# 2021년 지질자원 데이터 활용 및 인공지능 경진대회 최종 제안서

머신러닝 모델을 이용한 광산 운반시스템의 예측과 문제 진단

박세범1), 정다희2), 최요순3)

## I. 서론

## 1. 문제정의

### (1) 광산 운반시스템의 개념과 운영원리

철, 구리, 아연, 석회석, 골재, 우라늄 등의 광물자원은 인류가 살아가는 데 필수적인 요소이다. 철강, 자동차, 전자, 화학, 조선, IT 산업 등 우리나라 주력산업에 사용되는 원료 대부분이 광물자원에서 만들 어진다. 특히, 에너지전환 및 4차 산업혁명 시대 도래로 전기·자율차, 재생에너지, 바이오·헬스, 반도체· 디스플레이산업 등 미래 신산업들이 급부상함에 따라 첨단산업의 원료로서 광물자원의 중요성이 커질 것으로 전망된다.

분야	사용 희유금속
① 저기·자유차	• 이차전지(리튬, 코발트, 니켈, 망간, 흑연), 경량소재(니켈, 마그네슘, 크
	롬, 니오븀), 모터(희토류) 등
ી તા ગોરો	• 센서(주석, 탄탈륨, 바나듐), 전자부품(니켈, 크롬, 텅스텐), 모터(희토
② 101 기范	류), 금속부품(니켈, 크롬) 등
ത പിച്ചിച്ചിക്ക്	▪ ESS(리튬이온배터리, 바나듐레독스흐름전지 원료), 신재생(태양광∶실
③ 에너시신간입	리콘, 인듐, 갈륨, 셀레늄, 풍력: 니켈, 크롬, 몰리브덴) 등
④ 바이오·헬스	• 첨단의료기기(티타늄, 마그네슘, 크롬, 니켈, 텅스텐) 등
⑥ 바드케.디스프레이	• 반도체(실리콘, 텅스텐, 몰리브덴, 갈륨, 비소), 디스플레이(희토류, 실
① 린도제·너즈클데이	리콘, 텅스텐, 니켈, 인듐) 등

[표 1] 미래 신산업에 사용되는 희유금속 광물자원 [1]

광업은 지하 또는 지표상의 유용한 광물자원을 채광, 선광, 운송 등을 과정을 거쳐 소비지까지 공급하 는 산업 활동을 말한다. 이를 위해 자산(채광장, 장비, 광석), 공정(프로세스), 사람(의사결정)이 유기적으 로 결합하여 하나의 시스템을 구성한다(그림 1). 채광작업을 통해 광산에서 채굴된 광석(원석)은 선광장 으로 운반되며, 선광작업을 통해 가공된 제품은 다양한 운송 수단을 이용해 제철소, 제련소, 시멘트 공 장 등 소비지로 운송된다. 본 연구에서는 광산에서 채굴된 광석(원석)을 선광장까지 운반하는 시스템을 '광산 운반시스템'으로 정의하고, 이 시스템의 예측과 문제 진단에 사용될 수 있는 인공지능 모형을 개 발하고자 한다.

<sup>1)</sup> 부경대학교/에너지자원공학과 (sebumilv@gmail.com)

<sup>2)</sup> 부경대학교/에너지자원공학과 (98dahee@naver.com)

<sup>3)</sup> 부경대학교/에너지자원공학과 (energy@pknu.ac.kr)



[그림 1] 광물자원 공급 시스템의 구성과 절차

광산에서 광석을 채굴하여 선광장까지 운반하는 작업은 천공, 발파, 적재, 운반으로 구성된 단위작업 들로 구성된다(그림 2). 따라서 이러한 단위작업들로 구성된 생산 공정을 효과적으로 설계하고 관리하는 것이 중요하다 [2-4]. 생산 공정의 설계에 따라 광산의 생산성과 수익이 크게 달라질 수 있기 때문이다. 특히, 일반적으로 운반작업에 투입되는 비용은 전체 생산 비용의 절반 이상을 차지하기 때문에 광산 운 반시스템의 효율적으로 설계하고, 운영하는 것은 매우 중요하다 [5].



[그림 2] 광산의 단위작업

광산 운반시스템에서는 채광 작업장(막장)에서 채굴된 많은 양의 광석(원석)들이 길고 가파른 경로를 통해 선광장까지 지속해서 운반된다. 트럭, 철도, 컨베이어 벨트 등 다양한 장비들이 광산 운반시스템에 사용될 수 있으나, 다수의 트럭과 적재장비(쇼밸, 굴삭기, 로더 등)를 조합한 운반시스템이 일반적으로 사용되고 있다. 다수의 트럭과 적재장비로 구성된 광산 운반시스템의 작동원리는 Suboleski [6]가 제안 한 트럭 순환시간 이론을 이용하여 식 (1)과 같이 설명할 수 있다.

## TCT = STL + LT + TL + STD + DT + TE + AD(1)

여기서 TCT는 트럭 순환시간(사이클타임), STL(spotting time at the loader)은 적재장비로의 트럭 접근시간을 나타내고, LT(loading time)는 적재장비의 작업시간, TL(travel time of loaded truck)은 광 석을 적재한 트럭(실차)이 파쇄장으로 이동하는 시간, STD(spotting time at the crusher)는 파쇄기(광석 투하지점)로의 트럭 접근시간, DT(dumping time)는 트럭의 투하 작업시간, TE(travel time of empty truck)는 공차가 적재장으로 다시 이동하는 시간, AD는 적재장이나 파쇄장에서 트럭이 대기행렬에 들어 가 기다려야 하는 시간(average delay time)을 의미한다. 그림 3은 실제 광산 운반시스템에서 트럭 순환 시간 이론에 따라 진행되고 있는 트럭과 로더의 작업 모습을 보여준다. 트럭 순환시간과 이를 구성하는 각각의 시간 인자들의 단위는 분(min) 또는 초(sec)를 사용한다.



[그림 3] 트럭순환시간 이론에 따른 광산 운반시스템의 작동원리

식(1)을 좀 더 단순화하기 위해 적재장비로의 트럭 접근시간(STL)을 적재장비의 작업시간(LT)에 포 함하고, 파쇄기로의 트럭 접근시간(STD)을 트럭의 투하 작업시간(DT)에 포함해 함께 고려하면 식(2)와 같이 트럭 순환시간(TCT)을 표현할 수 있다.

$$TCT = LT + TL + DT + TE + AD \tag{2}$$

## (2) 광산 운반시스템 예측 및 문제 진단의 필요성

광산의 생산성과 수익성은 운반시스템의 설계와 운영 방법에 따라 크게 달라질 수 있다 [2-4]. 따라서 광산 운반시스템을 구성하는 장비의 이용 효율을 극대화하고 작업자의 안전을 보장하면서도 지연시간 없이 빠르게 작업을 수행할 수 있는 최적의 작업 공정(프로세스)을 설계하는 것이 매우 중요하다 [7,8]. 이를 위해서는 광산 운반시스템의 운영 시나리오에 따른 주요성능지표(트럭 사이클타임, 광석 생산량, 장비 이용률, 지연시간 등)를 예측하고 시나리오 간의 비교를 통해 운반작업에 투입되는 장비들의 종류, 수, 배차방식 등을 최적화할 필요가 있다.

광산 운반시스템의 예측을 통해 최적의 작업 공정이 설계되었더라도 실제 운영에 있어 계획대로 이행 이 되었는지를 확인할 필요가 있다. 광산 운반시스템은 장비, 작업자, 작업장 환경이 상호작용을 하며 공정이 진행되기 때문에 시스템의 모니터링을 통해 장비의 고장, 운반도로 상태 등에 대한 문제를 진단 하여 예지 정비를 통해 최적의 작업 공정 설계에 따라 시스템에 운영될 수 있도록 해야 한다.

### (3) 인공지능 모형 개발의 필요성

최근 광산 현장에는 4차산업혁명 시대의 디지털 전환에 대응하여 스마트 마이닝 기술이 도입되고 있 다. 스마트 마이닝 기술이란 광산의 자산(제품, 장비, 환경), 공정(프로세스), 사람(의사결정)을 지능정보 기술(AICBM)로 연결하여 실시간 모니터링, 예측, 진단, 최적화, 자동화를 통해 생산성과 안전성을 향상 시키는 기술이다(그림 4).



[그림 4] 스마트 마이닝 기술 개념

사물인터넷과 스마트 세서 기술이 적용됨에 따라 광산 현장에서는 많은 양의 데이터가 실시간으로 생 산, 수집, 공유되고 있다. 현재는 안전 모니터링을 위해 광산 현장의 작업 상황을 대시보드를 통해 실시 간 표출하는 정도로 활용되고 있다. 현장에서 수집된 빅데이터를 활용하여 광산 운반시스템 예측과 문 제 진단을 위한 인공지능 모형을 개발한다면 트럭 사이클 타임, 광석 생산량 등 시스템 성능지표를 예 측하고 장비 또는 운반 도로의 이상 여부를 진단하여 광산의 생산성과 수익성 개선을 위해 활용될 수 있을 것이다(그림 5).



공정(프로세스)

자산(광석/장비/작업장)

[그림 5] 광산의 자산(장비/환경)-공정(프로세스)-사람(의사결정)-인공지능(예측/진단)의 결합을 통한 운반시스템의 효율적 운영 전략

### 2. 기존연구 분석

#### (1) 광석 생산량 예측

머신러닝을 활용하여 생산량을 예측한 연구가 다수 수행되었다. 지하 광산에 설치된 무선 네트워크 시스템을 사용하여 얻은 장비 추적 데이터를 사용하여 트럭 운송 시스템의 광석 생산 및 파쇄기 활용을 예측하는 DNN 모델을 개발한 연구가 수행되었다 [9].

Baek and Choi [9]는 광물자원의 개발 및 운영 단계에서 사용될 수 있는 머신러닝 기술의 하나로서 DNN 모델을 이용하여 지하광산 트럭 운반 시스템의 광석 생산량과 파쇄기 이용률을 예측할 수 있는 새로운 방법을 제시하였다. ICT 기반 광산 안전관리시스템이 설치된 석회석 지하 광산을 연구지역으로 선정하고, 트럭 운반 시스템의 특성을 반영하여 DNN 모델의 입/출력 노드를 설계하였다. 2018년 10월 한 달간 현장에서 수집된 빅데이터를 처리하여 DNN 모델의 학습 데이터를 9,072개 생성하였고, 이 중 75%는 훈련(training), 25%는 검증(validation) 데이터로 활용하였다. 최적의 DNN 학습 모델을 선정하기 위해 DNN 모델의 은닉층 개수와 은닉층의 노드 개수를 다양하게 설정하면서 훈련/검증 데이터에 관한 결정 계수와 평균 절대 백분율 오차(MAPE)를 분석하였다. 그 결과 광석 생산량 예측을 위한 최적 DNN 모델 구조는 은닉층 5개, 은닉층 노드 개수 40개로 선정되었고, 이때 검증 데이터에 관한 결정 계 수는 약 0.99, MAPE는 약 2.80%로 나타났다. 파쇄기 이용률 예측을 위한 최적 DNN 모델 구조는 은닉 층 4개, 은닉층 노드 개수 40개로 선정되었고, 검증 데이터에 관한 결정 계수는 약 0.99, MAPE는 약 2.49%로 분석되었다. 학습된 DNN 모델을 이용하여 2018년 11월 1일부터 10일 동안의 광석 생산량과 파쇄기 이용률을 예측하였다. 광석 생산량에 대한 평균 제곱근 오차(RMSE)는 6.92 tons, 파쇄기 이용률 에 대한 RMSE는 0.04%로 분석되었다.

노천광산을 대상으로 ICT 기반의 광산안전관리시스템이 설치된 노천광산을 대상으로 오전 및 오후 광석 생산을 예측하는 두 개의 DNN 모델을 개발한 연구와 광석 생산을 예측하기 위한 다양한 머신러 닝 알고리즘의 개발하고 타당성을 평가하는 연구가 진행되었다 [10,11]. 그러나 데이터가 획득된 시스템 의 작동 매개변수와 운송 작업 주기만 고려할 수 있다는 한계점이 있었다(그림 6).





광산의 원석 운반과 관련된 문제를 해결하기 위해 이산사건 시뮬레이션을 Rist가 처음으로 구현한 이 래로, 많은 연구자들이 이산사건 시뮬레이션에 대한 연구를 수행해왔다. 최근에는 광산 운반시스템의 운 영방식과 장비 배차계획을 최적화하고 생산량을 예측하기 위한 이산사건 시뮬레이션(Discrete Event Simulation, DES) 기법들이 개발되고 있다 [12-31]. Ozdemir and Kumral [13]은 노천광산에 투입되는 트럭의 이동시간을 최소화하기 위해 시뮬레이션 기법을 활용하였으며, 수학적 최적화 방법을 이용한 실 시간 트럭 배차 방법을 제안하였다. Salama and Greberg [14]는 지하광산의 운반작업에 사용되는 트럭 의 수를 최적화하기 위해 LHD (loading-haulage-dumping machines)와 트럭으로 구성되는 적재-운반 시스템 시뮬레이션을 수행하였다. Torkamani and Askari-Nasab [19]은 노천광산의 트럭-쇼밸 자재 취 급 및 운반시스템의 거동을 분석하기 위해 이산사건 시뮬레이션 모델을 개발하였다. Choi [21]는 GPSS/H 시뮬레이션 언어를 이용하여 노천광산의 쇼밸-트럭 운반시스템을 모사할 수 있는 이산 사건 시뮬레이션 프로그램을 개발하였다. Choi and Nieto [4]는 이를 확장하여 트럭의 최적 운반경로 분석한 다음 그 경로를 따라 운반 장비들의 이산 사건 시뮬레이션을 수행할 수 있도록 하였으며, 시뮬레이션 결과를 가시화할 수 있는 기능을 제공하였다. Park and Choi [22-27]는 고정/실시간 트럭 배차방식, 파 쇄기 용량, 트럭의 고장 발생 가능성 등 다양한 조건들을 고려하여 트럭-로더 운반시스템을 시뮬레이션 할 수 있는 GPSS/H 기반의 프로그램들과 사용자 편의성을 갖춘 Windows용 프로그램을 개발하였다.



[그림 7] 트럭--로더 운반시스템을 시뮬레이션하기 위한 알고리즘 [26]

## (2) 문제 진단

광산 운반시스템에 대한 최적의 운영계획이 수립되었다면 운반시스템의 운영상태를 지속적으로 모니 터링하고 문제를 사전진단하여 정비하는 것은 매우 중요하다. 이를 위해, 광산의 운반시스템이나 장비의 작동상태를 모니터링하고 진단하는 것에 관한 연구가 다양한 연구자에 의해 수행되었다. Thompson et al. [32]은 기존의 광산 통신 및 자산 관리 시스템과 트럭에 설치된 온보드 멀티센서를 통해 수집되는 데이터를 통합하여 광산 유지관리시스템의 기초를 제공하였다. Park and Choi [33]는 블루투스 비콘과 태블릿 PC를 사용하여 수집되는 트럭 이동시간 자료를 수집할 수 있는 시스템을 개발하였다. 또한, 수 집된 데이터 이용하여 지하광산의 운반경로 상태를 분석하고 진단하는 방법을 제안하였다. Wodecki et al .[34]은 광산장비의 작동 파라미터를 이용하여 기계 고장 이벤트(failure event)의 주요 원인을 식별할 수 있는 모니터링 시스템을 제안하였다. Carvalho et al. [35]은 드론에 열화상 카메라를 결합하여 벨트 컨베이어의 중요한 구성 요소 중 하나인 롤러의 고장을 자동을 식별할 수 있는 시스템을 개발하였다 (그림 8).

최근에는 광산의 운영시스템과 자산을 모니터링하고 고장진단과 적절한 유지관리를 수행하기 위해 머 신러닝 기법을 활발히 활용하고 있다. Paduraru and Dimitrakopoulos [36]는 데이터 기반 의사결정 프로 세스에서 신경망과 정책경사 강화학습(policy gradient reinforcement learning)을 활용하여 대규모 광산 단지의 자재 흐름을 최적화하였다. Ristovski et al.[29]은 채굴작업에 사용되는 장비의 활동 기간에 대한 확률분포를 예측하기 위해 머신러닝을 활용하였다. Zhang et al. [37]는 탄광에서 스크레이퍼 컨베이어의 결함을 진단하고 분류하기 위해 머신러닝 기술인 서포트 벡터 머신(SVM)을 사용했다. D'Angelo et al. [38]는 딥러닝 아키텍처를 기반의 객체감지모델을 이용하여 벨트 컨베이어 롤러의 결함을 실시간으로 진단하는 방법을 제안하였다. 이처럼 광산 운영시스템과 장비 및 설비에 대해 모니터링하고 고장진단을 위해 다양한 연구자들이 머신러닝 기법을 활용하고 있다. 그러나 지금까지 머신러닝 기법을 활용하여 광산의 운반시스템을 모니터링하고 상태를 진단하는 것에 관한 연구 사례는 전혀 없는 실정이다.



[그림 8] 벨트 컨베이어 롤러의 고장을 진단할 수 있는 시스템: (a) 솔루션의 주요 부분, (b) 미들웨어 연결 및 프로토콜 변환 [35]

## 3. 연구목표

본 연구에서는 머신러닝 기법을 이용하여 광산 운반시스템의 예측과 문제를 진단할 수 있는 모형을 제안하고자 한다 (그림 9). 이를 위해 국내 석회석 지하광산을 연구지역으로 선정하고, 태블릿 PC와 블 루투스 비콘을 이용하여 트럭 이동시간과 관련한 로그 데이터를 수집하였다. 또한, 수집된 데이터를 사 용하여 머신러닝 모델을 학습했다. 학습된 모델을 이용하여 연구지역 운반경로의 트럭별 운행시간 (travel time)과 생산량을 예측하고 진단 및 분석한 결과를 제시하였다. 그림 10은 본 연구에서 개발할 광산 운반시스템의 예측 및 문제 진단 기술의 개요를 보여준다.



## 머신러닝 모델을 이용한 광산 운반시스템의 예측과 문제 진단

[그림 9] 인공지능 모형 개발 목표



[그림 10] 광산 운반시스템의 예측과 문제 진단 기술의 개요

## II. 연구지역 및 데이터 수집

## 1. 연구지역

지하광산 현장에서 수집한 운반시스템의 로그 데이터를 기반으로 운반시스템의 예측과 문제를 진단하 고 분석할 수 있는 머신러닝 모델을 개발하기 위해 강원도 정선에 위치한 성신미네필드(37°17′12″N, 128°43′53″E)를 연구지역으로 선정하였다. 그림 11은 연구지역의 항공사진과 지하광산 도면을 보여 준다. 이 광산은 주방식 채광법을 적용하여 연간 100만 톤의 고품질 석회석을 생산하고 있다. 점보 및 크롤러 드릴을 사용하여 V-Cut 방법으로 천공하며, 초유폭약(ANFO), 에뮬라이트, 전기뇌관(6 ms)을 사 용해 하루 평균 8~9회 발과하여 약 4,500 톤의 석회석을 생산하고 있다(그림 12). 채굴된 석회석은 로 더(3.0~5.6㎡)를 이용해 25~40톤 덤프트럭에 적재하여 갱외에 위치한 선광장으로 운반하고 있다. 연구 지역은 8개의 적재구역과 3개의 하역지점을 운영하고 있으며, 3대의 로더와 10대의 트럭을 투입하여 석 회석을 생산하고 있다.



[그림 11] 연구지역(성신미네필드 석회석 지하광산)의 적재 및 하역지점



[그립 12] 연구지역 현장조사('20.7~11월): (a) 차량정비소 및 대기장소, (b) 적재지점(Area B), (c) 갱 내 작업 중인 안포장전기

### 2. 데이터 수집

### (1) 데이터 수집방법

연구지역에서 트럭 운반시스템과 관련한 로그 데이터를 수집하기 위해 근거리 무선 통신 기기인 블루 투스 비콘과 태블릿 PC를 이용하여 광산생산관리시스템(Mine Production Managemnet System, MPMS)을 개발하였다. 비콘은 위치정보를 포함한 블루투스 신호를 주기적으로 송신하는 장치이다. 비콘 제품 중에는 블루투스 이외에 초음파, Wi-Fi, 가시광선 등의 신호를 이용하는 것도 있으나, 블루투스 (BLE) 기반의 비콘 제품이 주류를 이루는 이유는 다른 송신원에 비해 소비 전력이 매우 작기 때문이다 [39]. 최근에 개발된 블루투스 비콘의 경우 일반 건전지로도 수년 동 안 작동시킬 수 있으며, 사용자 스 마트폰의 배터리 소모량 또한 매우 작다. 블루투스 비콘 제품의 대표적인 표준으로는 2013년 애플이 발 표한 iBeacon과 2015년 구글에서 발표한 Eddystone이 있다.

블루투스 비콘은 주기적으로 사용자 정보(ID)와 수신된 신호의 세기(received signal strength indication, RSSI) 값을 블루투스 신호로 송신한다. 스마트폰 사용자가 신호 도달영역 내로 진입하면 스 마트폰 앱에서 블루투스 비콘의 신호를 수신하여 클라우드 서버로 사용자 정보를 전달하며, 클라우드 서버에서는 개별 사용자 정보를 인식한 뒤 관련된 적절한 서비스 정보를 사용자의 스마트폰 앱으로 송 신하여 블루투스 비콘 기반의 서비스가 이루어지게 된다(그림 13 (a)). 블루투스 비콘을 활용하면 응용 시스템 개발을 통해 사용자에게 실내 위치측위, 주변 환경변화 감지, 광고, 자동결제 등 다양한 서비스 를 제공할 수 있다(그림 13(b)).



[그림 13] 블루투스 비콘의 작동 원리와 서비스 유형: (a) 작동원리, (b) 서비스 유형

주요 구간별 트럭이동시간 데이터는 갱내/외에 설치된 블루투스 비콘과 차량에 탑재된 태블릿 PC를 이용하여 수집된다. 작동은 다음과 같은 순서로 이루어진다. (1) 운반경로 상의 주요 지점, 선광장(파쇄 기) 및 로더에 설치된 블루투스 비콘의 신호를 트럭에 탑재된 태블릿 PC로 수신한다. (2) 태블릿 PC는 신호가 수신된 시간, 트럭의 위치를 기록한다. 트럭 운전기사는 원석의 적재, 운반 및 하역작업이 1회 완료되면 운행 중 문제발생 여부(정상 혹은 비정상)를 입력한다. (3) 내장메모리에 저장된 자료 (데이터) 들을 무선통신이 가능한 구역에서 클라우드 서버로 전송한다. (4) 마지막으로, 클라우드 서버는 태블릿 PC가 설치된 다수의 트럭에서 전송한 자료를 지속적으로 저장하고 관리한다. 그림 14는 블루투스 비콘 과 태블릿 PC를 이용하여 구현한 광산생산관리시스템의 작동원리를 보여준다. 시스템의 작동과 관련한 자세한 내용은 Park and Choi [40]를 참고하길 바란다. 태블릿 PC는 운반작업에 투입되는 7대의 트럭에 설치하였다. 블루투스 비콘은 적재 및 하역지점(각각 8개, 3개), 그리고 운반경로 상의 주요지점(11개)에 설치하였다. 그림 15는 연구지역에 설치된 태블릿 PC와 블루투스 비콘의 예시를 보여준다. 적재지점과 하역지점, 주요 운반경로상에 설치된 블루투스 비콘의 위치를 나타내는 모식도는 그림 16과 같다.



[그림 14] 블루투스 비콘 및 태블릿 PC를 이용한 광산생산관리시스템의 작동원리



[그림 15] 로그 데이터 수집을 위해 설치된 블루투스 비콘 및 태블릿 PC의 예: (a) 운반갱도의 벽면, (b) 하역지점의 파쇄기 근처, (c) 트럭 운전석의 앞 유리



[그림 16] 연구 지역의 적재 및 하역 지점과 블루투스 비콘 설치지점 간의 운반 경로: (a) 2D 지도; (b) 모식도

### (2) 수집된 데이터의 형식/기간/양

MPMS를 이용하여 수집되는 로그 데이터는 쉽표를 기준으로 항목들을 구분하여 데이터를 저장하는 CSV(comma-separated variables) 파일 형식을 가진다. 로그 데이터 파일에는 태블릿 PC가 블루투스 비 콘의 신호를 수신할 때, 비콘의 설정되어있는 ID와 정보, 수신 시간, 차량 정보, 광석 운반 이외의 다른 작업을 수행했거나 작업이 비정상적으로 진행되었을 때 운전자가 직접 입력한 메모가 기록된다. 그림 17은 날짜별, 트럭별로 클라우드 서버에 업로드된 로그 데이터 파일을 엑셀(Excel) 소프트웨어를 이용하 여 불러온 것이다. 본 연구에서는 운반경로의 트럭별 운행시간과 생산량을 예측하고 진단하기 위해 15 주 동안 총 51,732개의 로그 데이터를 수집하였다.

1	차량번호	날짜(YYYYMMDD)	시간(hhmmss)	비콘ID	구분	지점명
2	강원06고3580	20201109	82724	SSM10027	갱도	2사갱 운반로(455ML)
3	강원06고3580	20201109	82854	SSM10020	갱도	3갱 운반로(480ML)
4	강원06고3580	20201109	83232	SSM12039	공장	2공장
5	강원06고3580	20201109	83831	SSM10019	갱구	3갱 입구(480ML)
6	강원06고3580	20201109	84010	SSM11015	작업장	2사갱 작업 <mark>장(</mark> 470ML)
7	강원06고3580	20201109	84114	SSM10027	갱도	2사갱 운반로(455ML)
8	강원06고3580	20201109	85303	SSM11015	작업장	2사갱 작업장(470ML)
9	강원06고3580	20201109	85424	SSM10020	갱도	3갱 운반로(480ML)
10	강원06고3580	20201109	85709	SSM12039	공장	2공장

[그림 17] 광산생산관리시스템에 의해 수집되는 로그 데이터 예시

구간별 트럭이동시간은 순차적으로 기록된 로그 데이터를 이용하여 계산할 수 있다. 그림 18은 로그 데이터를 불러와 블루투스 비콘이 설치된 지점 사이의 트럭이동시간을 계산하는 방법을 보여준다. 먼저 태블릿 PC가 비콘의 신호를 감지할 때마다 기록되는 각 로그 파일의 로그 데이터들을 하나의 데이터 시트로 취합한다. 다음으로, 로그 데이터를 다시 차량 ID, 날짜별로 구분하여 비콘의 신호를 수신한 순 서에 따라 경로 조합(출발지 및 도착지의 비콘 ID로 구성)을 생성하고 이에 대한 트럭 이동시간을 계산 한다. 마지막으로, 동일한 경로 조합에 대한 트럭 이동시간의 통계값을 출력한다. 출력되는 통계값의 항 목에는 경로 ID(출발지 및 도착지의 비콘 ID로 구성) 별 데이터의 수, 평균 트럭 이동시간, 표준편차, 최 소 및 최대 이동시간, 백분위수(P90, P75, P25, P10)가 있다. 이러한 과정을 통해 총 42,808개의 구간별 트럭이동시간 데이터와 444개 구간에 대한 데이터 통계값을 수집하였다.



[그림 18] 로그 데이터를 이용한 구간별 트럭이동시간 계산 방법 [33]

본 연구에서는 MPMS를 이용하여 수집되는 구간별 트럭이동시간 데이터를 검증하기 위해 연구지역 을 방문하여 직접 타임스터디를 수행하였으며, 일주일 기간의 차량운행일지를 확보하였다. 타임스터디는 트럭 운반시스템에 투입되는 덤프트럭에 직접 탑승한 후 블루투스 비콘이 설치된 지점 간의 트럭이동시 간을 스톱워치를 이용해 측정하였다(그림 19). 표 2는 Crusher 3과 Area E 사이의 구간을 운행하였던 트럭에 탑승하여 측정한 트럭이동시간(사이클 타임)을 나타낸다.



[그림 19] 스톱워치를 이용한 트럭이동시간(사이클 타임) 측정

Beacon IDs		Truck transport time (mm:ss)										
(20 ~ 4)	1회차	2회차	3회차	4회차	5회차	6회차	7회차	8회차				
Lap 1	10:23.7	05:33.6	03:33.1	03:49.7	04:55.8	08:46.1	09:04.0	09:33.4				
Lap 2	03:46.1	03:11.2	03:33.9	03:48.9	03:12.7	03:01.3	03:00.5	04:06.9				
Lap 3	03:12.2	03:01.9	03:17.2	03:00.9	03:15.6	03:10.5	03:12.4	03:00.1				
Lap 4	02:44.4	02:28.8	02:58.6	02:55.1	02:08.6	01:53.0	02:10.6	02:09.3				
Lap 5	01:05.2	00:43.8	01:14.8	00:52.3	00:49.2	00:35.0	00:41.6	00:45.1				
Lap 6	01:34.0	03:02.1	01:40.4		04:58.3	04:27.6	05:01.1					
Cycle time	22:45.6	18:01.4	16:18.0		19:20.2	21:53.5	23:10.2					

[표 2] 스톱워치를 이용하여 측정한 트럭이동시간의 예시(구간: Crusher 22 ~ Area 4)

광석의 적재 및 운반과 관련한 정보가 기록되어있는 생산일지는 날짜별, 트럭별로 구분하여 일주일 기간('20.11.23~28)의 차량운행일지 사본을 확보하였다. 연구지역에서 사용하고 있는 차량운행일지에는 차량 정보 및 운행기록, 운행 현황(출발지, 출발시간, 도착지, 제품명 등), 정비내역 등이 기록되고 있다. 그림 20은 성신미네필드에서 작성하고 있는 차량운행일지의 예시 이미지를 보여준다.



[그림 20] 성신미네필드의 차량운행일지 예시

평균기온과 강수량 데이터는 기상자료개방포털(data.kma.go.kr)에 공개되어있는 종관기상관측 자료에 서 강원도 정선군의 평균기온과 일강수량을 이용하였다.

## III. 머신러닝 모형 개발 방법

## 1. 생산량 예측 모형 개발 방법

## (1) 사이클 타임 예측 머신러닝 모형 개발

가. 머신러닝 모형 설계

지하광산의 사이클타임 예측을 위해 머신러닝 모델의 학습 및 검증을 위한 데이터수집, 데이터 처리, 머신러닝 알고리즘 적용, 머신러닝 모델 검증 및 최적 모델 선정 순으로 연구를 진행하였다. 사이클타임 은 운전자의 숙련도, 운반 도로의 경사와 거리, 환경적인 요인(기온, 강수량)에 의해 영향을 받는다. 따 라서 사이클 타임 예측 모델을 학습 데이터는 표 3과 같이 4개의 입력변수와 사이클 타임을 예측하는 레이블로 구성되어 있다. 범주형 데이터에는 운반 경로, 트럭의 종류(번호판)가 포함된다. 연속형 데이터 에는 일 평균기온, 일 강수량이 포함된다. 머신러닝 모델 학습을 위한 데이터는 광산생산관리시스템에서 수집한 트럭 이동시간과 관련한 로그데이터와 기상청에서 제공한 기상 데이터를 이용하여 수행하였다.

Data set	Description	Data type		
	Path ID	Character		
Fasturas	Truck ID	Character		
reatures	Average daily temperature	Celsius temperature (°C)		
	Daily precipitation	Millimeter (mm)		
Label	Truck cycle time	Float (min)		

[표 3] 머신러닝 모델 학습을 위한 데이터세트의 설명 및 데이터 유형

### 나. 훈련 데이터 제작 및 전처리

본 연구에서 사용된 입력변수의 데이터 유형은 범주형 데이터와 연속형 데이터로 구성된다. 머신러닝 알고리즘은 숫자형을 다루므로 문자형 또는 카테고리형을 숫자형으로 변환하는 과정이 필요하다. 범주형 데이터를 숫자형으로 변환하기 위해 원-핫 인코딩(One-hot encoding)을 수행하였다. 이 방법은 세 개 이 상의 카테고리를 정수형으로 변환하면 크기에 대한 정보가 추가되는 문제를 예방하는 방법으로 카테고리 별 이진 특성을 만들어 해결하는 방법이다. 연속형 데이터 중 차원이 다른 데이터는 정규화되지 않기 때 문에 절대값이 작은 변수는 결함 진단 시스템(fault diagnosis system)에서 무시된다. 따라서 데이터는 Min-Max 스케일링 정규화(Min-Max scaling normalization) 방법(식 (2))을 사용하여 정규화하였다.

$$x'_{i} = \frac{x_{i} - \min(x)}{\max(x) - \min(x)}$$
(2)

이 방법은 머신러닝 모델을 훈련시킬 때 과적합을 효과적으로 방지하고 [41] 데이터 전처리를 통해 데이터 항목 간의 절대적인 차이를 제거하면서 동일한 항목 내 데이터의 상대적인 차이를 유지할 수 있 다. 또한, 매개변수의 조정 단계를 줄이고 모델의 훈련속도를 향상시키기 때문에 머신러닝의 효율성을 높일수 있다.

머신러닝 모델 훈련을 위한 데이터세트는 약 400개(366개)의 데이터로 구성하였다. 학습된 모델을 검 증하기 위해 전체 데이터를 훈련 데이터세트와 검증 데이터세트를 75%와 25%로 설정하였다. 연구지역에 설치된 광산생산관리시스템을 이용하여 15주동안 총 42,808개의 구간별 트럭이동시간 데 이터를 수집하여 머신러닝 모델의 훈련과 검증에 사용하였다. 시스템을 이용하여 운반경로, 트럭이동시 간을 제외하고 사이클 타임에 영향을 줄 수 있는 일평균기온, 일강수량은 추가로 입력하였다. 시스템은 구간별로 트럭이동시간이 측정되어 트럭운반경로가 유효한 데이터를 판단한 결과, 총 약 400개(366개)의 데이터가 유효하였다. 훈련 데이터세트를 정규화하기 전에 트럭 이동시간, 일평균기온, 일강수량에 대한 평균값과 표준편차, 최소값 및 최대값을 계산하였다(표 4). 그림 21은 통계값에 대한 히스토그램을 보여 준다. 사이클 타임의 평균은 25.98분, 표준편차는 7.43분으로 나타났다. 일평균기온의 평균은 -4.44℃도, 표준편차는 5.42℃로 나타났다. 일강수량의 평균은 0.31mm, 표준편차는 0.84mm로 나타났다.

	Truck cycle time (min)	Average daily temperature (℃)	Daily precipitation (mm)
Mean	25.98	-4.44	0.31
Standard deviation	7.43	5.42	0.84
Minimum value	14.30	-14.30	0.10
Maximum value	54.50	8.80	6.90

【丑	41	머신러닝	민뎈	학습윽	위하	데이	터세트의	특징
	<b>T</b> I.	1110		- H Z	11 11	- 11		7 0



[그림 21] 머신러닝 모델 훈련을 위한 데이터세트의 특성 분포: (a) 사이클 타임, (b) 일평균온도, 일강 수량

### 다. 머신러닝 알고리즘 적용

kNN 모델은 머신러닝 모델 중 가장 직관적이고 간단한 지도학습 모델 중 하나이다. kNN은 학습을 미리 하지 않고 미뤄두고 있다가 새로운 데이터의 작업 요청이 수신되면 분류를 수행한다. 따라서 인스 턴스 기반 러닝, 메모리 기반 러닝 혹은 레이지 러닝이라고도 한다. kNN 모델의 개념은 k개의 최근접 이웃의 대다수가 속하는 클래스에 분류되지 않은 새로운 예제를 할당하는 것이다. kNN 모델의 경우 훈 련 데이터세트의 샘플 수가 많을 때 오분류의 오류를 줄이는 것이 효과적이다. 그러나 분류 정확도는 이웃 수를 의미하는 k값에 따라 달라지며 k값에 가장 가까운 거리를 계산하는데 사용되는 거리에 따라 크게 달라진다 [42]. 단순한 kNN에서 검색은 새로운 데이터에 더 가깝게 분류된 클래스의 데이터 수에 기반한다. 그림 22는 서로 다른 k값에 따라 데이터를 분류한느 방법을 보여준다.



[그림 22] k값에 따른 kNN 모델의 결과 예시: (a) k=1, (b) k=3

RF 모델은 결정 트리(Decision tree) 모델을 기반으로 발전된 알고리즘으로 무작위로 생성된 수많은 결정 트리들을 합쳐서 숲과 같은 하나의 모델을 만드는 방법이다. 트리 기반 모델들은 간단하고 성능이 뛰어나 인기 있는 지도학습 알고리즘 중의 하나이다. 여러 개의 모델을 조합하여 결과를 예측하는 앙상 블 방식으로 정확도가 높은 모델 하나를 쓰는 것보다 정확도가 낮은 모델을 여러 개의 조합하는 것이 오히려 좋은 성능을 보일 수 있다고 가정하고 사용한다. 따라서 RF는 각 트리에서의 수직 경계들을 합 하여 더 유연한 결과를 생성한다.

SVM은 1992년 Boser et al. [43]에 의해 도입되었으며, 1996년부터 학습 커뮤니티에서 인기를 끌고 있다. 최근에는 생물 정보학 및 이미지 인식의 패턴인식과 관련된 다양한 문제에 성공적으로 적용되고 있다 [44]. 또한, 선형, 비선형 회귀, 분류에 모두 사용될 수 있을 만큼 매우 강력하며 대중적으로 폭 넓 게 사용되고 있다. SVM은 기본적으로 선형 로지스틱 회귀와 같이 데이터를 선형적으로 분류하는 모델 이며, 그림 23과 같이 세 단계에 걸쳐 데이터를 분류한다. 그림 23(a)와 같이 두 개의 클래스로 구성된 2차원 데이터가 있다고 가정한다면, 이 클래스를 분리하는 직선은 무한개의 경우가 나올 수 있지만, SVM의 결정 경계 선택 조건을 사용하면 단 하나의 직선을 선택할 수 있다. 선택 조건은 가장 가까운 각 클래스의 데이터 점들 간의 거리를 최대로 하는 초평면(hyperplane)을 선택하는 것이다. 먼저, 그림 23(b)와 같이 각 클래스 간의 가장 가까운 점들을 선택하고, 이 점들을 포함하는 평행한 두 직선간의 거 리(margin)가 최대가 될 때 이 점들을 포함하는 두 직선을 선택한다. 두 직선을 선택하는데 사용되는 점들은 서포트 백터(support vector)라고 부르며, 이 두 직선이 결정되면, 그림 23(c)와 같이 두 직선의 같은 거리에 위치하는 중앙의 직선이 결정 경계가 된다.



[그림 23] 선형으로 구분 가능한 2차원 데이터의 예시: (a) 두 클래스로 구성된 2차원 데이터, (b) 두 클래스 간의 가장 가까운 점 선택 및 이 점을 포함하는 두 직선 사이의 거리가 최대가 되는 두 직선 선택, (c) 두 직선과 같은 거리에 위치하는 중앙의 초평면 선택

PSO-SVM 모델은 서포트벡터머신의 파라미터를 최적화하기 위해 입자 군집 최적화 알고리즘을 결합 한 알고리즘이다. 입자 군집 최적화 알고리즘은 날아가는 새의 떼와 같은 입자/사회적 동물의 행동에 기 초를 두어 군집의 다양성을 모사한 최적화 기법이며, 1995년 Kennedy와 Eberhart에 의해 개발되었다. 입 자 군집 최적화는 군집지능(swarm intelligence)에서 영감을 받은 계산 알고리즘이다. 군집지능은 입자 환경에서의 인구 또는 균질한 협력 때문에 발생하며 각 입자가 임의의 시작 위치를 갖는 특정 크기를 갖 는다고 가정한다. PSO-SVM에서 입자는 SVM의 하이퍼 파라미터인 C와 gamma를 뜻한다. 식 (3)을 이 용하여 속도( $v_j$ )를 계산하고, 계산된 속도를 사용하여 위치( $x_i$ )를 계산한다(식 (4)). 이렇게 각 입자들이 영역을 돌아다니면서 최적의 하이퍼파라미터 위치를 공유해서 수렴하는 하이퍼 파라미터를 찾게 된다 [45].

$$v_{j}(i+1) = v_{j}(i) + c_{1}r_{1}(P_{best} - x_{j}(i)) + c_{1}r_{1}(G_{best} - x_{j}(i))$$

$$(3)$$

$$x_{i}(i+1) = x_{i}(i) + v_{i}(i+1) \tag{4}$$

DNN 모델은 인간의 신경망 구조에서 모티브를 받아 인간 두뇌와 유사한 형태로 정보를 처리하는 기 술로 인공신경망(ANN, artificial neural networks)에 바탕을 둔 알고리즘이다. 딥러닝은 데이터 속성의 중요도를 알려줄 필요가 없는 장점을 가진다. 입력층(Input layer), 출력층(Output layer), 다수의 은닉층 (Hidden layer)의 계층 구조를 가지는 모델을 DNN 모델이라 지칭하며 많은 수의 신경층을 쌓아 입력된 데이터가 여러 단계의 특징 추출 과정을 거쳐 자동으로 고수준의 추상적인 지식을 추출하는 방식이다. 그림 24는 DNN 모델의 학습과정을 나타낸다. 인간 뉴런에 해당하는 각 노드 간의 정보전달과 연산, 연 산 결과 전달의 반복으로 구성되며 데이터를 전달한다. 최적의 딥러닝 모델을 찾기 위해 은닉층과 노드 의 수를 다양하게 조절하며 최적의 모델을 찾아 데이터를 예측한다.



[그림 24] DNN 모델의 학습 과정 [46]

머신러닝 모델의 성능과 검증 데이터세트에 대한 성능평가의 신뢰성을 향상시키기 위해 5겹 교차 검 증(5-fold cross-validation)을 통한 그리드 서치(grid search)를 활용하였다. 일반적으로 머신러닝 모델의 성능은 매개변수에 따라 달라지며, 머신러닝 알고리즘에 따라 다양한 매개변수가 존재한다. 따라서 높은 정확도를 가지는 모델을 설계하기 위해서는 최적의 매개변수를 설정하는 것이 중요하다. 5겹 교차 검증 은 데이터세트를 5개로 나누어 하나씩 검증 데이터세트로 사용하고 나머지를 모두 합해서 훈련 데이터 세트로 사용하는 방법이다. 이 방법을 사용하면 보유한 데이터의 100%를 검증 데이터세트로 사용할 수 있다. 그리드 서치는 원래 초매개변수(hyper parameter) 공간의 정의된 하위 집합을 기반으로 하는 철저 한 검색방법이다 [47]. 즉, 모델을 생성할 때 사용자가 직접 설정한 초매개변수를 순차적으로 입력하여 가장 성능이 좋은 변수를 찾는 탐색 방법이다. 표 5는 각 모델에서 사용되는 매개변수의 종류와 매개변 수 튜닝을 나타낸다. kNN의 정확도는 이웃 수를 의미하는 k 값에 따라 달라지며, k 값을 최소 1에서 100까지 1씩 증가시켜가면서 정확도를 예측하였다. RF의 정확도는 ccp alpha, min impurity decrease, 리프 노드의 최소 샘플 수(min samples leaf), 각 노드에서 분할에 사용할 최소 샘플 수(min samples split), 각 노드에서 분할에 사용할 최소 샘플 수(min samples leaf), 각 노드에서 분할에 사용할 최소 샘플 비율(min weight fraction leaf)에 의해 달라지기 때문에, ccp alpha와 min impurity decrease는 0에서 10까지 1씩 증가시키고 min samples leaf, min samples split(최소 1~최대 10), min weight fraction leaf(최소 0.1~최대 1)를 각각 1과 0.1씩 증가시켜가며 최적 의 매개변수를 결정하였다. PSO -SVM 모델의 분류 정확도는 매개변수 C와 γ에 의해 크게 달라지기 때문에, 매개변수 C(최소 10~최대 100)와 γ(최소 0.1~최대 1)를 입자 군집 최적화 알고리즘을 통해 모 델의 정확도를 높였다. DNN 모델은 은닉층(hidden layers)과 노드(node)에 의해 정확도가 달라지기 때 문에, 은닉층(최소 2~최대9), 노드(최소 20~최대 90)으로 각각 1과 10씩 증가시켜가며 모델의 정확도를 높였다.

	KNN	RF	PSO-SVM	DNN	
		ccp alpha			
		/ min impurity			
		decrease			
Parameter	Neighbors	/ min samples leaf	C / gamma	hidden layer / node	
		/ min samples split			
		/ min weight fraction			
		leaf			
Min	1	0 / 0 / 1 / 1 / 0.1	10 / 0.1	2 / 20	
max	100	10 / 10 / 10 / 10 / / 1	100 / 1	9 / 90	
Step	(+) 1	(+) 1 / 1 / 1 / 1 / 0.1	_	(+) 1 / 10	

	[丑	51	매개변수	튜닝을	위한	그리드	서치에	사용되는	값
--	----	----	------	-----	----	-----	-----	------	---

### 라. 머신러닝 모형 검증 및 최적 모형 선정

교차검증과 그리드 서치를 이용하여 머신러닝 모델의 학습 정확도가 가장 높게 나타나는 매개변수를 결정하였다. 결정된 모델을 검증 데이터세트를 이용하여 모델의 성능을 검증하였다. 본 연구에서 사용된 회귀 모델의 성능을 나타내는 성능지표인 MAE(mean absolute error), MSE(mean square error), RMSE(root mean square error), R2를 사용하여 모델의 성능을 검증하였다. MAE는 평균 절대 오차로 실제값과 예측값의 차이를 절대값의 평균을 사용한 지표를, MSE는 평균 제곱 오차로 실제값과 예측값 의 차이를 제곱하여 평균한 값으로 오차의 크기를 살펴보는 지표를, RMSE는 MSE의 제곱근으로 오차 의 크기를 살펴보는 지표를, R2는 회귀 직선의 방정식이 얼마나 원래의 자료를 잘 설명하는지를 의미한 다. 각 성능지표에 대한 수식은 아래와 같다. 여기서  $h(x^{(i)})$ 는 i번째 데이터의 모델의 예측값이고,  $y^{(i)}$ 는 i번째 데이터의 레이블을 의미하며, SSE는 추정값에서 곽값의 평균을 뺀 결과의 총합이고, SST는 관측 값에서 관측값의 평균을 뺀 결과의 총합을 의미한다.

$$MAE(X,h) = \frac{1}{n} \sum_{i=1}^{n} \left| h(x^{(i)}) - y^{(i)} \right|$$
(5)

$$MSE(X,h) = \frac{1}{n} \sum_{i=1}^{n} (h(x^{(i)}) - y^{(i)})^2$$
(6)

RMSE
$$(X,h) = \sqrt{\frac{1}{n} \sum_{i=1}^{n} |h(x^{(i)}) - y^{(i)}|}$$
(7)

$$R^2 = 1 - \frac{SSE}{SST} \tag{8}$$

## (2) 생산량 예측 머신러닝--이산사건 시뮬레이션(DES) 모형 개발

가. 머신러닝--이산사건 시뮬레이션 연계 모형 설계

연구지역의 일일 생산량을 예측하기 위해 구간별 트럭 사이클 타임 예측할 수 있는 머신러닝 모형과 이산사건 시뮬레이션(discrete event simulation) 모형을 활용하였다. 그림 25는 트럭 운반시스템을 모사 한 DES 모형이 일일 생산량을 예측하기 위해 입력되는 자료와 시뮬레이션 수행 후 출력되는 자료를 도 식화한 것이다. 시뮬레이션 모델의 입력자료는 운영조건과 관련한 시뮬레이션 인자와 단위작업들의 소 요시간과 관련한 시간 인자로 구분된다. 운영조건과 관련한 시뮬레이션 인자 값은 시뮬레이션 시간(오전 /오후), 트럭 ID 및 트럭용량, 적재지점 등이 포함되며, 시간인자 값에는 공차 및 실차상태의 트럭이동시 간, 적재 및 하역시간이 포함된다. 시뮬레이션 모델의 출력자료에는 총 시뮬레이션 시간, 적재-운반 횟 수, 원석 운반량, 1회 적재-운반시 소요시간이 있다.

**Input data** 

**Output data** 



[그림 25] 트럭 운반시스템 시뮬레이션 모델의 입/출력 자료

운영조건과 관련한 시뮬레이션 인자 값들은 현장직원의 인터뷰와 차량운행일지 분석을 통해 결정할 수 있다. 트럭운반시간 등 시간과 관련한 인자 값들은 머신러닝 모형을 이용하여 예측되는 트럭 배차 시나리오별 사이클 타임을 활용하였다.

### 나. 시뮬레이션 알고리즘 개발

연구지역의 현장 상황과 상기 트럭순환시간 이론을 적용하여 설계한 트럭 운반시스템의 시뮬레이션 알고리즘은 그림 26과 같다. 시스템에 투입된 트럭은 지정된 적재장으로 이동하여 원석을 파쇄장까지 운반하도록 설계되었으며, 사용자가 사전에 설정한 시뮬레이션 시간동안 지속적으로 작업을 수행한다. 애니로직 소프트웨어에서 구현되는 시뮬레이션 모델은 앞서 설계한 시뮬레이션 알고리즘을 반영하여 그 림 27과 같이 구현하였다. 또한, 시뮬레이션 모델의 레이아웃은 그림 16(b)와 같이 적재 및 하역지점, 운 반경로로 구성된 모식도를 이용하여 설계하였다. 그림 27의 시뮬레이션 모델은 특정 적재지점 1곳에 할 당된 트럭 1대에 대해 나타낸 것이며, 트럭의 종류 및 수, 적재지점의 수를 고려하여 확장이 가능하다.



[그림 26] 트럭 운반시스템 시뮬레이션 알고리즘 순서도

source_3580 hold_3580 t	timeStart_3580 select_3580a seize_	3580a select_3580c se	eize_3580b queueLF	_3580a LT_3580a	release_3580a n	n_3580_4_20	seize_3580d	queueDP_3580a	DT_3580a	release_3580c	release_3580e	timeEnd_3580	sink_3580
<b>0 0</b>		├ <u>-                                    </u>	·ثد ، ، <sup>ی</sup> دو	. (G) -		• → <sup> ~</sup> •	- 3 <sup>°</sup>	- <sup>.</sup>	G			⇒œ	
	-	-									Tas	kEnd_3580	
		L.										-	
TaskStart_3580 select_358	80a1 m_3580_20 m_3580_20_4												
	:												
Ę	•												

[그림 27] 애니로직 소프트웨어를 사용한 트럭 운반시스템 시뮬레이션 구현

## 다. 시뮬레이션 알고리즘 검증

시뮬레이션 알고리즘의 검증은 머신러닝 모형을 이용하여 예측한 트럭 사이클 타임을 시뮬레이션 모형 에 입력한 후 시뮬레이션을 수행한 결과와 일주일 기간의 차량운행일지를 분석한 데이터를 상호 비교하 여 수행하였다. 이를 위해 차량운행일지를 분석하여 트럭별로 해당기간에 운행되었던 구간(파쇄장~적재 장) 및 시간, 생산량을 분석하였다. 또한, 차량운행일지의 작성상태가 양호했던 작업일에 대해 적재 혹은 하역이 이루어졌던 시간과 DES 모형에서 출력되는 시간을 서로 비교함으로써 추가적인 검증을 수행하 였다.

### 2. 문제 진단 모형 개발 방법

#### (1) 머신러닝 모형 설계

지하광산 운반경로의 구간별 트럭이동시간과 머신러닝 기법을 이용하여 운반경로의 안정도를 평가 및 진단하기 위해 머신러닝 모델의 학습 및 검증을 위한 데이터 수집, 데이터 처리, 머신러닝 알고리즘 적 용, 머신러닝 모델 검증 및 최적 모델 선정 순으로 연구를 진행하였다. 운반경로 각 구간의 상태를 진단 하기 위한 요인은 물리적인 요인(구간의 위치와 경사, 주변 작업장의 유무, 운반로 너비, 원석 적재 여부 등)과 환경적인 요인(기상, 지하수 유무 등)이 있다 [40]. 따라서 운반경로 상태 진단을 위한 머신러닝 모델의 학습데이터는 표 6과 같이 6개의 입력변수와 운반경로의 상태를 판단하는 레이블로 구성되어 있 다. 데이터 유형은 범주형 데이터와 연속형 데이터로 구분할 수 있다. 범주형 데이터에는 운반경로 구간 의 출발지 및 도착지(비콘 ID로 구성), 광석의 적재 여부가 포함된다. 연속형 데이터에는 트럭이동시간, 일 평균기온, 일 강수량이 포함된다. 머신러닝 모델 학습을 위한 Raw 데이터 코딩은 광산생산관리시스 템에서 수집한 트럭이동시간과 관련한 로그데이터와 기상청에서 제공한 기상 데이터를 이용하여 수행하 였다. 운반경로의 상태는 연구지역에 설치된 광산생산관리시스템을 통해 수집하였다. 트럭 운전기사는 적재, 운송 및 하역작업이 한번 완료되면 작업이 정상 또는 비정상적으로 수행되었는지 입력한다. 본 연 구에서는 정상적으로 운행된 경우를 0으로, 비정상적으로 운행된 경우를 1로 분류하였다.

Data set	Description	Data type
	Origin beacon ID	Integer (1-22)
	Destination beacon ID	Integer (1-22)
Fasturas	Transport time	Seconds (sec)
Features	Average daily temperature	Celsius temperature (°C)
	Daily precipitation	Millimeter (mm)
	Whether ores are loaded	0: Loaded, 1: Empty
Label	Truck transport time status on transport route	0: Normal, 1: Abnormal

[표 6] 머신러닝 모델 학습을 위한 데이터세트의 설명 및 데이터 유형

#### (2) 훈련 데이터 제작 및 전처리

본 연구에서 사용된 입력변수의 데이터 유형은 범주형 데이터와 연속형 데이터로 구성된다. 차원이 다른 데이터는 정규화되지 않기 때문에 절대값이 작은 변수는 결함 진단 시스템(fault diagnosis system)에서 무시된다. 따라서 데이터는 Min-Max 스케일링 정규화(Min-Max scaling normalization) 방법(식 (2))을 사용하여 정규화하였다.

머신러닝 모델 훈련을 위한 데이터세트는 운반경로의 상태가 정상으로 분류된 데이터와 비정상으로 분류된 데이터의 비율을 1:1로 설정하고 6,000개의 데이터로 구성(정상: 3,000개, 비정상: 3,000개)하였다. 훈련 데이터세트로 학습된 모델을 검증하기 위해 전체 데이터를 훈련 데이터세트와 검증 데이터세트로 나누었다. 훈련 및 검증 데이터세트는 각각 전체 데이터세트의 75%와 25%로 설정(훈련 데이터세트: 4,500개, 검증 데이터세트: 1,500개)하였다. 머신러닝 모델의 훈련과 검증을 위해 연구지역에 설치된 광산생산관리시스템을 이용하여 15주 동안 총 42,808개의 구간별 트럭이동시간 데이터를 수집하였다. 시스템을 이용하여 취득할 수 있는 운반경로 의 구간별 출발지 및 도착지, 트럭이동시간을 제외하고 트럭이동시간에 영향을 줄 수 있는 일평균기온, 일강수량, 트럭의 원석 적재여부, 운반경로의 상태 이상은 판단하는 레이블을 추가로 입력하였다. 원석 의 적재여부는 공차 혹은 적차의 경우로 구분할 수 있다. 이는 운반경로의 구간별 비콘 ID의 순서에 따 라 트럭이 적재장을 향하는지(공차) 아니면 하역장을 향하는지(적차)를 판단하여 결정하였다. 15주간의 기간동안 수집된 데이터의 운반경로 상태를 판단한 결과, 총 42,808개의 트럭이동시간 데이터 중 3,314 개의 데이터가 비정상적으로 측정된 것으로 나타났다. 머신러닝 모델을 훈련시키기 위한 데이터는 운반 경로의 상태가 정상으로 분류된 데이터와 비정상으로 분류된 데이터의 비율을 1:1로 설정하였으며, 총 6,000개의 데이터를 준비하였다. 훈련 데이터세트를 정규화하기 전에 트럭이동시간, 일평균기온, 일강수 량에 대한 평균값과 표준편차, 최소값 및 최대값을 계산하였다(표 7). 그림 28은 통계값에 대한 히스토 그램을 보여준다. 트럭이동시간의 평균은 95.55초, 표준편차는 74.12초로 나타났다. 일평균기온의 평균은 - 2.71℃도, 표준편차는 5.03℃로 나타났다. 일강수량의 평균은 0.24mm, 표준편차는 0.85mm로 나타났다.

	Truck travel time (s)	Average daily temperature (℃)	Daily precipitation (mm)
Mean	95.55	-2.71	0.24
Standard deviation	74.12	5.03	0.85
Minimum value	1.00	-14.30	0.00
Maximum value	299.00	11.40	6.90

[표 7] 머신러닝 모델 학습을 위한 데이터세트의 특징



[그림 28] 머신러닝 모델 훈련을 위한 데이터세트의 특성 분포: (a) 트럭 이동 시간, (b) 일평균온도, 일강수량

#### (3) 머신러닝 알고리즘 적용

본 연구에서는 머신러닝 알고리즘을 활용하여 지하광산의 각 구간의 안정도와 상태를 진단하였다. 이 를 위해 가우시안 나이브 베이즈(GNB, gaussian naïve bayes), 최근접 이웃법(kNN, k-nearest neighbor), 서포트 벡터 머신(SVM, support vector machine), 분류 및 회귀트리(CART, classification and regression tree)를 사용하였다.

나이브 베이즈(NB, naïve bayes)는 모든 특성들 사이의 독립을 가정하는 베이즈 정리를 적용한 지도 학습 알고리즘이다 [48]. GNB는 NB 알고리즘의 하나로 베이즈 이론을 기반으로 학습하는 알고리즘이 다. 일반적으로 각 클래스와 관련있는 연속적인 값들이 가우스 분포를 따른다는 가정하에 각 클래스와 연관된 연속적인 값을 계산하는 알고리즘이다. 예를 들어, 연속적인 속성 *x*를 포함하고 있는 학습 데이 터를 클래스 별로 나눈 후, 각 클래스에서 *x*의 평균과 분산을 각각 μ*x*와 σ*k*라고 한다. 그런 다음, 특정 관측값 *v*를 수집했다고 가정하면, 주어진 클래스 값의 확률분포는 μ*x*와 σ*k*로 매개변수화되어 정규분포 식(식 (10))을 통해 계산될 수 있다.

$$p(x = vvertc) = \frac{1}{\sqrt{2\pi\sigma_c^2}} e^{-\frac{(v-\mu_c)^2}{2\sigma_c^2}}$$
(10)

CART는 의사결정 트리(DT, decision tree) 기반 알고리즘으로 분류 및 회귀 문제 모두에 사용할 수 있다 [49]. CART는 변수 간의 관계에 대한 이전 가정을 고려할 필요가 없다. 데이터는 반복적인 절차를 통해 예측 변수 값에 대한 답변(예/아니오)을 기반으로 균일한 레이블로 분할되며 최종적으로 이항 트리 가 생성된다. 종속변수가 정성적인 경유 분류 트리라고 하고, 정량적인 경우 회귀 트리라고 한다. 전체 데이터세트를 포함하는 노드를 루트 노드라고 한다. 루트 노드로부터 시작하여 좌우로 나뉘며, 데이터 분류는 종속변수와 관련된 추정오차가 최소화될 때까지 반복된다 [50].

머신러닝 모델의 성능과 검증 데이터세트에 대한 성능평가의 신뢰성을 향상시키기 위해 5겹 교차 검 증(5-fold cross-validation)을 통한 그리드 서치(grid search)를 활용하였다. 표 8은 각 모델에서 사용되 는 매개변수의 종류와 매개변수 튜닝을 나타낸다. GNB는 var smoothing 값에 의해 모델의 정확도가 달 라지기 때문에, var smoothing 값의 범위를 10<sup>-9</sup>에서 1까지 설정하고, 매개변수를 약 1.23배씩 증가시켜 가면서 모델의 정확도를 예측하였다. kNN의 분류 정확도는 이웃 수를 의미하는 k 값에 따라 달라지며, k 값을 최소 1에서 100까지 1씩 증가시켜가면서 정확도를 예측하였다. SVM 모델의 분류 정확도는 매개 변수 C와 γ에 의해 크게 달라지기 때문에, 매개변수 C(최소 10~최대 100)와 γ(최소 0.1~최대 1)를 각 각 5와 0.1씩 증가시켜가며 최적의 매개변수 쌍을 결정하였다. 마지막으로 CART 모델은 최소 샘플 리 프(min\_samples leaf)와 최소 샘플 분할(min samples split)에 의해 모델의 정확도가 결정된다. 본 연구 에서는 min\_samples\_leaf는 최소 1에서 최대 10까지 범위를 설정하고 1씩 증가시키고. min\_samples\_split은 최소 2에서 최대 10까지 범위를 설정하고 1씩 증가시켜가면서 최적의 매개변수를 결정하였다.

kNN 모델과 SVM 모델에 관한 설명은 3장 1절에서 제시되었다.

	GaussianNB	kNN	SVM	CART
Parameter	var_smoothing	Neighbors	C / gamma	min_samples_leaf / min_samples_split
Min	$10^{-9}$	1	10 / 0.1	1 / 2
max	1	100	100 / 1	10 / 10
Step	(×) 1.232847	(+) 1	(+) 5 / 0.1	(+) 1 / 1

[표 8] 매개변수 튜닝을 위한 그리드 서치에 사용되는 값

(4) 머신러닝 모형 검증 및 최적 모형 선정

5겹 교차 검증을 통한 그리드 서치를 이용하여 머신러닝 모델의 학습 정확도가 가장 높게 나타나는 매개변수를 결정하였다. 그런 다음 검증 데이터세트(전체 데이터의 25%, 1,500개)를 이용하여 모델의 성 능을 검증하였다. 모델의 성능을 평가할 수 있는 성능 지표는 일반적으로 지도학습의 유형(회귀 혹은 분 류)에 따라 달라진다. 본 연구에서는 분류 문제에서 일반적으로 사용하고 있는 정확도(accuracy), 정밀도 (precision), 재현율(recall), F1 score를 이용하여 모델의 성능을 검증하였다. 정확도는 전체 예측에서 맞 게 예측한 확률을, 정밀도는 양성으로 예측할 때 실제로 양성일 확률을, 재현율은 실제 양성을 맞게 예 측할 확률을, F1 score는 정밀도와 재현율의 조화평균을 의미한다. 각 성능지표에 대한 수식은 아래와 같다.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$
(11)

$$Precision = \frac{TP}{TP + FP}$$
(12)

$$Recall = \frac{TP}{TP + FN}$$
(13)

$$F1\,score = \frac{2 \times Recall \times Precision}{Recall + Precision} \tag{14}$$

여기서 P(positive)와 N(negative)은 모델의 예측이 양성(yes)인지 음성(no)인지를 의미하며, T(true)와 F(false)는 그 예측이 맞는지 틀린지를 의미한다. 이것을 행렬로 표시한 것을 오차행렬(confusion matrix)이라고 부르며, 표 9와 같이 나타낼 수 있다.

[표 9] 분류기(classifier)에 대한 오차행렬

Confusio	n motnix	Predicted data			
Confusion matrix		Negative (0)	Positive (1)		
	Nagatina (0)	TN	FP		
Astrol data	Negative (0)	(True Negative)	(False Positive)		
Actual data	$\mathbf{D}$ (1)	FN	TP		
	Positive (1)	(False Negative)	(True Positive)		

### 3. 머신러닝 모형 개발환경 및 활용 라이브러리

머신러닝 모델을 개발하기 위해 아나콘다(Anaconda), 주피터 노트북(Jupyter Notebook)의 개발환경에 서 파이썬(Python) 언어를 통해 다양한 라이브러리를 사용하여 머신러닝 모델을 개발하였다. 데이터 처 리를 위해 넘파이(Numpy), 판다스(Pandas) 등의 라이브러리를 이용하였다. 딥러닝 모델을 제외한 머신 러닝 알고리즘을 구현하기 위해 다양한 머신러닝 알고리즘이 구현되어 있는 사이킷런(scikit-learn) 라이 브러리를 사용하였다. 딥러닝 모델을 개발하기 위해 딥러닝에 최적화 되어있는 텐서플로우(TensorFlow) 를 사용하여 구현하였다.

생산량 예측 머신러닝-이산사건 시뮬레이터를 개발하기 위해 애니로직 소프트웨어를 이용하였다. 애 니로직 소프트웨어는 에이전트 기반 시뮬레이션, 이산사건 시뮬레이션, 시스템 다이내믹스 시뮬레이션이 모두 가능한 다중 기법 시뮬레이션 소프트웨어이다 [51,52]. 이를 활용하여 트럭 운반시스템 이산사건 시뮬레이터 모델을 개발하였다.

## IV. 생산량 예측 모형 개발 결과

## 1. 사이클 타임 예측 머신러닝 모형 개발 결과

### (1) 머신러닝 모델 훈련 결과

본 연구에서는 트럭 사이클 타임을 예측하기 위해 kNN, RF, PSO-SVM, DNN 모델을 사용하였다. 가장 성능이 우수한 예측 모델을 설계하기 위해 각 모델의 학습 정확도와 관련된 매개변수를 최적화하 였다. 이를 위해 5겹 교차 검증을 통한 그리드 서치를 이용하여 모델을 최적화하였다.

kNN 모델의 예측 정확도는 매개변수 k값에 따라 결정된다. 그림 29는 k값을 1부터 100까지 1씩 증가시 켜가면서 모델의 정확도를 예측한 것이다. kNN 모델의 정확도는 k값이 53일 때 훈련 데이터세트 기준 으로 MAE가 4.93 (min)으로 가장 낮은 오차를 나타냈다.



[그림 29] k값 (n\_neighbors)의 변화(1~100)에 따른 kNN 모델의 학습 정확도

RF 모델의 학습 정확도는 5가지의 하이퍼 파라미터에 의존한다. 본 연구에서는 ccp alpha와 min impurity decrease는 0부터 10까지 1씩 증가시켰으며 min samples leaf, min samples split는 1부터 10까 지 1씩 증가시켰고, min weight fraction leaf는 0.1에서 1까지 0.1까지 증가시키며 매개변수 값을 최적화 하였다. 그림 30은 매개변수 값의 변화에 따라 달라지는 RF 모델의 학습 정확도를 나타낸다. RF의 학 습 정확도는 ccp alpha는 2, min\_impurity\_decrease는 2, min\_samples\_leaf는 6, min\_samples\_splite 5, min\_weight\_fraction\_leaf가 0일 때 MAE가 3.83 (min)으로 가장 낮은 오차가 나타났다.



[그림 30] cp alpha(0~10), min impurity decrease(0~10), min samples leaf(1~10), min samples split(1~10), min weight fraction leaf(0.1~1)의 변화에 따른 RF 모델의 학습 정확도

SVM 모델의 학습 정확도가 가장 높게 나타나는 매개변수 값을 결정하기 위해 C와 γ를 변화시켜가 며 모델을 최적화하였다. 매개변수 C는 10에서 100까지 범위로 설정하고, γ는 0.1부터 0.9까지로 설정하 여 입자 군집 최적화를 통해 정확도를 계산하였다. 그림 31은 매개변수 C와 γ의 변화에 따른 모델의 학 습 정확도를 나타낸다. SVM 모델은 C를 30.2079059738887로, γ를 0.611032434487566으로 설정했을 때, 모델의 MAE가 3.45 (min)로 가장 좋은 성능을 나타냈다.



[그림 31] C(10~100)와 γ(0.1~0.9)의 변화에 따른 SVM 모델의 학습 정확도

DNN 모델을 최적화하기 위해 은닉층과 노드 수를 변화시켰다. 은닉층은 2에서 9까지 1씩 증가시키며 은닉층의 수를 변화시키고, 노드 수는 20에서 90까지 10씩 증가시키며 변화시켰다. 그림 32는 매개변수 은닉층과 노드 수의 변화에 따른 모델의 학습 정확도를 나타낸다. DNN 모델은 은닉층의 수가 2, 노드 수가 40일 때 가장 작은 오차(MAE = 4.11(min))를 보였다.



[그림 32] 은닉층(2~9)과 노드 수(20~90)의 변화에 따른 DNN 모델의 학습 정확도

#### (2) 사이클 타임 예측 성능평가 결과

모델의 학습정확도가 가장 좋은 성능을 나타낸 매개변수를 각 모델에 적용하여, 검증데이터(전체 데이 터의 25%)를 이용하여 모델의 성능을 평가하였다. 그림 33은 실제 측정된 사이클타임과 모델의 예측값 을 나타낸 것이다.

그림 33(a)는 kNN의 검증 결과를 나타낸 그림이다. 실제 트럭 사이클 타임이 가로축이며 kNN 모델이 예측한 값은 세로축을 나타낸다. kNN 모델의 예측값과 측정된 데이터의 오차를 구하면 MAE는 2.89(min), MSE는 13.65(min), RMSE는 3.69(min), R2는 0.69로 나타났다. RF 모델은 사이클 타임 예측값 의 최대값과 최소값에 편향되어있는 것으로 확인되었다(그림 33(b)). 또한, 성능지표 MAE는 2.88(min), MSE는 15.40(min), RMSE는 3.92(min), R2는 0.65로 나타났다. PSO-SVM 모델의 결과는 그림 33(c)와 같다. 예측한 값과 실제 데이터의 차이로 MAE는 2.79(min), MSE는 14.29(min), RMSE는 3.78(min), R2 는 0.68로 나타났다. DNN 모델의 검증 데이터로 검증한 결과는 그림 33(d)로 나타났으며, 모델의 회귀 성능지표 MAE는 2.80(min), MSE는 15.13(min), RMSE는 3.89(min), R2는 0.66으로 나타났다.



[그립 33] 실제 측정된 사이클 타임 및 모델의 예측값: (a) kNN 모델, (b) RF 모델, (c) PSO-SVM, (d) DNN 모델

### (3) 사이클 타임 예측 성능 비교

본 연구에서 검증 데이터세트를 이용하여 모델의 성능을 평가하였다. 모델의 성능평가는 MAE, MSE, RMSE, R2를 이용하여 수행하였다. 표 10은 각 모델의 성능지표를 나타낸 것이다. 머신러닝 모델의 예 측 정확도는 PSO-SVM이 MAE가 2.79(min)으로 가장 낮은 오차를 보였으며, DNN(MAE=2.80(min)), RF(MAE=2.88(min)), kNN(MAE=2.89(min)) 순으로 평가되었다. 따라서 지하광산의 사이클 타임을 예측 하는 모델로는 PSO-SVM이 가장 좋은 성능을 보인다고 할 수 있다.

[표 10] 머신러닝 모델의 성능평가 지표

Performance assessment indicators	KNN	RF	PSO-SVM	DNN
MAE (min)	2.89	2.88	2.79	2.80
MSE (min)	13.65	15.40	14.29	15.13
RMSE (min)	3.69	3.92	3.78	3.89
R2 (min)	0.69	0.65	0.68	0.66

## 2. 생산량 예측 머신러닝--이산사건 시뮬레이션 모형 개발 결과

## (1) 시뮬레이션 시나리오 및 인자설정

애니로직 소프트웨어를 이용하여 생산량 예측 머신러닝—이산사건 시뮬레이션 모형을 개발하였으며, 연 구지역의 트럭 운반시스템을 제대로 모사하는지에 대한 검증을 수행하였다. 사전에 확보한 차량운행일 지의 분석 결과와 해당 기간동안의 운영조건을 적용하여 시뮬레이션을 수행한 결과를 상호비교하여 시 뮬레이션 모형의 검증을 수행하였다. 표 11은 차량운행일지 분석을 통해 결정한 시뮬레이션 시나리오와 입력자료를 나타낸다. 차량운행일지를 분석한 결과, 운반시스템에 투입되는 트럭들은 일반적으로 하루 8 시간(08:00~17:00, 점심시간 1시간 제외) 동안 운반작업을 수행한다. 그러나 일일 생산계획과 현장에서 발생할 수 있는 돌발변수(파쇄기 고장, 갱도 일시 폐쇄 등)에 의해 운반경로가 수시로 변경되는 것으로 나타났다.

Date	Truck ID	Truck type (ton)	Loading point (Beacon ID)	Cruher (Beacon ID)	Simulation time
	1	37.5	4	20	08:00~12:00
11 99	6	23	17	22	10:00~12:00, 13:00~14:30
11.23	4	23	17	22	09:00~12:00, 13:00~14:30
	7	23	17	22	10:00~12:00, 13:00~14:30
11.24	3	23	9	20	08:00~12:00, 13:00~17:00
	1	37.5	4	20	08:00~12:00, 13:00~14:30
11.25	2	37.5	4	20	08:00~12:00, 13:00~14:30
	3	23	9	20	08:00~12:00, 13:00~17:00
	1	37.5	4	20	14:00~16:30
	2	37.5	4	20	14:00~16:00
	3	23	9	20	08:00~12:00, 13:00~16:30
11.26	6	23	19	22	08:00~12:00, 13:00~16:30
	5	23	19	22	08:00~12:00, 13:00~16:30
	4	23	19	22	08:00~11:00
	7	23	19	22	08:00~10:30
	1	37.5	4	20	08:00~12:00, 13:00~15:00
	2	37.5	4	20	08:00~12:00, 13:00~15:00
11.27	6	23	19	22	13:00~17:00
	4	23	19	22	13:00~17:00
	7	23	19	22	13:00~17:00
	3	23	9	20	08:00~12:00, 13:00~17:00
	5	23	17	22	10:30~12:00, 13:00~15:30
	4	23	17	22	10:30~12:00, 13:00~15:30
11.00	7	23	17	22	10:30~12:00, 13:00~15:30
11.20	6	23	19	22	08:00~10:30
	5	23	19	22	08:00~10:30
	4	23	19	22	08:00~10:30
	7	23	19	22	08:00~10:30

[표 11] 차량운행일지 분석을 통해 결정한 시뮬레이션 시나리오 및 입력자료

이산사건 시뮬레이션 모형에 입력되는 구간별 트럭이동시간 값은 트럭 사이클 타임 예측 머신러닝 모 형을 이용하여 계산하였다. 시뮬레이션 모형에 입력되는 트럭이동시간 평균±표준편차 형태의 정규분포 를 따른다. 표 12는 트럭별/구간별 트럭이동시간 데이터를 정리하여 나타낸 것이다. 원석의 적재 및 하 역시간의 경우 트럭의 종류에 따라 다르게 나타나며, 모든 구간에서 동일한 값을 가진다고 가정하였다.

		Travel time		Travel time	
Truck	Route	with empty	Loading time	with loaded	Dumping time
ID	ID	truck	(Mean ± SD)	truck	(Mean ± SD)
		(Mean ± SD)		(Mean ± SD)	
1	А	$8.83 \pm 1.77$	$3.73 \pm 0.75$	$8.23 \pm 1.65$	$0.62 \pm 0.12$
1	С	$13.13 \pm 2.63$	$3.73 \pm 0.75$	$12.24 \pm 2.45$	$0.62 \pm 0.12$
	А	$9.14 \pm 1.83$	$3.73 \pm 0.75$	$8.52 \pm 1.7$	$0.62 \pm 0.12$
2	В	$12.22 \pm 2.44$	$3.73 \pm 0.75$	$11.39 \pm 2.28$	$0.62 \pm 0.12$
	С	$16.36 \pm 3.27$	$3.73 \pm 0.75$	$15.26 \pm 3.05$	$0.62 \pm 0.12$
3	В	$12.38 \pm 2.48$	$4.05 \pm 0.81$	$9.67 \pm 1.93$	$0.88 \pm 0.18$
	С	$16.57 \pm 3.31$	$4.05 \pm 0.81$	$12.94 \pm 2.59$	$0.88 \pm 0.18$
4	D	$16.07 \pm 3.21$	$4.05 \pm 0.81$	$12.55 \pm 2.51$	$0.88 \pm 0.18$
	С	$18.28 \pm 3.66$	$4.05 \pm 0.81$	$14.28 \pm 2.86$	$0.88 \pm 0.18$
5	D	$13.24 \pm 2.65$	$4.05 \pm 0.81$	$10.34 \pm 2.07$	$0.88 \pm 0.18$
C	С	$16.79 \pm 3.36$	$4.05 \pm 0.81$	$13.12 \pm 2.62$	$0.88 \pm 0.18$
0	D	$14.47 \pm 2.89$	$4.05 \pm 0.81$	$11.3 \pm 2.26$	$0.88 \pm 0.18$
7	С	$17.04 \pm 3.41$	$4.05 \pm 0.81$	$13.31 \pm 2.66$	$0.88 \pm 0.18$
	D	$14.93 \pm 2.99$	$4.05 \pm 0.81$	$11.66 \pm 2.33$	$0.88 \pm 0.18$

[표 12] 트럭 사이클 타임 예측 머신러닝 모델을 이용하여 계산한 트럭별/구간별 트럭이동시간

Route ID: A (beacon IDs  $4 \sim 20$ ), B (beacon IDs  $9 \sim 20$ ), C (beacon IDs  $17 \sim 22$ ), D: (beacon IDs  $19 \sim 22$ )

### (2) 시뮬레이션 결과 및 검증

본 연구에서는 차량운행일지에 기록된 트럭별/구간별 생산량과 시뮬레이션 모형을 통해 계산된 생산량 을 상호비교하는 방법으로 생산량 예측 머신러닝—이산사건 시뮬레이션 모형을 검증하였다. 시뮬레이션은 앞서 결정한 시뮬레이션 시나리오 및 입력자료, 트럭이동시간 데이터를 입력하여 수행하였다. 현장에서 작성된 차량운행일지는 적재시점을 기준으로 작성되기 때문에 시뮬레이션 모형에서도 원석을 적재한 시 점에 원석의 운반량을 카운트하는 것으로 설정하였다. 표 13과 그림 34는 차량운행일지와 시뮬레이션 예 측 결과를 트럭별/구간별로 구분하여 운반량(ton) 및 운반횟수를 나타낸 것이다. 오전 시간대 작업의 경 우 시뮬레이션 모형이 차량운행일지와 대체로 유사하게 예측되는 것을 확인할 수 있다. 그러나 오후 시 간대 작업의 경우, 예측 결과에 다소 차이가 보였으나, 분석 결과와 예측 결과가 서로 상관성이 있는 것 으로 나타났다.

			Vehicle op	eration log	Discrete s	simulation
	Truck	Route	Amount of loa	ded ores (ton)	Amount of loa	ded ores (ton)
Date	ID	ID	AM	PM	AM	PM
			(08:00~12:00)	(13:00~17:00)	(08:00~12:00)	(13:00~17:00)
	1	А	412.5	—	412.5	-
11.92	6	С	112.5	112.5	150	112.5
11.20	4	C	187.5	112.5	187.5	112.5
	7	C	112.5	112.5	150	75
11.24	3	В	300	300	375	375
	1	А	337.5	75	450	150
11.25	2	А	412.5	37.5	412.5	150
	3	В	300	337.5	337.5	337.5
	1	А	-	262.5	-	300
	2	А	_	187.5	_	187.5
	3	В	300	225	412.5	300
11.26	6	D	262.5	225	262.5	262.5
	5	D	262.5	187.5	300	300
	4	D	225	-	187.5	-
	7	D	150	-	187.5	-
	1	А	375	150	412.5	187.5
	2	А	375	187.5	412.5	187.5
11.27	6	D	_	337.5	_	262.5
	4	D	_	337.5	-	262.5
	7	D	_	337.5	_	300
	3	В	300	300	412.5	337.5
	5	C	75	187.5	112.5	187.5
	4	C	75	187.5	112.5	187.5
11.98	7	C	75	187.5	112.5	150
11.20	6	D	187.5	-	187.5	-
	5	D	187.5	-	187.5	-
	4	D	150	_	150	-
	7	D	187.5	-	187.5	-

[표 13] 차량운행일지 및 이산사건 시뮬레이션 모형의 생산량 예측 결과 비교



[그림 34] 차량운행일지 및 이산사건 시뮬레이션 모형의 생산량 예측 결과 비교

본 연구에서는 2020년 11월 26일의 차량운행일지를 이용하여 원석의 적재시점을 정리하고, 이를 시뮬 레이션 모형에서 계산되는 적재시점을 비교함으로써 모형의 추가적인 검증을 수행하였다. 표 14는 차량 운행일지와 시뮬레이션 모형에서 계산되는 적재 시점을 구간별, 트럭별, 시간대별로 구분하여 나타낸 것 이다. 그 결과 일부 트럭 및 구간에서 차량운행일지와 시뮬레이션 모형 사이에 불일치가 발생하였지만 적재시점 및 운반횟수가 대체로 유사하게 나타났다. 시뮬레이션 모형이 제대로 예측하지 못하는 트럭 및 구간은 트럭 사이클 타임 예측 머신러닝 모형에 사용된 학습 데이터의 수가 상대적으로 부족해 사이 클 타임을 높은 정확도로 예측하지 못했을 가능성이 있다. 또한, 이산사건 시뮬레이션 모형은 실제 운반 작업시 비정상적으로 발생할 수 있는 변수 혹은 상황을 고려하지 못하는 한계점이 있기때문에 예측의 정확도가 낮은 트럭과 구간이 발생했을 가능성이 있다. 따라서 이산사건 시뮬레이션 모형의 예측 정확 성을 향상시키기 위해서는 우선 머신러닝 모형의 학습을 위해 사용되는 데이터의 충분한 축적이 필요하 며, 시뮬레이션 모형이 보다 현실을 반영할 수 있도록 개선이 필요하다.

		Rou	te A		Rout	te B	B Route D							
<b></b>	Tru	ck 1	Tru	ck 2	True	ck 3	True	ck 4	Tru	ck 5	True	ck 6	True	ck 7
Time	Actual	DES	Actual	DES	Actual	DES	Actual	DES	Actual	DES	Actual	DES	Actual	DES
	log		log		log	00:11	log		log		log		log	
8:00					08:10 08:40	08:11 08:35 08:58	08:19 08:51	08:27	08:34	08:16 08:21	08:25 08:58	08:19 08:45	08:29	08:24 08:54
9:00					09:10 09:38	09:17 09:41	09:21 09:51	09:05 09:48	09:06 09:36	09:09 09:34	09:27 09:56	09:21 09:54	09:02 09:31	09:25 09:51
10:00					10:06 10:33	10:09 10:33 10;58	10:20 10:48	10:19 10:53	10:05 10:35	10:03 10:31	10:25 10:52	10:27	10:01	10:24
11:00					11:00 11:27	11:22 11:47			11:02 11:35	11:06 11:43	11:26	11:03 11:39		
12:00							Lunch	n time						
13:00					13:17 13:43	13:15 13:35			13:23	13:18 13:24	13:13 13:44	13:22 13:29		
14:00	14:00 14:25 14:51	14:07 14:27 14:46	14:10 14:37 14:57	14:22 14:41	14:12 14:42	14:00 14:27 14:49			14:05 14:53	14:14 14:37	14:38	14:18 14:45		
15:00	15:08 15:28 15:46	15:04 15:26 15:46	15:17 15:38	15:07 15:30 15:52	15:14 15:56	15:15 15:41			15:21 15:50	15:04 15:30 15:55	15:03 15:29	15:19 15:50		
16:00	16:05	16:04 16:26				16:15				16:21	16:02	16:23		
Number of haulage	7	8	5	5	14	18	6	5	12	16	13	14	4	5

[표 14] 차량운행일지 및 머신러닝--이산사건 시뮬레이션 모형의 예측결과 비교

### 3. 생산량 예측 모형 활용

#### (1) 시뮬레이션 시나리오 및 인자설정

MPMS를 이용하여 수집된 트럭이동시간 관련 로그데이터를 트럭 사이클 타임 예측 모형에 입력하여 트럭이동시간을 예측하고, 예측된 결과를 다시 이산사건 시뮬레이션 모형에 입력하면 트럭별, 구간별 생 산량을 예측하고 작업장별 최적의 배차 트럭 수를 결정할 수 있다. 본 연구에서는 생산량 예측 모형의 활용 가능성을 확인하기 위해 일일 운영조건을 가정한 후 시뮬레이션을 수행하였으며, 이에 대한 최적 의 트럭 배차 계획을 도출하였다. 이를 위해 임의로 가정한 사항은 다음과 같다. (1) 운반작업은 하루 8 시간(540분)동안 이루어진다. (2) 총 6대의 트럭(37.5톤: 2대트럭 ID 1, 2), 23톤: 4개(트럭 ID 4~7))이 3 곳의 적재장(적재장 A, C, D))에 배차된다. (3) 각각의 적재장은 서로 다른 품위의 석회석이 생산된다. (4) 목표 품위를 달성하기 위해서는 각 적재장 별로 최소 600톤, 800톤, 700톤의 석회석이 생산된다야 한다. 4가지 가정 조건을 고려하면, 총 39개의 트럭 배차 조합을 결정할 수 있다. 시뮬레이션 모형에 입 럭되는 트럭별, 구간별 트럭이동시간은 사이클 타임 예측 머신러닝 모형을 이용하여 산출하였으며, 정규 분포(평균±표준편차) 형태로 변환하여 입력하였다.

#### (2) 시뮬레이션 결과 및 트럭 배차 계획 최적화

일일 운영조건과 트럭이동시간 데이터를 입력하여 시뮬레이션을 수행한 결과 39개의 트럭 배차 조합 중 적재장별 최소 생산 목표량을 만족할 수 있는 트럭 조합은 13개로 나타났다(표 15). 적재장 A(구간 A)의 경우 37.5톤의 트럭이 최소 1대, 적재장 C는 37.5톤 트럭 1대와 23톤 트럭 1대, 적재장 D는 23톤 트럭 3대가 투입되어야 일일 목표 생산량을 달성할 수 있는 것으로 나타났다(표 16). 총 생산량을 기준 으로 살펴보면 시나리오 ID 23이 하루 작업시간동안 가장 많은 석회석을 생산(2,995톤)하는 것으로 나타 났다. 또한, 일일 목표생산량을 달성하는데 소요되는 시간의 경우에도 시나리오 ID 23이 가장 적은 시간 (386분)이 소요되는 것으로 나타났다. 이때 적재장별 석회석 생산량은 각각 675톤(적재장 A), 801톤(적 재장 C), 897톤(적재장 D)으로 나타났다.

Scenario	Truck 1	Truck 2	Truck 3	Truck 4	Truck 5	Truck 6
ID	37.5 ton	37.5 ton	23 ton	23 ton	23 ton	23 ton
19	А	С	С	D	D	С
20	А	С	D	D	С	С
23	А	С	С	D	D	D
24	А	C	D	С	D	D
25	А	C	D	D	C	D
26	А	C	D	D	D	С
31	C	А	С	C	D	D
32	C	А	С	D	D	С
33	С	А	D	D	С	С
36	С	А	С	D	D	D
37	С	А	D	C	D	D
38	С	А	D	D	С	D
39	С	A	D	D	D	С

[표 15] 일일 목표 생산량을 달성할 수 있는 트럭 배차 조합

Route ID: A (beacon IDs 4 - 20), C (beacon IDs 17 - 22), D: (beacon IDs 19 - 22)

				O	re produ	action (t	ons)				Time
Scenar			by tr	rucks			by l	oading p	oints		achieve
io ID	1	2	4	5	6	7	A	с	D	Total	target production (min)
19	862.5	637.5	345.0	391.0	345.0	299.0	862.5	1281.5	736.0	2880.0	466
20	900.0	600.0	299.0	414.0	368.0	299.0	900.0	1267.0	713.0	2880.0	480
23	862.5	637.5	368.0	414.0	345.0	368.0	862.5	1005.5	1127.0	2995.0	386
24	825	637.5	299.0	345.0	345.0	368.0	825.0	982.5	1012.0	2819.5	399
25	862.5	600.0	299.0	414.0	345.0	345.0	862.5	945.0	1058.0	2865.5	411
26	862.5	600.0	299.0	414.0	345.0	299.0	862.5	899.0	1058.0	2819.5	405
31	600.0	825.0	345.0	345.0	368.0	345.0	825.0	1290.0	713.0	2828.0	471
32	600.0	862.5	345.0	391.0	322.0	299.0	862.5	1244.0	713.0	2819.5	464
33	600.0	825.0	299.0	414.0	368.0	299.0	825	1267.0	713.0	2805.0	474
36	637.5	862.5	345.0	414.0	322.0	368.0	862.5	982.5	1104	2949.0	390
37	600.0	825.0	276.0	368.0	345.0	368.0	825.0	968.0	989.0	2782.0	403
38	637.5	825.0	299.0	391.0	368.0	391.0	825.0	1005.5	1081.0	2911.5	393
39	637.5	825.0	299.0	414.0	345.0	299.0	825.0	936.5	1058.0	2819.5	422

# [표 16] 일일 목표 생산량을 달성할 수 있는 트럭 배차 조합에 대한 시뮬레이션 결과

## V. 문제 진단 모형 개발 결과

## 1. 문제 진단 머신러닝 모형 개발 결과

### (1) 머신러닝 모형 훈련 결과

본 연구에서는 트럭 운반경로의 안정도를 평가하고 진단하기 위해 GNB, kNN, SVM, CART 모델을 사용하였다. 가장 정확한 예측 모델을 설계하기 위해 각 모델의 학습 정확도와 관련된 매개변수 값을 최적화하였다. 이를 위해 본 연구에서는 5겹 교차 검증을 통한 그리드 서치를 이용하였다.

GNB 모델의 분류 정확도는 매개변수 variance smoothing (var\_smoothing) 값에 의해 달라진다. 매개 변수 값의 범위를 10<sup>-9</sup>에서 1까지 설정하고, 매개변수 값을 약 1.23배씩 증가시켜가면서 최적의 모델을 결정하였다. 그림 35는 var\_smoothing 값의 변화에 따른 모델의 정확도를 나타내는 그래프이며, 모델의 정확도는 매개변수 값이 10<sup>-2</sup>를 넘어서게 되면 급격히 감소하는 것으로 나타났다. GNB 모델은 var\_smoothing 값이 0.000188일 때 모델의 학습 정확도(0.60)가 가장 높게 나타났다.





kNN 모델의 정확도는 이웃의 수를 의미하는 k값에 따라 달라진다. 그림 36은 k값을 1부터 100까지 1 씩 증가시켜가면서 모델의 정확도를 예측한 것이다. kNN 모델의 정확도는 k값이 작을수록 높게 나타났 다(k=1, 0.85).



[그림 36] k값 (n\_neighbors)의 변화(1~100)에 따른 kNN 모델의 학습 정확도

SVM 모델의 학습 정확도가 가장 높게 나타나는 매개변수 값을 결정하기 위해 C와 γ를 변화시켜가 며 모델을 최적화하였다. 매개변수 C는 10에서 100까지 범위로 설정하여 5씩 증가시키면서 γ는 0.1부터 0.9까지 0.1씩 증가시켜가며 모델의 정확도를 계산하였다. 그림 37은 매개변수 C와 γ의 변화에 따른 모 델의 분류 정확도를 나타낸다. C와 γ가 증가할수록 모델의 정확도도 함께 증가하는 경향을 보였다. SVM 모델은 C를 100 γ를 0.9로 설정했을 때 모델의 정확도가 0.78로 가장 높게 나타났다.



[그림 37] C(10~100)와 γ(0.1~0.9)의 변화에 따른 SVM 모델의 학습 정확도

CART의 학습 정확도는 최소 샘플 리프와 최소 샘플 분할에 의존한다. 본 연구에서는 min\_sample \_leaf를 1에서 10까지 1씩 증가시키고 min\_sample\_split을 2에서 10까지 1씩 증가시키면서 두 매개변수 값을 최적화하였다. 그림 38은 두 매개변수 값의 변화에 따라 달라지는 CART 모델의 학습 정확도를 나타낸다. min\_sample\_leaf 값 3 이하일 경우 min\_sample\_split의 값이 증가할수록 모델의 정확도가 낮 아지는 경향을 보였다. 그러나 min\_sample\_leaf 값이 4 이상일 경우에는 min\_sample\_split 값이 증가하 더라도 정확도의 변화는 크게 나타나지 않았다. CART의 학습 정확도는 min\_sample\_leaf를 1, min\_ sample\_split을 4로 설정했을 때 학습 정확도(0.94)가 가장 높게 나타났다.



[그림 38] C(10~100)와 γ(0.1~0.9)의 변화에 따른 SVM 모델의 학습 정확도

### (2) 문제 진단 성능 평가 결과

앞서 결정한 매개변수를 각 모델에 적용하여 검증을 수행하였다. 머신러닝 모델의 검증은 검증 데이 터세트(전체 데이터의 25%, 1,500개)를 이용하여 수행하였다. 표 17~20은 모델의 검증 결과를 오차행렬 로 나타낸 것이다. 표 17은 GNB 모델의 검증 결과를 오차행렬로 나타낸 것이다. 실제 트럭이동시간이 정상인 것으로 분 류된 구간을 정상인 것으로 예측한 경우(TN, true negative)가 687회로 나타났다. 반대로 비정상인 것으 로 분류된 구간을 비정상인 것으로 예측한 경우 (TP, true positive)가 242회 나타났다. 또한, 트럭이동 시간이 비정상인 구간을 정상으로 예측하는 경우와 정상인 구간을 비정상으로 예측하는 경우가 각각 496회(FN, false negative), 75회(FP, false positive)씩 발생하였다. GNB의 검증 정확도는 0.62로 나타났 으며 실제 정상으로 분류된 데이터를 정상인 것으로 예측하는 경우에는 비교적 높은 정확도(0.90)를 보 였다. 그러나 비정상으로 분류된 데이터를 비정상으로 예측하는 경우의 정확도는 0.33으로 매우 낮게 나 타났다.

[표	17]	GNB	모델에	의해	분류된	오차행렬
----	-----	-----	-----	----	-----	------

Predicted data				
acy				
n				
J				
C				
2				
2				
C				

kNN 모델의 경우 1500개의 검증 데이터 중 실제 데이터를 올바르게 예측한 경우인 TN와 TP는 각각 642회, 616회로 나타났다. 예측에 실패한 FN과 FP는 각각 122회, 120회로 나타났다(표 18). kNN 모델의 검증 정확도는 0.84로 나타났으며, 모든 경우에서 비슷한 수준의 정확도를 보였다.

[표 18] kNN 모델에 의해 분류된 오차행렬

Normalizaition		Predicted data				
n_neigl	nbors=1	Negative (0)	Positive (1)	Accuracy		
	Nogative (0)	642	120	0.94		
	Negative (0)	(TN)	(FP)	0.04		
Actual data	Desitive (1)	122	616	0.83		
	Positive (1)	(FN)	(TP)			
	Accuracy	0.84	0.84	0.84		
		Training	0.85			

표 19는 SVM 모델의 검증 결과를 오차행렬로 나타낸 것이다. 실제 트럭이동시간이 정상인 것으로 분 류된 구간이 정상인 것으로 예측된 경우(TN)가 542회 나타났다. 반대로 비정상인 것으로 분류된 구간이 비정상인 구간으로 예측된 경우(TP)가 655회로 나타났다. 또한, 트럭이동시간이 비정상인 구간을 정상으 로 예측하는 경우, 정상인 구간을 비정상으로 예측하는 경우가 각각 196회, 107회씩 발생한 것으로 나타 났다. SVM 모델의 검증 정확도는 0.80로 나타났으며, 실제 비정상으로 나타났던 데이터를 분류하는 문 제에서는 높은 정확도(0.86)를 보였다. 그러나 정상인 데이터를 분류하는 문제에서는 정확도(0.73)가 비 교적 낮게 나타났다.

[표 19] SVM 모델에 의해 분류된 오차행렬

Normal	izaition	Predicted data				
C=100,	γ <b>=0.9</b>	Negative (0)	Positive (1)	Accuracy		
	Nagative (0)	655	107	0.96		
	negative (0)	(TN)	(FP)	0.00		
Actual data	Positive (1)	196	542	0.73		
		(FN)	(TP)			
	Accuracy	0.77	0.84	0.80		
		Training	0.79			

CART 모델의 검증 결과는 표 20과 같다. 모델의 검증 정확도는 0.95로 높게 나타났다. 실제 트럭 이 동시간이 정상인 것으로 분류된 구간을 정상인 것으로 예측한 경우가 713회(TN), 비정상으로 분류된 구 간을 비정상으로 예측한 경우가 706회(TP)로 나타났다. 또한, 비정상으로 분류되었던 구간을 정상으로 예측한 경우와 정상으로 분류되었던 구간을 비정상으로 예측한 경우가 각각 32회(FN), 49회(FP)로 나타 났다. CART 모델의 검증 정확도는 0.95로 매우 높게 나타났으며, 실제 정상인 구간을 분류하는 문제 (0.96)와 비정상인 구간을 분류하는 문제(0.94) 모두 정확도가 높게 나타났다.

[표 20] CART 모델에 의해 분류된 오차행렬

Normal	izaition	Predicted data						
leaf=1,	split=4	Negative (0) Positive (1)		Accuracy				
	Negative (0)	713	49	0.04				
	Negative (0)	(TN)	(FP)	0.94				
Actual data	$\mathbf{D}_{\mathbf{r}}$	32	706	0.06				
	rositive (1)	(FN)	(TP)	0.90				
	Accuracy	0.96	0.94	0.95				
		Training	0.94					

## (3) 문제 진단 성능 비교

본 연구에서는 검증 데이터세트를 이용하여 분석한 각 모델의 오차행렬을 바탕으로 모델의 성능을 평 가하였다. 모델의 성능평가는 정확도(accuracy), 정밀도(precision), 재현율(recall), F1 score를 이용하여 수행하였다. 표 21은 각 모델의 성능지표를 나타낸 것이다. 머신러닝 모델의 예측 정확도는 CART(95%) 가 가장 높게 나타났으며, kNN(84%), SVM(80%), GNB(62%) 순으로 나타났다. CART 모델은 정밀도, 재현율, F1 score 도 높게 나타났다. 따라서 지하광산의 구간별 운반경로의 안정도를 평가하는 문제에서 는 CART 모델이 가장 좋은 성능을 보인다고 할 수 있다.

[표 21] 머신러닝 모델의 성능평가 지표

Performance assessment indicators	GNB	kNN	SVM	CART
Accuracy (%)	61.9	83.9	79.8	94.6
Precision (%)	76.3	83.7	83.5	93.5
Recall (%)	32.8	83.5	73.4	95.7
F1 score (%)	45.9	83.6	78.2	94.6

#### 2. 운반경로 구간별 문제 진단 정확도 분석

머신러닝 모델의 검증 과정에서 사용한 1,500개의 테이터를 이용하여 CART 모델의 구간별 예측 정 확도를 계산하였다. 그림 39는 공차인 경우와 적차인 경우로 구분하여 구간별 모델의 정확도를 나타낸 것이다. 머신러닝 모델은 모든 구간 (45개 구간)에 대해 최소 57.1% 이상의 정확도를 보이는 것으로 나 타났으며, 평균적으로 93.3%의 정확성을 보였다. 공차인 상태로 운행하는 경로(23개 구간)의 경우에는 머신러닝 모델의 예측 정확도가 평균 90.9%로 높게 나타났다. 4개 구간(비콘 ID: 1→3, 5→21, 13→15, 16→17)을 제외하고는 모두 80% 이상의 정확성을 보이는 것으로 확인되었다. 적차인 상태로 운행하는 경우(22개 구간)에는 모델의 예측 정확도가 평균 95.9%로 매우 높게 나타났다. 또한, 22개의 구간 중 20 개 구간이 80% 이상의 정확성을 보였다. 운반경로 구간별 모델의 정확도는 학습을 위해 사용한 테이터 세트에 포함되는 구간별 데이터의 수가 많을수록 대체로 높게 나타나는 경향을 보였다(표 22). 따라서 모델의 예측 정확도가 높게 나타나는 구간의 경우에는 머신러닝 모델이 해당 구간에서 트럭의 운행이 정상적으로 이루어졌는지 평가하기 위해 충분히 활용이 가능할 것이라 판단된다. 그러나 정확도가 낮게 나타나는 구간의 경우에는 머신러닝 모델의 학습을 위한 추가적인 데이터 수집을 통한 머신러닝 모델의 개선이 필요할 것이란 판단된다.



[그림 39] 각 구간별 CART 모델의 예측 정확도: (a) 공차 운행, (b) 적차 운행

Operation Type	Prediction accuracy (%)	Number of sections	Average of the number of data used for machine learning for each section
	91 - 100	14	105.9
Empty	81 - 90	5	90.2
Empty	71 - 80	3	59.3
naui	61 - 70	0	N/A
	57.1 - 60	1	26.0
	91 - 100	19	138.0
Loaded	81 - 90	1	90.0
haul	71 - 80	1	48.0
	66.7 - 70	1	27.0

[표 22] 각 구간별 예측정확도와 머신러닝에 사용된 평균 데이터 수의 관계

### 3. 문제진단 모형 활용

제안된 머신러닝 모델들은 구간별로 측정된 트럭이동시간이 정상적인지 혹은 비정상적인지 판단하여 해당 구간의 운영상태를 진단하는데 활용될 수 있다. 본 연구에서는 CART 모델을 이용하여 분석을 수 행했을 때 검증 정확도가 높게 나타난 구간 1개와 낮게 나타난 구간 1개를 선택하였다. 그런 다음 광산 생산관리시스템에서 추가로 수집되는 로그데이터를 이용하여 트럭의 운행이 해당 구간에서 정상적으로 이루어졌는지에 대한 평가를 수행하였다. 이를 위해 16주차('21.02.22~27) 작업시 수집된 로그데이터를 분석에 이용하였다. 운반경로 구간은 비콘 ID 11에서 6번 구간과 13에서 14번 구간을 선택하였다. 이 구 간들은 머신러닝 모델 검증시 모델의 검증 정확도가 각각 100%와 82%로 나타났다.

먼저 비콘 ID 11에서 6 구간의 경우에는 3대의 트럭이 해당 구간을 일주일 동안 총 41회 운행하였다. 트럭 별로 구분하여 살펴보면 트럭 A는 1회, 트럭 B는 25회 그리고 트럭 C는 15회 운행한 것으로 나타 났다. 해당 구간에 대한 로그데이터를 살펴보면 37회의 운행에서 트럭이동시간이 정상적인 범위 내에서 측정된 것으로 나타났으며, 4회의 운행에서는 비정상적인 범위 내에서 측정된 것으로 나타났다. 해당 구 간은 공차 상태의 트럭이 적재지점으로 향하는 운반경로이며 주변에 적재 및 하역지점이 없다. 따라서 대부분의 트럭들은 해당 구간에서 정차없이 이동하는 특징을 가지고 있다. 해당 구간(비콘 ID 11→6)에 대해 16주차 작업시 수집된 데이터를 CART 모델의 입력 데이터로 변환한 다음 트럭의 운행이 정상적 으로 이루어졌는지 예측을 수행하였다. 그 결과, 실제 정상적으로 이루어진 운행의 경우 트럭이동시간이 정상적인 범위 내에서 측정되었다고 예측했다. 또한, 비정상적으로 이루어졌던 운행의 경우 비정상적으 로 운행되었다고 예측하였다. 즉, 실제 데이터와 CART 모델에 의한 예측 결과가 정확하게 일치하는 것 으로 나타났다. 표 23은 16주차 데이터에 대한 CART 모델에 의한 예측 결과가 정확하게 일치하는 것 이다. 이는 해당기간 동안 트럭들이 기존의 트럭이동시간의 경향을 잘 반영하여 운행하였다는 것을 의 미한다. 또한, 트럭 혹은 운행구간에서 트럭이동시간에 영향을 미칠 어떠한 문제도 발생하고 있지 않다 는 것을 의미한다.

	Normalization	Predicted data			
	leaf=1, split=4		Negative (0)	Positive (1)	
	Trucale A	Negative (0)	1 (TN)	0 (FP)	
	TTUCK A	Positive (1)	0 (FN)	0 (TP)	
Actual data	Tral D	Negative (0)	22 (TN)	0 (FP)	
Actual data	TIUCK D	Positive (1)	0 (FN)	3 (TP)	
	Truck C	Negative (0)	14 (TN)	0 (FP)	
		Positive (1)	0 (FN)	1 (TP)	

[표 23] CART 모델을 사용하여 분류한 오차행렬(비콘 ID 11~6 구간)

[표 24] 비콘 ID 11~6 구간에 대한 시간별/트럭별 CART 모델의 예측결과

	`2	1.02.	22		02.23			02.24	:		02.25			02.26			02.27	
Time	,	Frucl	ĸ		Frucl	c	,	Frucl	s	Truck		Truck		Truck				
	Α	В	C	A	В	C	A	В	C	Α	B	C	Α	В	С	Α	В	C
08:00																		
09:00		•			•	•									•		•	
10:00		•				•						•			•			•
11:00																		
12:00																		
13:00															•			
14:00																		
15:00											•						•	
16:00																		

• TN Cases in which data that are actually normal are predicted to be normal

TP: Cases in which data that are actually abnormal are predicted to be abnormal

: Break time (lunch time)

다음으로 비콘 ID 13에서 14번 구간은 2대의 트럭이 일주일 동안 총 58회(트럭 A:3 34회, 트럭 B: 24 회) 운행한 것으로 나타났다. 해당 구간에서는 총 58회 운행 중 54회는 트럭이동시간이 정상적인 범위 내에서 측정되었으나, 4회는 비정상적인 범위 내에서 측정된 것으로 나타났다. 이 구간의 경우 공차로 운행하는 트럭이 적재지점으로 이동하는 운반경로이다. 그러나 경로 주변에 적재지점(Area D)이 위치해 있기 때문에 트럭이동시간의 변동이 발생할 수 있는 구간이다. CART 모델을 이용하여 트럭이동시간의 상태를 예측한 결과 예측 정확도(86.2%)가 비교적 낮게 나타나는 것을 확인할 수 있었다. 전체적으로 정 상인 것으로 나타난 데이터를 정상으로 예측한 경우(TN)가 46회, 비정상인 데이터를 비정상으로 예측한 경우(TP)가 4회, 정상인 데이터를 비정상으로 예측한 경우(FP)가 8회로 나타났다(표 25). 이 구간의 경 우 이미 검증 정확도가 낮게 나타났기 때문에 16주차 데이터를 이용한 예측에서도 예측 정확도가 낮게 나타나는 것을 확인할 수 있다. 표 26은 16주차 데이터에 대한 CART 모델의 예측결과를 트럭별 시간 대별로 구분하여 시각화한 것이다. 해당 구간에서 CART 모델의 예측 실패가 일부 발생하고 있다. 따라 서 모델의 정확도를 향상시키기 위해서는 모델의 학습을 위한 추가적인 데이터 수집과 모델의 개선이 필요하다. 또한, 일부 데이터에서는 트럭이동시간이 비정상적으로 나타나고 있으므로 운반경로를 주의 깊게 모니터링 해야 할 필요가 있다. 광산의 전체적인 생산성과 트럭운반 작업의 효율성을 향상시키고 원석 운반에 소요되는 시간을 감소시키기 위해서는 이러한 구간을 사전에 모니터링하여 대처하는 것이 필요하다.

	Normalization	Predicted data			
	leaf=1, split=4		Negative (0)	Positive (1)	
	Travels A	Negative (0)	25 (TN)	7 (FP)	
Astual data		Positive (1)	0 (FN)	2 (TP)	
Actual data	Travels D	Negative (0)	21 (TN)	1 (FP)	
	TTUCK D	Positive (1)	0 (FN)	2 (TP)	

[표 25] CART 모델을 사용하여 분류한 오차행렬(비콘 ID 13~14 구간)

[표	26]	비콘	ID	$13 \sim 4$	구간에	대한	시간별/트럭별	CART	모델의	예측결과
----	-----	----	----	-------------	-----	----	---------	------	-----	------

	`21.0	)2.22	02	.23	02.24		02.25		02	.26	02.27		
Time	Tr	uck	Tri	uck	Trı	Truck		Truck		Truck		Truck	
	A	В	A	В	A	В	A	В	Α	В	Α	В	
08:00									•		•	•	
09:00			•			•	•		•	•		•	
10:00		•			•	•	•		•	•			
11:00			•		•			•	•				
12:00					•						•		
13:00	•		•				•		•				
14:00				•				•					
15:00	•			•	•	•	•		•	•	•	•	
16:00						•							

• TN Cases in which data that are actually normal are predicted to be normal

TP: Cases in which data that are actually abnormal are predicted to be abnormal

• FP: Cases in which data that are actually normal are predicted to be abnormal

: Break time (lunch time)

만약 트럭이동시간이 비정상적으로 예측되는 사례가 특정 트럭에서만 관찰된다면 트럭 운전사의 숙련 도 부족, 트럭의 정비불량 혹은 정비시기가 도래했을 가능성을 의심해야 한다. 그리고 광산의 관리자는 이에 대한 적절한 조치를 취해야 할 것이다. 지금까지 살펴본 바에 의하면 본 연구에서 제안한 CART 모델은 트럭이동시간의 상태를 예측한 다음 운반경로 혹은 장비에 발생한 문제나 발생할 가능성에 대해 사전에 모니터링 할 수 있다. 또한, 이에 대한 원인 분석과 대처방안을 마련하는데 도움을 줄 수 있다. 따라서 CART 모델은 광산의 관리자들이 운반작업의 생산성과 효율성을 향상시키기 위한 도구로 활용 이 가능할 것이라 판단된다.

## VI. 개발된 모형의 활용 방안

## 1. 지질자원 분야 활용 방안

개발된 모형은 지질자원 분야의 스마트 마이닝 기술(그림 40)에 직접적으로 활용될 수 있을 것이다. 스마트 마이닝의 핵심 기술은 표 27과 같이 구분할 수 있다. 개발된 모형은 스마트 마이닝에 필요한 Intelligence 기술에 해당한다. 개발된 모형을 활용하면 그림 41과 같이 혼합현실 환경에서 사람과 인공 지능 모형이 상호작용하면서 광산 운반시스템 예측 및 진단을 통해 운영계획을 수립할 수 있을 것이다.



[그림 40] 스마트 마이닝 핵심 기술

[표 27] 스마트 마이닝 핵심기술의 구분 및 정의

기술구분	기술정의	핵심기술		
HMI	실세계와 디지털 환경에 복제된 가상세계를	Mahila Waamahla VD(VD AD MD)		
(Human-Machine Interface)	사람을 중심으로 연계하는 기술	Mobile, wearable, AR(VR-AR-MR)		
Physical to Virtual	실세계의 상태 및 공간정보를 수집하여	LoT/Songon CIS/DIM/2D		
(P2V)	가상세계에 디지털 트윈 모델을 생성하는 기술	IOT/SERISOF, GIS/BINI/SD		
T	가상세계의 디지털 트윈 모델을 이용하여	Disdata (AL Cisculation (Outineitation		
Intelligence	분석, 예측, 진단, 최적화를 수행하는 기술	Bigdata/AI, Simulation/Opumization		
Virtual to Physical	가상세계의 분석, 예측, 진단, 최적화 결과를	Debation /Solf driving UAV/Drama		
(V2P)	실세계에 반영하는 자동화, 무인화 기술	Koboucs/Seir-ariving, UAV/Drone		



[그림 41] 개발된 인공지능 모형의 지질자원 분야 활용 방안

### 2. 타분야 활용 방안 (디지털 트윈 적용 분야 중 운송 관련 분야들)

#### (1) 항만 물류 분야

물류 분야에서는 디지털 트윈을 물류 운영 현황 모니터링과 최적화에 활용하고 있으며, 특히, 컨테이 너 터미널의 운영 현황 및 장비, 차량 상태 모니터링, 물류창고 내부 상황의 실시간 관제, 물류 흐름 및 이동동선 분석 등 다양한 목적으로 활용되고 있다. 컨테이너의 선적 혹은 하역과 같은 실제 항만에서 이루어지는 작업들을 시뮬레이션하고 각종 장비와 차량의 위치, 상태 정보를 실시간으로 모니터링하고 분석 할 수 있는 시스템이 이미 상용화되었다. 또한, 한국교통연구원에서 연구 및 개발한 인터모달 자동 화물운송시스템을 시뮬레이션 할 수 있는 모델이 GPSS/H와 Proof5로 구현되었으며, 이를 통해 시스템 의 처리용량, 장비 이용률, 장비 투입 규모를 예측하고 최적의 운영방안을 결정한 사례가 있다. 따라서 개발된 인공지능 모형을 확대 적용하면 항만 물류 분야에도 활용 가능할 것이라 판단된다.



[그림 42] 인터모달 자동화물운송시스템 시뮬레이션 프로그램(GPSS/H 및 Proof5로 구현) 및 시뮬레이 션 결과

## (2) 스마트 시티 및 자율주행 로봇 분야

도시환경, 교통, 물류 등에 대한 디지털 트윈 모델을 이용하여 가상공간에서 각종 도시 정책을 실험, 분석 및 검증함으로써 스마트시티 조성과 관련한 운영비용을 절감하고 생산성을 향상시키고 있다. 또한, 지속적인 환경정보 수집과 디지털 트윈 기술을 이용한 반복적인 시뮬레이션을 통해 인공지능(AI)을 학 습시킴으로써 새로운 가치를 창출하고 있다. 대표적인 사례로 영국의 VU.CITY는 런던을 대상으로 가상 의도시 모델을 만들어 도시 운영의 효율성을 향상시키고, 다양한 데이터를 접목하여 시민체감형 서비스 를 제공하고 있다. 소셜네트워크를 이용하여 날씨, 환경, 교통, 뉴스 등 데이터를 실시간으로 연동해 인 러랙티브한 모델을 구축함으로써 사회적으로 발생할 수 있는 문제를 모니터링 및 진단하고 있으며, 문 제발생시 빠르게 대응하고 있다. 따라서 개발된 인공지능은 스마트 도시 내의 다양한 물류 로봇의 운영 을 위해 확대 적용할 수 있을 것이라 기대한다.

## VII. 결론

본 연구에서는 태블릿 PC와 블루투스 비콘을 이용하여 수집되는 로그데이터와 머신러닝 모델을 활용 하여 트럭 사이클 타임을 예측하고 지하광산의 생산량을 예측하고 할 수 있는 시뮬레이션 모형을 개발 하였다. 또한, 머신러닝 모형을 이용하여 지하광산 운반경로의 안정도를 평가하고 운영상태를 진단할 수 있는 방법을 제안하였다. 이를 위해 블루투스 비콘과 태블릿 PC를 이용하여 지하광산의 트럭이동시간 데이터를 수집할 수 있는 광산생산관리시스템이 설치되어있는 석회석 광산을 연구지역으로 선정하였다. 머신러닝 모델의 개발을 위해 15주의 기간동안 트럭이동시간 데이터를 수집하였다.

지하광산의 트럭 사이클 타임을 예측하기 위해 kNN, RF, PSO-SVM, DNN 모델을 사용하였다. 가장 성능이 우수한 예측 모형을 설계하기 위해 5겹 교차 검증을 통한 그리드 서치를 이용하여 각 모델의 매 개변수를 최적화하였다. 검증 데이터세트를 이용하여 모형의 성능을 평가한 결과 PSO-SVM 모형이 가 장 좋은 성능을 보이는 것으로 나타났다. PSO-SVM의 MAE는 2.79(min)로 4개의 모형 중 오차가 가장 낮게 나타났으며, MSE는 14.29(min), RMSE는 3.79, R2는 0.68로 나타났다.

애니로직 소프트웨어를 활용하여 생산량 예측 머신러닝—이산사건 시뮬레이션 모형을 개발하였다. PSO-SVM 모형을 이용하여 트럭별/구간별 사이클 타임을 예측하여 시뮬레이션 모형에 입력한 후 시뮬 레이션 모형이 연구지역의 트럭 운반시스템을 제대로 모사하는지에 대한 검증을 수행하였다. 사전에 확 보된 차량운행일지의 분석 결과와 시뮬레이션 수행 결과를 상호비교하여 시뮬레이션 모형의 검증을 수 행하였다. 그 결과, 오전 시간대 작업의 경우 시뮬레이션 모형이 차량운행일지의 분석결과와 유사하게 예측하는 것으로 나타났다. 오후 시간대 작업의 경우, 예측 결과에 다소 차이가 보였으나, 분석결과와 예측결과가 서로 상관관계가 있는 것으로 나타났다. 본 연구에서 개발된 생산량 예측 머신러닝—이산사 건 시뮬레이션 모형은 트럭이동시간에 관한 로그데이터를 이용하여 사이클 타임을 예측할 수 있다. 또 한, 예측된 결과를 시뮬레이션 모형에 입력하여 트럭별, 구간별 생산량을 예측하고 작업장별 최적의 배 차 트럭 수를 결정할 수 있음을 입증하였다.

지하광산 운반경로의 안정도를 평가하고 운영상태를 진단하기 위해 머신러닝 모형(GNB, kNN, SVM, CART)을 활용하는 방법을 제안하였다. 15주 기간동안 수집된 데이터를 이용하여 머신러닝 모형의 학습 과 검증을 수행하였으며, 5겹 교차 검증을 통한 그리드 서치를 수행해 모형에 대한 최적의 매개변수를 결정하였다. 그 결과, CART 모델의 매개변수 leaf와 split을 각각 1과 4로 설정하였을 때 정확도(94.1%) 가 가장 높은 것으로 나타났다. 검증 데이터세트를 이용하여 수행한 CART 모델의 검증에서는 실제 트 럭이동시간이 정상인 데이터를 정상으로 예측한 경우가 713회, 비정상인 데이터를 비정상으로 예측한 경우가 706회로 나타났다. 머신러닝 모델의 성능은 정확도, 정밀도, 재현율, F1 score를 이용하여 판단하였다. CART 모델의 정확도는 94.6%, 정밀도와 재현율은 각각 93.5%, 95.7%로 나타났으며, F1 score도 94.6%로 높게 나타나는 것을 확인하였다. 본 연구에서 제안된 CART 모델은 지하광산의 트럭운반시스 템을 구성하는 운반경로의 상태를 모니터링하고 진단하는 데 활용할 수 있다. 또한, 광산 운반작업의 생산성과 효율성을 향상시키기 위한 도구로 활용이 가능할 것이라 판단된다. 구간별 트럭이동시간은 드라 이버의 운전 숙련도, 갱도 유지 및 보수 상태, 차량 배차 계획 등에 따라 변동성을 가지기 때문에, 트럭 이동시간은 트럭운반작업의 효율성 및 생산성에 큰 영향을 미친다. 따라서, 트럭이동시간이 비정상적으로 예측되는 구간을 미리 파악하고 해당 구간에서 발생하는 문제 혹은 차량에서 발생하고 있는 문제, 향후 발생할 수도 있는 문제들을 사전에 방지하는 것은 매우 중요하다. 제안된 CART 모델은 연구지역

의 모든 구간에 대해 평균적으로 94.1%의 예측 정확도를 보이는 것으로 나타났다. 이는 새롭게 수집되 는 트럭이동시간 데이터가 정상적인 범위에서 측정되었는지 비정상적인 범위 내에서 측정되었는지를 비 교적 신뢰성이 높은 수준에서 판단하여 운반경로의 안정성을 평가하고 진단할 수 있다는 것을 의미한 다.

## 참고문헌

- [1] 산업통상자원부, "제4차 에너지기술개발계획 이노베이션로드맵 (자원개발), 서울, 대한민국: 한국에너지기술평가원, p. 135.
- [2] H. L. Hartman and J. M. Mutmansky, "Unit operations of minings," in *Introductory mining engineering*, 2nd ed. New York, NY, USA: Wiley, 2002, pp. 119–152.
- [3] Y. Choi and A. Nieto, "Optimal haulage routing of off-road dump trucks in construction and mining sites using Google Earth and a modified least-cost path algorithm," *Autom. Constr.*, vol. 20 no. 7, pp. 982–997, Nov. 2011. doi: 10.1016/j.autcon.2011.03.015.
- [4] Y. Choi and A. Nieto, "Software for simulating open-pit truck/shovel haulage systems using Google Earth and GPSS/H," J. Korean Soc. Miner. Energy Resour. Eng., vol. 48 no. 6, pp. 734-743, Dec. 2011.
- [5] S. Alarie and M. Gamache, "Overview of solution strategies used in truck dispatching systems for open pit mines," Int. J. Min. Reclam. Environ., vol. 16, no. 1, pp. 59–76, Aug. 2010. doi: 10.1076/ijsm.16.1.59.3408.
- [6] S. C. Suboleski, *Mine Systems Engineering Lecture Notes*. The Pennsylvania State University, University Park, Pennsylvania, USA, 1975. 1.
- [7] S. G. Ercelebi and A. Bascetin, "Optimization of shovel-truck system for furface mining," *J. South. Afr. Inst. Min. Metall.*, vol. 109, no. 7, pp. 433-439, Jul. 2009.
- [8] D. Jung, J. Baek, and Y. Choi. "Stochastic Predictions of Ore Production in an Underground Limestone Mine Using Different Probability Density Functions: A Comparative Study Using Big Data from ICT System," *Appl. Sci.*, vol. 11, no. 9, 4301, May 2021. doi: 10.3390/app11094301.
- [9] J. Baek and Y. Choi. "Deep Neural Network for Ore Production and Crusher Utilization Prediction of Truck Haulage System in Underground Mine," Appl. Sci., vol. 9, no. 19, 4180, Oct. 2019. doi: 10.3390/app9194180.
- [10] J. Baek and Y. Choi. "Deep neural network for predicting ore production by truck-haulage systems in open-pit mines," *Appl. Sci.*, vol. 10, no. 5, 1657, Mar. 2020, doi: 10.3390/app10051657.
- [11] Y. Choi, H. Nguyen, X. N. Bui, T. Nguyen-Thoi and S. Park, "Estimating Ore Production in Open-pit Mines Using Various Machine Learning Algorithms Based on a Truck-Haulage System and Support of Internet of Things," *Nat. Resour. Res.*, vol. 30, pp. 1141–1173, Oct. 2020, doi: 10.1007/s11053-020-09766-5.
- [12] E. Torkamani and H. Askari-Nasab, "Verifying Short-Term Production Schedules using Truck-Shovel Simulation," In Mining Optimization Laboratory (MOL), University of Alberta, Edmonton, AB, Canada, 2012, pp. 190 - 205.
- [13] B. Ozdemir and M. Kumral, "Simulation-based optimization of truck-shovel material handling systems in multi-pit surface mines", Simul. Model. Pract. Theory, vol. 95, pp. 36-48, 2019. doi: 10.1016/j.simpat.2019.04.006.
- [14] A. Salama and J. Greberg, "Optimization of Truck-Loader Haulage System in an Underground Mine: A Simulation Approach Using SimMine," in *Proc. MassMin 2012: 6th International Conference & Exhibition on Mass Mining*, Sudbury, ON, Canada, 2012.
- [15] Y. Lizotte and E. Bonates, "Truck and shovel dispatching rules assessment using simulation", *Mining Science and Technology*, vol. 5, no. 1, pp. 45–58, 1987. doi: 10.1016/s0167-9031(87)90910-8.
- [16] C. Ta, J. Kresta, J. Forbes and H. Marquez, "A stochastic optimization approach to mine truck allocation", Int. J. Min. Reclam. Environ., vol. 19, no. 3, pp. 162–175, 2005. doi: 10.1080/13895260500128914.
- [17] G. Bastos, "Decision Making applied to Shift Change in Stochastic Open-pit Mining Truck Dispatching", IFAC Proceedings Volumes, vol. 46, no. 16, pp. 34-39, 2013. doi: 10.3182/20130825-4-us-2038.00090.
- [18] Dindarloo, M. Osanloo and S. Frimpong, "A stochastic simulation framework for truck and shovel selection and sizing in open pit mines", J. South. Afr. Inst. Min. Metall., vol. 115, no. 3, pp. 209–219, 2015. doi: 10.17159/2411-9717/2015/v115n3a6.
- [19] E. Torkamani and H. Nasab, "A linkage of truck-and-shovel operations to short-term mine plans using discrete-event simulation", Int. J. Min. Miner. Eng., vol. 6, no. 2, p. 97, 2015. doi: 10.1504/ijmme.2015.070367.
- [20] M. Matamoros and R. Dimitrakopoulos, "Stochastic short-term mine production schedule accounting for fleet allocation, operational considerations and blending restrictions", *Eur. J. Oper. Res.*, vol. 255, no. 3, pp. 911–921, 2016. doi: 10.1016/j.ejor.2016.05.050.
- [21] Y. Choi, "New software for simulating truck-shovel operation in open pit mines," J. Korean Soc. Miner. Energy Resour. Eng., vol. 48 no. 4, pp. 448-459, Aug. 2011.
- [22] S. Park and Y. Choi. "Simulation of Shovel-Truck Haulage Systems by Considering Truck Dispatch Methods," J. Korean Soc. Miner. Energy Resour. Eng., vol. 50, no. 4, pp. 543–556, Aug. 2013. doi: 10.12972/ksmer.2013.50.4.543.
- [23] S. Park, Y. Choi, and H. S. Park, "Simulation of shovel-truck haulage systems in open-pit mines by considering breakdown of trucks and crusher capacity," *Tunn. Undergr. Space*, vol. 24 no. 1, pp. 1-10, Feb. 2014. doi:

10.7474/TUS.2014.24.1.001.

- [24] S. Park, S. Lee, Y. Choi, and H. S. Park, "Development of a windows-based simulation program for selecting equipments in open-pit shovel-truck haulage systems," *Tunn. Undergr. Space*, vol. 24, no. 2, pp. 111–119, Apr. 2014. doi: 10.7474/TUS.2014.24.2.111.
- [25] S. Park, Y. Choi, and H. S. Park, "Simulation of truck-loader haulage systems in an underground mine using GPSS/H," *Tunn. Undergr. Space*, vol. 24, no. 6, pp. 430–439, Dec. 2014. doi: 10.7474/TUS.2014.24.6.430.
- [26] S. Park, Y. Choi, and H. S. Park, "Optimization of truck-loader haulage systems in an underground mine using simulation methods," *Geosystem Eng.*, vol. 19, no. 5, pp. 222–231, Apr. 2016. doi: 10.1080/12269328.2016.1176538.
- [27] Y. Choi, S. Park, S. J. Lee, J. Baek, J. Jung, and H. S. Park, "Development of a windows-based program for discrete event simulation of truck-loader haulage systems in an underground mine," *Tunn. Undergr. Space*, vol. 26, no. 2, pp. 87-99, Apr. 2016. doi: 10.7474/TUS.2016.26.2.087.
- [28] P. Chaowasakoo, H. Seppälä, H. Koivo and Q. Zhou, "Digitalization of mine operations: Scenarios to benefit in real-time truck dispatching", Int J Min Sci Technol., vol. 27, no. 2, pp. 229–236, 2017. doi: 10.1016/j.ijmst.2017.01.007.
- [29] K. Ristovski, C. Gupta, K. Harada, and H. K. Tang, "Dispatch with confidence: integration of machine learning, optimization and simulation for open pit mines," in *Proc. the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, Halifax, NS, Canada, 2017, pp. 1981–1989.
- [30] A. Moradi Afrapoli, M. Tabesh and H. Askari-Nasab, "A multiple objective transportation problem approach to dynamic truck dispatching in surface mines", *Eur. J. Oper. Res.*, vol. 276, no. 1, pp. 331–342, 2019. doie: 10.1016/j.ejor.2019.01.008.
- [31] J. Baek and Y. Choi. "Simulation of Truck Haulage Operations in an Underground Mine Using Big Data from an ICT-Based Mine Safety Management System," *Appl. Sci.*, vol. 9, no. 13, 2639, Jun. 2019. doi: 10.3390/app9132639.
- [32] R. J. Thompson, A. T. Visser, P. S. Heyns, and D. Hugo, "Mine road maintenance management using haul truck response measurements," *Mining Technology*, vol. 115, no. 4, pp. 123–128, Sep. 2013. doi: 10.1179/174328606X155147.
- [33] S. Park and Y. Choi, "Analysis and Diagnosis of Truck Transport Routes in Underground Mines Using Transport Time Data Collected through Bluetooth Beacons and Tablet Computers," *Appl. Sci.*, vol. 11, no.10, 4525, May 2021. doi: 10.3390/app11104525.
- [34] J. Wodecki, P. K. Stefaniak, P. D. S. R. Zimroz, M. S. P. Sliwinski, and M. S. M. Andrzejewski, "Condition monitoring of loading-haulage-dumping machines based on long-term analysis of temperature data," in *Proc. 16th International Multidisciplinary Scientific GeoConference SGEM 2016*, Albena, Bulgaria, 2016, pp. 157–164.
- [35] R. Carvalho, R. Nascimento, T. D'Angelo, S. Delabrida, A. G. C Bianchi, R. A. R. Oliveira, H. Azpúrua, and L. G. Uzeda Garcia, "A UAV-based framework for semi-automated thermographic inspection of belt conveyors in the mining industry," *Sensors*, vol. 20, no. 8, 2243, Apr. 2020. doi: 10.3390/s20082243.
- [36] C. Paduraru and R. Dimitrakopoulos, R. "Responding to new information in a mining complex: Fast mechanisms using machine learning," *Mining Technology*, vol. 128, no. 3, pp.129–142, Feb. 2019. doi: 10.1080/25726668.2019.1577596.
- [37] Y. Zhang, X. Ma, Y. Zhang and J. Yang, "Support vector machine of the coal mine machinery equipment fault diagnosis," 2013 IEEE International Conference on Information and Automation (ICIA), 2013, pp. 1141–1146, doi: 10.1109/ICInfA.2013.6720467.
- [38] T. D'Angelo, M. Mendes, B. keller, R. Ferreira, S. Delabrida, R. Rabelo, H. Azpurua, and A. Bianchi, "Deep Learning-Based Object Detection for Digital Inspection in the Mining Industry," 2019 18th IEEE International Conference On Machine Learning And Applications (ICMLA), 2019, pp. 633-640, doi: 10.1109/ICMLA.2019.00116.
- [39] D. Kim, S. Kim, and E. Jin, "The Research on iBeacon technology trend and issue," in Proc. Korea Computer Congress 2014, Busan, Korea, 2014, pp. 390–392.
- [40] S. Park and Y. Choi, "Bluetooth Beacon-Based Mine Production Management Application to Support Ore Haulage Operations in Underground Mines," *Sustainability*, vol. 13, no. 4, 2281, Feb. 2021. doi: 10.3390/su13042281.
- [41] Y. Yao, J. Wang, P. Long, M. Xie, and J. Wang, "Small batch size convolutional neural network based fault diagnosis system for nuclear energy production safety with big data environment," *Int. J. Energy Res.*, vol. 44. no. 7, pp. 5841–5855, Mar. 2020. doi: 10.1002/er.5348.
- [42] D. H. Pandya, S. H. Upadhyay, and S. P. Harsha, "Fault diagnosis of rolling element bearing with intrinsic mode function of acoustic emission data using APF-KNN," *Expert Syst. Appl.*, vol. 40, no. 10, pp. 4137–4145, Aug. 2013. doi: 10.1016/j.eswa.2013.01.033.
- [43] B. E. Boser, I. M. Guyon, and V. N. Vapnik, "A training algorithm for optimal margin classifiers," In Proc. the fifth annual workshop on Computational learning theory, Pittsburgh, PA, USA, 1992, pp. 144–152.
- [44] I. Yélamos, G. Escudero, M. Graells, and L. Puigjaner, "Performance assessment of a novel fault diagnosis system based

on support vector machines," *Comput. Chem. Eng.*, vol. 33, no. 1, pp. 244–255, Jan. 2009. doi: 10.1016/j.compchemeng.2008.08.008.

- [45] Y. R. Nugraha, A. P. Wibawa and I. A. E. Zaeni, "Particle Swarm Optimization Support Vector Machine (PSO-SVM) Algorithm for Journal Rank Classification," 2019 2nd International Conference of Computer and Informatics Engineering (IC2IE), 2019, pp. 69–73, doi: 10.1109/IC2IE47452.2019.8940822.
- [46] D. Yoon, S. Kim, J. Kim, G. Park, J. Byun, J. Suh, C. Lee, I. Jang, S. Cho and Y. Choi, "Machine learning and deep learning basic," in *Introduction to Machine Learning in Resource Development*, Seoul, Korea: CIR, 2018, pp. 265–288.
- [47] I. Syarif, A. Prugel-Bennett, and G. Wills, "SVM parameter optimization using grid search and genetic algorithm to improve classification performance," *Telkomnika*, vol. 14 no. 4, 1502, Dec. 2016. doi: 10.12928/TELKOMNIKA.v14i4.3956.
- [48] T. M. Mitchell, Machine learning. New York, NY, USA: McGraw-Hill, 1997.
- [49] L. Breiman, J. H. Friedman, R. A. Olshen, and C. J. Stone, *Classification and regression trees*. Belmont, CA, USA: Wadsworth International Group 432, 1984, pp. 151–166.
- [50] M. Hasanipanah, R. S. Faradonbeh, H. B. Amnieh, D. J. Armaghani, and M. Monjezi, "Forecasting blast-induced ground vibration developing a CART model," *Eng. Comput.*, vol. 33, no. 2, pp.307–316, Aug. 2016. doi: 10.1007/s00366-016-0475-9.
- [51] "AnyLogic: Simulation Modeling Software Tools & Solutions for Business", Anylogic.com, 2021. [Online]. Available: https://www.anylogic.com/. [Accessed: 10- Sep- 2021].
- [52] D. Jung, J. Baek and Y. Choi, "Simulation and Real-time Visualization of Truck-Loader Haulage Systems in an Open Pit Mine using AnyLogic," *J. Korean Soc. Miner. Energy Resour. Eng.*, vol. 57, no. 1, pp. 45–57, Feb. 2020. doi: 10.32390/ksmer.2020.57.1.045.