.95)
서비스업	56 (19.05)
제조업	42 (14.29)
기타업종	8 (2.72)
합계	294 (100)

다. 규모별 사망재해 발생 현황

건설현장의 공사금액별 이동식사다리 사망재해 현황을 <표 4-2>에서 살펴보면, 1억 원 미만 현장에서 78명(41.49%), 1~3억 원 미만 현장에서 29명(15.43%), 3~20억 원 미만 현장에서 35명(18.62%), 20억 원 이상 현장에서 45명(23.94%)으로 나타났다. 공사금액에 대한 적합도 검정 결과 유의한 차이가 있는 것으로 파악되었다 ($\chi^2(4) = 56.02, p < 0.001$). 이에 따라 20억 원 이상의 중대규모 이상의 현장에 비해 1억 원 미만의 소규모 현장에서 이동식사다리에 의한 사망재해가 많이 발생하는 것으로 나타나, 소규모 현장에서의 이동식사다리에 대한 안전관리가 시급함을 알 수 있다.

<표 4-2> 건설업 공사금액별 사망재해 현황

공사금액	사고사망자수 (%)
1억원 미만	78 (41.49)
1억 ~ 3억원	29 (15.43)
3억 ~ 20억원	35 (18.62)
20억 ~ 120억원	20 (10.64)
120억원 이상	25 (13.30)
분류불능	1 (0.53)
합계	188 (100)

건설업 외의 업종에서 사업장 규모별 이동식사다리 사망재해 현황을 보면, <표 4-3>과 같이 5인 미만 사업장 52명(49.06%), 5~15인 사업장 25명(23.6%), 16~49인 사업장 20명(18.87%), 50인 이상 사업장 9명(8.49%)으로 나타났다. 건설업 외 사업장

규모에 대한 적합도 검정 결과 유의하게 나타났다($\chi^2(5) = 26.97, p < 0.001$). 건설업과 마찬가지로 5인 미만의 영세 사업장에서 이동식사다리 관련 사망사고가 많이 발생하고 있는 것으로 나타났다.

<표 4-3> 건설업 외 사업장 규모별 사망재해 현황

사업장 규모	사고사망자수 (%)
5인 미만	52 (49.06)
5 ~ 9인	13 (12.26)
10 ~ 15인	12 (11.32)
16 ~ 29인	10 (9.43)
30 ~ 49인	10 (9.43)
50 인 이상	9 (8.49)
합계	106 (100)

라. 건설업 공정률별, 공사금액별 사망재해 발생 현황

건설현장의 공정률에 따른 이동식사다리 사망재해 현황을 살펴보면, <표 4-4>와 같이 공사규모에 따라 분포가 다를 수 있다. 공사금액 1억 원 미만의 건설현장은 모든 공정률에서 사망재해가 발생하고 있다. 특히 공정률 5% 미만의 공사초기에 12명, 공사완료 후에도 10명으로 다수의 사망재해가 발생하였다. 공사금액 3~20억 원 미만의 건설현장은 공정률 40~80% 미만의 공사 중간 정도에, 공사금액이 120억 원 이상인 건설현장은 공정률 80% 이상의 공사 후반에 이동식사다리에서의 사망재해가 많이 발생하는 것으로 나타났다.

일반적으로 공사금액이 작은 현장은 전기, 인테리어, 조경 등을 전문적으로 하는 공사현장이 많아, 공사 전반에 걸쳐 이동식사다리를 상시적으로 사용하기 때문에 모든 공정률에 걸쳐 사망재해가 발생하는 것으로 판단된다. 또한 공사초기 및 공사완료 시점에 이동식사다리에서 사망재해가 많이 발생하고 있으므로, 특히 안전 관리에 집중하고 주의가 필요할 것이다.


<표 4-4> 공정률별, 공사금액별 사망재해 현황

공정률	1억원 미만	1억 ~ 3억원	3억 ~ 20억원	20억 ~ 120억원	120억원 이상	분류 불능	합계
5% 미만	12	2	0	0	0	0	14
5~10%	6	3	2	2	0	0	13
10~20%	8	1	3	0	0	0	12
20~30%	9	5	2	0	0	0	16
30~40%	3	2	1	1	1	0	8
40~50%	7	4	8	3	1	0	23
50~60%	6	0	4	1	2	0	13
60~70%	6	2	3	4	1	0	16
70~80%	6	4	7	5	4	0	26
80~90%	3	1	2	1	8	0	15
90% 이상	2	5	3	2	8	0	20
공사종료 이후	10	0	0	1	0	0	11
분류불능	0	0	0	0	0	1	1
합계	78	29	35	20	25	1	188

다. 상병별 사망재해 발생 현황

이동식사다리에서 발생한 사망재해의 상병별 현황을 [그림 4-4]에서 살펴보면 상병명이 두개골 골절, 뇌출혈, 뇌손상 등 외상에 의한 두부(頭部)의 손상이 260명(88.44%)으로 이동식사다리 사망재해의 대부분을 차지하고 있다. 이동식사다리에서의 사망재해의 발생형태는 대부분 떨어짐이다. 떨어짐 사고는 인체구조의 특성으로 머리가 바닥에 부딪힐 가능성이 높는데, 이에 따라 두부에 손상이 발생하여 사망까지 이어지는 것으로 추정된다.

따라서 사고에 대비하기 위해 이동식사다리 작업 시에는 머리를 보호할 수 있는 안전모의 착용이 반드시 필요하다. 사망재해 예방을 위해 사업주는 이동식사다리 작업 시 노동자에 안전모를 지급하고 착용 관리를 실시해야 하며, 노동자는 작업 중에는 안전모 착용이 필수적이다.



[그림 4-4] 상병별 사망재해 현황

4.3.2 기계학습을 활용한 이동식사다리 및 안전모 착용 탐지

학습 모델에 대한 성능평가 결과, <표 4-5>와 같이 F1-score는 안전모 착용 여부, 사다리 등의 모든 범주에 대해서 0.852로 평가되어 적합한 것으로 나타났다. 개발된 예측 모델은 안전모 미착용이 mAP 0.951, 안전모 착용이 mAP 0.974로 안전모 착용 여부에 대해서 상대적으로 정확하게 탐지하였다. 그러나 예측 모델은 사다리를 탐지하는 성능이 mAP 0.733으로 상대적으로 낮은 것으로 파악되었다. 모든 범주에 대한 mAP는 0.886으로 나타났으며, 기존 연구 결과와 비교하였을 때, 다소 우수한 성능을 보이는 것으로 분석되었다. 안전모 착용 여부와 이동식사다리를 탐지한 것을 확인해 본 결과, [그림 4-5]와 같이 물체의 위치와 분류를 정확히 수행하는 것을 알 수 있었다.

<표 4-5> 학습용 데이터셋에 대한 모델의 성능평가

범주	F1-score	mAP
안전모 미착용	0.911	0.951
안전모 착용	0.920	0.974
사다리	0.723	0.733
모든 범주	0.852	0.886
박상윤 등, 2019	-	0.847
Nath et al., 2020	-	0.812



[그림 4-5] 탐지 성공 예시

평가용 데이터셋에 대한 결과는 <표 4-6>과 같이 대부분 정확하게 탐지하고 있지만, 사다리의 탐지 성능은 조금 부족한 것으로 나타났다. 머리에 안전모와 유사한 물체(예: 모자, 두건)를 착용하거나, 너무 원거리 또는 촬영 각도에 따라 주위 배경과 구분이 안 되는 육안으로도 식별하기 어려운 이미지에 대해서 [그림 4-6]과 같이 안전모 착용 여부에 대하여 탐지하지 못하는 경우가 있는 것으로 분석되었다. 또한, 사다리 고유의 특징인 버팀대 및 디딤대 구조와 형태가 유사한 물체(예: 세로로 또는 경사져 있는 철근 구조)가 있는 경우 [그림 4-6]의 아래와 같이 사다리의 오탐지가 발생하는 것으로 나타났다.

<표 4-6> 평가용 데이터셋에 대한 모델의 성능평가

범주	F1-score	mAP
안전모 미착용	0.856	0.946
안전모 착용	0.918	0.976
사다리	0.611	0.611
모든 범주	0.795	0.843
박상윤 등, 2019	-	0.847
Nath et al., 2020	-	0.812



[그림 4-6] 탐지 실패 예시

본 연구의 목적인 CCTV 영상에 대한 실시간 탐지 성능을 파악하기 위해 동영상 파일을 이용하여 평가하였다. 또한, 영상의 해상도에 따라 연산량이 달라지므로 다

양한 해상도를 가지는 영상파일을 이용하였다. 이에 따른 동영상에 대한 탐지 결과는 <표 4-7> 및 [그림 4-7]과 같다. CCTV 등에서 많이 사용되는 해상도인 SD(480p) 및 HD(720p)에 대해 FPS가 25이상으로 나타났다. 이러한 결과는 CCTV의 영상에서 이동식사다리와 안전모를 충분히 실시간으로 탐지할 수 있는 것을 나타낸다.

<표 4-7> 영상에 대한 물체 탐지 속도

동영상 해상도	평균 FPS
360p	38.52
480p	32.45
720p	25.37



[그림 4-7] 영상에 대한 탐지 예시

4.4 소결

이동식사다리는 거의 모든 산업현장과 일상생활에서 폭넓게 사용되고 있다. 그러나 낮은 높이와 대부분 간단한 작업이라는 인식으로 인해 이동식사다리가 산재사고의 대표적인 기인물이라는 위험성이 과소평가되고 있다. 산재통계 분석 결과, 이동식사다리에서 매년 약 30명의 산재 사망사고가 발생하고 있다. 건설업, 서비스업에서 많이 발생하고 있는데, 특히 공사금액 1억 원 미만의 소규모 건설현장, 5인 미만의 소규모 사업장에서 사망사고가 많이 발생하고 있다. 건설현장의 경우 이동식사다리의 사용이 빈번한 공사 초기 및 공사종료 시점에 사망사고가 많이 발생하는 것으로 나타났다. 이동식사다리 사망사고의 주요 상병은 외상성 두부 손상이며, 발생 형태는 대부분 떨어짐이므로, 이동식사다리의 사고예방을 위해서는 근로자가 반드시 안전모를 착용하도록 관리하여야 한다.

본 연구에서는 이동식사다리에 대한 안전 관리의 효율성, 효과성 제고를 위해 기계학습을 적용한 물체 탐지 알고리즘을 이용하여 이동식사다리 작업 시 안전모의 착용 여부를 확인할 수 있는 시스템을 제안하였다. CCTV 등을 통한 동영상에 대해서 이동식사다리, 안전모를 실시간으로 탐지하기 위해 1단 탐지기로 속도가 빠른 YOLO 알고리즘을 적용하였다.

학습에 사용한 데이터는 Open Image 등의 공개된 데이터셋을 활용하여 약 6천여 장 이미지를 사용하였다. 학습된 모델을 평가한 결과, F1-score가 0.795, mAP는 0.843로 기존의 연구와 비교할 때 유사한 것으로 나타나 학습이 충분히 효과적으로 되었음을 알 수 있다. 그러나 안전모 착용 여부에 비해 사다리의 탐지 성능은 다소 낮았는데, 학습에 사용된 사다리 데이터셋의 숫자가 상대적으로 부족하기 때문으로 사료된다. 또한, 주위 환경과 구분이 어렵거나, 사다리와 비슷한 특징을 가지는 물체 등에서 탐지 오류가 있는 것으로 나타났다. 동영상에 대한 탐지 속도는 FPS가 25 이상으로 측정되어 충분히 실시간 탐지에 적용할 수 있음을 확인하였다.

5. 건설현장의 사고사망 발생 여부 예측 모델

5.1 배경

건설현장은 업종 특성상 기후변화에 민감하고 다양한 중장비, 시설의 혼재, 위험한 가설구조 등 잠재된 근본적인 위험요인들로 인해 재해 위험이 매우 높다(Choi & Carlson, 2014; Liao & Perng, 2008). 이에 따라 세계적으로 가장 위험한 산업으로 꼽히고 있다(Chiang et al., 2018). 영국의 경우 건설업에서 안전사고에 의한 치명적 부상비율은 전체 산업대비 3배 이상 높으며, 미국도 제조업 대비 2배, 석유화학업 대비 6배 이상 높은 것으로 나타났다(최윤길 & 조근태, 2020). 한국 역시 전체 산재 사망사고의 절반 이상이 건설현장에서 발생하며, 노동자 만 명당 사고사망자수도 전 산업 대비 3.7배에 이르고 있다(고용노동부, 2020).

이러한 건설현장의 재해를 감소시키기 위해서는 위험요인을 제거하는 것이 필요하다. 산업안전보건 규제에 대하여 다양한 의견이 있으나, 감독기관의 규제와 개입은 사업장의 사망과 부상을 감소시키는데 효과가 있다. 정부는 사망사고를 줄이고 건설현장의 관리를 강화하기 위해 2019년부터 고위험 건설현장에 대하여 집중적인 안전점검 및 감독을 진행하고 있다. 그러나 전체 건설현장을 대상으로 안전점검을 지속적으로 확대하는 것은 한정된 인력과 자원으로 현실적으로 한계가 있다. 따라서 점점 효과를 극대화하기 위해 점검 대상을 선별하는 것이 필요하다. 현재 우리나라에서는 재해통계 등의 분석을 통해 도출된 위험요인과 관련한 사업장을 주요 점검 대상으로 하고 있다. 예를 들어 노후 건설기계로 인해 중대재해가 발생하면 해당 건설기계를 사용하는 건설현장을 일제 점검을 하거나 통계분석 결과 특정 공사금액 범위에서 사고사망자가 증가하면 해당 공사금액의 건설현장을 대상으로 선정하여 점검하고 있다. 이러한 방법은 사고 발생 이후의 사후적 정보만을 사용하고 있어, 사업장에서의 사망 발생 등 위험성을 선제적으로 파악하기에 어려움이 있다.

공사 착공 이전에 알 수 있는 공사 사전정보를 활용하여 사고 발생의 위험도를 예측할 수 있다면 안전점검 대상으로 선별하여 보다 효율적인 점검 계획을 수립할 수 있을 것이다. 또한, 예측된 위험도를 반영하여 건설현장의 안전관리 시스템 구축, 산업안전보건 관리비 등 투입자원을 편성하는 근거자료로도 활용할 수 있을 것이다.

본 연구는 공사 착공 전에 확인할 수 있는 사전정보를 활용하여 건설현장의 사고 사망 발생 여부를 예측하는 기계학습 모델을 개발하였다. 예측 모델은 정부의 안전 점검 대상의 우선순위를 결정하여 효과적으로 건설현장의 안전을 관리할 수 있도록 유용하게 활용될 수 있을 것으로 기대된다.

5.2 연구방법

본 연구는 기계학습의 절차에 따라 건설현장의 사고사망 발생 여부를 예측하는

모델을 개발하였다. 첫째, 기계학습을 활용한 예측 모델을 만들기 위해 1,079개의 건설현장에서 사전 정보(15종)와 사고사망 통계 데이터를 수집하고 전처리를 수행하였다. 둘째, 수집된 자료의 표본불균형을 해소하기 위해 과대표본화 기법을 적용하였다. 셋째, 예측 모델의 적합성 검증을 위해 교차검증 방법을 적용하고 성능평가 지표를 선정하였다. 넷째, 정형데이터의 분류 예측을 위한 대표적 기계학습 알고리즘인 SVM, Random Forest, XGBoost, LightGBM, AutoML을 선정하여 학습을 진행하였다. 다섯째, 초매개변수를 최적화하여 최종 성능을 도출하고 알고리즘별 성능을 비교 평가하였다. 마지막으로 구축된 예측 모델로부터 사망사고에 영향을 미치는 주요 요인을 도출하였다.


5.2.1 데이터 수집 및 전처리

본 연구는 2014년부터 2020년까지의 건설현장 중에서 아파트, 근린생활시설, 기숙사 등과 같은 대규모 건설현장을 대상으로 하여, 총 1,079개 건설현장에 대한 15종의 사전정보와 산재 사고사망자 통계자료를 수집하였다. 본 연구에서 수집한 15종의 사전정보는 건설현장의 기본적인 특징을 나타내고 수집이 용이한 건축계획서 및 건축허가 신청서 등에서 공통적으로 확인할 수 있는 정보로, <표 5-1>에 나타난 공사 및 공법 정보(공사기간, 지하층수, 지상층수, 개소, 최고높이, 굴착깊이, 공사금액, 구조, 대지면적, 건축면적, 연면적, 외부비계, 외부마감, 흙막이 벽체공법, 지지공법)를 사용하였다. 그리고 산재 사고사망자 통계자료는 각 건설현장에서의 사망사고가 발생하였는지 여부로 지도학습을 위한 라벨로 사용하였다. 산재 사고사망자는 연구 대상 건설현장 중에서 111개(전체 데이터의 10.3%)에서 발생한 것으로 나타났다.

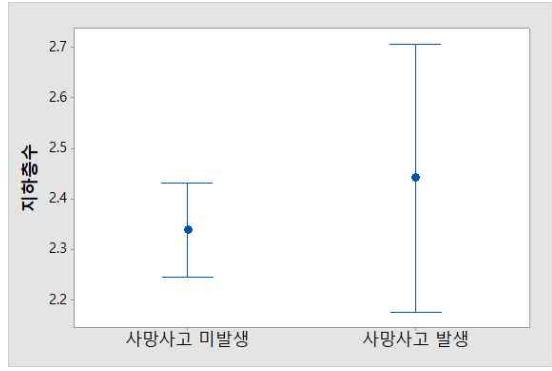
공사 사전정보(15종)에 따른 사고사망 발생 여부에 대한 자료는 [그림 5-1]과 같이 연속형 변수는 평균에 대한 95% 신뢰구간을 나타내는 구간 그림(Interval plot)으로 표시하였으며, 범주형 변수는 상위 5개 범주를 중심으로 구성 비율을 나타내는 파이 차트(Pie chart)로 표시하였다.

<표 5-1> 입력 데이터의 설명 및 형태

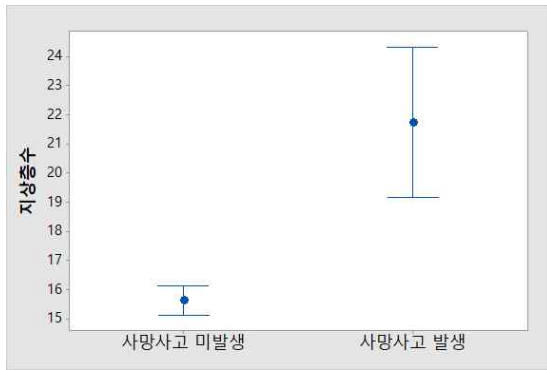
항목	설명	형태
공사기간	공사 수행기간	연속형
지하층수	지하층의 개수	연속형
지상층수	지상층을 포함한 건물의 층수	연속형
개소	건설할 건물의 총 개수	연속형
최고높이	건물의 최고 높이	연속형
굴착깊이	건설을 위해 굴착한 깊이	연속형
공사금액	건설 프로젝트의 총 비용	연속형
구조	건물 구조의 종류 (철근, 철골/철근, 철골철근, 철골철근/철근 등)	범주형 (8개 범주)
대지면적	건설현장 대지의 수평투영 면적	연속형
건축면적	건축물의 외벽 또는 기둥으로 둘러싸인 부분의 수평투영 면적	연속형
연면적	건축물 각 층의 바닥면적의 합	연속형
외부비계	외부에 설치된 비계의 종류 (강관, 시스템, 강관/시스템)	범주형 (3개 범주)
외부마감	건물 외벽 마감재 (도장/석재, 석재, 도장, 석재/패널, 패널 등)	범주형 (25개 범주)
흙막이 벽체공법	굴착면에 설치하는 벽체공법 (CIP, 토류판, 토류판/CIP, SCW, 토류판/SCW, 등)	범주형 (19개 범주)
지지공법	토사의 붕괴를 막기 위한 지지공법의 종류 (STRUT, STRUT/RAKER, EA, STRUT/EA, STRUT/EA/RAKER, 등)	범주형 (37개 범주)




(a) 공사기간




(b) 지하층수




(c) 지상층수




(d) 개소



(e) 최고높이



(f) 굴착깊이




(g) 공사금액




(h) 구조


[그림 5-1] 사망사고 발생별 데이터 분포 (계속)




(i) 대지면적




(j) 건축면적




(k) 연면적




(l) 외부비계



(m) 외부마감



(n) 흙막이 벽체공법



(o) 지지공법

[그림 5-1] 사망사고 발생별 데이터 분포

데이터는 유형을 고려하여 전처리되었다. 공사기간, 공사금액 등 연속형 정보는 데이터 간의 규모(Scale) 차이가 크기 때문에 정규화 하였다. 데이터 정규화는 기계 학습 시 변수별 영향력의 차이를 줄이고, 학습 속도를 개선하며, 지역 최적화(Local optimum)의 가능성을 줄일 수 있다(Shanker et al., 1996). 구조, 외부비계 등의 범주형 정보는 다양한 기계학습 방법에 범용적으로 적용될 수 있도록 원-핫 인코딩하였다. 마지막으로 결측치가 있는 데이터는 모두 제거(149개)하였다.

5.2.2 기계학습 모델 개발

본 연구는 건설현장의 사전정보를 이용하여 사망재해가 발생할 가능성이 높은 현장을 선별하기 위한 기계학습 기반의 예측모델을 구축하였다. 이를 위해, 본 연구에서는 사용하는 데이터의 특성에 따라 우수한 기계학습 방법이 상이하다는 기존 연구를 참고하여(Bhavsar & Ganatra, 2012), 5가지 기계학습 알고리즘(SVM, Random Forest, XGBoost, LightGBM and AutoML)의 성능을 정량적으로 비교 평가하였다.

각 기계학습 알고리즘의 초매개변수는 Optuna를 활용하여 최적화하였다(Akiba et al., 2019). 자동으로 초매개변수 최적화를 진행하는 AutoML을 제외하고 본 연구에 고려된 기계학습 알고리즘은 데이터 학습을 위해 초매개변수 설정이 필요하다. Optuna는 최적화할 초매개변수, 검색범위, 성능을 평가할 지표 등을 간단히 설정함으로써 초매개변수 최적화를 진행한다. 최적화 방법으로 베이지안 최적화의 한 형태인 TPESampler(Tree-structured Parzen Estimator Sampler)를 사용하였는데, 이전의 좋은 결과에서 가까운 위치의 값을 탐색할 수 있게 함으로써 무작위 검색보다 효율적으로 최적화를 진행한다.

본 연구에서 사용한 데이터는 사망재해의 발생빈도가 상대적으로 적은 불균형 데이터(본 연구의 사망재해는 전체 데이터의 약 10%)이다. 이에 따라 불균형 문제 해결을 위해 과대표본화 기법인 SMOTE와 ADASYN을 적용하였다. 본 연구는 사망사고 발생의 소수 데이터의 수와 사망사고 미발생의 다수 데이터의 수가 동일하게 되도록 과대표본화 비율을 1(사망사고 발생):1(사망사고 미발생)로 설정하였다.

개발한 예측 모델의 성능평가를 위해 5겹 교차검증을 사용하였다. 교차검증 시 과대표본화는 실제 데이터로만 평가하기 위해 학습에 사용할 데이터셋에만 적용하고 평가에 사용할 데이터에는 적용하지 않았다. 또한 정량적 성능 평가는 불균형 데이터임을 고려해 F1-score와 ROC 곡선 및 ROC-AUC를 적용하였다(Haixiang et al., 2017).

5.3 연구결과

5.3.1 예측 모델의 성능 비교

예측 모델의 성능 평가 결과는 <표 5-2>와 같이 교차검증에 따라 평균 및 표준편

차를 나타내었다. 데이터의 불균형 문제로 원시데이터를 학습시킨 모델의 평균 F1-Score는 0~0.181의 범위로 나타나 예측 성능이 매우 부족한 것으로 분석되었다. 과대표본화를 적용하여 학습시킨 모델은 F1-score가 기계학습 알고리즘에 따라 0.876~0.941의 범위로 나타나, 원시 데이터를 활용한 경우보다 매우 높으며 예측 성능이 충분한 것으로 분석되었다.

<표 5-2> 과대표본화 사용여부 및 알고리즘 별 F1-score

알고리즘	원시 데이터		과대표본화 적용				차이 (A-B)
			SMOTE		ADASYN		
	평균	표준편차	평균(A)	표준편차	평균(B)	표준편차	
SVM	0.181	0.054	0.876	0.019	0.904	0.014	-0.028
Random Forest	0.133	0.066	0.940	0.009	0.939	0.015	0.001
XGBoost	0.150	0.098	0.921	0.012	0.936	0.021	-0.015
LightGBM	0.067	0.084	0.940	0.010	0.941	0.013	-0.001
AutoML	0.000	-	0.913	0.021	0.927	0.019	-0.014
평균	0.106	-	0.918	-	0.929	-	-0.011

원시 데이터에서는 기계학습 알고리즘 중 SVM이 F1-score가 가장 높았으나 0.181에 불과하였다. 과대표본화 기법별로 보면, ADASYN이 SMOTE보다 성능이 다소 높게 나타났다. ADASYN의 F1-score가 기계학습 알고리즘에 따라 0.904~0.941의 범위를 보이는 반면, SMOTE의 F1-score는 0.876~0.940의 범위를 보여 ADASYN보다 평균적으로 0.011 낮은 것으로 파악되었다.

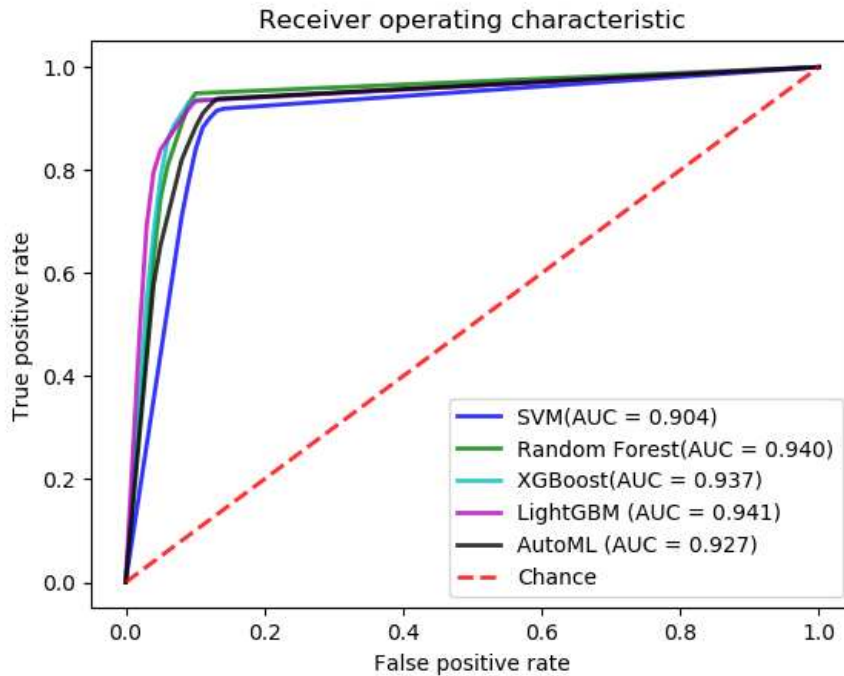
기계학습 알고리즘별로는 5가지 알고리즘 중, LightGBM이 두 가지 과대표본화 기법에서 가장 높은 F1-score를 보이는 것으로 나타나 성능이 가장 우수하였다. SMOTE 기법에서는 Random Forest와 LightGBM이 가장 높은 F1-score인 0.940로 나타났다. 한편, LightGBM은 ADASYN 기법을 사용하였을 때, 가장 우수한 성능으로 F1-score가 0.941로 나타났다.

한편 AutoML을 사용하여 구축된 모델 결과의 일부를 <표 5-3>에 나타내었다. 예측 모델의 앙상블에 사용된 주요 알고리즘으로는 Random Forest, Extra-trees, Linear Discriminant Analysis, Gaussian Naive Bayes, Stochastic Gradient Descent, Bernoulli Naive Bayes 등이다.

가장 성능이 높은 과대표본화 기법인 ADASYN을 적용한 알고리즘별 ROC 곡선은 [그림 5-2]와 같다. ROC-AUC는 기계학습 알고리즘에 0.904~0.941의 범위를 보이는 것으로 나타났는데, F1-score의 결과와 매우 유사하였다.

<표 5-3> 구축된 AutoML 모델 결과 예시

```
(0.340000, SimpleClassificationPipeline({'balancing:strategy': 'none', 'classifier:__choice__':  
'random_forest',  
'data_preprocessing:categorical_transformer:categorical_encoding:__choice__':  
'one_hot_encoding',  
'data_preprocessing:categorical_transformer:category_coalescence:__choice__':  
'minority_coalescer', 'data_preprocessing:numerical_transformer:imputation:strategy':  
'mean', 'data_preprocessing:numerical_transformer:rescaling:__choice__': 'standardize',  
'feature_preprocessor:__choice__': 'no_preprocessing', 'classifier:random_forest:bootstrap':  
'True', 'classifier:random_forest:criterion': 'gini', 'classifier:random_forest:max_depth':  
'None', 'classifier:random_forest:max_features': 0.5,  
'classifier:random_forest:max_leaf_nodes': 'None',  
'classifier:random_forest:min_impurity_decrease': 0.0,  
'classifier:random_forest:min_samples_leaf': 1, 'classifier:random_forest:min_samples_split':  
2, 'classifier:random_forest:min_weight_fraction_leaf': 0.0,  
'data_preprocessing:categorical_transformer:category_coalescence:minority_coalescer:mini  
mum_fraction': 0.01}),  
dataset_properties={  
  'task': 1,  
  'sparse': False,  
  'multilabel': False,  
  'multiclass': False,  
  'target_type': 'classification',  
  'signed': False})),  
  
:
```



[그림 5-2] ADASYN을 적용한 알고리즘별 ROC 곡선

5.3.2 공사 사전정보의 중요도 분석

과대표본화 기법을 적용한 예측 모델 중 가장 성능이 우수한 것으로 나타난 Random Forest와 LightGBM에 대해 공사 사전정보의 특성 중요도(Feature importance)를 <표 5-4>와 같이 도출하였다. 특성 중요도는 데이터가 예측 성능에 영향을 미치는 상대적 크기를 나타내는 것으로, 큰 값일수록 영향력이 크다고 해석할 수 있다. 연구에서 사용한 Random Forest는 LightGBM과 달리 중요도를 전체 합이 1이 되도록 0~1 사이의 값으로 표현하기 때문에 두 알고리즘의 중요도를 비교가 가능하도록 백분율로 환산하여 표시하였다. 지상층수는 두 기계학습 알고리즘에서 동일하게 사전정보 중 가장 중요도가 높은 것으로 나타났으나, 중요도 값은 Random Forest가 9.555%, LightGBM이 11.834%로 LightGBM에서의 영향도가 좀 더 높은 것으로 분석되었다. 공사기간, 굴착깊이, 최고높이는 두 기계학습 알고리즘에서 상위 5위 이내에 공통적으로 포함되었다. 반면, Random Forest에서 두 번째로 중요한 것으로 나타난 지하층수는 LightGBM에서는 아홉 번째로 중요한 것으로 나타났다.

특성 중요도는 의사결정나무 기반 모델에서 트리의 분할과 밀접한 관련이 있는데, 트리 분할에 얼마나 이바지하였는지를 계산하여 결정된다. 이에 따라 다른 알고리즘을 사용하거나 알고리즘의 초매개변수가 달라져도 특성 중요도는 변할 수 있다. 특히 LightGBM의 리프중심 분할 사용, Random Forest의 무작위성 등으로 두 알고리즘에서 중요도 순서가 차이가 났을 것으로 판단된다.

중요도가 높은 것으로 나타난 지상층수, 공사기간, 굴착깊이, 최고높이는 공사의 난이도와 높은 관계를 가지는 요인이다. 이는 예측 모델에 사용한 데이터가 어느 정도 안전관리를 하고 있는 대규모 건설현장에서 수집된 것이기 때문에 다소 일반적인 결과가 나왔을 것으로 사료된다.

<표 5-4> ADASYN을 적용한 2개 알고리즘별 특성 중요도

순위	Random Forest		LightGBM	
	특성	중요도	특성	중요도
1	지상층수	9.555	지상층수	11.834
2	지하층수	8.035	공사기간	10.918
3	공사기간	7.857	굴착깊이	10.550
4	최고높이	7.485	최고높이	10.071
5	굴착깊이	7.473	공사금액	9.146
6	연면적	6.852	대지면적	8.990
7	대지면적	6.537	건축면적	8.174
8	공사금액	6.521	연면적	8.131
9	건축면적	5.805	지하층수	5.575
10	개소	4.568	개소	3.573

5.4 소결

본 연구는 건설 현장의 사망재해 감소를 위해 사망재해 발생 위험 현장을 분류하는 예측 모델을 구성하고자 하였다. 이를 위해 2014년부터 2020년까지의 건설 현장의 공사기간, 지상층수, 건축면적 등 공사의 사전정보를 수집하여 활용하였다. 재해 통계 분석을 사용하는 기존의 연구와는 달리 공사 착공 전 또는 공사초기에 재해 발생 위험을 예측할 수 있도록 사전 정보를 활용하였으며, 다양한 기계학습 알고리즘의 예측 성능을 비교 평가한 결과 본 연구의 목적에 맞는 기계학습 알고리즘을 식별하여, 산업안전 분야에 기계학습의 적용 가능성을 확인하였다는 점에서 본 연구의 의의가 있다.

기계학습을 위해 수집된 데이터를 결측치의 처리, 원-핫 인코딩 등을 통해 정제하였다. 데이터의 불균형을 해소하기 위해 과대표본화 기법인 SMOTE, ADASYN을 적용하였다. 예측 모델의 성능평가를 위해 k-겹 교차검증을 적용하고 평가 척도로는 F1-score와 ROC 곡선, AUC를 사용하였다. 기계학습 알고리즘은 SVM, Random

Forest, XGBoost, LightGBM, AutoML을 사용하였고, Optuna를 이용하여 초매개변수를 최적화하여 각 알고리즘 간 성능을 비교하였다.

다른 업종에 비해 사망사고가 많이 발생하는 건설현장의 데이터를 활용하였으나, 사망사고 발생한 현장은 전체에 비해 상대적으로 소수이기 때문에 불균형 문제가 될 수밖에 없다. 본 연구에서는 사망사고 발생 현장이 10%에 불과하였다. 이러한 불균형은 기계학습에 편이(Bias)를 야기하는데, 본 연구에서는 원시 데이터에 대하여 학습시킨 예측 모델의 F1-score가 0.2 이하로 매우 낮게 나타나 적합하지 않은 것으로 파악되었다. 그러나 과대표본화 기법을 적용한 예측 모델은 F1-score가 0.88 이상으로 나타나 불균형 데이터를 효과적으로 통제할 수 있는 것으로 분석되었다. ROC-AUC와 F1-score는 매우 유사하게 나타났다. 기계학습 알고리즘 중 ADASYN을 적용한 LightGBM이 성능이 가장 우수한 것으로 파악되었다.

Random Forest와 LightGBM의 예측 모델로부터 사전정보 중에서 중요한 요인을 도출하였다. 건설현장의 사망사고를 예측하는 데에는 지상층수, 공사기간, 굴착깊이, 최고높이가 상대적으로 중요한 것으로 나타났다. 다만, Random Forest와 LightGBM은 앙상블 기법으로 예측 모델이 복잡하여 각 요인의 영향도를 정량적으로 파악하기엔 어려움이 있었다.

6. 결론 및 향후 연구방향

6.1 결론

그간 정부와 사업장의 노력 및 국민 의식의 향상으로 산업재해 지표는 좋아지고 있으나, 여전히 산업재해자수는 매년 9만 명을 넘고 사고사망만인율은 선진국에 비해 높은 수준이다. 이에 따라 정부는 사망사고를 중심으로 산업재해를 줄이기 위해 노력을 기울이고 있다. 최근 인공지능, 빅데이터 등의 첨단기술은 경제·사회 전반에 영향을 주고 있으며, 생산성 및 효율성을 증대시키기 위해 적용 범위가 점차 넓어지고 있다.

본 연구는 산업안전 분야에 기계학습 기술의 적용을 위해, 기계학습의 이론에 대한 검토와 산업안전 관리 방향을 고려하여 기계학습의 적용 방안을 제안하였다. 이에 따라 물체 탐지와 분류 예측을 사용하여 이동식사다리 작업 시 안전모 착용 탐지 및 건설현장 사전정보를 활용한 사고사망 발생 여부 예측 모델을 개발하고 성능을 분석하여 적용 가능성을 검토하였다.

산업안전 관리는 정부, 한국산업안전보건공단, 민간 재해예방기관, 사업주 등 각 주체들이 각자의 역할을 수행함으로써 이루어진다. 정부의 산업안전 정책의 가장 강력한 수단인 감독 및 안전점검을 위해서는 사업장의 위험성 수준에 따라 위험성이 높은 대상을 선정해야 한다. 또한 사업주는 자율적인 안전관리를 위해 사업장 내의 유해·위험요인을 파악하고 위험성을 추정·결정하는 위험성평가를 실시하도록 하고 있다. 이러한 위험성을 분석하기 위해서는 자료의 분석과 특징을 찾아내는 것이 필요하다.

기계학습은 많은 데이터의 분석을 통해 데이터의 관계를 파악하고 예측하는 데 널리 사용되고 있으며, 딥러닝은 이미지 및 영상을 분석하는 것에 효과적으로 적용되고 있다. 이러한 기계학습 기술은 산업안전 분야의 위험성평가, 사고의 예측 및 위험상황의 모니터링에 적용할 수 있다. 또한 기존의 사고결과 중심의 데이터를 확대하여 다양한 정보를 사용한다면 보다 정확하게 위험성을 파악할 수 있을 것이다. 그리고 개인보호구 착용 여부, 위험지역 진입 등의 불안정한 상태와 행동을 모니터링 하여 실시간 안전관리에 도움을 줄 수 있다.

기계학습의 산업안전 적용 방안에 따라 실제 현장에서의 문제에 적용함으로써 실현 가능성을 확인하고자 하였다. 이동식사다리는 산업 현장뿐만 아니라 일상생활에서도 널리 사용되고 있지만, 위험성이 높아 사망사고가 다발하는 주요 기인물이다. 산재통계 분석결과, 이동식사다리로 인해 매년 약 30명의 사고사망자가 발생하고 있다. 소규모 건설현장에서 많이 발생하고 있으며, 공사 초기와 공사 종료시점에 사망사고가 집중되고 있다. 이동식사다리에 의한 사망사고는 대부분 떨어짐으로 인한 두부의 손상으로 발생하고 있어 이동식사다리 작업 시 안전모를 반드시 착용해야 할 것이다. 이에 따라 이동식사다리 안전관리를 위해 기계학습을 이용하여 CCTV 등의 영상정보를 통한 이동식사다리 작업 시 안전모 착용을 탐지할 수 있는 모델을

개발하였다. 이동식사다리, 안전모 착용 여부에 대한 실시간 탐지를 위해 속도가 빠른 YOLO 알고리즘을 적용하였다. 모델의 성능은 F1-score와 mAP가 0.795와 0.843으로 나타났으며, 탐지속도가 25 FPS 이상으로 나타나, 개발된 모델이 이동식사다리와 안전모 착용 여부를 충분히 실시간으로 탐지할 수 있음을 확인하였다.

그리고 건설현장의 안전점검 대상 선정 등에 활용하기 위해 기계학습을 적용하여 사망사고 발생 위험현장 예측 모델을 개발하였다. 산재통계를 이용하는 기존의 방법과 달리, 공사기간, 지상층수 등 공사 사전정보를 활용하여 사고사망 발생 여부를 예측하기 위해 다양한 기계학습 알고리즘을 적용하여 비교 평가하였다. 데이터의 불균형 문제 해소를 위해 SMOTE, ADASYN의 과대표본화 기법을 적용하였다. 과대표본화 기법을 사용하지 않은 원시 데이터의 학습 모델은 F1-score가 0.2 이하로 매우 낮았으나, 과대표본화 기법을 적용한 결과 F1-score가 0.88 이상으로 나타났다. 사용한 기계학습 알고리즘 중 ADASYN을 적용한 LightGBM이 F1-score와 ROC-AUC가 각각 0.941로 예측력이 우수한 것으로 나타났다. 공사 사전정보 중 사망사고에 가장 영향을 미치는 요인은 지상층수로 나타났으며, 공사기간, 굴착깊이, 최고높이가 Random Forest와 LightGBM에서 공통적으로 중요한 요인인 것으로 나타났다.

본 연구는 산업안전 분야에 기계학습의 적용을 위해 다양한 기법과 알고리즘을 분석하여 산업안전 적용 방안을 제시하고 실제 문제 해결을 위한 기계학습 모델을 구축하였다는 점에서 의의가 있다. 기계학습 모델을 통해 위험작업 시 개인보호구 착용 여부를 실시간 탐지할 수 있었으며, 공사 사전정보를 활용한 사고사망 발생 여부를 예측할 수 있었다. 이 모델들은 현장에서 활용성을 보다 향상시켜 정부의 산재예방정책 및 사업장 안전관리에 반영한다면 우리나라의 산업현장의 사고 위험성을 낮추는데 기여할 것으로 기대된다.

6.2 향후 연구 방향

본 연구에서 개발한 이동식사다리 사고예방을 위한 물체 탐지 모델은 이동식사다리와 안전모 착용여부를 탐지할 수는 있으나, 실제 현장에서 사용하기 위해서는 안전모 미착용 상태로 이동식사다리에서 작업을 하는 행동을 검출해야 한다. 그러기 위해서는 3장에서 언급한 바와 같이 행동 인식이 필요하다. 행동 인식을 위해서는 심도까지 정확히 분석할 수 있어야 하며, 다양한 행동 시나리오를 도출하고 그에 맞는 데이터를 생성해서 학습해야 한다. 그리고 실시간 영상을 이용한 물체 탐지 시스템의 주요한 문제인 저조도, 흐릿함(Blurriness), 빛에 의한 차단(Occlusion) 등의 경우에 대한 해결도 향후 연구과제로 필요하다.

건설현장의 사고사망 발생 여부 예측 모델은 사고사망과 연관성이 높은 데이터의 수집이 필요하다. 본 연구에서도 일부 공법 정보는 사용하였지만, 많은 연구에서 사고사망과 연관성이 높다고 알려진 공종, 현장 안전관리 조직, 안전교육 여부, 안전문화 등의 다양한 데이터를 활용한 후속 연구가 필요하다. 그리고 본 연구에서 개발된 예측 모델은 사고사망의 발생 여부를 라벨로 사용했으나, 일반 사고부상 재해,

아차사고 등도 포함하여 사고발생 가능성, 사고의 크기 등을 예측할 수 있으면 정량적인 위험성평가로서 객관성을 높이는 데 도움이 될 것이다.

인공지능 분야의 세계적 석학인 앤드류 응(Andrew Ng) 교수는 인공지능 시스템의 성능을 향상시키기 위해서는 모델보다는 데이터 중심(Data centric)이 되어야 한다고 하였다. 학습을 잘 시키기 위해서 뿐만 아니라 기계학습 알고리즘이 도출해 낸 결과를 잘 활용하기 위해서도 데이터를 잘 관리해야 한다. 산업안전 분야에서 정보는 목적에 따라 주체별로 데이터를 수집하고 있기 때문에 공통으로 활용하기에는 어려운 상황이다. 건설현장의 경우는 고용노동부와 국토교통부 등에서 각각 자료를 수집하고 있는데 건설 프로젝트의 생성과 소멸을 반복하면서 산업안전과 관련하여 남아있는 정보가 거의 없을 정도로 데이터의 관리가 부족하다. 사고사망이 많이 발생하는 소규모 건설현장의 경우는 더욱 심각한 상황이다. 그리고 산업안전 특성으로 상당수의 데이터가 비구조화된 문서의 형태로 남아 있어 이를 활용하기 위한 방안을 마련해야 한다. 그러므로 산업안전 분야의 데이터를 연계·융합하여 활용하기 위해서는 범정부적인 데이터 거버넌스를 구축하여 데이터 관리 정책, 지침, 표준, 전략 및 방향을 수립하는 것이 필요하다. 재난안전 분야는 수년 전부터 재난정보의 효과적 관리와 활용에 대한 체계적 대응을 위해 정보공유 플랫폼 구축을 위한 연구가 진행되고 있다. 산업안전 분야에도 이러한 접근이 필요하다. 또한, 건강보험 등과는 달리 산업안전 분야에는 데이터를 수집할 수 있는 법적 근거가 부족하여 양질의 데이터를 모으는 데 한계가 있다. 산업안전 분야 데이터의 수집, 공유, 활성화를 위한 제도적 정비가 있어야 한다. 다양한 데이터를 활용하여 사고의 위험성에 대하여 정확히 예측할 수 있다면, 여러 산업안전 분야의 문제를 해결하여 많은 사람이 보다 안전하게 일할 수 있을 것이다.

참고문헌

- 고용노동부. (2018). 2017년도 산업재해 분석.
- 고용노동부. (2020). 2019년 산업재해 현황, <http://www.kosha.or.kr/kosha/data/industrialAccidentStatus.do>.
- 고용노동부. (2021). 2020년 산업재해 현황, http://www.moel.go.kr/policy/policydata/view.do?bbs_seq=20210401122.
- 김대영, 윤성민, 김지명, 이선용, 손기영. (2020). 해외 사례 비교를 통한 건설현장 추락재해 예방기법 개선방안, 한국건축시공학회지, 20(5), pp. 471-480.
- 김도수, 신윤석. (2019). 건설현장 추락재해의 발생 빈도에 따른 위험요인 연구, 한국건축시공학회지, 19(2), pp. 185-192.
- 김명호, 신성우, 서용윤. (2019). 건설현장 근로자의 안전모 착용 여부 검출을 위한 컴퓨터 비전 기반 딥러닝 알고리즘의 적용, 한국안전학회지, 34(6), pp. 29-37.
- 김영선, 이경용. (2016). 산재예방정책 및 예방활동이 산업재해 감소에 미치는 영향, 산업안전보건연구원 연구보고서.
- 김은미, 김상봉, 조은서. (2020). 기계학습을 활용한 주택매도 결정요인 분석 및 예측모델 구축, 지적과 국토정보, 50(1), pp. 181-200.
- 김현주. (2019). 산재예방정책의 중장기 전략 수립을 위한 연구, 산업안전보건연구원 연구보고서.
- 김형석, 이석원, 정원제, 류보혁. (2009). 이동식 사다리를 중심으로 한 제조업에서의 추락재해 예방대책 연구, 한국안전학회지, 24(6), pp. 136-143.
- 김희수, 장상철, 주진규. (2019). 건설현장 화재 발생 요인 분석에 따른 예방우선순위 연구, 한국건설안전학회지, 2(2), pp. 50~55.
- 문용혁, 신익희, 이용주, 민옥기. (2019). 자동 기계학습(AutoML) 기술 동향, 전자통신동향분석, 34(4), pp. 32-42.
- 박상윤, 윤상현, 허준. (2019). R-FCN과 Transfer Learning 기법을 이용한 영상기반 건설 안전모 자동 탐지, 대한토목학회지, 39(3), pp. 399-407.
- 박환표, 한재구. (2019). 통계자료를 활용한 건설안전 위험도 평가지수 개발, 한국건축시공학회지, 19(4), pp. 361-371.

- 산업안전보건연구원(OSHRI). (2015). 2014년 산업재해원인조사, 산업안전보건연구원 연구보고서.
- 손민재, 정승원, 황인준. (2019). 불균형 데이터 분류를 위한 딥러닝 기반 오버샘플링 기법, 정보처리학회논문지, 8(7), pp. 311-316.
- 송창섭, 권영희, 김동령, 강경식. (2013). 건설현장 사다리에서 추락재해 예방을 위한 개선방안, 2013년 대한안전경영과학회 춘계학술대회, pp. 225-234.
- 심현황, 강경식. (2017). 산업현장 사다리 관련 사망재해 분석 및 추락재해 예방대책에 관한 연구, 대한안전경영과학회지, 19(4), pp. 95-104.
- 양승수, 백신원. (2020). 건설기계작업 사망사고 예방을 위한 위험관리, 한국안전학회지, 35(3), pp. 16-23.
- 이강호, 이찬식, 구충완, 김태완. (2020). 연관규칙 기반 소규모 건설현장 사망재해 다중요인 분석, 한국건설관리학회지, 21(4), pp. 90-99.
- 이상길. (2018). 국내외 AI 활용 현황과 공공적용, ICT Spot Issue, 정보통신기술진흥센터.
- 이경용. (2014). 산업안전보건 지도감독체계 전환에 따른 효과 분석에 관한 연구, 산업안전보건연구원 연구보고서.
- 이재병. (2020). 최신 부스팅 기법에 대한 연구, 석사학위논문, 건국대학교.
- 이한솔. (2018). 사물 인식을 위한 효율적인 딥러닝 플랫폼, 석사학위논문, 송실대학교.
- 이현숙, 김중훈, 이화영, 김혜미, 정평강, 신재현, 이대식, 장혜원, 남지현, 이영호 (2019). 인공지능(AI) 활용 초등수학 수업지원시스템 개발 방안 연구. 한국과학창의재단.
- 임원준, 기정훈, 성주현, 박종일. (2019). 건설업 사고 발생원인 파악을 위한 사고 분석 모델 개발, 한국안전학회지, 34(1), pp. 45-52.
- 장원석, 신도형. (2009). 무선센서 네트워크를 이용한 건설현장 안전관리 모니터링 시스템, 한국재난관리표준학회지, 2(2), pp. 49-54.
- 장윤라, 고성석. (2018). 중·소규모 건설현장의 재해율 감소를 위한 위험성평가 방안, 한국건설관리학회지, 19(5), pp. 90-100.
- 정재민, 정재욱. (2020). 중대재해 사례에 기반한 건설업의 작업 및 위험분류체계 통합 프레임워크 개발, 한국건설관리학회지, 21(3), pp. 11-19.
- 정재휘, 이태희, 최돈승. (2020). 정부 산재예방정책이 사망사고 감축에 미치는 영향

- 분석, 산업안전보건연구원 연구보고서.
- 조윤희. (2020). 산업안전보건 데이터 통합 및 정보공개 활용 방안 연구, 산업안전보건연구원 연구보고서.
- 최수일, 김홍. (2006). 건설현장의 안전 분위기와 작업자 안전행동에 관한 실증적 연구, 한국안전학회지, 21(5), pp. 60-71.
- 최승주, 정기호. (2021). 이동식사다리 중대재해 통계분석 및 이동식사다리와 안전모 실시간 탐지 기계학습 모델 개발, 대한안전경영과학회, 23(1), pp. 9-15.
- 최윤길, 조근태. (2020). 인과지도를 활용한 건설 안전사고 원인 분석 : 안전문화 관점, 한국안전학회지, 35(2), pp. 34-46.
- 최재현, 류한국. (2019). 에이다 부스트를 활용한 건설현장 추락재해의 강도 예측과 영향요인 분석, 대한건축학회지, 35(11), pp. 155-162.
- 최정열. (2018). 기계학습 활용을 위한 학습 데이터셋 구축 표준화 방안에 관한 연구, 한국디지털정책학회, 16(10), pp. 205-212.
- 하선근, 김태희, 손기영, 김지명, 손승현. (2018). 확률론적 기법을 활용한 건설현장 외부 인명피해 정량화 모델 개발, 한국건축시공학회지, 18(2), pp. 151-159.
- 한국산업안전보건공단. 산업재해통계, 2010-2019.
- 한국지능정보사회진흥원. (2021). 인공지능 학습용 데이터 품질관리 가이드라인.
- 행정안전부. (2020). 공공분야의 인공지능 촉진 및 활성화를 위한 방안 연구.
- Akiba, T., Sano, S., Yanase, T., Ohta, T. and Koyama, M. (2019). Optuna: A Next-generation Hyperparameter Optimization Framework, KDD '19: Proc. of the 25th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, pp. 2623-2631.
- Andersen, J.H., Malmros, P., Ebbeltoft, N.E., Flachs, E. M., Bengtson, E. and Bondo, J.P. (2019). Systematic literature review on the effects of occupational safety and health (OSH) interventions at the workplace, Scandinavian Journal of Work Environment & Health, 45(2), pp. 103-113.
- Arlot, S. and Celisse, A. (2010). A survey of Cross-validation Procedures for Model Selection, Statistics surveys, 4, pp. 40-79.
- Bhavsar, H. and Ganatra, A. (2012). A Comparative Study of Training Algorithms for Supervised Machine Learning, International Journal of Soft Computing and Engineering, 2(4), pp. 2231-2307.

- Blanc, F. (2013). *Inspection reforms: why, how, and with what results*. OECD, Paris.
- Breiman, L. (2001). Random Forests, *Machine Learning*, 45, pp. 5-32.
- Burges, C.J.C. (1998). A Tutorial on Support Vector Machines for Pattern Recognition, *Data Mining and Knowledge Discovery*, 2, pp. 121-167.
- Cady, F. (2017). *The Data Science handbook*, Wiley.
- Capgemini Consulting. (2017). *Unleashing the potential of Artificial Intelligence in the Public Sector*.
- Chi, C.F., Yang, C.C. and Chen, Z.L. (2009). In-depth accident analysis of electrical fatalities in the construction industry, *International Journal of Industrial Ergonomics*, 39(4), pp. 635-644.
- Chawla, N.V., Hall, L.O., Bowyer, K.W., Hall, L.O. and Kegelmeyer, W.P. (2002). SMOTE: Synthetic Minority Over-sampling Technique, *Journal of Artificial Intelligence Research*, 16, pp. 321-357.
- Chiang, Y.H., Wong, F.K.W. and Liang, S. (2018). Fatal Construction Accidents in Hong Kong", *Journal of Construction Engineering and Management*, 144 (3), 04017121.
- Chen, T. and Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System, *KDD '16: Proceeding of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data mining*, pp. 785-794.
- Choi, J., Gu, B., Chin, S. and Lee, J.S. (2020). Machine learning predictive model based on national data for fatal accidents of construction workers, *Automation in Construction*, 110, 102974.
- Choi, S.D. and Carlson, K. (2014). Occupational Safety Issues in Residential Construction Surveyed in Wisconsin, United States, *Industrial health*, 52(6), pp. 541-547.
- Claesen, M. and Moor, B.D. (2015). Hyperparameter Search in Machine Learning, *arXiv preprint arXiv:1502.02127*.
- Dahl, Ø. (2019). The future role of big data and machine learning for health and safety inspection efficiency, *EU-OSHA*.
- Dahl, Ø., Kilskar, S.S., Skarholt, K. and Rosness, R., (2018). Risk-based labour inspections in the Nordic countries, *Nordic Council of Ministers*.

- Ertekin, S., Huang, J., Bottou, L., and Giles, L. (2007). Learning on the border: Active Learning in Imbalanced Data Classification, *CIKM '07: Proceeding of 16th ACM conference on Conference on Information and Knowledge Management*, pp. 127-136.
- Everingham, M., Gool, L.V., Williams, C.K.I., Winn, J. and Zisserman, A. (2010). The Pascal Visual Object Classes(VOC) Challenge, *International Journal of Computer Vision*, 88, pp. 303-338.
- Fang Q., Li H., Luo X., Ding L., Luo H. and Li C. (2018). Computer vision aided inspection on falling prevention measures for steeples in an aerial environment, *Automation in Construction*, 93, pp. 148-164.
- Fang, Y., Zhang, Y. and Huang, C. (2019). Credit Card Fraud Detection Based on Machine Learning, *Computers, Materials & Continua*, 61(1), pp. 185-195.
- Fawcett, T. (2006). An introduction to ROC analysis, *Pattern recognition letters*, 27(8), pp. 861-874.
- Feurer, M., Klein, A., Eggenberger, K., Springenberg, J., Blum, M. and Hutter, F. (2015). Efficient and Robust Automated Machine Learning, *Advances in Neural Information Processing Systems (NIPS 2015)*, 28, pp. 2962-2970.
- Freund, Y. and Schapire, R.E. (1995). A decision-theoretic generalization of on-line learning and an application to boosting, *Machine Learning*, 139, pp. 23-37.
- Friedman, J. H. (2001). Greedy Function Approximation: A Gradient Boosting Machine", *The Annals of Statistics*, 29, pp. 1189-1232.
- Girshick, R., Donahue, J., Darrell, T. and Malik, J. (2014). Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation, *2014 IEEE Conference on Computer Vision and Pattern Recognition*, pp. 580-587.
- Goh, Y.M. and Ubeynarayana, C.U. (2017). Construction accident narrative classification: an evaluation of text mining techniques, *Accident Analysis and Prevention*, 108, pp. 122-130.
- Gollapudi, S. (2016). *Practical Machine Learning*, Packt Publishing.
- Guzman, A., Ishida, S., Choi E. and Aoyama, A. (2016). Artificial Intelligence Improving Safety and Risk Analysis: A Comparative Analysis for Critical Infrastructure, *2016 IEEE International Conference on Industrial Engineering and*

- d Engineering Management (IEEM), pp. 471-475.
- Haixiang, G., Yijing, L., Shang, J., Mingyun, G., Yuanyue, H. and Bing, G. (2017). Learning from Class-imbalanced Data: Review of Methods and Applications," *Expert Systems with Applications*, 73, pp.220-239.
- He, H. and Garcia, E.A. (2009). Learning from imbalanced data, *IEEE Transactions on Knowledge and Data Engineering*, 21(9), pp. 1263-1284.
- He, H., Bai, Y., Garcia, E.A., and Li, S. (2008). ADASYN: Adaptive Synthetic Sampling Approach for Imbalanced Learning, 2008 IEEE International Joint Conference on Neural Networks, pp. 1322-1328.
- He, X., Zhao, K., and Chu, X. (2021). AutoML: A Survey of the State-of-the-Art, *Knowledge-Based Systems*, 212, 106622.
- Hegde, J. and Rokseth, B. (2020). Applications of machine learning methods for engineering risk assessment – A review, *Safety Science*, 122, 104492.
- ISO/IEC 25012. (2008). Software Engineering-Software product Quality Requirements and Evaluation(SQuaRE)-Data quality model.
- Jaccard, P. (1912). The Distribution of the Flora in the Alpine Zone, *New Phytologist*, 11(2), pp. 37–50.
- Jacobusse, G. and Veenman, C. (2016). On selection bias with imbalanced classes. *International Conference on Discovery Science*, Bari, pp. 325–340.
- Jocher, G., Kwon, Y., guigarfr, Veitch-Michaelis, J. et al. (2020). ultralytics/volov3: 43.1mAP@0.5:0.95 on COCO2014(version v7). Zenodo, <http://doi.org/10.5281/zenodo.3785397>.
- Ke, G., Meng, Q., Finley, T., Wang, T. and Chen, W. (2017). LightGBM: A Highly Efficient Gradient Boosting Decision Tree, *Advances in Neural Information Processing Systems (NIPS 2017)*, 30, pp. 3146-3154.
- Krasin, I., Duerig, T., Alldrin, N. et al. (2017). OpenImages: A public dataset for large-scale multi-label and multi-class image classification, <https://storage.googleapis.com/openimages/web/index.html>.
- Krizhevsky, A., Sutskever, I. and Hinton, G.E. (2012). Imagenet classification with deep convolutional neural networks, *Advances in neural information processing systems*, 25(2), 1097-1105.

- Kuznetsova, A., Rom, H., Alldrin, N. et al. (2020). The Open Images Dataset V4: Unified image classification, object detection, and visual relationship detection at scale, *International Journal of Computer Vision*, 128. pp. 1956-1981.
- Livine, D.I., Toffel, M.W. and Johnson, M.S. (2012). Randomized Government Safety Inspections Reduce Worker Injuries with No Detectable Job Loss, *Science*, 336(6083), pp. 907-911.
- Li, H., Lu, M., Hsu, S.C., Gray, M. and Huang, T. (2015). Proactive behavior-based safety management for construction safety improvement, *Safety Science*, 75, pp. 107-117.
- Liao, C.W. and Perng, Y.H. (2008). Data mining for Occupational Injuries in the Taiwan Construction Industry, *Safety Science*, 46(7), pp. 1091-1102.
- McClure, N. (2017). *TensorFlow Machine Learning Cookbook*, Packt
- Mischke, C., Verbeek, J.H., Job, J., Morata, T.C., Alvesalo-Kuusi, A., Neuvonen, K., Clarke, S., and Pedlow, R.I. (2013). Occupational safety and health enforcement tools for preventing occupational diseases and injuries, *Cochrane Database of Systematic Reviews* 2013, 8, Art. No CD010183.
- Nain, M., Sharma, S. and Chaurasia, S. (2021). Safety and Compliance Management System Using Computer Vision and Deep Learning, *IOP Conference Series: Materials Science and Engineering*, 1099(1), 012013.
- Nath, N.D., Behzadan, A.H. and Paal, S.G. (2020). "Deep learning for site safety: Real-time detection of personal protective equipment", *Automation on Construction*, 112, 103085.
- Nishimoto, T., Mukaigawa, K., Tominaga, S., Lubbe, N., Kiuchi, T., Motomura, T. and Matsumoto, H. (2017). Serious injury prediction algorithm based on large-scale data and under-triage control, *Accident Analysis & Prevention*, 98, pp. 266-276.
- OECD. (2014). *OECD Best practice principles for regulatory policy: Regulatory enforcement and inspections*. The Organisation for Economic Co-operation and Development, Paris.
- Olden, J. D., Lawler, J. J., and Poff, N. L. (2008). Machine learning methods witho

- ut tears: a primer for ecologists. *The Quarterly review of biology*, 83(2), pp. 171-193.
- Park, M.W., Elsafty, N. and Zhu, Z. (2015). Hardhat-wearing Detection for Enhancing on-site Safety of Construction Workers, *Journal of Construction Engineering and Management*, 141(9), 04015024.
- Perez H., Joseph H., Tah M. and Mosavi A. (2019). Deep learning for detecting building defects using convolutional neural networks, *Sensors*, 19(16), 3556.
- Piramuthu, S. (2008). Input data for decision trees, *Expert Systems with Applications*, 34, pp. 1220-1226.
- Poh, C.Q.X., Ubeynarayana, C.U. and Goh, Y.M. (2018). Safety leading indicators for construction sites: A machine learning approach, *Automation in Construction*, 93, pp. 375-386.
- Powers, D.M.W. (2011). Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation, *J. Machine Learning Technologies*, 2(1), pp. 37-63.
- Redmon, J., Divvala, S., Girshick, R. and Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection, *The IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, IEEE.
- Redmon, J. and Farhadi, A. (2017). "YOLO9000: Better, Faster, Stronger", *The IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, IEEE.
- Redmon, J. and Farhadi, A. (2017). "YOLOv3: An Incremental Improvement", *arXiv preprint arXiv:1804.02767*.
- Ridemar, A. (2018). Decision support for SWEA inspections. KTH Royal Institute of Technology, Stockholm.
- Robens, L. (1972). *Safety and Health at Work: Report of the Committee 1970-1972*. Her Majesty's Stationery Office, London.
- Rubaiyat, A.H.M., Toma, T.T., Khandani, M.K., et al. (2016). Automatic Detection of Helmet uses for Construction Safety, *2016 IEEE/WIC/ACM International Conference on Web Intelligence Workshops(WIW)*. IEEE, pp. 135-142.
- Samuel, A.L. (1959). *Some Studies in Machine Learning Using the Game of Checkers*. MIT Press, Cambridge, MA.

- kers. *IBM Journal of Research and Development*, 44, pp. 206-226.
- Sarkar, S., Pramanik, A., Maiti, J. and Reniers, G. (2020). "Predicting and analyzing injury severity: a machine learning-based approach using class-imbalanced proactive and reactive data, *Safety Science*, 125, 104616.
- Sarkar, S., Vinay, S., Raj, R., Maiti, J. and Mitra, P. (2019). Application of optimized machine learning techniques for prediction of occupational accidents, *Computers and Operations Research*, 106, pp. 210-224.
- Shanker, M., Hu, M.Y. and Hung, M.S. (1996). Effect of Data Standardization on Neural Network Training, *Omega*, 24(4), pp. 385-397.
- Soriano-Serrano, M. Carrillo-Castrillo, J.A., Rubio-Romero, J.C. and García-Jiménez, M. (2020). The Impact of Enforcement Capabilities on the Effectiveness of Public Assessment on Occupational Safety, *International Journal of Environmental Research and Public Health*, 17, 6426.
- Stehman, S.V. (1997). Selecting and interpreting measures of thematic classification accuracy, *Remote Sensing of Environment*, 62(1), pp. 77-89.
- Tixier, A.J.P., Hallowell, M.R., Rajagopalan, B. and Bowman, D. (2016). Application of machine learning to construction injury prediction, *Automation in Construction*, 69, pp. 102-114.
- Van Rijsbergen, C.J. (1979). *Information retrieval*. London: Butterworth and Co.
- Vapnik, V.N. (1999). *The Nature of Statistical Learning Theory*, Springer-Verlag.
- Xie, and Liangbin. (2019). *Hardhat*, <http://doi.org/10.7910/DVN/7-CBGOS>, Harvard Dataverse, V1.
- Yannis, G., Papadimitriou, E., Dupont, E. and Martensen, H. (2010). Estimation of fatality and injury risk by means of in-depth fatal accident investigation data, *Traffic Injury Prevention*, 11(5), pp. 492-502.
- Zeiler, M.D. and Fergus, R. (2013). *Visualizing and Understanding Convolutional Networks*, arXiv preprint arXiv:1311:2901.
- Zhang, W., Zhu, S., Zhang, X. and Zhao, T. (2019). Identification of Critical Cause of Construction Accidents in China using Model based on System Thinking and Cause Analysis, *Safety Science*, 121, pp. 606-618.
- Zhao Y., Chen Q., Cao W., Yang J., Xiong J. and Gui G. (2019). Deep learning fo

r risk detection and trajectory tracking at construction sites, *IEEE Access*, 7, pp. 30905-30912.

Zhu, R., Hu, X., Hou, J. and Li, X. (2021). Application of machine learning techniques for predicting the consequences of construction accidents in China, *Process Safety and Environmental Protection*, 145, pp. 293-302.

Zwerling, C., Daltroy, L.H., Fine, L.J., Johnston, J.J., Melius, J., and Silverstein, B.A. (1997). Design and Conduct of Occupational Injury Intervention Studies: A Review of Evaluation Strategies, *American Journal of Industrial Medicine*, 32, pp. 164–179.

Abstract

A Study on Application of Machine Learning for Occupational Safety

Seungju Choi

Department of Safety and Health, Graduate School
University of Ulsan

The Occupational accident rate, which reached 5% in 1960, fell to 0.57% in 2020. However, Occupational accidents have killed 882 workers in 2020. As machine learning has recently shown successful results in various fields, the use of big data and machine learning is expanding to increase efficiency throughout the industry. It is necessary to enhance safety management to reduce occupational accidents with limited resources. The purpose of this paper, therefore, is to present a plan that can be applied to occupational safety by utilizing machine learning techniques.

Safety inspections are probably the most important policy instrument that government use to ensure that companies take the necessary steps to comply with occupational safety regulations. And risk assessment shall be conducted in the workplace such as identifying potential hazards, estimating and evaluating risk. In order to make this possible, some types of data analysis are necessary. Such risk analysis are typically grounded on statistics related to occupational accidents. Machine learning is to provide a statistical model which can utilized to perform predictions, classifications, estimations or similar tasks. Therefore risk analysis based on machine learning could help in providing new insights about the characteristics and patterns by gathering various data such as proactive information. Deep learning are becoming popular because of their effectiveness in tasks related to images and videos. With object detection based on deep learning, continuous and automated monitoring of the unsafe acts can be accomplished with better accuracy.

This study evaluate the performance of two prediction model, object detection and classification according to the machine learning framework. Mobile ladders are the most common causes of fatal accidents as they are widely used in industry sites. According to statistics analysis of mobile ladders, about 30 victims occur every year, the most common at small construction sites and fatalities are concentrated at the beginning and end of construction work. Because the accidents of a mobile ladder

are caused by head damage by falling, workers on mobile ladders should wear safety helmets. To improve safety management of mobile ladder, this paper proposes a real-time detection model based YOLO algorithm which identifies whether workers wear safety helmet on mobile ladder using CCTV. It is found that the detector achieves 0.795 F1-score and 0.843 mAP, and can process 25 FPS or higher. Extensive experimental results has illustrated the effectiveness of mobile ladders and helmet wearing detection on CCTV.

To predict risk of fatalities at construction sites, machine learning model was established with proactive information such as construction cost, construction period, etc. For this five state-of-the-art algorithms, SVM, Random Forest, XGBoost, LightGBM, AutoML, were used and evaluated. The results show that F1-score of 0.88 or higher on two over-sampling techniques, SMOTE, ADASYN. And LightGBM with ADASYN achieve the best performance with F1-score and ROC-AUC, respectively 0.941. Among the proactive information, No. of stories is the most important feature in the Random Forest and LightGBM. And construction period, excavation depth, height are common important factors in the two algorithms.

Accordingly, this study established a framework for applying machine learning in the occupational safety and build predictive modes for demonstration. Further development of these methods is expected to contribute to reducing occupational accidents by enabling more efficient and effective safety management.

Key word : Occupational safety, Machine learning, Deep learning, Object detection, Prediction model