



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

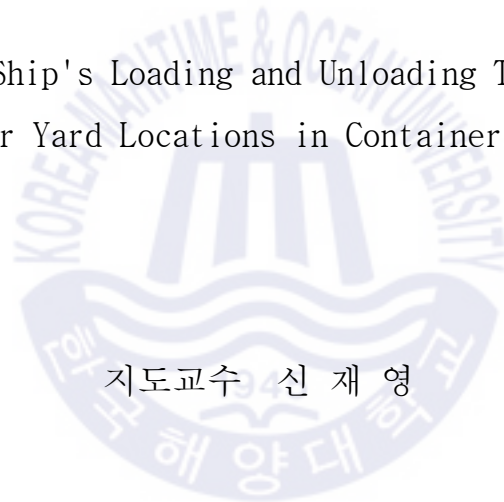
이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

物流學碩士 學位論文

컨테이너 터미널 야드 장치 위치를 고려한
선박 적양하 작업시간 추정

Estimation of Ship's Loading and Unloading Time considering
Container Yard Locations in Container Terminal



지도교수 신재영

2020년 2월

한국해양대학교 대학원

KMI학연합동과정

김남경

本 論文을 김남경의 物流學碩士 學位論文으로 認准함

위원장 : 김 울 성 (인)

위 원 : 김 시 현 (인)

위 원 : 신 재 영 (인)

2019 년 12 월

한국해양대학교 대학원

목 차

Abstract	iv
제 1 장 서 론	1
1.1 연구의 배경과 목적	1
1.2 연구 방향	2
제 2 장 관련 문헌 연구	4
2.1 관련 문헌 연구 개요	4
2.2 기존 문헌 고찰	6
제 3 장 컨테이너 터미널 야드 현황	7
3.1 야드 장치장 구조	7
3.2 야드 장치장 장비	9
3.3 야드 장치장 프로세스	10
3.4 대상 컨테이너 터미널 야드 현황	12
제 4 장 작업시간 추정 모형	18
4.1 모형 설정	18
4.2 적용 데이터 선정	22
4.3 작업시간 추정 모형 프로세스	25
제 5 장 작업시간 추정 모형	27
5.1 데이터 분석	27
5.2 Model 분석	34
5.3 비교 분석	38
제 6 장 결 론	45
참고문헌	46

표 목차

표 1 부산항 컨테이너 물동량 추이	2
표 2 장치장 운영 프로세스 현황과 특징	11
표 3 대상 터미널 제원 현황	13
표 4 물량별 일반 컨테이너 블록 이용수 통계	16
표 5 일반 컨테이너 블록 평균 물량 배치	17
표 6 활성화 함수 특징과 그림	21
표 7 총물량 정보 입력변수 목록	23
표 8 야드 장치 정보 입력변수 목록	24
표 9 하역작업시간과 총 양·적하 물량 상관관계	27
표 10 하역작업시간과 총 Twin 양·적하 물량 상관관계	30
표 11 하역작업시간과 총 Shifting 물량 상관관계	31
표 12 총물량 정보와 하역작업시간 상관관계	32
표 13 야드 장치 정보와 하역작업시간 상관관계	33
표 14 총물량 정보 다중회귀분석 결과	34
표 15 야드 장치 정보 다중회귀분석 결과	36
표 16 훈련 데이터 기반 절대 오차 통계	38
표 17 테스트 데이터 기반 오차 통계	43

그림 목차

그림 1 연구 방향 프로세스	3
그림 2 컨테이너 야드 구조	7
그림 3 야드 블록 구조	8
그림 4 수직형 컨테이너 터미널과 수평형 컨테이너 터미널	9
그림 5 이동 장비와 크레인 작업 모습	10
그림 6 대상 터미널 야드 장치장 조감도	14
그림 7 양·적하별 선박 빈도 도표	15
그림 8 예시 단층 퍼셉트론과 다층퍼셉트론	20
그림 9 작업시간추정모형 프로세스	26
그림 10 하역작업시간과 총 양·적하 물량 산점도	28
그림 11 계산된 총 양·적하 물량 히스토그램	28
그림 12 훈련 데이터와 테스트 데이터 산점도	29
그림 13 하역작업시간과 총 양·적하 Twin 물량 산점도	30
그림 14 하역작업시간과 총 Shifting 물량 산점도	31
그림 15 학습횟수에 따른 평균제곱오차 변화 그래프	38
그림 16 모델별 오차와 총 양·적하 산점도	40
그림 17 모델별 오차와 총 양·적하 밀도 그래프	41
그림 18 훈련 데이터 기반 절대오차 히스토그램	42
그림 19 테스트 데이터 기반 절대오차 히스토그램	43

Estimation of Ship's Loading and Unloading Time considering Container Yard Locations in Container Terminal

Kim, Nam Kyoung

KMI-KMOU Cooperation Program

Graduate School of Korea Maritime and Ocean University

Abstract

This paper grasps the constant changes current situation of port container terminals with limited storage capacity with increasing container traffic volume and suggests the necessity of estimating loading and unloading operation time considering container yard. For this purpose, the actual terminal data was divided into general total volume information and yard location information. As a result of analysis by model, the artificial neural network model with the yard location information was the highest. In the future, it is expected to contribute to the improvement of container terminal operation efficiency by suggesting the loading and unloading time estimation considering the yard location information.

KEY WORDS: Container Terminal 컨테이너 터미널, Loading and Unloading Time 하역작업시간, Yard Location 야드 위치, Estimation Model 추정 모형, Artificial Neural Network 인공신경망

제 1 장 서 론

1.1 연구의 배경 및 목적

컨테이너 터미널은 선박이 접안, 컨테이너를 하역 전용 부두 시설을 통해 운반·보관 하는 장소이며 하역용 이동장비를 통해 야드 장치장을 관리하는 다목적의 항만 부두를 일컫는다. 외·내항 선박에 의해 컨테이너 물량이 발생하고 해상 운송과 육상 운송의 결절점으로 이는 세계 경제활동의 필수불가결한 요소이다.

국내 부산항의 컨테이너 처리 물동량은 최근 5년 기준인 연평균성장률(CAGR : Compound Annual Growth Rate) 약 3.77% 기록하고 있으며 2018년 기준 약 21,663만 TEU를 처리하였다. 특히, 부산 신항은 향후 증가하는 물동량에 대응하기 위해 각 터미널 운영사별 인프라 및 장비 확장을 고려하고 있으며 2022년까지 서 컨테이너 부두(2-5단계)를 개장하여 글로벌 항만 경쟁력을 제고하기 위해 준비중이다.

선박 대형화와 더불어 증가하는 컨테이너의 물량은 항만 컨테이너 내 야드 상황에 영향을 미친다. 예시로, 한 선박의 접안 후, 선박 내 보유하고 있는 많은 물동량을 처리하기 위해 동일 시간상에 접안된 선박에 비해 선석 장비와 운송장비의 할당 대수가 증가한다. 할당 대수가 높아져 야드는 혼잡해지고 결국 야드 운영 효율성을 떨어트리게 된다. 중장기적인 관점에서 인프라를 확충하여 컨테이너 물량 처리 효율성을 높일 수 있으나, 단기적으로 인프라 확충을 통해 효율성을 높이는 것은 어렵다. 따라서, 고정된 야드 상황에서 발생하는 수·출입 컨테이너의 야드 배치 형태와 분포에 따라 어떤 영향을 미치는지 알아볼 필요가 있다.

표 1 부산항 컨테이너 물동량 추이

(단위: 천TEU)

연도	부산항			부산 신항		
	전체	수출입	환적	전체	수출입	환적
2014년	18,683	9,254	9,429	11,966	5,152	6,813
2015년	19,469	9,363	10,105	12,877	5,307	7,570
2016년	19,456	9,620	9,836	12,860	5,513	7,347
2017년	20,493	10,215	10,278	13,480	5,919	7,560
2018년	21,663	10,233	11,429	14,665	6,034	8,630
연평균 증가율 (CAGR)	3.77%	2.55%	4.93%	5.22%	4.03%	6.09%

자료: 부산항만공사 해운항만물류분석시스템 및 항만물류정보시스템(BPA-NET)

하역작업시간은 선박이 선석에 접안하여 수·출입 컨테이너의 양·적하가 시작되는 시점과 완료되는 사이의 시간을 말한다. 해당 선박의 작업시간을 추정하는 것은 다음과 같은 의미가 있다. 첫째, 선박 플래닝 계획에 있어 다음 선박의 접안예정시간을 도출한다. 둘째, 물동량에 대응하여 나타내는 수치이자 항만 경쟁력 제고를 나타낼 수 있는 수치이다.

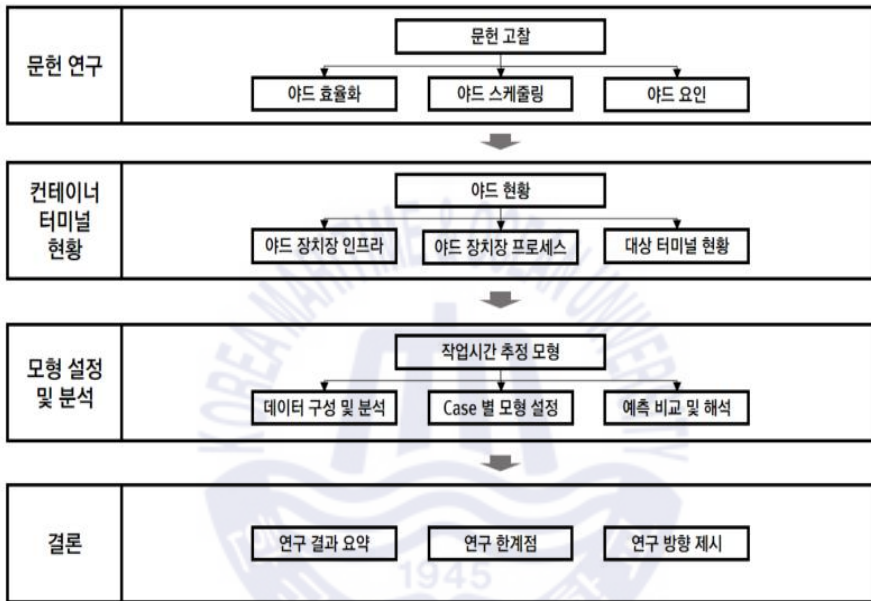
따라서, 본 논문은 고정된 인프라를 기준으로 선박 접안 후 수출입 컨테이너의 양·적하 패턴과 컨테이너 야드에서 발생하는 양·적하 될 컨테이너 블록 단위의 분포, 단적 배치, 패턴에 따라 컨테이너 선박 총 작업 처리시간에 미치는 영향을 조사하고 나아가 모형 간 총작업시간을 추정, 비교 후 컨테이너 장치 위치에 따른 하역작업시간을 해석해 보고자 한다.

1.2 연구 방향

본 논문에서는 현재 야드와 관련된 문헌을 참고한다. 효율화, 스케줄링, 요인에 따른 여러 야드 관련 논문을 참고한다. 대상 터미널 운영사의 실무 담당자를 대상으로 한 자료조사, 데이터 수집, 현 야드 상황을 조사한다.

문제 해결을 위한 모형 설정을 하고 가정한다. 그리고 Data Set을 전처리한다. 실제 데이터를 기반으로 현 야드 배치의 상황, 배치 별 형태에 따른 비교 정리하고 하역작업시간에 미치는 요인들을 파악하여 모형 적용을 위한 주요 변수들을 추출한다. 모형별 비교분석을 통해 해석한다.

그림 1 연구 방향 프로세스



제 2 장 관련 문헌 연구

2.1 관련 문헌 연구 개요

컨테이너 처리에 있어 야드 분포에 관한 연구는 다양한 방법으로 진행되어 왔다. 컨테이너 야드 효율화, 스케줄링, 요인 등의 분류되어 진행되어 왔으며, 세부적으로 컨테이너 야드 내 발생하는 재취급, 야드 트랙터의 할당, 컨테이너 레이아웃에 따른 생산성의 문제 등으로 연구가 진행되어 왔다.

2.1.1 컨테이너 야드 효율화 관련 연구

박영규[2016]는 컨테이너의 유희시간 내 임시 저장 공간이 존재하는 이웃한 베이를 활용하여 리핸들링 계획 수립 방법을 제시, 휴리스틱 방법을 통해 다양한 베이 상황에서 유희시간 내 유효하고 효율적인 계획 수립을 입증하였다.

Feng Chu 외 3인[2019]은 인접한 2개의 블록에 배치된 3개의 야드 크레인에 대한 문제를 혼합 정수계획법(MIP : Mixed Integer Programming)을 통해 해법을 제시하고, 인접한 블록 간 교차 되지 않는 제약을 고려, 총 흐름 시간을 최소화 하여 야드의 총 컨테이너 체류 시간을 단축할 수 있도록 제안된 알고리즘의 효율성을 CPLEX 프로그램을 통해 입증하였다.

Qingcheng Zeng 외 2인[2019]은 트럭 도착 정보가 주어진 컨테이너 화물의 재취급과 픽업순서 최적화 동시에 고려, 5개 트럭 그룹 도착 정보를 기반으로 휴리스틱 알고리즘을 제안하며 이를 통해 픽업순서와 재취급의 동시 최적화가 총 재취급의 횟수 감소에 도움 된다는 것을 나타냈다.

Caimao Tan 외 2인[2017]은 유연한 야드 관리 템플릿 전략을 제안, 공간 할당 및 야드 크레인 배치를 동시에 고려한 혼합정수계획법을 통해 해법을 제시 하며 고정된 템플릿과 유연한 야드 관리 템플릿 간 비교분석을 통해 각 템플릿 별 컨테이너 터미널 운영 효율성 효과를 표현하였다.

Ulf Speer, Kathrin. Fischer[2017]은 수직형 자동화 컨테이너 터미널에 있어

실시간 스케줄링을 위해 서로 다른 4개의 자동 크레인의 상호비교 분석을 시행, 상호 교차가 불가능하나 블록당 2기의 동형 사이즈 TRMG(Twin Rail Mounted Gantry Crane) 배치와 상호 교차가 가능한 DRMG(Double Rail Mounted Gantry Crane)의 배치가 생산성 증가와 지연 감소에 효과적인 것으로 나타났다.

2.1.2 컨테이너 스케줄링 관련 연구

강재호 외 2인[2004]은 컨테이너 적하 계획 수립에 무게중심의 리핸들링 발생 여부를 반출 시작 시점까지 남은 유희시간을 고려, 터미널의 야드 장치장의 크레인 사용 시간보다 적하 시간의 단축이 터미널 생산성에 의미를 중점으로 해석하며, 야드 장치장의 크레인을 통해 적하 작업시 재취급이 발생하지 않도록 베이 내의 컨테이너들을 재정돈하는 컨테이너 이동 순서를 계획하는 방안을 분지한계법을 통해 제시하였다.

최상희, 하태영[2006]은 야드와 터미널 생산성과의 상관관계를 파악하고 야드의 배치형태와 안벽형태의 모델을 제시, 시뮬레이션을 위한 모델기반 다수의 시나리오를 설정하여 야드배치 형태에 따른 대상모델 간 결합생산성 비교분석을 제시, 이를 통해 야드 배치형태에 따라 터미널의 생산성이 달라짐을 입증하였다.

정창윤[2009]은 야드와 선석에 있어 발생하는 공차 문제를 듀얼 사이클(Dual cycle)의 개념을 도입, 듀얼 사이클을 최대화하기 위한 수리적 모형을 제시하였으며 유전 알고리즘과 타부 서치 알고리즘을 통해 문제 해결을 제시하였다.

2.1.2 컨테이너 야드 요인 관련 연구

원태완[2011]은 터미널의 실데이터를 통해 생산성에 미치는 요소들을 파악하고 선석의 혼잡도가 생산성에 미치는 영향이 가장 높은 것으로 나타났다.

윤신휘, 하병현[2012]은 선박 물류 프로세스 실시간 모니터링의 필요성과 선박 프로세스 서비스 완료 시간 예측을 위해 항만 요인들을 추출 및 파악, 서비

스 완료 시간에 대한 실시간 예측을 의사결정 나무 방법론을 적용하여 데이터를 학습시킨 후, 시뮬레이션 모형을 통해 방법론을 검증하였다.

김병주[2015] 반출 전 야드에 체류하는 수입컨테이너의 체류시간 특성을 파악하고 확률분포를 사용한 기대 재취급 확률을 추정, 특성인자를 고려한 3가지 컨테이너 장치위치 결정방법과 기존 컨테이너 터미널의 장치위치 결정방법을 시뮬레이션을 통해 평균 재취급 횟수를 구하여 비교 분석하였다.

2.2 기존 문헌 고찰

기존 문헌은 컨테이너 터미널 야드 장비를 활용한 문제를 고찰하고 활용 목적을 인식, 해당 장비 분류 특성을 고려하여 장비 재취급의 최소화 및 효율적인 장비 활용을 위한 알고리즘을 제시하여 다양한 측면의 방법론을 통해 야드 운영 효율화와 생산성 향상을 고안하였다. 더욱이 야드 구조를 변환하여 유연한 운영 방식을 고려하고 있었다. 컨테이너 터미널의 운영과 효율성을 위해 다수의 연구가 진행되어왔으나 야드 장치장 내 블록에 할당된 컨테이너 물량 성질을 이용한 논문은 미흡하였다.

본 논문은 야드 장치 위치를 고려하여 하역작업시간을 추정하며 기존 문헌과의 차이점으로 간주한다. 이는 컨테이너 야드 분포에 따라 하역작업시간에 어떠한 영향을 끼치는지 알 수 없으며 파악해 볼 의미가 있다. 따라서 향후 분석 대상의 터미널의 야드 현황을 파악하고 야드 상황별 컨테이너 배치 형태 및 분포를 중심으로 하역작업시간 추정 연구를 진행한다.

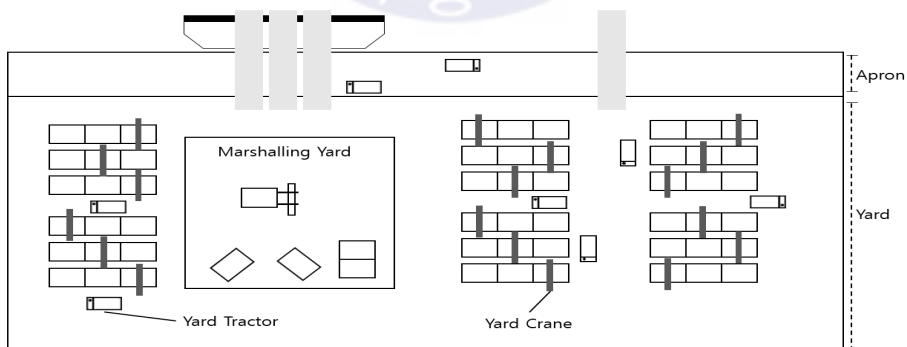
제 3 장 컨테이너 터미널 야드 현황

하역작업시간은 선석과 야드에 관련하여 나타나는 정보이다. 본 논문의 작업 시간 추정을 설명하기 위해 야드 장치장 구조, 야드 장치장 프로세스, 대상 터미널 현황 분석을 차례대로 서술한다.

3.1 야드 장치장 구조

컨테이너 항만은 화물을 효율적으로 반·출입하거나 선적 양하 할 수 있도록 하며, 작업을 할 수 있는 곳을 말한다. 컨테이너 야드는 여러 개의 야드 장비가 투입되어 운영되는 공간을 말하며, 화물을 인수 및 인도, 보관하는 장소를 일컫는다. 컨테이너 터미널 내 존재하는 야드를 On Dock 컨테이너 야드, 컨테이너 터미널 외부에 존재하는 야드인 Off Dock 컨테이너 야드로 장소를 구분하고 있다. On Dock 컨테이너 야드는 일반 보관장소인 컨테이너 야드(Yard), 선박에 양·적하 및 반·출입을 위해 정렬되는 장소인 마샬링 야드(Marshalling Yard), 컨테이너가 본선에 양·적하가 실제로 이루어지는 장소인 에이프런(Apron), 컨테이너 선박이 실제 접안되는 장소인 선석(Berth)으로 구분된다.


그림 2 컨테이너 야드 구조



야드 블록은 컨테이너가 하나의 집단을 이루고, 집단 간 경계를 이루는 공간을 말한다. 일정한 규칙으로 블록의 이름을 정하고, 다수의 야드 블록이 존재한

다. 블록 내 개별 컨테이너는 적재 행 위치인 베이(Bay), 적재 열 위치인 로우(Row), 적재 단적의 높이인 티어(Tier)로 구분된다. 야드 블록은 화물 유형에 따라 구분하여 쌓고 있으며 이는 컨테이너 항만의 운영 효율성을 위함이다. 적재 단수가 높아지면 컨테이너가 무너질 위험성이 존재하며 안전상의 이유로 최고 6단을 준수하고 있다.


그림 3 야드 블록 구조



선석과 야드 블록 컨테이너의 방향이 수평일 경우 수평형 컨테이너 터미널, 수직일 경우 수평형 컨테이너 터미널로 불린다.

아래 그림 4는 이를 나타낸 그림이다. 자동화 컨테이너 터미널의 역할이 일반적으로 수직형이며 반대로 수평인 경우 일반 컨테이너 터미널 항만이 배치 형태를 띤다. 수직형 컨테이너 터미널의 경우 선석에서 양하된 컨테이너가 외부 차량의 반입반출이 가능하기 때문에 야드 트랙터가 필요 없지만 환적화물을 처리하는 데 있어 수평구조가 더욱 효율적이다.

그림 4 수직형 컨테이너 터미널(왼쪽)과 수평형 컨테이너 터미널(오른쪽)



3.2 야드 장치장 장비

야드 장치장 장비는 크레인과 이동 장비로 구분된다. 크레인은 안벽과 야드의 위치로 구분되고 이동 장비는 야드 트랙터(Yard Tractor)와 야드 샤시(Yard Chassis)로 구분된다.

안벽 크레인은 에이프런(Apron)에 위치하여 접안의 길이를 따라 배치된 장비이다. 안벽 크레인은 본선에서 야드로 적하가 이루어질 때 야드 트랙터의 샤시에 해당 컨테이너를 내려놓으며 본선에 적하 시 반대의 순서로 수행한다. 안벽 크레인의 스프레더(Spreader)는 1회 작업에 있어 본선 작업 시 처리하는 컨테이너 물량을 기준으로 Single(1개), Twin(2개), Tendem(4개)로 구분된다. 안벽 크레인은 스프레더 형태에 따라 터미널 생산성에 영향을 미치며 본선에 여러 대가 할당되며 컨테이너 항만 생산성을 측정하는 기준이 된다. 본선 또는 야드 트랙터와 연결된 샤시에서 화물을 끌어 올리거나 내려놓는 형식이다.

야드 크레인은 컨테이너의 양·적하 및 수·출입을 위해 블록 내 위치하고 있으며, 컨테이너 운영 효율성을 위해 블록 내 컨테이너를 재정돈하고 수·출입 화물을 블록 배치 방향의 양 측면에서 양·적하를 수행한다. 할당된 야드 크레인은 블록의 적재 열을 방향으로 움직이며 보통 1~2대의 장비가 블록에 배치, 2대 이상일 경우 서로 간의 간섭이 발생하기 때문에 양 측면을 담당하여 컨테이너 양·적하를 수행한다. 야드 트랙터와 연결된 샤시에서 해당 컨테이너 화물을 끌어 올리거나 내려놓는 형식이다.

야드 트랙터는 본선 또는 야드 크레인에 수·출입 및 양·적하를 위해 해당 컨테이너를 운송하며 야드 샤프스와 함께 움직인다. 야드 샤프스는 야드 트랙터와 함께 움직이며, 컨테이너 운반을 돕고, 양·적하가 수월하게 하도록 하는 이동 장비이다. 야드 트랙터는 이동 장비로서 다른 장비에 비해 비교적 야드를 자유롭게 순환한다.

그림 5 이동 장비와 크레인 작업 모습



각, 장비 간 상호필요적인 요소로 작업을 수행하게 되며 항만 운영 효율성을 위해 컨테이너 터미널 운영사 별로 제원 투자를 하고 있다.

3.3 야드 장치장 프로세스

컨테이너 터미널의 자동화 추세가 나타나기 전 일반 컨테이너 터미널은 배정 계획을 통해 적하 작업을 시행하였다. 배정계획은 본선이 입항 전 야드 장치 계획에 의해 컨테이너가 분배 위치가 여러 특성에 따라 사전에 할당되고, 본선이 입항하여 컨테이너를 양하 후 향후 본선 적재까지의 원활한 컨테이너 적재 작업을 위한 계획을 말한다. 컨테이너 터미널에서 양하란 선박에서 컨테이너 화물을 내리는 작업을 말하며 적하는 컨테이너 터미널 접안된 본선에 화물을 싣는 작업을 말한다. 배정계획은 본선이 입항 전 야드 장치 계획에 의해 컨테이너가 분배 위치가 여러 특성에 따라 사전에 할당되고, 본선이 입항하여 컨테이너를 양하 후 향후 본선 적재까지의 원활한 컨테이너 적재 작업을 위한 계획을 말한다. 다음 특성은 순위 구분을 하지 않으며 가변적 진행되는 컨테이너

터미널 프로세스의 특징이다.

표 2 장치장 운영 프로세스 현황과 특징

분류	장치장 운영	
	북항	신항
공통점	특수 컨테이너 화물이 야드 내 블록 지정되어 할당	
차이점	작업 전 배정계획을 통한 지정 할당	실시간 정보(Real Time) 기반 빈 공간(Empty Space) 할당

첫째, 컨테이너 화물 및 규격의 유형을 고려한다. 컨테이너 화물 유형은 크게 일반 컨테이너 화물, 특수 컨테이너 화물로 구분되며 특수 컨테이너 화물은 냉동물, 위험물 등으로 구분된다. 규격 유형은 컨테이너 자체가 가지는 크기인 20ft와 40ft 이상 크기로 분류된다. 이는 양·적하의 유연성, 유지보수, 관리 및 정보시스템 활용을 위해 화물 및 규격 유형을 고려하여 분배한다.

둘째, 컨테이너 화물의 중량을 고려한다. 컨테이너 화물의 중량은 해당 컨테이너에 있는 화물의 내용을 포함한 중량을 말하며, 야드 장치장 내 블록 적재 시 해당 컨테이너 적재 장소의 상단과 향후 적재될 컨테이너의 무게를 고려하여 적재한다. 이는 적재 컨테이너의 무게 분산을 통해 컨테이너 사고 발생을 줄이고 작업자 및 장비사용의 안전을 고려하기 때문이다.

셋째, 컨테이너 화물의 POD(Port of discharging)를 고려하게 된다. POD 정보는 집화된 컨테이너 블록의 작업 진행 척도, 유연성, 현황파악을 유용하게 한다. POD(Port of discharging)는 컨테이너 최종 양하항구를 말하며, 국외로 나가는 컨테이너를 뜻한다. 예로써, 한국-일본-베트남(최종목적항구)로 운항하는 선박이 있고, 한국에서 베트남까지 수출 컨테이너 물량이 있음을 A라고 가정하고, 한국에서 일본까지 수출 컨테이너 물량을 B라고 가정한다면 해당 수출 장치장은 A를 B보다 아래에 쌓게 된다. 이는 블록 내 수출 컨테이너 화물의 취급 최소화하며 본선 적재 시 화물 일괄처리를 위함이다.

넷째, 반·출입 위치인 게이트(GATE)와 선석(Berth)을 고려한다. 반·출입 위치는 국내 수입과 국외 수출로 구분되며 게이트의 위치에서 가장 가깝게 할당

되는 블록을 국내 수입, 선석의 위치와 가장 가깝게 블록 위치 지정되는 것이 국외 반출로 볼 수 있다. 이는 국내 수출을 위한 게이트(GATE)의 위치가 가까울수록 화물운반중량이 거리대비 높아지고, 국외 또한 상기와 같아 반입 위치를 고려한다.

부산항의 신항과 북항은 화물 자체가 가지고 있는 특성인 위험물, 냉동물, 공컨테이너, 등의 특수화물은 일반적으로 분류되어 지정할당하는 공통점을 가지고 있으나 부산신항의 경우 글로벌 항만의 요충지인 동시에 자동화 도입이 활발하게 되어 실시간 데이터를 기반으로 사전 컨테이너 화물 특성별 지정 위치는 준수하되 야드 장치장 중 비어있는 블록을 발견하여 해당 양하 컨테이너를 적재, 블록 내 베이 간 분산 시키는 방식을 준수하고 있다. 이는 한 크레인이 발생하는 작업빈도 최소화를 통해 작업 제약을 줄이기 위한 노력이다. 그러나 신항의 실시간 기반 운영 방식이 하역작업시간에 어떠한 영향을 미치는지 알 수 없다. 북항의 경우 기존의 배정계획에 따라 앞선 특성을 가변적으로 고려하여 야드 장치장을 운영하고 있으나 북항의 배정계획이 오히려 해당 위치만을 고려하게 되어 야드 장치 운영에 복잡성을 유발하게 된다. 따라서, 야드 장치장에 제약점이 되고 이는 하역작업시간에 어떠한 영향을 미치는지 파악이 필요하다. 본 논문의 대상 터미널은 부산신항이며 부산 신항의 운영 프로세스를 바탕으로 장치장 야드 장치 위치 분배를 고려하여 하역작업시간이 어떠한 영향을 미치는지 파악을 진행한다.

3.4 대상 컨테이너 터미널 야드 현황

3.4.1 야드 장치장 인프라

부산 신항의 위치한 대상 터미널은 선석의 길이가 약 1200m로 통상적 3대의 선박을 접안 할 수 있는 능력을 갖추고 있다. 선석에는 총 12대의 안벽크레인(Quay Crane)이 설비되어 있으며 최대 70m의 스트래들(outreach)의 설비를 보유하고 있어 물동량 증가에 따라 대형화되는 선박을 처리할 수 있다. 선석의 방향과 수평형 컨테이너 배치이며 화물특성에 따른 일반 컨테이너, 공 컨테이

너, 특수화물 장치장이 있으며 A 터미널 장치장 내 일반 컨테이너 블록은 21개로 20ft 및 40ft 컨테이너를 혼재 및 각 블록 내 2개의 ATC(Automatic Transfer Crane)가 배치된 자동화 장비가 설치되어있다.

표 3 대상 터미널 제원 현황

(기준 연도 : 2018)

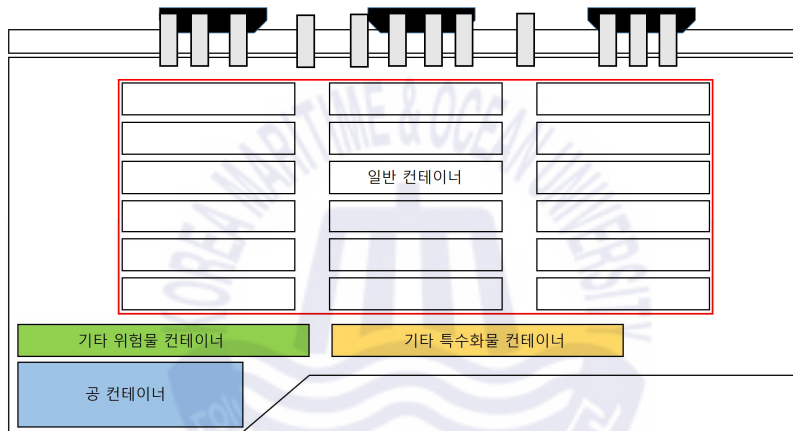
분류	장비 및 시설	개수 및 치수
크레인	안벽크레인	12
	야드크레인	40
이동장비	야드트랙터	85
	야드샤시	160
선석	길이	약 1,200m
	수심	17m
	선석 수	3개
야드	적재 능력	53,755 (TEU)
	일반 컨테이너 블록 수	18
	공 컨테이너 블록 수	2
	위험물 장치장 지정 수	1
	특수화물 장치장 지정 수	26

대상 컨테이너 터미널의 일반 컨테이너 블록은 총 21개이며, 일반 컨테이너 블록을 제외한 특수목적 블록들은 가변적으로 활용, 공 컨테이너 블록은 2개, 위험물 컨테이너 블록은 1개, 기타 특수화물 컨테이너는 26개의 블록으로 구성된다. 컨테이너 규격과 화물 특성에 따라 블록 ROW를 기준으로 분류하고 있다. 일반 컨테이너 블록은 냉동, 오픈(Open), 일반 컨테이너를 혼재하여 사용하며, 냉동 컨테이너의 경우 충전된 공 컨테이너 또는 화물이 실린 컨테이너가 해당 블록을 이용하고 있다. 특수화물을 포함하는 컨테이너의 공 컨테이너는 냉동, 플랫폼, 냉동 컨테이너가 있으며, 공 컨테이너의 경우 지정된 위치인 파란색 부분의 블록을 사용하게 된다. 화물의 폭발 위험성과 관련한 위험물 컨테이너의 지정된 위치가 초록색으로 표시되어 있다.

대상 터미널의 양·적하 작업이 발생하면 첫째, 화물의 특성을 파악, 특수목적 컨테이너의 경우 지정된 위치를 할당하나, 공 컨테이너이자 냉동 컨테이너는 일반 컨테이너 블록에 혼재하여 사용하며, 충전과 화물이 포함된 냉동, 기타 컨테이너 화물들은 지정된 장치장 블록에 할당된다. 둘째, 컨테이너 화물의 특

성 관계없이 일반 컨테이너 블록을 중심으로 할당, 할당 후 야드 장치장 내 TC(Transfer Crane)와 YT(Yard Tractor)를 이용하여 특수목적 블록에 재할당을 진행한다. 양하 작업은 작업이 완료된 후 기입된 정보이며 적하 작업은 본선 적재를 위한 단순 호출에 발생하기 때문에 해당 터미널 프로세스를 파악하기 위해 작업에 의한 야드 배치 형태 패턴을 파악해 볼 필요가 있다.

그림 6 대상 터미널 야드 장치장 조감도



3.4.2 야드 장치장 프로세스

대상 터미널의 야드 프로세스를 파악하기 위해 3년(2016.01.01.~2018.12.31.) 기간 데이터(4,577개)를 분석하였다. 본 논문의 목적인 야드 분포 형태에 따른 작업시간 추정 중 제약으로 냉동, 위험물, 공 컨테이너 블록 및 특수화물들이 지정되는 블록은 하나의 집단으로 처리한다. 특수화물들은 미리 지정된 블록을 사용하여 해당 블록의 위치와 선석까지의 거리대비 이동 작업시간이 포함되고 다수의 일반 컨테이너 블록을 통한 배치 형태와 작업시간을 파악하기 위함이다. 따라서 일반 컨테이너 블록의 양·적하 되는 형태 중심으로 현황을 파악한다.

그림 7은 양·적하 컨테이너 물량에 따른 선박 빈도 분포를 나타낸다. 선박

이 양·적하는 총물량을 보았을 때 해당 선박이 어느 정도 적하하는지, 양하하는지 알 수 없다. 따라서 양·적하를 구분하여 볼 필요가 있다. 단위는 양·적하 작업에 따른 호출 발생 수를 나타내고 물량 구간 기준인 이상과 미만으로 표현한다. 단위 구간별 표본추출 값인 30을 준수하기 위해 1,800개 이상 물량을 보유하고 있는 선박들은 합쳐서 표현하며 300구간의 물량을 나눠서 진행한다. 해당 그림에 따라 선박이 보유한 양·적하 물량에 따라 블록에 배치 형태의 달라짐을 파악해 볼 필요가 있다.

그림 7 양·적하별 선박 빈도 도표

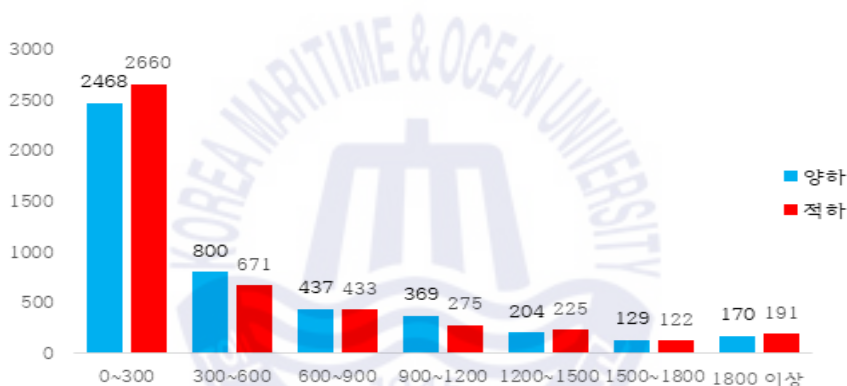


표 5는 앞선 물량별 선박 빈도수 도표를 통해 나눠진 구간별 물량 단위를 통해 일반 컨테이너 블록(18개)에 할당되는 블록 수의 통계를 나타낸다. 양하 측면에서 물량이 증가함에 따라 사용되는 블록의 평균이 증가하는 것을 알 수 있다. 이는 대상 터미널의 선박의 물량이 적을 경우 일반 컨테이너 블록에 상대적으로 적은 블록을 이용하며, 편차가 낮아짐에 따라 이용된 블록 간에 집중도가 떨어지는 것을 알 수 있다. 즉, 상대적으로 적은 물량의 양하는 집중되게 쌓는 경향이 있으며, 이와 반대인 경우 일반 컨테이너 블록의 이용수가 많아진다. 즉, 단순히 물량이 증가함에 따라 사용되는 블록이 많아지는 것으로 자명되나 상대적으로 블록에 집중되지 않는다. 적하 측면에서 적하 물량이 증가함에 따라 사용되는 블록의 평균은 증가하나 편차가 줄어드는 경향은 없어 증가하는 적재 물량에 대해 이용된 블록 간 뚜렷한 집중도가 나타나지 않는다. 이는 일

반 컨테이너 블록 위치별 단순 호출에 따라서 적재 물량이 발생 되는 것을 알 수 있다.

표 4 양·적하 물량별 일반 컨테이너 블록 이용수 통계

소수점 셋째 자리에서 반올림 (단위 : 개)

물량 범위	양하		적하	
	사용된 블록 평균	사용된 블록 편차	사용된 블록 평균	사용된 블록 편차
0~300	9.52	5.55	11.73	5.79
300~600	16.28	1.96	17.60	0.83
600~900	16.59	1.68	17.82	0.60
900~1200	17.10	1.45	17.95	0.30
1,200~1,500	17.34	1.12	17.95	0.34
1,500~1,800	17.45	0.96	17.92	0.44
1,800 이상	17.65	0.73	17.94	0.37

일반 컨테이너 블록을 구분하기 위해 행 방향으로 선석 라인, 열 방향으로 영어명 순서를 부여하였다. 앞선 그림 6의 구조형식을 참고, 블록별 컨테이너 해당 선박이 보유한 물량 범위에 따라 양·적하 물량 블록 배치 현황을 나타낸다. 대상 터미널은 선박 물량이 증가함에 따라 A,C,E 블록에 컨테이너에 집중 양하 작업의 패턴이 나타난다. 특히 1선석과 2선석의 블록별 배치가 뚜렷하고 이와 반대로 3선석의 D,E,F 블록의 물량이 낮아짐과 동시에 패턴이 나타난다. 현장 실무자의 의견으로 위험물 블록 근접한 곳에 물량 할당을 제한하고 있는 것으로 언급하였다.

적하 작업시 발생하는 물량은 앞선 양하 물량의 패턴과 유사하며 앞선 위험물 블록의 제한에 의해 3선석의 물량이 상대적으로 낮다. 적하 작업시 블록별 평균 물량 변동 폭은 양하 작업 대비 낮음을 알 수 있으며 이는 단순 호출에 의해 물량이 발생되고 장치장 내 양하 작업 후 재작업을 통해 컨테이너 분배의 효과로 나타난다.

대상 컨테이너 터미널의 야드 배치 현황에 따른 하역작업시간과의 관계는 향후 분석 부분에서 자세히 다룬다.

표 5 일반 컨테이너 블록 평균 물량 배치

소수점 둘째 자리에서 반올림 (단위 : 개)

물량 범위	블록 이름	양하			적하		
		3선석	2선석	1선석	3선석	2선석	1선석
0이상 ~ 300미만	A	10.61	8.86	9.69	7.86	8.13	7.58
	B	8.82	7.53	7.75	7.32	7.89	7.40
	C	10.27	9.18	8.95	7.55	8.15	7.71
	D	6.32	7.16	7.02	4.20	7.53	7.37
	E	6.97	8.66	8.91	4.46	7.58	7.28
	F	5.86	6.74	6.86	4.07	7.12	6.66
300이상 ~ 600미만	A	28.53	31.51	31.10	24.66	27.51	24.62
	B	22.52	22.41	21.62	19.67	21.81	18.63
	C	29.61	30.35	27.39	25.72	28.02	27.25
	D	12.55	20.85	20.87	9.13	21.61	20.39
	E	15.67	29.68	28.80	11.29	25.64	24.56
	F	11.59	19.05	19.89	8.70	20.64	17.99
600이상 ~ 900미만	A	44.21	49.95	51.79	48.82	50.11	44.11
	B	34.20	36.20	32.95	34.13	37.85	32.62
	C	45.55	49.11	47.17	46.31	47.73	46.79
	D	17.97	33.57	29.79	19.29	37.97	35.69
	E	19.95	48.70	46.70	25.31	47.44	42.97
	F	16.48	31.42	28.22	18.53	35.26	29.86
900이상 ~ 1,200미만	A	67.90	78.05	73.63	65.52	67.43	58.47
	B	45.59	48.49	44.58	49.83	56.44	44.68
	C	67.43	74.83	67.74	62.73	64.49	66.32
	D	21.78	47.57	42.11	26.82	51.69	51.22
	E	28.64	74.50	67.88	33.07	63.78	58.60
	F	23.17	42.46	40.55	26.31	51.35	43.27
1,200이상 ~ 1,500미만	A	88.07	93.79	90.75	80.24	80.15	71.35
	B	58.45	61.04	60.26	76.55	83.76	66.98
	C	88.29	89.54	87.74	77.13	78.79	78.26
	D	29.78	59.81	58.89	36.56	77.70	78.41
	E	32.28	93.85	91.28	36.37	73.42	67.82
	F	29.07	55.66	56.80	37.50	78.28	62.82
1500이상 ~ 1800미만	A	94.54	119.06	122.09	97.42	97.29	80.07
	B	60.67	76.47	74.09	92.79	100.90	83.32
	C	90.45	114.41	115.99	97.02	95.92	88.62
	D	26.72	75.36	71.02	46.35	92.46	93.30
	E	33.45	121.40	119.34	45.32	88.16	81.50
	F	27.97	67.26	70.98	46.86	90.50	76.73
1800이상	A	118.70	176.02	193.18	143.57	146.11	136.12
	B	81.11	100.95	110.59	99.33	116.54	97.63
	C	123.97	171.49	178.58	137.37	140.77	146.50
	D	35.56	100.97	108.62	52.76	106.20	106.00
	E	44.32	172.29	183.42	67.99	137.51	130.69
	F	35.42	90.70	103.39	50.26	109.56	93.74

제 4 장 작업시간 추정 모형

4.1 모형 설정

작업시간 추정에 다양한 분석방법이 사용되고 있으나, 실데이터 내 다양한 변수를 활용하고 설명력을 파악하기 위해 다중회귀분석(Multiple Regression Analysis) 모형을 사용한다. 이는 다중변수 간 단순 선형적인 설명력에 대해 야드 장치 위치의 변수들을 어느 정도 활용하는지 파악하기 위함이다. 또한 모든 변수를 사용하는 인공신경망(ANN : Artificial Neural Network) 모형을 사용한다. 기계학습 통해 모든 변수의 설명력을 파악, 추정력을 높이고 세부적인 추정을 통해 선형적인 분석결과를 제시하는 다중회귀모형과의 추정력을 비교분석하기 위함이다.

총물량만을 고려하는 데이터 정보와 총물량 정보를 보완한 야드 장치 위치 정보를 고려한다. 각 분석 모델은 3가지 유형으로 나눈다. 첫째, 총물량의 정보만을 고려한 다중회귀모형 둘째, 야드 장치 위치를 고려한 다중회귀모형 셋째, 야드 장치 위치를 고려한 인공신경망 모형으로 구성한다. 사전 다중회귀모형을 통해 선형적인 예측치를 관찰하고 모든 변수의 투입을 통해 인공신경망 모형을 적용하여 비교분석을 하기 위함이다.

4.1.1 다중회귀분석 모형

다중회귀분석은 입력변수가 2개 이상, 종속변수가 한 개인 인과관계 모형을 말하며 독립변수와 종속변수 간 관계를 검증하여 독립변수가 종속변수에 미치는 영향력을 파악한다.

다중공선성(Multicollinearity)은 독립변수 간 강한 상관관계가 나타나는 문제를 말하며 이는 부정확한 회귀결과값을 제시하게 된다. 다중공선성을 파악하기 위해 분산팽창요인(VIF : Variance Inflation Factors), 데이터 시각화에 따른 산점도 그래프를 통해 확인하며 문제를 해결하기 위해 독립변수 중 하나 혹은 일부

를 제거하거나 자료형태의 현황을 제시하여 해결한다.

동시투입방식(All Possible Selection)은 모든 독립변수를 투입하여 분석하는 방법이며 다른 모든 독립변수 간 종속변수의 설명력을 비교분석 할 수 있는 장점이 있다. 그러나 다중공선성의 문제가 발생할 수 있어 사전에 공선성의 문제를 파악해 볼 필요가 있다.

전진선택법(Forward Selection)은 종속변수에 가장 강한 설명력의 변수부터 차례대로 모형에 추가하는 방법이며 변수의 유의성을 고려하여 분석을 진행하는 장점이 있다. 그러나 한번 선택된 설명변수가 다른 변수 입력에 의해 더이상 유의하지 않게 되더라도 제거되지 않고 해당 모형 설정을 반복하는 단점이 있다.

후진제거법(Backward Elimination)은 초기 모든 변수들의 모형으로 시작하여 기여도가 가장 적은 변수에서부터 차례로 제거해 나가는 방법이며 다중공선성의 문제를 해결하기 위한 하나의 방법으로 사용되고 있다.

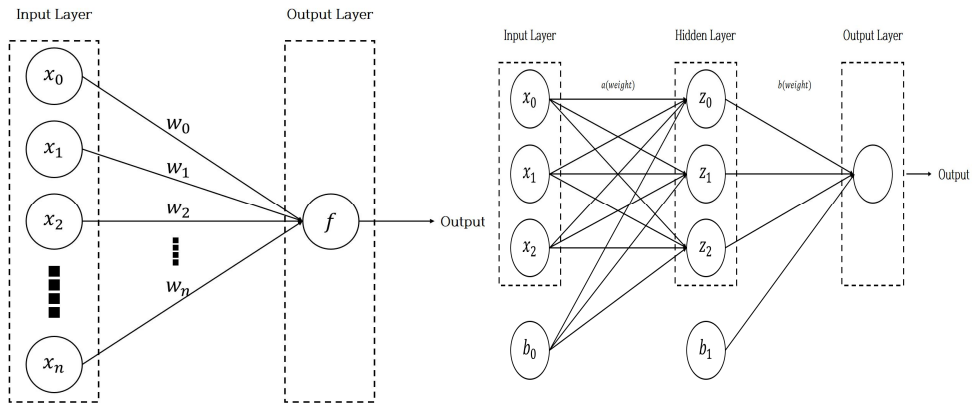
단계적선택법(Stepwise Selection)은 전진선택법과 후진제거법의 단점을 보완한 것으로 중요한 설명 변수를 선택해가며 다음 설명 변수가 추가됨에 따라 제거될 수 있는지를 단계별로 확인하는 방법이다.

다중회귀분석에 있어 설명력을 확인하고 예측력을 높이는 단계적선택법을 적용하여 분석을 진행한다.

4.1.2 인공신경망 모형

생물학적인 뉴런의 착안하여 고안된 인공신경망은 기계가 선형 및 비선형 데이터의 패턴을 학습(Training)하며, 예측 및 분류를 스스로 가능하게 할 수 있는 장점이 있다. 본 논문의 목적인 하역작업시간 추정을 위해 데이터들의 패턴을 파악하고 케이스별 하역작업시간 추정을 위해 인공신경망을 사용한다.

그림 8 예시 단층 퍼셉트론(왼쪽)과 다층퍼셉트론(오른쪽)



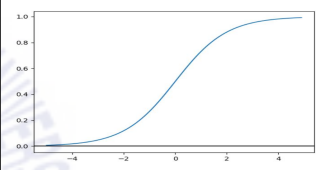
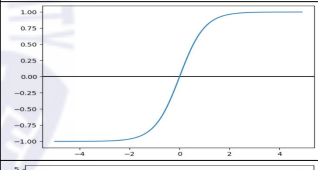
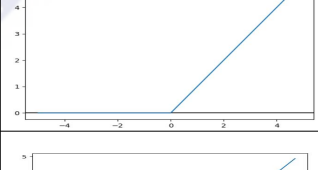
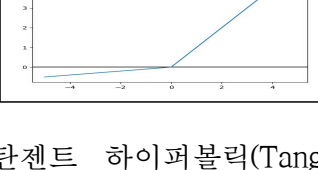
일반적인 신경망은 인간의 뉴런 모양을 바탕으로 만들어진 퍼셉트론(Perceptron)이 바탕이 된다. 단층 퍼셉트론은 초기 변수의 입력값(Input) 집단인 입력층(Input Layer), 출력값(Output)으로 구성, 다층 퍼셉트론(MLP : Multi-Layer Perceptron)일 경우 출력값이 다시 입력값으로 진행되며 활성화 함수(Activation Function)가 있는 은닉층(Layer)이 존재한다. 각 변수들의 가중치 값(Weight)과 다음 층으로 보내지는 결과값을 보정 해주는 편향값(Bias)이 존재 하며 데이터의 학습을 통해 가중치와 편향값을 조정해 나간다. 예시의 다층퍼셉트론 그림은 3개의 변수를 입력, 1개의 히든층으로 구성되고, 하나의 출력값을 나타낸다. 해당 그림의 입력층에서 히든층의 가중치 파라미터(parameter)를 구해야 할 개수는 초기 입력 변수의 개수 3개와 각 노드로 보내질 방향의 수를 곱한 9개이며 편향값인 3개를 더 추가한 12개의 파라미터로 구성, 최종 파라미터의 개수는 16개가 된다.

인공신경망은 초기 가중치를 설정, 가중치와 은닉층의 함수에 따라 결과값을 제시, 해당 결과값과 실제값의 오차를 구하게 된다. 이러한 순방향의 프로세스를 순전파(Forward)라고 하며 변수를 입력하여 앞으로 보낸다는 의미로 (Feed Forward)라고 한다. 오차 역전파(Error Backpropagation)는 오차의 집단을 하나의 함수로 보고 해당 오차값이 가장 낮은 지점을 찾는 기법이다. 가중치 조절이 필요한 인공신경망은 경사 하강법(Gradient Descent)의 방식을 통해 오차 함

수의 낮은 지점을 찾아가며 최적화를 진행한다. 오차 함수는 손실함수라고도 하며, 오차가 가장 낮은 지점(기울기 0)이 가장 예측에 맞게 훈련한 것으로 판단하고 순방향의 아닌 역방향의 가중치를 조절해나간다. 해당 기법은 인공신경망의 가중치를 설정하는 중요 과정이다.

하역작업시간의 단순한 회귀성을 벗어나 컴퓨터의 기계학습과 과정을 묘사하기 위해 히든층을 추가하여 분석 진행하며 히든층 내 뉴런의 개수에 따라 비교 분석을 최적의 추정계산 적합성을 손실함수의 값으로 판단한다.

표 6 활성화 함수 특징과 그림

분류	특징	그림
시그모이드 (Sigmoid)	간단한 신경망 구현 클래스 분류 활용 기울기 소실 발생 계산시간 증가	
탄젠트 하이퍼볼릭 (Tangent Hyperbolic)	시그모이드 개선 계산 시간 완화	
렐루 (Relu)	최초 layer 정보 전달 음의 가중치 소실 계산 시간 감소	
리키 렐루 (Leaky Relu)	렐루 함수 개선 가중치의 음의 방향을 고려	

은닉층의 활성화 함수는 시그모이드(Sigmoid), 탄젠트 하이퍼볼릭(Tangent Hyperbolic), 렐루(Relu), 리키 렐루(Leaky Relu) 등이 있으며 본 논문에서 리키 렐루 함수를 사용한다. 시그모이드 함수는 인공신경망의 기반이 되는 함수이나 오차 역전파 계산 과정에서 기울기 소실문제와 장시간 계산 단점이 존재한다. 탄젠트 하이퍼볼릭 함수는 시그모이드 함수를 개선한 것으로 계산시간을 완화

하였으나 기울기 소실문제에 대해 해결하지 못하였다. 최근 가장 많이 활용되는 렐루와 리키 렐루 함수는 앞선 함수보다 계산시간이 감소하고 초기 layer의 영향력까지 고려 할 수 있는 장점이 있으며 특히 리키 렐루 함수의 경우 가중치의 음의 방향을 고려하기 기울기 소실의 문제를 보완한다.

오버피팅(Overfitting)은 과도하게 훈련 데이터를 기반으로 학습을 한 경우 발생하는 문제를 말한다. 즉, 새로운 데이터가 들어옴에 따라 일반화되어 버린 학습이 새로운 데이터의 추정을 하지 못하는 현상이 발생한다. 언더피팅(Underfitting)은 오버피팅과는 반대의 의미로 충분한 학습이 이루어지지 않아 해당 모형을 설명하지 못하는 상황을 일컫는다. 이를 방지하기 위해 훈련데이터(Training Data)와 테스트 데이터(Test Data)를 구분하고 학습모형의 일반화와 실제 추정력을 분석하여 모형을 해석한다.

본 논문의 목적인 하역작업시간 추정과 관련하여 분류(Classification) 및 시계열 자료(Sequence Data)가 아닌 입력데이터에서 연속적인 값을 예측하는 문제로 볼 수 있다. 따라서, 출력층에서 사용되는 함수는 항등함수(Identity Function)로 지정한다. 항등함수는 입력을 그대로 출력하는 함수를 말하며 일반적인 회귀모형 추정에 있어 사용된다.

인공신경망에 투입변수 목록에 대해 한번 훈련한 것을 1 에포크(epoch)라고 하며 학습훈련이 1회 진행된 의미를 가진다. 에포크 횟수가 증가할 때마다 인공신경망의 문제가 제기된다. 따라서 최적의 훈련횟수와 정확도를 파악할 필요가 있다.

인공신경망의 모형을 정립하고 실제 데이터를 기반으로 분석을 위해 파이썬(python) 3.6 버전과 IDE 개발환경인 Visual Studio Code를 이용하며, 코드 구현을 쉽게 할 수 있는 패키지인 Python의 numpy, pandas, Scikilt-Learn, Keras, 를 사용한다.

4.2 적용 데이터 선정

부산항에 위치한 대상 터미널의 야드 배치 형태에 따른 작업시간 추정을 위

해 2015~2018년 기간에서 발생한 선석 정보 데이터, 야드 정보 데이터를 활용하였으며 필요한 변수를 도출하기 위해 서로 간 매핑(Mapping)과 데이터 전처리를 시행한다. 선석 정보 데이터는 선석에서 발생 되는 데이터 정보를 내포하고 있으며 접안선박의 위치, 물량, 크기 등이 기록되어 있다. 야드 정보 데이터는 양·적하에 따라 발생 되는 개별 컨테이너 화물의 위치가 포함된 데이터이다.

다수의 정보가 포함된 실데이터를 파악하여 2가지 케이스의 인공지능망 추정모형을 설정한다. 첫째, 선박과 선석에서 발생 된 여러 정보를 파악하고 인공지능망 모형을 제시한다. 둘째, 앞선 첫째의 정보와 야드 블록 배치 형태의 정보를 추가하여 인공지능망 모형을 제시한다. 해당 터미널에서 비중을 가지는 데이터 정보를 파악하기 위함이며 어떤 추정 모형이 더 나은 결과값 인지 파악하기 위함이다.

4.2.1 총물량 정보 데이터

총물량 정보는 선석과 선박에서 발생하는 정보를 말한다. 양·적하의 물량은 작업시간 관계에 있어 가장 상당한 관계가 있으며, Shifting은 터미널에 양하할 컨테이너가 아닌 물량이 선박 양·적하 작업을 위해 임시로 에이프런 또는 선박 내 장치하는 것을 말한다. 크레인의 스프레더 형태에 따라 작업시간은 상당히 단축되며 Twin의 경우 해당 작업이 1회 발생 시 2개의 컨테이너 화물 작업처리를 진행하기 때문에 이를 고려한다. 아래의 표는 한 항차 선박이 내포하고 있는 물량정보를 다중회귀모형에 적용하기 위해 선정된 입력변수 목록이다.

표 7 총물량 정보 입력변수 목록

변수명	설명	개수
양하 물량	선박 본선에서 내리는 컨테이너 물량의 수	1
양하 Twin 물량	Twin형 안벽 크레인을 사용한 양하 물량의 수	1
적하 물량	선박 본선에 싣는 컨테이너 물량의 수	1
적하 Twin 물량	Twin형 안벽 크레인을 사용한 적하 물량의 수	1
Shifting 물량	선박 본선 작업을 위해 Shifting 되는 물량의 수	1
크레인의 수	본선 양적하 작업중 할당된 크레인의 수	1

대상 터미널의 실제 데이터를 바탕으로 항차 선박 4,577개의 데이터를 적용하여 다중회귀모형분석을 시행한다.

4.2.2 야드 장치 정보 데이터

대상 터미널의 실제 데이터를 바탕으로 항차 선박 4,577개의 데이터를 적용하여 다중회귀모형과 인공신경망 모형 분석을 시행한다. 현장 실무전문가의 의견을 바탕으로 변수를 선정하며 표 9는 이를 나타낸다.

표 8 야드 장치 정보 입력변수 목록

변수명	설명	개수
적하 블록 물량	장치 블록에서 발생된 적하 물량	22
Twin 적하 블록 물량	장치 블록에서 발생된 Twin 적하 물량	22
양하 물량	선박 본선에서 내리는 컨테이너 총 물량 수	1
Twin 양하 물량	선박 본선에서 내리는 Twin 컨테이너 총 물량 수	1
Shifting 1	선석 크레인이 선내 이적을 1회 하는 물량 수	1
Shifting 2	선석 크레인이 선내 이적을 2회 하는 물량 수	1
선석 위치	선박이 접안 한 선석의 위치	1
크레인의 수	본선 양·적하 작업 중 할당된 크레인의 수	1

앞선 해당 변수들은 야드 장치 위치를 고려한 변수목록이다. 입력변수 목록에서 적하, 양하, Shifting 물량이 세부적으로 구분할 필요가 있다. 이는 야드 상황을 고려하여 추정값의 설명력을 보충하기 위함이다. 적하 블록 물량은 야드 내 발생하여 한 항차에 적재하는 컨테이너의 수를 말하며, 대상 터미널의 일반 블록과 기타 블록으로 나눈다. 일반 블록은 총 18개의 블록, 기타 블록은 공컨테이너, 위험물, 냉동 컨테이너, 기타 컨테이너 블록으로 구분하여 총 22개의 적하 발생 블록 변수를 선정한다. 기타 블록은 상대적 거리가 존재하며 물량에 따라 하역작업시간이 증가하기 때문이다. 크레인의 Twin 작업의 발생 여부는 하역작업시간을 단축하기 때문에 적하 블록 물량을 보강한 변수를 추가한다. 대상 터미널의 양하 작업 시 사전 배정계획이 아닌 실시간 위치 기반 적재 방식을 사용하고 있다. 일반 블록에서 양하 컨테이너들의 블록 배정 위치를 알 수 없어 총 양하 물량의 변수를 선정한다. 또한 Twin 작업 여부에 따라 양하 물량을 구분한 변수를 추가한다. 앞선 총물량 정보 Shifting의 변수는 2개로 나

누어 구분한다. 이는 크레인의 작업횟수를 1회 또는 2회 진행하는 물량 수로 볼 수 있으며 해당 본선에서 크레인의 작업시간이 고려된 변수이다. 현장 전문가의 의견을 반영한 선석 위치는 해당 터미널의 야드 상황에 영향을 받는 것으로 추정하고 변수로 선정한다.

4.3 작업시간 추정 모형 프로세스

다중회귀 및 인공신경망 모형 설정을 위한 프로세스는 그림 9과 같다. 필요 변수목록에 의해 데이터를 투입한 모형은 실제 데이터를 통해 얼마나 추정이 되는지 확인이 필요하다. 이를 위해 훈련 데이터와 테스트 데이터로 구분한다. 그러나 단순한 훈련데이터와 테스트 데이터 구분은 표본의 대표성을 나타내지 못한다. 따라서, 종속변수에 가장 영향력이 있는 변수를 선정, 선정된 변수를 기준으로 층화추출법(Stratified sampling)을 진행한다.

작업시간추정 모형에 있어 다중회귀모형에는 항차 선박에서 발생하는 총물량 정보와 항차 정보에서 파생되어 컨테이너 야드 배치 형태를 고려한 야드 장치 정보 회귀모형으로 구분하여 데이터를 파악한다. 야드 장치 정보는 본 논문의 목적인 야드 배치 형태를 고려하고 총물량 정보를 보완하여 한정된 제원에서 발생하는 문제를 고려하기 때문이다. 인공신경망 모형은 야드 장치 정보만을 고려하여 진행한다. 이는 야드배치형태에 따른 기계학습의 추정치를 구하고 회귀모형과의 비교분석을 위함이다. 총물량정보, 야드장치 정보를 다중회귀로 분석한 예측치와 야드장치 정보만을 고려한 인공신경망 예측치 비교분석을 통해 작업시간추정 모형을 해석한다.

1) 다중회귀모형

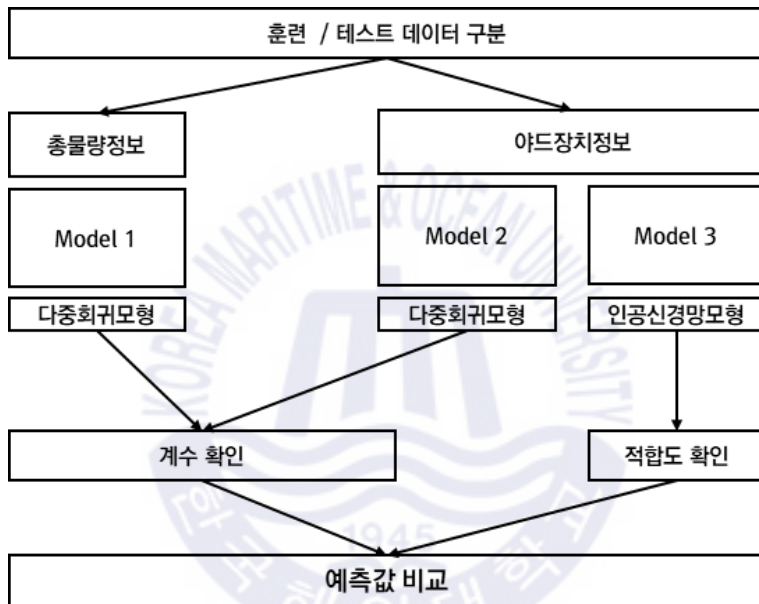
6개의 입력변수의 총물량 정보와 50개의 입력변수인 야드장치 정보를 구분하여 분석진행한다. 데이터 입력변수가 종속변수에 미치는 설명력 고찰, 문제점을 파악하고 회귀계수를 도출, 결과값을 인공신경망 모형과 비교한다.

2) 인공신경망 모형

인공신경망 모형의 입력되는 변수는 50개이며 출력층 활성화 함수는 항등함

수를 이용한다. 히든층과 노드수의 결정에 따라 출력되는 결과값이 상시 달라진다. 훈련데이터에 있어 검정데이터(Validation data)를 지정하여 분석한다. 이는 여러 검증 절차를 통해 얼마나 추정이 잘되었는지에 대해 확인하고 평균절대오차(Mean Absolute Error)의 값을 통해 확인하며 실측값과 예측값의 비교를 제시, 다중회귀모형과의 예측값을 비교분석하기 위함이다.

그림 9 작업시간추정모형 프로세스



제 5 장 하역작업시간 추정 분석

5.1 데이터 분석

5.1.1 데이터 구분

훈련 데이터와 테스트 데이터를 구분하기 위해 하역작업시간과 가장 관련성이 있는 변수를 파악한다. 표 10은 총 양·적하물량 정보를 바탕으로 하역작업시간과의 상관관계를 나타낸다. 일반적으로 물량이 증가함에 따라 작업시간이 증가하는 것으로 자명되기 때문에 총 양·적하물량 정보를 바탕으로 훈련 데이터와 테스트 데이터를 구분 진행한다. 표 10은 하역작업시간과 총 양·적하물량의 상관관계를 나타낸다. Pearson 상관이 0.941로 강한 양의 상관관계임을 알 수 있다.


표 9 하역작업시간과 총 양·적하 물량 상관관계

		총 양·적하 물량
하역 작업 시간	Pearson 상관	.941**
	유의확률 (양측)	.000
	N	4,577

** 상관관계가 0.01 수준에서 유의(양측)


시각화를 통해 해당 데이터의 구조를 파악해 볼 필요가 있다. 아래의 그림 10은 전체 총물량(가로 축)과 하역작업시간(세로 축)에 대한 산점도를 나타낸다. 전체적으로 물량이 증가함에 따라 상관성이 증가하며, 3,000 이하의 물량이 집중적으로 배치된 형태가 나타난다. 이는 단순히 훈련데이터와 테스트 데이터의 표본을 추출하게 될 경우 문제가 될 수 있으며, 표본 데이터의 대표성이 사라지게 된다. 따라서 총물량의 히스토그램을 파악하고 층화추출법을 이용한다.

그림 10 하역작업시간과 총 양·적하 물량 산점도



층화추출법을 위해 총물량의 히스토그램을 파악한다. 그림 11은 층화추출을 통해 만들어진 히스토그램이다. 해당 히스토그램을 만드는 과정은 다음과 같다. 첫째, 총물량을 600으로 나눈다. 이는 계급 구간을 600의 물량 구간으로 지정한다. 둘째, 계산편의를 위해 소수점 첫 번째 자리에서 올림처리를 진행한다. 따라서 다음과 같은 히스토그램이 도출된다. 가로축은 편의상 계산된 범위 구간 1 ~ 10을 나타내며, 세로축은 이에 구분되는 빈도수를 나타낸다.

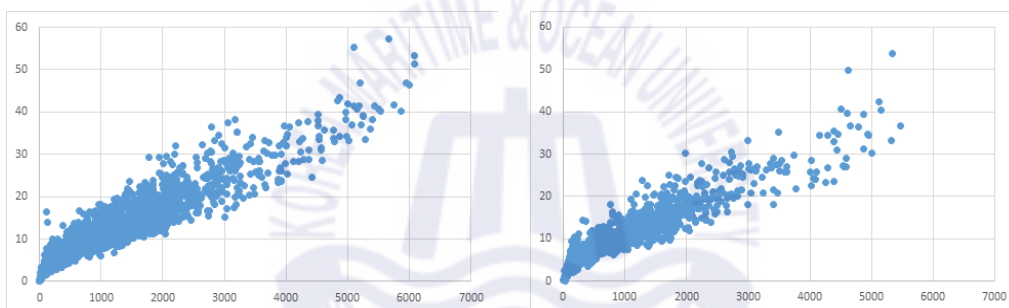
그림 11 계산된 총 양·적하 물량 히스토그램



셋째, 5 이상의 구간을 모두 하나의 집단으로 구분한다. 앞선 총물량의 데이터의 분포를 파악하여 3,000 이상의 데이터의 수가 상대적으로 적기 때문에 진행된다. 즉, 모형의 충분한 학습 데이터를 투입하고 충분한 테스트 데이터를 구성하여 비교분석 하기 위함이다.

계급 구간별 훈련데이터 70%와 테스트 데이터 30%를 랜덤추출(Random Sampling)을 시행, 도출된 데이터는 그림 12과 같다. 총 양·적하 물량 중심으로 구분하며, 훈련데이터의 총 수는 3,203개, 테스트 데이터의 총 수는 1,374개로 구성된다.

그림 12 훈련 데이터(왼쪽)와 테스트 데이터(오른쪽) 산점도



(가로축 : 총 양·적하 물량, 세로축 : 하역작업시간)

5.1.2 데이터 분석

본 논문의 목적인 하역작업시간 추정을 위해 하역작업시간과 입력변수 간의 패턴과 상관성을 파악해 볼 필요가 있다. 각 모델에 투입되는 물량 정보 및 장치 위치 정보 변수의 패턴과 특징을 파악하기 앞서 분리하지 않은 변수를 파악할 필요가 있다. 따라서 전체 물량으로 간주되는 물량 데이터의 하역작업시간과의 상관관계와 산점도를 제시하며 분석한다. 총 양·적하 물량에 해당하는 물량 기반 변수는 앞서 데이터 구분에서 제시함을 참고한다.

표 10은 하역작업시간과 총 Twin 양·적하물량의 상관관계를 나타낸다. 총 Twin 양·적하물량은 총 양하 Twin 물량과 총 적하 Twin 물량의 합을 나타낸다. Pearson 상관이 0.785로 뚜렷한 양의 상관관계를 나타낸다. 이는 해당 변수

가 하역작업시간에 영향을 미치는 것으로 볼 수 있다.

표 10 하역작업시간과 총 Twin 양·적하 물량 상관관계

		총 Twin 양·적하 물량
하역 작업 시간	Pearson 상관	.785**
	유의확률 (양측)	.000
	N	4,577

** 상관관계가 0.01 수준에서 유의(양측)

Twin 물량은 안벽 크레인의 스프레더 형태에 따라 작업 진행 방식이 달라지며 해당 1회 작업횟수에 있어 2개의 컨테이너 화물의 양·적하를 진행한다. 따라서 단일 작업횟수에 비해 하역작업시간이 단축되는 결과를 가져온다. 그림 13은 가로축이 총 양·적하 Twin 물량을 세로축이 하역작업시간을 나타낸다. 물량이 증가함에 따라 하역작업 산점도가 퍼지는 형태가 나타난다. 상대적으로 물량이 많은 대형선박 하역작업시간을 보완할 수 있는 변수특징으로 볼 수 있다. 총 양·적하 Twin 물량의 변수는 총물량 정보에서 총 Twin 양하와 총 Twin 적하 물량으로 분류, 야드장치 위치 정보에서 세부적으로 분류하여 모델에 투입 진행한다.

그림 13 하역작업시간과 총 양·적하 Twin 물량 산점도

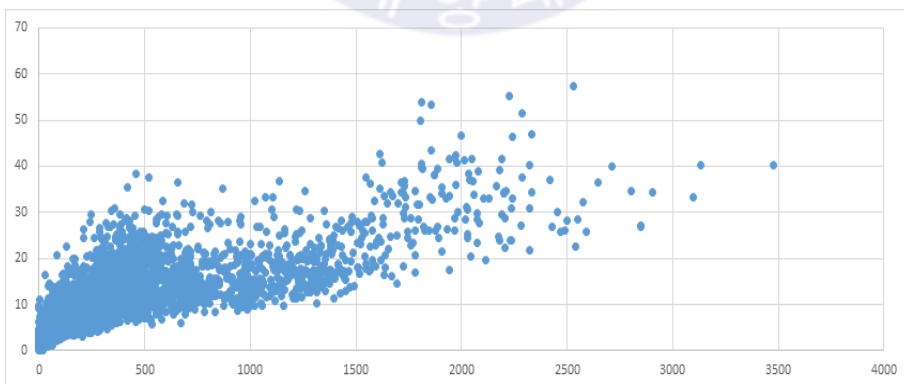


표 11은 하역작업시간과 총 Shifting 물량의 상관관계를 나타낸다. Shifting 물량은 선석에 인접한 에이프런에 양·적하 하거나 선박 내에서 크레인에 의해

재작업이 일어난 횟수를 말하며 Pearson 상관이 0.333으로 상대적으로 약한 상관관계를 보여 하역작업시간에 미치는 영향력이 낮을 것으로 판단된다. 산점도를 통한 시각화로 해당 변수의 특징을 파악해 볼 필요가 있다.


표 11 하역작업시간과 총 Shifting 물량 상관관계

		총 Shifting 물량
하역 작업 시간	Pearson 상관	.333**
	유의확률 (양측)	.000
	N	4,577

** 상관관계가 0.01 수준에서 유의(양측)

그림 14은 가로축이 총 Shifting 물량을 세로축이 하역작업시간을 나타낸다. 총 Shifting 물량이 상대적으로 낮은 구간(400개 이하)에서 하역작업시간 산점도의 흩어짐이 뛰는 것을 볼 수 있다. 이는 Shifting 물량이 선박마다 상이하기 때문에 관계성이 없어 보이나, 많은 물량을 보유하고 있는 대형선의 경우 기항하는 항만이 상대적으로 높아짐에 따라 재작업의 횟수가 증가하게 된다. 따라서 상대적으로 물량이 많을 경우 선형적인 상관성이 나타난다. 모형에 투입될 경우 상대적으로 많은 물량의 하역작업시간에 영향을 미칠 것으로 판단된다. 야드장치정보에서 해당 변수는 Shifting 1과 2로 구분하고 하역작업시간 설명력을 보강 진행한다.

그림 14 하역작업시간과 총 Shifting 물량 산점도



총 양·적하 물량과 총 쉬프팅 물량은 상관관계가 있는 것으로 판단된다. 위 변수들을 다중회귀모형과 인공신경망 모형에 적용하기 위해 구분되는 변수들의 상관관계를 파악할 필요가 있다.

1) 총물량 정보

다중회귀모형에 투입되는 총물량 정보의 하역작업시간과 상관관계를 파악하기 위한 분석결과는 표 12와 같다. 모든 입력변수는 하역작업시간과 양의 상관관계가 존재하는 것을 알 수 있다. 양하물량과 적하 물량은 총 양·적하 물량에서 구분된 변수로 하역작업시간과 양의 강한 상관관계가 존재한다. 총 양·적하 Twin 물량을 구분한 양하 Twin과 적하 Twin도 강한 양의 상관관계가 나타난다. 이는 해당 변수를 구분지어 회귀모형에 투입시 설명력을 높일 수 있는 변수로 타당하다. 변수 간 상관관계 발생여부에 따라 다중 공선성을 해결하기 위해 다중회귀모형에서 단계적 방법을 통해 진행하며 해당 공선성의 문제는 분석 모델에서 제시한다.

표 12 총물량 정보와 하역작업시간 상관관계

		입력변수					
		양하	적하	양하 Twin	적하 Twin	Shifting	크레인수
하역 작업 시간	Pearson 상관	.772**	.791**	.678**	.707**	.333**	.737**
	N	4,577					

** 상관관계가 0.01 수준에서 유의(양측)

2) 야드장치 정보

다중회귀모형과 인공신경망 모형에 투입되는 야드장치 정보의 하역작업시간과 상관관계를 파악하기 위한 분석결과는 표 13과 같다. 총 50개의 입력변수 중 하역작업시간과 상관관계가 있는 변수는 46개로 구성, 적하 Twin 물량 변수에서 구분된 1라인 B, D, F, 3라인 B에서 상관관계가 없는 것으로 나타났다. 이는 해당 변수 내 데이터가 동일한 상수이자 발생하지 않은 물량 정보로 하역작업시간과 관계가 없는 것으로 나타났다. 향후 인공신경망 모형에서 분석을 위

해 변수를 투입하되 설명력을 부과되지 않을 것으로 판단되나 데이터 축적과 향후 실증적인 제안을 위해 인공신경망 모형에 있어 해당 변수를 고려하며 회귀모형에서는 단계적 방법으로 제거될 것으로 판단된다. 적하 물량 변수에서 구분된 일반 및 기타 컨테이너 블록은 모든 변수가 하역작업시간과 양의 상관관계를 나타내고 있으며 또한 일반 및 기타 컨테이너 블록에서 구분된 적하 Twin 물량 변수는 공 컨테이너 블록을 제외한 모든 변수(21개)가 양의 상관관계를 나타내고 있다. Shifting 변수는 1과 2로 구분하여 진행하며 양의 상관관계가 있음을 알 수 있다. 앞서 공통 제시된 변수인 양하, 양하 Twin, 크레인 수는 양의 상관관계가 있음을 제시하였다. 접안위치 변수는 전문가의 의견을 바탕으로 추가한 변수로서 약한 음의 상관관계를 나타내고 있었다. 이를 통해 야드 장치 위치 변수가 설명력이 타당한 것으로 간주하고 해당 변수들을 회귀모형에 투입하여 분석 진행하되 구분된 변수 간 공선성의 문제 발생여부를 파악하기 위해 회귀모형의 단계적 방법을 통해 진행하고 공선성의 문제는 분석 모델에서 제시한다.

표 13 야드 장치 정보와 하역작업시간 상관관계

	Pearson	적하 물량 변수					
		1라인A	1라인B	1라인C	1라인D	1라인E	1라인F
하역 작업 시간	상관	.641**	.711**	.645**	.709**	.643**	.700**
		2라인A	2라인B	2라인C	2라인D	2라인E	2라인F
		.650**	.720**	.643**	.712**	.640**	.720**
		3라인A	3라인B	3라인C	3라인D	3라인E	3라인F
		.621**	.696**	.629**	.649**	.586**	.626**
		위험물	냉동	공컨테이너	기타		
		.509**	.467**	.202**	.539**		
		적하 Twin 물량 변수					
		1라인A	1라인C	1라인E	2라인A	2라인B	2라인C
		.665**	.677**	.669**	.675**	.461**	.679**
		2라인D	2라인E	2라인F	3라인A	3라인C	3라인D
		.432**	.659**	.434**	.654**	.677**	.488**
		3라인E	3라인F	위험물	냉동	공컨테이너	기타
		.618**	.489**	.574**	.494**	.051**	.395**
		양하	양하 Twin	Shifting 물량 변수		크레인수	접안위치
				Shifting 1	Shifting 2		
		.772**	.678**	.334**	.333**	.737**	-.144**

** 상관관계가 0.01 수준에서 유의(양측), 데이터 수 : 4,577

5.2 Model 분석

각 모델의 분석 데이터는 훈련데이터로 진행한다. 이는 동일 조건하에 비교 분석을 진행하고 각 모형을 통해 테스트 데이터를 얼마나 추정하는지 비교, 실증적인 접근을 하기 위함이다.

5.2.1 Model 1

해당 모델은 총물량의 정보만을 고려한 다중회귀모형이다. 변수 간 공선성의 문제를 해결하고자 단계적 선택법을 적용하여 분석을 진행한다. 훈련 데이터를 적용한 다중회귀모형 결과는 다음과 같다.

표 14 총물량 정보 다중회귀분석 결과

구분		R		R ²	adj R ²	추정값의 표준오차		
모형요약		.955		.911	0.911	2.242677		
구분	변수	비표준화 계수		표준화 계수	t	유의 확률 *	공선성 통계량	
		B	표준화 오류	베타			공차	VIF
6회 - 출력 결과	(상수)	4.709	0.100		47.011	0.00		
	적하	0.010	0.000	0.792	57.426	0.00	0.146	6.857
	양하	0.009	0.000	0.651	51.697	0.00	0.175	5.718
	Shifting	0.014	0.000	0.161	28.911	0.00	0.899	1.113
	크레인수	-0.890	0.052	-0.161	-17.168	0.00	0.314	3.180
	적하 Twin	-0.005	0.000	-0.159	-11.700	0.00	0.150	6.666
	양하 Twin	-0.002	0.000	-0.077	-6.250	0.00	0.183	5.456

*p<.05, 소수점 셋째 자리에서 반올림

총물량 정보 변수가 설명력(R² : 0.911, 수정 R² : 0.911)이 높은 것을 알 수 있다. 모든 입력변수들의 유의미한 영향을 미치고 있는 것으로 나타났으며, 모든 입력변수의 투입과 다중 공선성의 측면에서도 10이상의 값이 없어 문제가

없는 것을 알 수 있다.

비표준화 계수의 측면의 양하, 적하, Shifting은 하역작업시간의 양의 영향력을 미치며 Twin양하, Twin적하, 크레인수는 하역작업시간의 음의 영향을 미치는 것으로 알 수 있다. 앞선 산점도를 통해 파악된 변수들의 특징이 계수를 통해 반영되는 것을 알 수 있다. 결과의 도출된 회귀계수가 타당한 것으로 간주하고 비표준화계수를 통해 추정을 진행한다.

5.2.2 Model 2

해당 모델은 총물량의 정보를 보완한 야드 장치 위치의 정보를 토대로 분석한 다중회귀이다. 변수 간 공선성의 문제를 해결하고자 단계적 선택법을 적용하여 분석을 진행한다. 훈련 데이터를 적용한 다중회귀모형 결과는 표 15와 같다.

해당 분석결과에서 처음 시행 시 공선성 단계가 존재한 변수 Shifting 1과 Shifting 2가 발생하여 이를 제외하고 재분석을 시행하였다. 각 변수명에 tw 는 Twin 물량을 의미한다. 야드 장치 정보가 설명력($R^2 : 0.957$, 수정 $R^2 : 0.916$)이 높은 것을 알 수 있다. 단계적선택법에 의해 총 50개의 변수 중 23개의 변수가 설명력을 가지고 이를 설명하고 있다. 다중공선성의 측면에서도 10이상의 값이 없어 문제가 없는 것을 알 수 있다. 따라서 도출된 회귀계수가 타당한 것으로 간주하고 비표준화계수를 통해 예측을 진행한다.

표 15 야드 장치 정보 다중회귀분석 결과

구분	R	R ²		adj R ²	추정값의 표준오차			
모형 요약	.957	0.916		0.916	2.18			
구분	변수	비표준화 계수		표준화 계수	t	유의 확률 *	공선성 통계량	
		B	표준화 오류	베타			공차	VIF
23회 - 계수 출력 결과	(상수)	4.02	0.15		27.14	0.00		
	D	0.01	0.00	0.67	51.27	0.00	0.16	6.44
	2라인D	0.02	0.00	0.07	4.69	0.00	0.11	9.31
	Shifting	0.01	0.00	0.16	29.78	0.00	0.87	1.15
	3라인C_tw	0.02	0.00	0.08	6.03	0.00	0.16	6.11
	냉동 컨테이너 블록	0.03	0.00	0.09	13.18	0.00	0.55	1.81
	1라인D	0.02	0.00	0.10	6.45	0.00	0.12	8.40
	크레인수	-0.91	0.05	-0.17	-17.72	0.00	0.30	3.33
	3라인F	0.03	0.00	0.06	6.68	0.00	0.30	3.37
	2라인A	0.01	0.01	0.03	2.50	0.01	0.20	5.00
	1라인C_tw	0.02	0.00	0.06	4.52	0.00	0.14	7.26
	3라인C	0.02	0.00	0.05	4.52	0.00	0.22	4.63
	양하Twin	0.00	0.00	-0.08	-6.50	0.00	0.17	5.93
	선석위치	0.27	0.05	0.03	5.67	0.00	0.93	1.07
	1라인F	0.01	0.00	0.05	3.86	0.00	0.15	6.82
	기타물량	0.02	0.00	0.04	4.69	0.00	0.45	2.20
	1라인E	0.02	0.01	0.04	3.74	0.00	0.24	4.08
	3라인E_tw	0.02	0.01	0.04	3.62	0.00	0.24	4.16
	2라인F	0.01	0.00	0.04	2.55	0.01	0.13	7.87
	3라인A	0.01	0.01	0.03	2.44	0.01	0.22	4.47
	공 컨테이너 블록	-0.77	0.34	-0.01	-2.27	0.02	0.99	1.01
	2라인C	0.01	0.01	0.03	2.37	0.02	0.20	5.05
	1라인C	-0.01	0.01	-0.03	-2.25	0.02	0.20	4.89
1라인E_tw	0.01	0.00	0.03	2.19	0.03	0.13	7.49	


*p<.05, 소수점 셋째 자리에서 반올림

5.2.3 Model 3

해당 모형은 야드 장치 위치를 고려한 인공신경망 모형이다. 모든 변수를 투입하여 기계학습을 진행하여 예측치를 측정한다. 앞선 모델에서 도출된 크레인의 수(변수)가 음의 설명력을 가지고 있기 때문에 활성화함수인 Leaky-Relu를 사용하여 음의 가중치를 고려하였다. Adam의 경사하강법을 도입하여 계산시간과 학습횟수를 줄이는 효과를 부여하였다. 과적합을 피하기 위해 검증데이터가 최저이면서 30회이상 학습개선이 나타나지 않을 시 종료를 하는 조건으로 모형을 추정하였다. 훈련 데이터 내 분류된 검증데이터는 33%(1,056개), 실제 훈련 데이터는 67%(2,146개)로 구성하였다. 이는 기계학습과정에서 매번 랜덤 추출된 33%의 검증데이터를 통해 분석을 진행한다. 모든 변수의 훈련 배치수는 랜덤으로 100개 식 투입하여 진행되었다. 최적의 신경망 구조를 찾기 위해 동일한 노드 수를 가지는 Flat 형태의 층을 1층부터 추가하여 시뮬레이션을 진행하였다. 이에 따라 동일한 노드 수 11개를 가지고 15층의 모형이 가장 적합한 것으로 나타났다.

그림 15은 학습횟수에 따라 검증데이터의 평균제곱오차가 줄어드는 과정을 나타낸 그래프이다. 가로축은 학습횟수를 의미하며 세로축은 학습횟수에 따른 검증데이터의 평균제곱오차를 나타낸다. 1회 학습의 초기 평균제곱오차 값은 약 106.89로 해당 그래프를 파악하기 위해 20 이하의 평균제곱오차 값을 표현하였다. 왼쪽 그림은 전체 학습의 진행척도를 나타내며 오른쪽의 그림은 459회 학습에서 본 신경망 모형이 도출된 지점을 나타내고 최저 검증 평균제곱오차 값은 약 3.687로 나타났다. 본 모델이 다른 대상의 데이터를 적용할 경우 과적합의 위험을 파악할 필요가 있다. 이는 앞서 구분한 테스트 데이터를 통해 진행한다. 또한 다른 모델과의 비교를 위해 모델별 테스트 데이터를 투입한 예측치를 검증한다.

그림 15 학습횟수에 따른 평균제곱오차 변화 그래프



5.3 비교 분석

5.3.1 훈련 데이터

훈련 데이터 기반 추정을 통해 훈련된 현황을 판단할 수 있다. 이는 훈련 데이터를 통해 학습 척도가 진행됨을 파악하기 위함이다. 표 16은 절대오차를 통해 도출된 통계를 나타낸다. 모델별 정량적인 비교를 위해 평균절대오차를 서술하였다. 다중회귀모형인 모델 2는 다양한 변수의 투입과 상호 변수 간 간섭 결과로 모델 1의 회귀모형보다 예측력이 낮음을 알 수 있다. 그러나 야드 장치 위치를 고려한 모델 3이 다중회귀모형보다 예측력이 높은 것을 알 수 있다. 인공신경망 모형인 모델 3은 평균적으로 1시간 5분의 절대오차를 나타내고 약 1시간 10분의 편차를 가지는 정보이다.

표 16 훈련 데이터 기반 절대 오차 통계

구분	Model 1	Model 2	Model 3
평균절대오차	1.66	1.74	1.07
절대오차편차	1.50	1.81	1.15

(소수점 셋째 자리에서 반올림, 단위 : 시간)

시각화를 통해 각 모델의 오차를 파악할 필요가 있다. 그림 16의 가로축은 훈련 데이터의 총 양·적하 물량을 세로축은 실측값과 추정값의 오차를 나타낸다. 하역작업시간은 대형선의 추세를 반영한 물량에 따라 증가하며 물량에 따른 추정 정도를 파악하기 위해 비교 대상 값으로 선정하였다. 모델별 최대 오

차 편차가 다르며 오차 편차의 시각적 비교를 위해 세로축의 범위를 음의 15시간부터 양의 15시간까지 설정하였다. 물량이 낮은 구간은 모든 모형이 일반화된 추정력이 낮고 이는 다중회귀모형 및 인공신경망 모형의 적용이 유의미한 것으로 볼 수 있다. 그러나 모델 1과 2는 총 양·적하 물량이 증가함에 따라 하역작업시간 오차의 간격이 커지나 모델 3의 경우 상대적으로 오차의 간격이 좁음을 알 수 있다. 이는 인공신경망 모형이 증가하는 물동량에 대비하여 일반화 및 학습 정도가 높게 추정되는 것을 알 수 있다.

그림 11을 바탕으로 총물량은 상대적으로 낮은 물량에서 많은 빈도가 발생하며 훈련 데이터를 통한 모델 학습의 일반화(오차)가 낮은 물량 구간의 발생하는 빈도의 밀집도를 알 수 없다. 따라서, 밀도 그래프를 통해 오차 데이터를 시각적으로 볼 필요가 있다.

그림 17은 해당 오차 산점도 그래프의 밀도와 빈도를 나타낸다. 오차의 히스토그램을 통해 모델 3가 가장 높은 밀도를 가지며 이는 앞서 제시된 표 16을 통해 수치로 입증된다. 모든 모형의 오차는 음과 양의 5시간 내 밀집된 것을 알 수 있다. 모델 1과 2는 묘사된 등곡선 밀도가 유사하며 인공신경망 모형의 등곡선 밀도는 상대적으로 안정적으로 밀집된다. 하역작업시간과 5시간의 오차는 상당한 차이를 두고 있으며 상대적으로 오차가 낮고 밀도가 큰 인공신경망 모형이 학습 일반화가 높은 것을 알 수 있다.

그림 16 모델별 오차와 총 양·적하 산점도

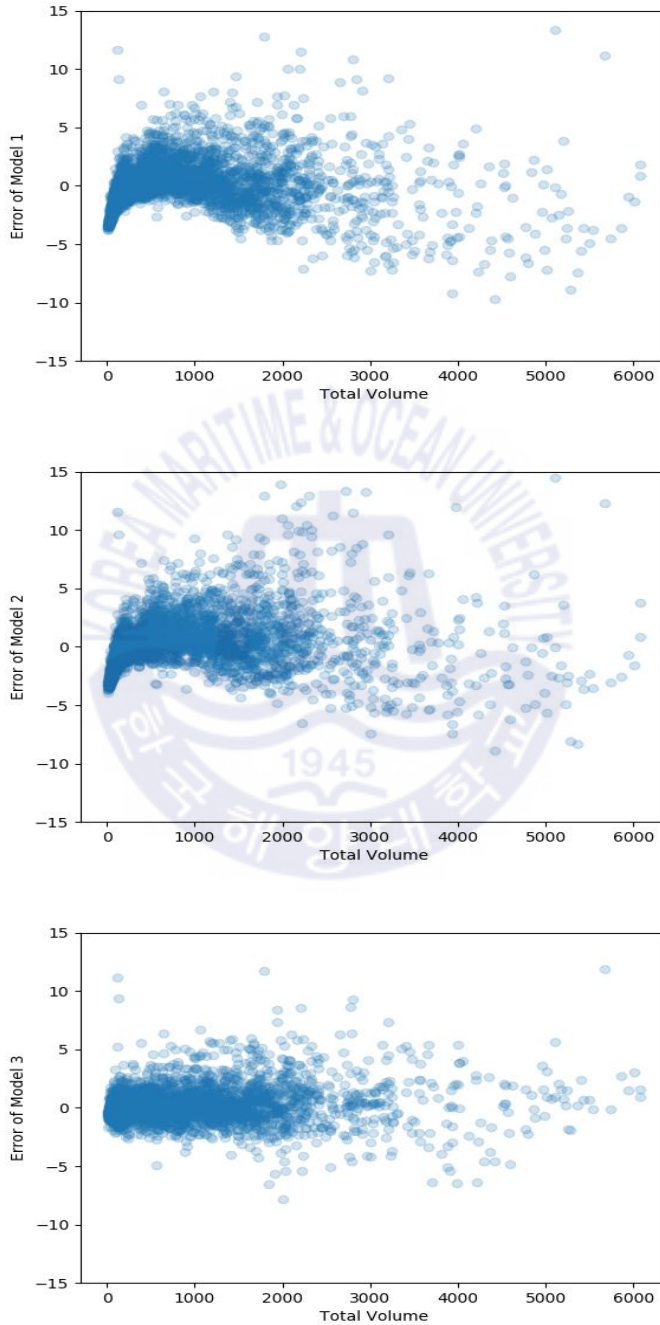
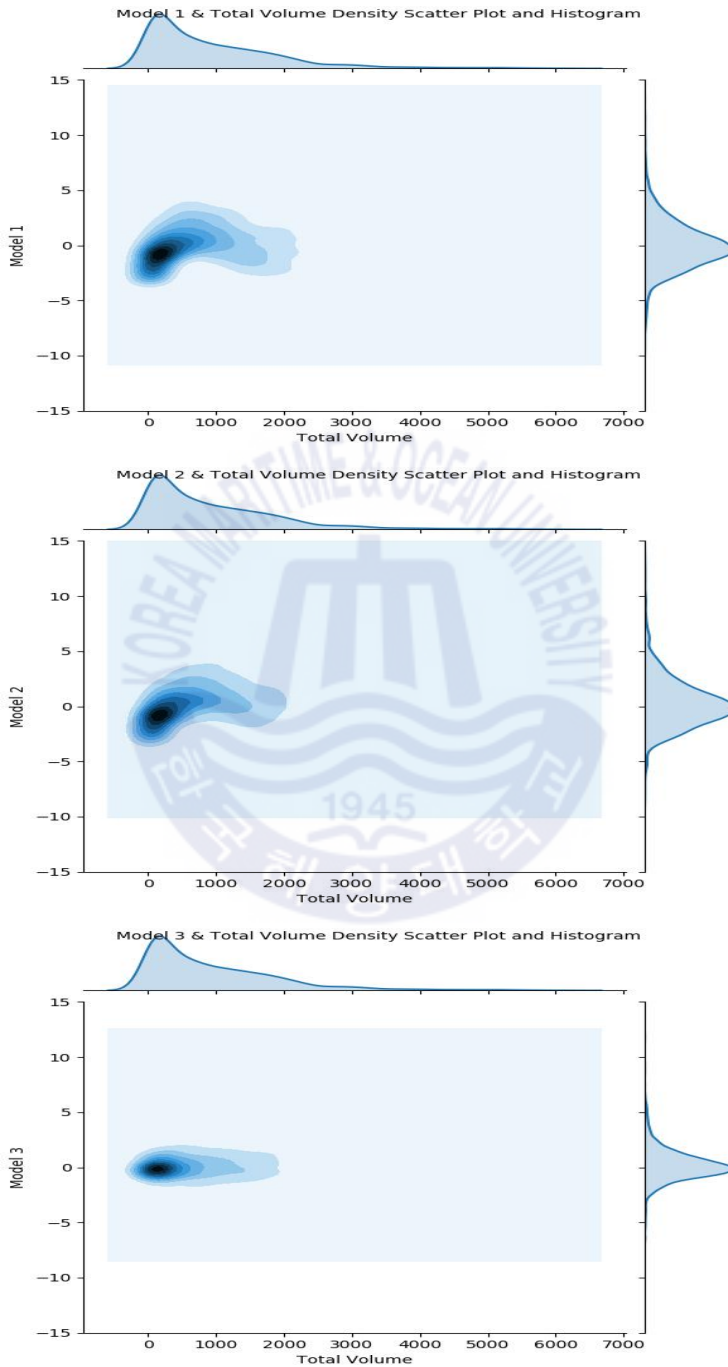


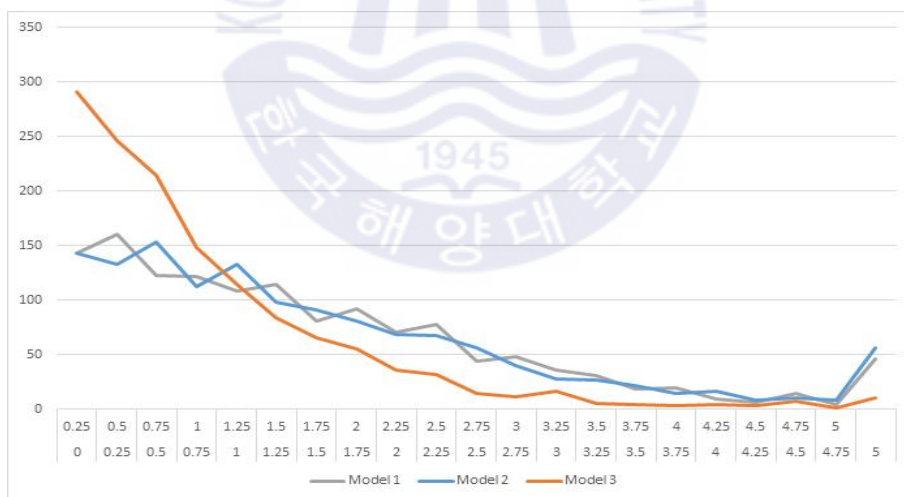
그림 17 모델별 오차와 총 양·적하 밀도 그래프



총 양·적하 물량이 증가함에 따라 하역작업시간 오차의 간격이 퍼지는 것을 알 수 있었다. 이는 앞선 그림 10의 산점도를 고려할 때 해당 모델의 선형적인 예측으로 인해 추정값과의 차이로 나타난다. 반면 인공지능망 모형인 모델 3은 총 양·적하 물량이 증가함에 따라 오차값의 차이가 상대적으로 낮은 것으로 파악된다. 이는 기계 학습에서 물량이 많은 구간에서도 학습이 반영되어 추정치를 확인해 나가는 것으로 파악된다.

학습 정도 및 밀집의 수치 비교를 위해 그림 18은 절대오차의 히스토그램을 나타낸다. 단위 구간은 15분으로 설정, 5시간 이상 차이나는 오차를 하나의 집단으로 구분하였다. 모델 3의 상대적으로 낮은 범위의 오차 빈도수가 가장 밀집된 형태를 나타내며, 모델 1과 모델 2는 유사한 형태의 그림을 나타낸다. 1시간 내 오차 기준으로 모델 3의 빈도수는 1,015개(약 65.5%), 모델 2의 빈도수는 675개(약 39.4%), 모델 1의 빈도수는 656개(약 39.8%)를 나타낸다.

그림 18 훈련 데이터 기반 절대오차 히스토그램



결과적으로 학습력(일반화) 이(가) 가장 높은 인공지능망 모형이 향후 데이터 및 물동량에 따른 대형선박 입항 시 상대적으로 적합한 것으로 볼 수 있다. 그러나 인공지능망의 단점인 일반화가 새로운 데이터를 받아들이지 못하는 과적합의 문제를 제시할 수 있다. 따라서 모든 모델과 동시 상호비교와 인공지능망의 과적합 여부를 확인하기 위해 구분된 테스트 데이터를 활용하여 파악한다.

5.3.2 테스트 데이터


각 훈련된 모델이 얼마나 새로운 데이터에 적응하는지 확인할 필요가 있다. 이는 학습 진행된 모형이 실제 새로운 데이터 대상으로 볼 수 있는 테스트 데이터의 예측 척도를 파악하여 비교하고 인공지능망의 과적합 문제를 발견하기 위함이다. 표 17은 이를 나타낸다. 모델별 정량적인 비교를 위해 평균절대오차를 서술한다. 다중회귀모형인 모델 2는 다양한 변수의 투입과 선형적인 결과로 모델 1의 회귀모형보다 예측력이 떨어지고 앞선 테스트 데이터를 통해 제시된 오차 통계와 유사하다. 반면, 야드 장치 위치를 고려한 모델 3이 다중회귀모형보다 예측력이 상대적으로 높은 것을 알 수 있다. 인공지능망 모형인 모델 3은 평균적으로 1시간 20분의 절대오차를 나타내고 약 1시간 30분의 편차를 가지는 정보이다.

표 17 테스트 데이터 기반 오차 통계

구분	Model 1	Model 2	Model 3
평균절대오차	1.72	1.85	1.31
절대오차편차	1.62	1.78	1.54

(소수점 셋째 자리에서 반올림, 단위 : 시간)

그림 19 테스트 데이터 기반 절대오차 히스토그램



예측력의 척도를 파악하기 위해 시각화된 오차 히스토그램을 제시한다. 그림

19는 계급 구간의 증가를 15분으로 설정한 절대오차 히스토그램이다. 절대오차가 5시간 이상은 모두 하나의 집단으로 처리한다. 모델 3의 상대적으로 낮은 범위의 오차 빈도수가 가장 밀집된 형태를 나타내며, 모델 2와 모델 1은 유사한 형태의 그림을 나타낸다. 1시간 내 오차 기준으로 모델 3의 빈도수는 609개(약 55.2%), 모델 1의 빈도수는 429개(약 39.1%), 모델 2의 빈도수는 402개(약 37.7%)를 나타낸다.

결과적으로 과적합의 문제를 해소하고 한정된 제원 공간 내 야드 장치 위치를 고려한 인공지능망 모형이 향후 증가하는 물동량 및 선박의 새로운 데이터 적용 시 적합한 것으로 판단된다. 이는 더 나은 하역작업시간 추정을 제시하여 터미널 스케줄링 및 운영 효율에 기여 할 것으로 판단된다.



제 6 장 결 론

본 논문은 증가하는 컨테이너 물동량에 한정된 저장 능력을 갖춘 항만 컨테이너 터미널의 현황을 파악하고 장치장 내 블록의 화물 배치 형태에 따른 하역 작업시간 추정을 다중회귀모형과 인공신경망 모형을 통해 제시하였다.

첫째, 훈련데이터와 테스트 데이터를 구분하였다. 모형의 학습과 실제 예측력 정도를 비교분석을 위해 훈련 데이터와 테스트 데이터를 구분하였다.

둘째, 물량정보와 야드 장치 위치 정보를 고려하였다. 단순 물량 정보의 예측력과 야드 장치 위치 정보의 예측력을 파악하기 위해 구분하여 진행하였다.

셋째, 다중회귀와 인공신경망 모형을 고려하여 예측을 시행하였다. 다중회귀 모형에 있어 단순 물량정보와 야드 장치 위치 정보를 고려하고 인공신경망 모형에서 야드 장치 위치 정보를 고려하였다. 회귀모형에서 공선성의 문제가 나타나며 모든 변수를 고려하고 변수의 패턴을 학습하는 인공신경망 모형을 고려하였다.

단순 물량 정보와 야드 장치 위치 정보를 동시에 고려하여 분석결과 다중회귀모형 중 일반 단순 물량의 정보가 하역작업시간 설명력이 높음을 알 수 있었다. 다중 회귀모형에 있어 야드 장치 위치 정보는 여러 변수의 공선성으로 인해 단순 물량 정보보다 낮은 예측력의 결과를 나타냈다. 반면, 야드 장치 위치 정보를 고려한 인공신경망 모형 예측력이 가장 높은 결과를 나타냈다. 이는 기계학습에 반영되는 인공신경망의 특징인 가중치를 조절해 나감으로 하역작업시간에 반영되는 결과를 나타낸다.

결과적으로 모형 간 비교를 통해 인공신경망 모형을 이용한 야드 장치 위치 정보가 더 나은 하역작업시간 추정을 제시하여 터미널 스케줄링 및 운영 효율에 기여할 것으로 판단된다.

연구의 한계점으로

첫째, 일반적인 물량 변수는 하역작업시간의 증감을 간주하는 결과를 나타내며 효율적인 분석을 위해 주성분 분석이 선행되어야 한다. 그러나 야드 장치 위치를 고려한다는 관점하에 진행되며 모형 학습에 유의미한 연구결과를 도출한 것으로 볼 수 있다.

둘째, 인공지능망 모형이 최적의 예측 모형을 제시하는 것은 아니며 다양한 예측 방법을 적용하여 분석이 진행되어야 한다. 그러나 야드 장치 위치를 고려한 변수의 패턴과 기계 학습을 통해 더 나은 예측치를 제공하는 점에서 유의미한 결과를 도출한 것으로 볼 수 있다.

셋째, 물량 구간별 데이터 표본의 차이로 인해 부족한 추정력을 내포하고 있다. 앞선 층화추출법을 통해 학습데이터와 테스트 데이터를 구분하여 진행하였으나 물량이 많은 항차 선박의 경우 상대적으로 적은 표본의 수를 가지고 있으며 이는 학습력이 떨어지는 결과를 나타낼 수 있다. 그러나 학습 오차를 인공지능망 모형이 물량이 많은 구간에서 학습이 반영된 결과를 나타내고 향후 컨테이너 터미널의 입출항 대형선박의 증가의 따라 실증적인 데이터 수가 증가하여 향후 분석에 보완 및 반영할 수 있어 유의미한 것으로 볼 수 있다.

향후 연구 방향으로 하역작업시간의 오차 데이터의 특성을 모아 다양한 관점을 고려한 분석을 진행해 볼 필요가 있다. 예시로 항만에서 1시간 이상의 오차는 다음 스케줄링 선석에 크게 영향을 미치며 이는 터미널 생산성과 운영 효율성 저하를 유발한다. 오차 시간대별 특성을 파악하고 추가적으로 고려할 수 있는 다양한 변수를 선정 및 분석을 진행하여 예측력을 높일 필요가 있다. 따라서, 단일 모형이 아닌 앙상블(Ensemble) 모형을 적용하여 추후 물량 구간별 적합한 추정모형을 적용, 향후 터미널 제원의 변화와 증가하는 물량에 대응하여 하역작업시간 예측력을 높일 것으로 볼 수 있다. 또한 항차 선박이 가지는 컨테이너 물량을 도식화하여 새로운 관점인 패턴을 학습한 CNN(Convolutional Neural Network) 모형으로 예측 진행을 해볼 수 있다.

참 고 문 헌

<논문>

윤신휘, 하병현(2017), 선박 물류 프로세스의 실시간 서비스 완료시간 예측에 대한 연구, *한국전자거래학회지*, 17(2), pp 149-163.

박영규(2016), 컨테이너 터미널에서 이웃 베이를 활용한 컨테이너 재정돈 계획, *한국항해항만학회지*, Vol. 40, pp 113-120.

김병주(2015), 수입컨테이너 특성인자를 고려한 장치위치 결정방법, 부산대학교 석사학위논문.

원태완(2011), 컨테이너터미널의 생산성에 미치는 요소 및 효율성 증대에 관한 연구, 한국해양대학교 석사학위논문.

정창윤(2009), 컨테이너 터미널의 효율적인 선적 작업을 위한 Dual Cycle 계획, 한국해양대학교 석사학위 논문.

최상희, 하태영(2006), 컨테이너터미널의 야드배치 형태별 생산성 분석에 관한 연구, 한국해양수산개발원, *해양정책연구*21(1), pp 151-183.

강재호, 류광렬, 김갑환(2004), 장치장에서 베이 내 컨테이너의 효율적인 재정돈 방안, *한국지능정보시스템학회*, 2004년 11월 추계학술대회, pp 2587-295.

Feng. Chu. et al(2019), "Scheduling multiple yard cranes in two adjacent container blocks with position-dependent processing times", *Computers & Industrial Engineering*, 136, pp. 355-365.

Qingcheng. Zeng. et al(2019), "Intergrated optimization of pickup sequence and container rehandling based on partial truck arrival information", *Computers & Industrial Engineering*, 127, pp 366-382.

Caimao. Tan. et al(2017), "Storage yard management based on flexible yard template in container terminal", *Advanced Engineering Informatics*, 34, pp 101-113.

Ulf. Speer., Kathrin. Fischer. (2016), "Scheduling of Different Automated Yard Crane Systems at Container Terminals", *Transportaion Science*, 51, pp 305-324.

<웹사이트>

https://www.joc.com/port-news/asian-ports/port-jawaharlal-nehru/psa%E2%80%99s-jnpt-terminal-poised-accelerated-growth_20190502.html, 그림 5 참고.