

Research on ITB Contract Terms Classification Model for Risk Management in EPC Projects: Deep Learning-Based PLM Ensemble Techniques

Hyunsang Lee[†] · Wonseok Lee^{††} · Bogeun Jo^{†††} · Heejun Lee^{††††} · Sangjin Oh^{†††††} · Sangwoo You^{†††††} · Maru Nam^{†††††} · Hyunsik Lee^{†††††††}

ABSTRACT

The Korean construction order volume in South Korea grew significantly from 91.3 trillion won in public orders in 2013 to a total of 212 trillion won in 2021, particularly in the private sector. As the size of the domestic and overseas markets grew, the scale and complexity of EPC (Engineering, Procurement, Construction) projects increased, and risk management of project management and ITB (Invitation to Bid) documents became a critical issue. The time granted to actual construction companies in the bidding process following the EPC project award is not only limited, but also extremely challenging to review all the risk terms in the ITB document due to manpower and cost issues. Previous research attempted to categorize the risk terms in EPC contract documents and detect them based on AI, but there were limitations to practical use due to problems related to data, such as the limit of labeled data utilization and class imbalance. Therefore, this study aims to develop an AI model that can categorize the contract terms based on the FIDIC Yellow 2017 (Federation Internationale Des Ingenieurs-Conseils Contract terms) standard in detail, rather than defining and classifying risk terms like previous research. A multi-text classification function is necessary because the contract terms that need to be reviewed in detail may vary depending on the scale and type of the project. To enhance the performance of the multi-text classification model, we developed the ELECTRA PLM (Pre-trained Language Model) capable of efficiently learning the context of text data from the pre-training stage, and conducted a four-step experiment to validate the performance of the model. As a result, the ensemble version of the self-developed ITB-ELECTRA model and Legal-BERT achieved the best performance with a weighted average F1-Score of 76% in the classification of 57 contract terms.

Keywords : EPC Projects, ITB Documents, Deep Learning, PLM, ELECTRA

EPC 프로젝트의 위험 관리를 위한 ITB 문서 조항 분류 모델 연구: 딥러닝 기반 PLM 앙상블 기법 활용

이 현 상[†] · 이 원 석^{††} · 조 보 근^{†††} · 이 희 준^{††††} · 오 상 진^{†††††} · 유 상 우^{†††††} · 남 마 루^{†††††} · 이 현 식^{†††††††}

요 약

국내 건설수주 규모는 2013년 91.3조원에서 2021년 총 212조원으로 특히 민간부문에서 크게 성장하였다. 국내외 시장 규모가 성장하면서, EPC(Engineering, Procurement, Construction) 프로젝트의 규모와 복잡성이 더욱 증가되고, 이에 프로젝트 관리 및 ITB(Invitation to Bid) 문서의 위험 관리가 중요한 이슈가 되고 있다. EPC 프로젝트 발주 이후 입찰 절차에서 실제 건설 회사에게 부여되는 대응 시간은 한정적인 뿐만 아니라, 인력 및 비용의 문제로 ITB 문서 계약 조항의 모든 리스크를 검토하는데 매우 어려움이 있다. 기존 연구에서는 이와 같은 문제를 해결하고자 EPC 계약 문서의 위험 조항을 범주화하고, 이를 AI 기반으로 탐지하려는 시도가 있었으나, 이는 레이블링 데이터 활용의 한계와 클래스 불균형과 같은 데이터 측면의 문제로 실무에서 활용할 수 있는 수준의 지원 시스템으로 활용하기 어려운 상황이다. 따라서 본 연구는 기존 연구와 같이 위험 조항 자체를 정의하고 분류하는 것이 아니라, FIDIC Yellow 2017(국제 컨설팅엔지니어링 연맹 표준 계약 조건) 기준 계약 조항을 세부적으로 분류할 수 있는 AI 모델을 개발하고자 한다. 프로젝트의 규모, 유형에 따라서 세부적으로 검토해야 하는 계약 조항이 다를 수 있기 때문에 이와 같은 다중 텍스트 분류 기능이 필요하다. 본 연구는 다중 텍스트 분류 모델의 성능 고도화를 위해서 최근 텍스트 데이터의 컨텍스트를 효율적으로 학습할 수 있는 ELECTRA PLM(Pre-trained Language Model)을 사전학습 단계부터 개발하고, 해당 모델의 성능을 검증하기 위해서 총 4단계 실험을 진행했다. 실험 결과, 자체 개발한 ITB-ELECTRA 모델 및 Legal-BERT의 앙상블 버전이 57개 계약 조항 분류에서 가장 평균 F1-Score 기준 76%로 가장 우수한 성능을 달성했다.

키워드 : EPC 프로젝트, ITB 문서, 딥러닝, 사전학습 언어 모델, ELECTRA

※ 이 논문은 현대엔지니어링(주), (주)빅웨이브에이아이와 공동으로 참여한

기술개발 과제에 의하여 연구되었음.

† 비 회 원 : (주)빅웨이브에이아이 데이터 분석팀 팀장

†† 비 회 원 : (주)빅웨이브에이아이 CTO

††† 비 회 원 : (주)빅웨이브에이아이 이사

†††† 비 회 원 : (주)빅웨이브에이아이 대표

†††† 비 회 원 : 현대엔지니어링(주) 스마트ICT팀 매니저

††††† 비 회 원 : 현대엔지니어링(주) 해외법무팀 책임매니저

†††††† 정 회 원 : 현대엔지니어링(주) 스마트ICT팀 팀장

Manuscript Received : August 2, 2023

Accepted : September 4, 2023

* Corresponding Author : Hyunsik Lee(hslee74@hec.co.kr)

1. 서 론

1980년대 이후 국내의 건설 산업이 부흥하면서 EPC(Engineering, Procurement, Construction) 프로젝트 발주 유형이 다양해지고 계약 형태 또한 더욱 세분화되었다. EPC 프로젝트란 건설 산업에서 프로젝트의 설계 및 계획 과정을 수행하는 Engineering 단계부터, 필요한 자재를 조달하는 Procurement 단계, 실제 건설 작업이 수행되는 Construction 단계로 구성된 프로젝트 단위를 의미한다[1]. EPC 프로젝트의 세분화 및 이해관계자들의 증가로 인해 ITB(Invitation to Bid) 문서에 프로젝트 요구사항과 함께 수행 방법, 권고사항, 지시사항 등 많은 부수적인 내용들을 포함하게 되었다. ITB 문서란 프로젝트를 수행하고자 하는 조직이나 개인들에게 제출하는 문서이며, 프로젝트의 상세한 정보와 요구사항을 포함하고 있기 때문에 입찰자들이 프로젝트를 정확하게 이해하고 적절한 제안을 준비하는데 중요한 역할을 한다. ITB 문서의 특성상 복잡성이 높으므로 상호 모순되는 조항, 발주처에 과도하게 유리하거나 수행 기업에게 부당한 조항 등이 포함되는 경우가 빈번하며, 결국 요구사항 관리가 제대로 되지 않는 상황에서 발생하는 변경 사항(change order)은 프로젝트 수행 기업에게 막대한 시간 소모와 비용의 원인이 될 수 있다[2].

국내 건설수주 규모는 2013년 공공수주 36.2조원에 민간수주 55.1조원, 총 91.3조원 수준에서 2021년 민간수주 156조원에 공공수주 56조원, 총 212조원으로 특히 민간수주 부문에서 약 100조원 이상으로 크게 성장했다[3]. 민간수주 건설 프로젝트들의 규모와 복잡성이 더욱 증가하면서 국내 건설 업계에서 프로젝트 관리 및 계약 문서의 관리가 중요한 이슈가 되고 있다. 국내의 건설 분야에서는 이러한 트렌드에 대응하기 위해 다양한 해결책을 연구하고 있다. EPC 프로젝트 계약서를 자동으로 해석하기 위해, 규칙 기반 혹은 제한된 데이터의 학습 및 추론으로 위험 조항을 탐지해내려는 시도도 있었다[4, 5]. 그러나 이와 같은 접근 방식은 데이터 레이블링에 필요한 리소스의 한계 및 계약 조항의 수정과 보안을 위한 세부 분석이 불가능하다는 점에서 한계가 존재한다.

본 연구는 이러한 상황에서 PLM(Pretrained Language Model)을 기반으로 새로운 방식을 활용하는 시스템을 제시한다. PLM이란 대용량 텍스트 데이터를 사전학습하여 해당 모델의 가중치를 통해 텍스트 분류, 번역, 챗봇 등의 여러 가지 문제에 적용하는 방식을 의미한다. PLM은 대용량 텍스트 데이터의 다양한 컨텍스트 정보를 학습하기 때문에 데이터가 적거나, 클래스가 불균형한 문제에 강력한 성능을 가지고 있다. 최근에는 특히 PLM 중에서 GPT(Generative Pretrained Transformer) 기술을 기반으로 마이크로소프트의 ChatGPT, Bing AI와 같은 서비스들이 주목을 받고 있다[6-8]. 또한, 기존 PLM 연구에서는 법률 등의 다양한 분야에 특화된 모델을 개발하려는 연구들이 시도되고 있다[9]. 본 연구도 이와 같이 ITB 문서에 특화된 PLM을 개발하여 문서 위험 관리 업무를 지원할 수 있는 시스템을 개발하고자 한다.

따라서 본 연구는 ITB 문서의 위험 관리를 위한 PLM 기반 ITB 문서 조항 분류 시스템을 제안하며, 이에 ITB 문서 조항

분류 모델을 실험했다. 해당 EPC 프로젝트 위험 관리 시스템은 조항 분류를 통해서 위험 관리를 위한 핵심 계약 조항을 탐지하고, 이를 바탕으로 EPC 프로젝트 계약을 검토하는 실무자들의 기존 지식체계를 지원할 수 있는 딥러닝 기반 시스템을 개발하고자 한다.

2. 관련 연구

2.1 EPC 계약 문서 위험 관리

EPC(Engineering, Procurement, Construction)에서의 ITB(Invitation to Bid) 문서란 '입찰 안내서'를 의미하며 프로젝트에 대한 설명 및 요구사항의 내용을 가지고 있다. 프로젝트의 발주처는 ITB 문서를 통해서 입찰 참가자들에게 계약 조건을 안내하는데, 이 때 ITB에 포함되어 있는 계약 문서, 예컨대 FIDIC(Federation Internationale Des Ingenieurs-Conseils) 표준계약 조건 또는 발주처나 발주처의 법무 대리인이 직접 작성한 조항에 따라서 일정 지연, 요구 사항 미충족 등의 위험 상황이 발생할 수 있으며, 이는 프로젝트 입찰 기업에게 큰 손해를 유발할 수 있다. 여기서 FIDIC이란 1915년 창립된 국제 건설링엔지니어링 연맹으로, FIDIC에서 제정한 표준계약 조건을 FIDIC 표준계약조건 또는 FIDIC 표준계약서라고 한다. FIDIC 표준계약서는 크게 Red Book(Construction), Yellow Book(Design-Build), Silver Book(EPC Turnkey) 3가지 종류로 구분되며, 건설 산업계에서 가장 많이 사용되는 국제 표준계약조건이다. 이러한 상황에서 EPC 계약 문서의 위험 조항 관리를 텍스트 분석을 통해서 보완 및 해결하고자 하는 연구들이 시도되고 있다[10-12].

EPC 위험 관리 연구에서는 국제 건설 프로젝트를 대상으로 ITB 문서 관리를 위한 UNI(User Needed Information)-Tacit이라는 프로토타입 시스템을 개발했다[10]. UNI-Tacit는 웹 크롤링을 활용하여 글로벌 건설 시장의 이슈 정보를 수집하고, NLP(Natural Language Processing)를 기반으로 각 문서에 대한 태그 정보를 워드 클라우드 형태로 시각화할 수 있다. 또한, 다른 관련 연구에서는 AI와 텍스트 마이닝 기술을 활용하여 프로젝트 입찰 참가자를 위한 디지털 위험 관리 도구를 개발했다[11]. 해당 연구에서는 CRC(Critical Risk Check) 및 TFA(Term Frequency Analysis) 모듈을 개발했는데, CRC의 경우 EPC 프로젝트에서 ITB 등 계약 문서에 대해 구문 일치 분석을 통해서 계약 위험도가 높은 조항을 자동으로 추출한다. TFA 모듈은 머신러닝 NER(Named-Entity Recognition) 기술을 기반으로 개체명의 위험 조항이 포함된 문장을 탐색한다. 해당 연구는 위험 조항 추출을 위해서 CRC 및 TFA 모듈을 함께 활용했다.

한편, 딥러닝 활용 연구에서는 온톨로지 시맨틱(ontology semantic) 및 Bi-LSTM(Bidirectional Long Short-Term Memory) 방법론을 활용하여 EPC 입찰 문서의 프로젝트 리스크를 분석하고자 했다[12]. 해당 연구에서는 SA(Semantic Analysis) 및 RLR(Risk Level Ranking) 모델을 개발했으며, SA 모델의 경우 NLP 시스템을 기반으로 주요 위험 조항을 추출할 수

있다. RLR 모델은 ITB 등 계약 문서 조항의 위험 영향도에 대한 순위를 Bi-LSTM을 기반으로 예측할 수 있다. 비교적 RLR 모델의 F1 Score 기준 성능이 저조하지만, 해당 논문에서는 위험 관리의 측면에서 두 모델의 상호보완성을 주장했다.

EPC 계약 문서의 위험관리를 위한 기존 연구의 경우 대체적으로 위험 조항 자체를 예측하고자 하는데, 이는 두 가지 한계점이 존재한다. 첫 번째, 프로젝트 계약 문서의 위험 조항을 이진 분류하는 경우 다양한 상황에 따라서 위험도가 달라지는 문제를 해결할 수 없다. 두 번째, ITB 문서의 분량은 일반적으로 100페이지 내외이며, 이 중 위험 조항을 구분하는 문제는 데이터의 측면에서 클래스가 매우 불균형하다는 문제가 있다. 따라서 본 연구는 기존 연구대비 고도화된 딥러닝 PLM 시스템을 기반으로 ITB 문서의 계약 조항 자체를 예측하는 새로운 방식을 제안한다. 본 연구에서 제안하는 기법은 명확하게 구분된 ITB 문서의 계약 조항을 분류함으로써 위험 관리를 위한 검토가 필요한 부분을 명확하게 파악할 수 있다.

2.2 PLM 기반 텍스트 분류

텍스트 분류란 특정 문서, 문장 등의 단위에서 범주를 구분하는 것으로 2010년 이후 딥러닝 텍스트 분류 기술이 발전하면서 감성 분석, 스팸 메일 필터링, 혐오 표현 탐지 등 다양한 분야에서 연구되고 있다[13-15]. 본 연구의 ITB 문서의 계약 조항 분류도 텍스트 분류의 문제로 볼 수 있다. 최근에는 PLM(Pre-trained Language Model) 기반의 텍스트 분류 기법들의 성능이 우수한 수준을 달성하면서 주목을 받기 시작했다[16, 17]. PLM이란 사전학습된 언어 모델을 의미하며, 대용량 텍스트를 학습한 거대 모델을 텍스트 분류, 생성, 번역 등 다양한 분야에 적용할 수 있다. BERT(Bidirectional Encoder Representations from Transformers)는 사전 학습 시 임의의 특정 단어가 마스킹된 단어를 예측하는 MLM(Masked Language Model) 메커니즘을 활용한다[16]. MLM을 통해 BERT 모델은 딥러닝 네트워크의 가중치에 텍스트 데이터의 컨텍스트 정보를 반영한다. 즉, BERT의 사전학습 방식은 특정 언어 자체의 특성을 학습할 수 있으며, 레이블링 처리 없이 대용량의 텍스트 데이터를 학습하는 것이 가능하다. 사전학습된 BERT 모델은 fine-tuning을 통해서 다양한 NLP 분야에 적용될 수 있다. BERT 기법은 양방향으로 언어의 특성을 학습하기 때문에 텍스트 분류, 요약, 개체명 인식, 질의응답 등의 분야에서 강점을 가지고 있다.

그러나 BERT의 경우 양방향 트랜스포머 인코더를 기반으로 대용량의 데이터를 학습해야 하기 때문에 큰 규모의 모델 아키텍처와 학습 시간이 필요하다. 또한 마스킹된 단어 자체를 예측해야 하므로 예측 대상이 광범위하다는 문제로 인해 비효율성이 발생한다. ELECTRA는 BERT의 이와 같은 한계점을 보완하고자 생성자(Generator) 및 판별자(Discriminator) 구조를 활용한다[17]. 생성자에서는 마스킹 단어의 위치에 임의의 단어를 생성하고, 판별자에서는 이를 참, 거짓으로 분류하는 방식으로 기존 BERT의 MLM 방식을 개선했다. ELECTRA 모델의 실험 결과로써 BERT에 비교적 적은 학습 시간, 적은 모델 용량, 우수한 성능이 나타났다[17].

3. 연구 방법론

3.1 AI 모델 및 실험 설계

본 연구의 전체적인 AI 모델 설계 및 분석 프로세스는 Fig. 1과 같다. 본 연구에서는 EPC 계약서 및 공개 데이터를 활용하여 ITB-ELECTRA 모델을 사전학습했다. ITB-ELECTRA와 함께 성능 비교를 위해서 Baseline PLM(Pre-trained Language Model)에 대해서도 Fine-tuning을 동시에 실시했다. 비교군 모델의 경우 Google-ELECTRA와 Legal-BERT로 설정했다[17, 9]. Google-ELECTRA는 기존의 BERT와 마찬가지로 다양한 영역의 텍스트를 학습했고, Legal-BERT의 경우 법률 분야에서 사전학습 모델을 효율적으로 활용하기 위해 EU 법 조항 및 ECHR-CASES 등의 데이터를 활용한 사전학습 모델이다[9]. Google-ELECTRA와 Legal-BERT 모델을 성능 비교군으로 선정 한 이유는 자체 개발한 ITB-ELECTRA 모델이 기존에 공개된 사전학습 모델 대비 성능 수준을 확인하기 위함이다. 본 연구에서는 ITB-ELECTRA, Google-ELECTRA, Legal-BERT의 모델 정확도를 비교하고, 성능 고도화를 위해서 데이터 증강(Data Augmentation) 및 앙상블(Ensemble) 기법을 적용했다.

본 연구에 적용된 데이터 증강(Data Augmentation) 기법은 덴마크, 독일, 스페인, 이탈리아, 프랑스에 해당하는 5개 국어를 가지고 역번역을 수행했으며, 이에 활용한 모델은 Hugging Face에서 오픈 소스로 공개된 트랜스포머 기반 번역 모델이다[18]. 여기서 역번역이란 데이터의 수를 증가시키기 위해서 다른 언어로 번역한 텍스트를 되돌리는 방식으로 딥러닝 텍스트 분석에서 데이터 증강을

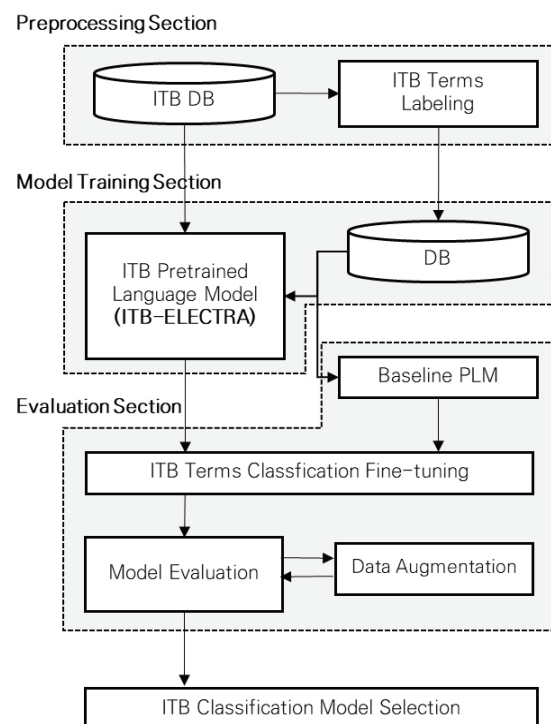


Fig. 1. Methodology Architecture




Fig. 2. ITB-ELECTRA Architecture

위해 주로 사용하는 방법론이다[19]. 또한, MLM 매커니즘을 활용한 데이터 증강기법을 추가로 적용하였다. MLM을 활용한 데이터 증강은 각 텍스트 데이터의 15%를 랜덤하게 마스킹한 이후 각 MLM의 생성자를 활용해 마스킹 된 부분을 추론한 데이터를 다시 적용하는 방식이다. 데이터 증강 기법 실험은 학습 데이터셋에 적용하여 실험 단계에서 ITB-ELECTRA와 Legal-BERT 모델에 적용 전후를 비교했다. 최종적으로 EPC 계약 조항 분류 실험에서 Weighted F1 Score 기준 가장 높게 나타난 모델을 선정했다. 앙상블 기법의 경우 PLM이 예측한 다중 분류의 소프트맥스 확률을 평균하는 일반적인 방식을 활용했다.

3.2 제안 기법

본 연구의 제안 기법인 ITB-ELECTRA의 모델 구조는 Fig. 2와 같다. 자체 토큰 처리된 입력 텍스트 데이터에 대해 15%를 임의로 마스킹 처리를 수행했다. 다음 단계로 토큰(token), 타입(type), 포지셔널 인코딩(Positional Encoding)에 대한 임베딩(embedding)을 모델에 입력했다. 여기서 토큰이란 문장 내 텍스트를 나눈 최소 단위를 의미하며, 토큰화를 통해 문장을 단어, 서브워드 또는 문자 단위로 분할할 수 있다. 타입 임베딩은 문장 간의 구분자를 의미한다. 포지셔널 인코딩은 텍스트 시퀀스에서 각 토큰의 상대적 위치를 의미한다. 입력 데이터의 임베딩은 GELU(Gaussian Error Linear Unit)를 통해

서 투영되어 모델에 입력되는데, GELU란 기존의 ReLU, ELU 등의 은닉층 활성화 함수의 복잡성을 개선한 것으로 최근 트랜스포머 관련 딥러닝 연구에서 활용되고 있다[20]. 본 모델에서는 트랜스포머 레이어를 통해서 데이터의 특성을 학습하여 생성자에서 최종적으로 마스킹 단어를 예측한다. 판별자에서는 입력 임베딩과 예측 결과를 판별자의 트랜스포머 레이어에 입력하여 최종적으로 생성자가 예측한 단어가 실제 단어와 일치하는지를 분류한다. 여기서 생성자와 판별자의 어텐션(attention) 정보가 공유된다.

4. 실험

4.1 데이터

본 연구의 PLM 모델 학습에 활용한 데이터는 Table 1과 같이 FEED(Front End Engineering Design), ITB 등 EPC 계약 문서 77건과 오픈소스 외부 데이터를 같이 활용했다. 여기서 FEED란 프로젝트의 설계 단계에서 세부적인 사항에 대한 내용을 의미하며, 해당 문서에는 과업의 범위, 공정 흐름도, 기술 스펙, 일정 등의 내용을 포함한다. PLM은 특정 언어 자체의 특성을 학습하기 위해 대용량의 데이터와 많은 자원과 비용이 필요하다. 오픈소스 데이터의 경우 CUAD_v1, Contract-NLI, American National Corpus, News Article Corpus,

Table 1. Data Descriptions

Source	Data	Descriptions
Internal	EPC Terms	77 Documents
External	CUAD_v1	510 commercial legal contract documents collected for AI training
	Contract-NLI	607 contract document data collected for natural language processing training
	American National Corpus	English corpus data composed of more than 15 million words
	News Article Corpus	Over 800,000 English news article data collected for natural language processing training
	Wikipedia Corpus	More than 4.4 million Wikipedia full-text data




Fig. 3. Fine-tuning Data Preprocess

Wikipedia Corpus의 출처에서 수집했다[21-25]. 최종 데이터는 EPC 계약 문서에 특화하기 위해서 법률 및 계약 문서를 중심으로 비교적 정형화된 텍스트를 위주로 구성했다. 본 연구에서 활용한 전체 텍스트 데이터셋의 용량은 약 12GB 수준이다.

본 연구에서 활용한 Fine-tuning 데이터는 Table 1의 EPC 계약 문서 77건 중 23건이며, Fig. 3과 같이 구축되었다. 우선적으로 PDF 파일 형태의 내부 EPC 계약 문서에 대해서 텍스트 데이터 추출을 목적으로 전처리를 수행했다. PDF 형태의 문서 파일로부터 계약 내용 텍스트를 추출하기 위해 PyMuPDF 패키지를 활용하였다. 이 단계에서 EPC 계약문서의 형태가 다양하여 텍스트 처리에 어려움이 있었다. 이를 해결하기 위해 각 EPC PDF 문서로부터 계약 정보 시작 페이지 범위, EPC 문서 형태(테이블 유형, 소제목이 흰으로 나열된 형태 등)와 같은 추가 정보를 활용했다.

4.2 모델링

본 연구의 ITB-ELECTRA의 사전학습 모델링은 초기 실험을 위해서 기존 ELECTRA 모델의 small과 base 중간 수준의 규모인 small++ 모델의 하이퍼파라미터(Hyperparameter)를 참고했다[27]. 사전학습 모델링의 실험 환경은 Table 2와 같으며 약 10일 소요되었다. ITB-ELECTRA 모델의 생성자 및 판별자에 대한 하이퍼파라미터 명세는 Table 3과 같다. Google-

Table 2. Experimental Environment

List	Descriptions
CPU	32 core, Intel(R) Xeon(R) Gold 5315Y @ 3.20GHz
RAM	128GB
GPU	NVIDIA A40(VRAM : 48GB) x 2
Training Duration	10 days

Table 3. ITB-ELECTRA small++ Model Hyperparameters

Parameters	Descriptions	Generator	Discriminator
attention_probs_dropout_prob	Attention probability dropout ratio	0.1	0.1
embedding_size	Input token's embedding size	128	256
hidden_act	Encoder and pooler's activation function	gelu	gelu
hidden_dropout_prob	Embedding, encoder, and pooler's individual fully connected layer dropout ratio	0.1	0.1
hidden_size	Encoder and pooler's	256	512
max_position_embeddings	Number of Dimensions Model's maximum sequence length that can be processed	512	1024
num_attention_heads	Number of attention heads in the encoder	4	8
num_hidden_layers	Number of attention heads in the encoder	12	12
vocab_size	Number of Tokens	32200	32200

ELECTRA와 Legal-BERT 모델의 경우 Fine-tuning 성능 비교 및 양상불 기법의 적용을 위해서 기존 연구에서 사전학습된 모델을 활용했다[27, 28]. 성능 테스트는 데이터 클래스의 불균형을 고려하여 가중 평균 F1-Score를 기준으로 설정했다.

4.3 모델 성능 지표

본 연구의 성능 지표는 AI 모델의 전반적인 분류 성능을 측정하기 위해 가중 평균 방식을 사용했고, 클래스가 불균형한 상황을 고려하여 Macro 평균 방식을 같이 활용했다. 가중 평균은 Equation (1)과 같이 클래스마다 샘플 수에 따른 가중치를 부여하여 점수를 계산하는 방식이고, Macro 평균은 Equation (2)와 같이 다중 클래스 분류에서 샘플 수를 고려하지 않고 클래스별 수치를 평균하는 방식이다. 세부 성능 지표로는 Accuracy, Precision, Recall, F1-Score를 활용했다. Accuracy는 가장 일반적인 지표이며, Equation (3)과 같이 분류 문제에서 정답을 맞춘 경우의 비율을 의미한다. 하지만 이는 다중 클래스 분류 문제에서 클래스 간 샘플 개수가 불균형한 경우 실제 성능과 모순이 발생한다. 따라서 다양한 지표를 활용한 검증이 필요하다. Equation (3)에서의 TP(True Positive), TN(True Negative), FP(False Positive), FN(False Negative)는 Confusion Matrix에서의 각 경우의 수를 의미한다. Precision의 경우 Equation (4)와 같이 예측값의 양성 중에서 정답을 맞춘 비율을 의미하며, Recall은 Equation (5)처럼 실

제값의 양성 중에서 정답을 맞춘 비율을 의미한다. F1-score는 Equation (6)과 같이 Precision과 Recall의 조화 평균을 의미하고 Precision과 Recall 중 지표가 낮은 편에 큰 가중치가 부여되기 때문에 두 성능 지표의 상호보완적이라고 할 수 있다.

$$\text{Weighted Score} = \sum_{i=1}^N w_i \times \text{Score}_i \quad (1)$$

$$\text{Macro Score} = \frac{\sum_{i=1}^n \text{Score}_i}{n} \quad (2)$$

$$\text{Accuracy} = \frac{(TP+TN)}{(TP+FP+TN+FN)} \quad (3)$$

$$\text{Precision} = \frac{TP}{TP+FP} \quad (4)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (5)$$

$$\text{F1 Score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (6)$$

5. 실험 결과

본 연구의 ITB-ELECTRA 사전학습 모델을 검증하기 위해 Fine-tuning에서 총 4단계의 실험 절차를 진행했다. 첫 번째, ITB-ELECTRA와 Google-ELECTRA 모델의 성능을 비교했다. 또한, 본 연구에서 개발한 연구 모델의 검증을 위해서 Google-ELECTRA의 small 및 base 모델을 같이 비교했다. 두 번째, ITB-ELECTRA와 Legal BERT의 Fine-tuning 모델 성능을 비교했다. 세 번째, MLM 및 역번역 기법을 활용한 데이터 증강에 따른 성능의 개선이 있는지와 모델의 예측 클래스에 대한 정밀 분석을 위해 Top-K 검증을 기반으로 실험했다. 마지막으로, 본 연구에서는 PLM Fine-tuning 모델 간 앙상블 기법을 활용하여 최종적으로 성능을 테스트했다.

5.1 ITB-ELECTRA 모델 실험

실험의 첫 단계로 ITB-ELECTRA small++ 모델의 성능을 검증하기 위해서 Google-ELECTRA의 PLM과 Fine-tuning 모델을 비교 검증했다. 실험 결과에 따르면 초기 실험을 위해서 small 규모의 모델을 비교했음에도 Google-base 모델보다 성능이 모든 지표에서 우수한 것으로 나타났다. 특히 Macro 평균 Recall에서 43%로 다른 지표보다 우수한 성능이 나타나는데, 이는 EPC 계약 문서에 특화된 PLM이 Fine-tuning에서 희소한 클래스의 데이터를 정확하게 예측한 것으로 해석된다. 본 연구의 첫 단계 실험을 통해 EPC 계약 문서에 특화된 PLM이 기존 연구에서 공개된 모델보다 성능이 우수함을 확인할 수 있었다. 이에 따라 본 연구의 제안 모델이 충분히 고도화될 수 있음을 확인하고, 다음 단계의 실험을 진행했다.

5.2 Legal BERT 실험

두 번째 실험에서는 baseline 비교를 위해 Fine-tuning한 Legal-BERT 모델과 ITB-ELECTRA를 비교 실험했다.

Table 4. ITB-ELECTRA small++ Model Experimental Result

Metric/Models	Google-small	Google-base	ITB-small++ (ours)
Weighted Average F1-Score	67.88%	70.01%	71.90%
Weighted Average Precision	70.99%	72.36%	73.92%
Weighted Average Recall	66.52%	69.13%	71.22%
Macro Average F1-Score	25.29%	31.53%	37.17%
Macro Average Precision	22.47%	34.36%	36.06%
Macro Average Recall	29.63%	34.70%	43.23%
Accuracy	66.52%	70.41%	70.86%

Table 5. Legal-BERT & ITB-ELECTRA

Metric/Models	Legal-base	ITB (ours)
Weighted Average F1-Score	72.62%	71.90%
Weighted Average Precision	75.18%	73.92%
Weighted Average Recall	72.37%	71.22%
Macro Average F1-Score	38.21%	37.17%
Macro Average Precision	31.82%	36.06%
Macro Average Recall	39.72%	43.23%
Accuracy	72.41%	70.86%

두 모델의 성능 지표 차이는 크지 않았지만, 전반적으로 Legal-BERT의 분류 성능이 더 우수했다. 이는 유럽 연합 및 영국 법령, ECJ(European Court of Justice) 판례 등의 법률 분야에 특화된 데이터셋을 학습한 Legal-BERT가 base 규모로 Fine-tuning을 수행했을 때 우수한 성능이 측정되는 것으로 해석된다. ITB-ELECTRA small++ 모델의 경우 Macro 평균 Precision과 Recall에서 수치가 상대적으로 높은 것으로 봤을 때 분포가 희소한 클래스에서 정확하게 예측을 수행한 것으로 판단된다. 이는 EPC 계약 문서에 특화된 PLM이 base 모델 이상으로 고도화되었을 때 성능 개선의 가능성을 내포하고 있다고 볼 수 있다.

5.3 데이터 증강 & Top-K 실험

ITB-ELECTRA와 Legal-BERT의 데이터 증강(Data Augmentation) 적용 결과는 Table 6과 같다. 이전 Table 5의 결과와 같이 Legal-BERT 모델의 성능이 우수하게 나타났으며, 특히 가중 평균 Recall과 Macro 지표에서 큰 성능의 향상이 있었다. 이는 역번역과 마스킹 단어 예측을 통한 데이터 증강 기법이 데이터가 희소한 클래스에 대해서 정밀한 예측을 수행할 수 있도록 모델을 개선했음을 의미한다. 본 연구의 데이터 증강 기법 적용 시 전체 학습 데이터가 6배 증가하기 때문에 Fine-tuning 모델에 성능적인 측면에서 효과적으로 작용했다고 판단된다.

추가적으로 3단계 실험에서는 ITB-ELECTRA와 Legal-BERT의 예측 결과를 심층적으로 분석하기 위해서 Top-K Hit

Ratio를 측정했다. Top-K Hit Ratio란 데이터의 클래스를 K 번째 안에 정확하게 예측한 비율을 의미하며, 다중 분류의 결과인 소프트맥스 확률을 기준으로 Top-K를 선정한다. Top-K 클래스 안에 정답이 존재할 경우 Hit Ratio는 1이 되며, 없을 경우 0이 된다. 본 연구에서는 Top-5까지의 Hit Ratio를 측정했으며 그 결과는 Table 7과 같다. Legal-BERT 모델은 Top-1, 2 Hit Ratio에서 ITB-ELECTRA에 비해 높은 수치를 기록했으나, Top-3, 4, 5의 Hit Ratio에서 ITB-ELECTRA 모델이 우수한 성능을 나타냈다. 이는 ITB-ELECTRA 모델이 정밀한 예측 성능적인 측면에서는 Legal-BERT에 비해 부족하지만, 전반적인 EPC 계약 문서에 대한 문맥적 특성을 우수한 수준으로 학습했음을 알 수 있다. 기존의 딥러닝 텍스트 분류 분야의 연구에서도 추론의 성격이 다른 2개 이상의 모델을 앙상블, 혹은 하이브리드 방식으로 결합하는 경우도 있다[29, 30]. 이에 따라 본 연구에서는 최종적으로 ITB-ELECTRA와 Legal-BERT의 앙상블 기법 실험을 실시했다.

Table 6. Data Augmentation

Metric/Models	Legal-base+DA	ITB+DA (ours)
Weighted Average F1-Score	75.26%	75.49%
Weighted Average Precision	77.96%	78.24%
Weighted Average Recall	74.56%	73.42%
Macro Average F1-Score	41.46%	40.88%
Macro Average Precision	45.05%	42.68%
Macro Average Recall	42.63%	41.02%
Accuracy	74.69%	73.16%

Table 7. Top-5 Hit Ratio Evaluation Result

Metrics/Models	Legal-base+DA	ITB+DA (ours)
Top-1 Hit Ratio	74.69%	73.16%
Top-2 Hit Ratio	83.28%	82.82%
Top-3 Hit Ratio	86.81%	88.04%
Top-4 Hit Ratio	88.65%	89.72%
Top-5 Hit Ratio	89.42%	91.10%

5.4 최종 앙상블 모델 실험

4단계 실험에서의 앙상블 실험 결과는 Table 8과 같다. 본 연구의 4단계 실험 결과를 비교하기 위해서 Fig. 4에서는 모든 성능 측정 결과를 종합했다. 결론적으로 모든 지표에서 ITB-ELECTRA와 Legal-BERT의 앙상블 모델이 우수한 성능을 나타냈다. 특히 Macro Recall 및 Precision 지표에서 높은 성능을 기록했는데, 이는 본 연구의 앙상블 모델이 클래스 분포 차이에 강건하며, EPC 계약서 조항 분류에 안정적인 성능을 가지고 있다고 볼 수 있다. 본 연구를 통해 EPC 계약 문서에 특화된 PLM과 법률 관련 텍스트 데이터를 대용량으로 학습한 Legal-BERT 모델의 예측 기준이 상이하면서도 상호보완적임을 알 수 있었다. 최종적으로 4단계 실험 결과로써 본 연구는 ITB-ELECTRA 및 Legal-BERT의 앙상블 모델을 선정했다.

Table 8. Ensemble Model

Metric/Models	ITB+DA	Legal-base+DA	ITB+Legal+DA (ours)
Weighted Average F1-Score	75.49%	75.26%	76.27%
Weighted Average Precision	78.24%	77.96%	78.43%
Weighted Average Recall	73.42%	74.56%	75.92%
Macro Average F1-Score	40.88%	41.46%	41.96%
Macro Average Precision	42.68%	45.05%	46.13%
Macro Average Recall	41.02%	42.63%	43.63%
Accuracy	73.16%	74.69%	76.38%
Top-1 Hit Ratio	73.16%	74.69%	76.38%
Top-2 Hit Ratio	82.82%	83.28%	84.18%
Top-3 Hit Ratio	88.04%	86.81%	89.42%
Top-4 Hit Ratio	89.72%	88.65%	90.69%
Top-5 Hit Ratio	91.10%	89.42%	93.03%

6. 결론

본 연구는 EPC 계약 문서의 조항을 분류할 수 있는 모델을 개발하기 위해서 데이터 처리 및 실험을 수행했다. 데이터 처리에서는 사전학습을 위해 EPC 계약 문서 포함 약 12GB의 텍스트 데이터를 수집하고, Fine-tuning에는 23건의 EPC 계약 문서를 레이블링 처리하여 총 6,190건의 AI 학습용 데이터를 구축했다. Fine-tuning 모델 실험은 사전학습된 ITB-ELECTRA 모델을 검증하기 위해 수행되었으며 4단계의 절차를 수행했다.

본 연구의 시사점은 다음과 같다. 첫 번째, 본 연구는 EPC 계약 문서의 조항을 효과적으로 분류하기 위해 12GB 용량의 텍스트 데이터를 활용하여 자체 사전학습 모델을 개발했다. ITB-ELECTRA 모델은 small++ 규모의 파라미터 크기에도 Google-ELECTRA small, base 모델의 성능을 상회했으며, base 규모인 Legal-BERT와도 성능적인 측면에서 크게 차이가 나지 않았다. 특히 Top-5 Hit Ratio 검증에서는 Top-3, 4, 5 지표에서 더욱 우수한 성능을 달성했는데, 이는 ITB-ELECTRA가 small++ 사이즈임에도 EPC 계약 문서의 컨텍스트를 효율적 및 효과적으로 학습했다는 것을 의미한다. 두 번째, 본 연구는 ITB-ELECTRA와 기존 연구의 Legal-BERT를 Top-5 Hit Ratio 지표를 기준으로 비교하면서 두 모델을 앙상블하는 새로운 방식을 제시했다. 해당 방식을 적용한 결과 가중 평균 F1-Score, Precision, Recall 등 모든 지표에서 가장 우수한 성능을 달성했다.

세 번째, 본 연구는 역번역 및 마스킹 단어 예측에 의한 데이터 증강의 효과를 실험으로써 실증했다. Table 8의 실험 결과를 보면 특히 Macro 평균 Precision이 ITB-ELECTRA, Legal-BERT 각각 32%, 36%에서 43%, 45%로 큰 성능 향상을 확인할 수 있다. 네 번째, 본 연구는 사전학습과 Fine-tuning

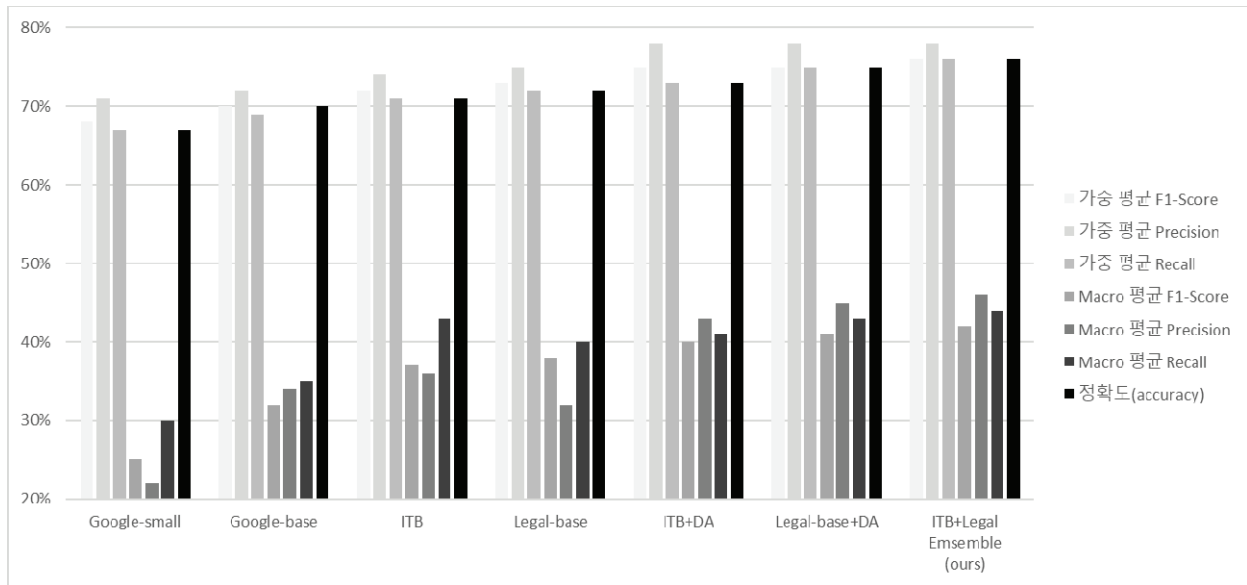


Fig. 4. 4-Step Experimental Result

단계에서 학습용 데이터 구축을 위해 다양한 형태의 EPC 계약 문서 PDF 파일에서 텍스트 데이터를 추출할 수 있는 고도화된 시스템을 활용했다. AI 모델 학습을 위해서 모든 유형의 계약 문서 파일을 처리할 수 있도록 지속적으로 시스템을 개선 및 고도화를 수행했으며, 본 연구에서 가장 많은 시간과 비용이 투자되었다.

본 연구의 한계점은 다음과 같다. 본 연구는 자체 개발 모델의 효과성을 선제적으로 검증하기 위해서 small++ 규모의 ELECTRA 사전학습 모델만을 활용했다. 향후 연구에서는 base 규모의 ITB-ELECTRA 모델을 실험하고자 한다. 또한, 본 연구는 23건의 EPC 계약 문서를 활용하여 데이터셋을 구축했는데, 이에 Fine-tuning 모델들의 전반적인 성능 및 모델의 일반화 수준에 문제가 있을 수 있다. 본 연구의 모델을 실제 EPC 프로젝트 계약 관리에 활용하려면 추가적인 데이터 구축이 필요한 상황이다. 향후 연구에서 AI 모델 고도화 및 추가 데이터 수집을 통해 EPC 프로젝트 계약 실무에서 활용할 수 있는 수준의 시스템을 구축할 것을 기대한다.

References

[1] K. Kabirifar and M. Mojtahedi, "The impact of engineering, procurement and construction (EPC) phases on project performance: A case of large-scale residential construction project," *Buildings*, Vol.9, No.1, pp.15, 2019.

[2] R. Joslin and R. Muller, "The relationship between project governance and project success," *International Journal of Project Management*, Vol.34, No.4, pp.613-626, 2016.

[3] C. H. Park, "2023 Construction Industry Outlook Report," Construction & Economy Research Institute of Korea (CERIK).

[4] A. F. Bakr, K. El. Hagla. and A. N. A. Rawash, "Heuristic approach for risk assessment modeling: EPCCM Application (Engineer Procure Construct Contract Management)," *Alexandria Engineering Journal*, Vol.51, No.4, pp.305-323, 2012.

[5] Y. Kim, J. Lee, E.-B. Lee, and J.-H. Lee, "Application of Natural Language Processing (Nlp) and Text-Mining of Big-Data to Engineering-Procurement-Construction (Epc) Bid and Contract Documents," *Paper Presented at the 2020 6th Conference on Data Science and Machine Learning Applications (CDMA)*, 2020.

[6] T. Brown et al., "Language models are few-shot learners," *arXiv preprint arXiv:2005.14165*, 2020.

[7] ChatGPT [Internet], <https://openai.com/blog/chatgpt>, 2022.

[8] BingChat [Internet], <https://www.microsoft.com/en-us/edge/features/bing-chat?form=MT00D8>, 2023.

[9] I. Chalkidis, M. Fergadiotis, P. Malakasiotis, N. Aletras, and I. Androutsopoulos, "Legal-Bert: The muppets straight out of law school," *arXiv preprint arXiv:2010.02559*, 2020.

[10] S. Moon, Y. Shin, B.-G. Hwang, and S. Chi, "Document management system using text mining for information acquisition of international construction," *KSCE Journal of Civil Engineering*, Vol.22, pp.4791-4798, 2018.

[11] S. J. Choi. S. W. Choi. J. H. Kim. and E.-B. Lee, "Ai and Text-Mining Applications for Analyzing Contractor's Risk in Invitation to Bid (Itb) and Contracts for Engineering Procurement and Construction (Epc) Projects," *Energies*, Vol.14, No.15, pp.4632, 2021.

- [12] S.-W. Choi and E.-B. Lee, "Contractor's risk analysis of engineering procurement and construction (Epc) contracts using ontological semantic model and bi-long short-term memory (Lstm) technology," *Sustainability*, Vol.14, No.11, pp.6938, 2022.
- [13] L. Zhang, S. Wang, and B. Liu, "Deep learning for sentiment analysis: A survey," *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, Vol.8, No.4, pp.1253, 2018.
- [14] Q. Yaseen, "Spam email detection using deep learning techniques," *Procedia Computer Science*, Vol.184, pp.853-58, 2021.
- [15] N. Djuric, J. Zhou, R. Morris, M. Grbovic, V. Radosavljevic, and N. Bhamidipati, "Hate speech detection with comment embeddings," *Paper Presented at the Proceedings of the 24th International Conference on World Wide Web*, 2015.
- [16] J. Devlin, M.-W. Chang, K. Lee, and K. Toutanova, "Bert: Pre-training of deep bidirectional transformers for language understanding," *arXiv preprint arXiv:1810.04805*, 2018.
- [17] K. Clark, M.-T. Luong, Q. V. Le, and C. D. Manning, "Electra: Pre-training text encoders as discriminators rather than generators," *arXiv preprint arXiv:2003.10555*, 2020.
- [18] Huggingface, "Helsinki-NLP", <https://huggingface.co/Helsinki-NLP>, Language Technology Research Group at the University of Helsinki, 2021.
- [19] C. Shorten, T. M. Khoshgoftaar, and B. Furht, "Text data augmentation for deep learning," *Journal of big Data*, Vol.8, pp.1-34, 2021.
- [20] D. Hendrycks and K. Gimpel, "Gaussian Error Linear Units (Gelus)," *arXiv preprint arXiv:1606.08415*, 2016.
- [21] Contract Understanding Atticus Dataset (CUAD) [Internet], <https://www.atticusprojectai.org/cuad>, 2021.
- [22] ContractNLI, A Dataset for Document-level Natural Language Inference for Contracts [Internet], <https://stanfordnlp.github.io/contract-nli/>, 2021.
- [23] American National Corpus [Internet], <https://anc.org/>, 2008.
- [24] News Articles Corpus, Kaggle [Internet], <https://www.kaggle.com/datasets/sbhatti/news-articles-corpus>, 2022.
- [25] Wikipedia Corpus [Internet], <https://www.english-corpora.org/wiki/>, 2022.
- [26] Plant and Design-Build Contract 2nd Ed (2017 Yellow Book), Federation Internationale Des Ingenieurs-Conseils, 2017.
- [27] Github, "Google Research ELECTRA" [Internet], <https://github.com/google-research/electra>, 2021.
- [28] Huggingface, "legal-bert-base-uncased" [Internet], <https://huggingface.co/nlpaueb/legal-bert-base-uncased>, 2020.
- [29] Z. H. Kilimci and S. Akyoku, "Deep learning-and word embedding-based heterogeneous classifier ensembles for text classification," *Complexity*, 2018.
- [30] A. Mohammed and R. Kora, "An effective ensemble deep learning framework for text classification," *Journal of King Saud University-Computer and Information Sciences*, Vol.34, No.10, pp.8825-8837, 2022.

Appendix

Number	Terms
1.4	Law and Language
1.5	Priority of Documents
1.7	Assignment
1.9	Errors in the Employer's Requirements
1.15	Limitation of Liability
2.1	Right of Access to the Site
4.2	Performance Security
4.4	Subcontractors
4.6	Co-operation
4.10	Use of Site Data
4.12	Unforeseeable Physical Conditions
8.1	Commencement of Works
8.2	Time for Completion
8.5	Extension of Time for Completion
8.8	Delay Damages
8.9	Employer's Suspension
8.10	Consequences of Employer's Suspension
8.11	Payment for Plant and Materials after Employer's Suspension
8.12	Prolonged Suspension
9.1	Contractor's Obligations
9.3	Retesting
9.4	Failure to Pass Tests on Completion
11.1	Completion of Outstanding Works and Remedying Defects
11.2	Cost of Remedying Defects
11.3	Extension of Defect Liability
11.4	Failure to Remedy Defects
11.9	Performance Certificate
13.1	Right to Vary
13.2	Value Engineering
13.3	Variation Procedure
13.6	Adjustments for Changes in Laws
13.7	Adjustments for Changes in Cost
14.2	Advance Payment
14.7	Payment
14.8	Delayed Payment
15.2	Termination for Contractor's Default
15.3	Valuation after Termination for Contractor's Default
15.4	Payment after Termination for Contractor's Default
15.5	Termination for Employer's Convenience

Number	Terms
15.6	Valuation after Termination for Employer's Convenience
15.7	Payment after Termination for Employer's Convenience
16.1	Suspension by Contractor
16.2	Termination by Contractor
16.3	Contractor's Obligations After Termination
16.4	Payment after Termination by Contractor
17.1	Responsibility for Care of the Works
17.2	Liability for Care of the Works
17.3	Intellectual and Industrial Property Rights
17.4	Indemnities by Contractor
17.5	Indemnities by Employer
18.1	Exceptional Events(Force Majeure)
18.2	Notice of an Exceptional Event
18.3	Duty to Minimise Delay
18.4	Consequences of an Exceptional Event
18.5	Optional Termination
20.2	Claims For Payment and/or EOT
21.6	Arbitration



이 희 준

<https://orcid.org/0000-0002-3155-7966>
 e-mail : leej3471@gmail.com
 2019년 계명대학교 경영정보학 전공(학사),
 비즈니스데이터분석 부전공
 2021년 계명대학교 경영정보학과(석사)
 2020년~현 재 (주)빅웨이브에이아이 대표

관심분야: 딥러닝, 머신러닝, 추천시스템 등



오 상 진

<https://orcid.org/0009-0009-6104-2101>
 e-mail : dhtkdwls537@hec.co.kr
 2018년 을지대학교 의료IT마케팅학과(학사)
 2020년 연세대학교 정보대학원 정보보호
 전공(석사)

2020년~현 재 현대엔지니어링(주) 스마트ICT팀 매니저
 관심분야: 딥러닝, 컴퓨터 비전, 자연어처리 등



이 현 상

<https://orcid.org/0000-0002-3155-7966>
 e-mail : coolwin200@gmail.com
 2018년 경북대학교 경영학부(학사)
 2020년 경북대학교 경영정보 전공(석사)
 2020년~현 재 (주)빅웨이브에이아이
 데이터 분석팀 팀장

관심분야: 딥러닝, 빅데이터, 시스템 개발 등



유 상 우

<https://orcid.org/0009-0000-5124-2630>
 e-mail : ysw2864@hec.co.kr
 2020년 University of California, Davis
 Computer Science 전공(학사)
 2021년~현 재 현대엔지니어링(주)
 스마트ICT팀 매니저

관심분야: 자연어처리, 딥러닝, 머신러닝 등



이 원 석

<https://orcid.org/0009-0000-9754-9689>
 e-mail : ifu.seok@gmail.com
 2019년 계명대학교 통계학 전공(학사)
 2019년 계명대학교 비즈니스 빅데이터
 전공(학사)
 2021년 계명대학교 경영정보학(석사)

2020년~현 재 (주)빅웨이브에이아이 CTO
 관심분야: 자연어처리, 추천시스템, 머신러닝 및 딥러닝



남 마 루

<https://orcid.org/0009-0009-9884-7325>
 e-mail : maru@hec.co.kr
 2009년 한양대학교 법학과(학사)
 2010년~현 재 현대엔지니어링(주)
 해외법무팀 책임매니저
 관심분야: 국제계약, 국제중재, AI 등



조 보 근

<https://orcid.org/0009-0008-2857-0853>
 e-mail : iambgjo@gmail.com
 2018년 Eastern Michigan University
 Computer Information System
 전공(학사)
 2020년 경북대학교 경영정보 전공(석사)

2020년~현 재 (주)빅웨이브에이아이 이사
 관심분야: 딥러닝, 자연어처리, 시계열 예측 등



이 현 식

<https://orcid.org/0009-0007-3838-2103>
 e-mail : hslee74@hec.co.kr
 2000년 동국대학교 컴퓨터학과(학사)
 2022년 고려사이버대학원 융합정보학과(석사)
 2016년~현 재 현대엔지니어링(주)
 스마트ICT팀 팀장

관심분야: ICT 전략 기획, 데이터 분석 등